

# SAĞLIK BİLİMLERİNDE YAPAY ZEKA

ARTIFICIAL INTELLIGENCE IN HEALTH

Yıl: 1 Sayı:1 2021

SCIENCES

Year: 1 Issue:1 2021



## EDİTÖR KURULU / EDITORIAL BOARD

## Dergi Sahibi &amp; Kurucu / Owner

Dr. Öğr. Üyesi Ali Murat Koç  
İzmir Katip Çelebi Üniversitesi, Tıp Fakültesi

## Baş Editör / Editor-in-Chief

Dr. Öğr. Üyesi Ali Murat Koç  
İzmir Katip Çelebi Üniversitesi, Tıp Fakültesi /  
Radyoloji  
alimuratkoc@gmail.com

## Editörler / Editors

Prof. Dr. Aydın Akan  
İzmir Ekonomi Üniversitesi,  
Elektrik-Elektronik Mühendisliği  
akan.aydin@ieu.edu.tr

Prof. Dr. Melih Bulut  
Çocuk Cerrahisi  
drmelihbulut@gmail.com

Prof. Dr. Tülay Yıldırım  
Yıldız Teknik Üniversitesi, Elektrik Elektronik  
Fakültesi / Elektronik ve Haberleşme  
Mühendisliği  
tulay@yildiz.edu.tr

Doç. Dr. Mümin Alper Erdoğan  
İzmir Katip Çelebi Üniversitesi, Tıp Fakültesi /  
Fizyoloji  
muminalper.erdogan@ikcu.edu.tr

Doç. Dr. Çiğdem Selçukcan Erol  
İstanbul Üniversitesi / Enformatik  
cigdems@istanbul.edu.tr

Doç. Dr. Esra Meltem Koç  
İzmir Katip Çelebi Üniversitesi, Tıp Fakültesi / Aile  
Hekimliği  
emeltemkoc@gmail.com

Doç. Dr. Aytuğ Onan  
İzmir Katip Çelebi Üniversitesi, Mühendislik-  
Mimarlık Fakültesi / Bilgisayar Mühendisliği  
aytug.onan@ikc.edu.tr

Dr. Öğr. Üyesi Can Özlü  
Kütahya Sağlık Bilimleri Üniversitesi, Evliya Çelebi  
Eğitim ve Araştırma Hastanesi / Hematoloji  
can.ozlu@ksbu.edu.tr

Uzm. Dr. İlker Özgür Koska  
Hatay Devlet Hastanesi / Çocuk Radyolojisi  
ozgurkoska@yahoo.com

## İstatistik Editörü / Statistical Editor

Doç. Dr. Mustafa Agah Tekindal  
İzmir Katip Çelebi Üniversitesi, Tıp Fakültesi /  
Biyostatistik  
matekindal@gmail.com

## Dil Editörü / Language Editor

Dr. Cemal Kavasogulları  
Yakın Doğu Üniversitesi, Sağlık Bilimleri Fakültesi /  
Sağlık Yönetimi  
cemal.kavasogullari@neu.edu.tr

## Hukuk Editörü / Law Editor

Dr. Başak Ozan Özparlak  
Özyeğin Üniversitesi, Hukuk Fakültesi  
basak.ozan@ozyegin.edu.tr

SAĞLIK BİLİMLERİNDE YAPAY  
ZEKA DERGİSİ

2021

Cilt / Volume:1

Sayı / Issue 1

Sağlık Bilimlerinde Yapay Zekâ Dergisi yayım dili Türkçe ve İngilizce olan, yılda üç kez (Nisan, Ağustos ve Aralık aylarında) yayımlanan uluslararası, hakemli bir bilimsel dergidir.

SBYZD açık erişimli ve ücretsizdir.

Yazım kuralları ve dergi hakkında detaylı bilgiye [www.jaihs.com](http://www.jaihs.com) adresinden ulaşılabilir.

Journal of Artificial Intelligence in Health Sciences is an international, refereed, scientific journal published three times a year (April, August and December) in Turkish and English.

JAIHS is a free, open access journal.

Author guidelines and detailed information about the journal can be found at [www.jaihs.com](http://www.jaihs.com).

©Her hakkı saklıdır. Bu dergide yer alan yazı, makale, fotoğraf ve illüstrasyonların elektronik ortamlarda dahil olmak üzere kullanma ve çoğaltılma hakları Sağlık Bilimlerinde Yapay Zekâ Dergisine aittir. Yazılı ön izin olmaksızın materyallerin tamamının ya da bir bölümünün çoğaltılması yasaktır. Dergi Basım Meslek İlkeleri'ne uymaktadır.

©All rights are reserved. Rights to the use and reproduction, including in the electronic media, of all communications, papers, photographs and illustrations appearing in this journal belong to JAIHS. Reproduction without prior written permission of part or all of any material is forbidden. The journal complies with the Professional Principles of the Press.

## ÖĞRENCİ EDITÖRLER / STUDENT EDITORIAL BOARD

Yavuz Kağan Aydem  
İstinye Üniversitesi, Tıp Fakültesi

Bilge Aydemir  
İzmir Katip Çelebi Üniversitesi, Tıp Fakültesi

İrem Candan  
İzmir Katip Çelebi Üniversitesi, Tıp Fakültesi

Dilan Erbaş  
İzmir Katip Çelebi Üniversitesi, Tıp Fakültesi

Elif Damla Karakolcu  
İstanbul Üniversitesi, Moleküler Biyoloji ve Genetik,  
Yönetim Bilişim Sistemleri

Hilal Metin  
Bahçeşehir Üniversitesi, Moleküler Biyoloji ve  
Genetik

Elif Mut  
İzmir Katip Çelebi Üniversitesi, Tıp Fakültesi  
Berke Can Ongun

Bahçeşehir Üniversitesi, Elektrik – Elektronik Mühendisliği

Ceyda Ünal  
Dokuz Eylül Üniversitesi, Yönetim Bilişim Sistemleri

## Danışma Kurulu / Advisory Board

**Prof. Dr. Mutlu Avcı**  
Çukurova Üniversitesi / Biyomedikal  
Mühendisliği

**Prof. Dr. Serhat Burmaoğlu**  
İzmir Katip Çelebi Üniversitesi /  
İktisadi ve İdari Bilimler

**Prof. Dr. Ali Serdar Fak**  
Marmara Üniversitesi / Kardiyoloji

**Prof. Dr. Rabia Kahveci**  
Ukraine Management Sciences for  
Health / Senior Technical Advisor  
on Pharmaceutical Policies and  
Governance

**Prof. Dr. Mustafa Ersel Kamaşak**  
İstanbul Teknik Üniversitesi / Bilgi-  
sayar Mühendisliği

**Prof. Dr. Yusuf Cem Kaplan**  
İzmir Ekonomi Üniversitesi / Tıp  
Fakültesi

**Prof. Dr. Kaan Orhan**  
Ankara Üniversitesi / Dış Hekimliği

**Prof. Dr. Süleyman Sevinç**  
Bilgisayar Mühendisliği

**Prof. Dr. Atadan Tunacı**  
İstanbul Üniversitesi / Radyoloji

**Doç. Dr. Salih Beyaz**  
Başkent Üniversitesi / Ortopedi ve  
Travmatoloji

**Assoc. Prof. Wg. Cdr. Dr. Tossa-  
pon Boongoen**  
Mae Fah Luang University / School  
of Information Technology

**Doç. Dr. Murat Ceylan**  
Konya Teknik Üniversitesi / Elekt-  
rik-Elektronik Mühendisliği

**Doç. Dr. Süleyman Ayhan Çalış-  
kan**  
Ege Üniversitesi / Tıp Eğitimi

**Doç. Dr. Gökhan Bora Esmer**  
Marmara Üniversitesi / Elektrik-E-  
lektronik Mühendisliği

**Doç. Dr. Esin Öztürk Işık**  
Boğaziçi Üniversitesi / Biyomedikal  
Mühendisliği

**Assoc. Prof. Dr. Eng. Olimpiu  
Stoicuta**  
University of Petrosani / Department  
of Control Engineering, Computers,  
Electrical Engineering and Power  
Engineering

**Doç. Dr. Leyla Türker Şener**  
İstanbul Üniversitesi / Biyofizik

**Dr. Öğr. Üyesi Gökbalp Tulum**  
İstanbul Arel Üniversitesi, Mühen-  
dislik-Mimarlık Fakültesi

**Öğr. Gör. Dr. Murat Gezer**  
İstanbul Üniversitesi / Enformatik

**Uzm. Dr. Nevit Dilmen**  
Sonomed / Radyoloji

**Uzm. Dr. Mehmet Ali Gedik**  
Kütahya Sağlık Bilimleri Üniversite-  
si / Radyoloji

**Uzm. Dr. Sedat İrgil**  
Psikiyatri

**Uzm. Dr. Ayşe Nilüfer Köylüoğlu**  
Kütahya Sağlık Bilimleri Üniversite-  
si / Göz Hastalıkları

**Dr. Abdüssamet Aslan**  
Tıp Doktoru

**Dr. Salih Tutun**  
Washington University in St. Louis /  
Data Analytics

**Dr. Yusuf Yeşil**  
İstanbul Üniversitesi / Tıbbi Biyo-  
kimya

**Öğr. Gör. Önder Öztürk**  
Kütahya Sağlık Bilimleri Üniversite-  
si / Bilgisayar Mühendisliği

**Emel Gümüş**  
İstinye Üniversitesi / Sağlık Kurum-  
ları İşbirliği Koordinatörü

## İçindekiler / Contents

---

Editörden-I .....	
Editörden-II .....	
Pandemi Döneminde Tıp Fakültesi Öğrencilerine Simülasyon Tabanlı Online Eğitim: Biyofizik Örneği .....	1-5
Sağlık Veri Setlerinde Öznitelik Seçiminin Sınıflandırma Performansına Etkisi .....	6-11
Ortopedi ve Travmatolojide Yapay Zeka Uygulamaları .....	12-15
Covid-19 Pandemic and Investigation of Artificial Intelligence Applications Used in the Pandemic .....	16-23
Kızılıötesi Termal Görüntülemenin Yapay Zeka Tabanlı Biyomedikal Uygulamaları.....	24-34
Sağlık Çalışanları Yapay Zekaya Hazır Mı ?.....	35

# Editörden / Editorial

Değerli Okuyucularımız,

Sağlık Bilimlerinde Yapay Zeka Dergisi (Journal of Artificial Intelligence in Health Sciences)'nin ilk sayısını çıkarmış olmanın heyecanını ve mutluluğunu sizlerle paylaşıyoruz.

Tamamen bağımsız, akademik bir girişim sonucu ortaya çıkan Sağlık Bilimlerinde Yapay Zeka Dergisi'ne Türkçe ve İngilizce makaleler kabul edilmektedir. Sağlık Bilimlerinde Yapay Zeka Dergisi Nisan, Ağustos ve Aralık aylarında yılda toplam üç kez basılacak olup sağlık bilimleri ve yapay zeka uygulama alanlarında makaleler yayımlayacaktır. İki disiplini bir araya getiren yazıların yer alacağı Sağlık Bilimlerinde Yapay Zeka Dergisi'nde; editörler, danışma kurulu üyeleri ve hakemler de bu vizyona uygun olarak farklı disiplinlerden akademisyenlerden oluşmaktadır. Dergimizde, seçkin yurt dışı örneklerde uygulanan öğrenci editör (student editorial board) sistemi benimsenmiştir. Bu yaklaşım ile akademik potansiyeli olan gençlerin de dergi işleyişine katkı sağlayarak tecrübe edinmesi hedeflenmektedir. Çift-kör hakemli bir dergi olan Sağlık Bilimlerinde Yapay Zeka Dergisi; deneysel ve klinik çalışmaları, özgün araştırma, derleme, olgu sunumu ve editöre mektup yazılarını yayımlayarak literatüre ve sağlık alanındaki tüm disiplinlere katkı sağlamayı hedeflemektedir. Sağlık Bilimlerinde Yapay Zeka Dergisi, Budapeşte açık erişim politikası doğrultusunda açık erişimli ve ücretsiz yayın yapmaktadır. Dergimizin yayın süreçleri, The International Committee of Medical Journal Editors (ICMJE), World Association Medical Editors (WAME) ve Committee on Publication Ethics (COPE) kriterlerine uygundur. Dergide yayımlanmak üzere gönderilen tüm araştırma makalelerinde etik kurul onay şartı aranmaktadır. Makaleler, benzerlik veya intihal açısından akademik intihal önleme programı iThenticate ile kontrol edilmektedir. Sağlık Bilimlerinde Yapay Zeka Dergisi ilk sayıdan itibaren yayımlanan tüm yazılara DOI (Digital Object Identifier) numarası vermektedir. Hedefimiz, sağlık bilimleri ve yapay zeka birlikteliğinin önemini vurgulayarak ulusal ve uluslararası bilimsel yayımlara ev sahipliği yapan, bu konudaki farkındalığı artıran ve araştırmaya teşvik eden bir dergi haline gelmektir.

Çalışmalarını dergimize gönderen yazarlara, değerlendirmeleri yapan editör ve danışma kurulu üyelerine çok teşekkür ediyoruz. Saygılarımızla

Dr. Ali Murat KOÇ  
Sağlık Bilimlerinde Yapay Zeka Dergisi Baş Editörü

## YAPAY ZEKA SAĞLIĞI DÖNÜŞTÜREBİLİR Mİ ?

İnsanı diğer canlılardan ayıran en önemli özelliği hayal gücünü harekete geçirerek ortak üretim ile bilim yapabilmesi ve teknoloji geliştirebilmesidir. Bunlar sayesinde Tarım Devrimi'ni yaparak dünya üzerindeki varlığımızı pekiştirdik ve bugünkü medeniyet seviyesine ulaştık. Şimdi Bilim Devrimi ile bir büyük dönüşüm daha gerçekleştiriyoruz. Başlığımızın cevabı bana göre evet; dijital teknolojilerin öncülük ettiği bu devrimin öğelerinden biri olan yapay zeka, yaşamın bir çok alanında olduğu gibi tıp ve sağlık uygulamaları üzerinde de dönüştürücü etkisini gösteriyor.

Bir teknoloji veya yeniliğin “Dönüştürücü” olarak tanımlanması için öncelikle ilgili alana ait temel uygulama felsefesinde, ve alanın paradigmalarında anlamlı değişikliklere yol açması lazımdır. Bu yazımızda tartışacağımız üzere yapay zeka; insan sağlığı ile ilgili öngörülerimizi moleküler düzeyden başlayarak o kadar geliştiriyor ki tıbbın Hipokrat'tan beri süregelen “Önce Zarar Verme” prensibini hızla aşabiliyoruz. Bununla beraber; ilgili alanın tüm bileşenleri üzerinde, dönüştürücü teknolojinin olumlu veya olumsuz etkilerinin görülmesi lazım. Örneğin yapay zekayı mikroskobun keşfi ile kıyaslasak şimdye kadar hiçbir yeniliğin sağlığın bileşenlerini böylesine geniş bir kapsamda etkilemediğini öne sürüyorum. Burada konumuz sağlık olduğu için sağlığın üçlü sacayakları şeklinde, yani üçü bir arada- olmazsa olmaz biçiminde tarif ettiğimiz temel bileşenlerini hatırlatmakta yarar var. Sağlık bedence, akılca ve sosyal iyilik halidir; ve bu iyilik hali bireysel, toplumsal ve evrensel düzeyi kapsamalı ve sürdürülmelidir. Sağlığı korumak, tedavi kadar hatta daha da fazla önemlidir. Sağlığı geliştirici ortamlarda yaptığımız iş, daima eğitim ve araştırma faaliyetleriyle desteklenen hizmetleri sunmak olmalıdır. İşte yapay zeka tüm bu bileşenleri olumlu yönde ve derinden etkileyebilecek dönüştürücü güce sahiptir.

Yapay zeka, insan evladının çok eski bir rüyasıydı; antik metinlerde bile izlerini görmek mümkün. 1950'lerden itibaren teknolojik olanakların el vermesiyle birlikte bugün yapay zeka üretebilir hale geldik. 20. Yüzyıl, hastalıklarla mücadelenin ön planda olduğu; halk sağlığı düşünürlerinin gösterdiği hedeflerin aksine çeşitli tercihler ve imkanlarla sağlık hizmetinin hastalık, hastane, uzman doktor üçgeninde sıkıştığı bir zaman dilimiydi. Doğal olarak yapay zeka çalışmaları da uzun süre hastalıklarla çeşitli şekillerde mücadelenin bir aracı olarak kullanılmak istendi ve bir hayli başarılı da olundu. Halbuki yapay zeka, bilgi, bilişim, iletişim ve internet teknolojilerinin sağlıkta kullanımı demek olan dijital sağlık teknolojileri ile beraber bize bütünsel iyilik hali olarak tanımlanan sağlık durumunu ayrıntılı matematiksel parametrelerle belirlememizde çok yardımcı olabilir. Aslında sağlığı bir bütün olarak tanımlamaya her bakımdan çok ihtiyacımız var. Analizler için teknoloji geliştikçe çeşitli göstergelerle organ ve dokuların fonksiyonlarını bu teknolojilerle incelemek, hekimlerin en önemli işi oldu. Bazı madde, enzim veya belirteçlere bakarak durumu anlamaya çalışıyoruz; ama bunların birbirleriyle etkileşimlerini saptamakta bile çok yetersiz kalıyoruz. Yapay zekanın katkısıyla yakın bir gelecekte karaciğer ile pankreasın nasıl etkileştiğini (bir bakıma organların interneti) ve nesnelerin interneti ile birlikte organların internetini ve bunlardan aldığımız tüm verileri birlikte işlemeyi, dolayısıyla organ fonksiyonlarını daha geniş bir bakış açısıyla değerlendirebilme olanağını elde edebiliriz. Bu bilgilerle insan vücudunu, sağlığı ve hastalıkları çok farklı yönleriyle anlamaya başlayabiliriz.

Tıp ister muayene ister laboratuvar bulguları olsun, veriye dayanır. Bir hastayla ilgili olarak edindiğiniz deneyimi diğer benzer hastanızda kullanırsınız. Ancak şu anda hastalıklarda ve sağlıkta bilimsel bilgi üretmek için kullandığımız veri çok dar kapsamlı ve depolama, işleme gücümüzün azlığı nedeniyle sınırlı. Yapay zeka, bize çevresel faktörlerden kişinin alışkanlıklarına kadar çok geniş bir yelpazeyi birlikte değerlendirme olanağı sunarak gerçekten “Veriye Dayalı Sağlık” anlayışının ve “Veriye Dayalı Tıp” uygulamasının önünü açıyor. Bu imkan, tıpta her şey değilse de önemlidir. Çünkü insan vücudu bir bütün, insan çevresiyle ve doğayla bir bütün; sağlığa bütünsel yaklaşım yapmadıkça hastalıkların önlenme ve tedavisinde kalıcı başarı elde etmek mümkün değil. Yapay zeka, elde ettiğimiz verileri çeşitlendirerek ve çoğaltarak bedensel sağlıkta bütüne bakmamızı kolaylaştırıyor. Üstelik bize hücrede olan biteni anlamak için yardımcı olduğu gibi; dokuda, sistemlerde, vücutta, toplumda ve hatta evrensel düzeyde verileri bir araya getirerek değerlendirebilme olanağı sağlıyor. Böylesi geniş etkiye sahip bir teknolojiye doğrusu daha önce hiç sahip olmadık.

Yapay zekanın tedavi hizmetlerine olan katkıları hakkındaki yayınlara yetişmek artık neredeyse mümkün değil.

# Editörden / Editorial

Tıp, sağlık ve temel bilimlerdeki anlamlı ve tedavide kullanılabilir bilgi birikimimizin son yıllarda çok hızlı artmasında yapay zekanın büyük rolü var. Bunun yanı sıra sağlığın korunma ve geliştirilmesinde de önemli desteği olabilir. Yapay zeka ile bir bölgede salgın olasılığını, hipertansif hastaların inme geçirme durumunu, hangi sporcuların antrenmanda hangi adalelerinden sakatlanacağını, periferik yaymada hangi hücrelerin malign olma potansiyeli taşıdığını belirleyebiliyoruz; erken tanı için farklı düzeylerde öngörüye sahip olabiliyoruz. İşte bu da bize “Önce Zarar Verme” mottosundan “Öngörü İle Sağlığı Geliştirme” aşamasına bir sıçrama şansı veriyor. COVID-19 acı tecrübesinin ABD başta tüm dünyaya öğrettiği üzere tedavi edici sağlık hizmetlerinde çok iyi olmak salgın gibi yaygın bir halk sağlığı sorununda işe yaramıyor. Geleceğin tıbbının ve sağlık anlayışının sağlığı koruma ve geliştirme ekseninde olacağı ve yapay zekanın bu alanlara çok katkı yapacağı bugünden belli oluyor.

Sağlığın önemli bileşenlerinden birisi de araştırmadır. Yapay zeka yeni ilaç moleküllerinin keşfinde çok yararlı, bir hastalık için binlerce aday molekülü birkaç taneye indirilebiliyor, böylece ilaç geliştirme kolaylaşıp ucuzluyor. Keza eski ilaçları yeni durumlarda konumlamak için de yapay zeka yaygın kullanılıyor. Bir firmanın COVID-19 için geliştirdiği aşının tasarımında yapay zekadan yararlanması ilginç bir gelişme oldu. Veri işleyen yapay zeka programları sayesinde normalde yıllar sürecek veriye dayalı araştırmaları günler, hatta saatler içinde tamamlayabilir hale geldik. Bunlar kadar önemli bir gelişme yapay zekanın, bilhassa derin öğrenme ve yapay sinir ağlarının temel bilim araştırmalarında kullanılmasıdır. Böylelikle temel bilimlerde birkaç yıl öncesine kadar hayal bile edemeyeceğimiz ilerlemeleri yapabilir hale geldik. Bugün üst düzeyde kimya, fizik, matematik bilgisi olmadan hücre biyolojisi konusunda bir buluş ortaya koymak neredeyse olanaksız. Bu ise o kadar kolay değil, hatta neredeyse imkansız. İşte yapay zeka sayesinde herkesin bin bilimli (hezarfen-polymath) olması yolu açılıyor.

Yapay zeka karar destek sistemi olarak şimdiden pek çok hastalıkta neredeyse rutine girmiş durumda. Burada doğruluk kadar önemli bir avantajı hızlı olması, çok kısa sürede yüzlerce binlerce tetkiki inceleyebiliyor. Bir radyoloji uzmanının günler sürecek iş yükünü dakikalar içinde üstünden alıyor. Hız yanında bu işlemleri mekandan bağımsız olarak yapabilir olması da büyük bir avantaj. Örneğin bir hastada inme nedeninin kanama mı yoksa damar tıkanması mı olduğunu tetkik yapıldıktan dakikalar sonra yapay zeka sayesinde öğrenebilir ve uzman hekime 7/24 ulaşmanın zorluklarını yaşamadan hastanın tedavisini planlayabilirsiniz. Zaman ve mekandan bağımsız sağlık hizmetinin değeri COVID-19 ile daha da iyi anlaşıldı. Teletıp başta olmak üzere bundan sonra dijital sağlık teknolojilerinin ve yapay zekanın eskisi kadar direnç görmeyeceğini öngörmek mümkün. Zaman ve mekandan bağımsızlık şimdiye kadar sağlık hizmetine erişim sorunları yaşamış dezavantajlı gruplar için de büyük olanaklar sağlamakta. Belki de tarihte ilk defa sağlığa erişim herkes için her bakımdan daha kolay hale gelecek, devletlerin işi kolaylaşacak, teknik imkanlar elverdiğinde sağlıktaki eşitsizlikleri azaltma, tüm insanlar için hakkaniyetle hizmet sunma yolunda anlamlı adımlar atabileceğiz. İlaveten yapay zeka sayesinde cep telefonlarımız mikroskop, ultrasonografi, sperm ölçüm cihazı haline getirilip farklı şekillerde kullanılabilir. Bunlar gerçekten birer devrim.

Şimdiye kadar teknoloji, girdiği tüm sektörlerin aksine, sağlıkta ucuzluk yaratmadı. Yapay zeka ve dijital teknolojilerin, maliyetleri azaltarak, bireyler, aileler, devletler için taşınamaz hale gelen sağlık giderleri ve medikal enflasyon için panzehir olması mümkün. Ayrıca sağlık hizmetinde bütünsel değerlendirmeye yaptığı katkılarla farklı sağlık bileşenleri üzerindeki olumlu etkisi nedeniyle sağlıkta verimliliği arttıracığına şüphe yok. Sağlık sistemlerinde hizmet sunumunda ABD’de %30, OECD ülkelerinde ortalama %20 verimsizlik ile gerçekleşen israf artık hızla sürdürülemez boyuta ulaşmakta. Hizmetin pahalılığının bir nedeni kalifiye ve göreceli olarak pahalı insan gücü ve üstelik kalifiye insanların 24 saat hizmete hazır tutulma zorunluluğu. Yapay zeka ile bu sınırlılığı büyük ölçüde gidermek mümkün. Kalifiye insan gücünün ne yapılırsa yapılsın altından kalkamayacağı sorunlar da var. Diyabetik retinopati buna çok iyi bir örnek. Şu anda dünyanın bütün diyabetiklerini, dünyadaki mevcut oftalmologların 24 saat başka hiçbir iş dahi yapmasalar klinik rehberlerde belirtildiği şekliyle izlemesi mad-detten mümkün değil! Bırakın tüm dünyayı en gelişmiş ülkelerde bile bunu değil yapmak hayal bile etmek imkansız. İşte burada teknolojiyi kullanmanın sihri devreye giriyor. Yapay zeka yardımıyla diyabetik hastaları göz komplikasyonları yönünden rahatlıkla izleyebilir ve en azından sadece ihtiyacı olan hastaları göz hastalıkları uzmanına yönlendirebilir ve verimlilik sağlarız.

Dermatoloji, radyoloji (ve patoloji) gibi görünüm veya görüntü ile tanı koyduğumuz alanlarda yapay zekanın uzman hekimler kadar başarılı olabildiğini biliyoruz. Örnekleri çoğaltmak mümkün, depresyon ve intihar riskini psikiyatri uzmanı kadar iyi belirleyebiliyor. Ancak

# Editörden / Editorial

burada çarpıcı olan, hekim ile yapay zekanın birlikte karar verdiği durumlarda tanıda daha yüksek doğruluk oranlarına ulaşılması ve her bakımdan maliyet demek olan yanlışların çok azalması. Yapay zeka ve sağlığının bir arada çalışmasının eşsiz yararlar sağlayabileceği açık. Ayrıca yapay zeka sağlık personelinin bilgi, tecrübe eksikliğinden kaynaklanan hatalarını önlemede ciddi rol oynayacaktır. Her durumda sağlıkçı ile yapay zeka birbirini denetlemeli ve hataları sıfıra indirmelilerdir.

Bütün dünya hızla yaşıyor, kronik hastalıklar ve kanser çıg gibi artıyor. Hastaneye, sağlık kurumuna başvuran kişilerin karmaşık, çoklu sağlık problemleri ender değil. Bütün bunlar zaten sorunlu sağlık sistemleri üzerine ilave yük bindiriyor ve bu durum sağlık sorunu nedeniyle bir kuruma başvuran veya hastaneye yatan hastaların değerlendirilme ve izlenmesinde yeni çözümler gerektiriyor. Bu konuda da yapay zekanın sağlıkçılara çok destek olacağını öngörmek mümkün. Yapay zeka destekli hastane sistemleri ile hangi hastanın MR çekimine daha önce girmesi gerektiği, çekim esnasında hangi miktarda kontrast madde verilmesi gerektiği belirlenebiliyor. Hastaların, hastaneye adım atmalarından itibaren, ulusal sağlık veritabanından otomatik çekilen bilgileri ile risk profili ve şikayetlerine göre uygun yönlendirilmesi, acil durumların belirlenmesi ve öncelik sıralaması yapay zeka destekli sistemler ile yapılabiliyor. Bu da hem hasta için fayda artışı hem de hastane için maliyetlerin azaltılması anlamına geliyor. Ayrıca doğal dil işleminin gelişmesi ve yapay zekanın desteğiyle sesin yazıya dökülebilmesi; hemşire, hekim ve sağlıkçıların hasta bulgularını elle yazmalarına gerek bırakmayarak kıymetli zamanlarından tasarruf sağlayacak bir başka olanak. Benzeri örneklerin hızla artacağına şüphe yok.

Gelecekteki tıp anlayışında kişiselleşmiş hassas tıp öne çıkıyor. Bunu yapay zekasız gerçekleştirmek mümkün değil. Asırlardır “Hastalık yoktur hasta vardır” dedik ama fiiliyatta hastaları -örneğin tüm meme kanserlerini- aynı protokollerle tedavi etmeye çalıştık. Artık yapay zekanın desteğiyle bazı kanser türlerinde tümörün nasıl davranacağını, hangi kemoterapötik ajanlara duyarlı olduğunu çok daha iyi biliyor, bu bilgiye göre yönlendirme yapabiliyoruz.

Yapay zekanın olumlu etkisinin sağlığın yönetim bileşeninde de her geçen gün arttığını görüyoruz. Evrensel, toplumsal ve kurumsal düzeyde sağlık otoritelerinin ve karar vericilerin bu eşsiz yardımcıdan ihtiyaç duyulan bilgileri derleyerek yönetim fonksiyonunda yararlanması, her düzeyde kaynaklarımızı daha verimli ve etkin kullanmamıza olanak sağlayacaktır. Yapay zekadan alabildiğine faydalanarak sağlık sistemlerimizi hastalık, hastane, tedavi, hekim odaklı olmaktan çıkartabilir; kolayca sağlık, sağlığı geliştiren kurumlar, tedavi ile birlikte koruma ve geliştirme, insan odaklı hale getirebiliriz.

