

Yıl / Year: 2 Sayı / Number: 3 2022

SAĞLIK BİLİMLERİNDE YAPAY ZEKA

Journal of Artificial Intelligence in Health Sciences

DERGİSİ

ISSN: 2757-9646

Dergi Sahibi & Kurucu / Owner

Doç. Dr. Ali Murat Koç
İzmir Katip Çelebi Üniversitesi Tıp Fakültesi

Baş Editör / Editor-in-Chief

Doç. Dr. 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
akanaydin@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
muminalpererdoğan@ikcu.edu.tr

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

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

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

Dr. Öğr. Üyesi Can Özlü
Kütahya Sağlık Bilimler 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 Ağah 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
cemalkavasogullari@neu.edu.tr

Hukuk Editörü / Law Editor

Dr. Başak Ozan Özparlak
Özyeğin Üniversitesi Hukuk Fakültesi
basakozan@ozyegin.edu.tr

SAĞLIK BİLİMLERİNDE YAPAY ZEKA DERGİSİ

2022
CİLT / VOLUME : 2
SAYI / ISSUE: 3

Sağlık Bilimlerinde Yapay Zekâ Dergisi yaym dil 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 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.

©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 Mesleki İlkeleri'ne uymaktadır

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

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 Sistemler

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. Erhan AKDOĞAN
*Türkiye Sağlık Enstitüleri Başkanlığı
(TÜSEB) Başkanı*

Prof. Dr. Mutlu AVCI
*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 KAHVECİ
*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 / Dış Hekimliği
Prof. Dr. Süleyman Sevinç
Bilgisayar Mühendisliği*

Prof. Dr. Süleyman SEVİNÇ
Bilgisayar Mühendisliği

Prof. Dr. Atadan TUNACI
İstanbul Üniversitesi / Radyoloji

Prof. Dr. Songül VARLI
*TÜYZE (Türkiye Sağlık Veri
Araştırmaları ve Yapay Zeka
Uygulamaları Enstitüsü) Başkanı*

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

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

Doç. Dr. Murat CEYLAN
*Konya Teknik Üniversitesi / Elektrik-
Elektronik Mühendisliği*

Doç. Dr. Süleyman Ayhan ÇALIŞKAN
Ege Üniversitesi / Tıp Eğitimi

Doç. Dr. Gökhan Bora ESMER
*Marmara Üniversitesi / Elektrik-
Elektronik Mühendisliği*

Doç. Dr. Esin ÖZTÜRK IŞIK
*Boğaziçi Üniversitesi / Biyomedikal
Mühendisliği*

Dr. Öğr. Üyesi Mehmet Emin AKTAN
*Türkiye Sağlık Veri Araştırmaları ve
Yapay Zeka Uygulamaları Enstitüsü*

**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
*Nişantaşı Üniversitesi, Mühendislik-
Mimarlık Fakültesi*

Öğr. Gör. Dr. Murat GEZER
İstanbul Üniversitesi / Enformatik

Uzm. Dr. Nevit DİLMEN
Sonomed / Radyoloji

Uzm. Dr. Mehmet Ali GEDİK
*Kütahya Sağlık Bilimleri Üniversitesi /
Radyoloji*

Uzm. Dr. Sedat İRGİL
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 YEŞİL
İstanbul Üniversitesi / Tıbbi Biyokimya

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

Emel GÜMÜŞ
*İstinye Üniversitesi / Sağlık Kurumları
İşbirliği Koordinatörü*

İçerikler/Contents

ARAŞTIRMA MAKALESİ/Research Article

Sağlık Ekosisteminde Yapay Zeka Kaygı Düzeyi: Hemşire
Örneklemi 1-7

ARAŞTIRMA MAKALESİ/Research Article

CPV Tahmininde Makine Öğrenme Yöntemlerinin
Performanslarının Değerlendirilmesi: Farklı Bölgeler ve
Parametreler ile Büyük Veri Uygulaması 8-18

ARAŞTIRMA MAKALESİ/Research Article

İç Kalite Kontrol Süreçlerinde Geçmiş ve Gelecekteki Kontrol
Dışı Olayları Tahmin Etmede Yeni Bir Paradigma:
Makine Öğrenimi için Gaussian Modeli 19-26

Sağlık Bilimlerinde Yapay Zeka Dergisi

Journal of Artificial Intelligence in Health Sciences

Sağlık Ekosisteminde Yapay Zeka Kaygı Düzeyi:
Hemşire ÖrneklemiThe Level of Artificial Intelligence Anxiety in the Health Ecosystem:
A Sample of NursesEmel GÜMÜŞ*¹, Ece UYSAL KASAP²

Özet

Amaç: Bu araştırma, Türkiye’de çalışan hemşirelerin sağlık ekosisteminde yapay zeka kaygı düzeylerini belirlemek amacıyla yapılmıştır.

Gereç ve Yöntem: Tanımlayıcı tasarımda olan araştırmanın evreni, Türkiye’de çalışan hemşireler, örneklemini ise araştırmayı kabul eden 215 hemşire oluşturmuştur. Araştırma verileri, demografik ve mesleki özellikler formu ve Yapay Zeka Kaygı ölçeği ile toplanmıştır. Araştırma verileri, tanımlayıcı istatistikler ve çoklu lineer regresyon analizi ile değerlendirilmiştir.

Bulgular: Çalışmaya katılan hemşirelerin Yapay zeka kaygı düzeyi ortalama puanı 2,64 (SS=0,79) olduğu belirlenmiştir. Kişilerin yaş, cinsiyet, yaşadığı yer, eğitim, çalıştığı kurum, çalıştığı birim, çalıştığı pozisyon, çalışma şekli, meslekte deneyim süresi ve çalışılan hastane-deki deneyim süresi durumları ile yapay zeka kaygı durumları arasında istatistiksel olarak anlamlı bir farklılık gözlemlenmemiştir.

Sonuçlar: Çalışma sonucunda, hemşirelerin öğrenme durumu arttıkça yapay zeka yapılandırma durumunda artış meydana geldiği gözlemlenmiştir. Kişilerin iş değiştirme durumu arttıkça yapay zeka yapılandırma durumunda artış meydana geldiği ve kişilerin yapay zeka kaygı düzeyi durumu arttıkça en yüksek artış meydana gelen alt faktörün yapay zeka yapılandırma olduğu gözlemlenmiştir. %95 güven seviyesinde pozitif yönlü çok yüksek dereceli anlamlı bir ilişki olduğu değerlendirilmiştir. Elde edilen sonuçların daha büyük örneklerde ve daha farklı boyutlar eklenerek çalışılması önerilmektedir.

Anahtar kelimeler: Yapay zeka, Hemşirelik, Hemşirelikte yapay zeka, Yapay zeka kaygı

Abstract

Aim: This research was conducted to determine the level of artificial intelligence anxiety in the health ecosystem of nurses working in Turkey

Materials and Method: The universe of the descriptive research was composed of nurses working in Turkey and the sample was composed of 215 nurses who accepted the research. The research data were collected with the demographic and occupational characteristics form and the

Received / Geliş	04.12.2022
Accepted / Kabul	27.12.2022
Publication Date	30.12.2022

*Sorumlu Yazar
Corresponding Author

Emel GÜMÜŞ*¹

İstinye Üniversitesi,
İstanbul Türkiye

ORCID iD: 0000-0002-3313-6831
e posta: emellgumus@gmail.com

Ece UYSAL KASAP²

İstanbul Üniversitesi Cerrahpaşa,
İstanbul Türkiye

ORCID iD: 0000-0001-8973-0904

Çıkar Çatışması

Yazarlar herhangi bir çıkar çatışması veya finansal destek bildirmemişlerdir.

Finansman

Bu çalışmada finansal destek alınmamıştır.

Teşekkürler

Bu çalışmaya gönüllü olarak katılmayı kabul eden tüm Hemşirelere teşekkürler.

Etik Onay

İstinye Üniversitesi Sosyal ve Beşeri Bilimler Araştırma Etik Kurulu 13.01.2022, 2022/01,02 Sayılı Etik Kurul Kararı

Yazar Katkıları

Motivasyon / Konsept: EG,EUK

Çalışma Tasarımı: EG, EUK

Kontrol / Gözetim: EUK, EG

Veri Toplanması ve / veya İşlemesi: EUK, EG

Analiz ve / veya Yorum: EG, EUK

Literatür inceleme: EUK, EG

Makalenin Yazılması: EG, EUK

Eleştirel İnceleme: EUK, EG

Artificial Intelligence Anxiety scale. The research data were evaluated with descriptive statistics and multiple linear regression analysis.

Results: As a result of the study, it was observed that as the learning status of the nurses increased, there was an increase in the artificial intelligence structuring status. It has been evaluated that there is a positive and very high degree significant relationship at the 95% confidence level. It is recommended to study the results obtained in larger samples and by adding more different dimensions.

Keywords: *Artificial Intelligence, Nursing, Artificial Intelligence in Nursing, Artificial Intelligence Anxiety*

Giriş

Yapay zeka kavramı, dijital bir bilgisayarın veya bilgisayar kontrollü robotun akıllı varlıkla ortak görevleri yerine getirme yeteneği olarak tanımlanmaktadır (9). Yapay zeka (AI), belirli bir eylem için açıkça programlanmadan hedeflere ulaşmak için “akıl yürütme, anlam keşfetme, genelleme yapma veya geçmiş deneyimlerden öğrenme gibi insanlara özgü entelektüel süreçleri” taklit eden bir bilgisayarı ifade eder (3). AI, “çeşitli hesaplama, matematiksel, mantıksal, mekanik ve hatta biyolojik ilke ve cihazları kullanarak zeka ve bilişsel süreçleri anlamaya, modellemeye ve çoğaltmaya yönelik disiplinler arası bir yaklaşım” olarak da tanımlanabilir (5). Dijital değişimin yıkıcı ve dönüştürücü gücü sağlık sektöründe de etkisini göstermektedir. Bu dönüşümün başında yapay zeka teknolojilerinin kullanımı, insansız üretim, insanların yaptığı işlerin robotlara devredilmesi ve insansı özelliği olan teknolojilerin iş gücü olarak kullanımının yaygınlaşması akla gelmektedir (11). Dijital değişimin yıkıcı ve dönüştürücü gücü sağlık profesyonelleri arasında fark edilir olmuş ve en çokta sahada hasta ile bire bir etkileşimde olan doktor ve hemşireleri etkisi altına almaya başlamıştır (18). Dijital devrimin sağlık sektöründe ortaya çıkarttığı bu dönüştürücü değişim, doktor ve hemşirelerin hasta bakım gibi dinamik süreçlerinde ve saha uygulamalarında oldukça sık yer almaktadır (19). Geleceğin teknolojilerini yöneten yapay zeka kavramının sağlık ekosistemi üzerinde önemli etkileri olacağı öngörülmektedir. Sağlık alanındaki hızlı gelişmeler, kullanılan teknolojiler, teknolojiyi anlama ve nasıl kullanılacağını keşfetme konusunda çaba göstermeleri sağlık ekosisteminin değişen ve gelişen yüzü açısından oldukça önemli olacaktır (10).

Hemşireler, Her ortamda bireyin, ailenin ve toplumun hemşirelik girişimleri ile karşılanabilecek sağlıkla ilgili ihtiyaçlarını belirler ve hemşirelik tanılama süreci kapsamında belirlenen ihtiyaçlar çerçevesinde hemşirelik bakımını kanıta dayalı olarak planlar, uygular, değerlendirir ve denetler (16). Kaygı, Bedenin ve zihnin, gerçek ya da hayali, tehdit ya da tehlike algısıyla oluşan durumu olarak tanımlanır. Kaygı, aynı zamanda korku ve endişenin bir derecesi olarak tanımla-

nır ve strese verilen en ortak tepkilerden biri olarak kabul edilir (15). Sağlık ekosisteminde yaşanan teknolojik hızlı değişimlerin ardından sağlık profesyonelleri yapay zeka ve robot teknolojileri insanların yerini alabilir mi? Mesleki değişim ile birlikte hasta güvenliği ve bakımın sürdürülebilirliği güvenle sağlanır mı? Sorularını akla getirmiştir (10). Gelecekte rutin işleri yapan yapay zeka teknolojilerinin sağlık profesyonellerinin iş tanımında yer alan işleri yapabileceği, bakım gibi daha karmaşık işlerin insanlar tarafından yapılmaya devam edeceği düşünülmektedir (13). Dünya genelinde pek çok Avrupa ülkesi yapay zeka teknolojileri ve bu teknolojiler ile entegre sağlık sistemlerini kullanmaktadırlar (14). Türkiye’de bu sürecin nasıl işleyeceği sağlık profesyonellerinin bu süreci nasıl karşılayacağı ve özellikle hemşirelerin yapay zeka kaygı düzeyleri ve kaygı düzeylerinin sürece yansması merak edilen sorular arasında yerini almaktadır. Kaygı aynı zamanda algılanan tehditler ve çözülmemiş korku sonrasında dikkat dağınıcı bir uyanma hali olarak tanımlanmaktadır ve temel bir insani duygudur (7). Bu duygunun yapay zeka ile birlikte değerlendirilmesi ve uygulamalara yansması tüm mesleklerde olduğu gibi sağlık profesyonelleri için yeni bir kavramdır. Günümüzde yapay zekanın ve yapay zeka teknolojilerinin eleştirel düşünmeyi destekleyerek sağlık ekosisteminin olumlu yönde etkileyeceği özellikle bakım odaklı çalışan hemşirelerin karar verme sürecine katkısı olacağı düşünülmektedir (8). Bu çalışmanın amacı Türkiye sağlık ekosisteminde yapay zeka çalışmalarına yönelik farkındalık oluşturmak ve bakım süreci içinde bire bir yer alan hemşirelerin yapay zeka kaygı düzeylerini belirlemektir. Bu veriler ışığında sağlık profesyonellerine ve literatüre katkı sunulması hedeflenmektedir.

