

ISSN: 2757-9646

# SAĞLIK BİLİMLERİNDE YAPAY ZEKA

Journal of Artificial Intelligence in Health Sciences

DERGİSİ

Yıl / Year : 1 Sayı / Number : 2 2021



## EDİTÖR KURULU / EDITORIAL BOARD

**Dergi Sahibi & 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  
cigdem@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 Özlu  
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  
basakozan@ozyegin.edu.tr

# SAĞLIK BİLİMLERİNDE YAPAY ZEKA DERGİSİ

2021

CİLT / VOLUME : 1

SAYI / ISSUE 2

Sağlık Bilimlerinde Yapay Zekâ Dergisi yaym 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 ilkeleri'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.



## Danışma Kurulu / Advisory Board

### 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

**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 / Bilgisayar  
Mühendisliği

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

**Prof. Dr. Kaan Orhan**  
Ankara Üniversitesi / Diş 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 Çalışkan**  
Ege Üniversitesi /Tıp Eğitimi

**Doç. Dr. Gökhan Bora Esmer**  
Marmara Üniversitesi/Elektrik-Elektronik  
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 Gökalp Tulum**  
İstanbul Arel Üniversitesi, Mühendislik-  
Mimarlık Fakültesi

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

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

Uzm. Dr. Mehmet Ali Gedik  
Kütahya Sağlık Bilimleri Üniversitesi /  
Radyoloji

**Uzm. Dr. Sedat İrgil**  
Psikiyatri

**Uzm. Dr. Ayşe Nilüfer Köylüoğlu**  
Kütahya Sağlık Bilimleri Üniversitesi /  
Göz Hastalıkları

**Dr. Abdüssamet Aslan**  
Tıp Doktoru

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

**Dr. Yusuf Yeşil**  
İstanbul Üniversitesi / Tıbbi Biyokimya

**Öğr. Gör. Önder Öztürk**  
Kütahya Sağlık Bilimleri Üniversitesi /  
Bilgisayar Mühendisliği

**Emel Gömüş**  
İstinye Üniversitesi / Sağlık Kurumlan  
İşbirliği Koordinatörü



## İçindekiler / Contents

---

**Editörden** ..... IV - V

### **Orijinal Araştırma/Original Research**

Makine Öğrenmesi Yöntemleri İle Covid-19 Verilerinin İncelenmesi: Türkiye Örneği ..... 1-7

Google Trendler İle COVID-19'un Analiz Edilmesi: Türkiye ve Dünya Vaka Örnekleri ..... 8-13

Akıllı telefon kullanarak yapay zeka tabanlı farenjit tespiti ..... 14-19

### **Derleme/Review**

Hemşirelik Mesleğinin Geleceği: Robot Hemşireler ..... 20-25

Dış Hekimliğinde Yapay Zeka ..... 26-33

Artificial Intelligence Applications Used in Pharmacy and Pharmacy Related Fields ..... 34-42

## ▶ Yapay Zekâ Sistemlerine Dair Hukuki Düzenlemelere Doğru

Avrupa Birliği (AB) nezdinde yapay zekâ sistemlerinin geliştirilmesi, pazarlanması ve kullanımına dair hukuki bir çerçeve sağlamak için AB Komisyonu, Yapay Zekâ Tüzüğü Teklif metnini 21 Nisan 2021'de kamuoyu ile paylaşmıştır. Bu Teklifin, takım küçük değişiklikler dışında, yasama sürecini tamamladıktan sonra yürürlüğe girmesi beklenmektedir. Söz konusu Tüzük Teklifi, özellikle sağlık alanında önleyici tıptan, tedaviye dek kullanılan ve kullanılacak yapay zekâ sistemleri açısından sadece AB için değil, ülkemiz için de yakından takip edilmesi gereken bir yasa çalışmasıdır.

Tüzük bu hali ile yasalaşır, Türkiye gibi AB üyesi olmayan ülkelerde yapay zekâ sistemlerini üretenler açısından da bazı hallerde bağlayıcı olabilecektir. Şöyle ki, Teklifin 2. Maddesinde belirtildiği üzere, tüzük hükümleri AB içinde kurulmuş olup olmadığına bakılmaksızın, bir Yapay Zekâ sistemini AB pazarına sokan veya hizmete sunan Yapay Zeka sağlayıcılarını, AB sınırları içindeki yerleşik kullanıcıları ve ürettiği çıktılar AB içinde kullanılan Yapay Zekâ Sisteminin üçüncü ülkelerdeki sağlayıcı veya kullanıcılarını kapsayacaktır.

AB Komisyonu'nun Yapay Zekâ Regülasyon Teklifinde yapay zekâ sistemlerine dair yapılmış olan tanımlar, teknoloji tarafsız bir anlayışla, ileride ortaya çıkacak olan yeni teknolojileri de kapsayacak şekilde düzenlenmiştir. Teklif kapsamındaki yapay zekâ sistemleri hem bağımsız hem de bir başka ürünün bileşeni olan yapay zekâ sistemlerini kapsayacak şekilde tanımlanmıştır. Bu nedenle tüzüğün yürürlüğe girmesi durumunda, sağlık alanında kullanılan makine öğrenmesi gibi yapay zekâ sistemlerinde ve ayrıca yapay zekanın başat rol oynadığı farklı teknolojilerin uygulanmasında da önemli rol oynayacaktır. Örneğin, 2030'da hayatın bir parçası haline gelecek olan 6G Kablosuz teknolojisinde yapay zekâ ile desteklenen bir ağ yapısı söz konusu olacaktır. 6G'de yapay zekâ algoritmaları hem ağdaki anormal durumları tespit edilerek güvenliğin güçlendirilmesi hem de sürekli olarak toplanacak eş zamanlı verilerin analizi ile sağlık alanındakiler dahil olmak üzere hizmetlerin kesintisiz ve güvenli şekilde sürdürülmesini sağlayacaktır. Öte yandan özellikle sağlık alanında önemli vaatleri olan beyin makine arayüzü teknolojisinde son yıllarda kaydedilen gelişmelerde yapay zeka sistemlerinin rolü yadsınamaz. 6G ile birlikte sağlık hizmetleri ve uygulamalarından iletişime dek çok daha hızlı bir şekilde bireylerin sağlık hizmetlerine erişimini sağlama potansiyeli taşıyan bu yeni teknolojilerin geniş kitleler tarafından kabulünde iki unsur göze önüne alınmalıdır: Güven ve ulaşılabilir ücretler.

Bireylerin uzaktan sağlık hizmetlerine, makine öğrenmesi ile giderek gelişen önleyici tıp uygulamalarına, robotik cerrahi, vücut içi ve vücut üstü sensörler ile sağlık takibi gibi uygulamalara açık olabilmeleri için bu teknolojilerin güvenli ve mahremiyete saygılı olduklarına güven duymaları gerekmektedir. Güveni sağlamak için en önemli aracımız, hukuki belirliliği sağlayan, güvenlik standartlarını yasal bir çerçeveye kavuşturan ve zarar ortaya çıkması halinde etkili başvuru olanakları sağlayan yasal düzenleme-lerdir. İkinci olarak, pek çok konuşmasında Prof. Dr. Melih Bulut tarafından da altı çizildiği üzere, yapay zekâ ve bileşeni olduğu diğer



yeni teknolojiler ile doğruluk ve hızı artan sağlık hizmetlerinin sadece dar bir ayrıcalıklı sınıf için değil, tüm bireyler için ulaşılabilir olması hedeflenmelidir. Bu hedefe ulaşmamız da tekelciliği önleyen, yeni oyuncuların pazara girişine olanak tanıyan kurallar ile mümkündür.

Yapay zekâ sistemi dediğimizde veri ile gelişen bir teknolojiden bahsettiğimizden, geniş veri setlerinin birkaç piyasa aktörü elinde yoğunlaşmasının engellenmesi gerekmektedir. Böylece, rekabet canlanacak ve tüm toplumun adil şekilde ulaşması gereken yeni nesil sağlık hizmetleri de ulaşılabilir ücretler ile sunulabilecektir. Özellikle, katılım ve iş birliğini destekleyen bir toplum yapısı önündeki tüm engellerin kaldırılması inovas-yonda çeşitliliği artıracak ve sonucunda kazanan tüm toplum olacaktır. Her bir bireyin yeterli sağlık hizmetinden yararlanmasının ve bu hizmetlere güvenmesinin tüm toplum için ne kadar önemli olduğunu Covid-19 salgınında yaşayarak öğrendik. Bu nedenle, AB Yapay Zekâ Tüzüğü gibi yasal düzenlemeler, sadece bugün kullanılan yapay zekâ sistemlerini değil, yakın gelecekte kullanacağımız uygulamaları ve bu uygulamalar ile dönüşecek hayatlarımızı etkileyecek niteliktedir.

Covid-19 sırasında gözlemlediğimiz bir başka nokta ise, hastaneler başta olmak üzere sağlık kurumlarında siber güvenliğin önemidir. Salgın sıra-sında Avrupa'da siber saldırıya uğrayan bazı hastanelerde acil sağlık hizmetleri kesintiye uğramış ve insan hayatı risk altına girmiştir. Bugün artık hastanelerin bilişim sistemlerinin güvenliğinin teknik önlemler ile sağlanmasının yanı sıra, teknik önlemleri hukuki bir çerçeveye kavuşturan ve verinin hem mahremiyetini hem de güvenliğini korumayı hedefleyen yasal düzenlemelerin insan yaşamı üzerinde hayati etkileri olduğunu biliyoruz. Öte yandan, bilimsel araştırma ve geliştirme çalışmalarının yapılabilmesi için açık veriye ilişkin hukuki çerçevenin netleştirilmesine ihtiyaç vardır. Bu konuda hukuki belirlilik sağlanmadığında hassas veri olan sağlık verisinin paylaşımı tereddütler yaratmakta, bu da yapay zekâ ekosisteminde geride kalınmasına yol açmaktadır. Hukuki düzenlemeler inovasyonun düşmanı değil, dostudur yeter ki doğru kaleme alınsın. Bu nedenle, sağlık verisinin mahremiyeti ve güvenliğini korumaya yönelik yasal düzenlemelerin tümü, sağlıkta yapay zekâ uygulamaları açısından yapay zeka ve hukukun en önemli kesişim alanlarından denilebilir.

Son olarak, yukarıda ele aldığımız AB Komisyonu'nun sunduğu Yapay Zeka Tüzük metninde hukuki sorumluluk ile ilgili yeterince açık bir düzenleme yer almamaktadır. Özellikle sağlık alanında doktorlara destek olmak üzere teşhisten tedaviye dek yapay zekâ sistemlerinin kullanılması nedeni ile çeşitli faktörlerden (sistem arızası, hatalı karar, siber saldırı gibi) ortaya çıkabilecek zararlar kim/nasıl sorumlu olacaktır? Paydaşların çoğaldığı ve farklı ülkelerde yer aldığı bu hizmetlerde hangi ülke hukuku uygulanacaktır? Sağlık alanında kullanılan yapay zekâ sistemleri bir değil birden çok hukuk dalını ilgilendirmektedir. Sağlık hukuku, borçlar hukuku, bilişim hukuku, veri koruma hukuku, rekabet hukuku, sigorta hukuku, ceza hukuku, fikri mülkiyet hukuku, iş hukuku, idare hukuku bunlardan sadece bazılarıdır.

Bu nedenle, Sağlık Bilimlerinde Yapay Zekâ Dergisi'ne her alanda çalışan hukukçuların sağlık ve yapay zeka sistemleri kesişimindeki çalışmalarını heyecanla bekliyoruz. Sağlık ve yapay zekâ kesişiminde pek çok hukuki soru ve sorun hala üzerinde çalışılmayı, keşfedilmeyi ve yanıtlanmayı beklemektedir. Yelkenimiz merakımız, yakıtımızın çok disiplinli işbirliği olması dileği ile dergide emeği geçen tüm hocalarımıza, öğrencilere ve yazıları ile katkı veren herkese teşekkür ederim.

Av. Dr. Başak Ozan ÖZPARLAK

# Makine Öğrenmesi Yöntemleri ile Covid-19 Verilerinin İncelenmesi: Türkiye Örneği

*An Analysis of Covid-19 Data With Machine Learning Methods: The Case of Turkey*

Zeynep ÖZEL\*<sup>1</sup>, Mert DEMİRSÖZ<sup>2</sup>

## Öz

Covid-19 virüsü günümüzde sağlığımızı ve yaşamımızı etkileyen en önemli sorunların başındadır. Bu virüsün normal bir hastada etkisinin yaklaşık olarak bir ay sürdüğü düşünülmektedir. Buradan yola çıkarak Türkiye Sağlık Bakanlığının açıkladığı günlük vakalar, vefatlar, iyileşenler, testler ve ağır hasta sayıları verilerinden yola çıkarak aylık bir değerlendirme yaparak virüsün aylık olarak seyrinin değerlendirilmesi amaçlandı. Araştırmada Mart 2020 ile Mart 2021 arasında açıklanan 12 aylık veri seti kullanıldı. Bu veri seti Makine Öğrenmesi sınıflandırma yöntemlerinden Random Forest algoritması ile analiz edildi. Analiz sonucunda yöntem kesinlik, duyarlılık, F ölçüsü ve AUC-ROC performans ölçütleri ile sınılandı. Ayrıca kullanılan değişkenlerin model için önemi değerlendirildi. Yapılan analizler sonucunda modelin doğruluğu (OOB) ise %83 olarak bulundu. Performans ölçütleri de kesinlik oranı %90, duyarlılık oranı %89, F ölçüsü %89 ve eğrinin altında kalan alan (AUC-ROC) %99 olarak bulundu. Modelinin doğruluğu için en önemli değişken günlük iyileşen sayısı iken sınıf belirlemedeki en önemli değişken günlük iyileşen sayısı olarak belirlendi.

**Anahtar Kelimeler:** Covid-19, Türkiye, Makine öğrenmesi, Rasgele orman, Sınıflandırma yöntemleri

## Abstract

Covid-19 virus is one of the most important problems affecting our health and life today. It is considered that the effect of this virus for a normal patient continues approximately one month. Turkey's Health Ministry declared that the daily cases of death, recovering patient, tests and the number of seriously ill and these cases aimed to evaluate on a monthly basis the progress of virus. In our research were used to announced between March 2020 and March 2021 the data set twelf montly. This data set was analysed with the Random Forest algorithmn, which is one of the machine learning classification methods. As a result of the analysis, the method was tested with precision, recall, score F and AUC-ROC performance criteria. In addition, the importance of the variables used for the model was evaluated. As a result of the analysis, the accuracy (OOB) of our model was found to be 83%. Performance criteria were found to have an precision rate of 90%, a recall rate of 89%, an F score of 89%, and an area under the curve (AUC-ROC) of 99%. While the most important variable for the accuracy of the model was the daily healing number, the most important variable in determining the grade was the Daily Healing Number.

**Keywords:** Covid-19, Turkey, Machine learning, Random forest, Classification methods

Received / Geliş	20.03.2021
Accepted / Kabul	20.07.2021
Publication Date	18.08.2021

\*Sorumlu Yazar  
Corresponding Author

Zeynep ÖZEL  
<sup>1</sup>Selçuk Üniversitesi  
Veterinerlik Fakültesi  
Biyostatistik Anabilim Dalı,  
Konya, Türkiye

✉ zozel4225@gmail.com  
<https://orcid.org/0000-0002-1077-1250>

Mert DEMİRSÖZ  
<sup>2</sup>KTO Karatay Üniversitesi,  
Teknoloji Transfer Ofisi  
<https://orcid.org/0000-0002-4800-2529>

## Giriş

Geçmişten günümüze kadar tüm toplumları etkisi altına alan salgın hastalıkların yaşandığı bilinmektedir. 21. yüzyılın başında ortaya çıkan korona virüsler: 2002 yılında SARS, 2012 yılında MERS ve son olarak 2019 yılında Covid-19 virüsü ile küresel bir sağlık problemi haline gelmiştir. Covid-19 virüsü ilk olarak 2019 yılının Aralık ayında Çin'in Hubei eyaletine bağlı Wuhan şehrinde ortaya çıkmış olan virüs ağır akut solunumsal sorunlara yol açan bir RNA virüsüdür. İnsandan insana damlacık ve temas yoluyla bulaşabilen ve insanlarda ciddi hasara veya ölümcül sonuçlara neden olan bir virüs olduğu bilinmektedir (24).

Türkiye'de ilk olarak 11 Mart 2020 tarihinde görülen Covid-19 virüsü ilk vakanın ardından hızla tüm ülkeyi etkisi altına almış ve günümüzde de hala etkileri devam etmektedir. Sağlık Bakanlığı tarafından Türkiye'de virüsün yayılma hızı, hastanelerde yoğun bakım servislerinde tedavi gören, solunum cihazına bağlı olan, iyileşen hasta sayıları ile ölüm istatistikleri her gün periyodik olarak açıklanmaktadır (25).

Covid-19'un yaygın olarak görülen diğer solunum yolu enfeksiyonlarından ayrılan güvenilir bir klinik özelliği ve teşhis yöntemi yoktur. Yapılan bir çalışmada hastalığın ilk aşamasında en sık görülen semptomların %98'i ateş, %76'sı öksürük, %44'ü halsizlik veya yorgunluk ve atipik semptom olarak %28 balgam, %8 baş ağrısı, %5 hemoptizi, %3 ishal olduğu ve hastaların yaklaşık yarısında nefes darlığı gibi problemlerin yaşandığı görülmüştür (1-3). Yapılan çalışmalarda Covid-19 virüsünün etkisi normal hastalarda maksimum 15 gün kuluçka, 15 gün tedavi olmak üzere 1 aylık iyileşme sürecinden oluşmaktadır (4, 5).

Makine öğrenmesi öngörücü disiplinlerden biri olmasından dolayı mevcut verilerden hareketle tutarlı sonuçlar ortaya koymaktadır. Bu amaçla geliştirilen farklı algoritmalarından biri olan Random Forest yöntemi 2001 yılında Breiman tarafından öne sürülmüştür (22). Breiman'ın bu çalışması 1996 yılında kendisinin önerdiği Bagging yöntemi ile 1998'de Ho tarafından önerilen The Random Subspace tekniğinin bir kombi-nasyonu olarak oluşturmuştur (6,7). Ayrıca 1997'de tanımlanan, her düğüm için en iyi ayrımın rasgele bir seçim üzerinden belirlendiği belirtilen bir çalışmadan da etkilenmiştir (8). Hem regresyon hem de sınıflandırma problemlerine uygulanabilir olmasından dolayı popüler bir modelleme türüdür.

Random Forest yönteminin kullanılmış olduğu Rusya'da yapılmış bir çalışmada iklimsel faktörlerin virüsün yayılmasını etkilemiş olduğu bulunmuş. Araştırmaya göre mevsim sıcaklığı ve günlük sıcaklık aralığının COVID-19 iletiminin yoğunluğu bağlamında önemli olduğu rapor edilmiş. Çalışma bulgularına göre, bahar dönemindeki sıcaklık artışı nedeni ile COVID-19 bulaşma yoğunluğunun azalmasına neden olabileceği belirtilmiştir (13).

Endonezya'da yapılmış bir çalışmada, Nisan ve Eylül ayları arasında süren kurak mevsimde yüksek güneş ışığına

maruz kalma süresi ile iyileşme oranları arasında ilişki bulunduğu rapor edilmiş (23).

Çalışmanın temel hipotezi Türkiye'de Covid-19 verilerinin Random Forest yöntemi ile aylık olarak incelendiğinde pandeminin seyri ve mevsim normallerinde aylara göre değişen hava sıcaklıklarından nasıl etkilenmiş olduğunu ortaya koymaktır.

## Gereç ve Yöntem

### Veri seti tanımı

Veri seti oluşturulurken temelde beş farklı öznelik ele alınmıştır. Bunlar: Sağlık Bakanlığının açıkladığı günlük vakalar, vefatlar, iyileşenler, testler ve ağır hasta sayılarıdır (21). Bu veriler Sağlık Bakanlığı tarafından oluşturulmuş veriler olup buradan elde edilmiştir. Her gün kaydedilen bilgiler, 11 Mart 2020 ile 12 Mart 2021 arasındaki zamanı içermektedir.

Sağlık Bakanlığı tarafından açıklanan hem laboratu-var onaylı hem de klinik olarak teşhis edilmiş vakalar kullanılmıştır. Onaylanmış vakalar veya ölümler kadar medyada yer almayan iyileşmiş vakaların, yapılan testlerin ve ağır hasta sayılarının da büyük bir önemi mevcuttur. Çünkü verilerin doğruluğu medyada oluşmuş veriler değil, hükümetin resmi organlarından açıklanan verilerdir.

### Random forest sınıflama algoritması

Araştırmada veri madenciliği alt çalışma alanlarından olan makine öğrenmesinin Random Forest sınıflandırma algoritması kullanılmıştır.

Random Forest algoritması hem sınıflandırma hem de regresyon problemlerinde kullanılabilir. Algoritma sınıflama için şu şekilde çalışır: Sınıflandırıcı girdi özelliğindeki vektörü alır, ormandaki her ağaçla sınıflandırır ve önermenin çoğunluğunu alan sınıf etiketini çıkarır. Bir regresyon durumunda sınıflandırıcının cevabı ormandaki tüm ağaçlar üzerindeki cevapların ortalamasıdır. Tüm ağaçlar aynı parametrelerle fakat farklı eğitim setleriyle eğitime alınmıştır. Eğitim-den geçen bütün ağaçların her bir düğümünde, bütün değişkenler en iyi bölünmeyi bulmaya değil bunların bir alt kümesini bulmak için kullanılır. Her düğümde yeni bir alt set oluşturulur. Rastgele ağaçlarda eğitim hatasının tahmini için ayrı bir test setine gerek yoktur. Çünkü hata eğitim esnasında tahmin edilmektedir (9).

Random Forest yönteminde, torbalama ve rastgele özellik seçimi birlikte kullanılır. Her yeni eğitim seti, orijinal eğitim setinden iadeli olarak çekilir. Ardından rastgele özellik seçimi kullanılarak yeni eğitim setinde bir ağaç yetiştirilir. Yetiştirilen ağaçlarda budama yapılmaz. Yapılan çalışmalar, özellik seçimi ölçütlerinin değil, budama yöntemlerinin seçiminin ağaç tabanlı sınıflandırıcıların performansını etkilediğini göstermektedir. Torbalamanın kullanılmamasının iki nedeni vardır: Birincisi, rastgele özellik seçimi kullanıldığında torbalama kullanımının doğruluğu arttırdığı görülmektedir. İkincisi, torba dışı hataların (OOB)



hesaplanmasıdır. Budamanın olmaması rastgele ormanları diğer karar ağacı yöntemlerinden daha uygun hale getirmiştir (10).

Model sınıflaması için performansı değerlendiren ve başarıyı ölçen birtakım ölçütler vardır. Bu ölçütlerin hesaplanmasında hata matrisi kullanılmaktadır. Hata matrisi, tahminlerin doğruluğu hakkında bilgi veren 2x2'lik bir matristir. Model performansını ölçmek için tahmin değerleri

ile gerçek değerleri karşılaştırarak bu matris oluşturulur. Bu matris Tablo 1'deki gibidir (11).

Sınıflandırma işlemini yapan sistemin pozitif sınıf etiketlerinin tahmin etmedeki etkililiği duyarlılık olarak tanımlanmaktadır. Duyarlılık, doğru sınıflandırılan pozitif örneklerin toplam pozitif örnek sayısına oranıdır (11).

**Tablo 1:** Hata Matrisi

		Tahmin Edilen Sınıf	
		Pozitif (P)	Negatif (N)
Gerçek Sınıf	Doğru (T)	<b>TP</b> (Doğru tahmin edilen pozitif sınıf)	<b>FN</b> (Yanlış Tahmin Edilen Negatif Sınıf)
	Yanlış (F)	<b>FP</b> (Yanlış Tahmin Edilen Pozitif Sınıf)	<b>TN</b> (Doğru Tahmin Edilen Negatif Sınıf)

**Tablo 2:** Türkiye için aylara göre Performans Ölçütleri

Aylar	Kesinlik	Duyarlılık	F Ölçüsü	AUC
Mart 2020	0,99	0,99	0,99	0,99
Nisan 2020	0,99	0,99	0,99	0,99
Mayıs 2020	0,99	0,88	0,93	0,99
Haziran 2020	0,80	0,57	0,67	0,98
Temmuz 2020	0,57	0,99	0,73	0,99
Ağustos 2020	0,99	0,99	0,99	0,99
Eylül 2020	0,50	0,33	0,40	0,99
Ekim 2020	0,71	0,83	0,77	0,99
Kasım 2020	0,99	0,99	0,99	0,99
Aralık 2020	0,99	0,99	0,99	0,99
Ocak 2021	0,99	0,99	0,99	0,99
Şubat 2021	0,86	0,99	0,92	0,99
Mart 2021	0,99	0,83	0,91	0,98
Model	0,90	0,89	0,89	0,99

**Tablo 3:** Değişken Önem Değerleri

	Doğruluk Önemi	Sınıf ayırma önemi
Günlük Hasta Sayısı	0.058	0.536
Ağır Hasta Sayısı	0.364	0.293
Günlük Test Sayısı	0.362	0.272
Günlük Vefat Sayısı	0.223	0.250
Günlük İyileşen Sayısı	0.541	0.008

$$Duyarlilik = \frac{TP}{TP + FN}$$

Sınıflandırma işlemini yapan sistemin negatif sınıf etiketlerinin tahmin etmedeki etkililiği özgüllük şeklin-de tanımlanmaktadır. Özgüllük, doğru sınıflandırılan negatif örneklerin toplam negatif örnek sayısına oranıdır (12).

$$Özgüllük = \frac{TN}{TN + FP}$$

Doğruluk oranı: Sınıflandırma modellerini değerlendirmek için de bir metrik yöntemdir. Doğruluk oranı testi ile yapılan sınıflandırma modelinin ne kadar verimli olduğunun da tespiti yapılmış olur. Doğruluk oranı yüzde olarak ne kadar yüksek çıkarsa sınıflandırma modelinin de o kadar iyi çalıştığı anlaşılır (11).

$$Doğruluk = \frac{TP + TN}{TP + TN + FP + FN}$$

Kesinlik oranı: Doğru tahmin edilen pozitif sınıf değerinin, bütün pozitif olarak tahmin edilen sınıf değerlerine oranıdır (11).

$$Kesinlik = \frac{TP}{TP + FP}$$

F1 ölçüsü: Duyarlilik ile kesinlik ölçütlerini beraber değerlendirilebilmek için kullanılan F-ölçütü, bu iki ölçütün harmonik ortalamasıdır (11).

$$F \text{ ölçüsü} = 2 \times \frac{Duyarlilik \times Kesinlik}{Duyarlilik + Kesinlik}$$

Modelimizin doğruluğunu tespit etmek için ROC (Receiver Operating Characteristic Curve- Alıcı İşletim Karakteristik Eğrisi) eğrisi kullanılır bu eğri oluşturulurken eğrinin altında kalan alanı belirlemek için AUC (Area Under Curve) değeri hesaplanır. Bu değer modelin sınıfları ne kadar başarılı ayırt edebildiğini anlatır. AUC-ROC değeri 1'e ne kadar yakınsa modelin performansı o kadar iyi denilebilir. Bu değer alabileceği en düşük değer ise 0,5'tir (11).

ROC eğrisi çizilirken y ekseninde duyarlılık, x ekse-ninde ise (1- Özgüllük) değerleri kesişim noktası belirlenerek grafik çizilir (11).

Yukarıda verilen değerler tüm sınıflar için belirle-nerek sonuçlar tüm sınıflara göre değerlendirilir. Bu değerler sayesinde model ile ilgili değerlendirme yapılacaktır.

Random Forest sınıflama algoritmasında değişkenler için doğruluktan ortalama düşüş (mean decrease in accuracy) ve

düğüm saflığında toplam artış (total increase in node purity) olarak iki farklı değer hesaplanmaktadır. Bu değerler 1'e yaklaştıkça değişken önemi artmakta azaldıkça değişken önemi azalmaktadır. Yapılan tahmin ile en iyi sınıflamayı yapmasında en çok yardımcı olan değişkenin belirlenmesi sağlanır. Bunun sonucunda değişkenin model için kullanılabilirliği incelenir (9).