Yapay zeka ve dijital sağlık teknolojileri böyle büyük dönüşümleri tetiklerken tıp ve sağlık mesleklerinin müfredatında yer almaması düşünülemez. Şu anda tüm sağlık mesleklerinde “Önce zarar verme” prensibinin benimsendiğini ve hastalık, hastane, tedavi, hekim odaklı yaklaşımın temel felsefe olarak alındığını; eğitimin, müfredatın bunun üzerine inşa edildiğini görüyoruz. Hızla dönüşen sağlığa, tıp anlayışına uygun eğitim programlarını ve yöntemlerini entegre etmeliyiz. Dijital teknolojiler aslında günün koşullarına, zamanın ruhuna uygun eğitim yapmak için sınırsız imkanlar sunuyor, bunları cesaretle uygulamaya sokmalıyız. Dönüşüm, eğitimde de sancılı olacak ama geleceğimiz için bunu yapmak zorundayız.

Yaşamın tüm alanlarında çok hızlanmış bir değişim dönemi yaşıyoruz. Bilimdeki yeni buluşlar olağanüstü süratle günlük hayatımıza giriyor. Bunlardan biri olan yapay zekanın sağlıktaki dönüştürücü etkisini yaklaşılan bir fırtına gibi hissediyoruz. Bu öyle bir fırtına ki eskinin artık ayağımıza bağ olmaya başlamış ama bir türlü kurtulamadığımız yüklerinden bizi kurtaracak ve baharı getirecek. Hazır olun, yapay zeka sağlığı bütünüyle dönüştürme potansiyelini yerine getirmek için sabırsızlanıyor!

Dr. Melih Bulut, Şubat 2021.



## Pandemi Döneminde Tıp Fakültesi Öğrencilerine Simülasyon Tabanlı Online Eğitim: Biyofizik Örneği

*Simulation-Based Online Education for Medical Students in the Period of Pandemic: An Example of Biophysics*

Güven AKÇAY

### ÖZ

Temel tıp eğitimi, hekimlik eğitiminin birinci ve en temel basamağını oluşturmaktadır. Anatomi, biyofizik, farmakoloji, fizyoloji, histoloji gibi bazı dersler dahili ve cerrahi bilimlere zemin oluşturmaktadır. Bu derslerin hem yoğunluğu hem de zorluğundan dolayı konuların bazen anlaşılması güçleşmekte ve pekiştirilmemektedir. Özellikle pandemi döneminde online eğitim ile uygulama/pratik derslerin yürütülememesi nedeniyle konuların anlaşılması daha da güçleşmektedir. Simülasyon ile gerçekleştirilen derslerin konunun kavranmasına yardımcı olduğu bilinmektedir. Bundan dolayı pandemi sürecinde verilen online eğitimlerde simülasyon uygulamalarının kullanımı konunun anlaşılmasına yardımcı olabilmektedir. Pandemi döneminde tıp fakültesi 1. sınıf öğrencilerinin online eğitimde simülasyon tabanlı öğretimin biyofizik dersindeki genel memnuniyetinin değerlendirilmesi amaçlanmıştır. Araştırma Hitit Üniversitesi Tıp Fakültesi'nde birinci sınıfta öğrenim gören 102 öğrenci katılmıştır. Veriler Google Anket Formu kullanılarak toplanmıştır. Bu çalışmada yer alan memnuniyet anketinde 13 madde yer almaktadır ve iç tutarlılık kat sayısı 0,86 olarak hesaplanmıştır. Buna göre anketin tıp eğitimi veren kurumlarda öğrencilerin memnuniyet düzeylerini belirlemede kullanılabileceği düşünülmüştür. Bu çalışmada pandemi döneminde tıp fakültesi öğrencilerine biyofizik dersinde simülasyon ağırlıklı online eğitiminin öğrencilerin dersten memnuniyet ve beklenti düzeylerinin betimlenmesi araştırılmıştır.

**Anahtar kelimeler:** Simülasyon uygulamaları, Online eğitim, Biyofizik.

### ABSTRACT

Basic medical education constitutes the first and most basic step of medical education. Some courses such as anatomy, biophysics, pharmacology, physiology, histology provide the basis for internal and surgical sciences. Due to both the intensity and the difficulty of these lessons, the topics are sometimes difficult to understand and are not reinforced. Especially during the pandemic period, it becomes even more difficult to understand the issues due to the fact that online education and application/practical lessons cannot be carried out. It is known that the lessons conducted with simulation help to comprehend the subject. Therefore, the use of simulation applications in online trainings during the pandemic process can help to understand the subject. In the pandemic period, it was aimed to evaluate the general satisfaction of the first year students of the Faculty of Medicine in the biophysics course of the simulation-based education in online education. 102 students studying in the first year of Hitit University Faculty of Medicine participated in the research. Data were collected using the Google Survey Form. There were 13 items in the satisfaction questionnaire in this study and the internal consistency coefficient was calculated as 0.86. Accordingly, it is thought that the questionnaire can be used to determine the satisfaction levels of students in institutions providing medical education. In this study, it was investigated to describe the level of satisfaction and expectation of the students in the biophysics course of the medical faculty students during the pandemic period.

**Keywords:** Simulation applications, Online education, Biophysics

Received/Geliş : 11.03.2021

Accepted/Kabul: 31.03.2021

Publication date: 15.04.2021

**Güven AKÇAY**

Hitit Üniversitesi Tıp Fakültesi,

Biyofizik Anabilim Dalı,

Çorum, Türkiye.

guvenakcayibu@gmail.com

ORCID: 0000-0003-3418-8825

Hekim kelimesi Arapçadan Türkçemize geçmiş olup, kelime anlamı olarak hastalıkları teşhis ve tedavi eden kişi olarak tanımlanmaktadır. Özellikle pandeminin yaşandığı günümüzde hekimlerin hayatımızdaki yeri ve önemi bir kez daha yadsınmaz bir şekilde anlaşılmıştır. Tıp fakültesi öğrencileri altı yıllık eğitimlerini tamamlamalarının ardından hekimliğe başlamaktadırlar. Bu altı yıllık eğitimin yaklaşık olarak yarısı (1., 2. ve 3. sınıf) temel bilimlerdeki dersler oluşturmaktadır. Temel tıp bilimleri tıp eğitiminin önemli bir bölümünü oluşturmaktadır. Ayrıca hastalığın tanı, teşhis ve tedavisi gibi aşamalarda temel bilimlere ihtiyaç duyulmaktadır. Bundan dolayıdır ki tıp eğitiminin kalitesinin temelinde temel tıp bilimleri önemli yer tutmaktadır. Nitekim, Nobel Tıp Ödülü'nün çoğunlukla moleküler biyolog, fizyolog, tarafından alınması temel bilimlerin tıpa katkısı olarak değerlendirilebilir (1). Temel bilimleri anatomi, biyoistatistik, biyofizik, fizyoloji, farmakoloji, histoloji ve embriyoloji, moleküler biyoloji, tıbbi biyokimya, tıbbi mikrobiyoloji gibi bölümler oluşturmaktadır. Yirminci yüzyılın ikinci yarısından itibaren biyoloji ve tıp disiplinleri arasında biyofizik önde gelen bir bilim dalı olmuştur (2). Biyofizik, “canlı varlıkların incelenmesinde fiziğin uygulanması” daha kısaca “canlı organizmaların fiziği” ya da “biyolojinin fiziği” şeklinde tanımlanabilir (2). Biyofizik temel bilimler için önemli bir ders olması ile beraber, klinik bilimlerin de özellikle nöroloji, kardiyoloji, kulak burun boğaz, göz, radyoloji gibi anabilim dallarının da temelini oluşturduğu ifade edilebilir. Bundan dolayı biyofizik dersinin iyi anlaşılması tıp fakültesi öğrencileri için çok büyük önem arz etmektedir. Günümüzde, yaşadığımız Covid-19 pandemisinden dolayı dersler online eğitim olarak sürdürülmektedir. Online eğitimde sadece sunumlar yerine animasyon ve simülasyon eğitimlerinin de öğrenmeye katkı sağlanabileceği ileri sürülebilir (3). Online eğitimde geri bildirim yeteri kadar iyi alınmadığından, öğrencilerin neyi öğrendikleri ve öğrendikleri şeyi nasıl pekiştirdikleri gözlemlenemediği için geri bildirim anketleri eğitimcilerin derse ve öğrenciye karşı tavır ve tutumunu değerlendirmede kullanılan en ideal yöntemdir (4-6). Bu bağlamda anket çalışmalarındaki geri bildirimler ile öğrencilerin dersi değerlendirmeleri olanaklı olacaktır. Bu çalışmada online eğitim döneminde biyofizik dersinde simülasyon ile sürdürülen bir öğrenme sürecine ilişkin öğrenci memnuniyet ve beklenti düzeyleri değerlendirilmiştir.

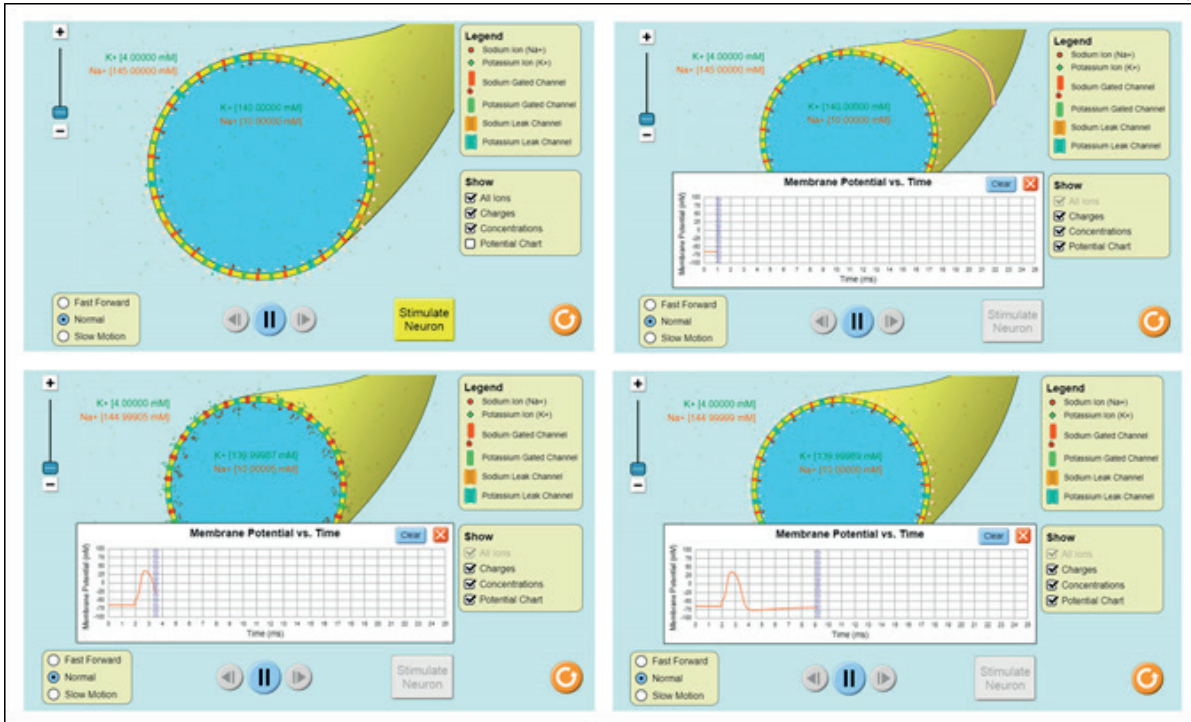
Öğrencilerin Ders Beklentileri	Kesinlikle katılmıyorum	Katılmıyorum	Kararsızım	Katılıyorum	Kesinlikle katılıyorum	Ortalama	Standart Sapma
Öğretim elemanı derslere hazırlıklı olarak girmektedir.			21	81	4,8	0,41	
Öğretim elemanı simülasyonu etkin olarak kullanıyordu.			19	83	4,81	0,39	
Derste kullanılan simülasyon konuyu daha iyi anlamamızı sağladı.	2	24	76	4,73	0,49		
Öğrenci- öğretim elemanı simülasyonu etkin olarak kullanmaktadır.	1	27	74	4,71	0,52		
Simülasyonda kullanılan örnekler konuyu pekiştirmemizi sağladı.		14	88	4,86	0,35		
Öğretim elemanı, derslere öğrencilerin aktif katılımını sağlayan yöntem ve teknikler kullanmaktadır.	6	33	63	4,56	0,61		

**Tablo 1.** Öğrencilerin ders beklentileri sorularına verdiği yanıtların dağılımı

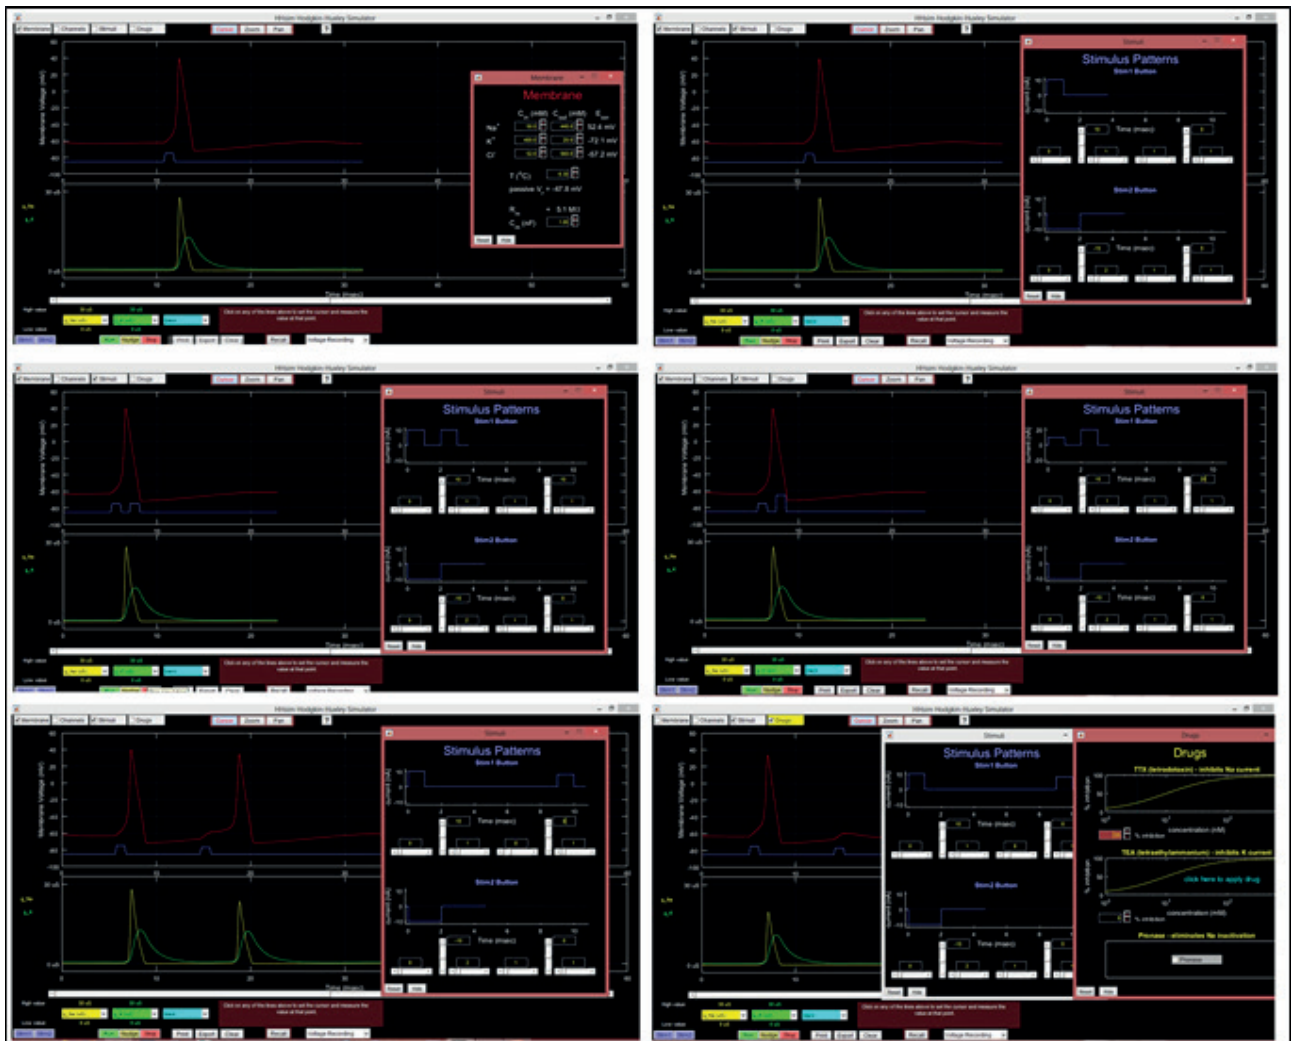
Biyofizik dersinde HHsim: Graphical Hodgkin-Huxley Simulator (7) ve PhET Interactive Simulations (1) simülasyonları temel olmak üzere bazı uygulamalar kullanılmıştır. Membran biyofiziği ve potansiyeli, yerel potansiyel, aksiyon potansiyeli, iyon kanalları, iyon akımlarının zamanla değişimi, uyarı ve uyarı iletimi, uyarıya fiziksel ve kimyasal etkiler gibi biyofiziğin temel konuları, PhET (Şekil 1.) ve HHsim (Şekil 2.) simülasyonları kullanılarak anlatılmıştır. Hitit Üniversitesi Tıp Fakültesi 2020-2021 eğitim öğretim yılının güz yarısında biyofizik dersi almakta olan 102 öğrenci çalışma grubunu oluşturmuştur. Anketlerin uygulanması Google Formlar anket kısmından yapılmıştır. Geri bildirimlerin güvenilirliğini artırmak amacıyla anketi dolduran öğrencilere isim yazmalarının gerekli olmadığı belirtilip formda öğrenci kimliğini açığa çıkaracak bilgiler yer almamıştır. Kocaeli Üniversitesi, Doğu Üniversitesi ve Düzce Üniversitesi'nin daha önce kullanmış oldukları ölçek formu uyarlanarak kullanılmıştır. Öğrenci memnuniyeti ölçeğinde 20 soru bulunmaktadır. Ankette ilk 7 soru öğrencilerin online derse katılımı ve dersi takip etmeleri ile ilgilidir. Anketteki 13 soru ise öğrencilerin öğretim elemanından beklentisini ve dersten memnuniyetini içermektedir. İfadelere katılma düzeyi likert tipi ölçeklendirme ile 1'den 5'e kadar derecelendirilme kullanılmıştır. Derecelendirmede: “1= Kesinlikle katılmıyorum”, “2= Katılmıyorum”, “3= Kararsızım”, “4= Katılıyorum”, “5= Kesinlikle katılıyorum” şeklinde değerlendirildi. Cronbach Alfa iç tutarlılık katsayısı 0,86'dır. Cronbach Alfa katsayısı, toplam puanlar üzerine kurulu Likert türü bir ölçeğin güvenilirliğinin hesaplanmasında sıklıkla kullanılan (8). Çalışmanın etik kurul izni 28.01.2021 tarih ve 2021-19 karar numarası ile Hitit Üniversitesi Girişimsel Olmayan Etik Kurulu'ndan alınmıştır. Verilerin analizi SPSS 20.0 programı kullanılarak analiz edilip yorumlanmıştır. Öğrencilerin sorulara verdiği yanıtların dağılımı ve aritmetik ortalama puanları analiz edilmiştir.

Öğrencilerin Ders Memnuniyeti	Kesinlikle katılmıyorum	Katılmıyorum	Kararsızım	Katılıyorum	Kesinlikle katılıyorum	Ortalama	Standart Sapma
Ders içeriği günceldi.			6	22	74	4,67	0,59
Konuları anlatırken örneklerle pekiştirdi.			1	23	78	4,76	0,46
Derslere aktif olarak katılmamızı sağladı.	3	3	33	63	4,53	0,70	
Derste kullanılan eğitim materyalleri ihtiyaçlarımızı karşılıyor.	3	15	36	48	4,3	0,78	
Eğitim faydalı geçmekte, öğretim elemanı anlaşılır bilgiler paylaşılmaktadır.			3	25	74	4,7	0,52
Ders temel ve/veya mesteki beceriler kazanmamı sağlayacak şekilde kurgulanmıştır.			7	38	57	4,49	0,63
Bu ders sayesinde bilgiyi analiz etme, yorumlama ve yeni bilgilere ulaşma yeteneklerim gelişti.	1	1	11	40	49	4,32	0,79

**Tablo 2.** Öğrencilerin ders memnuniyeti sorularına verdiği yanıtların dağılımı



Şekil 1. PhET Simülasyonu membran potansiyelinin zamanla değişimi



Şekil 2. HHSim Simülasyonu Hodgkin Huxley, aksiyon potansiyeli ve iyon kanal blokörleri

### Bulgular

Bu araştırma Hitit Üniversitesi Tıp Fakültesi Dönem I öğrencilerine online eğitimde simülasyon ağırlıklı öğretimin biyofizik dersindeki genel memnuniyetinin değerlendirilmesi amacıyla 102 öğrenci üzerinde uygulanmıştır. Araştırmaya katılım oranı %80'dir. Tablo 1'de öğrencilerin sorulara verdiği yanıtların dağılımı, ortalama ve standart sapma değerleri izlenmektedir.

Öğrencilerin ders beklentileri Tablo 1'de gösterilmektedir. Öğrencilerin %21'inin öğretim elemanının derse hazırlıklı girdiği yönündeki ifadeyi katılıyorum şeklinde yanıtladığı; %79'unun ise tamamen katıldığı tespit edilmiştir (Tablo 1). Öğrencilerin öğretim elemanının simülasyonu etkin olarak kullandığı yönündeki soruya %19'unun katılıyorum cevabını verdiği, %81'inin tamamen katılıyorum cevabını verdiği görülmüştür. Derste kullanılan simülasyonun konuyu daha iyi anlamalarını sağladığı yönündeki cevapların %2'sinin kararsız olduğu, %24'ünün katıldığı ve %74'ünün tamamen katıldığı tespit edilmiştir. Öğrencilerin %14'ünün simülasyonda kullanılan örneklerin konuyu pekiştirmelerini sağladığı yönündeki ifadeyi katılıyorum şeklinde yanıtladığı; %86'sının ise tamamen katıldığı tespit edilmiştir (Tablo 1). Öğrencilerin ders memnuniyetleri Tablo 2'de gösterilmektedir. Ders içeriğinin güncelliği hakkında sorulan soruyu öğrencilerin %6'sının kararsızım, %22'sinin katılıyorum ve %72'sinin ise tamamen katılıyorum şeklinde cevapladığı görülmüştür. Öğrencilerin %1'inin konuların anlatılırken örneklerle pekiştirildiği yönündeki ifadeyi kararsızım, %23'ünün katılıyorum şeklinde yanıtladığı; %76'sının ise tamamen katıldığı tespit edilmiştir (Tablo 2). Eğitim faydalı geçmekte, öğretim elemanı anlaşılır bilgiler paylaşmakta sorusuna ise öğrencilerin %3'ünün kararsızım, %24'ünün katılıyorum ve %73'ünün de tamamen katılıyorum şeklinde yanıt verdiği görülmüştür.

### Tartışma

Tıp eğitimi temel tıp bilimleri, dahili tıp bilimleri ve cerrahi tıp bilimlerinden oluşmaktadır. Temel tıp bilimleri adından da anlaşılacağı üzere tıp eğitiminin en temel ve ilk basamağıdır. Dersin zorluğu ve içeriğinden dolayı öğrencilerin konuyu anlamakta en çok zorlandığı temel bilimler derslerinden biri de biyofiziktir. Yüz yüze eğitimde dersin anlaşılmasına ilişkin zorluklar göz önünde bulundurulduğunda, pandemi döneminde uzaktan eğitim sürecinde öğrencileri desteklemek her zamankinden daha önemli hale gelmektedir. Simülasyon eğitimleri öğrencilere konuyu anlama ve kavramada büyük kolaylıklar sağlamaktadır. Online eğitimde simülasyon uygulamalarından faydalanılarak yaşanan öğrenme güçlüğünün önüne geçilebilmektedir (3). Simülasyon uygulamalarının derslerde kullanılması ile pandemi döneminde derslerin daha iyi kavranıp anlaşılması sağlanabilir. Bu bağlamda Hitit Üniversitesi Tıp Fakültesi Dönem I Biyofizik derslerinde PhET ve HHsim simülasyonları kullanılmıştır. Bu uygulamalar ile biyofizik dersinin Zoom üzerinden öğrenciler ile interaktif bir şekilde konuyu daha iyi anlamalarına ve pekiştirmelerine imkân sağlamıştır. Yeşildal ve arkadaşları 4-5-6. sınıf tıp fakültesi öğrencileri ile yaptığı çalışmada öğretim üyelerinin bilgisi kadar ders anlatımının da konuyu anlamada önemli olduğunu göstermişlerdir (9). Tablo 1 ve Tablo 2'de gösterildiği üzere, öğrencilerin öğretim üyesinin bilgisinden, konu anlatım yönteminden oldukça memnun oldukları ve simülasyon eğitimi mesleki becerilerine, bilgiyi analiz etme, yorumlama ve yeni bilgilere ulaşma yeteneklerinin gelişmesine katkı sağlayarak beklenti düzeylerini yüksek derecede karşılamıştır.

### Sonuç

Sonuç olarak, bu çalışmada online eğitimde öğrencilerin simülasyon tabanlı biyofizik dersinin işlenmesi ile ilgili beklenti ve memnuniyet düzeyleri incelenmiştir. Öğrencilerin simülasyon kullanılarak anlatılan dersten beklentilerinin yüksek düzey karşılandığı ve memnuniyet düzeylerinin yüksek olduğu görülmüştür. Simülasyon uygulamaları ile konunun daha iyi anlaşılması ve edinilen bilginin analiz edilme, yorumlanma ve yeni bilgilere ulaşmada büyük katkı sağladığı sonucuna varılmıştır.

### Kaynakçalar

1. Neuron PhET Simulation. Available from: [https://phet.colorado.edu/sims/html/neuron/latest/neuron\\_en.html](https://phet.colorado.edu/sims/html/neuron/latest/neuron_en.html).
2. Pehlivan F. Biyofizik. 8.baskı ed. 2015, Pelikan Yayıncılık.
3. Midik Ö, Kartal M. Simülasyona dayalı tıp eğitimi. Marmara Medical Journal, 2010. 23(3);389-399.
4. Karabilgin Ö, Şahin H. Tıp eğitimi değerlendirilmede öğrenci geri bildiriminin kullanımı. Tıp Eğitimi Dünyası, 2006(21): p. 27-33.
5. Fresko B, Nasser F. Interpreting Student Ratings: Consultation, Instructional Modification, and Attitudes Towards Course Evaluation. Studies in Educational Evaluation, 2001(27): p. 291-305.
6. El-Hassan K. Students' Ratings of Instruction: Generalizability of Findings. Studies in Educational Evaluation, 1995(21): p. 411-429.
7. Touretzky DS, Albert MV, Daw ND, Ladsariya A, Bonakdarpour M. HHsim: Graphical Hodgkin-Huxley Simulator 2017; Available from: <http://www.cs.cmu.edu/~dst/HHsim>.
8. Alpar R. Uygulamalı Çok Değişkenli İstatiksel Yöntemler. 2013, Detay Yayıncılık.
9. Yeşildal Çelebiler N, Süzen B, Sendağ R, Sıpal A, Tamses ES, Tatoğlu Y, Temir AN, Tezcan G. Düzce Üniversitesi Tıp Fakültesi 4-5-6. Sınıf Öğrenci Memnuniyeti Düzeyi Değerlendirilmesi. Sağlık Bilimleri Enstitüsü Dergisi, 2013. 1(3): p. 1-9.

## Anket

	Kesinlikle katılmıyorum	Katılmıyorum	Kararsızım	Katılıyorum	Kesinlikle katılıyorum
Öğretim elemanı derslere hazırlıklı olarak girmektedir.					
Öğretim elemanı simülasyonu etkin olarak kullanıyordu.					
Derste kullanılan simülasyon konuyu daha iyi anlamamızı sağladı.					
Öğrenci- öğretim elemanı simülasyonu etkin olarak kullanmaktadır.					
Simülasyonda kullanılan örnekler konuyu pekiştirmemizi sağladı.					
Öğretim elemanı, derslere öğrencilerin aktif katılımını sağlayan yöntem ve teknikler kullanmaktadır.					
Ders içeriği günceldi.					
Konuları anlatırken örneklerle pekiştirdi.					
Derslere aktif olarak katılmamızı sağladı.					
Derlerde kullanılan eğitim materyalleri ihtiyaçlarımı karşılıyor.					
Eğitim faydalı geçmekte, öğretim elemanı anlaşılır bilgiler paylaşmaktadır.					
Ders temel ve/veya mesleki beceriler kazanmamı sağlayacak şekilde kurgulanmıştı.					
Bu ders sayesinde bilgiyi analiz etme, yorumlama ve yeni bilgilere ulaşma yeteneklerim gelişti.					