Gereç ve Yöntem

Genel kapsamda tartışmaya açık olan Yapay zeka kaygı düzeyi değerlendirme süreci yapılan literatür taramaları sonrasında kapsamlı bir araştırma ile tanımlayıcı çalışma kapsamında Şubat – Nisan 2022 tarihleri arasında Türkiye’de yapılmıştır. Kamu, üniversite ve özel hastaneler olmak üzere Türkiye’de çalışan 156.205 hemşire evreni belirlenmiş (Sağlık Bakanlığı, 2020) çalışmaya katılmaya gönüllü olan 215 kişilik örneklem grubu ile online anket yöntemi kullanılarak veri toplanmıştır. Örneklem sayısının yeterliliğini incelemek üzere G power (3.1.9.4) programı ile posthoc güç analizi yapılmış, iki bağımsız değişken ile elde edilen $R^2:0,06$ değeri, düşük etki büyüklüğü, %5 anlamlılık düzeyi ile güç 0,95 bulunmuştur.

Çalışma için etik kurul izni (13.01.2022/2022/1:2) alınmış olup, veri toplamada, demografik ve mesleki özellikler formu (13 soru), 16 madde ve 4 alt boyuttan oluşan Yapay Zeka Kaygı Ölçeği kullanılmıştır. Bu ölçek Wang ve Wang tarafından 2019 yılında geliştirilmiştir. Kullanılan ölçek, Yapay Zeka Kaygı Ölçeğinin Türkçeye uyarlanmasıdır. Yapay zeka kaygı ölçeğinin; öğrenme, iş değiştirme, sosyoteknik körlük ve yapay zeka yapılandırması olmak üzere dört

boyutu bulunmaktadır. Yapay Zeka Kaygı Ölçeđi'nin dört faktörlü yapısının doğrulandıđı görölmüřtür. Uyum iyiliđi deđerleri ($\Delta\chi^2 = 260.120$, $sd= 99$ $\chi^2/sd=2.627$, $NFI=0,923$, $CFI=0,950$, $RFI=0,906$, $IFI=0,951$, $TLI=0,940$, $RMSEA=0,078$, $p=0,001$) kabul edilebilir aralıklarda bulunmuřtur. Ölçeđin güvenirliliđini belirlemek için yapılan toplam iç tutarlılık katsayısının $\alpha=0,937$, Öđrenme boyutunun $\alpha=0,948$, İş Deđiřtirme boyutunun $\alpha=0,895$, Sosyoteknik Körlük boyutunun $\alpha=0,875$ ve Yapay Zeka (YZ) Yapılandırması boyutunun ise $\alpha=0,950$ olduđu ve ölçeđin iç tutarlılıđa sahip olduđu bulunmuřtur. Yapay Zeka Kaygı Ölçeđinin Türkçe formunun 16 madde ve 4 boyuttan oluřtuđu saptanmıřtır. Elde edilen tüm bu bulgular ile beraber Yapay Zeka Kaygı Ölçeđinin Türkçe Formunun kabul edilebilir deđerlerde güvenilir ve geçerli bir ölçme aracı olduđu söylenebilir. Yapay Zeka Kaygı ölçeđi'nin madde puanlaması 5'li likert yapıda olup "(1) Kesinlikle Katılmıyorum (2) Katılmıyorum (3) Kararsızım (4) Katılıyorum (5) Kesinlikle katılıyorum" şeklinde olmuřtur. (7). Ölçek, Akkaya, Özkan&Özkan tarafından Türkçeye

uyarlanmıř olup Cronbach alfa katsayısı, orijinal ölçek için 0,95, Türkçe ölçek için 0,81 ve bu çalışmada 0,94 bulunmuřtur. Veri analizinde tanımlayıcı istatistikler ve çoklu lineer regresyon analizi kullanılmıřtır.

Bulgular

Çalışmaya katılan hemřirelerin %59,1'i 30 yařının altındadır ve çalışmaya katılan hemřirelerin yař ortalaması 31,5'dur. Hemřirelerin %89,9'u kadın ve %74 oranında İstanbul'da yařamaktadırlar. %53,5 i lisans mezunu,%54,4 ü devlet hastanelerinde çalıştıđını bildirmiřtir. Çalışmaya katılan hemřirelerin %60,5'i yatan hasta servislerinde görev almaktadır ve %85,1'i hemřire olarak çalışmaktadır. Hemřirelerin %56,3'ü vardiya (gece/gündüz/karma) şeklinde çalışmaktadır. Mesleki deneyim yılları 9 yıl ve altında olanların oranı %61,9, ortalama mesleki deneyim yılı 9,2 yıldır. Çalışmaya katılan hemřirelerin %72,6'sı řu an çalıştıđı hastanede 5 yıldan daha az sürede çalışmakta ve buldukları hastanede çalışma yıl ortalamaları 4,5 yıldır. Hemřirelerin bireysel özellikleri dađılımı Tablo 1'de belirtilmektedir.

Tablo-1: Hemřirelerin Bireysel Özelliklerinin Dađılımı (N=215)

Hemřirelerin Bireysel Özellikleri		n	%
Yař	< 30 yař	127	59,1
	≥ 30 yař	88	40,9
Ortalama (SS)	=31,5 (8,4)		
Cinsiyet	Kadın	193	89,8
	Erkek	22	10,2
Yařadıđı Yer	İstanbul	159	74,0
	İstanbul Dıřı	56	26,0
Eđitim	Sađlık Meslek Lisesi	30	14,0
	Önlisans	30	14,0
	Lisans	115	53,5
	Lisans Üřtü	40	18,5
Çalıştıđı Kurum	Özel Hastane	70	32,6
	Devlet Hastanesi	117	54,4
	Üniversite Hastanesi	28	13
Çalıştıđı Birim	Yönetim / Özel Dal Alanları	66	30,7
	Yatan Hasta Servisleri	130	60,5
	Ayaktan Hasta Servisleri	19	8,8
Çalıştıđı Pozisyon	Yönetici Hemřire	32	14,9
	Hemřire	183	85,1
Çalışma Şekli	Sürekli Gündüz	94	43,7
	Vardiya (Gece/Gündüz/Karma)	121	56,3
Meslekte Deneyim Süresi	< 9 yıl	133	61,9
	≥ 9 yıl	82	38,1
Ortalama (SS)	= 9,2 (8,8)		
Şu an Çalıştıđı Hastanedeki Deneyim Süresi	< 5 yıl	156	72,6
	≥ 5 yıl	59	27,4
Ortalama (SS)	= 4,5 (6,1)		

*SS:Standart Sapma

Araştırmaya katılan kişilerden elde edilen verilerin normal dağılıma uygunluğunu değerlendirmek için veri gruplarının çarpıklık (skewness) ve basıklık (kurtosis) değerleri incelenmiştir. George and Mallery (2003)'e göre, +2 ile -2 aralığındaki çarpıklık ve basıklık değerleri normal dağılım göstermektedir.(24) Araştırmaya katılan kişilere uygulanan 215 adet anketten elde edilen veri setinin normal dağılıma uygunluğunu tespit etmek amacıyla çarpıklık ve basıklık değerleri kontrol edilmiştir. Bu kontrol sonucunda verilerinin normal dağılıma sahip olduğu söylenebilir ve araştırmada uygulanacak olan test istatistiklerinde parametrik yöntemler kullanılmıştır. Tablo 2'de görüldüğü üzere, katılımcıların sorulara verdikleri yanıtlara göre tüm faktörlerden elde ettikleri puan ortalaması ve standart sapması dikkate alındığında, yapay zeka kaygı düzeyi ölçeği ($\bar{X}=2.64$, $S=0.79$) elde edilmiştir. Katılımcıların vermiş oldukları cevaplara göre yapay zeka kaygı düzeyi alt faktörlerinde en yüksek ortalamaların sosyoteknik körlük alt faktörü ($\bar{X}=3.09$, $S=0.96$) olduğu gözlenmektedir. Sırası ile iş değiştirme alt faktörü ($\bar{X}=2.79$, $S=1.01$), yapay zeka yapılandırma alt faktörü ($\bar{X}=2.69$, $S=1.06$) ve öğrenme alt faktörü ($\bar{X}=2.12$, $S=0.87$) izlenmektedir.

Çalışmaya katılan kişilerin yapay zeka kaygı düzeyi ile alt faktörleri arasındaki ilişkiyi incelemek için pearson korelasyon analizi ile araştırılmıştır. Sonuçlar incelendiğinde; kişilerin öğrenme durumu arttıkça iş değiştirme durumunda artış meydana geldiği gözlemlenmiştir ($r=0,487$; $p= 0,000<0,05$) ve %95 güven seviyesinde pozitif yönlü

orta dereceli anlamlı bir ilişki mevcuttur. Kişilerin öğrenme durumu arttıkça sosyo teknik körlük durumunda artış meydana geldiği gözlemlenmiştir ($r=0,353$; $p= 0,000<0,05$) ve %95 güven seviyesinde pozitif yönlü düşük dereceli anlamlı bir ilişki mevcuttur. Kişilerin öğrenme durumu arttıkça yapay zeka yapılandırma durumunda artış meydana geldiği gözlemlenmiştir ($r=0,526$; $p= 0,000<0,05$) ve %95 güven seviyesinde pozitif yönlü orta dereceli anlamlı bir ilişki mevcuttur. Kişilerin iş değiştirme durumu arttıkça sosyo teknik körlük durumunda artış meydana geldiği gözlemlenmiştir ($r=0,748$; $p= 0,000<0,05$) ve %95 güven seviyesinde pozitif yönlü yüksek dereceli anlamlı bir ilişki mevcuttur. Kişilerin iş değiştirme durumu arttıkça yapay zeka yapılandırma durumunda artış meydana geldiği gözlemlenmiştir ($r=0,687$; $p= 0,000<0,05$) ve %95 güven seviyesinde pozitif yönlü yüksek dereceli anlamlı bir ilişki mevcuttur. Kişilerin yapay zeka kaygı düzeyi durumu arttıkça en yüksek artış meydana gelen alt faktörün yapay zeka yapılandırma olduğu gözlemlenmiştir ($r=0,872$; $p= 0,000<0,05$) ve %95 güven seviyesinde pozitif yönlü çok yüksek dereceli anlamlı bir ilişki mevcuttur.

Yapay zeka kaygı ölçeğini ve alt faktörler incelendiğinde, öğrenme alt boyutu 0,94, iş değiştirme 0,88, sosyo teknik körlük 0,87, yapay zeka yapılandırma 0,94 ve Yapay zeka kaygı ölçeği 0,94 olduğu gözlemlenmiş olup cronbach alfa katsayıları 0,80'dan büyük olduğu için ölçeğin çok yüksek derecede güvenilirliğe sahip olduğu gözlemlenmiştir.

Hemşirelerin Yapay Zeka Kaygı Ölçeği tanımlayıcı İstatistikleri Tablo 2'de belirtilmektedir.

Tablo-2: Yapay Zeka Kaygı Ölçeği Tanımlayıcı İstatistikleri (N=215)

Ölçek ve Alt Boyutları	1	2	3	4	5
1-Öğrenme	1	0,487*	0,353*	0,526*	0,740*
2-İş Değiştirme		1	0,748*	0,687*	0,886*
3-Sosyo Teknik Körlük			1	0,628*	0,823*
4-Yapay Zeka Yapılandırma				1	0,843*
5-Toplam Ölçek					1
Ort (SS)	2,12 (0,87)	2,79 (1,01)	3,09 (0,96)	2,69 (1,06)	2,64 (0,79)
Min- Max	1 - 5	1-5	1-5	1-5	1-5
Cronbach Alpha	0,94	0,88	0,87	0,94	0,94
Skewness	1,28	0,23	-0,28	0,21	0,31
Kurtosis	0,33	-0,64	-0,41	-0,66	0,47

* $p<0.01$

Tablo 3'de elde edilen bulgulara göre kişilerin yaş ($p= 0,874$; $p>0,05$), cinsiyet ($p= 0,149$; $p>0,05$), yaşadığı yer ($p= 0,072$; $p>0,05$), eğitim ($p= 0,980$; $p>0,05$), çalıştığı kurum ($p= 0,208$; $p>0,05$), çalıştığı birim ($p= 0,935$; $p>0,05$), çalıştığı pozisyon ($p= 0,126$; $p>0,05$), çalışma şekli ($p= 0,481$; $p>0,05$), meslekte deneyim süresi ($p= 0,771$; $p>0,05$) ve çalışılan hastanedeki deneyim süresi ($p= 0,937$; $p>0,05$) du-

rumları ile yapay zeka kaygı durumları arasında istatistiksel olarak anlamlı bir farklılık gözlemlenmemiştir ($p= 0,874$; $p>0,05$). Bu bulgulara göre kişilerin yapay zeka kaygı düzeyleri ilgili gruplar benzer nitelik göstermektedir.

Pozisyonu yönetici hemşire olanların yapay zeka kaygı düzeyleri daha düşük, diğer çalışanların ise daha yüksek gö-

rülmüştür. Çalışma şekli vardiya olanların diğer çalışanlara kıyasla yapay zeka kaygı düzeyleri daha düşük bulunmuştur. İkinci olarak ise sürekli gündüz çalışanlar gelirken, en çok yapay zeka kaygı düzeyi sürekli gece çalışanlarda görülmüş-

tür. Hemşirelerin Bireysel ve Mesleki Özelliklerine Göre Yapay Zeka Kaygı Düzeyi Ölçeği Puanlarının Karşılaştırılması Tablo 3’de ayrıntılı olarak verilmiştir.