### Veri analizi

Random Forest sınıflandırma algoritması için maksimum 100 ağaç oluşturulmuş ve bu 100 ağacın %50'si eğitim seti için kullanılmıştır. Bu eğitim setinde kullanılacak ağaçların her biri bir tahmin üreterek algoritmayı eğitmiştir. Eğitilen algoritma sonucunda tahminler oluşturulmuştur. Tahminler veri setindeki sonuç çıktılarının %20'si kullanılarak test edilmiştir. Buradan yola çıkarak veri setinde kullanılan değişkenler bağımsız olsa da test seti ile eğitim seti birbirinden bağımsız değildir. Bu ilişkiden yararlanarak doğruluk oranları oluşturulmuştur. Test seti ile eğitim setinin kesiştiği optimum doğruluk oranı bize modelimizin doğruluk oranını (Out Of Bag-OOB) ve en verimli ağacı belirlememizi sağlamıştır. Eğitilen verinin ise %20'si doğrulama için kullanılmıştır. Elde edilen sonuçlar doğrultusunda modelin doğruluk eğrisi çizilmiştir. Modelin performansını değerlendirmek için Kesinlik, Duyarlilik, F Ölçüsü ve AUC-ROC performans ölçütleri kullanılmış ve bu ölçütler yardımı ile ROC eğrisi çizilmiştir. Son olarak modelde kullanılan değişkenlerin önemleri değerlendirilmiştir. Model hakkında genel bir değerlendirme yapabilmek için karar sınır matrisleri kullanılmıştır. Bu matristeki her hücre kesişen iki sınıf hakkında değerlendirme yapması sağlanmıştır.

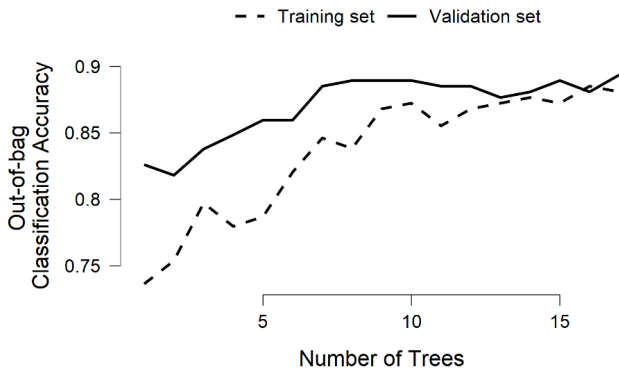
Analizimiz Jasp (JASP Team (2020). JASP (Version 0.14) [Computer software]) programı kullanılarak gerçekleştirildi. Jasp programında analizin nasıl yapılacağı eklerde görsel olarak verilmiştir.

### Bulgular

Şekil 1'de araştırmada değişkenler arasındaki ilişkiler incelendiğinde en yüksek ilişkinin günlük test sayısı ile ağır hasta sayısı arasında %86, daha sonra günlük hasta sayısı ile ağır hasta sayısı arasında %80 ilişki bulunmuştur. En düşük ilişki ise %21 ile günlük hasta sayısı ile günlük iyileşen sayısı arasındadır. İncelenen tüm değişkenler arasında istatistiksel olarak anlamlı ilişkiler vardır.

Random Forest yöntemi ile oluşturulan modelde maksimum 100 ağaç kullanılmıştır. Bu ağaçlardan en verimli ağacın 17. ağaç olduğu tespit edilmiştir. Eğitilen model test aşamasında maksimum %89, doğrulama aşamasında ise maksimum %93 doğruluğa ulaşmıştır. Modelin doğruluğu (OOB) ise %83 olarak bulunmuştur. Modelin doğruluk grafiği Grafik 1'de verilmiştir.

Modelin performansını değerlendirmek için Tablo 2' de kesinlik, duyarlılık, F ölçüsü ve AUC-ROC performans ölçütleri verilmiştir.



Grafik 1: Model Doğruluk Grafiği

Kesinlik değeri modelin %90 doğru sınıflandırıldığını göstermektedir. Duyarlılık oranı ise eğitim veri setinin %89 ile gerçek sonuçları temsil ettiğini göstermektedir. F ölçüsü ise kesinlik be duyarlılık değerlerinin harmonik ortalaması ile bulunduğu ve metriklerin doğruluğunu göstermektedir. Metrikler %89 doğruluğa sahiptir. Eğrinin altında kalan alan (AUC-ROC) %99 olarak bulunmuştur. Modelin performansının aylara göre değerlendirilmesi sonucunda elde edilen metrikler Tablo 2' de detaylı olarak verilmiştir.


Şekil 2' de çalışmadaki aylara ait ROC eğrileri çizilmiştir. Tablo 2' de verilen AUC-ROC değerleri ROC eğrisinin altında kalan alanı belirtmektedir. Buradan yola çıkarak Random Forest sınıflandırma yönteminin aylara göre çok iyi bir sınıflandırma yaptığı görülmektedir.

Tablo 3'e göre doğrulukdaki ortalama düşüş, her bir özelliğin Random Forest modelinin doğruluğu üzerindeki etkisini ölçmek için değerlendirilmiştir. Bunun sonucunda Random Forest modelinin doğruluğu için en önemli değişken günlük iyileşen sayısı olarak belirlenmiştir. Sınıf ayırma önemi ise hangi değişkenin sınıfları belirlemede daha önemli olduğunu göstermektedir. Bunun sonucunda sınıf belirlemedeki en önemli değişken günlük iyileşen sayısı olarak belirlenmiştir.

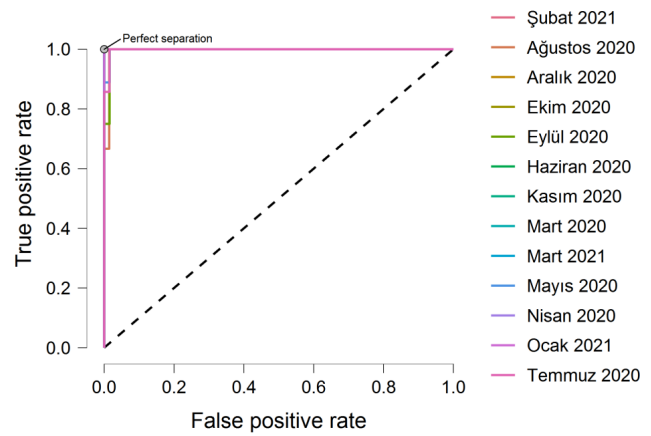
Şekil 3' e göre günlük hasta sayısı ile günlük test sayısı birlikte incelendiğinde; günlük test sayısı en çok Ocak 2021, Şubat 2021, Mart 2021 aylarında, günlük hasta sayısı en çok Ekim 2020, Kasım 2020, Aralık 2020 aylarında artmıştır.

Günlük hasta sayısı ile günlük vefat sayısı birlikte incelendiğinde; günlük test sayısı en çok Ocak 2021, Şubat 2021, Mart 2021 aylarında, günlük vefat sayısı ise en çok Ekim 2020, Kasım 2020, Aralık 2020 aylarında Nisan 2020, Mayıs 2020 aylarında da artmıştır.

Günlük iyileşen sayısı ile günlük test sayısı birlikte incelendiğinde; Aralık 2020'de hem günlük test sayısı hem de günlük iyileşen sayısı artmıştır. Ocak 2021 ve Şubat 2021'de artış daha çok günlük test sayısında olmuştur. Diğer tüm aylarda günlük iyileşen sayısında ciddi bir artış olmamıştır.



Şekil 1: Değişkenler arasındaki ilişkiler




Şekil 2: Random Forest Yöntemi için ROC Eğrileri

Ağır hasta sayısı ile günlük iyileşen sayısı birlikte incelendiğinde; Eylül 2020, Ekim 2020, Kasım 2020' de ağır hasta sayısı en yüksek seviyeye ulaşmıştır. Aralık 2020' de ise hem ağır hasta sayısı hem de günlük iyileşen sayısı yüksektir. Ocak 2021 ve Şubat 2021' de ağır hasta sayısı daha yüksek seviyededir.

### Tartışma

Covid-19 salgını, önemli küresel sağlık ve ekonomik zorluklara neden olmuştur. Bu çalışmada Türkiye Covid-19 verileri Random Forest sınıflama algoritması ile aylık olarak sınıflayıp virüsün aylara göre durumları değerlendirilmiştir. Çalışmada hava sıcaklıkları değişken olarak ele alınmamıştır. Hava sıcaklıklarının mevsim normallerinde seyrettiği düşünüldüğünde aylara göre temel alınarak incelenmiştir. Sonuç olarak oluşturduğumuz modelin doğruluğu %83 olarak bulunmuştur. Kesinlik, duyarlılık, F ölçüsü ve AUC-ROC performans ölçütleri değerlendirilmiş ve bu değerlendirme sonucunda kesinlik oranı %90, duyarlılık oranı %89, F ölçüsü %89 ve eğrinin altında kalan alan (AUC-ROC) %99



**Şekil 3:** Türkiye için aylara göre karar sınır matrisi

olarak bulunmuştur. Değişken önemleri açısından modelin doğruluğu için en önemli değişken günlük iyileşen sayısı iken sınıf belirlemedeki en önemli değişken günlük iyileşen sayısı olduğu belirlenmiştir.

Buradan yol çıkarak Covid-19 modelinin aylık olarak çok yüksek derecede sınıflandırılma oranına (%83) sahip olduğu belirlenmiştir. Bu oranın yüksek olması, verilerin aylık olarak farklı etkilere sahip olduğunu göstermektedir. Ayrıca Rusya'da yapılan bir çalışmada Rusya'daki bölgelerdeki biyoklimatik değişkenler ve iklim değişkenleri ile Covid-19 vakaları arasındaki bağlantıları bulunmuş. Bu çalışmada mevsimsel durumların Covid-19 üzerinde anlamlı bir etkisinin olduğu tespit edilmiş. Ayrıca nemli bölgelerde sıcaklık ve rüzgâr hızı ile Covid-19 yoğunluğu arasında pozitif bir ilişki olduğunu tespit edilmiş. Mevsimsel olaylar aylara göre değişiklik gösterdiği için bu sonuçlar bu çalışmadaki bulguları desteklemektedir (13). Öte yandan, yapılan diğer bir çalışmada altı bölgede, günlük sıcaklık aralığı, nem ve sıcaklığın tümü, Covid-19'un yayılması üzerinde olumlu bir etkiye sahip olduğu belirlenmiş. İklim ilişkilerinin sonuçları önceki çalışmalarla tutarlıdır (14). Ek olarak, Covid-19 vakalarının ve ölümlerinin sıcaklık dalgalanmasından etkilendiğini ve daha düşük sıcaklıkla önemli bir ilişkinin bulunduğu tespit edilmiş (15, 16, 17). Sıcaklığın Covid-19 vakalarının üzerindeki etkisini inceleyen çalışmalar da vardır (18, 19). Bazı çalışmalar hem sıcaklığın hem de soğğun etkilerinin solunum hastalıklarını olumsuz etkileyebileceği kanısındadır. Ayrıca 30 doğu Asya şehrinde artan günlük sıcaklık aralığı riskinin daha yüksek kardiyovasküler hastalık riski ile bağlantılı olduğu bulunmuş (19, 20). Bu sonuçlara göre değerlendirilmesi bize yeni bir bakış açısı sağlayacaktır.

## Sonuç

Bu araştırmalar ışığında tüm solunum yolu rahatsızlıklarında olduğu gibi Covid-19 virüsünün de mevsimler ve sıcaklıklar ile arasında anlamlı ilişkiler vardır. Aylara göre virüsün etkilerinin farklı olduğu çalışmamız sonucunda bulunmuştur. Random Forest sınıflama algoritması bu değerlendirmeyi yapmada oldukça kullanışlı bir makine öğrenme algoritmasıdır.

Artan Covid-19 vakalarına ve ölümlerine hızlı yanıt vermek için iklim temelli, hava sıcaklıklarının göz önüne alınması ve erken uyarı sistemlerinin geliştirilmesi Covid-19 bulaşma riskini azalmak için önemli bir yol olabilir. Bu ilişkilerin daha iyi anlaşılması, Covid-19 pandemisini kontrol etmek ve önlemek için temel bir unsur olan daha iyi iklime duyarlı müdahaleler yoluyla hızla büyüyen vakaları ve ölümleri kontrol etmek için kritik öneme sahiptir.

**Çıkar çatışması:** yok

**Finansal destek:** yok

**Yazar katkıları:**

**Motivasyon / Konsept:** ZÖ, MD

**Çalışma Tasarımı:** ZÖ

**Kontrol / Gözetim:** ZÖ, MD

**Veri Toplanması ve/veya İşlemesi:** MD

**Analiz ve/veya Yorum:** MD

**Literatür inceleme:** ZÖ, MD

**Makalenin Yazılması:** ZÖ

**Eleştirel İnceleme:** ZÖ, MD

## KAYNAKLAR

1. Wu D, Wu T, Liu Q, Yang Z. The Sars-Cov-2 outbreak: what we know, International Journal of Infectious Diseases. 2020 March; 94:44-48. doi: 10.1016/j.ijid.2020.03.004.
2. Huang C, Wang Y, Li X, et al. Clinical features of patients infected with 2019 novel coronavirus in Wuhan, China. The lancet. 2020 January;395.10223:497-506. doi:10.1016/S0140-6736(20)30183-5.
3. Uğraş-Dikmen A, Kına HM, Özkan S, İlhan MN. Covid-19 epidemiyolojisi: Pandemiden ne öğrendik. Journal of Biotechnology and Strategic Health Research. 2020 April;4: 29-36. doi: 10.34084/bshr.715153.
4. Atalay S, Ersan G. Covid-19 Tedavisi. Tepecik Eđit. ve Arařt. Hast. Dergisi. 2020 Temmuz;30: 126-134. doi:10.5222/terh.2020.48030.
5. Sağlık Bakanlığı. Covid-19 Bilgilendirme Platformu İnkübasyon süresi [İnternet]. Türkiye Cumhuriyeti Sağlık Bakanlığı; 2020 Temmuz [Eriřim 2021 Mart 13]. Eriřim adresi: <https://covid19.saglik.gov.tr/TR-66474/inkubasyon-suresi.html>
6. Breiman L. Bagging predictors. Machine learning. 1996 August; 24.2: 123-140.
7. Ho TK. The random subspace method for constructing decision forests, IEEE transactions on pattern analysis and machine intelligence. 1998 August; 20.8: 832-844.
8. Amit Y, Geman D, Wilder K. Joint induction of shape features and tree classifiers. IEEE transactions on pattern analysis and machine intelligence. 1997 November; 19.11: 1300-1305.
9. Demirsöz M, Özel Z, Yonar H et al. 2020 Classification of Covid-19 Case Numbers for G8 Countries and Turkey by Random Forest Method, Medicres-2020 7th International Multidisciplinary Congress On Good Medical, Research Conference Abstracts and Proceedings Book. pp;52-53.
10. Palczewska A, Palczewski J, Robinson RM, Neagu D. Interpreting random forest classification models using a feature contribution method, In: Integration of reusable systems. Springer, Cham. 2014 February;193-218.
11. Karlı ÖB. Makine öğrenme yöntemleri ile karaciđer hastalığının teşhisi [Yüksek lisans tezi]. Ağrı İbrahim Çeçen Üniversitesi; 2019.
12. Khan SUR, Islam MA, Aleem M, Iqbal M.A. Temporal specificity-based text classification for information retrieval, Turkish Journal of Electrical Engineering & Computer Sciences. 2018 November; 26.6: 2915-2926. doi:10.3906/elk-1711-136.
13. Pramanik M, Udmale P, Bisht P et al. Climatic factors influence the spread of Covid-19 in Russia, International journal of environmental health research. 2020 July;1-15. doi:10.1080/09603123.2020.1793921.
14. Pramanik M, Chowdhury K, Rana MJ, et al. Climatic influence on the magnitude of Covid-19 outbreak: a stochastic model-based global analysis, Medrxiv. 2020 October;1-17 doi:10.1101/2020.06.02.20120501.
15. Fallah GG, Mayvaneh F. Effect of air temperature and universal thermal climate index on respiratory diseases mortality in Mashhad, Iran. Arch Iran Med. 2016 September; 19(9):618–624. doi:10.161909/AIM.004.
16. Gomez-Acebo I, Llorca J, Dierssen T. Cold-related mortality due to cardiovascular diseases, respiratory diseases and cancer: a case-crossover study, Public Health. 2013 March; 127(3):252–258. doi:10.1016/j.puhe.2012.12.014.
17. Dadbakhsh M, Khanjani N, Bahrapour A, Haghighi PS. Deaths from respiratory diseases and temperature in Shiraz, Int J Biometeorol. 2017 July; 61(2):239–246. doi:10.1007/s00484-016-1206-z.
18. Xie J, Zhu Y. Association between ambient temperature and Covid-19 infection in 122 cities from China. Sci Total Environ. 2020 July; 724:138201. doi:10.1016/j.scitotenv.2020.138704.
19. Li M, Zhou M, Yang J et al. Temperature, temperature extremes, and cause-specific respiratory mortality in China: a multi-city time series analysis, Air Qual Atmos Health. 2019 January; 12(5):539–548. doi:10.1007/s11869-019-00670-3.
20. Kim J, Shin J, Lim Y et al. Comprehensive approach to understand the association between diurnal temperature range and mortality in East Asia, Sci Total Environ. 2016 January; 539:313–321. doi:10.1016/j.scitotenv. 2015.08. 134.
21. Tekindal MA, Yonar H, Yonar A, et al. Analyzing Covid-19 outbreak for Turkey and Eight Country with Curve Estimation Models, Box-Jenkins (ARIMA), Brown Linear Exponential Smoothing Method, Autoregressive Distributed Lag (ARDL) and SEIR Models Eurasian J Vet Sci, Covid-19 Special Issue. 2020 November; 142-155.
22. Breiman L. Random forests. Machine learning. 2001 October; 45(1), 5-32.
23. Asyary A, Veruswati M. Sunlight exposure increased Covid-19 recovery rates: A study in the central pandemic area of Indonesia, Science of The Total Environment. 2020 August; 729, 139016. doi:10.1016/j.scitotenv.2020.139016.
24. World Health Organization. Coronavirus disease (Covid-19) pandemic [İnternet]. [Eriřim 2021 Mart 13]. Eriřim adresi: <https://www.euro.who.int/en/health-topics/health-emergencies/coronavirus-covid-19/novel-coronavirus-2019-ncov>
25. Sağlık Bakanlığı. Covid-19 Bilgilendirme Platformu [İnternet]. Türkiye Cumhuriyeti Sağlık Bakanlığı; [Eriřim 2021 Mart 13]. Eriřim adresi: <https://covid19.saglik.gov.tr/TR-66935/genel-koronavirus-tablosu.html>

# Google Trendler İle COVID-19'un Analiz Edilmesi: Türkiye ve Dünya Vaka Örnekleri

*Analyzing COVID-19 with Google Trends: Turkey and World Case Studies*

Tevfik BULUT<sup>1</sup>

## Öz

Bu çalışmada 01.01.2020 ile 21.03.2021 tarihini içine alan yaklaşık 14 aylık süre içerisinde büyük veri kaynağı olan Google Trends'i kullanarak COVID-19 pandemisinin eğilimleri ve bu eğilimler ile COVID-19 vakaları arasındaki ilişki düzeylerinin analiz edilmesi amaçlanmıştır. Bu amaçla, öncelikle koronavirüs verileriyle ilişkili arama terimlerine göre oluşturulan Google Trends verilerine bağlı olarak pandeminin seyri hem Türkiye hem de dünya bağlamında ortaya konulmuştur. Ardından ise günlük onaylanmış koronavirüs vakaları ile koronavirüs ilişkili arama terimleri kullanılarak üretilen Google Trends verileri karşılaştırmalı olarak hem dünya hem de Türkiye özelinde incelenmiştir. Son olarak, Türkiye'de ve dünyada Google Trend koronavirüs pandemisi ilişkili alt arama sorgularında öne çıkan arama terimleri ortaya konulmuştur. Türkiye ve dünya vakalarından elde edilen bulgular, Google Trend Hit sayıları ile günlük onaylanmış vaka sayıları trendinin birbiriyle benzerlik göstermediğini ortaya koymuştur. Aynı zamanda Türkiye ve dünya vakalarında Google Trend Hit sayılarının izlediği dalgalı seyrin aksine günlük onaylanmış vaka sayılarının doğrusal bir seyir izlediği gözlenmiştir. Google Trends üzerinden halk sağlığına yönelik arama faaliyeti verileri, COVID-19 pandemisi gibi halk sağlığı krizlerinde gerçek zamanlı, bilgilendirici ve maliyet etkili halk sağlığı politikaları oluşturulmasında ön bulgu olarak kullanılabilir. Bu tür bulgular aynı zamanda istatistiki verilerle ilişki karşılaştırılarak aralarındaki ilişki ortaya konulabilir.

**Anahtar Kelimeler:** Google trends, COVID-19, Halk sağlığı, Pandemi, Salgın.

## Abstract

In this study, it is aimed to analyze the trends of COVID-19 pandemic and relationship levels between these trends and COVID-19 cases by using Google Trends as a big data source in about 14 months including the dates between 2020-01-01 and 2021-03-21. For this purpose, first, the course of the pandemic depending on Google Trends data generated according to the search terms associated coronavirus has been demonstrated both in the context of Turkey and World. At the same time, daily confirmed cases, and Google Trends data produced using the search terms associated coronavirus were studied in a comparative context of the world and in Turkey. Finally, featured search terms in Google Trend coronavirus pandemic-related sub-search queries has been demonstrated in World and Turkey. The findings obtained in Turkey and world cases have indicated that the trend that Google Trends Hit counts followed was not similar to the one that the number of daily confirmed coronavirus cases followed. Public health search activity data via Google Trends can be used as preliminary evidence for real-time, informative and cost-effective public health policies in public health crises such as COVID-19 pandemic. Such findings can also be compared with statistical data and relationship between them can be revealed.

**Keywords:** Google trends, COVID-19, Public health, Pandemic, Outbreak.

Received / Geliş	27.05.2021
Accepted / Kabul	27.07.2021
Publication Date	18.08.2021

**\*Sorumlu Yazar  
Corresponding Author**

Tevfik BULUT  
<sup>1</sup>T.C. Sanayi ve Teknoloji Bakanlığı,  
Ankara, Türkiye

✉ buluttevfik@gmail.com

<https://orcid.org/0000-0002-3668-7346>

## Giriş

31 Aralık 2019 tarihinde Çin'in Hubei eyaletinin Wuhan kentinde bir grup hasta içinde kaynağı bilinmeyen yeni bir koronavirüs tespit edildi [1]. Bu tarihten başlayarak dünyayı etkisi altına alan koronavirüs pandemisinde 11 Nisan 2021 itibarıyla dünyada toplam onaylanmış vaka sayısı 135 milyonu geçmiş, hayatını kaybedenlerin sayısı ise 3 milyona yaklaşmıştır [2].

Son yıllarda kuruluşlar içinde ve web üzerinden toplanan, depolanan ve iletilen benzeri görülmemiş miktarda veriye tanık olunmaktadır. Bu veri patlaması, büyük veri kullanımlarına ve analitiğe dikkat çekmiş ve büyük verinin kullanımı ve uygulanmasından kaynaklanacak sosyal dönüşüme akademik ilgiyi artırmıştır. Büyük veri, büyük veri hacmi ve karmaşık veri yapıları ile genellikle bağlanabilir bilgi olarak kabul edilir [3]. Örnekler arasında sosyal medya verileri, cep telefonu arama kayıtları, ticari web sitesi verileri, halka açık coğrafi bilgiler, arama motoru verileri, akıllı kart verileri ve taksi yörünge verileri bulunur [4]. Büyük veri kullanımının en önemli uygulamalarından biri de insan davranışlarını ve sosyal değişimleri anlamak, tahminlerde bulunmak ve projeksiyonlar çizmek isteyen çeşitli organizasyon ve grupları desteklemektir [5,6].

Milyonlarca insan, sağlıkla ilgili semptomlar, teşhisler, tedaviler ve bunların olası yan etkileri veya teşhis prosedürleri hakkında bilgi ve materyallere ulaşmak için her gün çevrimiçi arama motorlarını kullanmakta ve kişisel sağlık durumlarını ve davranışlarını içeren bilgileri çeşitli Web sitelerinde gönüllü olarak paylaşmaktadır. Bu nedenle, çevrimiçi bilgi arayanların davranışlarının izlenmesinden elde edilen veriler, halk sağlığı sürveyansı ve araştırmasında kullanım için potansiyel fırsatlar sunmaktadır. Google Trends, internet kullanıcılarının zaman içinde veya coğrafi konuma göre tek bir terim veya kelime öbeğine göre arama sıklığını ortaya konulmasına imkân tanıyan en popüler arama motoru olan Google arama motoru özelliğidir [7, 8, 9, 10]. Google Trendler ilk olarak 11 Mayıs 2006'da tanıtılmıştır. Google daha sonra 5 Ağustos 2008'de, kullanıcılara arama trendleri hakkında veri sağlayan gelişmiş ve daha ayrıntılı bir hizmet olan Google Arama Trendleri'ni piyasaya sürdü. 27 Eylül 2012'de Google, Google Arama Trendleri ile Google Trendleri birleştirdi [11].

Google Trendler, bulaşıcı hastalıkların ve salgın hastalıkların izlenmesinde kullanılmakta olan değerli, kolay erişilebilir araçlardan birisidir. Google Trendler üzerinden Covid-19 ilişkili arama terimlerine göre elde edilen veri ile yapılan çalışmalar mevcuttur. Bu çalışmalardan biri Mavragani ve Gkillas (2020) tarafından yapılmış olup, bu çalışmada Amerika Birleşik Devletleri'nde hem ulusal hem de eyalet düzeyinde COVID - 19 salgını analiz edilmiştir. Analizde COVID-19 vaka ve ölüm sayıları ile Google Trendler verileri arasındaki ilişki ortaya konulmuştur [10]. Li ve diğerleri (2020) tarafından da Çin'de COVID-19 ilişkili benzer bir

çalışma yapılmış olup, bu çalışmada da internet ve sosyal medya aramaları ile COVID-19 onaylanmış ve şüpheli vakalar arasındaki ilişki ortaya konulmuştur [12]. Effenberger ve diğerleri (2020) tarafından yapılmış çalışmada ise farklı ülkelerdeki Google Trends verileri ile COVID-19 yeni vakaları arasındaki ilişki incelenmiştir [13]. Hong ve diğerleri (2020) tarafından yapılan bir diğer çalışmada da Amerika Birleşik Devletleri'nde COVID-19 ve tele sağlık aramaları arasında ilişki Google Trends verileri üzerinden yapılmıştır [14]. Mavragani ve Gkillas (2020) tarafından COVID-19 pandemisinde en çok etkilenen İtalya (ulusal ve bölgesel düzey), İspanya, Fransa, Almanya ve Birleşik Krallık özelinde yapılan çalışmada ise Google Trends verileri ile COVID-19 vakaları ve ölümleri arasında ilişki ortaya konulmuştur [10].

Çalışma kapsamında belirlenen arama terimlerine göre yaklaşık 14 aylık süre içerisinde Türkiye ve dünyadaki COVID-19 vakaları özelinde Google Trendler ile bilgi arama davranışı kalıpları ortaya konulmuştur. Ardından ise bu bilgi arama davranış kalıpları ile onaylanmış koronavirüs vakaları arasındaki ilişkiyi ortaya koymaya yönelik keşifsel bir araştırma yürütülmüştür.

## Yöntem

Çalışma kapsamında ilk olarak Google Trends verileri kullanılarak COVID-19 pandemisinin 01-01-2020 ile 21-03-2021-tarihleri arasındaki trendinin analiz edilmesi amaçlanmıştır. Bu kapsamda Türkiye için Türkçe olarak belirlenen COVID-19 ilişkili arama terimleri şöyledir: "virüs", "pcr", "aşı", "korona", "corona", "kovit", "covid", "covid-19", "covid19", "pandemi", "salgın", "epidemi", "maske", "sosyal mesafe", "karantina".