## Sağlık Veri Setlerinde Öznitelik Seçiminin Sınıflandırma Performansına Etkisi

### *The Effect of Feature Selection Methods to Classification Performance in Health Datasets*

Mert DEMİRARSLAN<sup>1</sup>, Aslı SUNER<sup>\*2</sup>

#### ÖZ

Giriş: Günümüzde veri setleri, farklı cihazlardan toplanan verilerle çok yüksek boyutlu ve spesifik hale geldiğinden, öznitelik seçimi veri madenciliğinde veri boyutunu azaltmada önemli bir veri ön işleme adımıdır. Bu çalışma, öznitelik seçim yöntemlerini kullanarak makine öğrenmesi yöntemlerinin hesaplama süresini ve maliyetini düşürüp sınıflandırma performansının iyileştirilmesini amaçlamaktadır. Gereç ve Yöntem: Öznitelik seçim yöntemleri; filtreleme yöntemleri, sarmal yöntemler ve gömülü yöntemler olmak üzere üç ana başlık altında incelenmektedir. Çalışmada, makine öğrenmesi sınıflandırma algoritmalarından destek vektör makinesi, Naïve Bayes ve karar ağaçları yöntemleri kullanılmıştır. Çalışmada kullanılan veriler UCI ve Kaggle veri tabanlarından elde edilmiştir. Algoritmaların sınıflandırma performanslarını karşılaştırmak için doğruluk, duyarlılık, özgülük, kesinlik ve F ölçütü değerleri hesaplanmıştır. Tüm analizlerde WEKA 3.8.3, R3.3.0 ve Tableau programları kullanılmıştır. Analizlerde uygun yöntemler kullanılarak gereksiz öznitelikler çıkarıldıktan sonra; algoritmaların sınıflandırma performansları ve çalışma süreleri hesaplanmıştır. Bulgular: Doğruluk değerleri, öznitelik seçiminden sonra kullanılan veri setlerinde MNIST için % 87'e, Parkinson için % 85'e, SCADI için % 97'ye, HCC için % 100'e ve meme kanseri için % 78'e yükselmiştir. En yüksek performansa sahip algoritma karar ağaçları (J48) sarmal yöntem öznitelik seçimi ile elde edilmiştir. En hızlı metod filtreleme yöntemi iken, en uzun süre çalışan algoritma sarmal yöntemdir. Bulgulara göre, çok sayıda özniteliğe sahip verilerin sınıflandırma performansları, öznitelik seçimi yapılmış verilere göre daha düşük bulunmuştur. Sonuç: Sonuç olarak; düşük boyutlu veri setleri, daha düşük hesaplama maliyetleri ile daha yüksek sınıflandırma doğruluğu sağlayabilmektedir.

**Anahtar kelimeler:** Veri madenciliği, Öznitelik seçimi, Makine öğrenmesi, Sınıflandırma, Sağlık verileri

#### ABSTRACT

Introduction: Nowadays, since data sets become very high-dimensional and specific with the data collected from different devices, attribute selection has an important pre-processing task in reducing data size in data mining. This study aims to improve classification performance by reducing the calculation time and cost by using attribute selection methods. Materials and Methods: Attribute selection methods are examined under three main headings: filter method, wrapper method and embedded method. In the study, support vector machine, Naïve Bayes and decision trees methods (J48) among the machine learning classification algorithms were used. Data sets were obtained from UCI and Kaggle databases. Accuracy, sensitivity, specificity, precision and F-measure values were calculated to compare the classification performances of the algorithms. WEKA version 3.8.3, R3.3.0 and Tableau programs were performed in all analyzes. After unnecessary features were extracted by using appropriate methods in the analysis; classification performances and run times of algorithms were calculated. Results: Accuracy values increased to 87% for Colorectal Histology MNIST, 85% for Parkinson's disease, 97% for SCADI, 100% for HCC, and 78% for breast cancer after attribute selection. The algorithm with the highest performance was found as a wrapper method with decision trees (J48). While the fastest algorithm was filter method, the longest-running algorithm was the wrapper method. According to results, the performance improvement was higher in feature sets with a large number of attributes after selecting feature. Conclusion: As a result, low-dimensional data sets may provide higher classification accuracy with lower calculation costs

**Keywords:** Data mining, Feature selection, Machine learning, Classification, Health Datasets

Received/Geliş : 7.03.2021

Accepted/Kabul: 21.03.2021

Publication date: 15.04.2021

**Mert DEMİRARSLAN**

Ege Üniversitesi, Tıp Fakültesi,  
Biyostatistik ve Tıbbi Bilişim  
Anabilim Dalı, İzmir, Türkiye  
ORCID: 0000-0001-8848-7340

**Aslı SUNER**

Ege Üniversitesi, Tıp Fakültesi,  
Biyostatistik ve Tıbbi Bilişim  
Anabilim Dalı, İzmir, Türkiye  
asli.suner@ege.edu.tr  
ORCID: 0000-0002-6872-9901

## 1. GİRİŞ

Yapay zeka uygulamaları, sağlık alanında yaygın bir şekilde kullanılmaktadır. Sağlık alanında, hayati önem taşıyan konularda hızlı ve doğru kararlar verilmesi gerektiğinden, özellikle hastalık tanısı koymada sınıflandırma algoritmalarının sıklıkla kullanıldığı görülmektedir (1). Bu algoritmaları besleyen hastalık tanısı veri setlerinin doğru ve yüksek performanslı değerler içermesi için kullanılan verilerin düzgün, temiz, sınıflandırma algoritmalarının kullanımı için uygun şekilde olması büyük önem taşımaktadır. Ancak veri setlerinde kayıp gözlem, sınıf gürültüsü, sınıf dengesizliği, aykırı gözlem, korelasyon olması ve ilgisiz değişken gibi bir çok problem ortaya çıkabilmektedir (2). Bu durum da algoritmaların performans değerlerini olumsuz yönde etkileyebilmektedir.

Sağlık veri setlerinde diğer verilerde de görüldüğü gibi sınıflandırma performansını düşüren ya da yavaşlatan ilgisiz değişkenler bulunmaktadır (3). Bu ilgisiz değişkenlerin veri setinden uzaklaştırılması için literatürde birçok öznelik seçim yöntemi önerilmiştir. Yang ve ark. (1997) yaptıkları çalışmada öznelik seçim yöntemlerinde genetik algoritmaları 17 farklı veri seti ile kullanmışlar ve sınıflandırma performansının farklı algoritmalar da yükseldiğini göstermişlerdir (4). John ve ark. (1997) yaptıkları çalışmada, sınıflandırma algoritmalarında oluşan aşırı öğrenme problemini gidermek için sarmal yöntemler ile ilgisiz değişkenleri veri setinden çıkartarak aşırı öğrenme problemini çözümlenmişlerdir (3). Rodriguez ve ark. (2018) ise öznelik seçim yöntemlerinin (filtreleme, sarmal ve gömülü) sınıflandırma performanslarını karşılaştırmışlardır. Filtreleme yöntemlerinin daha hızlı, sarmal ve gömülü yöntemlerin ise daha yavaş ancak filtreleme yöntemlerine göre daha başarılı olduklarından bahsetmişlerdir (5).

Bu çalışma, öznelik seçim yöntemlerini kullanarak makine öğrenmesi yöntemlerinin hesaplama süresini ve maliyetini düşürerek sınıflandırma performansının iyileştirilmesini amaçlamaktadır.

## 2.YÖNTEM

Çalışmada makine öğrenmesi algoritmaları kullanılırken %70 eğitim verisi ve %30 test verisi olarak alınmıştır. Öznelik seçim yöntemleri filtreleme, gömülü ve sarmal yöntemler olarak incelenmiştir. Filtreleme yöntemlerinden korelasyon tabanlı öznelik seçim yöntemi; sarmal yöntemlerden rasgele ağaç yöntemi ve gömülü yöntemlerden ileri artırımı yöntem kullanılmıştır. Sınıflandırma yöntemlerinden Naïve Bayes; destek vektör makinaları ve karar ağacı algoritmalarından C4.5 kullanılmıştır (6). Algoritmaların sınıflandırma performansı hesaplanırken ölçüm metriklerinden doğruluk, duyarlılık, özgüllük, kesinlik ve F ölçütü tercih edilmiştir. Tüm analizlerde WEKA 3.8.3, R3.3.0 ve Tableau programları, Windows 10 işletim sisteminde kullanılmıştır.

### 2.1. Veri Setleri

Çalışmada kullanılan kolorektal kanser (Colorectal Histology MNIST), Parkinson hastalığı (Parkinson's Disease), öz bakım aktiviteleri (SCADI), hepatoselüler kanser (HCC) ve meme kanseri (Breast Cancer) veri setleri, UCI (7) ve Kaggle (8) veri tabanlarından elde edilmiştir. Veri setlerinin seçiminde, öznelik seçim yöntemleri arasındaki farklılıkları incelemek amacıyla gözlem sayılarının ve öznelik sayılarının farklı olmasına dikkat edilmiştir. Veri setleri hakkında bilgilerin özetlendiği Tablo 1'e göre kolorektal kanser veri seti 2 sınıfa, 1250 örneklem büyüklüğüne ve 785 özneliğe sahiptir. Parkinson veri seti 2 sınıflı iken örneklem büyüklüğü ve öznelik sayısı 755'tir. SCADI veri setindeki sınıf

sayısı 7, örneklem büyüklüğü 70 ve öznelik sayısı 206'dır. HCC veri setinde sınıf sayısı 2, örneklem büyüklüğü 204 ve öznelik sayısı 45'tir. Meme kanseri verisinde ise 2 sınıf yer almakta, örneklem büyüklüğü 286 iken öznelik sayısı 10'dur. Sadece HCC veri setinde %10,22 oranında kayıp gözlem bulunmaktadır.

Veri Seti	N	Öznelik Sayısı	Sımf Sayısı
Colorectal Histology MNIST	1250	785	2
Parkinson's Disease	755	755	2
SCADI	70	206	7
HCC	204	45	2
Breast Cancer	286	10	2

**Tablo 1:** Veri setlerine ilişkin bilgiler

### 2.2. Öznelik seçim yöntemleri

Literatüre bakıldığında öznelik seçim yöntemleri 3 ana başlık altında toplanmıştır (9). Bunlardan ilki istatistiksel yöntemlere dayanan ve bu sayede hızlı sonuçlar alınmasını sağlayan filtreleme yöntemleridir. İkincisi, makine öğrenmesi yöntemlerine dayanan ve her aşamada sınıflandırıcı ile ilişki kuran sarmal yöntemlerdir. Üçüncü grupta ise makine öğrenmesi algoritmaları ve öznelik seçim yöntemlerinin birlikte çalıştığı ve yine her aşamada sınıflandırıcı ile ilişki kurarak çalışan gömülü yöntemler yer almaktadır.

#### 2.2.1. Filtreleme yöntemleri

Filtreleme yöntemleri, boyut indirgeme, öznelik seçim işlemlerinde kullanılan en eski tekniklerdir (10). İstatistiksel yöntemler kullanılarak yapılan bu işlemlerde sınıflandırma yöntemleri kullanılmamaktadır. Bu sebeple algoritmalar daha hızlı çalışmakta ve daha hızlı sonuçlar alınmaktadır. Bu sayede de hesaplamalar yapılırken zaman ve maliyet açısından yüksek fayda sağlanmaktadır. Gömülü ve sarmal yöntemlere göre daha az karmaşık, açıklanabilirliği daha yüksektir. Filtreleme yöntemleri; Fisher skor, t-skor, korelasyon tabanlı filtreleme ve bilgi kazancı gibi yöntemlerden oluşmaktadır.

#### 2.2.2. Gömülü yöntemler

Gömülü yöntemlerde hem özellik seçim algoritmaları hem de sınıflandırma algoritmaları bir arada kullanılmaktadır. Bu yüzden gömülü yöntemler filtreleme yöntemlerine göre, sarmal yöntemler gibi daha yavaş ve daha yüksek maliyetli olmaktadır. Filtreleme yöntemleri, hızlı ve düşük maliyetli olsa da sınıflandırma yöntemlerini kullanmadığından sınıflandırmada bazı sorunlar ya da düşük performanslar görülebilmektedir. Bununla birlikte, sarmal yöntemlerin, özellikle mikrodizi verilerinin yüksek boyutsallığı ile artan bir hesaplama maliyeti olabilmektedir (9). Araştırmacılar için ara bir çözüm olan ve özellikleri sıralamak için bir kriter oluşturmada sınıflandırma yöntemlerini de kullanan gömülü yöntemler keşfedilmiştir. Örneğin, karar ağaçları ya da destek vektör makine yöntemleri ile alt kümelerin oluşturulup sıralanmasının ardından istenilen düzeydeki öznelikler seçilebilmektedir.

#### 2.2.3. Sarmal yöntemler

Sarmal yöntemlerde, öznelik seçimi için makine öğrenmesi algoritmaları kullanılarak en yüksek performans gösteren yöntem seçilmektedir. Bu yöntemde en iyi alt küme oluşturma ve seçme tekniği filtreleme yöntemlerine göre daha başarılı olmakta; ancak her aşamada sınıflandırıcı başarısına bakıldığından daha yavaş ve daha yüksek maliyetli olmaktadır. Alt küme arama stratejileri ola-

## Öznitelik Seçiminin Sınıflandırmaya Etkisi

rak; ardışık ileri yönde seçim, ardışık geri yönde seçim, ardışık ileri yönde kayan seçim, ardışık geri yönde kayan seçim, 1 ekle r çıkar ve genetik algoritmalar gibi farklı yöntemler kullanılabilir (9).

### 2.3. Makine öğrenmesi sınıflandırma algoritmaları

Makine öğrenmesi, temel olarak yapay zekanın sayısal öğrenme ve model tanıma çalışmalarından geliştirilen bilgisayar biliminin bir alt dalıdır. Makine öğrenmesi algoritmaları; verilerin yapısını ve işlevini öğrenen, aynı zamanda veri seti üzerinde veri öngöründe bulunabilen sistemlerdir. Bu algoritmalar, örnek girişlerden veri tabanlı tahminler ve kararlar gerçekleştirmek için bir model oluşturarak çalışmaktadırlar (11).

#### 2.3.1. Naïve Bayes (NB) sınıflandırıcı

Naïve Bayes koşullu olasılık hesaplama yöntemi Thomas Bayes tarafından 1812 yılında bulunmuştur. Bu yöntem, rassal bir değişken için olasılık dağılımı içinde koşullu olasılıklar ile marjinal olasılıklar arasındaki ilişkiyi göstermektedir. Naïve Bayes sınıflandırma yönteminin temelini Bayes teoreminden gelmektedir. Basit sınıflandırma algoritmaları kategorisinde yer almakta ve dengesiz sınıflı verilerde de çalışmaktadır. Algoritmanın çalışma prensibi, bir eleman için her durumun olasılığını hesaplamakta ve olasılık değeri en yüksek olana göre sınıflandırılmaktadır. Küçük boyutlu eğitim verisiyle de çalışabilmektedir. Test kümesindeki bir değer için eğitim kümesinde gözlemlenemeyen bir değeri varsa olasılık değeri olarak 0 verdiğinden tahmin yapamamaktadır. Bu durum genellikle sıfır frekans adıyla bilinmektedir. Bu durumu çözmek için düzeltme teknikleri kullanılabilir. En basit düzeltme tekniklerinden biri Laplace tahminidir (12).

#### 2.3.2. Destek vektör makinaları (DVM)

Temelleri 1960 yılında Vladimir N. Vapnik tarafından atılan destek vektör makinaları, 1990 yılında tam anlamıyla geliştirilmiştir. Başlangıçta iki sınıflı veriler için tasarlanırsa da daha sonradan çok sınıflı verileri sınıflandırmak için geliştirilmiştir. Bu yöntemin eğitim süresi diğer algoritmalara göre yavaş olsa da güvenilirliği daha yüksektir ve doğrusal olmayan gözlemlerde de üstün başarı göstermektedir (13).

#### 2.3.3. Karar ağacı C4.5

Karar ağacı C4.5 algoritması J. Ross tarafından bulunmuştur. Verideki bağımlı/sınıflı öznitelik için entropi (bilgi kazancı) değeri hesaplanmaktadır. Bu yöntem, entropi değerine göre değerlendirmekte ve her seferinde tek bir özelliği dikkate almaktadır. Entropi, veri setindeki karmaşıklık veya belirsizliğin ölçümü olarak tanımlanabilmektedir (Formül 1). Entropi ölçüsü, değişkenleri sıralamak için bir ölçüt olarak kabul edilmektedir. Y özniteliğini anlamak için gerekli olan bilgi ile X özniteliğini de kullanarak aralarındaki fark ile Y özniteliğini kullanmaya bilgi kazancı denmektedir (Formül 2). Bir sınıf özelliği olarak Y'nin entropisi, p(y) rastgele değişken olan Y için marjinal olasılık yoğunluk fonksiyonudur. Entropi ölçüsü hesaplamada Y öznitelisinin entropi ölçüsü X öznitelisine göre gruplanan verilerden yüksek olacaktır (Formül 3). Yöntem tüm özellikleri düzenli bir şekilde sınıflandırmakta, daha sonra elde edilen sıraya göre en yüksek kazanç bilgisine sahip olanı göstermektedir (14).

$$\text{Entropi}(Y) = -\sum_{i \in Y} p(i) \log_2(p(i)) \quad (1)$$

$$\text{Bilgi Kazancı} = H(Y) - H(Y|X) \quad (2)$$

$$H(Y|X) = -\sum_{j \in X} p(j) \sum_{i \in Y} p(i|j) \log_2(p(i|j)) \quad (3)$$

## 2.4. Performans metrikleri

Performans metrikleri, hata matrisi yardımıyla hesaplanmakta ve 0 ile 1 arasında değerler almaktadır. Hesaplamalar sonucunda, metriklerin değerleri 1'e yaklaştıkça iyi performans gösterdikleri söylenmektedir. Doğru pozitif (DP), tahmin edilenin pozitif ve gerçek durumun pozitif olduğu durumdur (örneğin hastayı hasta olarak tahmin etmek). Yanlış pozitif (YP), tahmin edilenin pozitif ancak gerçek durumun negatif olduğu durumdur (örneğin sağlıklı bireyi hasta olarak tahmin etmek). Yanlış negatif (YN), tahmin edilenin negatif ancak gerçek durumun pozitif olduğu durumdur (örneğin hastayı sağlıklı olarak tahmin etmek). Doğru negatif (DN), tahmin edilenin negatif gerçek durumun negatif olduğu durumdur (örneğin sağlıklı bireyi sağlıklı olarak tahmin etmek) (15). Bu hesaplamaların yapılmasında kullanılan hata matrisi aşağıdaki şekilde gösterilmektedir (Tablo 2):

Tahmin Durumu	Gerçek Durum	
	Pozitif	Negatif
Pozitif	DP	YP
Negatif	YN	DN

Tablo 2: Hata Matrisi

Doğruluk (Accuracy): Sınıflandırma performansı incelemesinde en çok dikkat edilen kısım doğruluk değeridir. Doğru pozitif ve doğru negatif değerlerinin tüm değerlere olan oranı ile bulunmaktadır. Örneğin doğruluk değeri 1 olduğunda gerçekten hasta olan ile hasta olmayan bireylerin sınıflandırılmasının tam olarak doğru yapıldığı sonucuna varılır. Doğruluk formülü (Formül 4) aşağıdaki gibi hesaplanmaktadır:

$$\text{ACC} = \frac{D P D N}{D P Y P Y N D N} \quad (4)$$

Duyarlılık (Sensitivite): Bu metrik; doğru pozitif olan, tahmin edilenin pozitif ve gerçek durumun pozitif olduğu kısma ilgilenebilir. Örneğin, hastayı hasta olarak tahmin ederek hasta bireylerin ayırt edilmesini sağlamaktadır (16). Ayrıca duyarlılık ölçümü testin gücüne de eşittir (güç=1-β). Duyarlılık formülü (Formül 5) aşağıdaki gibi hesaplanmaktadır:

$$\text{SEN} = \frac{D P}{D P Y N} \quad (5)$$

Özgüllük (Specificity): Bu metrik; doğru negatif olma durumuyla, başka bir ifadeyle tahmin edilenin negatif gerçek durumun da negatif olduğu durum ile ilgilenebilir. Örneğin sağlıklı bireyi sağlıklı olarak tahmine etmektedir (16). Seçicilik formülü (Formül 6) aşağıdaki gibi hesaplanmaktadır:

$$\text{SPE} = \frac{D N}{D N Y P} \quad (6)$$

Keskinlik (Precision): Doğru tahmin edilen tüm pozitif sınıflardan kaç tanesinin gerçekten pozitif olduğunu tahmin eden metriktir. Başka bir deyişle, tanı testi sonucu pozitif olanların hasta olma olasılığını tahmin etmedir (16). Keskinlik formülü (Formül 7) aşağıdaki gibi hesaplanmaktadır:

$$\text{PRE} = \frac{D P}{D P Y P} \quad (7)$$

F-ölçütü: Özgüllük ve keskinlik ölçümlerinin harmonik ortalama-



siyla hesaplanan F-ölçütü, her iki metriğin birlikte değerlendirilmesine olanak tanımaktadır (16). F-ölçütü formülü (Formül 8) aşağıdaki gibi hesaplanmaktadır:

$$F = 2 * \frac{\text{Özgüllük} * \text{Kesinlik}}{\text{Özgüllük} + \text{Kesinlik}} \quad (8)$$


### 3.BULGULAR

Veri setlerinin ham halindeki sınıflandırma performanslarına bakıldığında kolorektal kanser verisi en yüksek doğruluğu DVM algoritmasında 0,72 doğruluk, duyarlılık, özgüllük, kesinlik ve F değeri göstermiştir. Parkinson verisi, C4.5 ve DVM algoritmalarıyla 0,80 doğruluk, duyarlılık, özgüllük, kesinlik ve F değeri; SCADI verisi DVM algoritmasıyla 0,79 doğruluk, duyarlılık, özgüllük, kesinlik ve F değeri; HCC verisi DVM algoritmasıyla 0,75 doğruluk, duyarlılık, özgüllük, kesinlik ve F değeri; meme kanseri verisi NB algoritmasıyla 0,71 doğruluk, duyarlılık, özgüllük, kesinlik ve F değeri göstermiştir. Verilere korelasyon tabanlı filtreleme yöntemi uygulandığında, kolorektal kanser verisinde sınıflandırma performansı destek vektör makinesi algoritması ile verinin ham haline göre 0,82 doğruluk oranına yükselmiştir. Parkinson verisinde DVM algoritması en yüksek 0,82 doğruluk, SCADI verisinde DVM en yüksek 0,97 doğruluk, HCC verisinde DVM algoritması en yüksek 0,97 doğruluk ve meme kanseri verisinde en yüksek C4.5 algoritması en yüksek 0,76 doğruluk göstermiştir. Verilere öznelik seçiminden gömülü yöntemlerde ileri artırımı yöntem kullanıldığında, kolorektal kanser verisinde doğruluk oranı C4.5 algoritması ile verinin ham haline göre 0,81 oranına yükselmiştir. Parkinson verisinde C4.5 algoritması en yüksek 0,86 doğruluk, SCADI verisinde DVM algoritması en yüksek 0,91 doğruluk, HCC verisinde DVM algoritması 100 doğruluk, meme kanseri verisinde NB algoritması 0,78 doğruluk göstermiştir. Verilerde sarmal yöntemler için rasgele orman yöntemi uygulandığında, kolorektal kanser verisinin doğruluk oranının en yüksek C4.5 algoritmasıyla 0,87 doğruluk oranı sahip olmuştur. Diğer verilerde bu durum; Parkinson verisinde C4.5 algoritması ile 0,80 doğruluk, SCADI verisinde C4.5 ile 0,88 doğruluk, HCC verisinde DVM algoritması ile 0,92 doğruluk ve meme kanseri verisinde C4.5 ile 0,78 doğruluk şeklinde olmuştur (Tablo 3).

Veri Seti	Yöntem	Ham Veri					Filtreleme					Gömülü					Sarmal				
		Doğruluk	Duyarlılık	Özgüllük	Kesinlik	F değeri	Doğruluk	Duyarlılık	Özgüllük	Kesinlik	F değeri	Doğruluk	Duyarlılık	Özgüllük	Kesinlik	F değeri	Doğruluk	Duyarlılık	Özgüllük	Kesinlik	F değeri
Ham Veri	Kolorektal	0,54	0,54	0,54	0,54	0,54	0,50	0,51	0,51	0,50	0,51	0,72	0,73	0,72	0,73	0,73	0,80	0,80	0,80	0,80	0,80
	Parkinson	0,80	0,81	0,81	0,80	0,81	0,79	0,79	0,79	0,79	0,79	0,82	0,82	0,82	0,82	0,82	0,82	0,82	0,82	0,82	0,82
	SCADI	0,70	0,70	0,70	0,70	0,70	0,73	0,74	0,74	0,73	0,74	0,78	0,78	0,78	0,78	0,78	0,78	0,78	0,78	0,78	0,78
	HCC	0,37	0,36	0,36	0,37	0,37	0,73	0,74	0,74	0,73	0,74	0,78	0,78	0,78	0,78	0,78	0,78	0,78	0,78	0,78	0,78
	Meme Kanseri	0,68	0,69	0,69	0,68	0,68	0,71	0,71	0,71	0,71	0,71	0,69	0,68	0,69	0,68	0,68	0,68	0,68	0,68	0,68	0,68
Filtreleme	Kolorektal	0,81	0,81	0,81	0,81	0,81	0,79	0,80	0,80	0,79	0,80	0,82	0,82	0,82	0,82	0,82	0,82	0,82	0,82	0,82	0,82
	Parkinson	0,80	0,80	0,80	0,80	0,80	0,79	0,79	0,79	0,79	0,83	0,82	0,83	0,82	0,83	0,83	0,83	0,83	0,83	0,83	
	SCADI	0,88	0,89	0,89	0,88	0,88	0,92	0,93	0,93	0,92	0,92	0,97	0,96	0,97	0,96	0,96	0,96	0,96	0,96	0,96	
	HCC	0,68	0,68	0,68	0,68	0,68	0,85	0,84	0,84	0,85	0,85	0,97	0,96	0,97	0,96	0,97	0,97	0,97	0,97	0,97	
	Meme Kanseri	0,76	0,76	0,76	0,76	0,77	0,74	0,74	0,74	0,74	0,74	0,68	0,68	0,68	0,68	0,68	0,68	0,68	0,68	0,68	
Gömülü	Kolorektal	0,81	0,81	0,81	0,81	0,81	0,78	0,78	0,78	0,78	0,78	0,79	0,79	0,79	0,79	0,79	0,79	0,79	0,79	0,79	
	Parkinson	0,85	0,84	0,84	0,85	0,85	0,85	0,85	0,85	0,85	0,84	0,84	0,84	0,84	0,84	0,84	0,84	0,84	0,84	0,84	
	SCADI	0,88	0,88	0,88	0,88	0,88	0,88	0,88	0,88	0,88	0,88	0,91	0,91	0,91	0,91	0,91	0,91	0,91	0,91	0,91	
	HCC	0,49	0,49	0,49	0,49	0,49	0,95	0,95	0,95	0,95	0,95	100	100	100	100	100	100	100	100	100	
	Meme Kanseri	0,77	0,78	0,78	0,77	0,77	0,78	0,79	0,79	0,78	0,79	0,74	0,73	0,74	0,73	0,73	0,73	0,73	0,73	0,73	
Sarmal	Kolorektal	0,87	0,86	0,86	0,87	0,86	0,78	0,78	0,78	0,78	0,78	0,78	0,78	0,78	0,78	0,78	0,78	0,78	0,78	0,78	
	Parkinson	0,80	0,80	0,80	0,80	0,80	0,79	0,77	0,77	0,79	0,78	0,77	0,76	0,77	0,76	0,76	0,76	0,76	0,76	0,76	
	SCADI	0,88	0,86	0,86	0,88	0,88	0,84	0,85	0,85	0,84	0,85	0,88	0,88	0,88	0,88	0,88	0,88	0,88	0,88	0,88	
	HCC	0,80	0,80	0,80	0,80	0,80	0,75	0,75	0,75	0,75	0,75	0,92	0,91	0,92	0,91	0,92	0,92	0,92	0,92	0,92	
	Meme Kanseri	0,78	0,78	0,78	0,78	0,78	0,76	0,75	0,75	0,76	0,76	0,69	0,68	0,69	0,68	0,69	0,69	0,69	0,69		

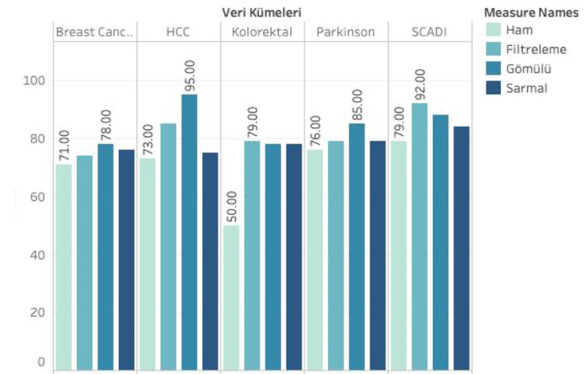
**Tablo 3:** Öznelik seçim yöntemlerinin algoritmalarındaki sınıflandırma performansları

Araştırmada kullanılan verilerde algoritmaların başarıları incelendiğinde en yüksek doğruluk değerine sahip olan yöntemler; meme kanseri verisinde C4.5 algoritmasına göre gömülü yöntem, HCC verisinde filtreleme yöntemi, kolorektal kanser verisinde sarmal yöntem, Parkinson verisinde sarmal yöntem ve SCADI verisinde sarmal ve gömülü yöntemdir (Şekil 1).



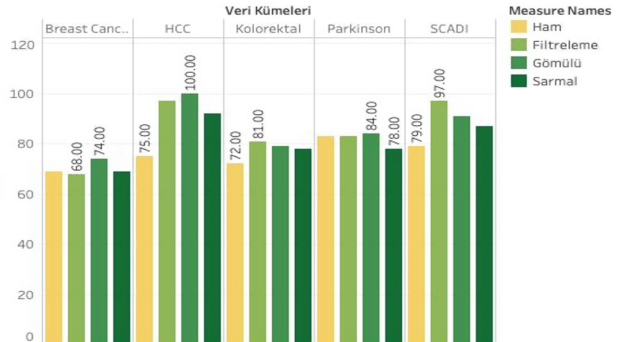
**Şekil 1:** C4.5 algoritmasına göre öznelik seçim yöntemlerinin verilerdeki doğruluk değerleri

NB algoritmasına göre öznelik seçim yöntemlerinin verilerdeki doğruluk değerlerine bakıldığında, meme kanseri verisinde 0,78 doğruluk oranıyla gömülü yöntem, HCC verisinde 0,95 doğruluk ile gömülü yöntem, kolorektal kanser verisinde 0,79 doğrulukla filtreleme yöntemi, Parkinson verisinde 0,85 doğrulukla gömülü yöntem, SCADI verisinde 0,92 doğruluk ile filtreleme yöntemi en yüksek başarıyı göstermiştir (Şekil 2).