Tablo-3: Hemşirelerin Bireysel ve Mesleki Özelliklerine Göre Yapay Zeka Kaygı Düzeyi Ölçeği Puanlarının Karşılaştırılması (N=215)					
Hemşirelerin Bireysel Özellikleri		Ortalama	SS	Test	p
Yaş	< 30 yaş	2,65	0,78	t=0,159	0,874
	≥ 30 yaş	2,63	0,80		
Cinsiyet	Kadın	2,67	0,77	t=1,448	0,149
	Erkek	2,41	0,94		
Yaşadığı Yer	İstanbul	2,80	1,02	t=1,811	0,072
	İstanbul Dışı	2,58	0,69		
Eğitim	Sağlık Meslek Lisesi /Önlisans	2,64	0,94	t=0,026	0,980
	Lisans / Lisans Üstü	2,64	0,73		
Çalıştığı Kurum	Özel Hastane	2,50	0,94	F=1,581	0,208
	Devlet Hastanesi	2,70	0,68		
	Üniversite Hastanesi	2,71	0,79		
Çalıştığı Birim	Yönetim / Özel Dal Alanları	2,67	0,82	F=0,067	0,935
	Yatan Hasta Servisleri	2,63	0,81		
	Ayaktan Hasta Servisleri	2,60	0,60		
Çalıştığı Pozisyon	Yönetici Hemşire	2,44	0,71	t=-1,536	0,126
	Hemşire	2,67	0,80		
Çalışma Şekli	Sürekli Gündüz	2,68	0,76	t=0,705	0,481
	Vardiya (Gece/Gündüz/Karma)	2,60	0,81		
Meslekte Deneyim Süresi	< 9 yıl	2,65	0,78	t=0,291	0,771
	≥ 9 yıl	2,62	0,81		
Şu an Çalıştığı Hastanedeki Deneyim Süresi	< 5 yıl	2,64	0,78	t=0,079	0,937
	≥ 5 yıl	2,63	0,82		

Yapay zeka kaygı ölçeğinin toplam ölçeğinin bağımlı değişken olduğu ve demografik değişkenler ve mesleki özellikler ile açıklandığı lineer regresyon modeli sonuçları da yer almaktadır. Model tahmininde backward yöntem kullanılmıştır. Modelin R2 değeri %5,6 seviyesinde bulunmuştur. Bu modelin açıklama gücü olup, modelde yer alan anlamlı açıklayıcı değişkenlerin bakım değerlendirme ölçeğini açıklama oranı %5,6’dır. Modelin genel olarak anlamlılığı ölçen F test istatistiği 6,171 çıkmış buna bağlı olarak p değeri 0,05’den küçük çıktığından model genel olarak anlamlı bulunmuştur.

Tartışma:

Hemşireler geleneksel olarak şefkat, güven ve empati duyguları ile birlikte anılmaktadır. Hemşirelerden hasta bakımını yanı sıra sürekli genişleyen ve karmaşık görevler üstlenmeleri beklenir (1). Tüm bu görevlerle beraber yapılan çalışmalar

gösteriyor ki Hemşireler, ve sağlık çalışanları, dürüstlükleri ve etik standartları nedeniyle halk tarafından en yüksek notları almaya devam ediyor (2). Sağlık profesyonellerine yönelik yapılan çalışmaların çoğunda kaygı düzeyleri ve kaygıya neden olan faktörler ele alınmıştır. Ancak Yapay zeka konusunda oldukça yeni bir konu ve bu konuda yapılan çalışmalar sınırlıdır. Yapılan bir çalışmada Hemşirelerin sorunları ele alması ve bilgi teknolojileri katkısıyla bakım çalışmalarında yapay zeka teknolojilerinin uygulandığı ve hemşirelerin yapay zeka teknolojileri kullanmadan önce ve kullandıktan sonra sorulardaki ve hemşire memnuniyet düzeylerindeki farklılıklar olduğu belirlenmiş (4). Hemşireler için yapay zeka teknolojileri ile çalışmak ve yapay zeka kaygı düzeyi oldukça yeni bir kavram olup yapılan çalışmaların artırılması literatüre önemli katkı sağlayacaktır. Yapay zekanın (AI) Hemşirelikte yönetim, klinik bakım, eğitim, politika ve

araştırma dahil olmak üzere tüm alanlarında hemşireliği dönüştüreceği tahmin edilmektedir (6). bu nedenle hemşirelerin yapay zeka kaydı düzeylerinin belirlenmesi ve kaygı düzeyleri ile ilgili geliştirilmesi gereken alanların tespiti önemli olacaktır.

Yapılan bir çalışmada hemşirelerin, Sağlık Anksiyetesi Ölçeği (SAÖ) toplam puan ortalamasının $17,77 \pm 6,680$, aşırı duyarlılık ve kaygı alt boyutu puan ortalaması $14,15 \pm 5,199$ ve hastalığın sonuçları alt boyutu puan ortalaması $3,62 \pm 2,281$ da olduğu tespit edilmiştir. Hemşirelik öğrencilerinde yapılmış bir çalışmada, Sağlık Anksiyetesi Ölçeği toplam puan ortalamasının $34,33 \pm 6,50$ bulunmuştur (20). Başka bir çalışmada ise sağlık anksiyetesi puan ortalaması $0,97 \pm 0,39$ olarak bildirilmiştir (21). Ayrıca hastanede yatan bireylerde yapılan çalışmada, Sağlık Anksiyetesi Ölçeği (SAÖ) toplam puanı $17,34 \pm 8,45$, bedensel belirtilere aşırı duyarlılık ve kaygı boyutu puan ortalamalarının $13,39 \pm 6,97$ ve hastalığın olumsuz sonuçları boyutu puan ortalamalarının $3,94 \pm 2,70$ olduğu belirlenmiştir (20). Bu çalışmada hemşirelerin yaşlarının Sağlık Anksiyete Ölçeği puanını etkilediği görülmüştür (20). Çalışmamızda görülen bu durumun, meslekte deneyim arttıkça anksiyetenin azalması durumuyla ilişkilendirebileceği söylenebilir.

Bir üniversite hastanesinde görevli hemşirelerin sağlıklı yaşam biçimi davranışları ve sağlık kaygısı düzeylerini inceleyen bir çalışmada, yaşın anksiyete düzeyini etkilemediği görülmüştür (10, 22). Yenilikçi teknolojilerin; klinikler, sanal ortamlar ve hemşirelik eğitimi de dahil olmak üzere tüm ortamlara taşınmasında hemşirelerin katılımcı ve destekleyici rolleri önemlidir (8). Kaygı düzeylerini kontrol edebilen Hemşireler katılımcı ve destekleyici rollere daha kolay uyum sağlayacaktır. Farklı bir çalışmada, bizim de çalışma bulgularımızda olduğu gibi cinsiyetin sonucu değiştirmedeği görülmüştür (23). Yapılan farklı bir çalışmada sağlık profesyonellerinin ele alınan sosyo-demografik değişkenlerden öğrenim durumu ve kurumdaki görevi ile yapay zeka kaygı ortalaması arasında anlamlı bir fark tespit edilmiştir. Ancak diğer sosyo-demografik değişkenler olan yaş, cinsiyet, medeni durum, kurum çalışma yılı ve kurumda yapay zeka kullanım durumu ile yapay zeka kaygı ortalaması arasında anlamlı bir fark bulunamamıştır. Ayrıca sağlık profesyonellerinin yapay zeka kaygı durumlarının da orta düzeyde olduğu sonucuna varılmıştır (12).

Yapılan çalışmalarda da görüldüğü gibi, ekonomik durumun düşük olması da bir stres faktörü olabildiğinden gelir gider dengesinin düşük olmasının stresle baş etme durumunu da olumsuz etkileyebileceği söylenebilir. Sağlık kaygısı kavramı, bireyin ciddi bir hastalığa yakalanma korkusu olarak ifade edilebilir. Hemşireler, önemli ve ölümle mücadele eden hastalarla birebir çalıştıkları için sağlık kaygıları yüksek olabilmektedir.

Sonuç:

Sağlık profesyonelleri bir saat dışlisinin çarkları gibi çalışırlar, her bir parça özeldir ve biri olmadan diğeri tam performans çalışmaz. Hemşireler de bu saat dışlisi çarkında olduğu gibi sağlık ekosisteminde önemli bir yere sahiptirler. Hemşireler, her ortamda bireyin, ailenin ve toplumun hemşirelik girişimleri ile karşılanabilecek sağlıkla ilgili ihtiyaçlarını belirleyebilir ve gerekli ihtiyaçlar çerçevesinde planlayabilirler. Hasta bakımını planlamak, uygulamak, denetlemek ve değerlendirmek hemşirenin temel görev tanımındadır. Almış oldukları bu sorumluluk ve iş yüklerinin fazla olması yapmış oldukları işin sürecini hem değişken hem de kompleks bir özellik kazanmasına neden olur. Sağlık ekosisteminde yapay zeka ve dijital teknolojilerin kullanılmaya başlaması ile birlikte hemşirelerin takip etmesi ve yönetmesi gereken değişkenlerin sayısı artmış daha kompleks ve dikkatli takip edilmesi gereken bir süreç haline almıştır.

Sağlık sektöründe yapay zekanın kullanılmaya başlanması ile birlikte hemşirelerin takip etmesi ve yönetmesi gereken değişkenlerin sayısı artmış olup bu durum daha karmaşık ve dikkatli takip edilmesi gereken bir süreç haline almıştır. Geleceğin teknolojilerini yöneten yapay zeka kavramının hemşirelik mesleği üzerinde önemli etkileri olacağı öngörülmektedir. Sağlık alanındaki hızlı gelişmeler, kullanılan teknolojiler, teknolojiyi anlama ve nasıl kullanılacağını keşfetme konusunda çaba göstermeleri hemşirelik mesleği açısından oldukça önemlidir ve bu konuda yapılmış çalışmalar sınırlıdır. Bu çalışmanın amacı, Türkiye’de çalışan hemşirelerin Yapay Zeka Kaygı düzeylerine etki eden bireysel ve mesleki özelliklerin belirlenmesi ve bu kapsamda ortaya çıkacak veriler ışığında hemşirelere rehberlik edecek kaynaklar oluşturmak ve yapay zeka ile entegrasyonu kolaylaştırmaktır.

Pozisyon şekli YZ kaygı ölçeğini doğru yönlü etkilemektedir ve etki düzeyi 0.215 olup, pozisyonu yönetici hemşire olanların diğer çalışanlara kıyasla YZ kaygı düzeyleri daha düşük bulunmuştur. İkinci olarak ise hemşireler gelirken, en çok YZ kaygı düzeyi diğer çalışanlarda görülmüştür.

Teşekkürler: Çalışmaya Gönüllü katılan tüm hemşirelere teşekkürler

KAYNAKLAR

1. Stokes F, Palmer A. Artificial Intelligence and Robotics in Nursing: Ethics of Caring as a Guide to Dividing Tasks Between AI and Humans. *Nursing Philosophy*. 2020; 21:e12306. <https://doi.org/10.1111/nup.12306>
2. Brenan M. Nurses Again Outpace Other Professions for Honesty, Ethics. *Gallup*, December 20, 2018; Retrieved from: <https://news.gallup.com/poll/245597/nurses-again-outpace-professions-honesty-ethics.aspx>
3. Bali J, Garg R, Bali RT. Artificial Intelligence (AI) in Healthcare and Biomedical Research: Why a Strong Computational/AI Bioethics Framework is Required?. *Indian Journal of Ophthalmology*. 2019; 67:3-6. Doi: 10.4103/ijo.IJO_1292_18

4. Liao PH, Hsu PT, Chu, W, and Chu WC. Applying Artificial Intelligence Technology to Support Decision-Making in Nursing: A Case Study in Taiwan. *Health Informatics Journal*, 2015; 21(2): 137-148. <https://doi.org/10.1177/1460458213509806>
5. De Saint Laurent C. In Defence of Machine Learning: Debunking the Myths of Artificial Intelligence. *Europe's Journal of Psychology*. 2018; 30;14(4):734-747. Doi: 10.5964/ejop.v14i4.1823.
6. Clipper B, Batcheller J, Thomaz AL, and Rozga, A. Artificial Intelligence and Robotics: A Nurse Leader's Primer. 2018; 16 (6): 379-384. doi: <https://doi.org/10.1016/j.mnl.2018.07.015>
7. Akkaya B, Özkan H, Özkan A. Yapay Zeka Kaygı (YZK) Ölçeđi: Türkçeye Uyarlama Geçerlilik ve Güvenilirlik Çalışması. *Alanya Akademik Bakış*. 2021; 5(2): 1125-1146. <https://doi.org/10.29023/alanyaakademik.833668>
8. Çetin B, Erođlu N. Hemşirelik Bakımında Yenilikçi Teknolojiler. *Acta Media Nicomedia*. 2020; 3(3):120-126
9. Eşkin Bacaksız F, Yılmaz M, Ezizi K, Alan H. Sağlık Hizmetlerinde Robotları Yönetmek. *Sađlık ve Hemşirelik Yönetim Dergisi*. 2020;7(3): 458-65.
10. Şendir M, Şimşekođlu N, Kaya A ve Sümer K. Geleceđin Teknolojisinde Hemşirelik. *Sađlık Bilimleri Üniversitesi Hemşirelik Dergisi*. 2019; 1(3): 209-14
11. Akın Ö. Hızla Artan Endüstriyel Robotların Üretim Süreçlerinin Yarattığı Deđişimler ve Türkiye İşgücü Piyasasında Yaratacađı Olası Etkilerin Deđerlendirilmesi. *İş ve Hayat*. 2017; 3(6):71-42.
12. Filiz, E., Güzel, Ş. & Şengül, A. (2022). Sağlık Profesyonellerinin Yapay Zeka Kaygı Durumlarının İncelenmesi. *Journal of Academic Value Studies*, 8(1), 47-55. <http://dx.doi.org/10.29228/javs.57808>
13. Gümüř U, Uysal Kasap E. Hemşirelik Mesleđinin Geleceđi: Robot Hemşireler. *Sađlık Bilimlerinde Yapay Zeka Dergisi*. 2021; 1(2):20-25. doi: <https://doi.org/10.52309/jai.2021.10>
14. International Federation of Robotics. Robots and the Workplace of the Future. [Internet], Frankfurt; 2018. https://ifr.org/downloads/papers/IFR_Robots_and_the_Workplace_of_the_Future_Positioning_Paper.pdf Eriřim Tarihi: 05.01.2022
15. Türk Dil Kurumu, <https://sozluk.gov.tr/> Eriřim Tarihi: 17.11.2022
16. Hemşirelik Yönetmeliđi, <https://www.mevzuat.gov.tr/> Eriřim Tarihi: 17.11.2022
17. Resmî Gazete, Tarihi: 08.03.2010, Resmî Gazete Sayısı: 27515 Eriřim Tarihi: 02.11.2022
18. Blumenthal, D. (2017). Data with holding in the age of digital health. *The Milbank Quarterly*, 95(1): 15-18. doi: 10.1111/1468-0009.12239
19. Bayer, E., Kuyrukçu, A. N., Akbař, S. (2019). Dijital hastane uygulamalarının hastane çalışanlarının ve yöneticilerinin perspektifinden deđerlendirilmesi; Bir devlet hastanesi örneđi. *Akademik Arařtırmalar ve Çalışmalar Dergisi*, 11(21): 335-360. doi: [org/10.20990](https://doi.org/10.20990)
20. Gülbetekin E, Gül Can F, Tunç Y. 2022. Determining the factors affecting health anxiety levels of nurses in the COVID-19 process. *BSJ Health Sci*, 5(2):226-231.
21. Irmak B, Bölükbař N. 2015. Hemşirelik öğrencilerinde sađlık anksiyetesi düzeylerinin belirlenmesi. 14. Ulusal Hemşirelik Öğrencileri Kongresi Özet Kitabı, 22-26 Nisan, Kayseri, 305.
22. Chen Y, Zhou H, Zhou Y, Zhou F. 2020. Prevalence of self-reported depression and anxiety among pediatric medical staff members during the COVID-19 outbreak in Guiyang, China. *Psychiatry Res*, 288: 113005.
23. Özdemir K. 2014. Yođun bakım hemşirelerinde görülen ölüm kaygısı. Yüksek Lisans Tezi, Atatürk Üniversitesi, Sađlık Bilimleri Enstitüsü, Psikiyatri Hemşireliđi Anabilim Dalı, Erzurum, ss. 69.
24. George, D., & Mallery, P. (2003). *SPSS for Windows step by step: A simple guide and reference 11.0 update (4th ed.)*. Boston: Allyn & Bacon