Diğer taraftan dünya için İngilizce olarak belirlenen COVID-19 ilişkili arama terimleri ise şöyledir: "virus", "pcr", "vaccine", "corona", "coronavirus", "covid-19", "covid", "pandemic", "covid19", "pandemic", "epidemic", "isolation", "mask", "social distance", "quarantine".

Çalışma kapsamında kullanılan bir diğer veri seti onaylanmış COVID-19 vakalarını kapsamaktadır. Bu veri seti, Birleşmiş Milletler İnsani İşler Koordinasyonu Ofisi'ne ait web sitelerinden biri olan İnsani Veri Alışverişi'nden (HDX) elde edilmiştir [15]. Bu web sitesinde koronavirüs veri setleri birbirinden bağımsız olup onaylanmış vaka veri seti analiz kapsamında kullanılmıştır. Bu web sitesinden alınan veri seti csv uzantılıdır.

Hem Google Trend ve hem de onaylanmış vaka veri setleri, veri madenciliği teknikleri kullanılarak zaman serisine göre eşleştirilmiştir. Veri madenciliği ve analiz aşamasında Microsoft Excel 2016 [16] ve ağırlıklı olarak R programlama dili [17] kullanılmıştır. Veri setlerinde zaman serilerinde mükerrer kayıtlar olduğu için bu kayıtlar her ülke içinde benzersiz zaman serilerine indirgenmiştir. Google trend verisinin elde edilmesinde ise R yazılımında kayıtlı

“gtrendsR” paketi kullanılmıştır [18]. Grafiklerin elde edilmesinde ise “ggplot2” paketi kullanılmıştır [19]. Grafiklerin sunulmasında kullanılan grafik temaları ise “ggthemes” paketinden alınmıştır [20].

COVID-19 ilişkili arama terimlerine bağlı olarak COVID-19 pandemisinin Türkiye’de ve dünyada izlediği seyir ortaya konulmuştur. Ardından ise Türkiye’de ve dünyada öne çıkan COVID-19 ilişkili alt arama terimleri ve Türkiye’de ve dünyadaki COVID-19 arama trendleri ile onaylanmış vakalar arasındaki ilişki verilmiştir.

Google Trendler, terimler arasında karşılaştırma yapmayı kolaylaştırmak için arama verilerini normalleştirir. Arama sonuçları, aşağıdaki işlemle bir sorgunun zamanına ve konumuna göre normalleştirilir: Her veri noktası, görece popülarlığı karşılaştırmak için temsil ettiği coğrafya ve zaman aralığının toplam aramalarına bölünür. Aksi takdirde, en çok arama hacmine sahip yerler her zaman en yüksek sırada yer alırdı. Ortaya çıkan sayılar daha sonra bir konunun tüm konulardaki tüm aramalara oranına bağlı olarak 0 ila 100 aralığında ölçeklenir. Bir terim için aynı arama ilgisini gösteren farklı bölgeler her zaman aynı toplam arama hacimlerine sahip değildir [11].

Türkiye’de ve dünyada COVID-19 ilişkili arama terimindeki hit sayıları ve Türkiye’de ve dünyada COVID-19 onaylanmış vaka sayıları ile COVID-19 ilişkili arama terimindeki hit sayıları arasındaki ilişki düzeyi Pearson korelasyon analizi ile ortaya konulmuştur.

### Bulgular

Bu kısımda ilk olarak yöntem bölümünde belirtilen COVID-19 ilişkili arama terimlerine bağlı olarak COVID-19 pandemisinin Türkiye’de ve dünyada izlediği seyir ortaya konulmuştur. Ardından ise Türkiye’de ve dünyada öne çıkan COVID-19 ilişkili alt arama terimleri ve Türkiye’de ve dünyadaki COVID-19 arama trendleri ile onaylanmış vakalar arasındaki ilişki verilmiştir.

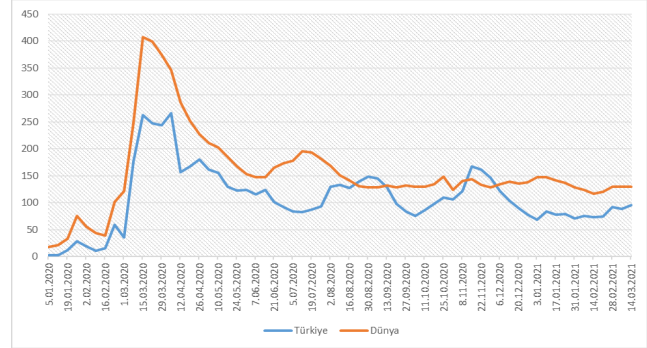
Şekil 1’de COVID-19 ilişkili arama terimlerine dayalı olarak COVID-19 pandemisinin Türkiye’de ve dünyada izlediği seyir ortaya koyulmuştur. Şekil 1’e göre öne çıkan bulgular şöyledir:

- Türkiye’de COVID-19 ilişkili arama terimlerine bağlı olarak en yüksek hit sayısına ulaşılan tarih 5.04.2020 olup, bu tarihte hit sayısı 266’dır. Bu tarihleri sırasıyla 15.03.2020 (n=263), 22.03.2020 (n=243) tarihleri izlemiştir. Diğer taraftan 2021 yılında en yüksek hit sayısına ulaşılan tarih ise 14.03.2021 olup bu tarihte hit sayısı 95’tir.

- Dünyada COVID-19 ilişkili arama terimlerine bağlı olarak en yüksek hit sayısına ulaşıldığı tarih 15.03.2020 olup, bu tarihte hit sayısı 408’dir. Bu tarihleri sırasıyla 22.03.2020 (n=399), 29.03.2020 (n=374) tarihleri izlemiştir. Diğer taraftan 2021 yılında en yüksek hit sayısına ulaşılan tarih ise 3.01.2021 olup bu tarihte hit sayısı 147’dir.


- Elde edilen bulgular bir bütün olarak değerlendirildiğinde 2020 yılının mart ayından sonra COVID-19

ilişkili arama terimindeki hit sayıları nispeten istikrarlı bir şekilde düşüş eğilimi göstermekte ve arama trendlerindeki etkisinin azaldığı görülmektedir. Diğer taraftan Türkiye’de ve dünyada COVID-19 ilişkili arama terimindeki hit sayılarında benzer bir seyir gözlenmiştir.



Şekil 1: Türkiye’de ve Dünyada COVID-19 İlişkili Arama Terimlerine Göre Google Trendleri Veri kaynağı: Google Trends

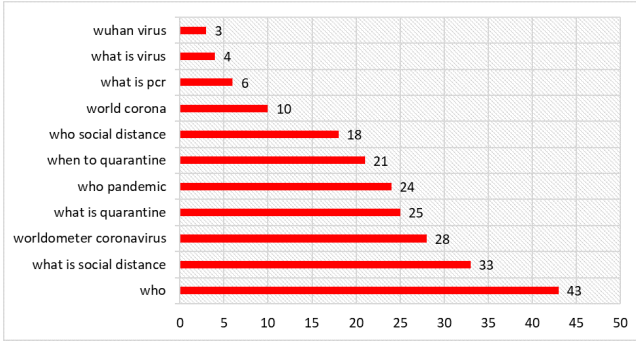
Şekil 1’deki verilerden hareketle Türkiye’de ve dünyada COVID-19 ilişkili arama terimindeki hit sayıları arasındaki ilişki ise Pearson korelasyon analizi ile incelenmiştir. Türkiye (N=63, Ort=108,51, SS=58,13)’deki COVID-19 ilişkili arama terimindeki hit sayıları ve dünya (N=63, Ort=155,56, SS=77,70)daki COVID-19 ilişkili arama terimindeki hit sayıları arasında oldukça çok yüksek düzeyde pozitif yönlü korelasyon bulunmuş olup istatistiksel olarak anlamlıdır ( $p=0.000$ ,  $r=0,878$ ).



Şekil 2. COVID-19 Alt Arama Terimlerine Göre En Yüksek Hit Sayısına Ulaşan Terimler, Türkiye Veri kaynağı: Google Trends

Yöntem kısmında belirtilen arama terimlerine bağlı olarak COVID-19 pandemisinin Türkiye ve dünyada izlediği seyir ortaya konulmuştu. Şimdi ise arama terimlerinin ilişkili olduğu alt arama terimlerine bağlı olarak en yüksek hit sayısına ulaşan 15 alt arama terimi Türkiye özelinde Şekil 2’de verilmiştir. Şekil 2’ye göre alt arama terimlerinde en yüksek hit sayısına ulaşan terim “virüs türkiye” olup, hit sayısı (n) 20’dir. Bu terimi sırasıyla “ykanaanabilir maske” (n=18) ve “virüs sayısı” (n=16) terimleri izlemiştir. Diğer taraftan alt arama terimlerinde en az aranan terim ise “yurtdışı pcr testi” (n=3) olmuştur.

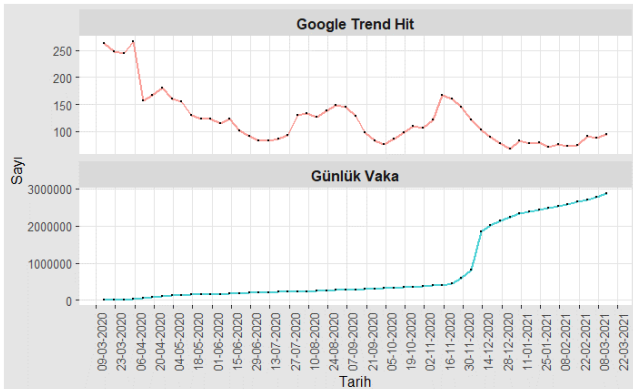




Şekil 3. COVID-19 Alt Arama Terimlerine Göre En Yüksek Hit Sayısına Ulaşan Terimler, Dünya Veri kaynağı: Google Trends


Dünyada arama terimlerinin ilişkili olduğu alt arama terimlerine bağlı olarak en yüksek hit sayısına ulaşan 15 alt arama terimi ise Şekil 3'te verilmiştir. Şekil 3'e göre alt arama terimlerinde en yüksek hit sayısına ulaşan terim "who" olup hit sayısı (n) 43'tür. Bu terimi sırasıyla "what is social distance" (n=33) ve "worldometer coronavirus" (n=28) terimleri izlemiştir. Diğer taraftan alt arama terimlerinde en az aranan terim ise "wuhan virus" (n=3) olmuştur.

HDX web sitesinden 11.04.2021 tarihinde alınan günlük COVID-19 onaylanmış vaka sayıları ile Google Trend COVID-19 ilişkili arama terimlerine dayalı olarak COVID-19 pandemisinin Türkiye'de izlediği seyir ise Şekil 4'te karşılaştırmalı olarak verilmiştir. Şekil 4'te zaman serilerine göre karşılaştırma yapılabilmesi adına baz alınan tarih aralıkları ise 15.03.2020 ile 14.03.2021 tarihleri arasındır. Bunun nedeni HDX veri tabanından alınan onaylanmış vaka veri setinde Türkiye için zaman serilerinin 15.03.2020 tarihinden itibaren başlamasıdır. Şekil 4'te ortaya konulan bulgulara bakıldığında Türkiye'deki Google Trend hit sayıları ile günlük onaylanmış vaka sayılarının izlediği trendin birbiriyle örtüşmediği ve doğrusal bir seyir izlemediği görül-müştür.



Şekil 4. Türkiye'de COVID-19 İlişkili Arama Terimlerine Göre Google Trendleri ile Onaylanmış Vaka Sayıları Veri Kaynağı: HDX ve Google Trends

Şekil 4'teki verilerden hareketle Türkiye'deki COVID-19 ilişkili Google Trend hit sayıları ile günlük onaylanmış COVID-19 vaka sayıları arasındaki ilişki de Pearson korelasyon analizi ile ortaya konulmuştur. Türkiye'deki COVID-19 ilişkili Google Trend hit sayıları (N=53, Ort= 122,13, SS= 48,62) ve günlük onaylanmış COVID-19 vaka sayıları (N=53, Ort= 820535,21, SS= 992965,38) arasında



Şekil 5. Dünyada COVID-19 İlişkili Arama Terimlerine Göre Google Trendleri ile Onaylanmış Vaka Sayıları Veri Kaynağı: HDX ve Google Trends

orta düzeyde negatif yönlü korelasyon bulunmuş olup istatistiksel anlamlıdır (p=0,000, r=- 0,544).

HDX web sitesinden 11.04.2021 tarihinde alınan günlük COVID-19 onaylanmış vaka sayıları ile Google Trend COVID-19 ilişkili arama terimlerine dayalı olarak COVID-19 pandemisinin dünyada izlediği seyir ise Şekil 5'te karşılaştırmalı olarak verilmiştir. Şekil 5'te zaman serilerine göre karşılaştırma yapılabilmesi adına baz alınan tarih aralıkları ise 26.01.2020 ile 14.03.2021 tarihleri arasındır. Bunun nedeni HDX veri tabanından alınan onaylanmış vaka veri setinde dünya için zaman serilerinin 26.01.2020 tarihinden itibaren başlamasıdır. Şekil 5'e göre ortaya konulan bulgulardan Google Trend Hit sayıları ile günlük onaylanmış vaka sayılarının izlediği trendin birbiriyle örtüşmediği, Google Trend Hit sayılarının izlediği dalgalı seyrin aksine günlük onaylanmış vaka sayılarının doğrusal bir seyir izlediği anlaşılmaktadır.

Şekil 5'teki verilerden hareketle dünyadaki COVID-19 ilişkili Google Trend hit sayıları ile günlük onaylanmış COVID-19 vaka sayıları arasındaki ilişki de Pearson korelasyon analizi ile incelenmiştir. Dünyadaki COVID-19 ilişkili Google Trend hit sayıları (N=60, Ort= 162,13, SS= 73,60) ve günlük onaylanmış COVID-19 vaka sayıları (N=60, Ort=38938473,65, SS=38938473,65) arasında zayıf düzeyde negatif yönlü korelasyon bulunmuş olup, istatistiksel anlamlıdır (p=0,007, r=-0,343).

### Tartışma ve Sonuç

Bu çalışmada belirlenen arama terimlerine bağlı olarak Google Trendler üzerinden bilgi arama davranışı kalıpları ile onaylanmış koronavirus vakaları ve bilgi arama davranışı kalıpları arasındaki ilişkiyi ortaya koymaya yönelik keşifsel veri analizi yapılmıştır. Şekil 1'de ortaya konulan Google Trends bulguları birlikte değerlendirildiğinde özellikle Türkiye ve dünya vakalarının Google Trends COVID-19 ilişkili arama terimlerinde en yüksek hit sayılarının meydana geldiği ay mart ayıdır. Türkiye'de ve dünyada COVID-19 ilişkili arama terimlerinde hit sayılarında benzer bir seyir olduğu da görülmüştür. Nitekim Şekil 1'deki verilerden hareketle ortaya konulan Pearson korelasyon analizi bulguları da Türkiye'deki COVID-19 ilişkili arama

terimlerdeki hit sayıları ve dünyadaki COVID-19 ilişkili arama terimlerdeki hit sayıları arasında oldukça çok yüksek düzeyde pozitif yönlü korelasyon olduğunu göstermiş-tir. Ancak arama terimlerine göre hit sayılarındaki dalgalanmalar her iki vakada benzer olsa da Türkiye 'deki dalgalanmalar dünyadaki vakalara göre nispeten daha fazladır. Diğer taraftan her iki vakada da 2020 yılının mart ayından sonra COVID-19 ilişkili arama terimlerdeki hit sayıları nispeten istikrarlı bir şekilde düşüş eğilimi göstermekte ve arama trendlerindeki etkisinin azaldığı görülmektedir. Bunun nedeni, pandeminin ilk çeyreğinde olması ve kamuoyunun salgın hakkında yeterli düzeyde bilgisi olmamasının kamuoyunu Google üzerinde salgın hakkında arama yapmaya itmesi olduğu düşünülmektedir. Bu durum COVID-19 ilişkili arama terimlerdeki hit sayılarının mart ayındaki en yüksek seviyesine ulaşmasını açıklayabilir. Ancak mart ayından sonraki tarihlerdeki azalışlar ise salgının dünyada tamamen bilinir hale gele gelmesinden dolayı arama-lardaki azalışlara bağlanabilir.

Şekil 2 ve Şekil 3'te ortaya konulan Google Trends ilişkili alt arama terimleri bulguları birlikte değerlendirildiğinde ise öne çıkan arama terimleri açısından farklılıklar öne çıkmaktadır. Şekil 2'de özellikle "yıkabilir maske" arama teriminin Türkiye özelinde öne çıkması aslında salgınla birlikte ekonomik alım gücü gibi ekonomik kaygıları akla getirmektedir. Şekil 3 ise dünya kamuoyunun ilişkili alt terimleri arasında "who" terimini 1. sırada aramada ise salgınla ilgili olarak DSÖ'ye güvenildiğini ve oradan bilgi alınmak istendiğini göstermektedir.

Diğer taraftan Şekil 4 ve Şekil 5'te ortaya konulan Türkiye ve dünya Google Trends bulguları birlikte değerlendirildiğinde ise günlük onaylanmış vaka sayılarının Google Trend hit sayıları ile benzer bir seyir göstermediği, Google Trend hit sayılarının izlediği dalgalı seyrin aksine günlük onaylanmış vaka sayılarının doğrusal bir seyir izlediği görülmektedir. Bu durumunun COVID-19 pandemisinin genel olarak dünyada ilk kez görülmesine bağlı olarak Google üzerinden yapılan genel kamuoyu aramalarının açıklanan günlük onaylanmış vaka sayılarından önce Google Trend hit sayılarına yansımından kaynaklandığı düşünülmektedir. Bu durum özellikle COVID-19 salgınının dünyada gündeme oturmaya başladığı 2020 yılının 1. çeyreğinde ortaya çıktığı, sonraki tarihlerde ise günlük onaylanmış vaka sayıları ile ters orantılı olduğu görülmüştür. Bu durum, Şekil 4 ve Şekil 5 verilerinden hareketle aralarında çok güçlü ilişki olmasa da Pearson korelasyon analizi ile ortaya konulan negatif ilişki katsayı (r) bulgularını destekler mahiyettedir.

Bu kısımda bulguların tamamı birlikte ele alındığında bilgi arama davranışının keşfedilmesinde Google Trends analizi bulgularının bilgi veya farkındalığın ölçülmesinde vekil ölçü olarak kullanılabilir. Ancak Google Trendler, mutlak sayıda arama sağlamadığı için verilerdeki korelasyonların ve ilişkilerin karşılaştırmalı istatistiksel analizini zorlaştırabilir. Verilerdeki eğilimler yararlı olsa da bilgi arama davranışı doğrudan istatistiki tablo verileriyle

ilişkilendirilemez [7]. Google Trends verilerinin yanında başta Twitter, Facebook olmak üzere diğer sosyal medya gibi çeşitli kaynaklardan gelen epidemiyolojik bulgular epidemiyolojide değerli veri kaynaklarıdır. COVID-19'un gerçek zamanlı izlenerek bu tür veri kaynaklardan ön bulguların kullanılması ve yeni yaklaşımların geliştirilmesi çok önemlidir [10].

Bu kısıtlara rağmen Google Trends, COVID-19 hakkında kolayca erişilebilir ve doğru çevrimiçi bilgi kaynakları sağlamak ve bireyleri verimli internet arama teknikleri hakkında eğitmek, bilgiyi aramayı, yönetmeyi ve kullanmayı optimize edebilir. Dahası, bilgi arama davranışını anlamak, sağlık kuruluşlarını, savunuculuk gruplarını ve sağlık profesyonellerini halk sağlığı bilgi ihtiyaçları ve özellikle web tabanlı ortamlarda eğitim ve danışmanlığa uygun odak, içerik ve yaklaşım konusunda karar vericileri bilgilendirebilir. Web sorgularının izlenmesi, halk sağlığı sorunlarının ve bilgi ihtiyaçlarının belirlenmesi için etkili, hızlı ulaşılabilen ve aynı zamanda maliyet-etkili bir kaynaktır ve halk sağlığı müdahale politikalarında yol gösterici rol oynayabilir. Halk sağlığı kuruluşları da bu bilgileri ilgili çevrimiçi sağlık kaynaklarının doğruluğunu ve erişilebilirliğini iyileştirmek için kullanabilir. Diğer taraftan araştırmacıların, uygulayıcıların ve politika yapımcıların halk sağlığı ile ilgili bilgi arayışını ve bunun bilgi, kaygı veya hasta-hizmet sunucu iletişim uygulamalarındaki değişiklikler gibi klinik olarak anlamlı sonuçlar üzerindeki etkisini ölçmek için Google Trendler'i nasıl kullanabileceklerini anlamak için ilave araştırmalara ihtiyaç bulunmaktadır [7, 12].

**Çıkar çatışması:** yok

**Finansal destek:** yok

## KAYNAKLAR

1. DSÖ COVID-19 Zaman Akışı. (2019). Dünya Sağlık Örgütü (DSÖ).  
<https://www.who.int/news/item/27-04-2020-who-timeline---COVID-19>. Ulaşım Tarihi: 14.04.2021.
2. Dünya Sağlık Örgütü (DSÖ). 13 Nisan 2021 Tarihli Durum Raporu  
[https://www.who.int/docs/default-source/coronaviruse/situation-reports/20210413-weekly-epi-update-35.pdf?sfvrsn=ce70cdf5\\_4&download=true](https://www.who.int/docs/default-source/coronaviruse/situation-reports/20210413-weekly-epi-update-35.pdf?sfvrsn=ce70cdf5_4&download=true). Ulaşım Tarihi: 14.04.2021.
3. M.J. Khoury, J.P. Ioannidis Big data meets public health Science, 346 (2014), pp. 1054-1055.
4. J. Liu, J. Li, W. Li, J. Wu . Rethinking big data: a review on the data quality and usage issues ISPRS J. Photogramm. Remote Sens., 115 (2016), pp. 134-142.
5. Jun, Seung-Pyo & Yoo, Hyoung Sun & Choi, San, 2018. "Ten years of research change using Google Trends: From the perspective of big data utilizations and applications," Technological Forecasting and Social Change, Elsevier, vol. 130(C), pages 69-87.
6. Mavragani, A., Ochoa, G., & Tsagarakis, K. P. (2018). Assessing the Methods, Tools, and Statistical Approaches in Google Trends Research: Systematic Review. Journal of medical Internet research, 20(11), e270. <https://doi.org/10.2196/jmir.9366>.
7. Fazeli Dehkordy S, Carlos RC, Hall KS, Dalton VK. Novel data sources for women's health research: mapping breast screening online information seeking through Google trends. Acad Radiol. 2014 Sep;21(9):1172-6. doi: 10.1016/j.acra.2014.05.005. Epub 2014 Jul 4. PMID: 24998689; PMCID: PMC4399798.
8. Brigo F, Trinka E. Google search behavior for status epilepticus. Epilepsy Behav. 2015 Aug;49:146-9. doi: 10.1016/j.yebeh.2015.02.029. Epub 2015 Apr 11. PMID: 25873438.
9. Schootman M, Toor A, Cavazos-Rehg P, et al. The utility of Google Trends data to examine interest in cancer screening. BMJ Open 2015;5:e006678. doi:10.1136/bmjopen-2014-006678.
10. Mavragani, A., Gkillas, K. COVID-19 predictability in the United States using Google Trends time series. Sci Rep 10, 20693 (2020). <https://doi.org/10.1038/s41598-020-77275-9>.
11. Google Trends 2021,  
<https://www.google.com/trends>.
12. Li C, Chen LJ, Chen X, Zhang M, Pang CP, Chen H. Retrospective analysis of the possibility of predicting the COVID-19 outbreak from Internet searches and social media data, China, 2020. Euro Surveill. 2020 Mar;25(10):2000199. DOI: 10.2807/1560-7917.ES.2020.25.10.2000199. PMID: 32183935; PMCID: PMC7078825.
13. Effenberger M, Kronbichler A, Shin JI, Mayer G, Tilg H, Perco P. Association of the COVID-19 pandemic with Internet Search Volumes: A Google Trends™ Analysis. Int J Infect Dis. 2020 Jun;95:192-197. doi: 10.1016/j.ijid.2020.04.033. Epub 2020 Apr 17. PMID: 32305520; PMCID: PMC7162745.
14. Hong YR, Lawrence J, Williams D Jr, Mainous III A. Population-Level Interest and Telehealth Capacity of US Hospitals in Response to COVID-19: Cross-Sectional Analysis of Google Search and National Hospital Survey Data. JMIR Public Health Surveill. 2020 Apr 7;6(2):e18961. doi: 10.2196/18961. PMID: 32250963; PMCID: PMC7141249.
15. United Nations Office for the Coordination of Humanitarian Affairs (OCHA), The Humanitarian Data Exchange (HDX). URL: <https://data.humdata.org/dataset/novel-coronavirus-2019-ncov-cases>. Access Date: April 11, 2021.
16. Microsoft Corporation. (2018). Microsoft Excel. Retrieved from <https://office.microsoft.com/excel>.
17. R Core Team (2021). R: A language and environment for statistical computing. R Foundation for Statistical Computing, Vienna, Austria. URL <https://www.R-project.org/>.
18. Philippe Massicotte and Dirk Eddelbuettel (2020). gtrendsR: Perform and Display Google Trends Queries. R package version 1.4.7. <https://CRAN.R-project.org/package=gtrendsR>.
19. H. Wickham. ggplot2: Elegant Graphics for Data Analysis. Springer-Verlag New York, 2016.
20. Jeffrey B. Arnold (2021). ggthemes: Extra Themes, Scales and Geoms for 'ggplot2'. R package version 4.2.4. <https://CRAN.R-project.org/package=ggthemes>.

# Akıllı Telefon Kullanarak Yapay Zeka Tabanlı Farenjit Tespiti

## Artificial Intelligence Based Pharyngitis Detection Using Smartphone

Vakkas DOĞAN<sup>1</sup>, Volkan KILIÇ<sup>1</sup>

### Öz

Burun ve ağız boşluğunun arka duvarında oluşan iltihaplanma farenjit olarak tanımlanmaktadır. Son küresel salgınla birlikte solunum semptomları gösteren farenjit gibi hastalıkların ön teşhisinde mobil teknolojilerin kullanımı gittikçe önem kazanmıştır. Bu çalışmada, geliştirdiğimiz Android tabanlı akıllı telefon uygulamasına gömülü yapay zeka algoritması ile çekilen boğaz görüntülerinden farenjitin tespit edilmesi sağlanmıştır. Yapay zeka yöntemlerinden biri olan derin öğrenmenin Android'e gömülebilmesi ile internet bağlantısı olmaksızın hızlı ve yüksek doğrulukla sonuçlar alınabilmektedir. Popüler derin öğrenme yöntemlerinden Inception-v3, MobileNet-v2, Xception, VGG16, VGG19 ve ResNet50 mimarileri farenjit tespitindeki performanslarını değerlendirmek için eğitilmiştir. Çekilen görüntünün ağız içi veya dışı olduğunun tespitinden sonra ağız içi görüntülerinin farenjit tespiti yapılması gerekmektedir. Bu nedenle sıralı olarak çalışan iki sınıflandırıcı tasarlanmıştır. İlk sınıflandırıcılar MSCOCO veri kümesiyle eğitilirken, ikinci sıradaki sınıflandırıcılar çoğaltma yöntemleri ile genişletilen 131 adet farenjit ve 208 adet farenjit olmayan boğaz görüntüsünün olduğu veri kümesiyle eğitilmiştir. Eğitilen mimariler arasında ResNet50 %96.20 doğrulukla en yüksek performansı göstermiştir. Geliştirdiğimiz 'Farenjit Tanımlama' adlı Android uygulamasına ResNet50 mimarisinin gömülmesiyle kullanıcılar pratik bir şekilde ön teşhis yapabilecek, böylelikle salgından kaynaklı sağlık sistemindeki yükün azaltılmasına katkı sağlayacaktır.