**Şekil 2:** NB algoritmasına göre öznelik seçim yöntemlerinin verilerdeki doğruluk değerleri

DVM algoritmasına göre öznelik seçim yöntemlerinin verilerdeki doğruluk değerlerine bakıldığında; meme kanseri verisinde 0,74 doğrulukla gömülü yöntem, HCC verisinde 100 doğrulukla gömülü yöntem, kolorektal kanser verisine göre 0,81 doğrulukla filtreleme yöntemi, Parkinson verisinde 0,87 doğruluk ile gömülü yöntem ve SCADI verisinde 0,91 filtreleme yöntemi başarılı olmuştur (Şekil 3).



**Şekil 3:** DVM algoritmasına göre öznelik seçim yöntemlerinin verilerdeki doğruluk değerleri

## Öznitelik Seçiminin Sınıflandırmaya Etkisi

Tablo 4'te öznitelik seçim yöntemlerinin çalışma sürelerine bakıldığında; kolorektal kanser verisinde filtreleme yöntemi 2 saniye, gömülü yöntem 32 saniye ve sarmal yöntem 69 saniye sürede sonuç vermiştir. Parkinson verisinin çalışması ise filtreleme yönteminde 4 saniye, gömülü yöntemde 37 saniye, sarmal yöntemde 77 saniye sürmüştür. SCADI verisi, filtreleme yöntemi 2 saniye, gömülü yöntem 21 saniye, sarmal yöntem 47 saniye çalışırken; HCC verisinin çalışması filtreleme yöntemi için 2 saniye, gömülü yöntem için 13 saniye ve sarmal yöntem için ise 35 saniye sürmüştür. İstatistiksel tabanlı olan filtreleme yöntemleri her veri setinde ve her algoritmada en kısa çalışma süresine sahiptir.

Veri Seti	Filtreleme	Gömülü	Sarmal
Colorectal Histology MNIST	2 s	32 s	69 s
Parkinson's Disease	4 s	37 s	77 s
SCADI	2 s	21 s	47 s
HCC	2 s	13 s	35 s
Breast Cancer	2 s	13 s	35 s

Tablo 4: Öznitelik seçim yöntemlerinin çalışma süreleri

## 4.TARTIŞMA

Çalışmada kullanılan veri setlerinin orijinal/ham hallerinde algoritmaların sınıflandırma performansları oldukça düşük değerler göstermiştir. Verilerde öznitelik seçimi yapıldıktan sonra ilgili değişkenlerin seçiminden dolayı algoritmaların sınıflandırma performansları yükselmiştir. Öznitelik seçim yöntemlerinin çalışma sürelerine bakıldığında, tüm veri setlerinde en hızlı çalışan yöntem filtreleme yöntemi, ardından sırasıyla gömülü yöntem ve sarmal yöntem olmuştur. Filtreleme yöntemi, istatistik tabanlı olması nedeniyle hızlı çalışmaktadır. Gömülü yöntem ve sarmal yöntem, her adımda sınıflandırma performansı hesaplamasından dolayı filtreleme yöntemlerine göre daha yavaş hesaplama yapmaktadır. Literatüre bakıldığında, Parkinson veri seti için, Patra ve ark. (2019) yaptıkları çalışmada, basit ve topluluk öğrenme algoritmalarının sınıflandırma performanslarını araştırmışlardır (17). Yapılan çalışmada herhangi bir öznitelik seçim işlemi yapılmamıştır. Topluluk öğrenme algoritmalarının sınıflandırma performansları incelendiğinde; rasgele orman için 0,84; Bagging için 0,81 ve Adaboost için 0,82 doğruluk yüzdesi elde edilmiştir. Bizim çalışmamızda Parkinson verisinde gömülü yöntem öznitelik seçimi yapıldıktan sonra C4.5 ve Naïve Bayes algoritmalarında 0,85 doğruluk elde edilmiştir. Coudhury and Grene (2019), SCADI verisi için çalışmalarında birçok sınıflandırma algoritmasını karşılaştırmışlar, öznitelik seçim işleminde Boruna algoritmasını kullanarak DVM algoritmasında 0,83; Naïve Bayes algoritmasında 0,83 doğruluk elde etmişlerdir (18). Bizim çalışmamızda ise filtreleme yöntemi kullanılarak ilgili değişkenlerin seçilmesinin ardından DVM algoritması kullanılarak 0,97 doğruluk değeri ile daha yüksek performans elde edilmiştir. Pal ve ark. (2018) öznitelik sıralama yöntemlerinin sınıflandırma performansını etkisini araştırırken HCC veri setinden faydalanmışlardır (19). Yaptıkları çalışmada, veri ön işleme adımında kayıp gözlem problemi kübik spline veri interpolasyonu yöntemi ile atama yaparak çözmüşlerdir. Öznitelik seçimi sıralama işlemlerinde ReliefF, mRMR, karşılıklı bilgi yöntemi, hızlı korelasyon tabanlı filtre ve kendi önerdikleri öznitelik sıralama yöntemlerini kullanmışlardır. Kendi önerdikleri öznitelik sıralama yöntemi ile SVM algoritması 0,76 ile en yüksek doğruluk değerini sağlamıştır. Bizim çalışmamızda HCC verisinde gömülü yöntemlerde DVM algoritması %100 doğruluk göstermiştir. Ancak bu durum verinin dengesiz sınıf dağılımından kaynaklı olarak aşırı öğrenmeye neden olmuş olabileceğinden, filtreleme yöntemlerindeki DVM algoritmasının

daki 0,97 doğruluğu ele almak daha doğru olacaktır. Chaurasia ve Pal (2014), meme kanseri verisi için yaptıkları sınıflandırma çalışmasında öznitelik seçimi uygulamamışlardır (20). Kullandıkları sınıflandırma algoritmaları ile Rep Tree için 0,71; RBF Network için 0,73 ve Simple Logistic için 0,74 doğruluk yüzdesi elde etmişlerdir. Bizim çalışmamızda ise gömülü yöntem kullanılarak Naïve Bayes algoritması ile 0,78 ve sarmal yöntem kullanılarak C4.5 algoritması ile 0,78 doğruluk değeri elde edilmiştir.

## 5.SONUÇ

İlgisiz değişken probleminin giderilmesinden sonra, algoritmaların sınıflandırma performanslarının orijinal halindeki sınıflandırma performanslarına göre yükseldiği görülmüştür. Veri setlerinde değişken sayıları ile örneklem genişliklerinin birbirlerinden oldukça farklı olması da sınıflandırma performansını olumsuz yönde etkilemektedir. Sağlık veri setlerinde öznitelik seçim işlemi yapılırken filtreleme yöntemlerinin kullanılması, yüksek sınıflandırma performansı sağlarken zaman ve maliyet açısından da fayda sağlayacaktır. Gelecek çalışmalarda, örneklem sayısı ve öznitelik sayısı 1000'den fazla olan verilerle çalışılarak öznitelik seçim yöntemlerinin performanslarının ve çalışma sürelerinin karşılaştırılması önerilmektedir.

## KAYNAKLAR

- [1] Deo RC. Machine learning in medicine, Circulation. 2015;132:1920-1930. doi:10.1161/Circulationaha.115.001593.
- [2] Lin JH, Haug PJ. Data preparation framework for preprocessing clinical data in data mining, AMIA Annual Symposium Proceedings. American Medical Informatics Association, 2006. p. 489.
- [3] Kohavi R, John GH. Wrappers for feature subset selection. Artificial intelligence, 1997, 97.1-2: 273-324. doi.org/10.1016/S0004-3702(97)00043-X.
- [4] Yang J, Honavar V. Feature subset selection using a genetic algorithm. In Feature extraction, construction and selection. Springer, Boston, MA, 1998. p. 117-136.
- [5] Rodriguez GV, Luque EJ, Chica OM, Mendes MP. Feature selection approaches for predictive modelling of groundwater nitrate pollution: An evaluation of filters, embedded and wrapper methods. Science of the total environment. 2018, 624: 661-672.
- [6] D Chen DY. Pandas for everyone, Python data analysis. Addison-Wesley Professional, 2017. p.161.
- [7] UCI Machine Learning Repository [Internet]. Available from: <https://archive.ics.uci.edu/ml/index.php>
- [8] Open Datasets and Machine Learning Projects | Kaggle [Internet]. Available from: <https://www.kaggle.com/datasets>
- [9] Bolón CV, Sánchez MN, Alonso BA. Feature selection for high-dimensional data. Cham, Springer International Publishing, 2015.
- [10] Zhang L, Duan Q. A feature selection method for multi-label text based on feature importance. Applied Sciences, 2019, 9.4:665. doi: 10.1007/s11042-018-6083-5.
- [11] Kononenko I. Machine learning for medical diagnosis: history, state of the art and perspective. Artificial Intelligence in medicine, 2001, 23.1: 89-109. [https://doi.org/10.1016/S0933-3657\(01\)00077-X](https://doi.org/10.1016/S0933-3657(01)00077-X).
- [12] Choubey DK, Paul S, Kumar S. Classification of Pima indian diabetes dataset using naive bayes with genetic algorithm as an attribute selection. In Communication and computing systems: proceedings of the international conference on communication and computing system (ICCCS 2016). 2017. p. 451-455. doi:10.1201/9781315364094-82.

- [13] Indrayan A, Holt MP. Concise encyclopedia of biostatistics for medical professionals. Crc Press, 2016.
- [14] Bramer M. Principles of data mining (Vol. 180). London: Springer, 2007.
- [15] Ian AC, Bengio GY. Deep Learning Book. Deep Learn.,2015, 21(1), 111-124.
- [16] Powers, D. M. Evaluation: from precision, recall and F-measure to ROC, informedness, markedness and correlation. arXiv preprint arXiv: 2010.16061, 2020.
- [17] Patra AK, Ray R, Abdullah AA, Dash SR. Prediction of Parkinson's disease using Ensemble Machine Learning classification from acoustic analysis. In Journal of Physics: Conference Series IOP Publishing, 2019. p. 012041. doi: 10.1088/1742-6596/1372/1/012041.
- [18] Choudhury A, Greene CM, Classification of Functioning, Disability, and Health for Children and Youth: ICF-CY Self Care (SCADI Dataset) Using Predictive Analytics. 2021 Mar 13. [Online]. Available from: [https://papers.ssrn.com/sol3/papers.cfm?abstract\\_id=3307719](https://papers.ssrn.com/sol3/papers.cfm?abstract_id=3307719).
- [19] Pal P, Singh B, Kaur M. Prediction of Accuracy for Hepatocellular Carcinoma Patients using Cluster based Feature Ranking, International Journal of Medical Research and Health Sciences, 2018, 7.8: 130-140.
- [20] Chaurasia V, Pal S. Data mining techniques: To predict and resolve breast cancer survivability. International Journal of Computer Science and Mobile Computing IJCSMC, 2014, 3.1: 10-22.

## Ortopedi ve Travmatolojide Yapay Zeka Uygulamaları

### *Artificial Intelligence Applications In Orthopaedics & Traumatology*

Salih BEYAZ\*<sup>1</sup>, Şahika Betül YAYLI<sup>2</sup>

#### ÖZ

Ortopedide yapay zeka konusunda yayınlanan çalışmalara bakıldığında röntgen grafisinden kırık tanıma ve eklem dejenerasyon sınıflandırma sistemleri oldukça popülerdir. Bu durumun başlıca nedeni ortopedistlerin çoğu zaman bu hastalıkların tanısında sadece röntgen grafisine bakarak karar vermeleridir. Ayrıca röntgen grafisinin manyetik rezonans görüntüleme ve bilgisayarlı tomografi görüntülerine kıyasla daha kolay işlenmesidir. Yapılan çalışmalar geliştirilen algoritmaların verdiği kararlarda ortopedist olmayan hekimlerden daha iyi ve neredeyse bir ortopedik cerraha yakınlıkta tanı koyma potansiyeli göstermektedir. Yapay zeka uygulamaları sadece görüntü odaklı tanı koyma alanında değil, preop değerlendirmede, postop takip süreçlerinin yönetiminde, hasta memnuniyetinin artırılmasında ve maliyet etkin kişisel çözümler sunarak kaynakların daha verimli kullanılmasında gelecek vaad etmektedir. Yakın gelecekte doğal dil işleme tekniklerinin de etkin hale gelmesiyle hastayı dinleyen, raporları yorumlayan sistemlerin de hayatımıza girmesi olasıdır.

**Anahtar kelimeler:** Yapay zeka, Doğal dil işleme, Ortopedi ve travmatoloji, Karar destek sistemi

**Received/Geliş :** 7.03.2021

**Accepted/Kabul:** 21.03.2021

**Publication date:** 15.04.2021

**Salih BEYAZ**

Başkent Üniversitesi, Adana  
Dr. Turgut Noyan Uygulama ve  
Araştırma Merkezi,  
Adana, Turkey,  
sbeyaz@baskent.edu.tr  
ORCID:0000-0002-5788-5116

**Şahika Betül YAYLI**

Turkcell Teknoloji, Yapay Zeka &  
Dijital Analitik Çözümler, İstanbul,  
Turkey,  
ORCID:0000-0001-5057-8634

#### ABSTRACT

The published studies about artificial intelligence in orthopedics show that fracture recognition and joint degeneration classification systems from X-ray are very popular. The main reason for this situation is that orthopedists often decide to only look at the x-ray in the diagnosis of these diseases. In addition, the easier processing of X-ray radiography compared to magnetic resonance imaging and computed tomography images increases the interest in these issues. Studies show the potential of making a diagnosis better than non-orthopedic physicians and almost closer to an orthopedic surgeon in the developed algorithms' decisions. Artificial intelligence applications are promising in image-oriented diagnosis, in preoperative evaluation, management of postoperative follow-up processes, increasing patient satisfaction and providing cost-effective personal solutions, making the use of resources more efficient. In the near future, with the use of natural language processing techniques systems that listen to the patient and interpret the reports may also enter our lives.

**Keywords:** Artificial intelligence, Natural language processing, Orthopedics and traumatology, Decision support system

## Giriş

Alan Turing 1951 yılında Mind dergisinde yayınladığı makalesinde "Makineler düşünebilir mi?" sorusuyla modern anlamdaki yapay zekanın temellerini atarken, 2017 yılında ActaOrthopædica dergisi editörü Berg (1) "Düşünebilen makineler ortopedik görüntüleme de devrim yaratacak mı?" diye sordu. Olzack ve arkadaşları, (2) derginin aynı sayısında yayınlanan makalelerinde makinelerin travma radyografilerinin okunmasında ortopedist ile yarışacak derecede iyi sonuçlar elde ettiğini bildirdi. Günümüzde yapay zekanın ortopedi alanında başlıca kullanım alanları; radyolojik görüntülerin işlenmesi, doğal dil işleme ve cerrahi karar destek sistemleridir.

## Görüntü işleme

Görüntü işleme temelli yapay zeka uygulamaları radyoloji alanında manyetik rezonans görüntüleme (MRG) ve bilgisayarlı tomografi (BT) görüntüleri üzerine yoğunlaşırken, ortopedi ve travmatoloji alanında daha çok röntgen grafilere üzerine yoğunlaşmıştır. Bu durumun başlıca nedeni çekilen grafinin yorumlanmasının ve tedavi planının yapılmasının çoğu zaman tetkiki isteyen ortopedist tarafından yapılmasıdır. Grafiyi yorumlayan ortopedistlerin aldığı eğitim ve mesleki tecrübe, tedavilerde farklılıklara neden olabilmektedir. Bu duruma gözlemciler arası ve gözlemci içi güvenilirlik adı verilir. Gözlemciler arası güvenilirlik aynı grafiye bakan farklı gözlemcilerin farklı tedavi seçenekleri önermesi, gözlemci içi güvenilirlik ise aynı gözlemcinin aynı görüntüyü farklı zamanlarda farklı yorum sunması olarak açıklanmaktadır (3). Bu durum cerrahi-konservatif tedavi ayrımında, cerrahi yaklaşımlarda ve tedavi maliyetlerinde farklılıklara neden olmaktadır. Yapay zeka uygulamalarını temel hedeflerinden biri de yoruma ve tecrübeye dayalı karar verme mekanizmalarında standardizasyonun sağlanmasıdır. Görüntü işleme temelli yapayzeka yaklaşımları, sayısı önceden belirlenecek patolojik ve normal görüntülerin tecrübeli gözlemciler tarafından etiketlenerek sistemin eğitilmesi esasına dayanır. Üzerinde çalışılacak konuda yeterli görüntünün elde edilebiliyor olması gerekir. Ayrıca öncelikli konuların belirlenmesinde problemin yaygınlığı, maliyeti ve çözümü durumunda elde edilecek faydanın (para, zaman) büyüklüğüdür. Popülasyonun giderek yaşlanmasına bağlı olarak iki büyük ortopedik problem yıllar içerisinde giderek artacağı ön görülmektedir (4). Bu sorunlar proksimal femur kırıkları ve dejeneratif eklem sorunlarıdır. Her iki sorunun da çözümü için maliyeti yüksek cerrahi tedavilerin gelecek 20 yıl içinde sayısının artacak olması araştırmacıların en büyük motivasyonudur.

Her iki konuda yapılan çalışmalar incelendiğinde iki tip makale karşımıza çıkmaktadır. Birinci tip makalelerde yazarlar geliştirdikleri yaklaşımları kendi test datalarındaki başarılarını ortaya koymaktadır. Beyaz ve arkadaşları (5) kendi geliştirdikleri derin öğrenme tekniğini ve genetik algoritma ile destekleyerek femur boyun kırığı tanıma çalışmasında %83 lük bir başarı elde ettiklerini bildirmişlerdir. Norman ve arkadaşları (6) DenseNet kullanarak yaptıkları gonartroz tanıma ve sınıflandırma çalışmasında sensitivite oranlarını sırayla evre 1, evre 2, evre 3 ve evre 4 te %83.7, %70.2, %68.9 ve %86 olarak bunun yanında spesifite oranlarını ise yine aynı sırayla %81.6, %83.8, %97.1 ve %99.1 olarak saptamıştır. Literatürdeki diğer bir çalışma türü ise eğitilen algoritmaların doktorla kıyaslandığı çalışmalardır. Lindsey ve arkadaşları (7) 135,409 grafi ile eğittikleri el bileği kırığı tanıma karar destek sistemini ortopedist olmayan 40 doktor ile karşılaştırmış, algortimanın klinisyenlerin tanı koyma sensitivitesini %80.8'den %91.5'e, spesifitelerini ise %87.5'den %93.9'e çıkardığını saptamıştır. Böylece geliştirilen algoritmalarla birlikte

bu doktorların tanı koymadaki başarısının bir ortopedi asistanı seviyesine çıktığını ortaya koymuşlardır (7). Urakawa ve arkadaşları (8) geliştirdikleri intertrokanterik kalça kırığı tanıma algoritmasını beş ortopedik cerrah ile kıyaslamış, sonuçları birbirine oldukça yakın olarak bulmuşlardır. Çalışmada, geliştirilen algoritmanın ortopediste ulaşmanın mümkün olmadığı durumlarda güvenilir bir tanı metodu olduğunu göstermişlerdir. Bu makalelerin ortak noktası, üzerinde çalıştıkları görüntülerin iki boyutlu röntgen grafilere olmasıdır. Çoğu zaman ortopedistler her iki hastalıkta da röntgen grafilere bakarak cerrahi karar verir. Bu açıdan çalışmalar elde edilmesi ve işlenmesi MRG ve BT görüntülerine kıyasla daha kolay olan röntgen grafisi üzerine yoğunlaşmıştır. MRG, BT, Pozitron Emisyon Tomografi (PET) gibi diğer görüntü modaliteleri ile yapılan çalışmalar da giderek artmaktadır.

Görüntü işleme teknikleri nadir görülen hastalıklarda da kullanımına yönelik çalışmalar mevcuttur. Zlodsek ve arkadaşları (9) röntgen grafilere tipik femur kırıklarının tanısına yönelik yaptıkları çalışmada %94 güvenilirlik oranına ulaşmışlardır. Atipik femur kırıklarının erken tanısı tedavide büyük kolaylık sağlayarak, hasta konforunu artırıp komplikasyon oranını azaltmaktadır. Derin öğrenme veya makine öğrenmesi teknikleri kullanılarak görüntü üzerinde yapılan diğer çalışma konuları vertebral patoloji incelemeleri, kemik yaşı tespiti, optimal girişim lokalizasyonun belirlenmesi, ön çapraz bağ-arka çapraz bağ konumunun çevre dokulardan ayırt edilmesi, kemik-kıkırdak segmentasyonunun yapılması şeklinde sıralanabilir. (10)

## Doğal dil işleme

Doğal dil işleme veya orijinal ismiyle Natural Language Processing (NLP), insanlar arasında konuşulan dil unsurlarının yapay zeka tarafından algılanarak, çözümlenmesi ve anlamlandırılmasıdır. Bonotratvert ve arkadaşları (11) total diz artroplastisi sonrası hasta yorumlarından hasta memnuniyetini saptamaya çalışmışlardır. Elde ettikleri verilerle, bu yorumların hastalara sunulan hizmetin geliştirilmesinde kullanılabileceği öngörüsünde bulunmuşlardır. Thirukumaran ve arkadaşları (12) ise tıbbi kayıtlara uygulanan doğal dil işleme metodları ile ortopedik cerrahi sonrası enfeksiyonunu %97 doğrulukla saptanabildiğini ortaya koyarak, bu yaklaşımın cerrahi saha enfeksiyonunun önlenmesinde faydalı olabileceğini göstermiştir. Wyles ve arkadaşları (13) ise total kalça artroplastisi yapılan hastaların ameliyat notlarından cerrahlar tarafından belirtilmiş olan unsurları incelemişlerdir. Cerrahi yaklaşıma, tespit yöntemine kullanılan implant tipini anlamlandırmayı amaçlayan algoritma geliştirmişlerdir. Elde ettikleri verileri ile manuel olarak oluşturdukları çizelgelerle kıyaslamış, geliştirdikleri algoritmanın, cerrahi yaklaşım tipini %99.2, fiksasyon tekniğini %90.7, kullanılan implant tipini ise %95.2 doğrulukla saptadığını bildirmişlerdir. Bu tekniğin klinik araştırmalarda kullanılabileceğini belirtmişlerdir. Kolanau ve arkadaşları ise radyoloji raporlarında kırık ve kırık ile ilişkili terimleri saptayan bir yazılım (XTRAIT) geliştirip bunu geleneksel yöntemlerle kıyaslamışlardır. Kırık riski daha fazla olan hastaları saptamaya yönelik yaptıkları çalışmada yazılımın insana kıyasla kırık riskini saptamada 3 kat daha başarılı olduğunu ortaya koymuşlardır (14).

Doğal dil işleme çalışmalarının önemli bir yanı da literatür taramasını hastaya spesifikleştirerek yapmayı mümkün hale getirmesidir. Tıp literatüründeki bilgi birikimi her geçen yıl katlanarak artmaya devam etmektedir ve doktorların uzmanlık alanlarındaki yeni çalışmaların tümünü takip edebilmesi giderek olanaksızlaş-

## Ortopedi ve Yapay Zekâ

maktadır. Bu kadar bilgi birikimi içinde hastanın özelliklerine en uygun tedaviyi belirlemek yani tedaviyi kişiselleştirmek giderek zorlaşmaktadır. Doğal dil işlemenin bu sorunu aşmakta yardımcı olacağı düşünülmektedir.

### Cerrahi karar destek sistemi

1970 yılında New England Medical Journal'da yayınlanan makalesinde Willam B. Schwarts "Bilişim teknolojilerinin gelecekte etkilerini artırarak hekimin entelektüel işlevlerinin yerini alacağı" öngörüsünde bulunmuştur (15). Cerrahi karar destek sistemlerinin temel amacı, insanın yorumlayabileceğinden daha fazla datayı işleyerek, tedavide hem hastaya hem de doktora yol göstermektir. Ameliyat öncesi dönemde risklerin belirlenerek optimal şartların sağlanmasını, cerrahi sırasında hastaya özel çözüm stratejilerinin geliştirilmesini ameliyat sonrası dönemde ise komplikasyonların ortaya çıkmadan öngörülerek önlenmesini sağlar (16). Geleneksel tahmine dayalı analitik sistemler ile kıyaslandığında yapay zeka tabanlı cerrahi karar destek sistemlerinin postoperatif dönemde daha fazla hasta memnuniyeti, kaynakların daha verimli kullanılması, önyargıların önlenmesinde ve öngörülebilir hataların önüne geçilmesinde oldukça başarılıdır (16).

31.304 hastanın yer aldığı sistematik derlemede yapay zeka tabanlı karar destek sistemleri ile tedavileri konusunda daha aktif rol oynadıklarını ve daha fazla bilgi sahibi olduklarını ortaya koymuştur (17). Kim ve arkadaşları (18) posteriorlomber füzyonu takiben hastaların mortalite, venöztromboemboli, kardiyak komplikasyon ve yara ile ilişkili komplikasyonlarını öngörmeye yönelik yaptıkları çalışmada bu komplikasyonlar için ASA standardını yakalamıştır. Benzer bir çalışmada da Pereira ve arkadaşları (19) üç farklı metodlametastatikvertebra hastalıklarında mortalite riskini hesaplamış, bir yöntemlerinin (nomogram) 30 gün, 90 gün ve 365 günlük yaşam beklentisi öngörüsünde klasik skorlama algoritmalarından daha iyi olduğunu göstermişlerdir. PathFx ise metastatik kemik hastalıklarının kişiselleştirilmiş tedavisi için geliştirilmiş bir araçtır ve tedavi seçeneklerinin kararını vermek konusunda çeşitli popülasyonlar üzerinde yapılan testlerden başarıyla geçmiştir (20-21). Fontana ve arkadaşları (22) total eklem artroplastisinin 2 yıllık sonucunu tahmin etmek için geliştirdikleri algoritmayla çok yüksek bir başarı elde edemelerine karşın, programın gelecek vadettiğini bildirmişlerdir. Bunun gibi karar destek araçları sayesinde hastaya en uygun tedavi seçeneğini belirleyebilmek ve daha da önemlisi komplikasyon oranlarının azalmasına katkıda bulunacaktır. Ayrıca doktorların hastayı değerlendirirken ve karar verirken önyargılarından da sıyrılmaları kolaylaşacak, daha optimize karar sistemlerinin oluşması sağlanacaktır (23). Geliştirilmeye çalışılan karar destek sistemlerinin temel amaçlarından biri doktorların klinikte zamanını daha verimli geçirecek, hasta muayenesine daha çok zaman ayırabilmesine ve karar için daha geniş zamana sahip olmasına olanak sağlamaktır (24).

### Sonuç

Yapay zeka uygulamaları tıbbın her alanında olduğu gibi ortopedi alanına da yeni bir bakış açısı getirmekte, tanıdan tedaviye, operasyon öncesi endikasyonu belirlemeden, prognoz öngörülerine kadar birçok alanda ortopedistlerin karar vermelerini kolaylaştırıcı bir unsur olmaktadır. Hasta açısından bakıldığında ise her bireyin eşit ve en etkili tedaviye ulaşmasının sağlanmasının yanında, komplikasyonların ortaya çıkmadan engellenmesini sağlamaktadır. Teorik olarak elde edilen başarıların, pratik uygu-

lamaya geçirilmesi için ciddi hukuki düzenlemelere ihtiyaç vardır. En büyük sorunlardan biri, doktor farklı bir karar verdiğinde sorumluluğu kimin üstleneceğidir. Bu nedenle yakın gelecekte hayatımıza girecek karar destek sistemlerinin, tanı ve tedavi sürecine insan bağımsız karar vermeleri için zamana ihtiyaç vardır.