CPV Tahmininde Makine Öğrenme Yöntemlerinin Performanslarının Değerlendirilmesi: Farklı Bölgeler ve Parametreler ile Büyük Veri Uygulaması

Evaluating the Performance of Machine Learning Methods in CPV Prediction: Big Data Application With Different Regions and Parameters

Gözde ZABZUN¹, Meltem SEVİNÇ², Çınar DALKILIÇ³, Kıvanç Ege ÇAM⁴

Received / Geliş	06.12.2022
Accepted / Kabul	27.12.2022
Publication Date	30.12.2022

*Sorumlu Yazar Corresponding Author

Gözde ZABZUN¹

Karşıyaka Aydoğan Yağcı Bilim ve Sanat Merkezi
ÇİĞLİ/İZMİR

ORCID iD: 0000-0002-9502-8756
e posta: gzabzun@gmail.com

Meltem SEVİNÇ²

Karşıyaka Aydoğan Yağcı Bilim ve Sanat Merkezi
ÇİĞLİ/İZMİR

ORCID iD: 0000-0001-6351-3370
e posta: sevincmeltem2007@gmail.com

Çınar DALKILIÇ³

Karşıyaka Aydoğan Yağcı Bilim ve Sanat Merkezi
ÇİĞLİ/İZMİR

ORCID iD: 0000-0002-1881-56840
e posta: cinar.dalkilic@gmail.com

Kıvanç Ege ÇAM⁴

Karşıyaka Aydoğan Yağcı Bilim ve Sanat Merkezi
ÇİĞLİ/İZMİR

ORCID iD: 0000-0002-5951-7245
e posta: kivanccam2@gmail.com

Yazar Katkıları

Motivasyon / Konsept: GZ
Çalışma Tasarımı: GZ
Kontrol / Gözetim: GZ
Veri Toplanması ve / veya İşlemesi: MS
Analiz ve / veya Yorum: MS
Literatür inceleme: ÇD
Makalenin Yazılması: GZ, MS, KEÇ
Eleştirel İnceleme: GZ, KEÇ

ABSTRACT

Scopa: Nowadays, the interpretation, classification, storage and extraction of big data in different fields, which are rapidly increasing in regular and irregular areas, and making them useful again are among the subjects that are intensively studied. The correct interpretation of big data in the field of health is of vital importance as it enables fast and accurate diagnosis. In the project, machine learning methods that can interpret health data have been applied specifically to Canine parvovirus infection. While CPV can be diagnosed based on clinical findings, it needs to be supported by laboratory findings to distinguish it from other infections. Correct diagnosis is vital to distinguish CPV from other infections with bloody diarrhoea, which can result in death in puppies. For this reason, by analysing the virus together with other data that may be affected by the virus, the methods of making the most accurate decision were compared and evaluated.

Purpose: In this study, it was aimed to interpret CPV, which is considered to be one of the most important infectious agents of dogs, popularly known as mad-head disease, using K-NearestNeighbour (KNN), RandomForest (RF), Logistic Regression and NaiveBayes classification algorithms in terms of different parameters. When the total accuracy values were examined, the accuracy rates decreased in logistic regression and RF methods when the insignificant variable was removed in the model.

Result: RF method made the best predictions when Platelets, Platelet (PLT) variable was in the model. In cases where we do not want to remove this variable from the model, it can give us very efficient results. KNN method gives better results when the number of variables decreases. Especially when the data size increases, it has been observed that the machine learning method gives more efficient results with better performance.

Keywords: Big Data, Data Mining, Big Data in Health, Prediction Algorithms, Canine parvovirus (CPV)

Özet

Kapsamı: Günümüzde hızla artan düzenli/düzensiz farklı alanlardaki büyük verilerin yorumlanması, sınıflandırılması, depolanması ve ayıklanarak tekrar işe yarar hale getirilmesi, üzerinde yoğun çalışılan konuların arasındadır. Sağlık alanındaki büyük verilerin doğru yorumlanması ise hızlı ve doğru teşhis konulmasını sağladığından hayati öneme sahiptir. Projede sağlık verilerinin yorumlanabileceği makine öğrenme yöntemleri, Canine parvovirüsü enfeksiyonunun önleninde uygulanmıştır. CPV klinik bulgulara dayanılarak teşhis konulabilirken; diğer enfeksiyonlardan ayırt edilebilmesi için ise laboratuvar bulguları ile desteklenmesi gerekir. CPV, yavru köpeklerde ölümle sonuçlanabilen, kanlı ishale seyreden diğer enfeksiyonlardan ayırt edilebilmesi için doğru teşhis hayati önem taşır. Bu sebeple, virüsün etkilenebileceği diğer verilerle beraber incelenmesi yapılarak, en doğru kararın alma yöntemleri karşılaştırılarak değerlendirilmiştir.

Amaç: Çalışmada, halk arasında delibaş hastalığı olarak bilinen, köpeklerin en önemli enfeksiyöz etkenlerinden birisi olarak kabul edilen CPV farklı parametreleri açısından En Yakın komşu Algoritması (KNN), Rastgele Orman (RF), Lojistik Regresyon ve NaiveBayes sınıflandırma algoritmaları kullanarak yorumlamayı hedeflemiştir.

Sonuç/Bulgular: Toplam doğruluk değerleri incelendiğinde anlamsız değişken modelde çıkarıldığında lojistik regresyon ve RF yöntemlerinde doğruluk oranları düşmüştür. RF yöntemi Platelets, Trombosit (PLT) değişkeni modelde iken en iyi tahminleri yapmıştır. Bu değişkeni modelden çıkarmak istemediğimiz durumlarda bize çok verimli sonuçlar verebilmektedir. KNN yöntemi değişken sayısı azaldığında daha iyi sonuçlar vermektedir. Özellikle veri boyutu arttığında makine öğrenmesi yöntemi daha iyi performans ile daha verimli sonuçlar verdiği gözlemlenmiştir.

Anahtar kelimeler: *Büyük Veri, Veri Madenciliği, Sağlıkta Büyük Veri, Tahmin Algoritmaları, Canine parvovirüsü (CPV)*

Amaç

Projenin amacı, büyük veri olan sağlık verilerinin yorumlanmasında makine öğrenmesi kullanarak farklı yöntemler karşılaştırılarak değerlendirilmesidir. Araştırmada sağlık verilerinin değerlendirilmesinde dört farklı yöntem kullanılarak, sonuçlar karşılaştırılmış ve farklı yönlerden en iyi sonuçların elde edilme koşulları araştırılmıştır. Çalışmada, halk arasında delibaş hastalığı olarak bilinen, yavru köpeklerin en önemli enfeksiyonlarından biri olarak görülen Canine parvovirüsü (CPV) farklı parametreleri açısından En yakın komşu algoritması (KNN), Rastgele Orman, Lojistik Regresyon ve NaiveBayes sınıflandırma algoritmaları kullanarak yorumlamayı hedeflemiştir. Proje, elde edilen modellerin en doğru tahmini

yapabilme koşulları karşılaştırmalı olarak değerlendirerek, faydalı olanların kullanılabilirliğini artırmayı amaçlar.

Giriş

Biyolojik problemlerin tanımlanması ve çözümlerinde gerçek yaşama uygun doğru modellemelerin yapılabilmesi için büyük veri setlerinin kullanılması önemlidir. Biyolojik verilerin derlenmesi, işlenmesi, depolanması ve analiz edilmesi biyoinformatik bilim dalının konu alanıdır. (1).Bu alandaki büyük veriler, biyoinformatik açısından incelendiğinde hipotez odaklı araştırmalardan uzaklaşıp, veri odaklı modeller bulma arayışına yönlendirmektedir (2).Veri madenciliği yaklaşımları ise çok büyük miktarlardaki biyolojik verilerin biyoinformatik uygulamalar için analizinde idealdir.

Veri madenciliği tekniklerinin etkili ve doğru kullanılması ile biyolojik verilerden bilimsel çıkarım yapılmasını sağlayabilmektedir (3;1).21.yüzyıla kadar biyolojik verilerin depolanması ve veri tabanlarının analiz edilebilecek araçlar ulaşılabilir değildi (4) Ancak günümüz teknolojisi, bilim insanlarının çeşitli sağlık problemlerini çözebilecek büyük verileri yönetmelerine ve analiz etmelerine olanak sağlamaktadır (5). Biyolojik verilerin işlenmesi ve kullanılabilir modeller üretilmesi için sağlanan bu araçlar veri madenciliği konu alanına girmektedir.

Araştırma ekibi, biyolojik verilerin veri madenciliği ile büyük verilerin tahmin edilebilirliğini ve dahası doğru karar alınabilirliği için farklı yöntemleri denemiştir. Yapılan çalışmalar incelenmiş ve en çok tercih edilen dört farklı makine öğrenme yöntemi daha önce uygulanmamış bir veri setinde uygulanmış ve farklı açılardan değerlendirilmiştir. Araştırma ekibi, özellikle yavru köpekleri etkileyen, sonu ölümle sonuçlanabilen CPV'yi farklı değişkenler bazında incelemiştir. Halk arasında delibaş hastalığı olarak bilinen CPV,1978 yılında ilk kez dünyada tanımlanmış ve yavru köpeklerde en önemli enfeksiyöz olarak kabul edilmiştir. Ardından birçok ülkede (6;7) ve Türkiye'de (8; 9) de CPV'nin etkileri görülmeye başlanmıştır. CPV enfeksiyonunun teşhisi klinik bulgulara dayanılarak konulabilse de kesin teşhisin özellikle köpek yavrularında kanlı ishale seyreden diğer enfeksiyonlardan ayırt edilmesi açısından laboratuvar bulguları ile doğrulanması gerekir. Bu sebeple, projede virüsün etkilenebileceği diğer verilerle beraber incelenmesi yapılarak, en doğru kararın alma yöntemleri karşılaştırılarak değerlendirilmiştir.

Sağlıkta Büyük Veri

“Sağlıkta Büyük Veriler, sağlık ve sağlık sistemi performansını artırmak amacıyla elektronik olarak yakalanan ve saklanan, rutin veya otomatik olarak toplanan büyük veri kümelerini ifade eder. Büyük Veri çok amaçlı veri anlamında yeniden kullanılabilir ve var olan veri tabanlarının birleştirilmesi ve bağlantısını içerir” (10). Günümüzde büyük veri

analizi sağlık sektöründe AR-GE çalışmalarında ön plana çıkmaktadır. Özellikle, ilaç sektöründe ve sigorta şirketleri için çok önemli olan veriler işlenerek piyasaya yön verebilmektedir (11;12). Hekimler ve potansiyel hastalar açısından ise teşhis, tanı ve tedavinin en hızlı ve güvenilir sonuçlarını elde edilmesi açısından bu alandaki büyük verilerin analizi hayati bir önem sahiptir.

Günümüzde, dünyadaki sağlık için yapılan harcamanın yaklaşık %80'i tedaviye yöneliktir (13). Sağlık alanındaki büyük veri analizi ile hastalıkların önlenmesi öngörülmektedir (14,15). Bu durumda tedavi aşamasına geçmeden, koruyucu hekimlik önemli hale gelecek ve doğru tedaviler için zaman kazanılmış olacaktır (16;13). Hatta kişiselleştirilmiş büyük verilerin analizleri yapılarak hastalığa ve hastaya göre en az yan etki ile en etkin tedavi sağlayabilecektir (14; 15). Araştırmada kullanılan örnek veri seti Türkiye'de üç bölgede yer alan (Marmara, Karadeniz ve İç Anadolu Bölgeleri) farklı yaşlardaki (günlük yaş) köpekleri kandaki Ortalama Eritrosit Hemogloblin Konsantrasyonu (MCHC) (g/dL)

Platelets, trombosit (PLT) ($\times 10^3/\mu\text{L}$) değerlerine göre hastalığa sebep olan parvovirüsün varlığı hakkında tahmin algoritmaları incelenmiştir.


Makine Öğrenmesi

Makine öğrenmesi, mevcut bilgilerden hareketle tutarlı ve en doğru tahminleri yapmaya sağlayan öngörücü bir disiplin

olarak tanımlanır. Sağlıklı toplanmış büyük verileri tahmin algoritmaları ile işleyerek yeni veriler elde edilmesini sağlar (17). Mevcut verinin türü ve boyutu göz önünde bulundurulur, elde edilen sorunu çözmek için uygun algoritmayı seçmek çok önemlidir. Yüksek kaliteli ve niceliğe sahip veri kümeleri, çoğunlukla ML modellerinin doğruluğunu artırabilir (18)

En yakın komşu algoritması: Çalışma mantığı, bir veri seti içerisinde bağımsız değişkenleri sınıflandırarak en yakın komşuların hangi sınıfta olduğunu tahmin etmeye dayanır (2). Araştırmada, bağımsız değişkenlerin CPV varlığı hakkındaki tahminlerinin doğruluk değerleri incelenmiştir.