**Anahtar Kelimeler:** Farenjit, Derin öğrenme, ResNet50, Android, MSCOCO veri kümesi.

### Abstract

Pharyngitis is defined as inflammation in the back wall of the nose and mouth cavity. Mobile technologies have received an increasing amount of attention in the recent global epidemic due to their advantage in pre-diagnosis of diseases that show respiratory symptoms such as pharyngitis. In this study, we propose a custom-designed Android application that offers pharyngitis detection based on artificial intelligence using throat images. Deep learning, a subset of artificial intelligence, allows being embedded in Android applications which leads to be giving fast and highly accurate results without an internet connection. Popular deep learning architectures including Inception-v3, MobileNet-v2, Xception, VGG16, VGG19 and ResNet50, have been trained to evaluate their performance in pharyngitis detection. Detection of pharyngitis for the images could be performed after they were verified as inner of the mouth. Therefore, two sequential classifiers were designed. The first classifiers were trained with the MSCOCO dataset, while the second-ranked classifiers were trained with the dataset, including 131 pharyngitis and 208 non-pharyngitis throat images augmented with specific methods. Among the above architectures, ResNet50 showed the highest performance with 96.20% accuracy. By embedding the ResNet50 architecture into our custom-designed Android application named 'Farenjit Tanımlama', users will be able to pre-diagnose in a practical way, thus contributing to reducing the burden on the health system caused by the epidemic.

**Keywords:** Pharyngitis, Deep learning, ResNet50, Android, MSCOCO dataset.

Received / Geliş	30.03.2021
Accepted / Kabul	03.08.2021
Publication Date	18.08.2021

\*Sorumlu Yazar  
Corresponding Author

Vakkas DOĞAN  
<sup>1</sup> İzmir Katip Çelebi Üniversitesi,  
Elektrik ve Elektronik Mühendisliği  
Anabilim Dalı,  
İzmir, Türkiye

✉ \*y200207005@ogr.ikcu.edu.tr

<https://orcid.org/0000-0002-3164-1981>

Volkan KILIÇ  
<https://orcid.org/0000-0001-5934-4156>

## GİRİŞ

Uzaktan sağlık hizmetlerinde teşhis desteği, hastaların sağlık hizmeti sağlayıcılarına ve diğer hastalara temas süresini en aza indirme sağlaması açısından önem arz etmektedir (1). Son salgın ile birlikte, üst solunum yolu semptomlarının ön teşhisinde mobil uygulamaların kullanımını teşvik edilmiştir (2). Akıllı telefonların kullanımının yaygınlaşmasıyla sağlık alanında kullanılabilecek uygulamaların sayısında artış gözlemlenmiştir. Bu uygulamaların yapay zeka ile desteklenmesiyle uygulama performanslarında kayda değer bir ilerleme sağlanmıştır. Özellikle akıllı telefon kamerasından elde edilen görüntülerin yapay zeka yöntemleriyle işlenmesiyle basit seviyedeki hastalıkların otomatik teşhisi yapılabileceği gibi, uzman doktorların teşhis süresini kısaltacak önemli bilgiler sağlanabilmektedir (3). Bu uygulamaya örnek olarak farenjit gibi üst solunum semptomları gösteren hastalıklar gösterilebilir.

Dünyada her yıl milyonlarca insana hastalık teşhisi konulan farenjit, akut üst solunum yolu enfeksiyonu ile ilişkili yaygın bir durumdur (4). Farenjit, boğazın arkasındaki bademciklerin iltihaplanması ile belirti göstermektedir ve şiddetle boğaz ağrısı şikayetiyle kliniklere başvuru yapılmaktadır (5). Akut farenjitin en yaygın nedeni kendi kendini sınırlayan viral enfeksiyondur. Bununla birlikte, Streptococcus pyogenes bakteriyel enfeksiyözün farenjitin başlıca nedeni ve vakalarının yaklaşık %20-30'unun nedeni (6). Eksüdatif tonsillit ile ateş gibi immün aracılı ve enfeksiyon sonrası komplikasyonlara neden olabilen streptokokal farenjit birbirleriyle bağlantılıdır (7). Bununla birlikte, üst solunum yolu enfeksiyonu olan birçok hasta erken dönemde hastalık etkeni içeren semptomlarını görmezden gelir ve rutin tıbbi ziyaretler gerçekleşmemiş olur (8). Son küresel salgın ile birlikte hastaların klinikleri ziyaret etmelerindeki oranın düşüşü bu gerçeği gözler önüne sermektedir. Birçok hasta çözümü, tıbbi destek almadan kendi imkanlarıyla halledebilme yoluna başvurmuş ve akıllı telefon tabanlı bir izleme sisteminin önemi, uygulanabilirliği ve etkinliği bu nedenle artmıştır (9).

Akıllı telefonlardaki son teknolojik gelişmeler yapay zeka destekli algoritmaların çalışmasına olanak sağlamıştır. Yapay zeka alanında kullanılan derin öğrenme tabanlı akıllı telefon uygulamaları son zamanlarda gittikçe artan bir ilgi görmektedir (10, 11). Bir çalışmada akıllı telefona uyumlu bir ekipman ile boğazdaki streptokokal bademcik görüntüleri k en yakın komşu algoritması (kNN) ile sınıflandırılmıştır (12). Başka bir çalışmada ise derin öğrenme mimarilerinden ResNet50 kullanılmıştır. Yapılan çalışma incelendiğinde sadece ağız içi görüntülerden oluşan, kullanıcının farenjit ya da farenjit olmayan diye sınıflandıran bir sistem önerilmiştir (13). Akıllı telefon ile çekilen görüntüler internet bağlantısıyla bulut sistemi üzerinden sunucuya iletilerek farenjit tespiti yapılmaktadır. Yapılan başka bir çalışmada, farenjit teşhisine yardımcı olmak için sinir ağla-

ından faydalanılmıştır (14). 240 hastanın tıbbi kayıtlarında bulunan otuz sekiz değişken ile beslenen sinir ağı, vakaların %95.4'ünde farenjiti doğru şekilde teşhis etmiştir.


Önerilen çalışmanın diğer çalışmalardan farklı olarak, çekilen görüntüler ilk olarak ağız içi ve ağız içi değil diye sınıflandırılmaktadır. Eğer görüntü ağız içi ise farenjit ve farenjit olmayan diye ikinci bir sınıflandırma yapılmaktadır. Görüntü ağız içine ait değilse kullanıcıya ağızınızın resmini çekmelisiniz diye geri dönüşte bulunulmaktadır. Bununla beraber eğitilen derin öğrenme mimarisi mobil uygulamaya gömülerek internet olmaksızın çalışabilmesi sağlanmıştır. Bu çalışmada, boğaz görüntülerinden farenjiti internet bağlantısına ihtiyaç duymadan derin öğrenme yöntemiyle tespit edebilen kullanıcı dostu bir akıllı telefon uygulaması geliştirilmiştir.

Bu yazının geri kalanı aşağıdaki şekilde düzenlenmiştir: Bölüm 2, veri toplama, veri çoğaltma, çalışmada önerilen derin öğrenme mimarisini ve akıllı telefon uygulamasını açıklamaktadır. Bölüm 3'te önerilen yöntemden elde edilen deneysel sonuçlar açıklanmıştır ve son olarak Bölüm 4'te sonuçlara yer verilmiştir.

## GEREÇ ve YÖNTEM

### Veri kümesi ve veri çoğaltma

Derin öğrenme yöntemlerinin başarısında veri kümesinin doğrudan etkisi bulunmaktadır. Veri kümesinin genişliği, eğitimdeki başarı oranını artırmaktadır. Bu çalışmada, gelen görüntülerin ağız içine ait olduğunu tespit eden ve daha sonrasında farenjit tespiti yapan iki sınıflandırıcı kullanıldığından, her bir sınıflandırıcı için ayrı veri kümeleri kullanılması gerekmektedir. İlk sınıflandırıcı için içerisinde 118273 adet görüntünün olduğu MSCOCO (Microsoft Common in Context) (15) veri kümesi kullanılmıştır. MSCOCO veri kümesinde 110000 adet görüntü eğitim aşamasında ve 8273 adet görüntü ise test aşamasında kullanılmıştır. İkinci sınıflandırıcı için kullanılan veri kümesi, internetten erişimi herkese açık olan 131 adet farenjit ve 208 adet farenjit olmayan görüntülerden oluşmaktadır (16). Projede kullanılan veri kümesindeki görüntülerden örnekler verilmektedir (Şekil 1). İkinci veri kümesinde kullanılan görüntü sayısının az olması, farenjit ile farenjit olmayan görüntü sayılarındaki eşitsizlik nedeniyle veri çoğaltma işlemi uygulanmıştır. Veri çoğaltma işlemi yapılmadan önce elde bulunan veri kümesi ile derin öğrenme mimarileri eğitilmiştir. Eğitim sırasında toplam 339 adet boğaz görüntüsünden 271 adet boğaz görüntüsü eğitim için kullanılırken test veri kümesi 68 adet boğaz görüntüsüne sahiptir.



Şekil 1: Çalışmada kullanılan veri kümelerinden örnekler (a) farenjit olmayan, (b) farenjit, (c) MSCOCO

Ağız içi görüntülerinde farenjit tespiti yapabilmek için kullanılan veri kümesindeki görüntü sayısının yetersizliği derin öğrenme mimarilerinin sınıflandırma performanslarını olumsuz yönde etkilemiştir. Bunun önüne geçebilmek için, çevirme, döndürme ve parlaklık değişimi gibi temel veri çoğaltma teknikleri ile veri kümesindeki görüntüler artırılmıştır (17). Derin öğrenme mimarisini eğitmeden önce, veri kümesi, sol ve sağ çevirme, %7'den +%7'e genişlik ve yükseklik çevirme, 15°'den 15°'ye rastgele dönüş, %0'dan %15'ye rastgele yakınlaştırma dahil olmak üzere doğrusal dönüşüm kullanılarak artırıldı. Böylelikle, eğitim kümesi için 10000 adet farenjit ve 10000 adet farenjit olmayan boğaz görüntüsü oluşturuldu ve eğitilen mimari, 500 adet farenjit ve 500 adet farenjit olmayan boğaz görüntüsü ile test edilmiştir.

### Önerilen derin öğrenme mimarisi

Veri çoğaltmanın ardından derin öğrenme mimarilerini eğitme aşamasına geçilmiştir. Bu çalışmada, özel derin öğrenme mimarisi tasarlanmanın zaman alıcı olması (18) nedeniyle, yaygın derin öğrenme mimarilerinden faydalanılmıştır (19, 20). Bu mimariler, ResNet50, Inception-v3, MobileNet-v2, Xception, VGG16 ve VGG19'u kapsamaktadır. Bu mimarilerin seçiminde benzer çalışmalarda daha önce kullanılmış ve yüksek performans göstermeleri etkili olmuştur (21-24). İki sınıflandırıcı içinde aynı mimarilerden faydalanılmıştır. Ön eğitilmiş olarak indirilen mimariler, eğitim kümesiyle tekrar eğitilmiş olup, doğrulama kümesiyle de eğitimin performansı test edilmiştir.

Mimariler, 180 devir (epoch) ve 20'lik bir batch size ile eğitildi. 0.0001 öğrenme oranına (learning rate) sahip ADAM iyileştiricisi (optimizer) ve çapraz entropi kaybı (cross-entropy) kullanılmıştır.

Derin öğrenme mimarilerinin performansı, alıcı çalışma karakteristik eğrisinin (Receiver Operating Characteristic Curve-ROC) ve hassasiyet-geri çağırma eğrisinin (Precision-Recall Curve-PRC) altındaki alana (Area Under the Curve-AUC) ve doğruluğuna dayalı olarak değerlendirilmiştir. Optimal tanı eşliğinin bir tahmini olan Youden indeksi de kullanılmıştır. Duyarlılık ve özgüllük elde edildikten sonra, Youden indeksi her kesme noktasında hesaplanmıştır. Youden indeksini maksimize eden optimum değer seçilmiştir. Kullanılan performans metrik ve indeksleri aşağıdaki şekilde ifade edilir:

TP, TN, FP ve FN sırasıyla gerçek pozitifleri, gerçek negatifleri, yanlış pozitifliği ve yanlış negatifleri ifade etmektedir. Tanımlanan performans metrik ve indeks değerlerine göre kullanılan altı mimari arasından ResNet50 en iyi performansı göstermiştir.

Doğruluk (Accuracy)	[1]
Duyarlılık (Sensitivity)	[2]
Özgüllük (Specificity)	[3]
Hassas (Precision)	[4]
Youden İndeks	[5]

### Akıllı telefon uygulaması: farenjit tanımlama

Bu çalışmada, boğaz görüntülerinden farenjit teşhisini yapay zeka destekli yapabilen Android uygulaması geliştirilmiştir. Kullanıcıların testlerini uygulama üzerinden erişebileceği akıllı telefon kamerası ile yapabilmesi için kolay ve kullanıcı dostu bir arayüz tasarlanmıştır.


Tasarım, Android Studio programı kullanılarak yapılmıştır. Android Studio, Google tarafından önerilen ve birçok üst düzey özelliğe sahip bir programlama aracıdır (25). Uygulamanın internet gereksinimi olmadan çalışabilmesi derin öğrenme mimarisinin uygulamanın içerisine gömülmesi gerekmektedir. Bu amaçla Firebase MLKit ve TensorFlow-Lite (Tf-lite) kullanılmıştır. Firebase MLKit, mobil geliştiricilerin uygulamalarına makine öğrenme yeteneklerini eklemelerini kolaylaştıran mobil bir SDK'dır (Software Development Kit-Yazılım Geliştirme Kiti) (26). Tf-lite ise TensorFlow modellerinin mobil cihazlarda, gömülü sistemlerde ve IoT (Internet of Things-Nesnelerin İnterneti) cihazlarda daha verimli çalıştırılması için özelleştirilmiş bir araç setidir (27).

'Farenjit Tanımlama' olarak adlandırılan uygulamanın ana sayfası Farenjit Nedir, Uygulama Nasıl Çalışır ve Test İşlemleri başlıklarından oluşmaktadır. Mobil uygulamanın ana ekranı gösterilmektedir (Şekil 2a). Uygulamaya giriş yapıldığında kullanıcıyı "Farenjit Nedir?" ve "Uygulama Nasıl Çalışır?" adlı iki ana başlık karşılamaktadır. "Farenjit Nedir" başlığına giriş yapıldığında bu başlık kullanıcıyı farenjit ile ilgili bilgi veren sitelere yönlendirmektedir (Şekil 2b). Ek olarak "Uygulama Nasıl Çalışır?" başlığına giriş yapıldığında ise uygulamanın çalışma prensibi üzerine



Şekil 2: Farenjit Tanımlama uygulaması ekran görüntüleri. (a) uygulama ana ekranı, (b) farenjit bilgi ekranı, (c) uygulama nasıl kullanılır ekranı, (d) eklenen resmin ağız içi olmaması örneği, (e) farenjit olmayan kullanıcı örneği, (f) farenjit kullanıcı örneği

kullanıcılara bilgi verilmektedir (Şekil 2c). Ana sayfanın sağ taraf alt kısımda “Haydi Başlayalım” butonuna basıldığında uygulamanın test yaptığı bölüme giriş yapılmaktadır (Şekil 2a). Uygulamaya galeri kısmından görüntü yüklenildiği gibi telefonun kamera özelliği kullanılarak da anlık görüntü alınabilmektedir. Görüntüleri kırpma özelliği sayesinde gereksiz kısımlar görüntüden çıkarılabilmektedir. Galeriden yüklenen ya da kamera kullanılarak çekilen görüntünün ağız içi/ağız içi değil kontrolü yapıldığı bir örnek gösterilmektedir (Şekil 2d). Farenjit olmayan bir görüntü yüklendiğinde alınan sonuç gösterilmektedir (Şekil 2f). Son olarak farenjit olan bir resim yüklendiğinde alınan sonuç gösterilmektedir (Şekil 2e). Kullanıcıya gerekli durumlarda bilgilendirme yapılabilmektedir.



Şekil 3: Farenjit tespiti için ResNet50 derin öğrenme mimarisi eğitimsüreci. (a) Eğitim ve doğrulama kümelerinin doğruluk öğrenme eğrileri. (b) Eğitim ve doğrulama kümelerinin kayıp öğrenme eğrileri.

## BULGULAR

### Deneysel sonuçlar ve tartışma

İkili sınıflandırma işlemi yapılarak sonuçlar alınmaya çalışılmıştır. İlk sınıflandırma olarak MSCOCO veri kümesi kullanılmıştır. Bu veri kümesi ile ResNet50 %98 doğruluk değeri alınmıştır. Bu veri kümesi içerisinde ağız içi ile ilgili görüntü olmamasına dikkat edilmiştir. Daha sonraki aşamada farenjit tespiti yapacak derin öğrenme mimarileri ilk olarak çoğaltma işlemi yapılmayan orjinal veri kümesi ile eğitildi. Eğitim esnasında 271 adet boğaz görüntüsü eğitim aşamasında ve 68 adet boğaz görüntüsü ise test aşamasında kullanılmıştır. Elde edilen sonuçlar performans metrikleri ile analiz edildiğinde başarı yüzdelерinin düşük olduğu gözlemlenmiştir. Bundan dolayı veri kümesi çoğaltma işlemi yapılmıştır ve derin öğrenme mimarileri tekrardan eğitilmiştir. Optimal tanı eşiği değerinde, ResNet50 modeli farenjiti %96.2 doğruluk, %91.3 duyarlılık ve %95.1

özgüllük ile öngördü. Derin öğrenme mimarilerinin tüm veri kümesinde 4 kat çapraz doğrulama yoluyla performansını göstermektedir (Tablo 1).

	Doğruluk Değeri (%) (Accuracy)	Hassaslık (%) (Sensitivity)	Özgüllük (%) (Specificity)
Inception -v3	89.2	86.2	91.3
MobileNet -v2	87.6	84.6	89.4
VGG16	84.2	89.1	85.2
VGG19	71.7	77.2	74.4
Xception -v1	90.1	92.7	91.7
ResNet50	96.2	91.3	95.1

Tablo 1: Farenjit tespiti için mimarilerin sınıflandırma performansı


Eğitilen mimarilerin performansları karşılaştırıldığında ResNet50 mimarisi ile en yüksek doğrulama doğruluğu elde edilmiştir. Diğer eğitilen mimariler incelendiğinde Xception-v1 90.1%, Inception-v3 89.2%, MobileNet-v2 87.6%, VGG16 84.2% ve VGG19 71.7% doğruluk değerlerine sahip oldukları gözlemlenmiştir. Bu sonuçlardan dolayı ResNet50 mimarisi kullanılması kararına varılmıştır. Eğitim ve doğrulama kümelerini kullanan derin öğrenme mimarisi olan ResNet50'nin eğitim sürecini göstermektedir (Şekil 3). ResNet50 için eğitim süreci, her eğitim adımı için gerekli ortamlar oluşturularak 1000 devir boyunca yaklaşık 9 saat sürdü. 180. devirden sonra, doğrulama doğruluğu geliştirilmesi ve doğrulama sonucunun çapraz entropisi artmıştır. Bu nedenle, 180 devirlik eğitimin ResNet50 modelinde 0.1 kayıp değerine ulaşması ve bu değer ilerleyen devirler sonucunda sabite yakın bir yol izlemesi 180. devirde eğitilmiş modeli seçmekte etkili olmuştur.

Daha önce yapılan farenjit ile ilgili bir çalışmada (13) veri çoğaltma işlemi yapılmadan ResNet50 ile %92.5 doğruluk değeri elde edilirken GAN (Generative Adversarial Network) yöntemi veri çoğaltma işlemi yapıldıktan sonra doğruluk değeri %95.3 olmuştur. Bizim çalışmamızda ise veri çoğaltma işlemi yapıldıktan sonra doğruluk değeri %96.2 olarak elde edilmiştir. Bir diğer konu ise önerilen mimari bulut sistemleri ile internet gereksinimi duyularak yapılmıştır. Eğitilen derin öğrenme mimarisi bu çalışmada internet gereksinimi olmadan Android içine entegre edilmiştir. Ek olarak bu çalışmada (13) tek sınıflandırma işlemi yapılmakta ve yüklenen ya da çekilen görüntünün ağız içi/değil durumu göz önüne alınmamıştır.

Elde edilen sonuçlar mobil uygulama ile test edildiğinde başarılı sonuçlar sağlanmıştır (Şekil 2). Çeşitli görüntüler galeriden yüklenerek ve telefon kamera-sından çekilerek test etme aşaması tekrarlanarak yapılan çalışmanın doğruluğu kontrol edilmiştir. Yapılan çalışmadaki iş akışı gösterilmektedir (Şekil 4).

Bu çalışmada karşılaşılan bazı sınırlamalar vardır. İlk olarak, derin öğrenme mimarimiz düşük çözünürlüklü görüntüleri analiz etmek durumunda kalmıştır. Görüntü

boyutu veri çoğaltma adımından sonra düzenlenmiştir. Görüntü boyutunun düzenlenmesi, farenjit vakalarının sınıflandırmasını etkileyebilir. Gelecekteki çalışmalarda, daha doğru bir teşhis sağlamak için boğaz görüntüsünün çözünürlüğü iyileştirilmelidir. İkincisi, eğitim ve doğrulama için veri kümeleri sınırlı sayıda boğaz görüntüsü içeriyordu. Erişime açık internet tabanlı kaynaklardan boğaz görüntüleri toplamaya çalışılmasına rağmen, klinik ortamlardan gerçek boğaz görüntüleri veri kümesine dahil edilmemiştir. Bu nedenle, çalışmanın başarı yüzdesini artırmak için daha fazla klinik veri kümesine ihtiyaç duyulmaktadır. Üçüncüsü, internette indirilen farenjit veri kümesi görsel arama motorları aracılığıyla toplanmış olup sadece boğaz resimlerini içermektedir. Bu boğaz resimleri cinsiyet, ırk veya yaş dahil hiçbir metaveri içermiyordu. Önceden yapılan bir çalışmaya göre, bu faktörler farenjit tespit performansında önemli bir etkiye sahiptir (24). Dördüncüsü, veri kümeleri yazarlar tarafından tek tek incelenmesine rağmen, görüntüler veri kümesinde potansiyel olarak kopyalanabilir. Yenilenen görüntüler, doğrulama veri kümesinin bağımsızlığını etkileyecektir. Çalışmanın sınırlamaları, iyi organize edilmiş bir çalışma protokolüne sahip bir akıllı telefonla alınan yeterli sayıda boğaz görüntüsünün bulunması ile aşılmalıdır.



Şekil 4: Akıllı telefon kullanarak farenjit tespiti için derin öğrenme modeli iş akış diyagramı

Yapay zeka tabanlı mobil uygulama ile boğaz görüntüleri kullanılarak farenjit tespiti çalışmasını referans alarak, ilerleyen zamanlarda kulak burun boğaz kliniklerinde bir endoskopi sisteminden (28) görüntüler kullanılarak bilgisayar destekli tanıya genişletilmesi mümkündür. Çalışmanın etkinliğini doğrulamak için, uygulama tabanlı çalışmalar geliştirdikten sonra birçok hasta ile ileriye dönük bir çalışma bir klinikte yapılabilecektir.

## SONUÇ

Bu çalışmada, akıllı telefon kullanarak kullanıcılar tarafından çekilen boğaz görüntüleri ile farenjiti tespit etmek için yapay zekaya dayalı mobil uygulama geliştirildi. Veri çoğaltma ile, derin öğrenme mimarisinin sınıflandırma performansını iyileştirmek için yeni boğaz görüntüleri başarıyla oluşturulmuştur. Eğitilen mimariler arasında ResNet50 %96.20 doğrulukla farenjit tespitini yapabirmiştir. Geliştirilen mobil uygulama, farenjitin hızlı bir şekilde teşhisini sağlamış ve böylelikle oluşabilecek muhtemel komplikasyonları önlemek için zaman kazandırabilecektir. Ayrıca bu çalışma, üst solunum yolu semptomları olan hastaların daha rahat bir şekilde teşhis ve tedavi almalarına yardımcı olacak ve salgın mücadelede pozitif bir katkı sağlayacaktır.

**Çıkar çatışması:** yok

**Finansal destek:** yok

**Yazar katkıları:**

**Motivasyon / Konsept:** VD, VK

**Çalışma Tasarımı:** VD

**Kontrol / Gözetim:** VK

**Veri Toplanması ve / veya İşlemesi:** VD

**Analiz ve / veya Yorum:** VK

**Literatür incelemesi:** VD

**Makalenin Yazılması:** VD, VK

**Eleştirel İnceleme:** VK

## KAYNAKLAR

1. Pappot, N., G. Taarnhøj, and H.J.T.J.H. Pappot, Telemedicine and e-health solutions for COVID-19: patients' perspective [published online April 24, 2020]. Telemed JE Health, DOI: <http://doi.org/10.1089/tmj.2020.0099>.
2. Maurrasse, S.E., et al., Telemedicine during the COVID-19 pandemic: a pediatric otolaryngology perspective. Otolaryngology–Head Neck Surgery (SAGE), 2020. 163(3): p. 480-481 DOI: <https://doi.org/10.1177/0194599820931827>.
3. Celik Ertugrul, D. and A.H.J.E.J. Ulusoy, Development of a knowledge-based medical expert system to infer supportive treatment suggestions for pediatric patients. ETRI Journal, 2019. 41(4): p. 515-527 DOI: <https://doi.org/10.4218/etrij.2018-0428>.
4. Van, T.T., K. Mata, and J.D.J.J.o.c.m. Bard, Automated detection of Streptococcus pyogenes pharyngitis by use of colorex strep A CHROMagar and WASPLab artificial intelligence chromogenic detection module software. Journal of clinical microbiology (JCM) 2019. 57(11) DOI:



- <https://doi.org/10.1128/JCM.00811-19>.
5. Shaikh, N., E. Leonard, and J.M.J.P. Martin, Prevalence of streptococcal pharyngitis and streptococcal carriage in children: a meta-analysis. *Pediatrics (APC)* 2010. 126(3): p. e557-e564 DOI: DOI: <https://doi.org/10.1542/peds.2009-2648>.
6. Rao, A., et al., Diagnosis and antibiotic treatment of group a streptococcal pharyngitis in children in a primary care setting: impact of point-of-care polymerase chain reaction. *BMC pediatrics*, 2019. 19(1): p. 1-8 DOI: <https://doi.org/10.1186/s12887-019-1393-y>.
7. Vazquez, M.N. and J.E.J.P.e.m.p. Sanders, Diagnosis and management of group A streptococcal pharyngitis and associated complications. *Pediatric emergency medicine practice (EB Medicine)* 2017. 14(12): p. 1-20.
8. Norton, L.E., et al., Improving guideline-based streptococcal pharyngitis testing: a quality improvement initiative. *Pediatrics (APC)*, 2018. 142(1) DOI: DOI: <https://doi.org/10.1542/peds.2017-2033>.
9. Mustafa, Z., M.J.F.i.C. Ghaffari, and I. Microbiology, Diagnostic methods, clinical guidelines, and antibiotic treatment for group A streptococcal pharyngitis: a narrative review. *Frontiers in Cellular Infection Microbiology (FCIM)* 2020. 10: p. 644 DOI: <https://doi.org/10.3389/fcimb.2020.563627>.
10. de Haan, K., et al., Automated screening of sickle cells using a smartphone-based microscope and deep learning. *NPJ Digital Medicine*, 2020. 3(1): p. 1-9 DOI: <https://doi.org/10.1038/s41746-020-0282-y>.
11. Zulkifley, M.A., et al., Pterygium-Net: a deep learning approach to pterygium detection and localization. *Multimedia Tools Applications (MTAP)* 2019. 78(24): p. 34563-34584 DOI: <https://doi.org/10.1007/s11042-019-08130-x>.
12. Askarian, B., S.-C. Yoo, and J.W.J.S. Chong, Novel image processing method for detecting strep throat (streptococcal pharyngitis) using smartphone. *Sensors (MDPI)* 2019. 19(15): p. 3307 DOI: <https://doi.org/10.3390/s19153307>.
13. Yoo, T.K., et al., Toward automated severe pharyngitis detection with smartphone camera using deep learning networks. *Computers in Biology Medicine (ELSEVIER)* 2020. 125: p. 103980 DOI: <https://doi.org/10.1016/j.compbiomed.2020.103980>.
14. Zhang, S., et al., A flexible bifunctional sensor based on porous copper nanowire@ IonGel composite films for high-resolution stress/deformation detection. *Journal of Materials Chemistry C* 2020. 8(12): p. 4081-4092 DOI: <https://doi.org/10.1039/C9TC06091J>.
15. MSCOCO veri seti. Available from: <https://content.aigion.com/datasets/coco-ms-coco-dataset>.
16. Pharyngitis Dataset 2020 10-06-2020; Available from: <https://data.mendeley.com/datasets/8ynyhnj2kz/1>.
17. Maeda, H., et al., Road Damage Detection Using Deep Neural Networks with Images Captured Through a Smartphone, arvi preprint. arXiv preprint arxiv:.09454, 2018 DOI: <https://doi.org/10.1111/mice.12387>.
18. Ghiasi, V. and M.J.S.A.S. Koushki, Numerical and artificial neural network analyses of ground surface settlement of tunnel in saturated soil. *SN Applied Sciences*, 2020. 2(5): p. 1-14 DOI: <https://doi.org/10.1007/s42452-020-2742-z>.
19. Minaee, S., et al., Deep-covid: Predicting covid-19 from chest x-ray images using deep transfer learning. *Medical image analysis (MIA)*, 2020. 65: p. 101794 DOI: <https://doi.org/10.1016/j.media.2020.101794>.
20. Yoo, T.K., et al., The possibility of the combination of OCT and fundus images for improving the diagnostic accuracy of deep learning for age-related macular degeneration: a preliminary experiment. *Medical biological engineering computing (MBEC)* 2019. 57(3): p. 677-687 DOI: <https://doi.org/10.1007/s11517-018-1915-z>.
21. Gómez-Flores, W., W.C.J.C.i.B. de Albuquerque Pereira, and Medicine, A comparative study of pre-trained convolutional neural networks for semantic segmentation of breast tumors in ultrasound. *Computers in Biology Medicine (ELSEVIER)*, 2020. 126: p. 104036 DOI: <https://doi.org/10.1016/j.compbiomed.2020.104036>.
22. Kassani, S.H., et al. Diabetic retinopathy classification using a modified xception architecture. in *2019 IEEE International Symposium on Signal Processing and Information Technology (ISSPIT)*. 2019. IEEE DOI: 10.1109/ISSPIT47144.2019.9001846.
23. Malsagov, M.Y., et al., Exponential discretization of weights of neural network connections in pre-trained neural networks. *Optical Memory Neural Networks (OMNN)*, 2019. 28(4): p. 262-270 DOI: <https://doi.org/10.3103/S1060992X19040106>.
24. Rounds, J., et al. Probing for Artifacts: Detecting Imagenet Model Evasions. in *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops*. 2020.
25. Darwin, I.F., *Android Cookbook: Problems and Solutions for Android Developers*. 2017: " O'Reilly Media, Inc."
26. Sproull, T., D. Shook, and B. Siever. *Machine Learning on the Move: Teaching ML Kit for Firebase in a Mobile Apps Course*. in *Proceedings of the 52nd ACM Technical Symposium on Computer Science Education*. 2021. DOI: <https://doi.org/10.1145/3408877.3432496>.
27. Pienaar, J., *Mlir in tensorflow ecosystem*. 2020.
28. Ribeiro, E., et al., Exploring deep learning and transferlearning for colonic polyp classification. *Computational mathematical methods in medicine (CMMM)* 2016. 2016 DOI: <https://doi.org/10.1155/2016/6584725>.