**Çıkar Çatışması:** Yoktur.

**Finansal Destek:** Yoktur.

**Conflict of Interest:** None.

**Funding:** None.

### Yazar Katkıları

**Motivasyon / Konsept:** Beyaz S., Yaylı Ş.B.

**Çalışma Tasarımı:** Beyaz S., Yaylı Ş.B.

**Kontrol / Gözetim:** Beyaz S., Yaylı Ş.B.

**Veri Toplanması ve / veya İşlemesi:** Beyaz S., Yaylı Ş.B.

**Analiz ve / veya Yorum:** Beyaz S., Yaylı Ş.B.

**Literatür inceleme:** Beyaz S., Yaylı Ş.B.

**Makalenin Yazılması:** Beyaz S., Yaylı Ş.B.

**Eleştirel İnceleme:** Beyaz S., Yaylı Ş.B.

### Kaynaklar

- 1- Berg, Hans E. WillIntelligent Machine Learning RevolutionizeOrthopedicImaging? ActaOrthopaedica. 2017;88(6), 577–577. DOI: 10.1080/17453674.2017.1387732.
- 2- Olczak, J.,Fahlberg N., Maki A, et al. ArtificialIntelligenceforAnalyzingOrthopedicTraumaRadiographs. ActaOrthopaedica. 2017;88(6):581-586. DOI: 10.1080/17453674.2017.1344459
- 3-Audigé, Laurent, et al. How ReliableAreReliabilityStudies of FractureClassifications? A SystematicReview of TheirMethodologies. ActaOrthopaedicaScandinavica. 2004;75(2) 184–194. DOI: 10.1080/00016470412331294445.
- 4- Jeana,Z.,Elainea, D., Danielc, PA. et.al. Osteoporosisepidemiologyusinginternationalcohorts, CurrentOpinion in Rheumatology: 2020;32(4)-387-393 DOI: 10.1097/BOR.0000000000000722
- 5- Beyaz, S.,Acici K., Sumer E. FemoralNeckFractureDetection in X-Ray Images Using Deep Learning and GeneticAlgorithmApproaches. JointDiseases and RelatedSurgery. 2020;31(2)175–183. DOI: 10.5606/ehc.2020.72163.
- 6-Norman B.,Pedoia V., Noworolski A., et al. Applyingdensely-connectedconvolutionalneuralnetworksforstagingosteoarthritis-severityfromplainradiographs. J DigitImaging 2019;32(03):471–477. DOI: 10.1007/s10278-018-0098-3
- 7-Lindsey R.,Daluisi A., Chopra S., et al. DeepNeural Network ImprovesFractureDetectionbyClinicians. Proceedings of the National Academy of Sciences. 2018, vol. 115, no. 45, 11591–11596. DOI: 10.1073/pnas.1806905115
- 8-Urakawa T.,Tanaka Y., Goto S., et al. DetectingIntertrochantericHipFractureswithOrthopedist-Level Accuracy Using a DeepConvolutionalNeural Network. SkeletalRadiology, 2019 Feb;48(2):239-244.DOI:10.1007/s00256-018-3016-3.
- 9-Zdolsek G, Chen Y., Bögl HP, et al. Deepneuralnetworkswithpromisingdiagnosticaccuracyfor the classification of atypicalfemoralfractures, ActaOrthopaedica 2021, DOI: 10.1080/17453674.2021.1891512
- 10- Cabitza, F.,Locoro, A., Banfi, G. Machine learning in orthopedics: A literaturereview. Front BioengBiotechnol. 2018 Jun27;6:75. DOI: 10.3389/fbioe.2018.00075
- 11-Bovonratwet P, Shen TS, Islam W, Ast MP, Haas SB, Su EP. Natural Language Processing of Patient-ExperienceCommentsAfterPrimary Total KneeArthroplasty. J Arthroplasty. 2021;36(3):927-934. DOI:10.1016/j.arth.2020.09.055

- 12-Thirukumar CP, Zaman A, Rubery PT, et al. Natural Language Processing for the Identification of Surgical Site Infections in Orthopaedics. *J Bone Joint Surg Am.* 2019;101(24):2167-2174. DOI:10.2106/JBJS.19.00661
- 13-Wyles CC, Tibbo ME, Fu S, et al. Use of Natural Language Processing Algorithms to Identify Common Data Elements in Operative Notes for Total Hip Arthroplasty. *J Bone Joint Surg Am.* 2019;101(21):1931-1938. DOI:10.2106/JBJS.19.0007
- 14-Kolanu N, Brown AS, Beech A, Center JR, White CP. Natural language processing of radiology reports for the identification of patients with fracture. *Arch Osteoporos.* 2021 Jan 6;16(1):6. doi: 10.1007/s11657-020-00859-5.
- 15-Schwartz WB. Medicine and the computer: the promise and problems of change. *N Engl J Med.* 1970;283(23):1257-1264. doi:10.1056/NEJM197012032832305
- 16-Loftus TJ, Tighe PJ, Filiberto AC, et al. Artificial Intelligence and Surgical Decision-making. *JAMA Surg.* 2020;155(2):148-158. doi:10.1001/jamasurg.2019.4917
- 17-Stacey D, Légaré F, Lewis K, et al. Decision aids for people facing health treatment or screening decisions. *Cochrane Database Syst Rev.* 2017;4: CD001431. doi:10.1002/14651858.CD001431.pub5
- 18- Kim JS., Merrill RK., Arvind V., et al. Examining the Ability of Artificial Neural Networks Machine Learning Models to Accurately Predict Complications Following Posterior Lumbar Spine Fusion. *Spine.* 2018 Jun 15;43(12):853-860. DOI: 10.1097/BRS.0000000000002442.
- 19-Pereira NRP, Janssen, SJ., Dijk, EV., et al. Development of a prognostic survival algorithm for patients with metastatic spine disease. *J Bone Joint Surg Am.* 2016 Nov 2;98(21):1767-1776. DOI: 10.2106/JBJS.15.00975
- 20-Piccioli, Andrea, et al. How Do We Estimate Survival? External Validation of a Tool for Survival Estimation in Patients with Metastatic Bone Disease—Decision Analysis and Comparison of Three International Patient Populations. *BMC Cancer.* 2015 May 22;15:424. DOI: 10.1186/s12885-015-1396-5
- 21- Forsberg, J. A., Wedin, R., Boland, P. J. et al. Can we estimate short- and intermediate-term survival in patients undergoing surgery for metastatic bone disease? *Clin Orthop Relat Res.* 2017;475(4):1252-1261. DOI: 10.1007/s11999-016-5187-3
- 22-Fontana, MA., Lyman S., Sarker GK., et al. Can Machine Learning Algorithms Predict Which Patients Will Achieve Minimally Clinically Important Differences From Total Joint Arthroplasty? *Clin Orthop Relat Res.* 2019 Jun;477(6):1267-1279. DOI: 10.1097/CORR.0000000000000687
- 23-Cilla, Myriam, et al. Machine Learning Techniques for the Optimization of Joint Replacements: Application to a Short-Stem Hip Implant. *PLoS One.* 2017 Sep 5;12(9):e0183755. DOI: 10.1371/journal.pone.0183755.
- 24-Oosterhoff JHF, Doornberg JN; Machine Learning Consortium. Artificial intelligence in orthopaedics: false hope or not? A narrative review along the line of Gartner's hype cycle. *EFORT Open Rev.* 2020 Oct 26;5(10):593-603. DOI: 10.1302/2058-5241.5.190092

## Covid-19 Pandemic and Investigation of Artificial Intelligence Applications Used in the Pandemic

### *Covid-19 Pandemisi ve Pandemi Sürecinde Kullanılan Yapay Zekâ Uygulamaları*

Beşir Sefa MUMAY\*<sup>1</sup>, Ceren MUTLU<sup>2</sup>

#### ABSTRACT

It is certain that there have been dozens of pandemics in human history that caused mass deaths and destruction. Covid-19 disease has also turned into a pandemic with its rapid and intercontinental spread. According to some sources, the Covid-19 pandemic is one of the worst disasters in human history. Despite very serious precautions taken worldwide, Covid-19 continues to threaten health systems and human life. Under these conditions, humanity needs faster, cheaper, more efficient and more accurate diagnostic and treatment methods both in order to control the current pandemic and to be prepared for new pandemics. Undoubtedly, artificial intelligence technologies that are correctly designed and put into service will provide us with this support. In fact, many simultaneous vaccination studies, many applications that make life easier during the pandemic period, the use of artificial intelligence algorithms with foresight and predictive ability, have somewhat reduced the destruction of the pandemic. This study aims to evaluate the coronavirus-induced pandemics and SARS-CoV-2 virus in general in the light of current data and literature, to explain the features of artificial intelligence, and to present examples of artificial intelligence applications used in the pandemic period.

**Received/Geliş** : 11.03.2021

**Accepted/Kabul:** 26.03.2021

**Publication date:** 15.04.2021

**Beşir Sefa MUMAY**

<sup>1</sup>Istanbul University, Institute of Health Sciences, Department of Pharmaceutical Technology, İstanbul, TURKEY.

ORCID: 0000-0002-5097-8395

**Ceren MUTLU**

<sup>2</sup>Istanbul University, Faculty of Pharmacy, İstanbul, TURKEY.

\*sefamumay@gmail.com

ORCID: 0000-0003-2839-0146

**Keywords:** Coronavirus, Covid-19, Pandemic, Artificial Intelligence, SARS-CoV-2

#### ÖZ

İnsanlık tarihinde toplu ölümlere ve yıkımlara sebep olan onlarca pandemi yaşandığı kuşkusuzdur. Hızlı ve kıtalar arası sınır tanımayan yayılımıyla Covid-19 hastalığı da bir pandemiye dönüşmüştür. Covid-19 pandemisi, bazı kaynaklara göre insanlık tarihinin başına gelen en büyük felaketlerden biridir. Dünya genelinde alınan çok ciddi önlemlere rağmen Covid-19 sağlık sistemlerini ve insan yaşamını tehdit etmeye devam etmektedir. Bu şartlar altında hem mevcut pandemiye kontrol altına almada hem de yeni pandemilere karşı hazırlıklı olma noktasında insanlık daha hızlı, daha verimli, daha düşük maliyetli ve daha fazla doğruluğa sahip tanı ve tedavi yöntemlerine ihtiyaç duymaktadır. Hiç kuşkusuz doğru tasarlanmış ve hizmete sunulmuş yapay zekâ teknolojileri bize bu desteği sağlayacaktır. Öyle ki, eş zamanlı yürütülen birçok aşı çalışması, pandemi döneminde hayatı kolaylaştıran birçok uygulama, öngörü ve tahmin yeteneği olan yapay zekâ algoritmalarının kullanımı gibi durumlar, pandeminin yıkıcılığını bir miktar azaltmıştır. Bu çalışmanın amacı; güncel veriler ve literatür ışığında, koronavirüs kaynaklı pandemileri ve SARS-CoV-2 virüsünü genel olarak değerlendirmek; yapay zekanın özelliklerini açıklayarak pandemi sürecinde kullanılan yapay zekâ uygulamalarına örnekler sunmaktır

**Anahtar Kelimeler:** Koronavirüs, Covid-19, Pandemi, Yapay zekâ, SARS-CoV-2



**Introduction**

Pandemic is a term that means “affecting all humanity”, which is a combination of the words “pan” meaning “all” and “demos” meaning “people” in the ancient Greek language (1). The World Health Organization (WHO) defines a pandemic as “non-seasonal and rapidly spreading infectious diseases in which the human population does not have immunological resistance” (2). In pandemics, people experience not only health problems but also social and economic problems. Every epidemic in history has ended with great damage. Every pandemic in history has ended with a lot of damage.

According to some sources, the Covid-19 pandemic is one of the biggest disasters in human history. The current number of cases and deaths proves the seriousness of the situation to us every day. If this pandemic had occurred at a time when science and technology were not as advanced as this time, the power of destruction has been much greater. In fact, many simultaneous vaccination studies, many applications that make life easier during the pandemic period, the use of artificial intelligence algorithms with foresight and predictive ability, have somewhat reduced the destruction of the pandemic. Disruptive technologies and artificial intelligence are the key factors in making all these happen.

The concept of artificial intelligence first emerged in the 1950s. It has become widespread since 2010; After 2015, it started to be talked about in all areas of life. Artificial intelligence is a concept that we all need to adapt to and understand. In this study, the artificial intelligence applications used in the pandemic period were examined by explaining the Covid-19 Pandemic and the concept of artificial intelligence.



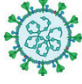

**Examination of coronavirus related pandemics**

Although the coronavirus that caused the pandemic didn’t sound familiar at first, it is likely that most people have encountered milder strains of this virus family before, as four strains of coronaviruses are responsible for approximately 20% of common cold cases (4). This pathogen, which has not been detected in humans before, has been identified as a new type of coronavirus. The causative virus was first named as 2019-nCoV (2019-novel coronavirus) and then SARS-CoV-2 due to its 70% similarity to SARS-CoV. WHO declared Covid-19 as a pandemic on March 11, 2020 (8, 9).

20 years ago, since coronaviruses cause only mild illnesses in humans, coronaviruses were not the focus of research. In 2003, it was discovered that the pathogen causing the SARS (Severe Acute Respiratory Syndrome) pandemic was the type of coronavirus, and researchers began to focus on this issue (4). The cause of SARS pandemic in China has been determined as “SARS-CoV” and the virus infected 8000 people around the world and killed approximately 800 people (5). About 10 years later, in 2012, another coronavirus strain caused the MERS (Middle East Respiratory Syndrome) outbreak. The strain that caused the MERS Pandemic originating from Saudi Arabia was named MERS-CoV, has spread to 27 different countries in 4 continents, killing 791 people (5, 6). In Table 1, epidemiological comparison of viral respiratory diseases as of March 2020 is given.

The WHO China Country Office reported cases of pneumonia of unknown cause in Wuhan, China, on December 31, 2019 (7). Most of these early cases were associated with the Huanan sea-food market, where livestock and seafood were sold. Later, in studies to find the origin of the virus, the most similar gene se-

quences were found in coronaviruses originating from bats. With these results, scientists thought that the virus was transmitted from bats. However, since bats were not sold in the Huanan sea-food market, it was concluded that another animal species was an intermediate carrier in the transmission of the virus to humans (4).

Disease	Flu	Covid-19 S	ARS	MERS
<b>Pathogen</b>	 Influenza virus	 SARS-CoV-2	 SARS-CoV	 Mers-CoV
<b>R<sub>0</sub> (Basic Reproduction Number)</b>	1.3	2.0 – 2.5*	3	0.3 – 0.8
<b>DTR (Death to-case Ratio)</b>	%0.05 – 0.1	~ %3.4*	%9.6 – 11	%34.4
<b>Incubation Time</b>	1 – 4 day	4 – 14 day*	2 – 7 day	6 day
<b>Possibility of Transmission</b>	%10 – 20 %	30 – 40*	%10 -60	%4-13
<b>Annual Number of Patients (Global)</b>	~ 1 billion U	nknown (In 3.5 months 145.000+)*	8098 (In 2013)	420


**Table 1.** Epidemiological Comparison of Viral Respiratory Diseases

**SARS-CoV-2 and covid-19**

SARS-CoV-2 is a single-stranded, positive-polarity enveloped Ribonucleic acid (RNA) virus located in the Coronaviridae sub-family of the Nidovirales class (8). The virus contains four main structural proteins which are: Nucleocapsid (N) protein, Transmembrane (M) protein, Envelope (E) protein and Spike (S) protein. These structures are shown in Figure 1.

The S (spike) protein in the structure of the virus enables the virus to enter the target cell by recognizing the receptor. After binding to the receptor, the S protein undergoes a structural change and with this change, the virus can release its own RNA into the cell. New viruses, which are formed as a result of a series of reactions taking place inside the cell with virus RNA and viral proteins, are released from the host cell through exocytosis and thus cause infection (5, 10).

The structural S protein, which also gives the virus its major antigenic property, shows high affinity for the Angiotensin Converting Enzyme 2 (ACE2) receptor in humans. ACE2 enzyme is highly expressed in the human body primarily in the lung tissue and then in the heart, kidney, vascular endothelium and intestinal epithelium. The widespread distribution of the ACE2 enzyme in different vital tissues in the body also explains the multiple organ failure seen in patients (8).



**Figure 1.** Schematic Representation of the SARS-CoV-2 Virus

## Covid-19 and AI applications

The mechanism of these injuries caused by the SARS-CoV-2 virus in the body has not been fully discovered, but it is known that the disease begins with flu-like symptoms and the infection progresses with varying severity from person to person (5). The most common symptoms of Covid-19 so far are dry cough, high fever, and fatigue. The disease progresses with loss of taste and smell, diarrhea, headache, nasal congestion, and rashes on the body. At the same time, in severe cases, the disease can turn into pneumonia and respiratory support may be needed. The infection has a more severe course especially in elderly individuals who are considered high-risk group as well as those with underlying chronic diseases. Babies, children, and young people also have the possibility of contracting and transmitting Covid-19 (6).

It is known that the disease is transmitted from person to person through droplets. Regardless of whether the patient is symptomatic or asymptomatic, the virus enters the body and spreads as a result of contact with droplets spreading from infected individuals through the mouth, nose, or eye mucosa (6). The period from infection with the virus to the onset of symptoms is called the incubation period. The most critical point is that people can transmit the disease in this presymptomatic stage (11).

Numerous clinical studies are ongoing in which new agents and drugs currently used for different indications are being tested in the treatment of Covid-19 (8). At the same time, scientists are competing with each other to develop vaccines to control this pandemic. It took a year for various vaccines to enter the application phase, and there are no curative treatments or drugs yet. Despite very serious precautions taken worldwide, Covid-19 continues to threaten health systems and human life. Under these conditions, humanity needs faster, cheaper, more efficient and more accurate diagnosis and treatment methods, both to control the current pandemic and to be prepared for future pandemics. Surely, artificial intelligence technologies that are correctly designed and put into service will provide us with this support.

### The concept of artificial intelligence (AI)

The clearest definition of the concept of AI in the literature is "Digital technology and/or applications that have the ability to imitate human beings, interact, learn, adapt and apply by expanding their experience" (12). AI is arguably the most popular topic of computer sciences and technology.

The first article about AI was written by Turing in 1950. In this article, rather than technical and hardware information; The philosophical dimension of the issue was discussed by posing the question "Can a machine think like a human?" (3). The main purpose of AI applications is to understand and apply the human mindset and decision-making mechanism of the mind. The first event that brought the ability of a machine to think and therefore the concept of intelligence to the literature and made these concepts recognized worldwide was International Business Machines's (IBM) virtual chess player, Deep Blue, defeating even the toughest players. AI algorithms occur with;

- Learning and understanding experiences,
- Evaluating the results,
- Ability to detect similarities between different situations (13).

The concept of artificial intelligence has many categories. AI categorization can be examined under three sections (14-16):


1. Rule-Based AI (Expert Systems, Decision Support Systems, Algorithms etc.)
2. Decision-Maker AI (Genetic Algorithm Code, Text Mining etc.)
3. Learning AI (Artificial Neural Networks, Deep Learning etc.)

The systems that AI algorithms decide by thinking like an expert in any subject are called expert systems. The concept of expert system can briefly be described as "Getting the information ready to be processed or making it processable and then its combination with machine learning." AI algorithms in expert systems are the basis of the decision mechanism (17, 18). It receives the information necessary to make a decision from the expert person and interprets it according to the information provided by the person who will use the system. Data is added to the database by experts, and outputs are taken by non-experts. AI is currently used in fields such as medical diagnosis, construction, coding, banking, transportation, and defense industry, and it is predicted that it can be used in almost every field in the future (13).

Although expert systems seem very complex in structure, when examined, they are actually simple systems. The information taken from the expert source specific to the subject under consideration passes through the decision-making mechanism and provides an output. The basic structure of expert systems is given in Figure 2. An expert system should include these parts;

- Database,
- Exit mechanism,
- Advanced chaining mechanism,
- User interface (19).

When we approach AI algorithms not technically but systematically, four main elements stand out: Verification, validity, security and supervision. These are described in Table 2 (20-24).



**Figure 2.** Fundamental Structure of Expert Systems

Elements	Definition
Verification	It is described as "proving or measuring the conformity of certain systems and / or applications to certain standards in a satisfactory and desired manner". The verified system is the systems in which no deviation occurs while the input is reflected in practice. In this way, artificial intelligence algorithms can be kept updated and effective.
Validity	Making sure that the system is set up correctly, shows the validity of that system. With this element, it is understood whether the system is suitable for the procedure or not.
Security	In areas where the use of artificial intelligence algorithms is critical, such as the defense industry, the security element plays an important role.
Control	Artificial intelligence algorithms can create their own self-control, but human control is constantly required. Because errors in such systems can produce very bad results.

**Table 2.** Systemic Elements of Artificial Intelligence Algorithms and Explanations of These Elements

## Artificial neural networks (ANN)

ANNs are information processing systems that mimic biological neural networks that form the parts of the brain and the thinking structure (25). ANN performs the desired tasks by learning from the examples given. For example, after reviewing sample photos labeled “dog” or “not dog”, they can learn to identify dogs in other pictures. They analyse the image pixel by pixel and generate distinctive features from the given and processed samples (26). Figure 3 shows a structure created using ANN. There may be more than one network connection in the middle outside the input and output areas. The example given in the figure is a single-link structure.

### Artificial intelligence applications used during the pandemic process

#### 1- Predicting and reporting the spread of the pandemic


One of the biggest challenges in the fight against Covid-19 is the lack of data and the uncertainty it brings. AI technology is one of the tools that can be used to eliminate some of these uncertainties. AI technologies accompanied by machine learning are able to achieve much faster and more consistent results than humans in processing existing information, processing data sets, establishing contextual relationships between data and decision-making processes (27). When these data analyses are used well, the transmission chains of the coronavirus can be broken, the domain of the pandemic can be reduced and even future outbreaks can be predicted.

Bluedot, a platform developed in Canada, is one of the companies using AI technology to protect humanity from infectious diseases. This platform managed to warn the Canadian government and its users about the “unusual pneumonia” that occurred in Wuhan, China, approximately 1 month before the WHO in December 2019. This platform, which examines international news reports, animal and plant disease networks, and official notifications with an AI-based algorithm, also points to new systems that can be used to ensure early measures to be taken by predicting future pandemics (27).

Various countries struggling with the virus at the point of controlling the spread of the outbreak have developed mobile applications that use different technologies such as Bluetooth, Global Positioning System (GPS), contact information, card transactions, and network-based Application Programming Interface (API). All these digital applications collect personal data and analyze them with artificial intelligence tools and thus help report the level of transmission of the disease. Studies show that more than 36 countries use these practices successfully (28, 29). South Korea, one of these 36 countries, has implemented a contact tracking system known as “Covid-19 Short Message Service (SMS)”. This system, which monitors the movements of individuals diagnosed with Covid-19, with data such as security camera images and credit card records, actively monitors people’s compliance with quarantine for 14 days. The system also sends notifications to people who may have been exposed to Covid-19 by contacting these individuals before diagnosis. South Korea was able to contain the spread of the outbreak in this way (30, 31).

In China, “Outbreak Prediction Technology” developed by the Alibaba is used. This structure, which is basically a cloud system, provides 98% prediction accuracy by using data such as flight information, number of new cases, number of close contacts, contact date. With this system using AI and machine learning, an effective outbreak strategy has been developed (27). Other coun-

tries and applications using digital contact tracking applications are as shown in Table 3 (28).



**Figure 3.** Example of Artificial Neural Networks  
**2- Control and detection of cases**

Whether it is contagious or not, early diagnosis of any disease is important for early treatment and saving more lives (28). When it comes to combating pandemics such as Covid-19, these rapid screening and diagnosis processes become an important factor affecting the future of societies. AI technology have been shown to help in the diagnosis of cases using medical imaging technologies such as Computerized Tomography (CT), and Magnetic Resonance Imaging (MRI) (29).

In a retrospective and multi-center study, a deep learning model that can detect Covid-19 from volumetric chest CT has been developed. This system, called the Covid-19 Perception Neural Network (COVNet), has been fed with 4356 chest CT exams taken from a total of 3322 patients. COVNet trained with a data group, which includes both Community-Acquired Pneumonia (CAP) and non-pneumonia CT samples, could distinguish Covid-19 from Community-Acquired Pneumonia and other lung diseases with 90% sensitivity and 96% specificity (32). The performance of COVNet is shown in Table 4.

A new Covid-19 diagnostic system that uses artificial intelligence and deep learning techniques has been developed in Turkey. The data set of the system consists of coronavirus, pneumonia, and normal CT X-ray images. It has been shown that this model can make an effective contribution in the detection of Covid-19 by achieving 99.27% success in classification (33).

In the United States of America (USA), a software developed with artificial intelligence at the Massachusetts Institute of Technology (MIT) can detect individuals with Covid-19 only using their cough sounds. MIT researchers discovered that the coughing characteristics of these individuals, even if they are asymptomatic, are different from healthy individuals. Then they trained artificial intelligence with cough samples and vocal words to detect cases. This software has been proven to detect up to 100% of asymptomatic cases correctly (34).

Considering that asymptomatic individuals are of critical importance in the transmission between individuals, it can be said that the widespread use of this software will be of great importance in the control of the pandemic.

The “Covid-19 Test Home Collection Kit”, in partnership with Kroger Health and Gauss companies in the USA, offers people the opportunity to make test in a home. Test kit is also supported by a mobile application. The test kit is analyzed in the laboratory and all steps of process can be controlled by the AI-based mobile application. Patient who would like to get tested follow step-by-step video instructions in this mobile application. Working with an AI-based technology, the application gives test results. According to results of a clinical trial submitted to the Food and Drug Administration (FDA) by the companies, the testing solution demonstrated a 93% positive correlation and 99% negative correlation compared to high-sensitivity, emergency-use-au-

## Covid-19 and AI applications

thorized Polymerase Chain Reaction (PCR) tests. Covid-19 Test Home Collection Kit has been authorized for emergency use by FDA under an Emergency Use Authorisation (EUA) (35). This test promises great potential in reducing the workload of health-care professionals.

Sl. No	Country	Contact Tracing App	Location Tracking	Launch on
1	Australia	COVIDSafe	BlueTrace protocol: Bluetooth	April 14,2020
2	Austria	Stopp Corona	Bluetooth, Google/Apple	March, 2020
3	Bahrain	BeAware Bahrain	Bluetooth & GSM	March 31, 2020
4	Bulgaria	Virusafe	GSM	May, 2020
5	China	Conjunction with Alipay	GPS, GSM, credit-card-transaction-history	Very little info
6	Cyprus	CovTracer	GPS, GSM	May, 2020
7	Colombia	CoronaApp	GPS	April 12, 2020
8	Czech Republic	eRouska (eFacemask)	BlueTrace protocol: Bluetooth	April 15, 2020
9	Estonia	Estonia's App	Google/Apple, DP-3T, Bluetooth	April, 2020
10	Finland	Ketju	DP-3T, Bluetooth	May, 2020
11	France	StopCovid	Bluetooth	May, 2020
12	Germany	CoronaApp	Bluetooth, Google	May, 2020
13	Ghana	GH Covid-19 Tracker App	GPS	April 12, 2020
14	Hungary	VirusRadar	Bluetooth	May 13, 2020
15	Iceland	Rakning C-19	GPS	April, 2020
16	India	Aarogya Setu	Bluetooth & location-generated social graph	April 2, 2020
17	Iran	Mask.ir	GSM	May, 2020
18	Ireland	HSE Covid-19 App	Bluetooth, Google/Apple	May, 2020
19	Israel	HaMagen	Standard location APIs	March, 2020
20	Italy	Immuni	Bluetooth, Google/Apple	May, 2020
21	Jordan	AMAN App-Jordan	GPS	May, 2020
22	Latvia	Apturi Covid	Bluetooth	May 29, 2020
23	Malaysia	MyTrace	Bluetooth, Google/Apple	May 3, 2020
24	Mexico	CovidRadar	Bluetooth	May, 2020
25	New Zealand	NZ COVID Tracer	Contact details and physical address	May 20, 2020
26	North Macedonia	StopKorona	Bluetooth	April 13, 2020
27	Norway	Smittestopp	Bluetooth and GSM	April 16, 2020
28	Poland	ProteGO	Bluetooth	May, 2020
29	Qatar	Ehteraz	Bluetooth and GSM	May, 2020
30	Saudi Arabia	Corona Map	Bluetooth	April 3, 2020
31	Singapore	TraceTogether	BlueTrace protocol: Bluetooth	March 20, 2020
32	South Korea	Non-app-based	Mobile device tracking data and card transaction data	May, 2020
33	Switzerland	SwissCovid	DP-3T protocol, Bluetooth, Google/Apple	May 20, 2020
34	Turkey	Hayat Eve Sığar	Bluetooth, GSM	April, 2020
35	UAE	TraceCovid	Bluetooth	May, 2020
36	UK	NHS Covid-19 App	Bluetooth	May, 2020

**Table 3.** Digital Contact Tracking Application

### 3- Biochemical test analysis

For people who have had Covid-19 disease, it is important to perform a blood test after the disease and to interpret the test results. Previous research has shown that, it is possible to read and interpret biochemical test results with AI (36, 37). Biochemical tests performed before and after a person's death can be compared and interpreted with the help of AI. In addition, thanks to AI algorithms, the reasons for which each out of limit value may arise can be analyzed and the highest probability case solutions can be made in this way.

### 4- Treatment, drug and vaccine development studies

Technology is used in drug and vaccine development studies. A traditional drug development process requires many years and very high costs. In fact, it is necessary to experiment with at least 10.000 similar molecules until the ideal molecule is found. AI can help with shortening these processes. Researchers use AI-based technologies to find new chemical molecules. AI-based technologies are important for finding the molecule with optimum properties (27). Researchers are working to identify and use AI-based innovative methods.

Considered to be the world's most powerful supercomputer, IBM Summit, with 200 quadrillion calculations per second, simulated 8000 different molecules available in the market in a short time and identified 77 molecules that could cure the infection by the virus. Under normal conditions, it is not possible to carry out such a study in such a short time. Experimental studies are needed to determine the molecule that gives the best results out of these 77 molecules (38).

The United Kingdom-based company Benevolent AI has proposed several compounds that are predicted to be effective when combined with molecular modeling based on the genomes of the relevant virus proteins (39).

Hong Kong-based Insilico Medicine has announced that it uses artificial intelligence infrastructure to design a molecule that can inhibit the ability of virus to reproduce. It was announced by the company officials that 100 molecules were determined among 100,000 molecules to be synthesized and tested by machine learning technique, and a 7-molecule component determined among these 100 molecules could be used for drug production. It is stated that with the help of the deep learning technique called Generative Tensorial Reinforcement Learning (GENTRL), new molecular structures with optimized properties can not be found using standard calculation methods (40, 41). Insilico Medicine company is one of the most active companies in the fight against Covid-19.

Another company working in this field is StoneWise. This firm announced that it obtained more than 1400 nucleoside components with the AI-based combination of nucleoside-based RNA polymerase inhibitors (42). All of these 1400 compounds are likely to be therapeutically useful compounds.

### 5- Patient data collection and storage

AI can also help create an electronic archive that can hold all medical transactions, records, assets and reports. With the increasing speed of storage capacity expansion such as flash disks, hard drives, optical media, flash drives that can hold huge volumes of information, it is becoming increasingly difficult for researchers to keep and analyze all this information (26). AI can be a reasonable resource for storing, interpreting, and using this type of data. It is important to set up these systems not only to store but also

to use the information stored in the warehouse. With the help of a decision-maker AI algorithm, information can be compared and new rules can be found. According to IBM, AI can be useful in examining patients' past health records and establishing correlations between patients (43).