Rastgele Orman Algoritması: Hem regresyon hem de sınıflandırma gerektiren verilerin analizinde kullanılır. Veriye ait her bir düğümden rastgele alınmış özelliklerin en iyisini seçerek elde edilen bütün düğümleri dallara ayırarak verileri işler (19). Karar ağaçlarının oluşumunda budama işleminin olmaması ve rastgele tercihi kullanmasından dolayı diğer pek çok algoritmaya göre daha doğru ve hızlı sonuç vermektedir (20). Özellikle karmaşık ve çok boyutlu içeren büyük verilerin analizinde iyi derecede performans göstermesinden dolayı, Rastgele Orman tercih edilen öğrenme algoritmalarından biridir (21;22). Bu özelliklerinden dolayı, araştırmada, kanda farklı değerlerin, yaş ve yaşadıkları bölgeler ile ilişkileri CPV özelinde yorumlanmasında kullanılmıştır.



Şekil 1: Rastgele Orman Sınıflama Algoritması Çalışma Mantığı

Lojistik Regresyon: Türkçe karşılığı istatistiksel analiz de olan yöntem, genellikle tahmine dayalı olasılıkları modelleme için kullanılan bir makine öğrenimi uygulamasıdır. Yöntemde, bağımlı değişken sonlu veya kategoriktir (22;19). Araştırmada kullanılan veri seti de kategorik ve sonlu olmasından dolayı bu yöntem tercih edilmiştir.

Naive Bayes sınıflandırma algoritmaları: Hızlı ve kolay uygulanabilir sınıflandırma yöntemleri arasında tercih edilen bir yöntemdir. Sınıflandırmanın temeli Bayes teoremine dayanmaktadır. Olasılık hesabının yapıldığı Bayes teorimi verilerin bağımsız olması koşulu ile daha iyi sonuçlar vermektedir. Farklı A ve B olayları için;

$$P(A|B) = \frac{P(B|A) P(A)}{P(B)}$$

Bu durum aynı zamanda yöntemin en büyük dezavantajı olarak görülse de istatistiksel bağımsızlık şartları esnetilerek karmaşık yapay sinir ağları gibi yöntemlerle karşılaştırılabilir sonuçlar elde edilebilmektedir. Araştırmada değişkenlerin bağımsız olup olmama durumuna göre sonuç tahmini incelenmiştir.

Sağlık verilerinin analizlerinin makine öğrenmesinin farklı yöntemleri ile son yıllarda yapılmış çalışmalar Tablo 1’de gösterilmiştir.

Literatürde yer alan çalışmalar, hastalığın durumuna göre, araştırmacıların tercihinin göre ve bağımsız değişkenlere göre farklı makine öğrenmesi yöntemleri gösterilmiştir. Bu araştırma ise literatürde sık karşılaştığımız dahası veri setimiz ile çalışmaya uygun farklı yöntemleri deneyerek sonuçları karşılaştırmayı hedefler.

Tablo 1: Sağlık Verileri ve ML hakkındaki çalışmalar. ML: Makine Öğrenmesi; SVM: Destek Vektör Makineleri; DT: Karar Ağaçları; NB: Naive Bayes; ANN: Yapay Sinir Ağları; LR: Lojistik Regresyon; RF: Rastagele Orman; KNN: k-En Yakın Komşu

Yazar/lar	Kullanılan Yöntem	Açıklama
Bollig N ve ark (2020)	SVM, RF, DT, Baging, Boosting, LR	Atopik dermatiti olan köpeklerde tedavi başarısını tahmin etmişlerdir.
Saberioo M ve ark (2018)	RF, SVM, LR, KNN.	Gökkuşluğu Alabalığı diyetler türleri başarıları üzerinde bir sınıflandırma çalışması yapmışlardır.
Bollig N ve ark (2020)	LR, SVM, DT, RF, Boosting	Ölüm raporlarına göre ölüme neden olan hasatlıkların tahmini için Makine Öğrenmesi (ML) algoritmaları kullanılmıştır.
Liang R et al. (2020)	NB, ANN, SVM, RF, AdaBoost, C4.5	Afrika domuz hastalığını ML yöntemlerini kullanarak tahmin etmişlerdir.
Romero MP et al. (2021).	RF	İngiltere’deki sığır tüberkülozu hastalığı kontrolünü desteklemek için iki makine öğrenimi tahmin modelinin değerinin karşılaştırmışlardır.
Bates AJ ve Saldias B. (2019)	LR, KNN, DT, ANN, RF	İneklerde vücut kondisyon puanı ve başvuru oranı arasındaki ilişkinin ML ve lojistik regresyon kullanarak modellenmişlerdir.
Cihan P ve ark. (2019)	Literatür Bilgisi	Veterinerlik Alanında ML yöntemleri ile tanı teşhis belirleyen çalışmalar hakkında literatür taraması yapmışlardır.
Dilwani AAR. (2019)	LR, RF, Boosting, KNN	Acil servis hastalarını triyaj durumuna göre değerlendirmişlerdir.
Bizal Ö. (2014)	NB, KNN, DT, LR, SVM	Parkinson hastalığının belirlenmesinde makine öğrenmesi tekniklerini kullanmışlardır.

Yöntem

Veri Toplama Araçları: Proje kapsamında kullanılan büyük veri seti (EK 1) için Selçuk Üniversitesi Veteriner Fakültesi Deneysel Hayvanları Üretim ve Araştırma Merkezi Etik Kurulu’ndan (SÜVDAMEK), 13.02.2018 gün ve 2018/14 sayılı karar ile izin alınmıştır

Kullanılacak terimler:

Tanı: Parvovirüs var / Parvovirüs yok

Merkez: Marmara Bölgesi / Karadeniz Bölgesi / İç Anadolu Bölgesi

Günlük Yaş: Köpeğin gün olarak yaşı


MCHC: Ortalama Eritrosit Hemogloblin Konsantrasyonu (g/dL)

PLT: Platelets, trombosit ($\times 10^3/\mu\text{L}$)

Araştırma Yöntemi:

Araştırmada Veri Madenciliğinin alt çalışma alanlarından olan Makine öğrenmesinin En Yakın Komşu (KNN), Rastgele Orman, ve NaiveBayes sınıflandırma algoritmaları kullanılmıştır.

Tablo 1: Sağlık Verileri ve ML hakkındaki çalışmalar. ML: Makine Öğrenmesi; SVM: Destek Vektör Makineleri; DT: Karar Ağaçları; NB:NaiveBayes; ANN: Yapay Sinir Ağları; LR: Lojistik Regresyon; RF: Rastgele Orman; KNN: k-En Yakın Komşu

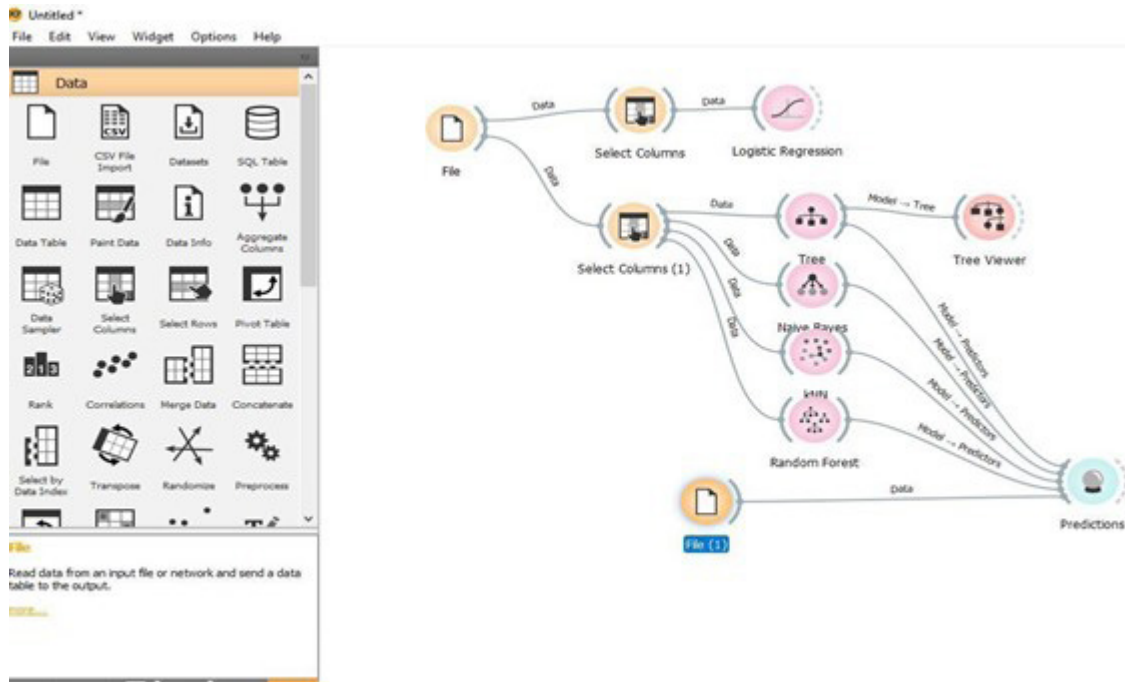


Araştırmada Orange Data Mining ve Jasp (JASP Team (2020). JASP (Version 0.14) [Computer software]) programı kullanılarak gerçekleştirilmiştir. Sonuçları daha iyi gözlemleyebilmek ve yöntem karşılaştırmalarının daha iyi görselleştirilmesi için araştırma ekibi tarafından tercih edilmiştir.

Bulgular

Araştırmada kullanılan veri seti öncelikle Orange Data Mining Programında incelenmiştir. Lojistik Regresyon, KNN, Rastgele Orman ve NaiveBayes Yöntemleri veri setinde uygulanmış (Tablo 2) ve doğruluk oranları incelenmiştir (Tablo 3)

Tablo 2: Orange Data Mining Programında Modellerin Uygulanması



Orange veri madenciliği programında modelin kurulması için öncelikle karar ağacı, NaiveBayes, KNN ve Rastgele Orman modelleri seçilerek ön görüsel bir modelleme kurul-

muştur. Ayrıca sınıflandırma performansını doğrulayabilmek için lojistik regresyon modeli kurulmuştur.

Tablo 3: ML yöntemlerinin doğruluk oranları

Model	AUC	CA	F1	Precision	Recall
Random Forest	0.998	0.976	0.976	0.976	0.976
KNN	0.990	0.949	0.949	0.949	0.949
Tree	0.996	0.970	0.970	0.970	0.970
Naive Bayes	0.556	0.568	0.525	0.543	0.568

Hastalık_Tanı	1:Var	2:Yok	GünlükYaş	Merkez	1:Marmara	2:Çanakkale	3:Karadeniz	PLT	MCHC
1	0.89	0.31	1	1.00	0.00	1.00	0.00	0.40	0.60
2	0.86	0.14	1	1.00	0.00	1.00	0.00	0.40	0.60
3	0.86	0.14	1	1.00	0.00	1.00	0.00	0.39	0.61
4	0.86	0.14	1	1.00	0.00	1.00	0.00	0.40	0.60
5	0.83	0.17	1	1.00	0.00	1.00	0.00	0.39	0.61
6	0.95	0.05	1	1.00	0.00	1.00	0.00	0.39	0.61
7	0.55	0.45	1	1.00	0.00	1.00	0.00	0.40	0.60
8	0.83	0.07	1	1.00	0.00	1.00	0.00	0.40	0.60
9	0.95	0.05	1	1.00	0.00	1.00	0.00	0.39	0.61
10	1.00	0.00	1	1.00	0.00	1.00	0.00	0.41	0.59
11	1.00	0.00	1	1.00	0.00	1.00	0.00	0.41	0.59
12	0.98	0.02	1	1.00	0.00	1.00	0.00	0.41	0.59
13	0.87	0.13	1	1.00	0.00	1.00	0.00	0.41	0.59
14	0.80	0.20	1	1.00	0.00	1.00	0.00	0.40	0.60
15	0.83	0.17	1	1.00	0.00	1.00	0.00	0.39	0.61
16	0.79	0.21	1	1.00	0.00	1.00	0.00	0.39	0.61
17	0.85	0.15	1	1.00	0.00	1.00	0.00	0.40	0.60
18	0.77	0.23	1	1.00	0.00	1.00	0.00	0.40	0.60
19	0.87	0.13	1	1.00	0.00	1.00	0.00	0.41	0.59
20	0.83	0.07	1	1.00	0.00	1.00	0.00	0.41	0.59

Doğru sınıflandırma kriterlerine bakıldığında eğri altında kalan alan (AUC) değerlendirildiğinde %99,8 yüzdeyle en yüksek performansı Rastgele Orman modeli ardından %99,6 oranıyla karar ağacı modeli ve %99 başarıyla KNN yöntemi göstermiştir. NaiveBayes yöntemi ise öngörü olasılığının ön-

sel bir olasılığa dayandırıldığı için %55,6 doğru sınıflandırma oranıyla diğer 3 modelden oldukça sınırlı şekilde çalışmıştır.

Bu sonuçlara göre parvovirüs olup olmama durumu, köpeklerin günlük yaşları, MCHC (g/dL) ve PLT ($\times 10^3/\mu\text{L}$) he-

matolojik parametreleri ile Rastgele Orman, KNN ve karar ağaçlarıyla modelleriyle doğru bir kesinlikle sınıflandırılabilir.

Lojistik Regresyon Uygulaması

Veri setine lojistik regresyon uygulaması sonucunda elde edilen çıktılar değerlendirilmiştir.