# Hemşirelik Mesleğinin Geleceği : Robot Hemşireler

*The Future of the Nursing: Robot Nurses*

Emel GÜMÜŞ<sup>1</sup>, Ece Uysal KASAP<sup>1</sup>

## Öz

Teknolojide hızlı değişim tüm sektörlerde olduğu gibi sağlık alanında da devrim yaratmıştır. Yapay zeka teknolojilerinin insan düşüncesinden daha yüksek performans gösterme olasılığı hemşirelik mesleğinde de avantajlarını ve dezavantajlarını düşündürmektedir. Hemşirelik mesleğinin geleceği açısından teknolojiyi anlama ve aktif kullanım önemlidir. Hemşireler rutin ve tekrarlayan işlerini robot teknolojisine devredebilecekler. Bu durum “Robot hemşireler, hemşirelerin yerini alabilir mi?”, “Hemşirelik mesleği son bulur mu?” gibi soruları düşündürmektedir. Hemşireler yapay zeka ve teknolojiye uyum sağladıklarında robot hemşirelerin kullanım kolaylığı ve avantajlarından yararlanacak, hasta ile duygusal bağ kurması gereken bakım gibi karmaşık işlere vakit ayırabilecektir. Robot hemşireler henüz yetkin olmadığı için, insiyatif kullanma ve eleştirel düşünme gibi süreçlerde hemşirelerin yeri daha önemli olacaktır. Robot hemşirelerin kullanımı, robotlar ile birlikte çalışmak ve robotları yönetmek gibi yeni iş kollarına gereksinim sağlayacaktır ve rutin görevlerde iş gücü ihtiyacını azaltacaktır. Bu çalışma, teknolojik gelişmelerin mesleki gelişim sürecindeki etkileri, hemşirelik mesleğinin geleceğinde robot hemşirelerin yeri, robot hemşirelerin sağlık alanında kullanımı, robotlar ile çalışma durumunda dikkat edilmesi gereken güncel bilgilerin derlenmesi amacıyla yapılmıştır

**Anahtar kelimeler:** Sağlıkta robot teknolojileri, robot hemşireler, hemşirelik

## Abstract

The rapid change in technology has revolutionized the field of health, as in all sectors. The possibility of artificial intelligence technologies to show higher performance than human thought also suggests their advantages and disadvantages in the nursing profession. Understanding and active use of technology is important for the future of the nursing profession. Nurses will be able to transfer their routine and repetitive work to robot technology. Can this situation replace robot nurses, nurses? Does the nursing profession end? suggest questions such as. When nurses adapt to artificial intelligence and technology, they will benefit from the ease of use and advantages of robot nurses, and will be able to devote time to complex tasks such as care that must establish an emotional connection with the patient. Since robot nurses are not yet competent, nurses' place will be more important in processes such as taking initiative and critical thinking. The use of robot nurses will require new lines of work, such as working with robots and managing robots, and will reduce the need for workforce for routine tasks. This study was conducted to compile the effects of technological developments on the professional development process, the place of robot nurses in the future of the nursing profession, the use of robot nurses in the field of health, and the current information that should be considered in the case of working with robots.

**Keywords:** Robot technologies in health, robot nurses, nursing

Received / Geliş	18.03.2021
Accepted / Kabul	04.04.2021
Publication Date	18.08.2021

**\*Sorumlu Yazar  
Corresponding Author**

**Emel GÜMÜŞ**  
<sup>1</sup>İstinye Üniversitesi,  
İstanbul, Türkiye

✉ emellgumus@gmail.com

<https://orcid.org/0000-0002-3313-6831>

**Ece Uysal KASAP**

<https://orcid.org/0000-0001-8973-0904>

## Giriş

Yaklaşık 200 yıl önce farklı vücut parçalarını birleştirerek elektriğin gücüyle onu canlandırmaya çalışan Doktor Viktor'un hikayesini anlatan Mary Shelley'nin "Frankenstein" adlı ünlü romanında, insanlığın en eski hayalinin yapay zeka teknolojisinin olduğu görülmektedir. O yıllara göre gerçekleşme ihtimalinin uzak görüldüğü teknolojilerin günümüze zemin hazırladığı düşünülmektedir (1).

Öğrenen bir sistem olan yapay zeka, öğrendiklerini hemen uygulayarak öğrenmediklerine cevap arar ve sürekli gelişir. 1950'li yıllarda hayatımıza girmeye başlayan yapay zeka ile donatılmış teknolojiler ve bu teknolojilerin geliştirdiği robotların insan hayatında nasıl yer alacağı ve insanlığı nasıl etkileyeceği konusunu gündeme getirmiştir (2). Yapay zeka teknolojisini konu alan bilimkurgu yazarları, bu teknolojileri sihirden öte bir güç olarak tanımlamışlardır. Bu gücün ise neler yapabileceğini tahmin etmekte çok zorlandıklarını dile getirmektedirler (3).

Yapay zeka uygulamalarının, önüne geçilemez hızlı gelişimi sayesinde robot teknolojileri de hız kazanmıştır. Sağlıkta insansı robotların varlığı ile beraber Robot Hemşire kavramı ortaya çıkmaya başlamış ve bu bir devrim olarak nitelendirilmiştir (4).

Hemşirelik, kişiler, aileler ve onları oluşturan toplulukların bakımına odaklanan bir meslektir. Hemşirelik mesleğini kim nasıl uygular, görev tanımları nedir? Robot hemşireler insan hemşirelerin yerini alabilir mi? Etik ve yasal açıdan uygun mudur? Hemşirelik mesleğinin geleceği robot hemşireler mi? anlamak önemlidir (4).

Bu derlemenin amacı; insansı robotlarla ilgili konuları, görüşleri ve önermeleri ve teknolojik gelişmelerin profesyonel hemşirelik uygulamaları üzerindeki etkilerini açıklamaktır.

Yapay zekanın hemşire ve sağlık sistemi açısından avantaj ve dezavantajları

Tarih boyunca hemşireler değişimi hızla kabul etmiş ve yeni çalışma yöntemlerine adapte olmuşlardır. Buna rağmen hemşirelik, özellikle teknoloji çevresinde değişime engel olma konusunda bir üne sahiptir. Bu durumun önüne geçilebilmesi için hemşirelerin, uygun teknoloji ve kaynaklar konusundaki yeniliklere ve çalışmalara aktif olarak dahil olmaları gerekir (5).

Hemşirelerin teknolojiyi anlamaları ve nasıl kullanılacağını keşfetmeleri mesleki gelişim açısından oldukça önemlidir. Teknolojik gelişmelerin öğrenilmesi için yoğun çaba gerekir ve teknolojik gelişmeleri daha yakından takip eden, anlayabilen hemşireler daha verimli ve güvenli bir şekilde çözüm yollarına ulaşabileceklerdir (6).

Karmaşık görevleri tamamlama konusundaki yetkinliği sayesinde insanlar diğer canlılardan ayrılır. Bununla birlikte günümüzde insanlardan daha hızlı bir şekilde çok sayıda karmaşık görevi hatasız ve düşük maliyetlerle yapan robotların sayısı giderek artmaktadır. Ayrıca, yakın gelecekte

robotların insan yetkinliğine göre yapamayacakları işlerin sayısı giderek azalacaktır (7).

Uzmanlar tarafından makine zekası, entelektüel görevlerde insanlardan daha iyi performans gösteren zeka olarak tanımlanmaktadır. İnsanlardan daha iyi performans gösteren bir makineye sahip olduğunuzda, insanların önemsiz hale gelebileceği yönünde çıkarımlar vardır. Yapay zeka teknolojilerinin insan düşüncesinden daha yüksek performans gösterme olasılığı tüm mesleklerde olduğu gibi hemşirelik mesleğinde de tehdit olarak görülebilmektedir (8).

Hemşireler sağlık hizmetlerinde önemli bir yere sahiptir ve teknolojik gelişmeler ile ilgili bilgi sahibi olmaları gerekir. Yapay zeka ile rutin işlerde tamamlayıcı rol oynayacak görevlerin neler olabileceği konusunda fikir sahibi olmalıdırlar (8).

## Robot teknolojileri

Robotlar, otonom veya önceden programlanmış görevleri yerine getirebilen elektro-mekanik cihazlardır. Algılama yetenekleri vardır ve programlanabilirler. Ayrıca robotlar, canlıların işlevlerini ve davranışlarını taklit edebilirler, fiziksel yetenek ve yapay zekâya sahiptirler (9).

Hemşirelerin bakım yeterlilik kriterlerinin başında hasta başına düşen hemşire sayısı gelir. Yapılan çalışmalar hemşire başına düşen hasta sayısının yükselmesinin, hasta ölümlerini ve hemşirelerde tükenmişlik sendromunu arttırdığını göstermiştir (10). 2018 Sağlık Bakanlığı verilerine göre Türkiye'de yüz bin kişiye düşen hemşire ve ebe sayısı tüm sektörlerde 301 kişidir. Türkiye'de 126.891 hemşire olduğu bunun %15,2 sinin özel sektörde çalıştığı belirtilmiştir (11). Hemşire sayısının yetersizliği dünya genelinde bir problemdir. Hasta bakım sürelerini arttırabilmek için hemşire başına düşen hasta sayısını azaltmak ve hemşirelerin günlük görevlerini yerine getirirken robot hemşirelerden yardım almak, hemşire iş gücüne ve hasta bakımına destek sağlamak için gereklidir. Günümüzde yeni başlamış olan bu tür uygulamaların, yakın gelecekte hem sayısal hem de nitelik olarak artması beklenmektedir. Ayrıca, robotlar belki de insan hemşireleri geçecek ve tamamen insan hemşirelerin yerini alacaktır (2).

Son yıllarda, robot teknolojisindeki hızlı değişim sağlık alanında büyük bir etki göstermeye başlamıştır (12). Özellikle 2013 yılı ve sonrası yapay zekaya sahip geliştirilen insansı robotların belli bir oranda günümüz hemşireliğine olan gereksinimi azaltabileceği ve bakım kalitesini de olumlu yönde etkileyeceği düşünülmektedir (13).

Robotlar, hastaları giydirme, banyo yaptırma, refakat etme gibi günlük işlere yardım etme, hastaları taşıma, izleme, rehabilite etme ve duygusal destek sağlama, damar yolu bulma, damar yolu açma, fizyolojik ölçüm yapmak gibi pek çok fonksiyona sahip olabilmektedir. Aynı zamanda robotlar, yoğun bakım ortamında hasta yakını ve hastanın temassız iletişimine izin verebilirken, yaşlı bakım evinde ya

da evde yalnız yaşayan bir hastaya refakat ederek fizyolojik gereksinimlerini tespit ederek, hekimi ile iletişime geçmesini sağlayabiliyor (8) (Tablo 1)

Teknolojik gelişmelerin sağlık alanına nasıl katkı sağlayacağı insansı robot hemşirelerin insan hemşirelerin yerini alıp alamayacağı yönünde çalışmalar devam etmektedir (14).

Hemşire, hastanın bireysel ihtiyaçları, istekleri, arzuları ve hedeflerine odaklanır ve bu hasta odaklı yaklaşım hasta memnuniyeti açısından da önemlidir. Hemşireler, teknolojinin kullanımıyla, rutin olarak tanımlanan işleri robotlara devretmesiyle beraber hastalarla duygusal bağ kurarak, onların ihtiyaçlarına uygun şekilde yanıt vermek için daha fazla zaman harcayabilirler. Rutin işleri kontrolü dahilinde robotlara devredebilen hemşireler, hasta bakımına yönelik planlamalar yapma ve hasta özelinde eleştirel düşünme, karar verme gibi daha karmaşık işlere zaman ayırabilecektir (15). Bunun için, sağlık bakım hizmeti veren kurumların dijital teknolojileri kullanmaları önemlidir. Sağlık kurumlarının, hasta memnuniyeti, çalışan memnuniyeti ve verimliliği, tıbbi kayıtların güvenilirliği, insan kaynağının etkin ve verimli kullanımı için sağlıkta teknoloji ve yapay zeka uygulamalarına yönelmeleri önem taşımaktadır (16, 17).

McKinsey Global Institute tarafından hazırlanan raporda, 2030 yılına kadar dünya çapında 800 milyon işçinin yerine robotların geçeceği ve hemşirelikte hali hazırda bir robotik devrim gerçekleştiği ifade edilmektedir. Ayrıca raporda, robotların görevleri ve prosedürleri daha verimli ve daha güvenli bir şekilde yerine getirecekleri belirtilmektedir (18).

### **Robot teknolojileri hemşirelerin yerini doldurabilir mi?**

Robot teknolojilerinin hemşirelerin yerini doldurup dolduramayacağını değerlendirebilmek için öncelikle hemşirelik rollerinin hangi yönlerinin teknolojiye devredilebileceğine ve hangi rollerin verilemeyeceğine karar verilmelidir (19). Hemşireler, otomatik teknolojinin ve yapay zekanın uygulamalarını denetleyerek, yeni sistemlerde bütünsel bir bakım rolü sağlayabilir. Bütünsel bakım rollerinin içerisinde etik ve ahlaki açıdan görev dağılımlarının doğru planlaması, olası bir hata durumunda sorumluluğun kim tarafından alınacağı açıkça belirtilmelidir (20). Hemşireler, hasta bakımının uygun şekilde sunulmasını sağlamak için teknolojilerle koordinasyonu denetleyecektir. Tarif edilebilen ve algoritmalara yüklenebilen işleri insansı robotlara devrederek, hasta etkileşimine daha fazla zaman ayrılabilir (4).

Hemşirelerin, ortaya çıkan teknolojiler üzerine araştırmalara daha fazla odaklanması onların teknolojiyi nasıl kullanılacağı konusunda fikir sahibi olmalarını sağlar. Hemşirelik için kullanılabilir hale gelen artan sayıda yeni teknoloji, bakımın kalitesini artırabilir, çalışma koşullarını iyileştirebilir ve maliyetleri düşürebilir. Bu yeni teknolojinin hemşirelik alanındaki etkisi ve hemşirelik uygulamalarında

benimsenmesinin nasıl hızlanacağına dair daha fazla bilimsel çalışmaya ihtiyaç vardır (21).

İnsanın doğasında olan, merhamet ve empatinin makinelere modellemesi zordur. Gelişmiş bir hemşirelik dünyasında hemşirelerin rolleri yeniden tanımlamalı, teknolojiyi hastanın ihtiyaçlarını karşılayabilecek şekilde uygulamalı ve yönetmelidir (22). Hemşirelerin etkin ve verimli bir bakım sağlayabilmesi için, olması gereken optimum insan gücü ve yapay zekanın birleşimi gereklidir. Yapay zekanın gelişmiş analiz teknolojisini hemşirelerin deneyim, bilgi ve eleştirel düşünme becerileri ile birleştirmek, hasta bakım maliyetlerini ve kaliteli hizmet sunumuna katkı sağlayacaktır (23).

### **Sonuç**

Dünyada birçok alanda hızla gelişen teknoloji ve yapay zeka uygulamaları, hemşirelik mesleğinde de etkisini gösterecektir. Hemşireler değişen dünyada teknolojiye uyum sağladıklarında insanları robotlardan ayıran en önemli özellikleri eleştirel düşünme ve insiyatif kullanabilme yetenekleri ile rutin ve tekrarlı işlerin çoğunu robot hemşirelere devredebilecek ve kendileri hem bu teknolojiyi yönetecek hem de bu sayede karmaşık işlere daha çok zaman ayırabileceklerdir. Bu değişim, hemşirelerde fiziksel iş gücü istihdam sayısını optimum düzeye çekerken, yapay zeka teknolojilerinin çalıştığı işlerde öngörülemez aksaklıkları öngörebilen, teknolojiyi kullanan ve yönetebilen hemşire ihtiyacını arttıracakı düşünülmektedir. Hemşireler teknoloji ve değişime bu gözle bakabilir ve insanları robotlardan ayıran en önemli özelliklerini vazgeçilmez kılabılırlerse değişen yeni dünyaya hızla uyum sağlayabilirler.

Teknolojik gelişmeler sayesinde hemşirelik eğitiminde de müfredat değişikliği kaçınılmaz olacaktır. Teknolojiyi bilen, anlayan ve yönetebilen akademisyenlere ihtiyacın artacağı öngörülmektedir. Hemşirelik eğitim müfredatı içerisinde yapay zeka, hemşirelikte inovasyon, robot hemşireler, robot hemşirelerin kullanım ve yönetimi, hemşirelikte stratejik yönetim ve değişim yönetimi gibi konular öncelikli olacaktır.

Eğitime devam eden öğrenci hemşireler müfredat değişikliği ile desteklenmeli, sahada aktif çalışan hemşirelere yönelik ayrıca eğitimler planlanmalı, hemşirelerin kendilerini gerekli bilgilerle donatmalarına destek olmak sağlanmalıdır.

20. yüzyılda tüm meslekler gibi hemşirelik mesleği de yapay zeka teknolojisi ile tanışmıştır. Bununla birlikte, geleceğin meslekleri arasında yer alabilmek için değişime ve gelişime uyum sağlamları önemlidir. Yapay zekayı sağlık alanına hızla entegre etmek ve kullanım özelliklerini bilerek avantaja çevirmek için yapay zeka ve robot hemşireleri kullanmak gerekecektir. Bu durum hemşirelik mesleğine değer katacaktır ve geleceğin meslekleri arasında güçlü ve prestijli bir şekilde ayakta kalmaya devam edebilmesini sağlayacaktır.

**Çıkar çatışması:** yok

**Finansal destek:** yok

**Yazar katkıları:** E.G, E.U.K

**Motivasyon / Konsept:** EG, EUK

**Çalışma Tasarımı:** EG, EUK

**Kontrol / Gözetim:** EG, EUK

**Veri Toplanması ve / veya İşlemesi:** EG

**Analiz ve / veya Yorum:** EG

**Literatür incelemesi:** EG, EUK

**Makalenin Yazılması:** EG, EUK

**Eleştirel İnceleme:** EG, EUK

## KAYNAKLAR


1. Özdemir Ş. Yapay zeka dünyasında kadının yeri. (Erişim: 11.03.2021). <https://aipaturkey.org/aipa-danisma-kurulu-uyesi-dr-sebnem-ozdemirden-8-mart-dunya-kadinlar-gunu-yazisi-yapay-zeka-dnyasinda-kadinin-yeri/>
2. Gonzalez H, Jimenez H. Taking the fiction out of science fiction: (Self-aware) robots and what they mean for society, retailers and marketers 2018; doi.org/10.1016/j.futures.2018.01.004.
3. Bryk W. Artificial super intelligence: the coming revolution. (Erişim: 11.03.2021). <https://harvardsciencereview.com/2015/12/04/artificial-superintelligence-the-coming-revolution-2/> Retrieved from Harvard Science Review.
4. Locsin RC, Ito H. Can Humanoid nurse robots replace human nurses? Journal of Nursing, 2018; doi:10.7243/2056-9157-5-1.
5. Hamer S, Cipriano P. Involving nurses in developing new technology. Nurs Times, 2013; 5;109(47):18-9.
6. Şendir M, Şimşekoğlu N, Kaya A, Sümer K. Geleceğin teknolojisinde hemşirelik. Sağlık Bilimleri Üniversitesi Hemşirelik Dergisi, 2019; 1(3).
7. Tarhan U. T İnsan, Destek Yayınları, 2017. s. 272.
8. Pepito JA, Locsin R. Can nurses remain relevant in a technologically advanced future? International Journal of Nursing Sciences, 2018; 6: 106-110. doi:10.1016/j.ijnss.2018.09.013. <https://tr.wikipedia.org/wiki/Robot>
9. (Erişim:14.01.2021).
10. Saraee E, Joshi A, Betke MA. A the rapeutic robotic system for the upper body based on the proficioroboticarm. International Conference on Virtual Rehabilitation, 2017; 138-140.
11. Sağlık Bakanlığı Sağlık İstatistikleri Yıllığı. Sağlık Bilgi Sistemleri Genel Müdürlüğü <https://dosyasb.saglik.gov.tr/Eklenti/36134,siy2018trpd.pdf?0> Erişim: 11.03.2021.
12. Blumenthal D. Data with holding in the age of digita lhealth. The Milbank Quarterly, 2017; 95(1): 15-18. doi: 10.1111/1468-0009.12239.
13. Barrat J. Our final invention: artificial intelligence and the end of the human era our final invention. New York, NY: Thomas DunneBooks, 2019.
14. Abutaleb A, Alsabhani J, Alkinani S, Alkaydi S, Alghamdi S, Bensenouci A. Design and implementation of a nurse robot. Proceedings of the International Conference on Industrial Engineering and Operations Management, 2020, Dubai, UAE.
15. Shishegar M, Kerr D, Blake J. A systematic review of research into how robotic technology can help older people. Smart Health, 2018 doi: 10.1016/J.SMHL.2018.03.002.
16. Altuntaş EY. Sağlık hizmetleri uygulamalarında dijital dönüşüm. 1.Baskı, Eğitim Kitabevi, Konya, 2019.
17. Tüfekçi N, Yorulmaz R, Cansever İH. Dijital hastane. Journal of Current Researches on Health Sector, 2017; 7(2): 143-156.
18. McKinsey Global Institute. McKinsey & Company; San Francisco: 2017. JOBS LOST, JOBS GAINED: workforce transitions in a time of automation. [https://www.mckinsey.com/featured-insights/future-of-work/jobs-lost-jobs-gained-what-the-future-of-work-will-mean-for-jobs-skills-and-wages# Erişim:11.03.2021]
19. Tanioka T. The development of the transactive relationship theory of nursing (treton): A nursing engagement model for persons and humanoid nursing robots. Int Nurs Clin Pract, 2017; 4: 223. doi.org/10.15344/2394-4978/2017/223.
20. De Veer AJE, Fleuren MAH, Bekkema N, Francke AL. Successful implementation of new technologies in nursing care: a questionnaire survey of nurse-users. BMC Med Inf Decis Making. 2011;11:67. doi: 10.1186/1472-6947-11-67.
21. Hojat M. Empathy in health professions education and patient care. Springer International Publishing; Cham: 2016. Empathy and patient outcomes; pp. 189–201.
22. Neill DB. Using artificial intelligence to improve hospital in patient care. Intelligent Systems, 2013; 28, 92-95. doi:10.1109/MIS.2013.51.
23. Eşkin Bacaksız F, Yılmaz M, Ezizi K, Alan. Sağlık Hizmetlerinde Robotları Yönetmek. SHYD,2020,7(3),458-465 doi:10.522/SHYD.2020.59455

**Tablo 1: Hemşirelik ve Sağlık Alanında Kullanılan Robot Örnekleri**

<b>Tarih</b>	<b>Robot ve Robotik Teknolojinin Adı</b>	<b>Yetenekler</b>	<b>Kullanım alanları</b>
2000	Da Vinci Cerrahi Robot	Cerrahların hassasiyetini ve doğruluğunu artırır Ameliyathanedeki hemşirelerin sorumluluklarını azaltır	Minimal invaziv bir yaklaşım kullanarak ameliyatı kolaylaştırmak için tasarlanmıştır ve bir konsoldan cerrah tarafından kontrol edilir.
2004	Paro	Yaşlılar, otistik çocuklar veya engelliler gibi özel ihtiyaçları olan kişilere yardımcı olur.  Rahatlık ve duygusal destek sağlar	Paro Robot, fok şeklinde tasarlanmış ve tüylü yumuşak dokuya sahiptir, hastanelerde ve huzurevlerinde kullanılmak üzere tasarlanmıştır. ParoRobot dikkat çekmek için ağlayacak ve ismine yanıt verecek şekilde programlanmıştır. Bir kapatma anahtarı içerir.
2006	Robotik Reçete Dağıtım Sistemleri	İlaç dağıtımının daha doğru ve güvenli hale getirilmesi hemşirelerin ilaç yönetimindeki sorumluluklarını azaltır.	Paketleme makineleri (Tek doz paketleme) doğru hasta, doğru zaman, doğru ilaç, doğru doz), tablet kontrol ve tanıma sistemleri, merkezi eczane sistemleri (ampul, flakon paketleme sistemleri), otomatik blister kesme sistemi, kapalı devre ilaç yönetim sistemi ve robotik eczane otomasyonu şeklinde kullanımları alanları yaygındır.
2009	RIBA	Hastaları ve ayağa kalkma konusunda yardıma ihtiyacı olanları kaldırır ve taşır	RIBA, bir insanı kaldırmak için özel olarak oluşturulmuş eklem konumlarına ve bağlantı uzunluklarına sahiptir. Üzerinde bulunun iki kamera ve iki mikrofon ile görsel ve işitsel ipuçlarına tepki verir, yön mesafe algılayarak operatörü ile etkileşime geçebilir.
2010	Georgia Tech'ten "Cody"	Hastalara yatak banyosu verir	Cody Robot, yaşlı, engelli ve kişisel hijyeni sürdürmek de sorun yaşayan hastalarda, çok yaralı veya kendi başlarına hareket özgürlüğü olmayan hastalarda kişisel hijyenlerini sağlayarak hastaları yıkama görevini yerine getiriyor.
2010	Veebot	En iyi damarı seçmede % 83 doğruluk oranına sahiptir	Robotik iğne yerleştirme (Kan alma / IV katater yerleştirme)
2013	SwisslogRoboCourier	Hastanelerde, klinik laboratuvarlarda ve eczanelerde örneklerin, ilaçların ve malzemelerin taşınmasında kullanılır	RoboCourier ile, laboratuvar numunelerinin, ilaçların ve diğer malzemelerin planlı ve isteğe bağlı teslimatlarını otomatik hale getirebilir. Hafif ve orta yükleri verimli ve uygun maliyetle otomatik kapılar ve asansörleri yöneterek katlar arasında taşır.