	Sensitivity %	Specificity %	AUC	P-value
<b>Covid-19</b>	90 (114 of 127) [83, 94]	96 (294 of 307) [93, 98]	0.96 [0.94, 0.99]	<0.001
<b>CAP</b>	87 (152 of 175) [81, 91]	92 (239 of 259) [88, 95]	0.95 [0.93, 0.97]	<0.001
<b>Non-Pneumonia</b>	94 (124 of 132) [88, 97]	96 (291 of 302) [94, 98]	0.98 [0.97, 0.99]	<0.001

Note: Values in parentheses are the numbers for the percentage calculation. Values in brackets are 95% confidence intervals [95%CI, %]. AUC=area under the receiver operating characteristic curve. Covid-19 = coronavirus disease 2019, CAP=community acquired pneumonia, COVNet=Covid-19 detection neural network.

**Table 4.** Performance of COVNet, the Deep Learning System, in the Independent Test Set

### Conclusion and discussion

There have been many pandemics in human history such as The Plague, Ebola, Spanish Flu and Acquired Immune Deficiency Syndrome (AIDS). It is a fact that new pathogens will keep emerging in the future that will lead to new pandemics.

In addition to causing serious health problems and mass death, pandemics also cause irreparable damage to social life, economy, and education. Therefore, the prevention and control of pandemics go beyond being a medical problem (2).

Covid-19, which has spread to more than 200 countries since its detection in China, continues to cause more and more deaths every day. Humanity, who seeks a solution to the virus that brings human life to a standstill, actively uses AI in prevention, diagnosis, and treatment. Surely, AI technologies that are properly designed and put into service; can increase productivity for new projects, reduce costs for health services, and provide greater accuracy and precision during diagnosis and treatment.

Some questions remain unanswered for now: "When will the Covid-19 pandemic end?" or "Can an effective drug or treatment be found for the virus?" However, with this pandemic, it has been seen that the whole world should be more prepared for possible future pandemics. In the light of these lessons learned with AI in the Covid-19 process, it is a need, even a necessity, to focus on studies for possible new pandemics.

### Acknowledgements

Thanks to Pharm. Selin PALABIYIKOĞLU for her support to the study.

### References

- 1- Aslan R. Tarihten Günümüze Epidemiler, Pandemiler ve Covid-19. *Ayrıntı Dergisi*. 2020 Apr;8:85.
- 2- Özkoçak V, Koç F, Gültekin T. Pandemilere antropolojik bakış: koronavirüs (covid-19) örneği. *Turkish Studies*. 2020 Apr;15(2):1183-1195. doi: 10.29228/TurkishStudies.42679
- 3- Turing AM, 2009. *Computing Machinery and Intelligence*, In: *Parsing the Turing Test*, Ed; Epstein R, Roberts G, Beber G, First edition, Springer, Dordrecht, Netherlands, pp; 23-65. doi: 10.1007/978-1-4020-6710-5\_3
- 4- Ak Ö. Küresel Kabus: Koronavirüs ve Covid-19 [Internet]. Turkey: TÜBİTAK Bilim ve Teknik Dergisi; 2020 Mar [cited 2020 Dec 12]. Available from: <https://bilimteknik.tubitak.gov.tr/makale/soguk-alginligindan-oluncul-salgina-kuresel-kabus-coronavirus-ve-covid-19>

- 5- Uludağ Ö. Koronavirüs enfeksiyonları ve yeni düşman: Covid-19. *ADYÜ Sağlık Bilimleri Dergisi*. 2020 Apr;6(1):118-127. doi: 10.30569/adiyamansaglik.716011
- 6- Budak F, Korkmaz Ş. COVID-19 Pandemi Sürecine Yönelik Genel Bir Değerlendirme: Türkiye Örneği. *Sosyal Araştırmalar ve Yönetim Dergisi*. 2020 May;1:62-79. doi: 10.35375/sayod.738657
- 7- Hasöksüz M, Kılıç S, Saraç F. Coronaviruses and SARS-COV-2. *Turk J Med Sci*. 2020 May;50:549-556. doi: 10.3906/sag-2004-127
- 8- Alp Ş, Ünal S. Yeni koronavirüs (SARS-CoV-2) kaynaklı pandemi: Gelişmeler ve güncel durum. *FLORA Dergisi*. 2020 May;25:69574. doi: 10.5578/flora.69574
- 9- Samancı M. Küresel Bir Salgın: Covid-19. *Samsun Sağlık Bil Der*. 2020 June;5(1):6-11.
- 10- Ulasli M, Verheije MH, de Haan CA, Reggiori F. Qualitative and quantitative ultrastructural analysis of the membrane rearrangements induced by coronavirus. *Cellular microbiology*. 2010 May;12(6):844-861. doi: 10.1111/j.1462-5822.2010.01437.x
- 11- Mavi D, İnkaya AÇ. Covid-19: İmmün patogenez. *FLORA Dergisi*. 2020 May;25:69606. doi: 10.5578/flora.69606
- 12- Oxford Insights, Government Artificial Intelligence Readiness Index [internet], England, Oxford Insights and the International Development Research Centre; 2019 Nov [cited 2021 Jan 11]. Available from: <https://www.oxfordinsights.com/ai-readiness2019>
- 13- Atav A. İlaçların diğer ilaçlar ile etkileşimlerinin uzman sistem ile belirlenmesi [master thesis]. [İstanbul (Turkey)]: Maltepe University, 2020.
- 14- Turban E, Aronson JE, Liang TP. *Decision Support System And Intelligent System*, 7th ed., Prentice Hall Inc, New Jersey, 2005. p.300-357.
- 15- Turban E. *Decision Support and Expert Systems: Management Support Systems*, 4th ed., Prentice Hall Inc, New Jersey, 1995, p435-675.
- 16- Kliegr T, Bahník S, Fürnkranz J. A review of possible effects of cognitive biases on interpretation of rule-based machine learning models. *Artificial Intelligence*. 2021 Jan;295:103458. doi: 10.1016/j.artint.2021.103458
- 17- Shrestha YR, Ben-Menahem SM, von Krogh G. Organizational Decision-Making Structures in the Age of Artificial Intelligence. *California Management Review*. 2019 July;61(4):66-83. doi:10.1177/0008125619862257
- 18- Dimiduk DM, Holm EA, Niezgodá SR. Perspectives on the Impact of Machine Learning, Deep Learning, and Artificial Intelligence on Materials, Processes, and Structures Engineering. *Integr Mater Manuf Innov*. 2018 Aug;7:157–172. doi: 10.1007/s40192-018-0117-8
- 19- Liao SH. Expert system methodologies and applications—a decade review from 1995 to 2004. *Expert Systems with Applications*. 2005 Jan;28(1):93-103. doi: 10.1016/j.eswa.2004.08.003
- 20- Russell S, Dewey D, Tegmark M. Research Priorities for Robust and Beneficial Artificial Intelligence. *AI Magazine*. 2015 Dec;36(4):105-114. doi: 10.1609/aimag.v36i4.2577
- 21- Russel S, Hauert S, Altman R, Veloso M. Ethics of artificial intelligence. *Nature*. 2015 May;521:415-418.
- 22- Tamer HY, Övgün B. Yapay Zeka Bağlamında Dijital Dönüşüm Ofisi. *Ankara Üniversitesi SBF Dergisi*. 2020 May;75(2):775-803. doi: 10.33630/ausbf.691119
- 23- Thierer AD, O’Sullivan AC, Russell R. *Artificial Intelligence and Public Policy*. Mercatus Research Paper, 2017 Aug. Available at SSRN: <https://ssrn.com/abstract=3021135>. doi: 10.2139/ssrn.3021135
- 24- Scherer MU. *Regulating Artificial Intelligence Systems: Risks, Challenges, Competencies, and Strategies*. *Harvard Journal of Law&Technology*. 2016 Sep;29(2):354-400. doi: 10.2139/ssrn.2609777
- 25- Lipmann RP. An Introduction to Computing with Neural Nets. *IEEE ASSP Magazine*. 1987 Apr;4(2):4-22. doi: 10.1109/MASSP.1987.1165576.
- 26- Gupta S, Sharma V, Johri P. Artificial Intelligence in Forensic Science. *International Research Journal of Engineering and Technology*. 2020 May;7(5):7181-7184.
- 27- Uzun MM. Covid-19 ile Mücadelede Yapay Zekâ Uygulamaları. *ULİSA12*. 2020 May;2:45-51.
- 28- Lalmuanawma S, Hussain J, Chhakchhuak L. Applications of machine learning and artificial intelligence for Covid-19 (SARS-CoV-2) pandemic: A review. *Chaos Solitons Fractals*. 2020 Oct;139:110059. doi: 10.1016/j.chaos.2020.110059
- 29- Vaishya R, Javaid M, Haleem KI, Haleem A. Artificial Intelligence (AI) applications for COVID-19 pandemic. *Diabetes&Metabolic Syndrome*. 2020 Apr;14(4):337-339. doi: 10.1016/j.dsx.2020.04.012
- 30- Worldmeters. The counter of coronavirus case in South Korea [internet]. South Korea, Government of South Korea; 2020 Dec [cited 2020 Dec 10]. Available from: <https://www.worldometers.info/coronavirus/country/south-korea/>
- 31- Lin L, Hou Z. Combat COVID-19 with artificial intelligence and big data. *Journal of Travel Medicine*. 2020 May;27(5):1-4. doi: 10.1093/jtm/taaa080
- 32- Li L, Qin L, Xu Z, Yin Y, Wang X, Kong B, Bai J, Lu Y, Fang Z, Song Q, Cao K, Liu D, Wang G, Xu Q, Fang X, Zhang S, Xia J, Xia J. Artificial Intelligence Distinguishes COVID-19 from Community Acquired Pneumonia on Chest CT. *Radiology*. 2020 Mar;200905. doi: 10.1148/radiol.2020200905
- 33- Toğaçar M, Ergen B, Cömert Z. Covid-19 detection using deep learning models to exploit Social Mimic Optimization and structured chest X-ray images using fuzzy color and stacking approaches. *Computers in biology and Medicine*. 2020 June;121:103805. doi 10.1016/j.combiomed.2020.103805
- 34- Chu J. Artificial intelligence model detects asymptomatic Covid-19 infections through cellphone-recorded coughs [internet]. USA, MIT News Office; 2020 Oct [cited 12 Jan 2021]. Available from: <https://news.mit.edu/2020/covid-19-cough-cellphone-detection-1029>
- 35- FDA. Emergency Use Authorization Summary The Kroger Health Covid-19 Test Home Collection Kit [internet]. USA, FDA; 2021 Feb [cited 2021 Feb 24]. Available from: <https://www.fda.gov/media/139683/download>
- 36- Jonker CM, Snoep JL, Treur J, Westerhoff HV, Wijngaards WC. Putting intentions into cell biochemistry: an artificial intelligence perspective. *Journal of Theoretical Biology*. 2002 Jan;214(1):105-134. doi: 10.1006/jtbi.2001.2444
- 37- Zimmerman DE, Kulikowski CA, Huang Y, Feng W, Tashiro M, Shimotakahara S, Chien C, Powers R, Montelione GT. Automated analysis of protein NMR assignments using methods from artificial intelligence. *Journal of molecular biology*. 1997 June;269(4):592-610.
- 38- Smith DM, Smith JC. Repurposing Therapeutics for COVID-19: Supercomputer-Based Docking to the SARS-CoV-2Viral Spike ProteinandViral Spike Protein-Human ACE2 Interface. *Chemrxiv*, preprint. 2020 Mar. doi: 10.26434/chemrxiv.11871402.v4
- 39- Richardson P, Griffin I, Tucker C, Smith D, Oechsle O, Phelan A, Rawling M, Savory E, Stebbing J. Baricitinib as potential treatment for 2019-nCoV acute respiratory disease. *Lancet*. 2020 Mar;395(10223):30-31. doi: 10.1016/S0140-6736(20)30304-4
- 40- Scudellari M. Five Companies Using AI to Fight Coronavi-

- rus [internet]. USA, Spectrum IEEE; 2020 Mar [cited 2021 Jan 13]. Available from: <https://spectrum.ieee.org/thehuman-os/artificial-intelligence/medicalai/companies-ai-coronavirus>
- 41- Zhavoronkov A, Aladinskiy VA, Zhebrak A, Zagribelnyy B, Terentiev V, Bezrukov DS, Polykovskiy D, Shayakhmetov R, Filimonov A, Orekhov P, Yan Y, Popova O, Vanhaelen Q, Aliper A, Ivanenkov YA. Potential 2019-nCoV 3C-like Protease Inhibitors Designed Using Generative Deep Learning Approaches. ChemRxiv, preprint. 2020 Mar. doi: 10.26434/chemrxiv.11829102
- 42- StoneWise. StoneWise Latest Devoloment [internet] China, StoneWise; 2020 Feb [cited 2021 Jan 17]. Available from: [http://www.stonewise.cn/Report\\_en](http://www.stonewise.cn/Report_en)
- 43- IBM. Artificial intelligence in medicine [internet]. USA, IBM Watson Health; 2020 Oct [cited 2021 Jan 18]. Available from: <https://www.ibm.com/watson-health/learn/artificial-intelligence-medicine>

## Kızılötesi Termal Görüntülemenin Yapay Zekâ Tabanlı Biyomedikal Uygulamalarına Bakış

### *Overview of Artificial Intelligence Based Biomedical Applications of Infrared Thermal Imaging*

Saim ERVURAL\*<sup>1</sup>, Murat CEYLAN<sup>2</sup>

#### ÖZ

Kızılötesi termal görüntüleme, vücut sıcaklığı dağılımının ve değişiminin izlenmesine izin veren invazif olmayan, zararlı radyasyon içermeyen, temassız bir modalitedir. Periferik kan akışı, otonom sinir sistemi, vazokonstriksiyon / vazodilatasyon, iltihaplanma, terleme veya diğer süreçler hakkında fizyolojik bilgiler sağlaması medikal alanda kullanımını yaygınlaştırmıştır. Yapay zekâ alanında yaşanan gelişmeler medikal uygulamalarda da karşılık bulmuş ve makine öğrenimi metotları; karar verme, hastalık takibi, cerrahi planlama gibi birçok görev için kullanılabilir hâle gelmiştir. Termal verilerin yorumlanması için yapay zekâ yöntemlerinin kullanılması, bir tanı, tedavi planlama veya cerrahi değerlendirme senaryosunda doktorlara ikinci bir görüş sağlamak için etkin bir çözüm olabilir. Bu araştırmanın amacı: Literatür kaynaklarının incelenerek termal görüntülemenin medikal uygulamadaki sınıflandırma, karar verme gibi süreçlerde yapay zekâ yöntemlerinin işleyişlerini değerlendirmek ve literatür hakkında bilgi sunmaktır.

**Anahtar kelimeler:** Yapay zekâ, Sınıflandırma, Termografi, Kızılötesi termal görüntüleme, Biyomedikal karar verme.

#### ABSTRACT

Infrared thermal imaging is a non-invasive, harmless radiation-free non-contact modality that allows monitoring of body temperature distribution and change. Providing physiological information about peripheral blood flow, autonomic nervous system, vasoconstriction / vasodilation, inflammation, sweating or other processes has expanded its use in the medical field. Developments in the field of artificial intelligence have also found response in medical applications, and machine learning methods have become used for many tasks such as decision making, disease monitoring, and surgical planning. Using artificial intelligence methods to interpret thermal data can be an effective solution to provide doctors with a second opinion in a diagnosis, treatment planning or surgical evaluation scenario. The purpose of this research; To evaluate the functioning of artificial intelligence methods in medical applications such as classification and decision making of thermal imaging by examining the literature sources and to provide information about the literature.

**Keywords:** Artificial intelligence, Classification, Thermography, Infrared thermal imaging, Biomedical decision making.

Received/Geliş : 11.03.2021

Accepted/Kabul: 31.03.2021

Publication date: 15.04.2021

**Saim ERVURAL**

<sup>1</sup>KTO Karatay Üniversitesi,  
Elektrik-Elektronik Mühendisliği,  
Konya, Türkiye

\*saim.ervural@karatay.edu.tr

ORCID: 0000-0003-4104-1928

**Murat CEYLAN**

<sup>2</sup>Konya Teknik Üniversitesi,  
Elektrik-Elektronik Mühendisliği,  
Konya, Türkiye

ORCID:0000-0001-6503-9668



## Giriş

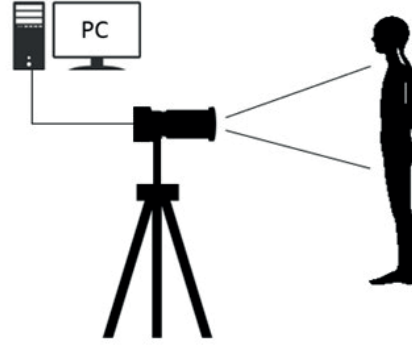
Mutlak sıfır noktası (-273,15 °C, 0 °K) üzerinde tüm nesnelere, sıcaklıklarına ve spektral emisivitelere bağlı olarak kızılötesi radyasyon yayma yeteneğine sahiptir [1]. Vücudun yaydığı radyasyon miktarı elektromanyetik spektrumun kızılötesi alanı içindedir ve dalga boyu 0,75-1000 mikrometre aralığındadır [2]. Deri emisivitesi, cilt sıcaklığını belirlemek için önemli bir unsurdur ve dalga boyuna bağlı olarak 0-1 arasında değerlenir [3]. İnsan derisinin emisivitesi 0,96-0,98 arasındadır bu nedenle neredeyse bir kara cisim gibi davranır [4]. Kara cisim, Planck Yasası'na göre gelen tüm enerjisi emen ve sürekli enerji yayan bir nesne olarak kabul edilir [5]. Bir kara cisim tarafından yayılan enerji, belirli bir sıcaklık için maksimum değerdedir [1]. Bu nedenle insan derisinin yayma gücü bir kara cismin yayma gücüne yakın olduğundan deriden yayılan kızılötesi radyasyon, termal görüntüleme kullanılarak doğrudan sıcaklık değerlerine dönüştürülebilir. Termal kameralar, kızılötesi enerjisi elektronik sinyallere dönüştürür; bu sinyaller iki boyutlu bir dizide düzenlenmiş pikseller olarak görüntülerle ifade edilir [6, 7]. Her piksel, görüntülenen bölgenin sıcaklık değerlerini temsil eder [2]. Termal kameralar tarafından üretilen görüntüler termogram olarak adlandırılır. Termogramların sıcaklık değerleri görsel olarak gri seviyede veya farklı renk paletlerinde görüntülenebilir. Böylece incelenen nesnenin yüzeyindeki sıcaklık dağılımının farklı renk tonlarıyla görsel olarak görülmesi sağlanır. Renklerin dağılımı, vücut yüzeyinden yayılan kızılötesi radyasyon miktarındaki azalma ya da artışı gösterir.

Medikal termografide termogramlar, kızılötesi radyasyonu yakalayan organların ve dokuların sıcaklık dağılımını ölçmek için kullanılır. Termal görüntüleme, insan vücudu cilt yüzeyinin geniş alanlarının kaydedilmesine ve haritalanmasına izin verir; böylelikle fizyolojik bozuklukların neden olduğu sıcaklık değişiklikleri hastaya herhangi bir rahatsızlık ve radyasyon hasarı vermeden tespit edilebilir [2]. Vücutta oluşan fizyolojik fonksiyon bozuklukları, sıcaklık artışlarına neden olur. Bu artışlar, kızılötesi görüntülerde sıcak noktalar veya asimetrik desenler olarak gösterilir. Sağlıklı bir insanda cilt sıcaklığının dağılımı kontralateral simetri gösterir. Belirli bir düzeyin üzerindeki asimetri ile sıcaklık dağılımı genellikle anormalliklerin güvenilir bir göstergesidir [8]. Bu nedenle, sağlıklı vücut termal olarak simetrik olduğundan, asimetrik sıcaklıklar görüntülerde kolayca tanımlanabilir. 50'li yılların ortalarından beri klinik pratikte ve vasküler, nörolojik, kas-iskelet sistemleri gibi çeşitli alanlardaki araştırmalarda kullanılmaktadır [9]. Süreç içerisinde tekniği standartlaştırmak ve sonuçlarını iyileştirmek için uluslararası kabul görmüş kılavuzlar geliştirilmiş ve termal tarama standartları oluşturulmuştur [10-13].

Medikal uygulamalarda kullanılan termal kameralar genellikle 3 - 5 µm orta dalga kızılötesi dalga boylarında ve 8 - 13 µm uzun dalga kızılötesi dalga boylarında çalışır. 5 - 7 µm arası atmosferdeki su buharı nedeniyle soğurulduğu için termal kameralar bu aralıkta tespit yapamazlar [1]. Kullanılacak kamera tipinin seçimi, incelenen nesnelere sıcaklık aralığı ile ilgilidir [14]. İnsan vücudunun yaydığı kızılötesi radyasyon 8-15 µm dalga boyu aralığında olup Planck Yasası'na göre, insanlarda yayılan kızılötesi radyasyonun yaklaşık %90' ı ise 9 - 10 µm dalga boyu aralığındadır [15]. Dolayısıyla medikal termal görüntüleme genellikle uzun dalga boylu termal kameralar tercih edilmektedir.

Bir yüzey tarafından yayılan kızılötesi radyasyon; nem, hava akışı ve ortam sıcaklığı gibi deneysel koşullara bağlıdır. Bu nedenle termografi deneylerinin, özellikle sıcaklık değişimlerinin birkaç derece içinde olduğu medikal uygulamalarda kontrollü ortamlarda yapılması mutlak bir zorunluluktur. Termografik görüntüleri karşılaştırmak için standart bir protokol izlenmelidir. Yayınlanan çalışmalar medikal uygulamalarda ancak belirli standartlara

uyulduğunda güvenilir sonuçlar üretebileceğini ortaya koymuştur [10-13]. Medikal termografi deneyi için tipik bir ölçüm kurulumu Şekil 1'de verilmiştir. Deney ortamının sıcaklığı ve nemi belirli sınırlar içinde tutulmalı ve ölçümde geometrik hataları en aza indirmek için kamera, gözlem yüzeyine dik olarak yerleştirilmelidir.



Şekil 1: Medikal termografi deneyi için tipik bir ölçüm kurulumu

Termografi deneyleri sırasında denekler rahat bir ortamda tutulmalıdır. Bir termografik inceleme sırasında hastaların görüntülenecek vücut bölümü, vazokonstriksiyonun cildin soğumasına neden olduğu ve altta yatan anormalliklerden kaynaklanan sıcak noktaların açıkça görünür hale getirildiği hafif bir termal stres üretmek için soğutulabilir [8]. Amalu ve ark. muayene odasının sıcaklık ve neminin, deneklerin fizyolojisinin "titreme veya terleme durumuna" girmeyecek şekilde kontrol edilmesi gerektiğini, akkor lamba veya direkt güneş ışığı gibi ikincil kızılötesi kaynaklardan arınmış olması gerektiğini bildirmiştir [16]. Deneklerin doğrudan güneş ışığına maruz kalmamaları ve termografi incelemelerinden hemen önce kozmetik, terlemeyi önleyici veya deodorant kullanmamaları önerilir. Deneklerin termal dengeye ulaşması için bir termal alışma süresi gerekmektedir [5].

Araştırma	Yıl	Çalışma	Deney Koşulları	
			Ortam Sıcaklığı °C	Alışma Süresi (dakika)
	1997	Yüksek riskli diyabetik ayak	21±2	15
	1998	Yüz teletermografisi	21-23	15
	2002	Çevresel dolaşım	20	15
	2006	Risk altındaki diyabetik ayaklar	21±2	15-20
	2007	Omuz sıkışma sendromu	19-21	15
	2009	Termoregülasyon	24±2	10
Bagavathiappan ve ark. [112]	2010	Diyabetik nöropati	25	5

Tablo 1. Kızılötesi termal görüntüleme bazı araştırma grupları tarafından kullanılan deneysel koşullar.

Tablo 1'de kızılötesi termal görüntüleme çalışmalarında bazı araştırma grupları tarafından kullanılan deneysel koşullar verilmiştir.

Bilgisayar teknolojisinde yaşanan gelişmelerin sağladığı daha düşük maliyetli-yüksek işlem kapasitesine sahip bilgisayarlar ve veri toplama süreçlerinin kolaylaşmış olması sayesinde yapay zekâ (YZ) alanında büyük ölçekli araştırma yapabilmek ekonomik açıdan mümkün hale gelebilmiştir. Yapay zekânın yükselişi medikal uygulamalarda da karşılık bulmuş ve karar verme, hastalık takibi, cerrahi planlama gibi birçok görev için kullanılabilir hâle gelmiştir. Bu araştırmanın amacı: PubMed, Scopus ve Web of Knowledge gibi literatür kaynaklarını inceleyerek termal görüntülemenin medikal uygulamalardaki sınıflandırma, karar verme gibi süreçlerde YZ yöntemlerinin işleyişlerini değerlendirmek ve literatür hakkında bilgi sunmaktır.

Kızılötesi radyasyon kavramı ilk olarak Frederick William Herschel tarafından ortaya atılmış ve Herschel prizmadan geçen güneş ışınlarının farklı sıcaklıklarda kırıldığı keşfini 1800 yılında yapmıştır. Kızılötesi görüntüleme üzerine ilk medikal çalışmalar, Lawson'ın [17] kadınlarda meme kanserini termal görüntüler kullanılarak, damarlanma ve asimetrik sıcak noktalar açısından incelemesi ile başlamıştır (1956). Bu çalışmada, memede kanserli bir dokudaki cilt sıcaklığının sağlıklı dokulara oranla daha yüksek olduğu görülmüştür. 1960'lerden itibaren kızılötesi görüntülemenin medikal uygulamaları ağırlıklı olarak meme kanseri teşhisi üzerine yapılmıştır. Lloyd-Williams ve ark. [18] memedeki şişliklerin teşhisi üzerine termogramları kullanırken (1961), Gershen-Cohen ve ark. [19] (1965) ve Haberman [20] (1968) termal görüntüleme ile meme kanserinin tespiti üzerine çalışmışlardır.

Winsor ve Bendezu'nun periferik dolaşım bozuklukları [21] (1964), Skverski ve ark.nın [22] vasküler hastalıklar (1964), Albert ve ark.nın [23] ortopedik anomaliler (1964), Connel ve ark.nın [24] travma (1964), Boas'ın [25] romatizmal eklem iltihabı (1964), Lane'in [26] göğüs hastalıkları (1964), Sandrow ve ark.nın [27] diyabetik nöropati veya vasküler bozukluklar (1972), Ring ve Bacon'ın [4] Raynaud fenomeni (1977), Hartmann ve ark.nın [28] cilt hastalıkları (1981), Cole'un [29] yanık yaraları (1990), Soffin ve ark.nın [30] diş (1983), Steed'in [31] çene eklem patolojisi (1991), Herrick'in [32] karpal tünel sendromu (1987), Shatsova'nın [33] tiroit hastalıkları (1989) üzerine gerçekleştirdikleri uygulamalar termografinin medikal alanda kullanımının önemini vurgulamış ve literatüre derinlik kazandırmıştır.


### Medikal Termografide Yapay Zekâ Uygulamaları

Yapay zekâ kavramı makinelerle insanlar gibi düşünme, karar verme, karşılaştırma, analiz etme gibi birtakım fonksiyonların kazandırılmasıdır. Verilerin nasıl yorumlanacağını öğrenmek üzere biyolojik sinir ağlarını örnek olarak belirli fiziksel insan davranışlarını yapan robotlar gibi makinalara yön vermesi, veri hesaplaması, tıbbi teşhis gibi belirli bir uzmanlık alanı ile ilgili beşeri düşünme sürecinin benzeşimini yapan sistemleri yönetme becerisine sahip olması mümkündür [34].

Termal kameralar aracılığıyla elde edilen sıcaklık matrisleri, yani termogramlar, analiz edilen durum için anlamlı olan sıcaklık verilerini almak için görüntü işleme stratejileri gerektirir. Termogram verilerinden anlamlı bilgiler elde edilmesi, makine öğrenimi algoritmalarına dayanan YZ hesaplama yöntemlerinin uygulanmasıyla kolaylaştırılabilen zorlu ve zaman alıcı bir görevdir [35].

Bilgisayar teknolojisinde yaşanan gelişmelerin sağladığı daha düşük maliyetli-yüksek işlem kapasitesine sahip bilgisayarlar ve veri toplama süreçlerinin kolaylaşmış olması sayesinde YZ alanında büyük ölçekli araştırma yapabilmek ekonomik açıdan mümkün hale gelebilmiştir.

Son yıllarda, termogram verileri, araştırmacılar tarafından YZ tabanlı sınıflandırıcıların hekimlere ikinci bir görüş vermesi için girdi özellikleri olarak uygulanmıştır. Medikal çalışmalarda kullanımı yaygınlaşan yapay zekâ algoritmalarından bazıları: Yapay Sinir Ağları (YSA), Destek Vektör Makinesi (DVM), Naif Bayes (NB), k-En Yakın Komşu (K-NN), Lojistik Regresyon (LR), Karar Ağaçları (KA), Rastgele Orman (RO) ve Evrişimsel Sinir Ağları (ESA) olarak karşımıza çıkmaktadır. Uygulamalarda değerlendirme kriteri olarak genellikle doğruluk, duyarlılık ve özgülük ölçütleri kullanılmıştır.



**Şekil 2.** Kızılötesi termografinin çeşitli tıbbi uygulamaları: a) Oftalmopati hastalarda metilprednizolon nabız tedavisinin etkisinin takibi [104], b) Bilgisayar destekli tanı tabanlı el termal görüntü analizi [91], c) Diyabetik ayağın otomatik tespiti [61], d) Doku özelliklerini kullanarak meme kanseri tespiti [105], e) Cilt kanseri tespiti [106], f) Yapay zekâ teknikleri ile yenidoğanlarda hastalık teşhisi [74].