Çizelge 1: Lojistik regresyon model değerlendirme

Model Summary - Hastalık_Tanı										
Model	Deviance	AIC	BIC	df	X ²	p	McFadden R ²	Nagelkerke R ²	Tjur R ²	Cox & Snell R ²
H ₀	60742.534	60744.534	60753.239	44591						
H ₁	59067.591	59079.591	59131.823	44586	1674.943	< .001	0.028	1.000	0.037	1.000

Analiz gerçekleştirildikten sonra ilk olarak modelin anlamlılık değerleri değerlendirilir. Bu değerlendirmeler için McFadden R² ve TjurR² değerleri incelendiğinde çoklu regresyonda elde edilen R² 'ye göre oldukça küçük değerler alma eğiliminde olup 1'e yaklaştıkça modelin açıklama gücü artarken 0'a yaklaştıkça azalır. Çıktılar sonucunda elde et-

tiğimiz değer McFaddenR² için 0,028 ve TjurR² için 0,037 olarak bulunmuş ve bu değer yeterli olduğu görülmüştür. NagelkerkeR² ve Cox&SnellR² sonuçlarına göre bağımsız değişkenler bağımlı değişkenin tamamını açıklamaktadır. Bu sonuçlar doğrultusunda modelin mükemmel uyum sahip olduğu söylenilir (=1674,943 p<0,001).

Çizelge 2: Lojistik regresyon model katsayı tahminleri

	Estimate	Standard Error	Standardized*	Odds Ratio	z	Wald Test			95% Confidence interval	
						Wald Statistic	df	p	Lower bound	Upper bound
(Intercept)	-0.179	0.093	0.837	0.836	-1.921	3.689	1	0.055	-0.362	0.004
GünlükYaş	0.048	0.003	0.547	1.050	13.847	191.752	1	< .001	0.042	0.055
MCHC	-0.047	0.003	-0.648	0.954	-16.108	259.473	1	< .001	-0.053	-0.042
PLT	0.002	0.001	0.017	1.002	1.782	3.175	1	0.075	-0.000	0.003
Merkez (İç Anadolu Bölgesi)	-0.167	0.032	-0.167	0.846	-5.291	27.993	1	< .001	-0.229	-0.105
Merkez (Karadeniz Bölgesi)	-0.829	0.027	-0.829	0.437	-30.201	912.101	1	< .001	-0.882	-0.775

Note. Hastalık_Tanı level 'Yok' coded as class 1.

* Standardized estimates represent estimates where the continuous predictors are standardized (X-standardization).

Model için katsayı değerleri incelendiğinde Günlük yaş, MCHC ve Merkez değişkenleri model için anlamlı etkiye sahip iken PLT ve sabit (Intercept) değerlerinin model üzerinde anlamlı etkisi yoktur.

Günlük Yaşta bir birimlik artış parvovirüs bulunma olasılığını 1.050 kat arttırmaktadır. (%10). MCHC değerindeki bir birimlik artış parvovirüs bulunma olasılığını 0,954 kat azaltmaktadır. İç Anadolu'dan alınan örneklerdeki köpeklerin Marmara bölgesine göre parvovirüs bulunma olasılığını 0,846 kat daha azdır. Karadeniz bölgesinden alınan köpeklerin ise parvovirüs bulunma olasılığını 0,437 kat daha azdır.

Çizelge 3: Lojistik regresyon hata matrisi

Observed	Predicted	
	Var	Yok
Var	0.043	0.379
Yok	0.039	0.539

Çizelge 4: Lojistik regresyon performans metrikleri

Performance metrics	
	Value
AUC	0.659
Sensitivity	0.940
Precision	0.582
F-measure	0.719

Oluşturulan model sonucunda tahmin değerleri ile gerçek değerlerin değerlendirmesi hata matrisi verilmiştir. Bu değerlendirme sonucunda CPV olan köpekleri %4,3 olmayan köpekleri ise %53,9 oranında doğru tahmin etmiştir. Toplamda model %58,2 doğru tahmin yaparken %41,8 yanlış tahmin yapmaktadır. Bu sonuçlar model anlamlı olsa da sonuçlarda büyük oranda hata olduğu görülmektedir.

Performans metrikleri değerlendirildiğinde eğri altında kalan alan 0,659, doğruluk 0,940, kesinlik 0,582 ve F ölçütü 0,719 olarak elde edilmiştir.

Rastgele Orman Algoritması Uygulaması

Veri setinde Rastgele Orman algoritması uygulaması sonucunda elde edilen çıktılar değerlendirilmiştir.

Çizelge 5: Rastgele Orman model değerlendirme

Random Forest Classification ▼							
Trees	Predictors per split	n(Train)	n(Validation)	n(Test)	Validation Accuracy	Test Accuracy	OOB Accuracy
96	2	28539	7135	8918	0.959	0.955	0.963

Note. The model is optimized with respect to the out-of-bag accuracy.

Modelde 100 ağaç üretilmiş ve bu ağaçlardan 96. ağacın en uygun sonucu verdiği tespit edilmiştir. Bu ağaçtaki doğrulama setindeki açıklayıcı değişkenler ile hedef değişken arasında uyum %96, test setindeki uyum %95 ve modelin test ve eğitim seti arasındaki doğruluk oranı %96 olarak bulunmuştur. Bu sonuçlara göre eğitim veri seti ile test veri seti arasında yüksek bir doğruluk oranı elde edilmiş ve modelimiz iyi bir uyuma sahip olduğu söylenebilir.

Çizelge 6: Rastgele Orman model hata matrisi

		Predicted	
		Var	Yok
Observed	Var	0.4	0.03
	Yok	0.02	0.56

Oluşturulan model sonucunda tahmin değerleri ile gerçek değerlerin değerlendirmesi hata matrisinde verilmiştir. Bu değerlendirme sonucunda CPV olan köpekleri %40 olmayan köpekleri işe %56 oranında doğru tahmin etmiştir. Toplamda model %96 doğru tahmin yaparken %4 yanlış tahmin yapmaktadır. Bu sonuçlar Rastgele Orman algoritmasının mükemmel bir doğrulukla tahmin yaptığı tespit edilmiştir.

Performans metrikleri değerlendirildiğinde eğri altında kalan alan 0,987, doğruluk 0,954, kesinlik 0,954 ve F ölçütü 0,954 olarak elde edilmiştir.

Doğruluktaki ortalama düşüş (Meandecrease in accuracy), her bir özelliğin Rastgele Orman modelinin doğruluğu üzerindeki etkisini ölçmek için değerlendirildi. Bunun sonucunda Rastgele Orman modelinin doğruluğu için en önemli değişken RDW olarak belirlendi. Sınıf ayırma önemi (Total increase in nodepurity) ise hangi değişkenin sınıfları belirlemede daha önemli olduğunu gösterir. Bunun sonucunda sınıf belirlemedeki en önemli değişken de RDW olarak belirlendi.

Çizelge 7: Rastgele Orman metrikleri

Evaluation Metrics

	Precision	Recall	F1 Score	Support	AUC
Var	0.951	0.939	0.945	3784	0.987
Yok	0.956	0.965	0.960	5134	0.987
Average / Total	0.954	0.954	0.954	8918	0.987

Note. Area Under Curve (AUC) is calculated for every class against all other classes.

Çizelge 8: Rastgele Orman değişken önemleri

Variable Importance ▼		
	Mean decrease in accuracy	Total increase in node purity
RDW	0.345	0.390
HCT	0.261	0.329
Şehir	0.010	0.008
MCHC	0.003	0.003

KNN Algoritması Uygulaması

KNN algoritması uygulaması sonucunda elde edilen çıktılar değerlendirilmiştir.

Veri setinde 44592 köpek değerlendirilmiştir. Bu veri setinden Hold-out yöntemi ile %20 (8918) test veri seti için

rastgele örneklem seçilmiştir. 44592 köpekten %20'si test veri setinin kullanıldığı için kalan %80 (35674) kişiden %20 (7135) oranında örneklem alınarak bu örnekleme de doğrulama için kullanılmıştır. Kalan veri (28539) eğitim için kullanılmıştır.

Çizelge 9: KNN model değerlendirme

K-Nearest Neighbors Classification

Nearest neighbors	Weights	Distance	n(Train)	n(Validation)	n(Test)	Validation Accuracy	Test Accuracy
2	rectangular	Euclidean	28539	7135	8918	0.732	0.847

Note. The model is optimized with respect to the validation set accuracy.

Çizelge 10: KNN model hata matrisi

		Predicted	
		Var	Yok
Observed	Var	0.34	0.08
	Yok	0.07	0.51

Oluşturulan model sonucunda tahmin değerleri ile gerçek değerlerin değerlendirmesi hata matrisi verilmiştir. Bu değerlendirme sonucunda CPV olan köpekleri %34 olmayan köpekleri ise %51 oranında doğru tahmin etmiştir. Toplamda model %85 doğru tahmin yaparken %15 yanlış tahmin yapmaktadır. Bu sonuçlar En Yakın Komşu algoritmasının iyi bir doğrulukla tahmin yaptığı tespit edilmiştir.

Çizelge 11: KNN performans metrikleri

Evaluation Metrics

	Precision	Recall	F1 Score	Support	AUC
Var	0.823	0.807	0.815	3721	0.865
Yok	0.864	0.876	0.870	5197	0.865
Average / Total	0.847	0.847	0.847	8918	0.865

Note. Area Under Curve (AUC) is calculated for every class against all other classes.

Tablo 4: LR, RF ve KNN değerleri

	PLT Değişkeni	Toplam Doğruluk (%)	AUC	Duyarlılık	Kesinlik	F ölçütü
Lojistik Regresyon (LR)	Var	58,2	0,659	0,94	0,582	0,719
	Yok	57,6	0,679	0,933	0,583	0,717
Random Forest (RF)	Var	96	0,99	0,955	0,955	0,955
	Yok	68	0,626	0,688	0,699	0,69
KNN	Var	85	0,847	0,853	0,853	0,853
	Yok	97	0,994	0,964	0,965	0,965

Performans metrikleri değerlendirildiğinde eğri altında kalan alan 0,865, doğruluk 0,847, kesinlik 0,847 ve F ölçütü 0,847 olarak elde edilmiştir.

Toplam doğruluk değerleri incelendiğinde anlamsız değişken modelde çıkarıldığında lojistik regresyon ve RF yöntemlerinde doğruluk oranları düşmüştür.

RF yöntemi PLT değişkeni modelde iken en iyi tahminleri yapmıştır. Bu değişkeni modelden çıkarmak istemediğimiz durumlarda bize çok verimli sonuçlar verebilmektedir.

KNN yöntemi değişken sayısı azaldığında daha iyi sonuçlar vermektedir. Bu sebeple değişken sayısını azaltmak istediğimizde bu yöntemi kullanabiliriz.

NaiveBayes modeli önsel olasılığın doğru kesinlikle sınıflandırılmadığı için değerlendirilmemiştir.

Sonuç ve Tartışma

Sonuç olarak, toplam doğruluk değerleri incelendiğinde anlamsız değişken modelde çıkarıldığında lojistik regresyon ve RF yöntemlerinde doğruluk oranları düşmüştür. RF yöntemi PLT değişkeni modelde iken en iyi tahminleri yapmıştır. Bu değişkeni modelden çıkarmak istemediğimiz durumlarda bize çok verimli sonuçlar verebilmektedir. KNN yöntemi değişken sayısı azaldığında daha iyi sonuçlar vermektedir. Bu sebeple değişken sayısını azaltmak istediğimizde bu yöntemi kullanabiliriz.

Bu çalışmada, tanı testlerinin performanslarını değerlendirirken duyarlılık, seçicilik ve Roc eğrisi altında kalan alan önemli ölçütler olmuştur. Uygun kesim noktasının AUC değerlerine bağlı olduğu görülmüştür. Duyarlılık ve seçicilik ne kadar yüksek ise AUC değerleri de o kadar yüksek olmuştur. Bunun sonucunda yüksek AUC değerleri de uygun kesim noktasını vermiştir. Bu çalışma ile, parvoviral enterit hastalığının teşhisi için, uygulanan istatistiksel hesaplamalar ile modellendiği ortaya konmuştur. Prognoz sürecinde deneğin MCHC, Platelet ve hangi bölgeden olduğu bilindiğinde parvoviral enterit hastalığının teşhisi için Rastgele Orman,

KNN ve karar ağaçları modelleriyle doğru bir seçim yapılabilir. Sonuçlar, ileride yapılacak bölgede/ülkede yayılım gösteren CPV suşlarını içeren aşılarda üretilmesi ve CPV'nin antijenik varyantlarının belirlenmesine dönük moleküler karakterizasyon çalışmalarına kaynak olacağı düşünülmektedir. Teşhis koymaya çalışan hekimler, bu değişkenler ile elde edilen sınıflandırma modellerini kullanarak yararlanabilirler. Sonuç olarak; köpeklerin parvoviral enterit hastalığının teşhisinde kan hemogram değerlerinden MCHC, Platelet ve yaş parametrelerinin kesim noktaları göz önünde bulundurularak büyük doğrulukla karar vermede yardımcı olacağı ortaya çıkmıştır. İleride yapılacak çalışmalara da kaynak olabilecektir

KAYNAKLAR

1. Karim, M. R., Beyan, O., Zappa, A., Costa, I. G., Rebholz-Schuhmann, D., Cochez, M., & Decker, S. Deep learning-based clustering approaches for bioinformatics. *Briefings in Bioinformatics*, (2021), 22(1), 393-415.
2. Li, H., Xue, Y., & Zeng, X. Investigation of data mining technique and artificial intelligence algorithm in microflora bioinformatics. In *E3S Web of Conferences* (2021). (Vol. 267, p. 01040). EDP Sciences.
3. De Mauro, A., Greco, M., & Grimaldi, M. What is big data? A consensual definition and a review of key research topics. In *AIP conference proceedings* (2015), (Vol. 1644, No. 1, pp. 97-104). American Institute of Physics.
4. Pathak, R. K., Singh, D. B., & Singh, R. Introduction to basics of bioinformatics. (2022). In *Bioinformatics* (pp. 1-15). Academic Press.
5. Ebrahimi, F., Asemi, A., Shabani, A., & Nezarat, A. Developing a Prediction Model for Author Collaboration in Bioinformatics-Research Using Graph Mining Techniques and Big Data Applications. *International Journal of Information Science and Management* (2021). (*IJISM*), 19(2), 1-18.
6. Sakulwira, K., Vanapongtipagorn, P., Theamboonlers, A., Oraveerakul, K., & Poovorawan, Y. Prevalence of canine coronavirus and parvovirus infections in dogs with gastroenteritis in Thailand. *Veterinari Medicina*, (2003). 48(6), 163..
7. Filipov, C., Decaro, N., Desario, C., Amorisco, F., Sciarretta, R., & Buonavoglia, C. Canine parvovirus epidemiology in Bulgaria. *Journal of Veterinary Diagnostic Investigation*, (2011), 23(1), 152-154.