<b>Tarih</b>	<b>Robot ve Robotik Teknolojinin Adı</b>	<b>Yetenekler</b>	<b>Kullanım alanları</b>
2014	Pepper	Yaşlılar, otistik çocuklar veya engelliler gibi özel ihtiyaçları olan kişilere yardımcı olur. Rahatlık ve duygusal destek sağlar	Yaşlı bakım evleri, çocuk kreşleri, hasta karşılamada kullanılıyor. Pepper'ın amacı "insanların hayattan zevk almasını sağlamak", insanların yaşamlarını iyileştirmek, ilişkileri kolaylaştırmak, insanlarla eğlenmek ve insanları dış dünyayla buluşturmak.
2015	Jibo	Rahatlık ve duygusal destek sağlar	Jibo, yüz ve ses tanıma teknolojisiyle desteklenmiştir, insanları hatırlar.yardımsaver, arkadaş canlısı bir robottur. Sorular sorar, önerilerde bulunur ve hatta şaka yapabilir.
2015	Buddy	Ev otomasyonu, güvenlik, duyguların ifadesiyle sosyal etkileşimler veya yaşlılar ve aileler için yardım robotudur.	Buddy, duygusal bir robottur. Buddy, operatörüyle olan etkileşimlerine dayanarak gün boyunca ifade edeceği bir dizi duyguya sahiptir
2015	Robear (RIBA ve RIBA-II)	Hastaları ve ayağa kalkma konusunda yardıma ihtiyacı olanları kaldırır ve taşır	Hastaları yataktan tekerlekli sandalyelere kaldırabilir veya ayağa kalkmalarına yardımcı olabilir.(RIBA ve RIBA-II ye kıyasla daha hafif daha nazik hareket kabiliyeti mevcut)
2015	TUG robotları	Hastanede nakliye ve teslimat görevlerini yerine getirin	Malzemeleri, ilaçları, çarşafı, yemekleri bir yerden başka bir yere taşıyabiliyor.
2015	Lynx Otonom Akıllı Araçlar	Malları büyük bir tesiste taşıyabilir ve dinamik ortamlarda kendi kendine gezinebilir	Malları büyük tesislerde otomatik kapılar ve asansörleri yöneterek taşıyabilir.
2020	Atacan	Türkiye'de üretilen ilk robot hemşire	Hastalara yemek ve ilaçlarını taşıyabiliyor, akıllı ekranı sayesinde bilgilendirme yapabiliyor.

Kaynak: Pepito JA, Locsin R. Can nurses remain relevant in a technologically advanced future? International Journal of Nursing Sciences, 2018; 6: 106-110. doi:10.1016/j.ijnss.2018.09.013.



# Diş Hekimliğinde Yapay Zeka

## ARTIFICIAL INTELLIGENCE IN DENTISTRY

Hande SAĞLAM<sup>1</sup>, Tuğba ARI<sup>1</sup>, İbrahim Şevki BAYRAKDAR<sup>1</sup>, Elif BİLGİR<sup>1</sup>, Mehmet UĞURLU<sup>1</sup>, Özer ÇELİK<sup>1</sup>, Kaan ORHAN<sup>1</sup>

### Öz

Teknolojik değişiklikler tıp ve diş hekimliği alanında büyük ilerlemelere neden olmuştur. Yapay zekâ teknolojisi bu değişimin başlıca tetikleyicisidir. Tıp ve diş hekimliği alanında hasta sağlık hizmetlerine önemli katkıları ve hekimlere sağladığı kolaylıklar sayesinde gittikçe daha çok tercih edileceği düşünülmektedir. İşlem hızındaki artış, hesaplama gücü, depolama kapasitesi, farklı görevleri yerine getirme yeteneği, gelişmiş grafik işlem birimleri ve bilgisayarların satın alınabilirliği ile tıpta ve özellikle radyolojide yeni bir dönemin başlangıcı kabul edilmektedir. Diş hekimliği alanında da başlayan bu yeni dönem, hastalıkların erken teşhisinin yapılması ve önlenmesinde büyük katkı ortaya koyacaktır. Bu derlemenin amacı yaşadığımız dönem ve gelecek için son derece önemli bir noktada olan yapay zekâ teknolojisinin diş hekimliği alanındaki uygulamalarını anlatmaktır.

**Anahtar Kelimeler:** *Yapay zekâ, Diş hekimliği, Sinir ağları, Evrişimli sinir ağları, Derin öğrenme.*

### Abstract

Technological changes have led to great advances in medicine and dentistry. Artificial intelligence technology is the main driver of this change. It is thought that it will be preferred more and more in the field of medicine and dentistry, thanks to its important contributions to patient health services and the convenience it provides to physicians. With the increase in processing speed, computing power, storage capacity, the ability to perform different tasks and the affordability of advanced graphics processing units and computers, it is considered the beginning of a new era in medicine and especially in radiology. This new era in the field of dentistry will make a great contribution to early diagnosis and prevention of diseases. The purpose of this review is to explain the applications of artificial intelligence technology in the field of dentistry, which is an extremely important point for the period we live in and for the future.

**Keywords:** *Artificial intelligence, Dentistry, Neural networks, Convolutional neural networks, Deep learning.*

Received / Geliş	14.03.2021
Accepted / Kabul	09.04.2021
Publication Date	18.08.2021

**\*Sorumlu Yazar  
Corresponding Author**

**Hande SAĞLAM**

<sup>1</sup> Eskişehir Osmangazi Üniversitesi,  
Diş Hekimliği Fakültesi,  
Ağız, Diş ve Çene Radyolojisi  
Anabilim Dalı,  
Eskişehir, Türkiye

✉ hande\_hegs@hotmail.com

<https://orcid.org/0000-0001-7792-5106>

**Tuğba ARI**

<https://orcid.org/0000-0002-5339-8214>

**İbrahim Şevki BAYRAKDAR**

<https://orcid.org/0000-0001-5036-9867>

**Elif BİLGİR**

<https://orcid.org/0000-0001-9521-4682>

**Mehmet UĞURLU**

<https://orcid.org/0000-0001-7555-3177>

**Özer ÇELİK**

<https://orcid.org/0000-0002-4409-3101>

**Kaan ORHAN**

<https://orcid.org/0000-0001-6768-0176>



## GİRİŞ

Bilim ve teknolojiadaki gelişmeler günlük hayatımızı etkileyen birçok değişime sebep olmaktadır. Bu değişime sebep olan en önemli yeniliklerden biri de yapay zekâ teknolojisidir. Yapay zekâ uygulamaları birçok sektörde hızla gelişmeye devam etmektedir.(1, 2)

Yapay zekânın en önemli avantajlarından biri büyük veri setleri sayesinde sürekli eğitilebilir ve güncellenebilir olmasıdır. Bu sayede bir insana kıyasla daha hassas, hızlı ve güvenilir sonuçlar ortaya koyabilmektedir. Yapay zekâdan, tanı ve tedavi süreci dışında; hasta randevularını organize etme, sigorta ve evrak işlerini yürütme, tıbbi anamnez kaydı tutma gibi alanlarda da faydalanılmaktadır.(3, 4) Bu özellikleri sayesinde hasta geçmişi, demografik bilgiler, yaşam tarzı ve gen faktörleri dahil olmak üzere hasta ile ilgili tüm özellikler kaydedilebilmektedir. Elde edilen büyük veri setleri sayesinde sınıflandırıcı ve öngörücü yapay zekâ modelleri oluşturulacaktır. Böylelikle hastalıklar ve hasta verileri arasındaki ilişkileri keşfederek risk faktörlerinin önceliklendirilmesine ve hastalıkların uzun vadeli sonuçlarını tahmin etmeye yardımcı olabileceklerdir.(5)

Diş hekimliği alanındaki bu büyük veri setleri hastalıkların erken teşhisinin yapılması ve önlenmesinde büyük katkı ortaya koyacaktır. Örnek olarak bir kişinin günlük diş fırçalama süresi, tekniği ve diş etlerine uyguladığı basınç gibi bilgiler yapay zekâ teknolojisi sayesinde bir sensör yardımıyla kaydedilebilecektir. Elde edilen bilgiler ışığında analizler ve araştırmalar yapılarak oral hijyen alışkanlıkları değerlendirilebilecektir.(6)

Bu derlemenin amacı yaşadığımız dönem için son derece önemli bir noktaya gelmiş olan yapay zekânın diş hekimliği alanındaki uygulamalarını incelemektir.

### Yapay zekâ nedir?

“Yapay zekâ” teriminin ilk olarak ortaya çıkışı 1956'da Hannover, New Hampshire, Dartmouth College'da yapılan bir konferansta gerçekleşmiştir. Bu kavramın yaratıcısı olan McCarthy, yapay zekâyı; “İnsan benzeri zeki makineler özellikle de zeki bilgisayar programları yapma bilimi ve mühendisliği” olarak tanımlamıştır.(7)

Yapay zekâ teknolojisindeki amaç, makinelerin, aktarılan veriler aracılığıyla problemleri çözme yeteneği kazanması olarak ifade edilmektedir. Yapay zekâyı anlayabilmek için en temel özelliklerinden olan “makine öğrenmesini” ve “yapay sinir ağlarını” bilmek gerekmektedir. Makine öğrenmesi, bir veri setine dayalı sonuçları tahmin etmek için algoritmalara dayanan yapay zekânın önemli bir alt sınıfıdır.–(8) Yapay zekânın en önemli yapıtaşlarından olan yapay sinir ağları insan beynini taklit eden matematiksel modelleri ifade etmektedir.(9) Bu modeller insan beynindeki biyolojik sinir ağlarının mekanizmasında olduğu gibi sinyalleri ileterek çalışır.(10) Sinir ağları tıp ve diş hekimliği alanında birçok görevi yerine getirebilen çeşitli özelliklere sahiptir.(11) Bu sinir ağlarının daha karmaşık ve zor görevleri yerine getirebilmesi için ise, derin evrişimli sinir ağları

kullanılmaktadır. Derin evrişimli sinir ağları çok katmanlı yapay sinir ağlarından oluşmaktadır. Katman sayısı arttıkça matematiksel hesaplama gücü de artmaktadır. Derin evrişimli sinir ağları bu katmanlar sayesinde daha büyük veriler işleyebilir, istenen birçok görevi yerine getirebilir. Evrişimli sinir ağları “derin öğrenme” olarak da ifade edilmektedir.(12) Bu ağların başarısı; yüklenen eğitim verilerinin miktarına ve kalitesine bağlıdır.(8, 13, 14)

### Ağız, Diş ve Çene Radyolojisi alanında yapay zekâ

Son yıllarda yapay zekâ ve evrişimli sinir ağları tıbbi görüntüleme ve diş hekimliği alanında iki boyutlu ve üç boyutlu radyografiler üzerinde yapılan çalışmalarda kullanılmaya başlanmıştır.(15)

Yapay zekâ ağız, diş ve çene bölgesinde bir insan gözüne kıyasla daha detaylı bir değerlendirme yapma imkânı sunmaktadır.–(16) Diş hekimliği radyolojisinde; sefalometrik radyografilerde anatomik landmarkların belirlenmesi, iki ve üç boyutlu radyografilerde diş tespiti ve numaralandırılması, dişlerde çürük ve periapikal bölgede patoloji tespitinin yapılması, periodontal bölgedeki alveolar kemik kaybının belirlenmesi, dişlerin kök morfolojisinin değerlendirilmesi gibi birçok alanda kullanılmaktadır.(17-22)

Yapay zekâ diş tespit ve segmentasyon alanında birçok çalışmada kullanılmıştır. Lee ve ark.(23) evrişimli sinir ağlarını kullanarak panoramik radyografilerde diş segmentasyonunu gerçekleştirmişlerdir. Yöntemin %85 oranında doğru numaralandırma yaptığını ve adli diş hekimliğinde kimlik tespitinde yararlı olabileceğini belirtmişlerdir.(23) Diğer bir çalışmada Chen ve ark.(19) evrişimli sinir ağlarını kullanarak periapikal radyo-grafiler üzerinde diş tespit ve numaralandırması gerçekleştirmişlerdir. Yapay zekâ ile diş tespitinde %90'ın üzerinde doğruluk değeri elde etmişlerdir. (19) Bir başka çalışmada ise panoramik radyografilerde diş tespiti ve segmentasyonu için bir yapay zekâ modeli geliştirilmiştir. Sonuç olarak sistemin hızlı performans gösterdiğini ve hassasiyet oranının %98,9 olduğu belirtilmiştir.(24)

Diş köklerinin tespit ve segmentasyonunda, ekstra kök varlığının belirlenmesinde, vertikal kök kırıklarının tespitinde, süpernumerer diş varlığının belirlenmesinde de yapay zekâdan faydalanılmıştır. Hiraiwa ve ark.(25) panoramik radyografilerde mandibular birinci molar dişlerin distal köklerindeki ekstra kök varlığını değerlendiren otomatik yöntem geliştirmişlerdir ve tanısal doğruluğunun %86.9 olduğunu belirtmişlerdir. (25) Bir diğer çalışmada ise konik ışınli bilgisayarlı tomografi üzerinde otomatik olarak diş köklerinin segmentasyonunu gerçekleştiren bir yapay zekâ çalışması yapılmıştır. Sonuçta sistemin %95 oranında kesinlik gösterdiğini, klinik pratiğinde büyük faydalarının olacağını bildirmişlerdir.(26) Fukuda ve ark. (27) ise, evrişimli sinir ağlarını kullanarak panoramik radyografiler üzerinde otomatik olarak vertikal kök kırıklarının tespit edildiği bir çalışmada, sistemin vertikal kök kırıklarını tespit etmedeki hassasiyetinin %93 oranında olduğunu

belirtmişlerdir. (27) Bir diğer çalışmada ise, panoramik radyografiler üzerin-de maksiller kesici bölgedeki gömülü süpernümerer diş varlığının tespit ve sınıflandırması için üç farklı derin öğrenme sistemi (DetectNet, AlexNet, VGG-16) kıyaslanmıştır ve sonuç olarak en yüksek tanısal etkinlik tespit edilen yapay zeka modeli DetectNet olmuştur. DetectNet modelinin maksiller kesici bölgedeki diş varlığını tahmin etmedeki kesinlik oranınının 1.0 olduğu belirtilmiştir. (28)

Ağız, diş ve çene radyolojisi alanında yapay zekânın bir diğer kullanım alanı da apikal lezyon tespitidir. Ekert ve ark.(17) yaptıkları bir çalışmada evrişimli sinir ağlarını kullanarak panoramik radyografilerde apikal lezyon tespiti yapmışlardır. Sistemin duyarlılık oranınının %65 olduğunu ve bir diş hekimine teşhis sürecinde kolaylık sağlayacağını bildirmişlerdir. Orhan ve ark.(21) yaptıkları bir çalışmada, konik ışınli bilgisayarlı tomografi üzerinde periapikal patolojilerin tespitini gerçekleştiren bir yapay zekâ modeli geliştirmişlerdir. Evrişimli sinir ağlarının kullanıldığı bu model, toplamda 153 periapikal lezyonun 142'sini başarıyla tespit etmiştir. (21)

Radyoloji alanında lenf nodu metastaz tespiti, Sjögren sendromu ve osteoporoz gibi hastalıkların tespitinde de yapay zekâ algoritmalarından faydalanılmıştır. Hiraiwa ve ark. (29) yaptıkları bir çalışmada Sjögren sendromunun tespiti için bilgisayarlı tomografi ve evrişimli sinir ağlarını kullandıkları bir çalışmada %96 oranında doğruluk değeri elde ettiklerini bildirmişlerdir.(29) Ariji ve ark. (30) ise, bilgisayarlı tomografi görüntüleri üzerinde derin öğrenme yöntemi ile lenf nodu metastazlarının tespitini gerçekleştirmişlerdir. Yapay zekâ modelinin yüksek teşhis doğruluğu, özgüllük ve duyarlılık sağladığını bildirmişlerdir.(30)

Osteoporoz tespitinde Lee ve ark.(31) tarafından yapılan bir çalışmada panoramik radyografiler üzerinde derin evrişimli sinir ağlarını kullanarak osteoporozun saptanması gerçekleştirilmiştir ve %98,5 oranında doğruluk oranı elde edilmiştir. Çalışmada geliştirilen yapay zekâ sisteminin tahminlerinin, maksillofasiyal radyoloji uzmanları ile uyum gösterdiği belirtilmiştir. Bu sonuçların yine Lee ve ark. (32) tarafından yapılan başka bir çalışmanın sonuçlarıyla örtüştüğü tespit edilmiştir.

### **Ortodonti alanında yapay zekâ**

Başarılı bir ortodontik tedavinin anahtar faktörü; doğru teşhis ve tedavi planlamasıyla birlikte doğru prognoz tahminidir. Ortodonti alanında yapay zekâ birçok analiz için kullanılabilir. Fotoğraf ve radyografi analizleri, dijital olarak yapılan ölçümler, diş hareketlerinin tahmini sonuçları gibi birçok hesaplamayı yapay zekâ yerine getirebilmektedir. İntraoral tarayıcılar ve kameraların uygulanmasıyla birlikte yapay zeka algoritmalarının, yüklenen veriler aracılığıyla eğitilerek, ortodonti alanında da tanı ve tedavi sürecinde hekime destek olabileceği düşünülmektedir.(33-35)

Xie ve ark.(33) lateral sefalometrik radyografiler üzerinde yaptıkları bir çalışmada, ortodontik tedavi öncesi diş çekim ihtiyacını değerlendirmişler ve elde ettikleri sonuçların ümit verici olduğunu bildirmişlerdir. Jung ve ark.(36) tarafından yine lateral sefalometrik radyografilerde daimî diş çekimi gerekliliği üzerine yapılan başka bir çalışmada ise, geliştirilen algoritmanın test veri setinde %93 oranında bir başarı gösterdiğini belirtmişlerdir.(36) Diğer bir çalışmada, lateral sefalometrik radyografiler üzerinde anatomik landmarkların tespiti ile ilgili bir yapay zekâ algoritması geliştirilmiştir. Çalışmanın sonucunda bir diş hekimi ve yapay zekâ modelinin anatomik landmarkların tespiti için başarıları karşılaştırıldığında, istatistiksel olarak bir fark olmadığını belirtmişlerdir.(37) Hwang ve ark.(38) da lateral sefalometrik radyografilerde yapay zekâ ile anatomik landmarkların belirlenmesi için bir çalışma yapmıştır. Sonuç olarak yapay zekânın bir diş hekimi kadar doğru bir şekilde tanımlama yapabildiğini tespit etmişlerdir. Yu ve ark.(39) ise, otomatik olarak iskeletsel sınıflandırma üzerine bir yapay zekâ modeli geliştirmişlerdir. Geliştirdikleri modelin teşhis performansının %90 oranında duyarlılık, doğruluk ve özgüllük gösterdiğini belirtmişlerdir.

Ortodontik cerrahi planlamasında da yapay zekâ modellerinden faydalanılmaktadır. Yapılan bir çalışmada cerrahi gerektiren ve gerektirmeyen olmak üzere ortodontik tedavi yapılacak hastaların teşhisi için bir yapay zekâ modeli geliştirdikleri çalışmalarında %96 oranında başarı elde etmişlerdir.(40) Yapay zekâ modelleri ayrıca büyüme gelişim dönemlerinin belirlenmesinde de kullanılmaktadır. Bu evrelerin belirlenmesi genellikle el-bilek ve lateral sefalometrik radyografiler aracılığıyla yapılmaktadır.(41) Yapılan bir çalışmada yapay zekâ modeli ile, sefalometrik radyografilerde servikal vertebralar incelenerek büyüme gelişim döneminin tespiti yapılmıştır. Sonuç olarak; %77,02 oranında doğruluk oranı elde edilmiştir. (42)

### **Ağız, Diş ve Çene Cerrahisi alanında yapay zekâ**

Yapay zekânın cerrahi alanındaki en büyük yeniliği robotik uygulamalar olmuştur. Yapay zekâ yazılımları sayesinde gerçek operasyon öncesinde en küçük anatomi yapıların bile korunabileceği tedavi planlamaları tespit edilerek, cerrahi prosedür daha kısa sürede tamamlanabilecektir.(43, 44) Yapay zekâ teknolojisi Ağız, Diş ve Çene Cerrahisi alanında diş çekimi işlemleri sonrasında post-operatif dönemdeki şişliği tahmin etmek için de kullanılmıştır. Zhang ve ark. (45), gömülü mandibular üçüncü molar dişlerin çekiminin ardından ameliyat sonrası yüz şişliğini tahmin etmek için yapay sinir ağlarına dayalı bir yapay zekâ modeli kullanmıştır. Modelin post-operatif yüzde şişlik tahminindeki doğruluk oranınının %98 olduğu belirtilmiştir. Bu modelin klinisyenler için hastalığın prognozunu tahmin etmede büyük önem taşıyacağı düşünülmektedir. (45) Orhan ve ark.(46) yaptıkları çalışmada konik ışınli bilgisayarlı tomografi üzerinde yapay zekâ modeli aracılığıyla gömülü

üçüncü molar dişlerin tanısal doğruluğunu araştırmışlardır. Sonuç olarak geliştirilen modelin gömülü üçüncü molar dişlerin tespitinde ve anatomik yapılarla olan ilişkilerinin değerlendirilmesinde %86,2 oranında doğruluk performansı gösterdiğini bildirmişlerdir.(46)

Vinayahalingam ve ark.(47) ise, derin öğrenmeye dayalı oluşturdukları bir otomatik sistem aracılığıyla, mandibular üçüncü molar dişler ile inferior alveolar kanalın tespit ve segmentasyonunu gerçekleştirmişlerdir. Üçüncü molar ve inferior alveolar kanal tespitinin otomatik olarak yapılmasının, ameliyat öncesi cerraha hızlı bir şekilde bilgilendirme yapabileceğini ve olası komplikasyonların önüne geçilebileceğini belirtmişlerdir. Ancak geliştirilen yapay zekâ modelinin klinik rutinde kullanılabilmesi için doğruluk oranlarının ve algoritmalarının iyileştirilmesini önermişlerdir.(47)

Bir başka çalışmada ise, panoramik radyografiler üzerinde evrişimli sinir ağları kullanılarak üçüncü molar dişlerin çekim zorluğu değerlendirilmiştir. Çekim zorluğu Pederson zorluk skoru (PDS) kullanılarak üç gözlemcinin fikir birliğine göre değerlendirilmiştir. Gömülü üçüncü molar dişlerin; ramusla ilişkisinin, angulasyonunun ve ayrıca mandibular ikinci molar referans alınarak belirlenen derinlik bilgisinin belirlenmesi ile ilgili sırasıyla %82,03, %90,23 ve %78,91 oranlarında başarı elde edilmiştir.(48)

#### **Restoratif diş hekimliği alanında yapay zekâ**

Son yıllarda florür ve diğer önleyici yöntemlerin kullanımının yaygınlaşması ile birlikte diş çürüklerinin görülme oranı azalmıştır. Bu durum çürüğün doğasını değiştirerek tespitini zorlaştırmıştır. Arayüz çürüklerinin teşhisinde en sık kullanılan yöntem bite-wing radyografilerdir.(49-51) Ancak bite-wing radyografi-lere rağmen çürük teşhisi zor olabilmektedir. Özellikle klinik olarak kavitezyon izlenmeyen ve minenin 1/3 dış kısmının demineralize olduğu aproksimal çürük lezyonlarında radyografik olarak herhangi bir bulguya rastlanmayabilir.(52) Bu nedenle son yıllarda bilgisayar destekli programlara talep artmıştır.(53-55) Karina ve ark.(56) sinir ağlarını kullanarak arayüz çürüklerini değerlendirdikleri bir çalışmada, oluşturdukları matematiksel modellerle teşhiste performansın %39,4 oranında arttığını tespit etmişlerdir.

Schwendicke ve ark.(57) evrişimli sinir ağlarını kullanarak proksimal yüzeydeki çürükler için yaptıkları çalışmada, modelin %80 oranında doğru tahminler yaptığını bildirmişlerdir. Yapay zekânın lezyonların erken tespit edilmesinde, çalışmadaki diş hekimlerine kıyasla daha hassas ve doğru performans ortaya koyduğunu göstermişlerdir. Benzer bir çalışmada da bite-wing radyografilerde derin öğrenme yöntemine dayalı bir model geliştirilerek çürük lezyonu tespiti gerçekleştirilmiştir. Sonuç olarak geliştirilen yapay zekâ modeli, çalışmada %71 oranında doğru tahminde bulunan diş hekimlerine kıyasla %80 doğruluk oranı ile daha yüksek başarı göstermiştir.(58)

Lee ve ark.(59) ise, evrişimli sinir ağlarını kullanarak periapikal radyografilerde çürük tespiti üzerine bir çalışma yapmışlardır. Evrişimli sinir ağı algoritmalarının çürük tespitinde oldukça iyi performans gösterdiğini bildirmişlerdir. Premolar ve molar dişler üzerinde yürüttükleri bu çalışmada en yüksek başarıyı %89'luk bir oran ile premolar dişlerde sağlamışlardır. Geliştirilen bu yapay zekâ algoritmalarının önümüzdeki yıllarda en etkili ve verimli çürük teşhis sistemi olacağını iddia etmişlerdir.(59)

Yapay zekânın restoratif diş hekimliğindeki diğer bir kullanım alanı ise, taşkın restorasyon tespitidir. Taşkın restorasyonlar diş eti iltihabı, periodontal hastalık ve kanama gibi olumsuz durumlara sebep olabilmektedir. Bu sebeple tespit edilmeleri önem teşkil etmektedir.(60) Yapılan bir çalışmada yapay sinir ağları kullanılarak taşkın restorasyonların teşhisi üzerinde çalışılmıştır. Sistem % 85,6 oranında doğruluk göstermiştir.(61)

#### **Protetik diş tedavisi alanında yapay zekâ**

Protetik diş tedavisi estetik beklentinin yüksek olduğu bir diş hekimliği alanıdır. Yapay zekâ ile yüz bölgesinde ölçümler ve antropolojik hesaplamalar yapılarak hastaların estetik arzularının başarıyla karşılanması sağlanabilecektir.(62) Protez alanındaki en büyük gelişmelerden biri olan CAD/CAM yazılımları ile geleneksel dökümün zaman alıcı ve zahmetli sürecinin yerini alarak insan hatalarını azaltmıştır. Yapay zekâyı CAD/CAM sistemlerine entegre etmenin klinik rutin için çok verimli olacağı düşünülmektedir.(63) Ayrıca protetik tedavi sonrası yüz profillerini stimüle etmek için sanal gerçeklik simülasyonu (Virtual Reality Simulation, VRS) teknolojisi kullanılabilir. Bu sadece diş hekiminin estetiği verimli bir şekilde tasarlamasını sağlamakla kalmaz, aynı zamanda hasta için motive edici bir araç görevi görür.-(64, 65)

Toshihito ve ark.(66) derin öğrenme yöntemini kullanarak yaptıkları bir çalışmada diş restorasyonlarını ve dişler üzerindeki protezleri otomatik olarak tespit etmeyi başarmıştır. Metal restorasyonların tespitinde %80'lik bir başarıya ulaşırken, diş rengindeki restorasyonların tespitinde %60 oranında başarı elde edilmiştir.