Şekil 2'de bazı medikal uygulama örnekleri gösterilmektedir. Anormal termal paternler kızılötesi termografi tekniği ile kolayca tanınabilir olduğundan, bu termal görüntülerden erken teşhis mümkündür. Termografik bulgular, olası korelasyonları değerlendirmek için genel olarak diğer klinik bulgularla karşılaştırılır. Sadece cilt yüzeylerinden yayılan doğal radyasyonu kaydetmesi ve zararlı radyasyon etkisinin olmaması uzun süreli ve tekrar tekrar kullanıma uygunluğu termografiyi medikal uygulamalarda zararsız ve invazif olmayan bir teknik olarak öne çıkarmaktadır. Geniş bir vücut yüzeyine odaklanarak eş zamanlı olarak farklı doku gruplarındaki sıcaklık değişimlerinin dinamik olarak izlenmesini sağlamaktadır. Bu başlık altında termografinin yapay zekâ tabanlı algoritmalarla birlikte kullanıldığı yaklaşımlar hakkında bilgiler verilmiştir.

### Meme Kanseri

Meme kanseri, kadınlarda en sık görülen hastalıktır. Küresel kanser verileri meme kanserinin akciğer kanserinden sonra dünya çapında en ölümcül ikinci kanser türü olduğunu göstermektedir [36]. Yaşam tarzı faktörlerinin değişmesi, endüstrilerin hızlı büyümesi nedeniyle, kentleşme meme kanseri insidansında kademeli bir artışa neden olmuştur [37]. Meme kanserinin erken teşhisi, uygun tedaviyi sağlayarak kadınların hayatta kalma oranını artırmaktadır [37-39]. Termal görüntüleme ile meme asimetrisinin değerlendirilmesi ve uygun yapay zekâ tekniklerinin kullanımı erken teşhiste önemli bir rol oynamaktadır. Sathish ve ark. şekil özellikleri ve polinomial eğri uydurma kullanarak sağ ve sol memenin asimetri analizi için tam otomatik segmentasyon çalışması gerçekleştirmiş ve meme kanserinin saptanmasında DVM sınıflandırıcı kullanarak 40 normal ve 40 anormallik içeren 80 görüntüden oluşan bir set için %90 doğruluk değeri elde etmiştir [40]. Araujo ve ark. meme tümörlerini belirlemek için 60 normal, 66 iyi huylu tümör içeren, 38 kanser dokusu olan toplam 164 meme termogramı ile DVM kullanarak sınıflandırma yapmış ve %90'ın üzerinde doğruluk elde etmiştir [41]. Gogoi ve ark. meme anomalilerinin tespiti için termal yamaların tekil değere dayalı karakterizasyonu ve analizi üzerine çalışmıştır. DVM, K-NN, KA, YSA, RO, AdaBoost (AB) ve doğrusal diskriminant analizi (DDA) algoritmalarının vereceği sonuçlar incelenmiş ve DVM kullanıldığında %98 doğruluk elde etmiştir [38]. Gogoi ve ark. bir başka çalışmada asemptomatik popülasyonda erken meme kan-

seri risk tahmini için kızılötesi meme termografisinin etkinliğini değerlendirmiştir. DVM'yi radyal temel fonksiyon çekirdeği ile kullanarak tüm özellik setleri arasında istatistiksel olarak anlamlı özellikleri içeren özellik seti %83,22 ile en yüksek sınıflandırma doğruluğunu sağlamıştır [42].

ESA, bir görüntüyü diğerlerinden ayıran önemli özellikleri haritalamak için belirli öğrenilebilir ağırlıklar ve Bias değerleri atayarak giriş görüntülerini işleyen derin bir sinir ağı algoritmasıdır. Böylelikle sınıflandırma sonucu çıktı olarak gözlenebilir. Şekil 3, göğüs termogramlarından hasta-sağlıklı ayrımı yapan ESA'ların genel mimarisini göstermektedir [39].



Şekil 3. Meme kanseri sınıflandırma için örnek ESA mimarisini

ESA kullanarak meme kanseri tespitine yönelik çalışmalardan birinde Baffa ve Lattari %98 doğrulukla hasta-sağlıklı sınıflandırması sonucu elde etmiştir. Bu çalışmada, ESA mimarisini iki evrilim katmanı ve iki maksimum havuzlama katmanından oluşmaktadır. Çıktı katmanı, iki sınıfa sahip tam bağlı ağırlıklı ağıdır. Sonuçlar Adam optimizasyon algoritması kullanılarak optimize edilmiştir [43]. Kızılötesi termografiye dayalı olarak meme kanserinin erken teşhisi için karşılaştırmalı olarak ESA performansını inceleyen Fernandez-Ovies ve Andres [44] ResNet18, ResNet34, ResNet50, ResNet152, VGG16 ve VGG19'un ESA mimarileri Fast.ai ve Pytorch kütüphanelerini kullanarak uygulamışlardır. Bu karşılaştırmanın sonucunda, ResNet50'nin %98,75 doğrulukla en iyi sınıflandırmayı sağladığı; ancak ResNet50'nin ResNet34'e kıyasla daha az kararlı olduğu ifade edilmiştir. Roslidar ve ark. meme kanseri sınıflandırması için termal görüntülemeye dayalı ince ayar ESA modellerine ilişkin bir çalışma ortaya koymuştur. Resnet101, Densenet210, MobilenetV2, ShufflenetV2 modellerini kullanarak gerçekleştirilen çalışmada %100 doğrulukla hasta-sağlıklı sınıflandırması elde edilmiştir [45]. Gomez ve ark. termal görüntüleri kullanarak meme kanseri teşhisi için ESA tabanlı bir metodoloji ortaya koymuştur. 38'i kanser 19'u sağlıklı olmak üzere 57 termal veri bulunan veri tabanı kullanarak, %92 doğrulukla sınıflandırma gerçekleştirmiştir. Çalışma sonucunda veri augmentasyonu, segmentasyon ve optimizasyon tekniklerinin etkileri karşılaştırmalı olarak sunulmuştur [37]. Schaefer ve ark. termogramlardan çıkarılan, sol ve sağ meme alanları arasındaki farklılıkları ölçen bulanık kural tabanlı bir dizi istatistiksel özelliği kullanarak meme kanseri analizi gerçekleştirmiştir ve yaklaşık %80 doğruluk elde etmiştir [46]. Nicandro ve ark. Bayes ağı sınıflandırıcılarını kullanarak meme kanserinde termografinin tanısal etkisini gözlemlemiştir [47]. Etehadtavakol ve ark. 9 kötü huylu, 12 iyi huylu ve 11 normal vakadan oluşan bir veri seti ve AB sınıflandırıcı kullanarak %95 doğrulukla meme kanseri olgularını sınıflandırmayı başarmıştır [48]. Silva ve ark. meme kanseri riskini belirlemek için yeni bir dinamik meme termografisi analiz tekniği önermiştir. Bu bağlamda YSA, Bayes ağları ve KA sınıflandırma teknikleri uygulanmış ve %90,90 isabet oranı elde edilmiştir [49]. Wahab ve ark. YSA kullanarak çeşitli doku bileşimleri ile meme termografisinde tümör lokalizasyonu gerçekleştirmiştir [50]. Milosevic ve ark. anormal dokuyu normal dokudan ayırt etmedeki özellik kümesinin yeteneğini SVM, K-NN ve NB kullanılarak araştırmıştır. Sonuçlar, K-NN ile % 92,5 doğrulukla

sınıflandırıldığını göstermektedir [51]. Francis ve ark. Curvelet dönüşümü tabanlı özellik çıkarımı kullanarak termogramlardan meme anormalliğinin tespitini gerçekleştirmiştir [52]. Zadeh ve ark. termografi ile kanserli bölgenin kenarlarını ve çekirdeğini tespit etmek için tam otomatik bir yaklaşım sunmuştur [53]. Lashkari denetimli ve denetimsiz algoritmalar kullanılarak termogram görüntülerinden meme kanserinin tespit edilmesinde bulanık c-ortalama tekniğini kullanarak %88, AB sınıflandırıcısı ile %75 doğruluk elde etmiştir [54]. Raghavendra ve ark. ise 25 normal, 25 tümör içeren meme termogramı veri setiyle, yönlendirilmiş gradyan histogramları ve çekirdek lokalizasyonu kullanarak entegre bir meme kanseri tanı aracı geliştirmiştir. [55].

## Diyabet ve Vasküler Bozukluklar

Diyabet hastalarının yaklaşık %50'si, en sık karşılaşılan sorun olan ayak komplikasyonları nedeniyle hastaneye kaldırılır [56]. Bu tür ayak komplikasyonlarının başlıca nedenleri, kan akışının azalması (vasküler bozukluk) ve duyu kaybıdır (nöropati). Hem vasküler bozukluk hem de diyabetik nöropati, cilt yüzey sıcaklığında değişikliklere neden olmakta, bu da kızılötesi termografiyi diyabetik nöropati veya vasküler bozuklukların teşhisi için uygun bir araç haline getirmektedir. Diyabetik ayağın sınıflandırılmasına yönelik çalışmalardan birinde Purnima ve ark. termal görüntüleri ön işleme ve segmentasyon uygulamış ve ardından dokusal özellikleri çıkarmıştır [57]. Diyabetik ayağı teşhis etmek için olasılıksal sinir ağı, K-NN ve DVM modellerini kullanarak performansları karşılaştırılmıştır. Deneysel sonuçlar en başarılı sınıflandırmanın gerçekleştirildiği K-NN algoritmasının %95,66 doğruluğa sahip olduğunu göstermektedir. Contreras ve ark. 3D morfolojik model spektrumuna ve göreceli konuma dayalı olarak oluşturulan özellik vektörleri, sistemin diyabetik olmayan (kontrol grubu) ve diyabetik grupları nicel olarak karakterize etmesine ve ayırt etmesine izin verdiğini ifade etmiştir. Bu amaçla sinir ağları ile lineer olmayan sınıflandırma kullanmış ve ortalama %94,33 sınıflandırma doğruluğu elde etmiştir [58]. Diyabetik ayak ülseri, uygun şekilde tedavi edilmezse amputasyona yol açabilen diyabetin ana komplikasyonlarından biridir. Alzubaidi ve ark. normal cilt (sağlıklı cilt) sınıfına karşı diyabetik ayak ülseri olan anormal cilt sınıfının otomatik sınıflandırılması için yeni bir ESA modeli (DFU\_QUTNet) önermiştir. Modelin başarısını AlexNET, VGG16 ve GoogleNET modelleri ile karşılaştırıldığında %94,50 ile daha iyi F1 skoru ürettiği ortaya koyulmuştur [59]. Diyabetik ayak ülseri üzerine yapılan bir başka çalışmada Cruz-Vega ve ark. otomatik segmentasyon ve özellik çıkarma yaptıktan sonra medikal görüntülerin sınıflandırılmasında sıklıkla kullanılan sınıflandırıcılardan ikisi olan DVM ve çok katmanlı algılayıcıları karşılaştırmıştır. Uygulamada kullanılan ayak termogramları ve segmente edilmiş versiyonları Şekil 4'te gösterilmiştir. Elde edilen sonuçlar DVM sınıflandırıcısının, %99,28 ile daha başarılı doğruluk değeri verdiğini göstermiştir. Çok katmanlı algılayıcılar kullanıldığında ise %97,85 doğruluk değeri elde edilmiştir [60]. Adam ve ark. entropi ve doku özelliklerini hesaplamak için sol, sağ ve bilateral ayak görüntülerini dekompoze ederek değerlendirmiştir ve en iyi performans K-NN yöntemi ile elde edilmiştir (Doğruluk: %93,16; Duyarlılık: %90,31; Özgüllük: %98,04) [61]. Gururajaro ve ark. diyabetik ayak sendromu teşhisi için ESA kullanarak analiz çalışması gerçekleştirmiş ve %91 doğrulukla diyabetik ayağı tespit etmiştir [62]. Samant ve Agarwal 338 denekten (180 diyabetik ve 158 diyabetik olmayan) oluşan bir grup üzerinde, iris görüntüleri ile RO algoritmasını kullanarak diyabetik ayak teşhisi gerçekleştirmiştir. Maksimum özgüllük ve duyarlılık sırasıyla %96,87 ve %98,8; doğruluk ise %89,63 olarak elde edilmiştir [63].



**Şekil 4.** Uygulamada kullanılan örnek görüntüler, (a) normal (kontrol grubu) ayak termogramı ve segmente edilmiş hali, (b) diyabetik ülserli ayak termogramı ve segmente edilmiş hali [60].

### Cilt Hastalıkları

Sağlık öncelikleri belirlenirken, dermatolojik hastalıkları bazen yüksek mortaliteye neden olan hastalıklarla karşılaştırıldığında primer riskler arasında gösterilmemektedir. Ancak, cilt problemleri genellikle tropikal bölgelerdeki görülen en yaygın hastalıklardır ve bulaşıcı hastalıkların endemik olduğu bazı bölgelerde, baskın eksozpozisyon haline gelirler. Ölüm oranları genellikle diğer koşullardan daha düşük olsa da cilt rahatsızlıklarının, birçok ölümcül hastalığın öncül semptomlarından biri olabileceği düşünüldüğünde insanların etkili çarelere olan ihtiyaçları dikkate değerdir [64, 65]. İleri aşamada cilt kanserine yol açan dermatolojik hastalıklar izlenmeli ve erken tedavi edilmelidir. Cilt kanseri vakalarının sayısındaki artış, özellikle çocuk ve genç yetişkinlik yıllarında ultraviyole radyasyona aşırı maruz kalmaya bağlanmıştır [66]. Cilt hastalıklarında mevcut tanı yöntemleri biyopsi (pahalı, invazif) ve dermatoskopidir (deneyime bağlı); bu nedenle yeni objektif yöntemlere ihtiyaç vardır. Magalhaes ve ark.a göre neoplazmaların büyümesi kan akışından etkilenir ve bu da cilt sıcaklığını etkiler [65, 67]. Gerçekleştirdikleri çalışmada melanom ve melanositik nevüs lezyonlarının statik ve dinamik (soğutmalı) termal görüntüleri, cilt lezyon tiplerinin karakteristik termal parametrelerini elde etmek için analiz etmiş ve melanom/nevüs lezyonlarının ayrımının elde edilebilir olup olmadığını doğrulamak için farklı makine öğrenimi sınıflandırıcılarıyla test etmişlerdir. DVM ve statik değişkenlerden oluşan bir giriş vektörüne dayalı olarak her iki cilt türünün ayrımını %84,2'lik doğruluk ve %91,3'lik duyarlılık ile elde etmişlerdir [65]. Bauer ve ark., gelişmiş ülkelerde puberte sonrası kadınların %85 ile %98'inde görülen dermis, epidermis ve subkutan dokuların yaygın bir fizyolojik durumu olan selülitin farklı aşamalarının tahmini ve otomatik tanımlanması için YZ ve termografi tabanlı uygulamasını gerçekleştirmiştir. Uygulama sonucunda selülitin ilk aşamalarında %90, ortalamada ise %81 doğruluk %85 özgüllük değeri ortaya çıkmıştır [68].

### Yenidoğan Hastalıkları

Dünya Sağlık Örgütü verilerine göre doğumdan sonraki ilk 4 haftada (yenidoğan dönemi) ortalama ölüm oranı 1000'de 18'dir [69]. Bu nedenle, neonatal sağlık durumunun izlenmesi ve erken müdahalenin gerçekleştirilmesi önemli ölçüde önemlidir [70]. Günümüzde BT ve MR görüntüleme yenidoğan bebeklerde tanı amaçlı kullanılmaktadır [71]. Ancak görüntüleme sırasında yenidoğanlar kuvözden çıkarılıp görüntüleme cihazına transfer edilmesi ısı izolasyonlarını bozmaktadır [72]. Ek olarak, BT ve MR görüntüleme genellikle lokal yapıldığından, görüntülenmeyen alanlardaki anormallikler gözden kaçabilmektedir. Bebeklerin çoğu solunum desteklerine veya oksijen saturasyonunun ve nabızın gözlendiği sensörlere bağlı olduğundan kuvözlerden çıkarılması mümkün değildir. Tüm bu olası senaryolar temassız ve zararsız bir yöntem olan termal görüntülemeyi yenidoğan

hastalıklarının tespiti ve takibinde gerekli kılmaktadır. Literatürde yenidoğan termogramları ile hasta-sağlıklı sınıflandırmasının yanında spesifik olarak yüksek mortalite ve morbiditeye yol açan hastalıklar da YZ teknikleri kullanılarak sınıflandırılmıştır. Topalidou ve ark. yenidoğan hastalıklarının termal görüntüleme ile teşhis ve takibine yönelik çalışmaların incelendiği etkili bir literatür araştırması ortaya koymuştur [73].


Şekil 5'te örnek bir yenidoğan termal görüntüleme prosesi, Şekil 6'da ise Ervural ve Ceylan tarafından sunulan ESA tabanlı sınırlı termal veri ile sınıflandırma çalışmasına ilişkin modelin blok gösterimi gösterilmiştir [74].



**Şekil 5.** Ölçüm kurulumu (a) yenidoğan, (b) kuvöz, (c) kızılıteşi termal kamera (d) taşınabilir bilgisayar [74].

Yenidoğan hastalıklarının erken teşhis, takip ve tedavisine dayalı çalışmalardan birinde Herry ve ark. NEC (Nekrotizan Enterokolit) hastalığı tanısı için yüzeysel abdominal sıcaklıkları kullanan regresyon analizi yöntemini kullanarak sınıflandırma çalışması gerçekleştirmiştir [75]. NEC hastalığı bulunan 11 ve sağlıklı 48 yenidoğan görüntüsü kullanılarak %90 doğruluk değeri elde edilmiştir. Frize ve ark.a göre NEC'li bebeklerde yukarıdan aşağıya bölge sıcaklıkları önemli ölçüde farklılık gösterirken, sağlıklı bebeklerde bölge sıcaklıklarında önemli bir fark yoktur [76]. Yenidoğanda NEC hastalığını belirlemek için termal görüntüleme ile KA algoritmasına dayalı analiz yöntemi geliştirmişlerdir. Üst ve alt karın arasındaki medyan sıcaklık farklılıklarının iki veri seti (20 sağlıklı ve 10 NEC hastalığı olan yenidoğan) kullanılarak sınıflandırmanın sonuçları, %90 +/-%12 özgüllük ve %78 +/-18% duyarlılık olarak hesaplanmıştır. Örnek ve ark. tarafından yayınlanan bir çalışma sıcaklık haritalarının kullanımının kırmızı-yeşil-mavi (RGB) görüntüleme göre daha etkili olduğunu vurgulamıştır [77]. Örnek ve ark. başka bir çalışmada yenidoğan termal görüntüleri ve makine öğrenimini birleştirerek otomatik bir sağlıklı-hasta sınıflandırma gerçekleştirmiştir. Çalışmalarında 38 bebekten alınan 3800 görüntü veri artırma ile 30400'e çıkarılmış ve %99,58 doğruluk elde edilmiştir [78]. Örnek ve ark. tarafından 2020'de yayınlanan çalışmada ise termal haritalardan yerel ikili desen ve hızlı korelasyon tabanlı filtre yaklaşımları ile özellik seçme uygulaması, KA, YSA, LR ve RO algoritmaları ile hasta-sağlıklı sınıflandırması %92,5 doğruluk, %100 duyarlılık, %85 özgüllük ile yapılmıştır. Örnek ve Ceylan, VGG16 modeliyle transfer öğrenme uygulayarak %100 duyarlılık ve %94,7 özgüllük değerlerine [79] ve açıklanabilir derin öğrenme tabanlı çalışma ile %94,73 doğruluk değerine ulaşmışlardır [80]. Savasçi ve ark. 2019'da gerçekleştirdikleri sınıflandırma çalışmasında YSA ve çoklu çözünürlüklü analizi yöntemleri ile 38 yenidoğanın 190 görüntüsü üzerine %98,4 doğrulukla hasta-sağlıklı ayrımı yapmışlardır [81]. Ervural ve Ceylan sınırlı termal veri kullanarak yenidoğanda pulmoner anomalilerin belirlenmesine yöne-

lik ESA tabanlı bir metodoloji kullanmıştır. On altısı pulmoner hastalıkları, 18'i ise kalp ve abdominal bölge anomalisi olan 34 yenidoğanın görüntüsünün değerlendirildiği çalışmada %91 doğruluk %100 duyarlılık ve %86 özgüllük ile iki sınıf birbirinden ayrılmıştır [82].



Şekil 6. Sınırlı termal veri ile yenidoğanda pulmoner anomalilerin belirlenmesi [82].

### Termoregülasyon Takibi

Termoregülasyon, canlıların yaşam fonksiyonlarını devam ettirebilmesi için vücut sıcaklığını çevredeki sıcaklık çok farklı olsa bile belirli sınırlar içinde tutma yeteneğidir. Yüzey sıcaklığı dağılımının dinamikleri yüzey tabakasındaki kan akışı, daha derin kan damarlarından ısı iletimi ve yüzeyden ter buharlaşması gibi bir dizi faktör tarafından yönetilir [83]. Termoregülasyon hem hayati fonksiyonların devamı hem de günlük konfor için çok önemlidir. Sıcak çarpmalarını önlemek, enfeksiyonların yayılmasını azaltmak, bağışıklık sistemi proteinlerinin metabolizmasını korumak gibi görevleri vardır [84].

Termografi, termoregülasyon süreçlerini izlemek için etkili bir araçtır. Alpar ve Kreicar el termografisinde düzensiz termoregülasyonun tespitinde bulanık c-ortalama tekniğini kullanmışlardır. Ellerde akut veya kronik vazospazm, parmaklara kan akışını azaltan aşırı vazokonstriksiyona neden olan önemli bir hastalıktır. Vasküler değişiklikler nedeniyle, ciddi vakalarda siyanoz ve renk değişikliğine de neden olabilir. Kan akışındaki azalma, termogramlar analiz edilerek termal görüntüleme ile teşhis edilebilir [85]. Çalışma sonucunda hafif vakalarda bile iskemi ve termoregülasyonu ortaya çıkaran etkin bir segmentasyon ortaya çıkmıştır.

### Diğer Hastalıklar

Yapay zekâ tabanlı diğer uygulamalar bu başlık altında ele alınmıştır. Papez ve ark., YSA sınıflandırıcıları ve termal verilerle karpal tünel sendromu üzerine çalışmış ve %82,2'lik doğruluk ile sınıflandırmışlardır [86, 87]. Acharya ve ark. çalışmalarında kuru göz hastalığına odaklanmış ve tedavi izleme (doğruluk: % 99,88; duyarlılık: % 99,7; özgüllük: % 100) ile tanı (doğruluk: % 99,8; duyarlılık: % 99,8; özgüllük: % 99,8) için K-NN yaklaşımını kullanmışlardır [88, 89]. Romatoid artrit hastalığının varlığı ve daha iyi teşhis için belirli ilgi alanları üzerine Frize ve ark. çalışmalarında karar ağaçlarını kullanarak %96 duyarlılık ve %92 özgüllük hesaplamışlardır [90]. Umaphy ve ark. ise K-NN ile romatoid artrit tespitine yönelik çalışmada el termal görüntülerini kullanmış ve 30 sağlıklı, 30 hasta olmak üzere 60 denek ile %83 doğrulukla sınıflandırma gerçekleştirmiştir [91]. Kızılötesi termografi ve YZ algoritmalarının diğer uygulamaları arasında boyun zedelenmesi [92], sırt ağrısı [93], tiroid tümörleri [94], solunum [95], sarhoşluk durumu [96], egzersize bağlı yorgunluk [97], hipertansiyon [98], şizofreni [99], yanık yaraları [100], kardiyovasküler hastalıklar [101], hemodinamik şok [102] ve stres tanıma [103] yer almaktadır. Bu çalışmalarda YSA [92, 95, 97, 98, 103], DVM [93, 96, 97, 99], KA [94], RO [100, 102] ve NB [101] gibi sınıflandırma yöntemleri tercih edilmiştir.

### Değerlendirme ve Sonuçlar

Araştırmacılar yoğun olarak DVM, YSA, ESA ve K-NN sınıflandırma algoritmalarını tercih etmektedir. Bazı çalışmalarda ise birden çok sınıflandırıcı birlikte kullanılmış ve karşılaştırmalı olarak sonuçlar değerlendirilmiştir. Hâlihazırda yayınlanmış olan çok sayıda başarılı uygulama stratejisi ve Weka, Python ve Matlab gibi geliştirme ve hesaplama araçlarında önceden yazılmış algoritmaların mevcudiyeti bu seçimlerin bir gerekçesi olabilir. Araştırmaya göre, YZ kullanılarak kızılötesi termal görüntülemenin biyomedikal uygulamaları: Meme kanseri tespiti (20), diyabetik ve vasküler hastalıklar (7), cilt hastalıkları (3), yenidoğan hastalıkları (8), termoregülasyon analizi (1), karpal tünel sendromu (2), kuru göz hastalığı (2), romatoid artrit (2), boyun zedelenmesi (1), sırt ağrısı (1), tiroid anormallikleri (1), sarhoşluk durumu (1), egzersiz kaynaklı yorgunluk (1), solunum analizi (1), hipertansiyon (1), yanık yaraları (1), kardiyovasküler hastalıklar (1), hemodinamik şok (1), stres tanıma (1) ve şizofreni (1) şeklinde karşımıza çıkmaktadır.

Sınıflandırma uygulamalarının performansını ölçmek için genellikle duyarlılık, özgüllük ve doğruluk değerleri kullanılmıştır. Bu çalışmada incelenen literatürdeki birçok uygulamada sonuçları doğruluk, özgüllük ve duyarlılık değerlerinin hesaplanması ile karşılaştırılmıştır. Doğruluk, duyarlılık ve özgüllük değerleri sırasıyla (1), (2) ve (3) kullanılarak hesaplanmıştır.

Doğru sınıflandırılan durumların, tüm durumlara oranı, doğruluk değerini ifade etmektedir.

$$\text{Doğruluk (\%)} = \frac{DP + DN}{DP + DN + YP + YN} \quad (1)$$

$$\text{Duyarlılık (\%)} = \frac{DP}{DP + YN} \quad (2)$$

$$\text{Özgüllük (\%)} = \frac{DN}{DN + YP} \quad (3)$$

Doğru pozitiflerin, doğru pozitif ve yanlış negatif sonuçların toplamına oranı duyarlılık, doğru negatif sonuçların, doğru negatif ve yanlış pozitif sonuçların toplamına oranı ise özgüllük değerlerini ifade etmektedir. Doğru pozitifler (DP), hasta etiketli bir durumun sınıflandırma algoritması tarafından hasta olarak sınıflandırılması. Doğru negatifler (DN), sağlıklı etiketli durumun sınıflandırma modeli tarafından sağlıklı olarak sınıflandırılması. Yanlış pozitifler (YP), hasta olarak etiketlenen bir sınıfın model tarafından sağlıklı olarak sınıflandırılması. Yanlış negatifler (YN), sağlıklı olarak etiketlenmiş hastalığın model tarafından hasta olarak sınıflandırılması olarak ifade edilir. Daha yüksek oranlar iyi bir YZ algoritmasının göstergesidir. Bununla birlikte, kötü sonuçlar çıkarmaktan kaçınmak için performans ölçütlerini tek tek değil bir bütün olarak incelemek büyük önem taşımaktadır.

Araştırma sonucunda incelenen çalışmalarda, medikal uygulama alanı, kullanılan sınıflandırma yöntemleri ve elde edilen doğruluk değerleri Tablo 2'de alfabetik sırayla verilmiştir.