8. ÖZKUL, A., KELEŞ, İ., KARAOĞLU, T., ÇABALAR, M., & BURGU, İ. Detection and rflp analysis of canine parvovirus (cpv) dna by polymerase chain reaction (pcr) in a dog. *Turkish Journal of Veterinary and Animal Sciences*, (2002). 26(5), 1201-1203.
9. Sellers, R. F., & Pedgley, D. E. (1985). Possible windborne spread to western Turkey of bluetongue virus in 1977 and of Akabane virus in 1979. *Epidemiology & Infection*, 95(1), 149-158.
10. Sterzing, F., Kratochwil, C., Fiedler, H., Katayama, S., Habl, G., Kopka, K., ... & Giesel, F. L. (2016). 68Ga-PSMA-11 PET/CT: a new technique with high potential for the radiotherapeutic management of prostate cancer patients. *European journal of nuclear medicine and molecular imaging*, 43(1), 34-41.
11. Khan, N. T. (2018). Data Mining—Basics of Bioinformatics. *Transcriptomics*, 6(142), 2.
12. Mahapatro, P. S. Association Rule Mining in HealthCare: A Study. *Studies in Indian Place Names*, (2020). 40(53), 87–91.
13. Dinov, I. D. Volume and value of big healthcare data. *Journal of medical statistics and informatics*, (2016). 4.
14. Polat, M., & KARAHAN, A. (2009). Multidisipliner yeni bir bilim dalı: biyoinformatik ve tıpta uygulamaları. *SDÜ Tıp Fakültesi Dergisi*, 16(3), 41-50.
15. Snyder, L. V., Atan, Z., Peng, P., Rong, Y., Schmitt, A. J., & Sinoysal, B. (2016). OR/MS models for supply chain disruptions: A review. *Iie Transactions*, 48(2), 89-109.
16. Zeynep, ÖZEL ve DEMİRSÖZ, M. . Makine Öğrenmesi Yöntemleri İle Covid-19 Verilerinin İncelenmesi: Türkiye Örneği: An Analysis of Covid-19 Data With Machine Learning Methods: The Case of Turkey. *Sağlık Bilimlerinde Yapay Zeka Dergisi (Journal of Artificial Intelligence in Health Sciences) ISSN: 2757-9646*, 1(2), 1-7.(2021)
17. Kochetkova, O. V., & Shiryayeva, E. V. Perspective architecture of dairy farming enterprises, using modern digital technologies for sustainable development. In *IOP Conference Series: Earth and Environmental Science* (2022), (Vol. 965, No. 1, p. 012062). IOP Publishing.
18. Ghaffarian, S., van der Voort, M., Valente, J., Tekinerdogan, B., & de Mey, Y. . Machine learning-based farm risk management: A systematic mapping review. *Computers and Electronics in Agriculture*, (2022), 192, 106631.
19. Bollig N, DeBoer D, Döpfer D Learning Tutorial for Veterinarians: Examples Using Canine Atopic Dermatitis, (2020)
20. Yazdanbakhsh, O., Zhou, Y., & Dick, S. An intelligent system for livestock disease surveillance. *Information Sciences*, (2017). 378, 26-47.
21. Kılınçalp, S., Ekiz, F., Başar, Ö., AYTE, M. R., ÇOBAN, Ş., YILMAZ, B., ... & YÜKSEL, O. (2014). Mean platelet volume could be possible biomarker in early diagnosis and monitoring of gastric cancer. *Platelets*, 25(8), 592-594.
22. Saberioon M, Císar P, Labbé L, Souček P, Pelissier, P ve Kerneis T. Comparative performance analysis of support vector machine, random forest, logistic regression and k-nearest neighbours in rainbow trout (*Oncorhynchus mykiss*) classification using image-based features. *Sensors*, (2018). 18(4), 1027.

Sağlık Bilimlerinde Yapay Zeka Dergisi

Journal of Artificial Intelligence in Health Sciences

A New Paradigm For Predicting Past And Future Out of Control Events In Internal Quality Control: Gaussian Process For Machine Learning

İç Kalite Kontrol Süreçlerinde Geçmiş ve Gelecekteki Kontrol Dışı Olayları Tahmin Etmede Yeni Bir Paradigma: Makine Öğrenimi için Gaussian Modeli

Suleyman Sevinc¹, Ali Riza Sisman², Banu Isbilen Basok*³, Murat Aksit³, Pinar Bilgi⁴, Oktay Yildirim¹, Eminullah Yasar¹, Ayfer Colak³, Can Duman⁵, Gokhan Akbulut⁶

Running Title: Predictive Quality Control Algorithm

Kısa Başlık: Tahmine Dayalı Kalite Kontrol Algoritması

Keywords: *Quality assurance, internal quality control, Gaussian Process Machine Learning, predictive quality control algorithm, quality control procedure, total analytical error.*

Abbreviations:

IQC: Internal quality control

TAE: Total analytical error

TEa: Total allowable error

GPR: Gaussian process regression

GPML: Gaussian process for machine learning

PQCA: Predictive quality control algorithm

CI: Confidence interval

OOCE: Out-of-control event

FSH: Follicle stimulating hormone

SD: Standard deviation

TAEP: Predicted total analytical error

RBF: Radial basis function, a.k.a squared exponential covariance function

TAEP: Total analytical error-predicted

ABSTRACT

Internal Quality Control (IQC) is the process of evaluating and controlling the reliability of a laboratory test before running patient samples. Currently used IQC process focus on the management of Total Analytical Error (TAE) using rule-based approaches. The process cannot predict timings of Total Allowable Error (TEa) violations, precisely. In the study, we proposed a predictive computational approach for IQC, Predictive Quality Control Algorithm (PQCA), to solve with this problem using Gaussian Process for Machine Learning (GPML) method. The software implementation carried out in Python and Scikit-learn library running

Received / Geliş	8.12.2022
Accepted / Kabul	28.12.2022
Publication Date	30.12.2022

*Sorumlu Yazar

Corresponding Author

Banu İSBİLEN BASOK*³ Suleyman SEVİNC, Oktay YILDİRİM¹
İstinye Üniversitesi, Labenko A.I.,
İstanbul Türkiye İzmir, Turkey.
ORCID iD: 0000-0002-1483-997X Suleyman Sevinc ORCID iD: 0000-0001-9052-5836
Oktay Yildirim ORCID iD: 0000-0001-7281-3623

Ali Rıza SİSMAN² **Murat AKSİT, Ayfer COLAK**³
Dokuz Eylül University, Health Sciences University,
Faculty of Medicine, İzmir Tepecik Training and Research Hospital,
Department of Medical Biochemistry, Department of Medical Biochemistry,
İzmir, Turkey İzmir, Turkey
ORCID iD: 0000-0002-9266-0844 Murat Aksit ORCID iD: 0000-0003-2106-9130
Ayfer Colak ORCID iD: 0000-0003-4910-0128

Pinar BİLGİ⁴ **Can DUMAN**⁵
Konya City Training and Research Hospital, İzmir Democracy University,
Department of Medical Biochemistry, Faculty of Medicine,
Konya, Turkey Department of Medical Biochemistry,
İzmir, Turkey
ORCID iD: 0000-0001-6598-0458 ORCID iD: 0000-0002-2630-0664

Gokhan AKBULUT⁵
Tınaztepe University,
Galen Bayraklı Hospital,
Department of General Surgery,
İzmir, Turkey
ORCID iD: 0000-0002-3924-5342

Çıkar Çatışması

Yazarlar herhangi bir çıkar çatışması veya finansal destek bildirmemişlerdir.

Finansman

Herhangi bir finansal destek alınmamıştır.

Teşekkürler

Bu çalışma 1. Sağlıkta Yapay Zeka Kongresi'nde sözlü bildiri olarak sunulmuş ve kongre kitabında özet metin olarak yayımlanmıştır.

Etik Onay

SBÜ İzmir Tepecik Eğitim ve Araştırma Hastanesi Girişimsel Olmayan Araştırmalar Etik Kurulu 11.12.2017, 2017/20 Sayılı Etik Kurul Kararı

Yazar Katkıları

Motivasyon / Konsept: SS, ARS, BIB
Çalışma Tasarımı: SS, ARS, BIB
Kontrol / Gözetim: SS, ARS, BIB
Veri Toplanması ve / veya İşlemesi: SS, ARS, OY, EY, MA, PB
Analiz ve / veya Yorum: SS, ARS, BIB, OY, EY, AC, CD, GA, PB, MA
Literatür inceleme: SS, ARS, BIB, AC, CD
Makalenin Yazılması: SS, ARS, BIB, OY, EY
Eleştirel İnceleme: ARS, BIB, AC, CD, GA, PB, MA

on a standard Windows-based PC. A digital control chart based on PQCA was introduced. It is demonstrated that observations fall within the 95% confidence intervals of their corresponding predictions generated by PQCA. It also presented that TAE calculated using classical formula is unable to capture all violations of TEa. PQCA is a simple procedure that can directly relate raw control data to quality targets and enabled a predictive approach with a high degree of accuracy. The classical TAE calculation model is based on a univariate Gaussian model. GPML, which PQCA is based on, is generalized by a multivariate Gaussian. Therefore, PQCA can be viewed as a generalization of the classical IQC model. Using PQCA, laboratories can take a proactive approach to the control of analytical quality, meet regulatory institutions' requirements, and hence provide better patient outcomes. PQCA based IQC can achieve controlling of analytical variability using a single algorithm overcoming the shortcomings of conventional methods. In the future, newly available computational models make possible more sophisticated, predictive mathematical frameworks for IQC.

ÖZET

İç Kalite Kontrol (İKK), hasta numunelerini çalıştırmadan önce bir laboratuvar testinin güvenilirliğini değerlendirme ve kontrol etme sürecidir. Mevcut İKK süreci, kural tabanlı yaklaşımlar kullanarak Toplam Analitik Hatanın (TAE) yönetimine odaklanmaktadır. Toplam İzin Verilebilir Hata (TEa) ihlallerinin zamanlamasını tam olarak tahmin edemez. Çalışmada, Tahmine Dayalı Kalite Kontrol Algoritması (PQCA) için Gaussian Process for Machine Learning (GPML) yöntemini kullanarak İKK sürecini değerlendirmede tahmine dayalı bir hesaplama yaklaşımı önerildi. Python ve Scikit-learn kütüphanesinde yürütülen yazılım uygulaması, Windows tabanlı standart bir PC üzerinde çalıştırıldı. PQCA'ya dayalı bir dijital kontrol tablosu oluşturuldu. Gözlemlerin, PQCA tarafından üretilen karşılık gelen tahminlerinin %95 güven aralığı içinde kaldığı gösterildi. Ayrıca, klasik formül kullanılarak hesaplanan TAE'nin tüm TEa ihlallerini yakalayamadığı da ortaya konuldu. PQCA, ham kontrol verilerini doğrudan kalite hedefleriyle ilişkilendirebilen basit bir prosedür olup, yüksek derecede doğrulukla tahmine dayalı bir yaklaşım sağlamıştır. Klasik TAE hesaplama modeli, tek değişkenli bir Gauss modeline dayanır. PQCA'nın temel aldığı GPML, çok değişkenli bir Gaussian modeldir. Bu nedenle PQCA, klasik IQC modelinin bir genellemesi olarak görülebilir. Laboratuvarlar, PQCA'yı kullanarak analitik kalitenin kontrolüne proaktif bir yaklaşım getirebilir, düzenleyici kurumların gereksinimlerini karşılayabilir ve dolayısıyla daha doğru ve güvenilir hasta sonuçları sağlayabilir. PQCA tabanlı İKK, geleneksel yöntemlerin eksikliklerinin üstesinden gelen tek bir algoritma kullanarak analitik değişkenliğin kontrolünü

sağlayabilir. Gelecekte, yeni kullanılabilir hesaplama modelleri, İKK için daha karmaşık, tahmine dayalı matematiksel çerçeveleri mümkün kılacaktır.

INTRODUCTION

Laboratory tests play a main role in the diagnosis, treatment, and prognosis and constitute a principal part of electronic patient records. For this reason, accuracy and repeatability, two basic parameters that demonstrate the performance of laboratory tests, should be guaranteed. When the accuracy and repeatability of a measurement system do not change, or the range of the measurement series is called "analytical run" according to the Clinical & Laboratory Standards Institute guideline C24-A2 (1). It is the utmost 24 hours for biochemical tests as declared by Clinical Laboratory Improvement Advisory Committee (CLIA)(2).

Internal Quality Control (IQC) is an evaluation process of the laboratory's reliability using quality control materials with different levels of analyte concentrations before running patient samples, i.e. before each run, and whether the result is within the acceptable range. In particular, it aims at controlling the analytical processes in use. In the process, "quality control charts" used, which are historically similar to those employed in the industry. The most well-known charts are Levey-Jennings control charts, with mean target and standard deviation (SD) limits. In routine, IQC result from each run are marked on the charts, at how many SDs from the target value. Westgard multi-rules are most often used in medical laboratories to evaluate the IQC results (3). For tests with different analytical performance, it is not very practical to use the fixed rules. Therefore, it is recommended using "individualized quality control rules" according to the analytical performance of each test. To prevent non-standardized IQC assessment of laboratory staff from these assessment challenges, many laboratories prefer to use the a few of Westgard multiple rules rather than all.

IQC is based on the acceptance or rejection of the distance (bias) of the control results in the run; however the power to show repeatability is somewhat weaker. For this reason, in addition to IQC applications, total analytical error (TAE) is monitored to determine analytical performance in clinical laboratories (4). TAE is the combination of bias and precision, and is calculated by the formula as $\text{bias} \pm 1.65 \text{ CV}\%$. Therefore, it is a common practice to use as a quality indicator for test performance (4). It has also become the focus of routine IQC work conducted regularly at many clinical laboratories.