#### **Periodontoloji alanında yapay zekâ**

Periodontal hastalıklar diş kayıplarına sebep olabilmek, geniş popülasyonları etkileyen, sık karşılaşılan bir hastalık grubudur.-(67) Yapay zekâ ve derin evrişimli sinir ağları sayesinde periodontoloji alanında da birçok uygulama yapılmaktadır. Radyografiler üzerinde kemik değişikliklerinin ve alveolar kemik kayıplarının tespiti, kemik yoğunluğundaki değişimlerin erken teşhisi yapılabilmektedir. Ayrıca peri-implantitisin erken tespitine yardımcı olarak, implantoloji alanında gerekebilecek erken müdahaleleri gerçekleştirmeye olanak tanıyabilir. (68, 69)

Lee ve ark.(70) periodontal hastalık sonucu durumu en kritik olan dişleri belirlemek amacıyla bir yapay zekâ modeli geliştirdiler ve %78,9'luk gibi bir doğruluk oranı elde ettiler. Alalharith ve ark. (71) ortodontik tedavi gören hastaların üzerinde yaptıkları bir çalışmada periodontal hastalığın otomatik olarak tespitini gerçekleştirmişlerdir. %77,12 oranıyla başarı elde etmişlerdir. (71) Bir başka çalışmada ise derin evrışimli sinir ağlarını kullanarak panoramik radyografilerde periodontal kemik kaybının tespiti üzerine bir çalışma yapmışlardır. Geliştirdikleri yapay zekâ modelinin uzman bir diş hekimiyle %81 oranında örtüşüğünü tespit etmişlerdir.(17)

#### **Ağız kanserleri ve yapay zekâ**

Yapay zekâ ile oral mukozadaki benign ve malign lezyonların sınıflandırılması yapılabilmektedir. Şüpheli bölgelerin taranması ve tespiti bu algoritmalar sayesinde mümkün hale gelmiştir. Özellikle geniş çaptaki ağız taramalarında kullanılarak değerlendirilen popülasyonun ağız kanserlerine yatkınlığını tahmin edebilir.(72, 73)

Erken tanı oral bölgedeki skuamöz hücreli karsinom-ların prognozunu belirleyen en önemli faktörlerden biridir. Ancak genellikle birçok ağız kanseri geç tespit edilmektedir. Özellikle sağlık hizmetlerinin sınırlı olduğu bölgelerde yapay zekâ destekli yazılımlar ile gerçekleştirilecek olan taramaların morbidite ve morta-lite oranlarını düşüreceği öngörülmektedir.(74, 75)

Ariji ve ark. (71) yaptıkları bir çalışmada, derin öğrenme yöntemini kullanarak oral kanserli hastalarda lenf nodu metastazının bilgisayarlı tomografi aracılığıyla tespitini sağlamışlardır. Geliştirdikleri yapay zekâ modeli %78,2 oranıyla doğru tahminlerde bulunmuştur. Yapay zekâ uygulamalarının malign lezyonların teşhis sürecinde hekime destek olabileceğini vurgulamışlardır.(76)

#### **Adli diş hekimliği alanında yapay zekâ**

Adli diş hekimliği yapay zekâ açısından nispeten yeni bir alan olmakla birlikte özellikle kimlik tespit çalışmaları için çok önemli bir yere sahiptir.-(8) Do Tobel ve ark.(77) panoramik radyografiler üzerinde mandibular üçüncü molar dişlerin evrelendirmesinde evrışimli sinir ağlarını kullanmıştır. Mandibular üçüncü molar dişleri evrelendirilerek yaş tahmini yapılmıştır. Geliştirilen yapay zekâ modelinin tahmini doğruluğunun %51 olduğu bildirilmiştir. Patil ve ark.(78) ise, panoramik radyografiler üzerinden cinsiyet tahmini için bir yapay zekâ modeli geliştirmişlerdir. Yapay sinir ağları kullanılarak geliştirilen bu sistemin sonuçlarının ümit verici (%75 doğruluk) olduğunu bildirmişlerdir. Bu yapay zekâ algoritmalarının cinsiyeti ve yaşı otomatik olarak belirlediği için oldukça kullanışlı oldukları belirtilmiştir. Bir başka çalışmada ise, mandibular morfolojiyi tahmin etmek için yapay sinir ağlarına dayalı bir sistem üzerinde çalışılmıştır ve başarılı sonuçlar (%95 doğruluk) elde edilmiştir. Bu çalışmalar adli diş hekimliğinde yapay zekâ uygulamalarının etkinliğini ve faydalarını ortaya koymuştur. (79)

#### **SONUÇ**

Yapay zekâ sayesinde diş hekimleri daha güvenilir ve hızlı teşhis yaparak, etkin tedaviler gerçekleştirebilecektir. Bu alanda yapılan çalışmalar bu algoritmalara olan katkıları sebebiyle çok önemlidir. Geliştirilecek olan algoritmalar ile oluşturulan yapay zekâ modelleri hekimlerin doğru sonuca ulaşmasını hızlandıracaktır. Hasta konforu ve hızlı teşhis klinik rutininde hekimlerin performansını artırarak daha verimli çalışma imkânı sunacaktır.

**Çıkar çatışması:** yok

**Finansal destek:** yok

**Yazar katkıları:**

**Motivasyon / Konsept:** İB

**Çalışma Tasarımı:** İB, EB, MU

**Kontrol / Gözetim:** İB, EB, MU, ÖÇ

**Veri Toplanması ve / veya İşlemesi:** HS, EB

**Analiz ve / veya Yorum:** HS, İB

**Literatür incelemesi:** HS, TA

**Makalenin Yazılması:** HS, TA

**Eleştirel İnceleme:** KO, İB

#### **KAYNAKLAR**

- 1.Russell S, Norvig P. Artificial Intelligence-A Modern Approach 3rd ed. M. Hirsch, ed. New Jersey: Pearson Education, Inc; 2010.
- 2.Wong S, Al-Hasani H, Alam Z, Alam A. Artificial intelligence in radiology: how will we be affected? European radiology. 2019;29(1):141-3.
- 3.Khanna SS, Dhaimade PA. Artificial intelligence: transforming dentistry today. Indian J Basic Appl Med Res. 2017;6(3):161-7.
- 4.Feeney L, Reynolds P, Eaton K, Harper J. A description of the new technologies used in transforming dental education. British Dental Journal. 2008;204(1):19-28.
- 5.Shan T, Tay F, Gu L. Application of Artificial Intelligence in Dentistry. Journal of dental research. 2020;0022034520969115.
- 6.Salagare S, Prasad R. An overview of internet of dental things: new frontier in advanced dentistry. Wireless Personal Communications. 2020;110(3):1345-71.
- 7.Moor J. The Dartmouth College artificial intelligence conference: The next fifty years. Ai Magazine. 2006;27(4):87-.
- 8.Khanagar SB, Al-Ehaideb A, Maganur PC, Vishwanathiah S, Patil S, Baeshen HA, et al. Developments, application, and performance of artificial intelligence in dentistryA systematic review. Journal of dental sciences. 2020.
- 9.Kositbowornchai S, Siriptawee S, Plermkamom S, Bureerat S, Chetchotsak D. An artificial neural network for

detection of simulated dental caries. *International Journal of Computer Assisted Radiology and Surgery*. 2006;1(2):91-6.

10.Khajanchi A. Artificial neural networks: the next intelligence. USC, Technology Commercialization Alliance [usc.edu/org/techalliance/Anthology2003/Final\\_Khajanchi.pdf](http://usc.edu/org/techalliance/Anthology2003/Final_Khajanchi.pdf). 2003.

11.Brickley M, Shepherd J, Armstrong R. Neural networks: a new technique for development of decision support systems in dentistry. *Journal of dentistry*. 1998;26(4):305-9.

12.Hwang J-J, Jung Y-H, Cho B-H, Heo M-S. An overview of deep learning in the field of dentistry. *Imaging science in dentistry*. 2019;49(1):1.

13.Burt JR, Torosdagli N, Khosravan N, RaviPrakash H, Mortazi A, Tissavirasingham F, et al. Deep learning beyond cats and dogs: recent advances in diagnosing breast cancer with deep neural networks. *The British journal of radiology*. 2018;91(1089):20170545.

14.Corbella S, Srinivas S, Cabitza F. Applications of deep learning in dentistry. *Oral Surgery, Oral Medicine, Oral Pathology and Oral Radiology*. 2020.

15.White SC, Pharoah MJ. *Oral radiology-E-Book: Principles and interpretation*: Elsevier Health Sciences; 2014.

16.Katne T, Kanaparthi A, Srikanth Gotoor S, Muppurala S, Devaraju R, Gantala R. Artificial intelligence: demystifying dentistry the future and beyond. *Int J Contemp Med Surg Radiol*. 2019;4:D6-D9.

17.Krois J, Ekert T, Meinhold L, Golla T, Kharbot B, Wittemeier A, et al. Deep learning for the radiographic detection of periodontal bone loss. *Scientific reports*. 2019;9(1):1-6.

18.Davies A, Mannocci F, Mitchell P, Andiappan M, Patel S. The detection of periapical pathoses in root filled teeth using single and parallax periapical radiographs versus cone beam computed tomography a clinical study. *International endodontic journal*. 2015;48(6):582-92.

19.Chen H, Zhang K, Lyu P, Li H, Zhang L, Wu J, et al. A deep learning approach to automatic teeth detection and numbering based on object detection in dental periapical films. *Scientific reports*. 2019;9(1):1-11.

20.Tuzoff DV, Tuzova LN, Bornstein MM, Krasnov AS, Kharchenko MA, Nikolenko SI, et al. Tooth detection and numbering in panoramic radiographs using convolutional neural networks. *Dentomaxillofacial Radiology*. 2019;48(4):20180051.

21.Orhan K, Bayrakdar I, Ezhov M, Kravtsov A, Özyürek T. Evaluation of artificial intelligence for detecting periapical pathosis on cone-beam computed tomography scans. *International endodontic journal*. 2020;53(5):680-9.

22.Kilic MC, Bayrakdar IS, Çelik Ö, Bilgir E, Orhan K, Aydın OB, et al. Artificial intelligence system for automatic deciduous tooth detection and numbering in panoramic radiographs. *Dentomaxillofacial Radiology*.

2021;50:20200172.

23.Lee J-H, Han S-S, Kim YH, Lee C, Kim I. Application of a fully deep convolutional neural network to the automation of tooth segmentation on panoramic radiographs. *Oral surgery, oral medicine, oral pathology and oral radiology*. 2020;129(6):635-42.

24.Leite AF, Van Gerven A, Willems H, Beznik T, Lahoud P, Gaëta-Araujo H, et al. Artificial intelligence-driven novel tool for tooth detection and segmentation on panoramic radiographs. *Clinical Oral Investigations*. 2020:1-11.

25.Hiraiwa T, Arijji Y, Fukuda M, Kise Y, Nakata K, Katsumata A, et al. A deep-learning artificial intelligence system for assessment of root morphology of the mandibular first molar on panoramic radiography. *Dentomaxillofacial Radiology*. 2019;48(3):20180218.

26.Li Q, Chen K, Han L, Zhuang Y, Li J, Lin J. Automatic tooth roots segmentation of cone beam computed tomography image sequences using U-net and RNN. *Journal of X-Ray Science and Technology*. 2020;28(5):905-22.

27.Fukuda M, Inamoto K, Shibata N, Arijji Y, Yanashita Y, Kutsuna S, et al. Evaluation of an artificial intelligence system for detecting vertical root fracture on panoramic radiography. *Oral radiology*. 2019:1-7.

28.Kuwada C, Arijji Y, Fukuda M, Kise Y, Fujita H, Katsumata A, et al. Deep learning systems for detecting and classifying the presence of impacted supernumerary teeth in the maxillary incisor region on panoramic radiographs. *Oral Surgery, Oral Medicine, Oral Pathology and Oral Radiology*. 2020;130(4):464-9.

29.Kise Y, Ikeda H, Fujii T, Fukuda M, Arijji Y, Fujita H, et al. Preliminary study on the application of deep learning system to diagnosis of Sjögren's syndrome on CT images. *Dentomaxillofacial Radiology*. 2019;48(6):20190019.

30.Arijji Y, Sugita Y, Nagao T, Nakayama A, Fukuda M, Kise Y, et al. CT evaluation of extranodal extension of cervical lymph node metastases in patients with oral squamous cell carcinoma using deep learning classification. *Oral radiology*. 2020;36(2):148-55.

31.Lee J-S, Adhikari S, Liu L, Jeong H-G, Kim H, Yoon S-J. Osteoporosis detection in panoramic radiographs using a deep convolutional neural network-based computer-assisted diagnosis system: a preliminary study. *Dentomaxillofacial Radiology*. 2019;48(1):20170344.

32.Lee K-S, Jung S-K, Ryu J-J, Shin S-W, Choi J. Evaluation of transfer learning with deep convolutional neural networks for screening osteoporosis in dental panoramic radiographs. *Journal of clinical medicine*. 2020;9(2):392.

33.Xie X, Wang L, Wang A. Artificial neural network modeling for deciding if extractions are necessary prior to orthodontic treatment. *The Angle orthodontist*. 2010;80(2):262-6.

34. Birnbaum NS, Aaronson HB. Dental impressions using 3D digital scanners: virtual becomes reality. *Compend contin educ dent*. 2008;29(8):494-6.
35. Mackin N, Sims-Williams J, Stephens C. Artificial intelligence in the dental surgery: an orthodontic expert system, a dental tool of tomorrow. *Dental update*. 1991;18(8):341-3.
36. Jung S-K, Kim T-W. New approach for the diagnosis of extractions with neural network machine learning. *American Journal of Orthodontics and Dentofacial Orthopedics*. 2016;149(1):127-33.
37. Kunz F, Stellzig-Eisenhauer A, Zeman F, Boldt J. Artificial intelligence in orthodontics. *Journal of Orofacial Orthopedics/Fortschritte der Kieferorthopädie*. 2020;81(1):52-68.
38. Hwang H-W, Park J-H, Moon J-H, Yu Y, Kim H, Her S-B, et al. Automated identification of cephalometric landmarks: Part 2-Might it be better than human? *The Angle Orthodontist*. 2020;90(1):69-76.
39. Yu H, Cho S, Kim M, Kim W, Kim J, Choi J. Automated skeletal classification with lateral cephalometry based on artificial intelligence. *Journal of dental research*. 2020;99(3):249-56.
40. Choi H-I, Jung S-K, Baek S-H, Lim WH, Ahn S-J, Yang I-H, et al. Artificial intelligent model with neural network machine learning for the diagnosis of orthognathic surgery. *Journal of Craniofacial Surgery*. 2019;30(7):1986-9.
41. Flores-Mir C, Nebbe B, Major PW. Use of skeletal maturation based on hand-wrist radiographic analysis as a predictor of facial growth: a systematic review. *The Angle Orthodontist*. 2004;74(1):118-24.
42. Kök H, Acilar AM, İzgi MS. Usage and comparison of artificial intelligence algorithms for determination of growth and development by cervical vertebrae stages in orthodontics. *Progress in orthodontics*. 2019;20(1):1-10.
43. Ruppini J, Popovic A, Strauss M, Spüntrup E, Steiner A, Stoll C. Evaluation of the accuracy of three different computer-aided surgery systems in dental implantology: optical tracking vs. stereolithographic splint systems. *Clinical oral implants research*. 2008;19(7):709-16.
44. Widmann G. Image-guided surgery and medical robotics in the cranial area. *Biomedical imaging and intervention journal*. 2007;3(1).
45. Zhang W, Li J, Li Z-B, Li Z. Predicting postoperative facial swelling following impacted mandibular third molars extraction by using artificial neural networks evaluation. *Scientific reports*. 2018;8(1):1-9.
46. Orhan K, Bilgir E, Bayrakdar IS, Ezhov M, Gusarev M, Shumilov E. Evaluation Of Artificial Intelligence For Detecting Impacted Third Molars On Cone-Beam Computed Tomography Scans. *Journal of Stomatology, Oral and Maxillofacial Surgery*. 2020.
47. Vinayahalingam S, Xi T, Bergé S, Maal T, de Jong G. Automated detection of third molars and mandibular nerve by deep learning. *Scientific reports*. 2019;9(1):1-7.
48. Yoo J-H, Yeom H-G, Shin W, Yun JP, Lee JH, Jeong SH, et al. Deep learning based prediction of extraction difficulty for mandibular third molars. *Scientific Reports*. 2021;11(1):1-9.
49. Le Y, Verdonschot E. Performance of diagnostic systems in occlusal caries detection compared. *Community Dentistry and Oral Epidemiology*. 1994;22(3):187-91.
50. Pine CM, Jaap J. Dynamics of and diagnostic methods for detecting small carious lesions. *Caries research*. 1996;30(6):381-8.
51. Ten Cate J. What dental diseases are we facing in the new millennium: some aspects of the research agenda. *Caries research*. 2001;35(Suppl. 1):2-5.
52. Akpata E, Farid M, Al-Saif K, Roberts E. Cavitation at radiolucent areas on proximal surfaces of posterior teeth. *Caries research*. 1996;30(5):313-6.
53. Heaven T, Weems R, Firestone A. The use of a computer-based image analysis program for the diagnosis of approximal caries from bitewing radiographs. *Caries research*. 1994;28(1):55-8.
54. Duncan RC, Heaven T, Weems Ra, Firestone Ar, Greer Df, Patel Jr. Using computers to diagnose and plan treatment of approval caries detected in radiographs. *The Journal of the American Dental Association*. 1995;126(7):873-82.
55. Wenzel A. Computer-automated caries detection in digital bitewings: consistency of a program and its influence on observer agreement. *Caries research*. 2001;35(1):12-20.
56. Devito KL, de Souza Barbosa F, Felipe Filho WN. An artificial multilayer perceptron neural network for diagnosis of proximal dental caries. *Oral Surgery, Oral Medicine, Oral Pathology, Oral Radiology, and Endodontology*. 2008;106(6):879-84.
57. Schwendicke F, Rossi J, Göstemeyer G, Elhennawy K, Cantu A, Gaudin R, et al. Cost-effectiveness of Artificial Intelligence for Proximal Caries Detection. *Journal of Dental Research*. 2020:0022034520972335.
58. Cantu AG, Gehrung S, Krois J, Chaurasia A, Rossi JG, Gaudin R, et al. Detecting caries lesions of different radiographic extension on bitewings using deep learning. *Journal of Dentistry*. 2020;100:103425.
59. Lee J-H, Kim D-H, Jeong S-N, Choi S-H. Detection and diagnosis of dental caries using a deep learning-based convolutional neural network algorithm. *Journal of dentistry*. 2018;77:106-11.
60. Lang NP, Adler R, Joss A, Nyman S. Absence of bleeding on probing an indicator of periodontal stability. *Journal of clinical periodontology*. 1990;17(10):714-21.
61. Fadel HT, Abu-Hammad O, Ghulam OA, Dar-Odeh N. Are Artificial Neural Networks Useful for Predicting Overhanging Dental Restorations? A Cross-sectional Study. *World*. 2020;11(2):100.
62. Vera V, Corchado E, Redondo R, Sedano J, Garcia AE. Applying soft computing techniques to optimise a dental

milling process. *Neurocomputing*. 2013;109:94-104.

63.Raith S, Vogel EP, Anees N, Keul C, Güth J-F, Edelhoff D, et al. Artificial Neural Networks as a powerful numerical tool to classify specific features of a tooth based on 3D scan data. *Computers in biology and medicine*. 2017;80:65-76.

64.Vecsei B, Joós-Kovács G, Borbély J, Hermann P. Comparison of the accuracy of direct and indirect three-dimensional digitizing processes for CAD/CAM systems in vitro study. *Journal of prosthodontic research*. 2017;61(2):177-84.

65.Kikuchi H, Ikeda M, Araki K. Evaluation of a virtual reality simulation system for porcelain fused to metal crown preparation at Tokyo Medical and Dental University. *Journal of dental education*. 2013;77(6):782-92.

66.Toshihito T, Kazunori N, Tomoya G, Tomoaki M, Kazunori I. Deep learning-based detection of dental prostheses and restorations. *Scientific Reports (Nature Publisher Group)*. 2021;11(1).

67.Lee J-H, Lee J-S, Choi J-K, Kweon H-I, Kim Y-T, Choi S-H. National dental policies and socio-demographic factors affecting changes in the incidence of periodontal treatments in Korean: a nationwide population-based retrospective cohort study from 2002-2013. *BMC Oral Health*. 2016;16(1):1-9.

68.Furman E, Jasinevicius TR, Bissada NF, Victoroff KZ, Skillicorn R, Buchner M. Virtual reality distraction for pain control during periodontal scaling and root planing procedures. *The Journal of the American Dental Association*. 2009;140(12):1508-16.

69.Sohmura T, Kusumoto N, Otani T, Yamada S, Wakabayashi K, Yatani H. CAD/CAM fabrication and clinical application of surgical template and bone model in oral implant surgery. *Clinical oral implants research*. 2009;20(1):87-93.

70.Lee J-H, Kim D-h, Jeong S-N, Choi S-H. Diagnosis and prediction of periodontally compromised teeth using a deep learning-based convolutional neural network algorithm. *Journal of periodontal & implant science*. 2018;48(2):114.

71.Alalharith DM, Alharthi HM, Alghamdi WM, Alsenbel YM, Aslam N, Khan IU, et al. A Deep Learning-Based Approach for the Detection of Early Signs of Gingivitis in Orthodontic Patients Using Faster Region-Based Convolutional Neural Networks. *International Journal of Environmental Research and Public Health*. 2020;17(22):8447.

72.Lim K, Moles D, Downer M, Speight P. Opportunistic screening for oral cancer and precancer in general dental practice: results of a demonstration study. *British dental journal*. 2003;194(9):497-502.

73.Rosmai MD, Sameemii AK, Basir A, Mazlipahiv IS, Norzaidi M. The use of artificial intelligence to identify people at risk of oral cancer: empirical evidence in

Malaysian University. *International Journal of Scientific Research in Education*. 2010;3(1):10-20.

74.Ilhan B, Lin K, Guneri P, Wilder-Smith P. Improving oral cancer outcomes with imaging and artificial intelligence. *Journal of dental research*. 2020;99(3):241-8.

75.Kar A, Wreesmann VB, Shwetha V, Thakur S, Rao VU, Arakeri G, et al. Improvement of oral cancer screening quality and reach: The promise of Artificial Intelligence. *Journal of Oral Pathology & Medicine*. 2020;49(8):727-30.

76.Ariji Y, Fukuda M, Kise Y, Nozawa M, Yanashita Y, Fujita H, et al. Contrast-enhanced computed tomography image assessment of cervical lymph node metastasis in patients with oral cancer by using a deep learning system of artificial intelligence. *Oral surgery, oral medicine, oral pathology and oral radiology*. 2019;127(5):458-63.

77.De Tobel J, Radesh P, Vandermeulen D, Thevissen PW. An automated technique to stage lower third molar development on panoramic radiographs for age estimation: a pilot study. *The Journal of forensic odonto-stomatology*. 2017;35(2):42.

78.Patil V, Vineetha R, Vatsa S, Shetty DK, Raju A, Naik N, et al. Artificial neural network for gender determination using mandibular morphometric parameters: A comparative retrospective study. *Cogent Engineering*. 2020;7(1):1723783.

79.Niño-Sandoval TC, Pérez SVG, González FA, Jaque RA, Infante-Contreras C. Use of automated learning techniques for predicting mandibular morphology in skeletal class I, II and III. *Forensic science international*. 2017;281:187.e1-.e7.

# Eczacılık, Eczacılık Bilimleri ve İlgili Alanlarda Yapay Zekâ Uygulamalarının Kullanımı

*Usage of Artificial Intelligence Applications in Pharmacy, Pharmaceutical Science and its Related Fields*

Beşir Sefa MUMAY<sup>\*1</sup>, Ömrüm ERGÜVEN<sup>2</sup>

## Öz

Teknolojinin gelişmesi ile birlikte değişen meslek şartları, her meslek için yeni tanımlamalar gerektirmiştir. Eczacılık, birçok farklı alanı barındıran multidisipliner çalışmaların mümkün olduğu bir alandır. İlk defa 1960'ta tıptan ayrı bir meslek olarak tanımlanan eczacılık mesleği, 1960'tan sonraki her dönemde, çağın gerektirdiği değişikliklere uğramıştır. Majistral ilaçların hazırlandığı eczane laboratuvarları, müstahzar ilaç sayısının artması, ilaç takip sistemi ve Medula sisteminin eczanelere entegre edilmesi gibi örnekler, eczacılık hizmetinin bulunduğu çağa uymasının bir sonucu olarak yorumlanabilir. Günümüzde, teknolojinin getirdiği değişim zorunluluğu da göz önüne alınınca, hiçbir eczacılık hizmeti teknolojiden bağımsız düşünülemez. Eczacılığın neredeyse her alanında yapay zekâ algoritmaları kullanılabilir. Akılcı ilaç kullanımında, hastane eczanesinde, serbest eczanelerde, ilaç geliştirilmesinde ve üretilmesinde kullanılan yapay zekâ uygulamaları bilinmektedir. Bu çalışmanın amacı; güncel veriler ve literatür ışığında, eczacının sorumluluklarını ve eczacılık uygulamalarını genel olarak değerlendirmek; yapay zekâyı ve yapay zekânın özelliklerini açıklayarak eczacılık alanında kullanılan yapay zekâ uygulamalarına örnekler sunmaktır.

**Anahtar Kelimeler:** Eczacılık, Akılcı ilaç kullanımı, İlaç üretimi, Yapay zekâ, Eczacı

## Abstract

The occupational conditions have been changing with the technology development in each of the profession. Pharmaceutical Science is a field which diverse perspectives are possible with multidisciplinary studies in many of the subjects. Pharmacy profession, which was defined as a separate profession from medicine since 1960 and has undergone changes required by the age in every period after 1960. Examples such as pharmacy laboratories where magistral medicines were prepared; from there an increase in the number of official drugs, arise of the drug tracking system and the integration of the Medula system into pharmacies can be interpreted as a result of the pharmacy service's adaptation to the era. Nowadays, considering the necessity of change brought by technology, no pharmaceutical service can be considered as an independent of technology. Artificial intelligence algorithms have been using in every field of pharmaceutical science. Artificial intelligence applications are used in rational drug use, hospital pharmacy, community pharmacy, drug development and production. The aim of this review is; To evaluate the pharmacist's responsibilities and pharmacy practices in general in the light of current data and literature to explain artificial intelligence and its properties whit current examples of artificial intelligence applications using in pharmaceutical science.

**Key Words:** Pharmaceutical Science, Rational drug use, Pharmaceutical production, Artificial intelligence, Pharmacist

Received / Geliş	11.03.2021
Accepted / Kabul	01.04.2021
Publication Date	18.08.2021

**\*Sorumlu Yazar  
Corresponding Author**

**Beşir Sefa MUMAY**

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

✉ sefamumay@gmail.com

<https://orcid.org/0000-0002-5097-8395>

**Ömrüm ERGÜVEN**

<sup>2</sup>Trakya University,  
Faculty of Pharmacy

<https://orcid.org/0000-0002-1191-0830>



## Introduction

Today, technology is very important in pharmaceutical science as in every profession and in every field of science. Technology is used in almost every field of pharmaceutical science. In some fields of pharmaceutical science, the importance of technology and the opportunities provided by technology are more from others:

- Rational drug use,
- Treatment, drug, and vaccine development studies,
- Pharmacy services,
- Hospital pharmacy,
- Patient data collection and storage (1-3).

In this review article, the concepts of pharmaceutical science and artificial intelligence are explained, and artificial intelligence applications used in pharmaceutical science have been reviewed. Among the duties and responsibilities of pharmacists, those related to technology were discussed. The advantages and disadvantages of using artificial intelligence applications in pharmaceutical science were discussed.

## Duties and responsibilities of pharmacists

A pharmacist is a person who has successfully completed 4-8 years of education, which varies according to countries, knows the pathways art of drug preparation and presentation, and can train the patient for drug use (4). Generally, pharmacies are the last place patients stop by before using the drug, and therefore the pharmacist is the last person they consult before using the drug. Members of this critical profession, pharmacists, have duties and responsibilities towards medicine, patients and society. The duties and responsibilities of pharmacists are given in Table 1 (4-6). Some parts of this table can be improved and modified using technology. It is important to benefit from technology in issues that cause worldwide problems, deaths, and high costs, such as rational drug use.