Medikal Termografi ve Yapay Zekâ Tabanlı Uygulamaları

Araştırma	Çalışma	En iyi sınıflayıcı	Doğruluk %
Acharya ve ark. [105]	Meme Kanseri	DVM	88,1
Acharya ve ark.[89]	Kuru Göz	DVM	100
Acharya ve ark. [88]	Kuru Göz	K-NN	99,8
Adam ve ark.[61]	Diyabetik Ayak	K-NN	93,1
Alzubaidi ve ark.[59]	Diyabetik Ayak	ESA	94,5
Araujo ve ark.[41]	Meme Kanseri	DVM	94,8
Baffa ve ark.[43]	Meme Kanseri	ESA	98
Cho ve ark. [103]	Stres Tanıma	YSA	78,3
Cruz-Vega ve ark.[60]	Diyabetik Ayak	YSA	95,3
Ervural ve ark.[82]	Yenidoğan Hastalıkları	ESA	91
Etehadtavakol ve ark.[48]	Meme Kanseri	AB	95
Fernandez-Ovies ve ark. [44]	Meme Kanseri	ESA	98,75
Francis ve ark.[52]	Meme Kanseri	DVM	90,9
Frize ve Ogungbemile [90]	Romatoid Artrit	KA	-
Frize ve ark. [76]	Yenidoğan, NEC	KA	-
Gogoi ve ark. [42]	Meme Kanseri	DVM	98
Gogoi ve ark. [38]	Meme Kanseri	DVM	83,2
Gopinath ve Prabu [94]	Tiroid Tümörleri	KA	98
Gururajarao ve ark. [62]	Diyabetik Ayak	YSA	91
Hernandez-Contreras ve ark. [58]	Diyabetik Ayak	YSA	94,3
Herry ve ark. [75]	Yenidoğan, NEC	REGRESYON ANALİZİ	90
Jayanthi ve Anburajan [101]	Kardiyovasküler Hastalık	NB	90
Jian ve ark. [99]	Şizofreni	DVM	94,3
Koukiou ve Anastassopoulos [96]	Sarhoşluk	DVM	100
Lashkari [54]	Meme Kanseri	AB	87,4
Lopez ve ark.[97]	Egzersize Bağlı Yorgunluk	ESA	81,5
Magalhes ve ark.[106]	Cilt Neoplazması	K-NN	60
Magalhes ve ark. [67]	Cilt Neoplazması	DVM	84
Magalhes ve ark.[65]	Cilt Neoplazması	DVM	84,2
Martinez-Jimenez ve ark.[100]	Yanık Yaraları	RO	85,3
Milosevic ve ark. [51]	Meme Kanseri	K-NN	92
Nagori ve ark. [102]	Hemodinamik Şok	RO	73
Nicandro ve ark.[47]	Meme Kanseri	NB	71,8
Örnek ve ark. [78]	Yenidoğan Hastalıkları	ESA	99,5
Örnek ve ark. [79]	Yenidoğan Hastalıkları	KA, YSA, LR, RO	92,5
Örnek ve ark. [80]	Yenidoğan Hastalıkları	ESA-VGG16	94,73
Papez ve ark. [86]	Karpal Tünel Sendromu	YSA	82,5
Papez ve ark. [87]	Karpal Tünel Sendromu	YSA	72,2
Prochazka ve ark. [95]	Solunum	YSA	100
Raghavendra ve ark. [55]	Meme Kanseri	KA	98
Roslidar ve ark. [45]	Meme Kanseri	ESA	100
Samant ve Agarwal [63]	Diyabetik Ayak	RO	89,6
Sathish ve ark. [40]	Meme Kanseri	DVM	90
Savasci ve ark. [81]	Yenidoğan Hastalıkları	ANN	98,4

Tablo 2. Kızılıötesi termal görüntülemelerde alfabetik olarak sıralanan biyomedikal termal uygulamalar ve sırasıyla uygulanan temel sınıflandırıcı ile doğruluk değerleri

Kızılötesi termal görüntüleme son yıllarda medikal uygulamalarda kullanılıyor olmasına karşın henüz tetkik, tanı ve tedavide birincil modaliteler arasında gösterilmemektedir. Yapılan çalışmalar, bu teknolojinin YZ ile kullanımının etkinliğini kanıtlayarak da termografiden faydalanma bakımından keşfedilmemiş medikal alanlar oldukça fazladır. Bu durumun nedeni olarak termografi teknolojinin ilkelininin sağlık uzmanlarınınca bilinmemesi, laboratuvar altyapısının yaygın ölçekte olmaması gösterilebilir. Mevcut bilgi sistemlerine entegrasyonu ve gelişmiş teşhis araçlarının geliştirilmesini sağlayan standart bir görüntüleme dosyası formatının olmaması gibi bazı engeller öncelikli modaliteler arasına girmemesine neden olan bir diğer faktör olabilir. Sıcaklık hassasiyeti, yüksek uzaysal çözünürlüğünün yanı sıra tamamen temassız olması kızılötesi termal görüntülemenin zararsız bir görüntüleme metodu olduğunu kanıtlamaktadır. Yeni nesil kızılötesi algılayıcıların ortaya çıkmasıyla, kızılötesi termal görüntüleme, anormal sıcaklık modeli ölçümleri için daha doğru bir alternatif tıbbi teşhis aracı haline gelecektir. Termal görüntüler dijital olarak depolanabilir ve termal model hakkında fikir edinmek için çeşitli yazılım paketleri kullanılarak sonradan işlenebilir olması avantajlarından biridir. Raynaud fenomeni, yumuşak doku romatizması, kan basıncı, el-kol titreşim sendromu, periferik sinir kompresyonları, kompleks bölgesel ağrı sendromu, ateş taraması, eklem romatizması, diyaliz, kemoterapi değerlendirilmesi ve rehabilitasyon prosedürlerinin değerlendirilmesi gibi sorunlar termal görüntüleme ve YZ kullanımı ile büyük başarı sağlayabilecek uygulamalara örnek olarak verilebilir.

## Kaynakça

- Rogalski, A. and Chrzanowski, K. Infrared devices and techniques. *Optoelectronics Review*, 2002. 10(2): p. 111-136.
- Sruthi, S. and Sasikala, M. A. low cost thermal imaging system for medical diagnostic applications. in 2015 International Conference on Smart Technologies and Management for Computing, Communication, Controls, Energy and Materials (ICSTM). 2015. IEEE.
- Bouzida, N., Bendada, A. and Maldague, X.P. Visualization of body thermoregulation by infrared imaging. *Journal of Thermal Biology*, 2009. 34(3): p. 120-126.
- Ring, E. and Bacon, P. Quantitative thermographic assessment of inositol nicotinate therapy in Raynaud's phenomena. *Journal of International Medical Research*, 1977. 5(4): p. 217-222.
- Lahiri, B., et al. Medical applications of infrared thermography: a review. *Infrared Physics & Technology*, 2012. 55(4): p. 221-235.
- Hildebrandt, C., et al. The application of medical infrared thermography in sports medicine. An international perspective on topics in sports medicine and sports injury, 2012. 534.
- Knobel, R.B., Guenther, B.D. and Rice, H.E. Thermoregulation and thermography in neonatal physiology and disease. *Biological research for nursing*, 2011. 13(3): p. 274-282.
- Jones, B.F. A reappraisal of the use of infrared thermal image analysis in medicine. *IEEE transactions on medical imaging*, 1998. 17(6): p. 1019-1027.
- Ring, E. and Ammer, K. Infrared thermal imaging in medicine. *Physiological measurement*, 2012. 33(3): p. R33.
- Technical reference for thermal imagers for human temperature screening. Part 1, Requirements and test methods. 2003: Singapore
- Technical reference for thermal imagers for human temperature screening. Part 2, SPRING Singapore. 2004, Standardisation Dept., SPRING Singapore: Singapore.
- Ammer, K., The Glamorgan Protocol for recording and evaluation of thermal images of the human body. *Thermol Int*, 2008. 18(4): p. 125-44.
- Schwartz, R., et al. The american academy of thermology. Guidelines for neuromusculoskeletal thermography. *Thermol Int*, 2006. 16: p. 5-9.
- Govindarajan, J., A Case for Joint Development of IR Cameras in India. *Journal on Intelligent Electronic Systems*, 2007. 1(1).
- Steketee, J., Spectral emissivity of skin and pericardium. *Physics in Medicine & Biology*, 1973. 18(5): p. 686.
- Amalu, W., et al. Infrared imaging of the breast—An overview. *The Biomedical Engineering Handbook*, 3rd ed., Medical Devices and Systems. CRC Press, Baton Rouge, 2006.
- Lawson, R. Implications of surface temperatures in the diagnosis of breast cancer. *Canadian Medical Association Journal*, 1956. 75(4): p. 309.
- Williams, K.L., Williams, F.L. and Handley, R. Infra-red thermometry in the diagnosis of breast disease. *The Lancet*, 1961. 278(7217): p. 1378-1381.
- Gershon-Cohen, J., Haberman-Brueschke, J. and Brueschke, E. Medical thermography: A summary of current status. *Radio-logic Clinics of North America*, 1965. 3(3): p. 403-431.
- Haberman, J.D. The present status of mammary thermography. *CA: a cancer journal for clinicians*, 1968. 18(6): p. 314-321.
- Winsor, T. and Bendezu, J. Thermography and the peripheral circulation. *Annals of the New York Academy of Sciences*, 1964. 121(1): p. 135-156.
- Skversky, N.J., Herring, A.B. and Baron, R.C. Thermography in peripheral vascular diseases. *Annals of the New York Academy of Sciences*, 1964. 121(1): p. 118-134.
- Albert, S., Glickman, M. and Kallish, M. Thermography in orthopedics. *Annals of the New York Academy of Sciences*, 1964. 121(1): p. 157-170.
- Connell Jr, J.F., Morgan, E. and Rousselot, L.M. Thermography in trauma. *Annals of the New York Academy of Sciences*, 1964. 121(1): p. 171-176.
- Boas, N.F. Thermography in rheumatoid arthritis. *Annals of the New York Academy of Sciences*, 1964. 121(1): p. 223-234.
- Lane, W.Z., Thermography in diseases of the thorax. *Annals of the New York Academy of Sciences*, 1964. 121(1): p. 190-208.
- Sandrow, R.E., et al. The use of thermography in the early diagnosis of neuropathic arthropathy in the feet of diabetics. *Clinical Orthopaedics and Related Research*, 1972. 88: p. 31-33.
- Hartmann, M., Kunze, J. and Friedel, S. Telethermography in the diagnostics and management of malignant melanomas. *The journal of dermatologic surgery and oncology*, 1981. 7(3): p. 213-218.
- Cole, R.P., Jones, S. and Shakespeare, P. Thermographic assessment of hand burns. *Burns*, 1990. 16(1): p. 60-63.
- Soffin, C.B., et al. Thermography and oral inflammatory . Oral surgery, oral medicine, oral pathology, 1983. 56(3): p. 256-262.
- Steed, P.A., The utilization of contact liquid crystal thermography in the evaluation of temporomandibular dysfunction. *CRA-NIO*, 1991. 9(2): p. 120-128.
- Herrick, R.T. and Herrick, S.K. Thermography in the detection of carpal tunnel syndrome and other compressive neuropathies. *The Journal of hand surgery*, 1987. 12(5): p. 943-949.
- Shatsova, E. and Popov, V. The possibilities of infrared thermography in the diagnosis of thyroid pathology. *Problemy endokrinologii*, 1989. 35(2): p. 34-37.
- Nilsson, N.J. Principles of artificial intelligence. 2014: Morgan Kaufmann.
- Deo, R.C. Machine learning in medicine. *Circulation*, 2015. 132(20): p. 1920-1930.

36. Ng, E. and Sudharsan, N. Numerical computation as a tool to aid thermographic interpretation. *Journal of medical engineering & technology*, 2001. 25: p. 53-60.
37. Zuluaga-Gomez, J., et al. A CNN-based methodology for breast cancer diagnosis using thermal images. *Computer Methods in Biomechanics and Biomedical Engineering: Imaging & Visualization*, 2020: p. 1-15.
38. Gogoi, U.R., et al. Singular value based characterization and analysis of thermal patches for early breast abnormality detection. *Australasian physical & engineering sciences in medicine*. 41(4): p. 861-879.
39. Roslidar, R., et al. A Review on Recent Progress in Thermal Imaging and Deep Learning Approaches for Breast Cancer Detection. *IEEE Access*, 2020. 8: p. 116176-116194.
40. Sathish, D., et al. Asymmetry analysis of breast thermograms using automated segmentation and texture features. *Signal, Image and Video Processing*, 2017. 11(4): p. 745-752.
41. Araujo, A.D.S., et al. Computer aided diagnosis for breast diseases based on infrared images. in *2017 IEEE/ACS 14th International Conference on Computer Systems and Applications (AICCSA)*. 2017. IEEE.
42. Gogoi, U.R., et al. Evaluating the efficiency of infrared breast thermography for early breast cancer risk prediction in asymptomatic population. *Infrared Physics & Technology*, 2019. 99: p. 201-211.
43. Baffa, M.d.F.O. and Lattari, L.G. Convolutional neural networks for static and dynamic breast infrared imaging classification. in *2018 31st SIBGRAPI Conference on Graphics, Patterns and Images (SIBGRAPI)*. 2018. IEEE.
44. Fernández-Ovies, F.J., et al. Detection of breast cancer using infrared thermography and deep neural networks. in *International Work-Conference on Bioinformatics and Biomedical Engineering*. 2019. Springer.
45. Roslidar, R., et al. A study of fine-tuning CNN models based on thermal imaging for breast cancer classification. in *2019 IEEE International Conference on Cybernetics and Computational Intelligence (CyberneticsCom)*. 2019. IEEE.
46. Schaefer, G., Závisek, M. and Nakashima, T. Thermography based breast cancer analysis using statistical features and fuzzy classification. *Pattern recognition*, 2009. 42(6): p. 1133-1137.
47. Nicandro, C.-R., et al. Evaluation of the diagnostic power of thermography in breast cancer using bayesian network classifiers. *Computational and mathematical methods in medicine*, 2013. 2013.
48. EtehadTavakol, M., et al. Breast cancer detection from thermal images using bispectral invariant features. *International Journal of Thermal Sciences*, 2013. 69: p. 21-36.
49. Silva, L.F., et al. Thermal Signal Analysis for Breast Cancer Risk Verification. in *MedInfo*. 2015.
50. Wahab, A.A., et al. Tumor localization in breast thermography with various tissue compositions by using Artificial Neural Network. in *2015 IEEE Student Conference on Research and Development (SCOREd)*. 2015. IEEE.
51. Milosevic, M., Jankovic, D. and Peulic, A. Thermography based breast cancer detection using texture features and minimum variance quantization. *EXCLI journal*, 2014. 13: p. 1204.
52. Francis, S.V., Sasikala, M. and Saranya, S. Detection of breast abnormality from thermograms using curvelet transform based feature extraction. *Journal of medical systems*, 2014. 38(4): p. 1-9.
53. Zadeh, H.G., et al. Segmenting breast cancerous regions in thermal images using fuzzy active contours. *EXCLI journal*, 2016. 15: p. 532.
54. Lashkari, A. Early Breast Cancer Detection in Thermogram Images using Supervised and Unsupervised Algorithms. *Middle East Journal of Cancer*, 2016. 7(3): p. 113-124.
55. Raghavendra, U., et al. An integrated index for breast cancer identification using histogram of oriented gradient and kernel locality preserving projection features extracted from thermograms. *Quantitative InfraRed Thermography Journal*, 2016. 13(2): p. 195-209.
56. Sims Jr, D.S., Cavanagh, P.R. and Ulbrecht, J.S. Risk factors in the diabetic foot: recognition and management. *Physical therapy*, 1988. 68(12): p. 1887-1902.
57. Purnima, S., et al. Automated Detection of Diabetic Foot Using Thermal Images by Neural Network Classifiers. *International Journal of Emerging Trends in Science and Technology*, 2017. 4(2348-9480): p. 5183-5188.
58. Hernandez-Contreras, D., et al. Automatic classification of thermal patterns in diabetic foot based on morphological pattern spectrum. *Infrared Physics & Technology*, 2015. 73: p. 149-157.
59. Alzubaidi, L., et al. DFU\_QUTNet: diabetic foot ulcer classification using novel deep convolutional neural network. *Multimedia Tools and Applications*, 2020. 79(21): p. 15655-15677.
60. Cruz-Vega, I., et al. A comparison of intelligent classifiers of thermal patterns in diabetic foot. in *2019 IEEE International Instrumentation and Measurement Technology Conference (I2MTC)*. 2019. IEEE.
61. Adam, M., et al. Automated detection of diabetic foot with and without neuropathy using double density-dual tree-complex wavelet transform on foot thermograms. *Infrared Physics & Technology*, 2018. 92: p. 270-279.
62. Gururajao, S.B., et al. Infrared thermography and soft computing for diabetic foot assessment, in *Machine Learning in Bio-Signal Analysis and Diagnostic Imaging*. 2019, Elsevier. p. 73-97.
63. Samant, P. and Agarwal, R. Machine learning techniques for medical diagnosis of diabetes using iris images. *Computer methods and programs in biomedicine*, 2018. 157: p. 121-128.
64. Lupi, O., Tying, S.K. and McGinnis, M.R. Tropical dermatology: Fungal tropical diseases. *Journal of the American Academy of Dermatology*, 2005. 53(6): p. 931-951.
65. Magalhaes, C., et al. Distinguishing melanocytic nevi from melanomas using static and dynamic infrared thermal imaging. *Journal of the European Academy of Dermatology and Venereology*, 2019. 33(9): p. 1700-1705.
66. Linos, E., et al. Increasing burden of melanoma in the United States. *Journal of Investigative Dermatology*, 2009. 129(7): p. 1666-1674.
67. Magalhaes, C., Vardasca, R. and Mendes, J. Recent use of medical infrared thermography in skin neoplasms. *Skin Research and Technology*, 2018. 24(4): p. 587-591.
68. Bauer, J., et al. Non-contact thermal imaging as potential tool for personalized diagnosis and prevention of cellulite. *Journal of Thermal Analysis and Calorimetry*, 2018. 133(1): p. 571-578.
69. Organization, W.H. Newborn death and illness. 2020; Available from: [https://www.who.int/pmnch/media/press\\_materials/fs/fs\\_newborndearth\\_illness/en/](https://www.who.int/pmnch/media/press_materials/fs/fs_newborndearth_illness/en/).
70. Hug, L., et al. National, regional, and global levels and trends in neonatal mortality between 1990 and 2017, with scenario-based projections to 2030: a systematic analysis. *The Lancet Global Health*, 2019. 7(6): p. e710-e720.
71. Vyas, H.V., Greenberg, S.B. and Krishnamurthy, R. MR imaging and CT evaluation of congenital pulmonary vein abnormalities in neonates and infants. *Radiographics*, 2012. 32(1): p. 87-98.
72. Taylor, A.M. Cardiac imaging: MR or CT? Which to use when. *Pediatric radiology*, 2008. 38: p. 433.
73. Topalidou, A., et al. Thermal imaging applications in neonatal



- tal care: a scoping review. *BMC pregnancy and childbirth*, 2019. 19(1): p. 1-14.
74. Ervural, S., Ceylan, M. and Örnek, A.H. Yapay zekânın termal görüntüleme üzerine uygulamaları. *Türkiye Klinikleri Radyoloji*, 2020: p. 6-11.
75. Herry, C.L., Frize, M. and Bariciak, E. Assessment of abdominal skin temperature change in premature newborns with NEC compared to healthy controls. in *5th European Conference of the International Federation for Medical and Biological Engineering*. 2011. Springer.
76. Frize, M., et al. Infrared Imaging and Classification of Neonates with Necrotising Enterocolitis. in *World Congress on Medical Physics and Biomedical Engineering May 26-31, 2012, Beijing, China*. 2013. Springer.
77. Ornek, A.H., Ervural, S. and Ceylan, M. Determination of Correct Approaches in Evaluation of Thermograms, in *IX. UR-SI-TÜRKİYE 2018 BİLİMSEL KONGRESİ*. 2018, International Union of Radio Science: KTO Karatay Üniversitesi, Konya.
78. Ornek, A.H., Ceylan, M. and Ervural, S. Health status detection of neonates using infrared thermography and deep convolutional neural networks. *Infrared Physics & Technology*, 2019. 103: p. 103044.
79. Örnek, A.H. and Ceylan, M. Classification of Medical Thermograms using Transfer Learning. in *2020 28th Signal Processing and Communications Applications Conference (SIU)*. 2020. IEEE.
80. Örnek, A.H. and Ceylan, M. Explainable Features in Classification of Neonatal Thermograms. in *2020 28th Signal Processing and Communications Applications Conference (SIU)*. 2020. IEEE.
81. Savasci, D., et al. Classification of unhealthy and healthy neonates in neonatal intensive care units using medical thermography processing and artificial neural network, in *Classification Techniques for Medical Image Analysis and Computer Aided Diagnosis*. 2019, Elsevier. p. 1-29.
82. Ervural, S. and Ceylan, M. Detection of Pulmonary Abnormalities of Neonates Using Thermal Imaging and Convolutional Neural Network, in *Conference on Machine Intelligence in Medical Imaging*. 2020, Society for Imaging Informatics in Medicine: Online.
83. Gulyaev, Y.V., et al. Dynamical infrared thermography in humans. *IEEE Engineering in Medicine and Biology Magazine*, 1995. 14(6): p. 766-771.
84. Ogura, Y., et al. Elevation of body temperature is an essential factor for exercise-increased extracellular heat shock protein 72 level in rat plasma. *American Journal of Physiology-Regulatory, Integrative and Comparative Physiology*, 2008. 294(5): p. R1600-R1607.
85. Alpar, O. and Krejcar, O. Detection of irregular thermoregulation in hand thermography by fuzzy C-means. in *International Conference on Bioinformatics and Biomedical Engineering*. 2018. Springer.
86. Papež, B.J., et al. Infrared thermography based on artificial intelligence as a screening method for carpal tunnel syndrome diagnosis. *Journal of International Medical Research*, 2009. 37(3): p. 779-790.
87. Papež, B.J., Palfy, M. and Turk, Z. Infrared thermography based on artificial intelligence for carpal tunnel syndrome diagnosis. *Journal of International Medical Research*, 2008. 36(6): p. 1363-1370.
88. Acharya, U.R., et al. Automated diagnosis of dry eye using infrared thermography images. *Infrared Physics & Technology*, 2015. 71: p. 263-271.
89. Acharya, U.R., et al. Diagnosis of response and non-response to dry eye treatment using infrared thermography images. *Infrared Physics & Technology*, 2014. 67: p. 497-503.
90. Frize, M. and Ogungbemile, A. Estimating rheumatoid arthritis activity with infrared image analysis. *Studies in health technology and informatics*, 2012. 180: p. 594-598.
91. Umopathy, S., Vasu, S. and Gupta, N. Computer aided diagnosis based hand thermal image analysis: a potential tool for the evaluation of rheumatoid arthritis. *Journal of Medical and Biological Engineering*, 2018. 38(4): p. 666-677.
92. Egbert, D.D., Kaburlasos, V.G. and Goodman, P.H. Neural network discrimination of subtle image patterns. in *1990 IJCNN International Joint Conference on Neural Networks*. 1990. IEEE.
93. Koprowski, R. Automatic analysis of the trunk thermal images from healthy subjects and patients with faulty posture. *Computers in biology and medicine*, 2015. 62: p. 110-118.
94. Gopinath, M. and Prabu, S. Classification of thyroid abnormalities on thermal image: a study and approach. *IIOABJ*, May, 2016: p. 41-57.
95. Procházka, A., et al. Breathing analysis using thermal and depth imaging camera video records. *Sensors*, 2017. 17(6): p. 1408.
96. Koukiou, G. and Anastassopoulos, V. Fusion of Dissimilar Features from Thermal Imaging for Improving Drunk Person Identification. *Int. J. Signal Process. Syst*, 2017. 5: p. 106-111.
97. Lopez, M.B., del-Blanco, C.R. and Garcia, N. Detecting exercise-induced fatigue using thermal imaging and deep learning. in *2017 Seventh International Conference on Image Processing Theory, Tools and Applications (IPTA)*. 2017. IEEE.
98. Thiruvengadam, J. and Mariamichael, A. A preliminary study for the assessment of hypertension using static and dynamic IR thermograms. *Biomedical Engineering/Biomedizinische Technik*, 2018. 63(2): p. 197-206.
99. Jian, B.L., et al. The facial expression of schizophrenic patients applied with infrared thermal facial image sequence. *BMC psychiatry*, 2017. 17(1): p. 1-7.
100. Martínez-Jiménez, M.A., et al. Development and validation of an algorithm to predict the treatment modality of burn wounds using thermographic scans: Prospective cohort study. *PloS one*, 2018. 13(11): p. e0206477.
101. Jayanthi, T. and Anburajan, M. Model-based computer-aided method for diagnosis of cardiovascular disease using IR thermogram. 2019.
102. Nagori, A., et al. Predicting hemodynamic shock from thermal images using machine learning. *Scientific reports*, 2019. 9(1): p. 1-9.
103. Cho, Y., Julier, S.J. and Bianchi-Berthouze, N. Instant stress: detection of perceived mental stress through smartphone photoplethysmography and thermal imaging. *JMIR mental health*, 2019. 6(4): p. e10140.
104. Chang, T.C., Hsiao, Y.L. and Liao, S.L. Application of digital infrared thermal imaging in determining inflammatory state and follow-up effect of methylprednisolone pulse therapy in patients with Graves' ophthalmopathy. *Graefe's Archive for Clinical and Experimental Ophthalmology*, 2008. 246(1): p. 45-49.
105. Acharya, U.R., et al. Thermography based breast cancer detection using texture features and support vector machine. *Journal of medical systems*, 2012. 36(3): p. 1503-1510.
106. Magalhaes, C., Vardasca, R. and Mendes, J. Classifying Skin Neoplasms with Infrared Thermal Images. in *presented at the 14th Quantitative InfraRed Thermography Conference (QIRT 2018)*. 2018.
107. Armstrong, D., et al. Infrared Dermal Thermometry for the High-Risk Diabetic Foot. *Physical therapy*, 1997. 77: p. 169-75; discussion 176.

## Medikal Termografi ve Yapay Zekâ Tabanlı Uygulamaları

108. Gratt, B. and Anbar, M. Thermology and facial telethermography: Part II. Current and future clinical applications in dentistry. *Dentomaxillofacial Radiology*, 1998. 27(2): p. 68-74.
109. Hosaki, Y., et al. Non-invasive study for peripheral circulation in patients with diabetes mellitus. *岡大三朝分院研究報告*, 2002. 72: p. 31-37.
110. Sun, P.C., et al. Relationship of skin temperature to sympathetic dysfunction in diabetic at-risk feet. *Diabetes research and clinical practice*, 2006. 73(1): p. 41-46.
111. Park, J.Y., Hyun, J.K. and Seo, J.B. The effectiveness of digital infrared thermographic imaging in patients with shoulder impingement syndrome. *Journal of shoulder and elbow surgery*, 2007. 16(5): p. 548-554.
112. Bagavathiappan, S., et al. Correlation between plantar foot temperature and diabetic neuropathy: a case study by using an infrared thermal imaging technique. *Journal of diabetes science and technology*, 2010. 4(6): p. 1386-1392.

## Sağlık Çalışanları Yapay Zekaya Hazır mı?

### *Are healthcare workers ready for artificial intelligence?*

S. Ayhan ÇALIŞKAN\*<sup>1</sup>, Ozan KARACA<sup>1</sup>, Kadir DEMİR<sup>2</sup>

Sayın Editör,

Sağlık bilimlerinde yapay zeka araştırmaları ile bu araştırma sonuçlarından yararlanılarak geliştirilip sağlık hizmeti kullanımına sunulan ürünler ve uygulamalar geniş bir yelpazeye yayılmaktadır. Sağlık verilerinin toplanması, sınıflanması, yorumlanması, bu verileri kullanarak laboratuvar verilerinin (örneğin, radyolojik ve patolojik görüntülerin) işlenmesi ile elde edilen bilgilerin tıbbi ve cerrahi tedaviyi destekleyici olarak kullanılması bu geniş çerçevenin içinde yer almaktadır. Ayrıca tüm bu aşamalar hakkında hastanın ve ilgili sağlık çalışanlarının bilgilendirilmesi, gerektiğinde erken uyarılması da sürecin önemli bir parçasıdır. Bu çerçeveden bakıldığında tıp ve sağlık bilimleri alanında yapay zekanın kullanımı ve görünürlüğü giderek artmaktadır.

Yapay zeka birçok meslek için ciddi bir tehdit unsuru olarak algılanırken yapay zekanın özellikle sağlık bakım hizmetinde birincil araç, doğrudan teşhis koyucu veya tedaviye ilişkin karar verici olmasını engelleyen nedir? Bu sorunun öncelikli yanıtı, hekimlerin hastanın durumu ile uyum gösteren (adaptif), hastayı anladığı açık ve anlaşılır biçimde sergileyebilmesini sağlayan, uzun evrim sürecinde kazandığı “doğal” iletişim ve empati yetenekleridir.

Buna ek olarak; sağlık çalışanlarının tanı koyarken, tedavi planlarken veya girişimsel uygulamalar sırasında -yapay zekanın eğitim veri setlerinde yer almayan farklılıklar nedeniyle göz ardı edebileceği- gerçek dünyaya ilişkin çok değişkenli durumları da klinik karar verme sürecinde kullanabilmesi gibi bilişsel becerileri de önemli unsurlardır. Bu soruya verilebilecek diğer bir yanıt ise yapay zeka uygulamaları sonucu oluşabilecek hatalı tıbbi uygulamalar (tıbbi malpraktis) ve sonuçlarının sorumlusunun kim olacağına ilişkin etik boyut tartışmasıdır.

Yapay zeka uygulamaları aslında; tanı koymada, tedavi planlamada, cerrahi girişimlerde sağlık çalışanlarının destek olan yararlı bir asistan, bir kolaylaştırıcı ve daha geniş kitlelere sağlık hizmeti sunulmasını sağlayan bir yardımcı, tıbbi malpraktis oranını azaltıcı rolü olan araçlardır. Sağlık alanında mesleklerarası iletişimin verimli yürütüldüğü bir klinikte sağlık hizmetine katkı sunan yapay zeka uygulamasını, klinik ortamda çalışan bir (sanal) sağlık profesyoneli gibi görmek gerektiğini bir betimleme olarak sunmak, sağlıkta yapay zeka dönüşümünün yarattığı “sağlık çalışanlarının yerine geçebilir” algısını değiştirmek için çok yararlı olacaktır.

Bu çerçeveden bakıldığında tüm sağlık çalışanlarının ve öğrencilerinin yapay zeka uygulamaları ve sağlık hizmetlerinde kullanılması konusunda farkındalıklarının artırılması için çalışmalar yapılması, eğitim programları geliştirilerek mezuniyet öncesi, mezuniyet sonrası ve sürekli mesleki gelişim etkinliği olarak uygulanmasına gereksinim vardır. Bu çalışmalar sağlık çalışanlarının yapay zeka uygulamaları konusunda bilgi ve deneyimlerini artırarak onların bu konuda kendilerini daha yetkin ve “hazır” hissetmelerini sağlayacaktır.

Received/Geliş : 11.03.2021

Accepted/Kabul: 31.03.2021

Publication date: 15.04.2021

**S. Ayhan ÇALIŞKAN**

\* ayhan.caliskan@ege.edu.tr

<sup>1</sup>Ege Üniversitesi Tıp Fakültesi,

Tıp Eğitimi Anabilim Dalı,

Bornova, İzmir

ORCID: 0000-0001-9714-6249

**Ozan KARACA**

<sup>1</sup>Ege Üniversitesi Tıp Fakültesi,

Tıp Eğitimi Anabilim Dalı,

Bornova, İzmir

ORCID: 0000-0001-5431-0942

**Dr. Kadir DEMİR**

<sup>2</sup>Dokuz Eylül Üniversitesi, Buca

Eğitim Fakültesi, Bilgisayar ve

Öğretim Teknolojileri Eğitimi

Bölümü,

Bornova, İzmir

ORCID: 0000-0001-9568-9450