## Artificial intelligence (AI)

AI systems can be considered simply as a two-stage system: In the first stage, it understands the thinking and decisionmaking mechanism of the human mind; In the second stage, it repeats these mechanisms autonomously. The definition of the concept of artificial intelligence is defined as "Digital technology and/or applications that have the ability to imitate human beings, interact, learn, adapt and apply by expanding their experience" (7). The concept of AI was brought to the agenda for the first time by Turing in the 1950s and the possibility of a machine to think like a human is philosophically discussed (8).

AI algorithms have the ability to understand experiences, evaluate the results, and identifies the similarities between different situations (9). In the literature review, it was seen that different subcategories were used together with the

concept of AI. AI can be examined under three subcategories; Rule-based AI (Expert Systems, Decision Support Systems, etc.), Decision-maker AI (Genetic Algorithm Code, Text Mining, etc.), and Learning AI (Artificial Neural Networks, Deep Learning, etc.) (10-12). The explanations and details of the sub categorization of AI are given in Table 2 (12-20).

## Artificial intelligence applications in pharmaceutical science

### 1. Artificial intelligence in rational drug use

According to the definition of the World Health Organization (WHO), rational drug use is a set of rules that enable patients to take drugs in accordance with their clinical needs, in doses to meet their personal needs, in sufficient time, and at the lowest cost to themselves and to the society (6). This definition is put into practice in the form of the right medicine, the right dose, the right time, the right patient, the appropriate cost, the right follow-up, the right information, and the documentation (4).

Advice on rational drug use is generally obtained from healthcare professionals in Turkey. However, sometimes due to lack of time, sometimes due to excessive intensity, healthcare professional may not be able to make the necessary warnings. The use of AI algorithms can contribute to rational drug use by helping healthcare professionals at this point.

### Artificial intelligence applications in detecting interactions:

Drug-drug and drug-nutrient interactions are very risky and can be fatal. In a study, death due to drug-drug interaction was detected in 6.7% of hospitalized patients. The cost of deaths due to undesirable effects to the USA is 136 billion dollars annually (21). Systems created by using ES and ANN have begun to use to prevent interactions. Expert systems can provide the following features:

- 1- Comparing the compatibility of drugs,
- 2- Active ingredient control,
- 3- Medication possible side effects control,
- 4- Drug-nutrient interaction control,
- 5- Examination of drug prospectuses,
- 6- Side effects and disease symptoms control (9).

These data, which are evaluated by expert systems, are presented to the user as information. If the patient enters the drugs to be used in the system, patient sees information that the active substances and nutrient interactions are evaluated by databases (9).

Supplement X is a project in the production stage by Pharmaino established in Turkey. Supplement X is the pharmacy kiosk system that will analyze the drugs people have used and the diseases they have by artificial intelligence and then make suggestions. The purpose of SupplementX is to ensure the rational use of supple-ments (22).




Figure 1. Artificial Intelligence, Machine Learning and Deep Learning Titles

#### · Artificial intelligence applications in providing patient compliance:

Patient compliance is to comply with what needs to be done for the treatment. Presence of compliance ensures maximum benefit from drug therapy. Communication between the doctor and pharmacists with the patient is very important. There is a direct relation between compliance and rational drug use (5).

Based in the United States of America (USA), the AiCure application works with an AI algorithm connected to the phone camera to check the accuracy of the medication used and the accuracy of the time used. The camera first recognizes the drug and then alerts the person by sending a notification when the time of use of the drug comes (23, 24). Thus, it helps the patient and the healthcare professional in the right time and the right medication titles. In another example, the interactions of drugs with other drugs are detected with the AI algorithm, helping healthcare professionals and preventing the patient from being harmed (9). Thus, the correct information is provided. In another example, through AI algorithms, the patient's information is processed, critical dose calculation is made, and healthcare professionals are supported to make more precise decisions on this issue (25). Thus, the correct dose will be provided.

SuperPharmacist is a mobile application in software stage designed by Pharmaino. It offers patients a personal treatment scheme with AI and enables patients to get the maximum efficiency from drugs (22).

#### · Artificial intelligence applications in the rational use of antibiotics and antivirals:

Unnecessary or incorrect use of antibiotics in Turkey as in other countries is a common problem. Misuse of antibiotics causes many health problems, especially resistance development (26). This problem has been recognized as a global risk by the WHO. AI was used for rational use of antibiotics and antivirals.

FluAI is a mobile application made by Yesil Science from Turkey. Users with symptoms such as throat ache and fever, after answering the questions, take a picture of their throat and upload it to the application. The photograph and the anamnesis given are evaluated by the artificial intelligence and tells the user that the infection is bacterial or viral over a percentage (27).

Researchers at Massachusetts Institute of Technology's (MIT) Computer Science and Artificial Intelligence Laboratory (CSAIL) announced that they developed a recommendation algorithm that predicts the likelihood that a patient's urinary tract infection will be treated with first or second-line antibiotics. It claims its models, trained with data from more than 10,000 patients, will allow clinicians to reduce second-line antibiotic use by 67 percent (28).

Using IDentif.AI, a team at the National University of Singapore identified combinations of antivirals that could be used in treatment of Covid-19 using AI algorithms. In the combinations, the combination of lopinavir/ritonavir was found to be relatively ineffective against Covid-19, while remdesivir alone was not found to be highly effective, it was found that taking lopinavir/ritonavir and remdesivir in combination inhibited the replication of the virus. Experiments have also supported these findings (29).

#### 2. Treatment, drug, and vaccine development studies

Drug development and production is not an easy task. A pharmaceutical company can take as long as 12-14 years to develop a new drug, and it can cost up to \$ 2.6 billion. One of the biggest advantages of AI is that it reduces the time required for drug development and in turn reduces the costs associated with drug development. A lot of research is being done to improve present AI technology to make the pharmacy profession more efficient (30).

Sanofi has signed an agreement to research the United Kingdom-based Exscientia's AI platform to research metabolic disease treatments, and Genentech is using an AI system created by GNS Healthcare in Cambridge, Massachusetts to help research cancer treatments. It appears that the largest biopharma companies go for similar collaborations (31).

According to a study, a library of small peptides with broad spectrum antibiotic activity was created and integrated with ANN. Thus, silico models representing antibiotic activity were created. When randomly generated samples

were examined, it was observed that the activity of peptides predicted by AI was very high. It has also been shown that the predicted peptides are highly effective against multiple superbugs which are multidrug resistant and have activities equal to or even better than the four of the most commonly used antibiotics. It was also observed to be effective against *Staphylococcus aureus* infections when tested in animal models (30).

Vaccine development is one of the most difficult parts of drug development. AI methods and systems biology approach have the potential to reduce failures while increasing efficiency and speeding up the development process (7). In 2020, humanity faced a pandemic that changed our lives and caused the death of many people. Governments and healthcare organizations are constantly working to combat the disease. Many scientists benefit from AI, especially in the development of vaccines and antivirals. Artificial intelligence can help as an effective tool to study the virus and its capabilities, virulence, and genome. It can also help predict the protein structure of the virus and its interaction with other chemical compounds (32).

Manufactured by IBM with AI technology, the Watson computer is designed for oncologists to make better decisions in cancer treatment. It functions by analyzing a patient's medical information from a wide network of data and expertise, and then offering treatment options based on the evidence obtained (30). Watson is also used in researching oncology drugs, selecting the correct pharmacophore groups, and evaluating the three-dimensional structures of molecules (33).

University of California San Francisco (UCSF) Medical Center uses robotic technology integrated with AI for the preparation and follow-up of medicines to increase the safety of patients. It has been observed that the robot, which works with AI technology, prepares 3,5 millions drug doses without error (34).

The MEDi Pain Control Robot was developed as part of a project led by Tanya Beran, Professor of Community Health Sciences at the University of Calgary in Alberta. This robot first establishes a relationship with the children and then tells them what to expect during a medical procedure. Provides guidance on how to breathe and cope with their fears during the medical procedure. MEDi can speak 20 different languages by taking data of Google Translate (35).

BERG is a biotechnology-based pharmaceutical company that uses AI in drug discovery. The company uses artificial intelligence technology to find various biomarkers that cause disease, verify them, and then decide treatments based on the data obtained. The company's goal is to speed up the drug discovery process and achieve a cost reduction with the help of AI (30).

### 3. Artificial intelligence applications in pharmacy services

There are different machine learning algorithms created for prediction purpose. One of the biggest problems in the field of health is to evaluate all illnesses of the patient when a patient comes to the pharmacy. ML algorithms can be used to accurately predict diseases and the most appropriate medication for that disease. The pharmacist can provide the




Figure 2. Example of Artificial Neural Networks (20)

effective medication to the patient with the help of machine learning prediction algorithms, instead of delivering the known drug. In addition, management can be achieved through ML algorithms in stock management (1).

Traditional pharmaceutical practices include categorizing medications manually, creating dosages, and tailoring medicines to patients' needs. Pharmacists spend a lot of time doing these tasks. The presence of robotic pharmacies in drug preparation is used to perform all these activities such as mixing, categorizing, and sealing drugs with minimal human intervention. There are automation systems in robotic pharmacies and systems such as ML, DL and Natural Language Processing (NLP) are used in this system according to the desired feature (36). The advantages of robotic and automation systems can be listed as follows (1):

- It is efficient. A pharmacy robot can fill and organize a large number of medications without any human intervention and without any mistakes. In addition to increasing the efficiency of operations, this also enables pharmacists to perform more value-added tasks.

- Creates an error-free environment for medical distribution. Human errors can be reduced with robots. "Once you program the robot to do the right thing, it always does the same thing over and over," says Rita Jew, UCSF Hospital Pharmacy Manager.

- It's safe. In a robotic pharmacy, medicines are securely stored in dispensing machines. With good security, the probability of drug theft or error is significantly reduced.

- There is a decrease in the waiting time of the patients. Robotic systems can meet thousands of prescriptions and fill desired drugs very quickly.

- It reduces risks in the sterile environment. Robotic pharmacies minimize microorganism contact in a sterile environment.

Robot Charlie, which is being used in some pharmacies in Germany, is involved in customer welcoming and sales. While hosting the customer, it communicates directly and directs it to the products on the shelves. It can give simple information and advice taught by its pharmacist. If the customer comes with a more complex problem or with a prescription, they can refer the person to the pharmacist or pharmacy staff. According to the feedback received from customers, the presence of Robot Charlie in the pharmacy makes customers and patients feel more comfortable (37). Robotic pharmacists can provide high efficiency in terms of workflow, reduce medication errors, provide drug delivery safety, minimize drug waste, and provide a sterile environment for the patient. On the other hand, it costs a lot and it can minimize human contact and needs to be updated frequently.

#### **4. Artificial intelligence applications used in hospital pharmacy**

##### **· Data collection and processing**

The digitalization of health and medicine, the increased availability of Electronic Health Records (EHRs) has encouraged healthcare professionals and clinical researchers to adopt the latest methodologies in the field of artificial intelligence to take advantage of the large medical databases available. More than 75% of hospital pharmacists in the USA use data mining functions to regularly document and collect patient-centered data. These include important information regarding drug safety, drug history, and therapeutic outcomes (2).

Patients' EHRs contain a large amount of valuable information, including drug history, adverse drug reactions, interactions, medication errors, and pharmacokinetics. Results are achieved through a combination of NLP and machine learning techniques. The information processed by deep learning classification methods that are fed and learned from the large amount of data in the EHR is then structured by artificial neural networks. Thus, clinical pharmacists can easily use a large number of data for patients (2).

##### **· Artificial intelligence in drug preparation and drug delivery methods in hospital pharmacies:**

Robot pharmacists are used in the preparation of chemotherapy drugs in an oncology unit in a hospital in China. These robots can minimize pharmacists' exposure to cytotoxic drugs. It can prepare 10-15 bags of chemotherapy drug per hour (38).

United Arab Emirates (UAE) opened its first "robot pharmacy" at Rashid Hospital in Dubai. It is the first time a robot is being used in the UAE to dispense prescription drugs by clicking a button based on a barcode. This robot can store up to 35,000 drugs and can enter approximately 12 prescriptions in less than a minute (38).

The University of Maryland Medical Center (UMMC) uses robotic technology to deliver medicines from pharmacies to patient care units. After the implementation of the robotic delivery system, the time from fax to label, order preparation time and idle time of the drugs to be delivered decreased, while nurses' overall satisfaction with the pharmacy and the reliability of pharmacy delivery increased significantly (39).

##### **Ethical Considerations**

The advancement of technology in healthcare has many benefits, but there are some situations that need to be considered. Patient rights and ethics are a very important issue in the age of technology in health. Although the number of errors decreases, it is not possible to be zero. It should be determined who will be responsible in case of an error. When an error occurs, it should be investigated forensic. The responsible person should also be responsible for the

technology used in the errors accepted as malpractice. However, it is very difficult to detect technology-related problems. It is also debatable to what extent it would be possible or correct to take some strict measures in this regard (40). Another disadvantage is that patients do not adopt AI-based healthcare adequately. The patient should be able to choose the treatment from among the options. The decision should be made by the patient, even if there is guidance by the doctor about treatment. This situation will decrease as the usefulness of AI is proven.

### Conclusion and discussion

It is estimated that the contribution of AI technologies to the global economy between 2020 and 2030 will be 15 trillion US Dollars (41). Even if this estimate is approached, considerably high amounts will be involved. Therefore, as Turkey, we should not fall behind, not depend on the outside, understand AI, and create our domestic and national AI algorithms.

Pharmaceutical science has developed considerably from past to present and continues to develop. It is possible to divide these periods as Pharmaceutics 1.0, Pharmaceutics 2.0, Pharmaceutics 3.0 and Pharmaceutics 4.0. Pharmaceutics 1.0 represents the use of herbal drugs for diseases, Pharmaceutics 2.0 represents the transition from the herbal period to the chemical production period, and Pharmaceutics 3.0 represents the use of an era-opening technology such as the internet in the field of pharmaceutics. Pharmaceutics 4.0 is a new concept, and it will develop the health technologies for future. As humanity know from the definition of Industry 4.0, disruptive technologies such as AI have begun to have a say in the industry. Today, machine-human cooperation in the industry can manage well. The concept of Pharmaceutics 4.0 has emerged with the use of destructive technologies in many stages from the production of drugs to their presentation to the patient. This concept continues today. Pharmacists who working in the period of Pharmaceutics 4.0 should have the competencies to fulfill the requirements of the age, that is, they should be closely interested in technology and use this technology to benefit their profession.

Using of different AI algorithms can contribute to different topics of the pharmaceutical science. However, pharmacists are essential for all topics at the same time.

**Disclosure:** none

**Financial support:** none

**Author contributions:** B.S.M., Ö.E.

**Motivation/Concept:** BM, ÖE

**Study Design:** BM, ÖE

**Control/Surveillance:** BM, ÖE

**Data Collection and/or Processing:** BM, ÖE

**Analysis and/or Interpretation:** BM, ÖE

**Literature Review:** BM, ÖE

**Manuscript Writing:** BM, ÖE

### References

- 1- Donepudi PK. AI and Machine Learning in Retail Pharmacy: Systematic Review of Related Literature. *ABC Journal of Advanced Research*. 2018 Nov;7(2):109-112. doi: 10.18034/abcjar.v7i2.514
- 2- Rio-Bermudez CD, Medrano IH, Yebes L, Poveda JL. Towards A Symbiotic Relationship Between Big Data, Artificial Intelligence, and Hospital Pharmacy. *J of Pharm Policy and Pract*. 2020 Nov;13:75. doi: 10.1186/s40545-020-00276-6
- 3- Nelson SD, Walsh CG, Olsen CA, McLaughlin AJ, LeGrand JR, Schutz N, Lasko TA. Demystifying artificial intelligence in pharmacy. *American Journal of Health-System Pharmacy*. 2020 July;77(19):1556–1570. doi: 10.1093/ajhp/zxaa218
- 4- Türkiye İlaç ve Tıbbi Cihaz Kurumu. Eczacılar ve Eczaneler Hakkında Yönetmelik [internet]. Turkey, 28970 Sayılı T.C. Resmi Gazetesi; 2014 Apr [cited 2020 Dec 12]. Available from: <https://www.resmigazete.gov.tr/eskiler/2014/04/20140412-14.htm>
- 5- Toklu HZ, Akıcı A, Keyer Uysal M, Dülger G. Akılcı ilaç kullanımını sürecinde hasta uyuncuna hekim ve eczacının katkısı. *Türkiye Aile Hekimliği Dergisi*. 2010 June;14(3):139-145. doi: 10.2399/tahd.10.139
- 6- World Health Organization (WHO). New tool to enhance role of pharmacists in health care [internet]. Switzerland, WHO; 2006 Nov [cited 2020 Dec 12]. Available from: <https://www.who.int/mediacentre/news/new/2006/nw05/en/#:~:text=The%20role%20of%20the%20pharmacist,of%20researcher%20has%20been%20added>.
- 7- 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>
- 8- 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
- 9- Atav A. İlaçların diğer ilaçlar ile etkileşimlerinin uzman sistem ile belirlenmesi [master thesis]. [İstanbul (Turkey)]: Maltepe University, 2020.
- 10- 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
- 11- 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
- 12- 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
- 13- Turban E, Aronson JE, Liang TP. *Decision Support System And Intelligent System*, 7th ed., Prentice Hall Inc, New Jersey, 2005. p.300-357.
- 14- Turban E. *Decision Support and Expert Systems*:

Management Support Systems, 4th ed., Prentice Hall Inc, New Jersey, 1995, p435-675.

15- 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

16- Kobayashi VB, Mol ST, Berkers HA, Kismihók G, Den Hartog DN. Text Mining in Organizational Research. *Organizational Research Methods*. 2018 Aug;21(3):733-765. doi: 10.1177/1094428117722619

17- Sevli O, Başer VG. Covid-19 Salgımına Yönelik Zaman Serisi Verileri ile Prophet Model Kullanarak Makine Öğrenmesi Temelli Vaka Tahminlemesi. *Avrupa Bilim ve Teknoloji Dergisi*. 2020 Aug;19:827-835. doi: 10.31590/ejosat.766623

18- Pesapane F, Volonté C, Codari M, Sardanelli F. Artificial intelligence as a medical device in radiology: ethical and regulatory issues in Europe and the United States. *Insights into imaging*. 2018 June;9(5):745-753. doi: 10.1007/s13244-018-0645-y

19- Lipmann RP. An Introduction to Computing with Neural Nets. *IEEE ASSP Magazine*. 1987 Apr;4(2):4-22. doi: 10.1109/MASSP.1987.1165576.

20- Bre F, Gimenez JM, Fachinotti VD. Prediction of wind pressure coefficients on building surfaces using artificial neural networks. *Energy and Buildings*. 2018 Jan;158:1429-1441. doi: 10.1016/j.enbuild.2017.11.045

21- Hardalaç F, Kutbay U. İlaç İlaç Etkileşimlerinin Jordan Elman Ağları Kullanılarak Sınıflandırılması. *Journal of the Faculty of Engineering and Architecture of Gazi University*, 2014 Mar;29(1):149-154. doi: 10.17341/gummfd.87747

22- Pharmaino. About Pharmaino [internet]. Turkey, Pharmaino Science; 2020 Nov [cited 2021 Jan 07]. Available from: [www.pharmaino.com](http://www.pharmaino.com)

23- AiCure Company. About AiCure [internet]. USA, AiCure LLC; 2019 Oct [cited 2021 Jan 03]. Available from: [www.aicure.com/company](http://www.aicure.com/company)

24- Labovitz DL, Shafner L, Reyes Gil M, Virmani D, Hanina A. Using Artificial Intelligence to Reduce the Risk of Nonadherence in Patients on Anticoagulation Therapy. *Stroke*. 2017 Apr;48(5):1416–1419. doi: 10.1161/STROKEAHA.116.016281

25- Özgüven Öztornacı B, Başbakkal ZD. İlaç hatalarının önlenmesinde yeni dizayn edilmiş karar destek sistemi örneği: web tabanlı ilaç uygulama ve doz hesaplama programı [internet]. Turkey, Uluslararası Sağlıkta Yapay Zekâ Kongresi Bildiri Kitabı; 2020 Jan [cited 2021 Jan 11]. Available from: [sagliktayapayzeka2020.org](http://sagliktayapayzeka2020.org)

26- Aydın M, Koyuncuoğlu CZ, Kılboz MM, Akıcı A. Diş Hekimliğinde Akılcı Antibiyotik Kullanımı. *Türkiye Klinikleri J Dental Sci*. 2017 Aug;23(1):33-47. doi: 10.5336/dentalsci.2015-47189

27- Yesil Science, About Yesil Science [internet]. Turkey, Yesil Science A.Ş.; 2020 Feb [cited 2021 Jan 07]. Available from: <https://www.yesilscience.com>

28- Stokes JM, Yang K, Swanson K, Jin W, Cubillos-Ruiz A, Donghia NM, MacNair CR, French S, Carfrae LA, Bloom-Ackermann Z, Tran VM, Chiappino-Pepe A, Badran AH, Andrews LW, Chory EJ, Church GM, Brown ED, Jaakkola TS,

Barzilay R, Collins JJ. A Deep Learning Approach to Antibiotic Discovery. *Cell*. 2020 Feb;180(4):688-702. doi: 10.1016/j.cell.2020.01.021

29- Abdulla A, Wang B, Qian F, Kee T, Blasiak A, Ong YH, Hooi L, Parekh F, Soriano R, Olinger GG, Keppo J, Hardesty CL, Chow EK, Ho D, Ding X. Project IDentif.AI: Harnessing Artificial Intelligence to Rapidly Optimize Combination Therapy Development for Infectious Disease Intervention. *Advanced Therapeutics*. 2020 Apr;3:2000034. doi: 10.1002/adtp.202000034

30- Vyas M, Thakur S, Riyaz B, Bansal KK, Tomar B, Mishra V. Artificial Intelligence: The Beginning of a New Era in Pharmacy Profession. *Asian Journal of Pharmaceutics*. 2018 June;12(2):72-76. doi: 10.22377/AJP.V12I02.2317

31- Fleming N. How artificial intelligence is changing drug discovery. *Nature*. 2018 May;557(7707):55-57. doi: 10.1038/d41586-018-05267-x.

32- Kannan S, Subbara K, Ali S, Kannan H. The Role of Artificial Intelligence and Machine Learning Techniques: Race for COVID-19 Vaccine. *Arch Clin Infect Dis*. 2020 April;15(2):103232. doi: 10.5812/archcid.103232.

33- IBM. Artificial intelligence in medicine [internet]. USA, IBM Watson Health; 2020 Oct [cited 2021 Jan 28]. Available from: <https://www.ibm.com/watson-health/learn/artificial-intelligence-medicine>

34- Khatib MME, Ahmed G. Robotic pharmacies potential and limitations of artificial intelligence: a case study. *International Journal of Business Innovation and Research*. 2020 Oct;23(3):298-312. doi: 10.1504/IJBIR.2020.110972

35- Farrier CE, Pearson JD, Beran TN. Children's fear and pain during medical procedures: A quality improvement study with a humanoid robot. *Canadian Journal of Nursing Research*. 2019 July;1-7. doi: 10.1177/0844562119862742

36- Shekhar SS. Artificial Intelligence in Automation. *International Journal of Multidisciplinary*. 2019 June;4(6):14-17. doi: 10.5281/zenodo.3247197

37- Stafford RQ, MacDonald BA, Jayawardena C, Wegner DM, Broadbent E. Does the robot have a mind? Mind perception and attitudes towards robots predict use of an eldercare robot. *International journal of social robotics*. 2014 Jan;6(1):17-32. doi: 10.1007/s12369-013-0186-y

38- Zhou F, Wang X, Goh M. Fuzzy extended VIKOR-based mobile robot selection model for hospital pharmacy. *International Journal of Advanced Robotic Systems*. 2018 Aug;15(4):1729881418787315. doi: 10.1177/1729881418787315

39- Summerfield MR, Seagull FJ, Vaidya N, Xiao Y. Use of pharmacy delivery robots in intensive care units. *American Journal of Health-System Pharmacy*. 2011 Jan;68(1):77–83. doi: 10.2146/ajhp100012

40- Hayran O. Yeni Tıp Teknolojilerinin Kullanımı ve Etik Sorunlar. *Journal of Biotechnology and Strategic Health Research*. 2019 Aug;3(2):54-60. doi: 10.34084/bshr.539032

41- Wirtz BW, Weyerer JC, Geyer C. Artificial Intelligence and the Public Sector - Applications and Challenges. *International Journal of Public Administration*. 2018 July;42(7):596-615. doi: 10.1080/01900692.2018.1498103

**Table 1.** Duties and Responsibilities of the Pharmacist

<b>Title</b>	<b>Explanation</b>
Providing Medication	Medications that must be available in the pharmacy must be kept in stock.
Reporting Drug Analysis	Analysis reports can be prepared in case of a problem regarding the content and/or formulation of drugs.
Pharmacovigilance Statements	The pharmacist is obliged to report when there are situations that need to be reported to Turkey Pharmacovigilance Center while monitoring the patient.
Medication Distribution	Medicines must be provided, stored, and presented under appropriate conditions.
Recommending Medication	Medication recommendations can be made if necessary ordered, in accordance with the needs and health status of the patient.
Patient Monitoring	It is necessary to follow up both the patient and the drug use in the long-term treatment of patients for the chronic diseases.
Cooperation with The Doctor	Communication is important to resolve prescription or patient-related problems.
Patient Care	Since the last person the patient speaks to before taking the drugs is usually a pharmacist, disease education, understanding of what the drugs are given and how they should be used are the most important factors that increase compliance in the treatment.
Patient Education	Pharmacists who gain the trust of patients on health-related issues should inform people periodically.
Reporting Drug Use Habits	Statistical analysis and evaluation of these data is the responsibility of the pharmacist. It is important for public health to keep regular records and to present them when requested by the relevant authorities.
Staff Education	The pharmacist carries out the task distribution of its staff and pharmacy faculty interns, supervises, and coordinates their work.

**Table 2.** Explanations and Details of the Subcategorization of AI

<b>Rule Based AI</b>	<b>Expert systems (ES)</b>	ES using AI algorithms on the basis of the decision mechanism are defined as "The information is ready to be processed or combined with the machine after it is processed" (13, 14). ES interpret the information obtained from experts using AI algorithms and output to non-experts. An ES includes four basic parts: database, exit mechanism, forward chaining mechanism and user interface (15).
<b>Decision-maker AI</b>	<b>Text Mining (TM)</b>	TM is defined as the discovery and extraction of new information from unstructured text (Kao & Poteet). Unlike computer-aided text analysis, which is widely used in this field, instead of extracting information based on word/term repetitions, TM usually makes use of other textual features such as grammar and uses natural language processing, computational linguistics, corpus linguistics, machine learning, and statistical techniques (16).
<b>Learning AI</b>	<b>Machine learning (ML)</b>	<p>ML is an algorithm that provides self-learning and improvement with the results obtained from the presented data or based on previous solutions. It is based on mathematical and statistical results (12). It is aimed for machines to make inferences and make decisions by evaluating the data and experiences (17). There are multiple ways to teach a machine the desired information. These are:</p> <ul style="list-style-type: none"> <li>• <i>Supervised learning</i>: In this method, machines are trained using data containing targeted results.</li> <li>• <i>Unsupervised learning</i>: There is no need for an additional promotional tool in this method. The machine alone classifies by extracting meanings from the data.</li> <li>• <i>Reinforcement learning</i>: In this method, the concept of 'Agent' is available. The aim of the agent is to achieve the goal by experimenting with trial and error. With the gamification method, it learns by getting reward for correct moves and punishments for wrong moves.</li> </ul>
	<b>Deep learning (DL)</b>	Deep learning is the sub-category of ML. The relationship between AI, ML, and DL concepts is shown in Figure 1. DL is a very useful method especially for the recognition and interpretation of images. It has a large number of data entries and automatically learns the distinguishing features (18). The biggest disadvantage of deep learning method is that all algorithms need big data.
	<b>Artificial neural networks (ANN)</b>	Artificial Neural Networks are systems that imitate biological neural networks (19). ANN performs the desired tasks by learning from the examples given. In ANN systems, input passes the information through the layer and interprets it as output. The structure of these systems is shown in Figure 2 (20).



# SAĞLIK BİLİMLERİNDE YAPAY ZEKA



Journal of Artificial Intelligence in Health Sciences