TAE is primarily used to characterize the past analytical performance of clinical laboratories by regulatory bodies. Laboratories need to ensure the future performance of their analytical systems so that future analytical errors lie within Total Allowable Error (TEa). TAE's current formulations do

not adequately mitigate these two diverging needs. In particular, the following issues need to address:

a. Current methods used in practice to compute TAE summarize the past performance of analytical systems. They do not offer any formal inference procedures for predicting the performance of analytical systems for a specific point in the future.

b. In theory, TAE might exceed the allowable limit at any time point. That is called an out-of-control event (OOCE). In cases an OOCE has been identified to occur at a control measurement point, the current IQC procedures do not offer any support to determine the certain moment when this OOCE might have started.

c. In Levey-Jennings chart, as one of the most widely used IQC tools, the acceptable limits are usually defined as two SDs, in each direction. Manufacturer based SD limits are often wider than the TEa limits currently used in practice (5). Consequently, control results accepted in routine practice, based on Levey-Jennings charts, may be classified as unacceptable based on TEa.

In the 1970s, Westgard used power-function curves when defining rules that set OOCEs. However, high-capacity central processors, graphics processors, and artificial intelligence software tools were not available in those years. However, we have high-capacity hardware and software support with artificial intelligence today. In the study, we aimed to propose a computational framework, "Predictive Quality Control Algorithm (PQCA)", which is a generalization of TAE and captures the temporal aspects of the data, to overcome all of

the above shortcomings of the current approaches. This new algorithm is designed to enable laboratories to take corrective actions in case of past OOCEs and to take preventative actions in case of future OOCEs through predictive capabilities and, hence a heightened level of readiness, and a new problem-solving capability are provided to laboratories.

MATERIALS AND METHODS

Routine IQC data from the database of the clinical laboratories at XXX Training and Research Hospital were retrospectively used in the study. No patient data was reported based on the findings of this study. The study was conducted by following the Helsinki Declaration, and the approval of the local ethics committee of XXX Training and Research Hospital (Decision No: 14/20, 2017) has been obtained.

A total of 10 analytes included in this work: aspartate aminotransferase, calcium, creatinine, glucose, sodium, CA 15.3, cortisol, follicle-stimulating hormone (FSH), insulin, testosterone, thyroid stimulating hormone, and vitamin B12 (see Table 1). These analytes have been chosen for the following reasons; a) to represent photometric, potentiometric, and immune-chemical assays, b) because they are common and easily recognizable. Each collected data was evaluated by two medical biochemistry specialists, one for each biochemical and immunochemical test group. IQC data was normally checked against non-analytical errors, e.g., human errors, marked if found to be erroneous and the control measurement was repeated. Data marked as erroneous were not included in the study. TAE is the combination of bias and precision, and is calculated by the formula as $\text{bias} \pm 1.65 \text{ CV\%}$ (4).

Table 1. Analytes evaluated within the scope of the study.

Analyte	Units	Analyzer	Method	IQC Product Specifications
AST Ca CREA Glc	U/L mg/dL mg/dL mg/dL	AU 5800 Beckman Coulter Inc., CA, USA	Spectrophotometric	Beckman Coulter Control Serum Level 1 and 2, Catalogue Number ODC0003-ODC0004, Lot Number 0037-0038
Na	mmol/L	AU 5800 Beckman Coulter Inc., CA, USA	Indirect potentiometric	Beckman Coulter Control Serum Level 1 and 2, Catalogue Number ODC0003-ODC0004, Lot Number 0037-0038
CA 15.3	U/mL	UniCel DxI 800 Beckman Coulter Inc., CA, USA	Chemiluminescence	MAS T-Marker Liquid Assayed Immunoassay Control Level I and II, Catalogue Number TUM-101- TUM-202, Lot Number TM19061- TM19062, Thermo Fischer Scientific Inc., MA, USA
Cortisol Insulin Testosteron TSH Vitamin B12	µg/dL µIU/mL ng/dL µU/mL pg/mL	UniCel DxI 800 Beckman Coulter Inc., CA, USA	Chemiluminescence	MAS Liquimmune Liquid Assayed Immunoassay Control Level I and II, Catalogue Number LIG-101- LIG-202, Lot Number LIA20041- LIA 20042, Thermo Fischer Scientific Inc., MA, USA

AST: aspartate aminotransferase; Ca: calcium; CREA: creatinine; Glc: Glucose; IQC: internal quality control; Na: sodium; TSH: thyroid stimulating hormone.

Gaussian Process for Machine Learning (GPML) (6) was used as the formal basis of the predictive model proposed in this work. GPML’s computational implementation was performed using Python 3.6.2 and Sci-Kit Learn Library 0.19.1 (7). A 64-bit Windows 10 machine (Intel i5 5200-U, 12 GB RAM) was used to run experiments reported in this article. Gaussian Process For Machine Learning

GPML is an extensive machine-learning algorithm for solving time-series-based medical problems (8-10). GPML is proposed as a probabilistic model to capture the generative process of control measurement variability. The selection of GPML is justified based on the fact that clinical laboratory control measurements are widely assumed to be normally distributed (1). This makes GPML an ideal candidate for our purposes as it is generalized by a multivariate Gaussian. The mean vector and the covariance matrix K together define multivariate Gaussian, uniquely. In GPML, the covariance between two points in the time series of control measurements is defined by a positive definite kernel function k. For

two output-input pairs, (y, t) and (y', t'), the kernel function defines $K(y, y') = k(t, t')$. Given a set of training observations y, t the distribution of test points y*, t* is

$$p(y^*|y) \sim N(\mu^*, \Sigma), \text{ (Equation 1)}$$

such that

$$\mu^* = K(t^*, t) K(t, t)^{-1} y, \text{ (Equation 2a)}$$

$$\Sigma = K(t^*, t^*) - K(t^*, t) K(t, t)^{-1} K(t, t^*) \text{ (Equation 2b)}$$

The kernel k is a function whose behavior is governed by a set of hyper-parameters.

A kernel function is used to compute the covariance matrix. Thus, it plays a major role in the success of the GPML model. Although mathematically a vast number of kernel functions can be defined, the kernel function to be used for a specific analytical method needs to be consistent with the data observed. In Figure 2, PQCA output was shown for the same data as in Figure 1 except that the kernel function is chosen to be Matern instead of Radial Basis Function (RBF) (11). A close look at the two figures could show differences in details.

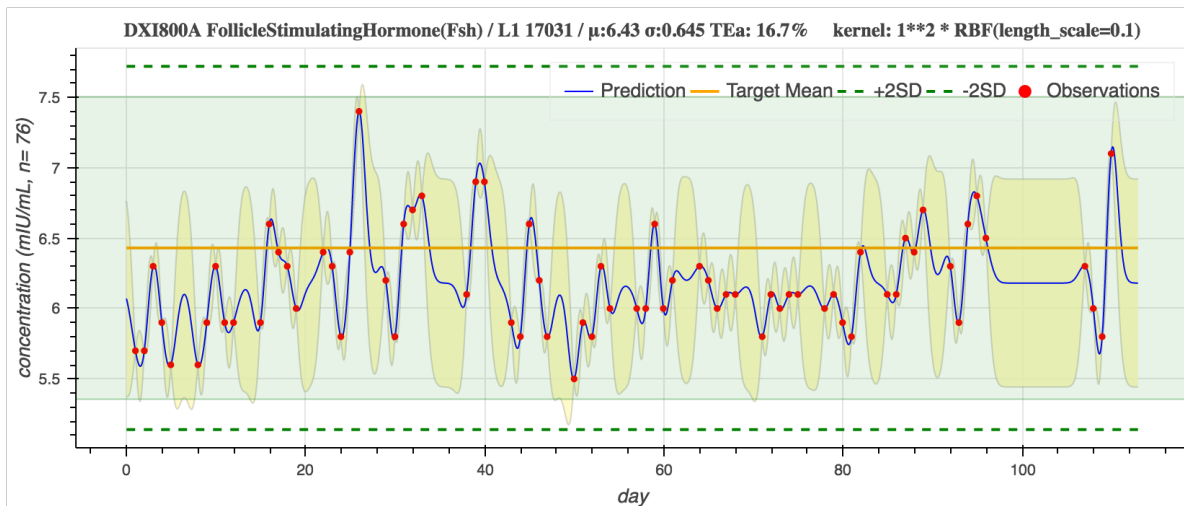


Figure 1. A Digital control chart for FSH level 1 control data




Figure 2. FSH level 1 control data processed using Matern kernel function

In control measurement time-series data, systematic errors in the analytical processes may cause bias or drift. GPML natively supports tracking of bias or drift in the mathematical model.

Equations 2a and 2b form the basis of GPML inference which enables the prediction of y^* after observing data (t, y) , thus updating prior beliefs about points t^* . As the GPML enables us to predict complete functions over the space of t , it also provides us both with mean predictions and with associated measures of uncertainty. In many cases of analytical methods, though, we observe some noise-corrupted versions of data. In other cases, where GPML over-fits the data, we might want to introduce some terms into the predictive equations to condition the data. Although in this article we will not be diving into these issues to keep our argument focused on the core issues, GPMLs can easily be extended to allow for Gaussian noise models of various sorts.

A digital control chart was prepared for each control material and was presented to the user through a computer (Figure 1). The chart displayed measured concentration on the vertical y-axis vs. time on the horizontal x-axis (x—the axis was the time axis and was denoted as 't-axis' where time values were given relative to the start date which was the origin of the t-axis). The target mean value, provided by the manufacturer of the IQC material, was drawn as a solid (orange-) horizontal line. Dashed (green-) horizontal lines, also provided by the manufacturer, represented two SDs (1.96 to be exact) from the target mean value in each direction. The shaded (light green) area in the middle marked the TEa. TEa value was set at 21.19% (5) above and below the target means which the current approach is based on a control limit. Prediction point using all data observed and predicted (TAEP) value, referred to in this article as upper and lower control limits, for the control material which in this case was FSH, level 1. At the top of Figure 1 were the name, the kit number, the numerical values for the target mean, the target SD, and the TEa set for the control material. Kernel information was placed at the top right and will be reviewed in detail in the following section.

Measured control results were called observations, whereas data predicted were called predictions. Observations were marked as solid (red-) dots on the chart. The continuous solid (blue-) curve consists of the predictions made. Symmetrically shaded (yellow-) areas on each side of the blue curve showed 95% confidence intervals (CI)s of predictions. 95% CI limits permit the use of simple decision criteria as will be presented later.

Prediction curves and 95% CIs were graphed on the digital control chart. OOCE's were defined to be those points where 95% CI limits overflow the control limits. Predictions

and CI limits can help identification of TEa violations (OOCE's) which may be in the past or the future of the analytical process under study. An OOCE occurred when CI limits exceeded control limits (TEa lines) in any direction. OOCEs that fall on the right-hand side of the current observation point were called future OOCEs and OOCEs that fall on the left-hand side of the current observation point were called past OOCEs. In Figure 1, one example of an OOCE could be observed between the 5th and the 6th observations (days 4–8) where CI limits go below the lower control limit and another one could be observed after the 20th observation (days 24–28).

In the case of OOCE's in the past, points that lie on the left side of the active point, of the analytical process under study, recovery and correction procedures were recommended to be started. In the case of future OOCE points, points that lie on the right side of the current observation time, either a new observation was planned for just before the first future OOCE or immediate corrective action was started.

PQCA presented below was activated each time a control result is observed, per control material. The definition of PQCA:

1. Is the current observation corrupted by non-analytical causes, e.g., using the wrong vial? If yes, reject the current observation and repeat the control measurement.
2. Run the GPML algorithm to generate a control chart using all data accumulated so far for the control material. The output of GPML is an entire prediction function for the specified range of time. Also in the output are the associated 95% CIs for predictions.
3. Note on the chart, periods where 95% CI limits are not contained fully within upper and lower control limits. Call these periods OOCE.
4. For OOCE's with time periods smaller than the time of the current observation, which is OOCE's in the past of the analytical process, start the laboratory's review procedure (not described in this article) for patient results generated during these OOCE periods.
5. For predicted OOCE's, which are in the future of the process, either start corrective action immediately or schedule another control measurement for a time point well before the first OOCE is predicted to occur.

RESULTS

The PQCA algorithm is defined and a digital control chart is introduced in the materials and methods section. PQCA is applied to each control level of 10 analytes chosen for this work. Similar conclusions are reached for the other analytes included in the study. Results are presented for FSH as a representative.




Figure 3. Prediction-observation pairs for FSH Level 1 kernel function testing




Figure 4. Comparison of TAE with TAE-predicted for FSH level 1 control data

Figure 4 presents TAE calculations using the classical formula $TAE = bias\% + 1.65 CV\%$. Solid black circles show TAE values computed as usual for each observation point. The solid blue curve shows TAE values computed for each prediction point using all data; both observed and predicted, total analytical error–predicted (TAEp). The horizontal axis shows the normalized data. TEa is set to 16.7%, which is the area shaded in the graphic. In TAE calculations, bias represents drift from the manufacturer’s mean, and CV% stands for the coefficient of variation.

TAE changes very little from one observation to another whereas TAEp is wigglier. The reason for this is that TAE computes two terms related to long-term averages of observed data. Consequently, TAE and TAEp follow separate trajectories. Around day 50, TAEp exceeds the upper control limit. TAE, which is the model used in current practice, misses

this OOCe. This demonstrates that the classical TAE method may miss some OOCe’s.

DISCUSSION

The use of ML-based solutions to ease the burden of increasing test demand and to improve quality and safety in clinical laboratories has begun in recent years (12). Although clinical laboratories are health services where digitalization and automation are used extensively in daily practice, there are limited examples that exist of ML implemented into routine clinical practice (13, 14). However, publications on ML research in clinical laboratory medicine still on arise in several aspects of laboratory work including the evaluation of flow cytometry results, classification of cell morphology, interpretation of urine steroid profiles, test result interpretation, test result prediction, and the diagnosis of hematologic disorders (15-20). The model we proposed is the first study that emp-

loys a ML approach to the analytical perspective of clinical laboratory practice by predicting past and future OOCEs in IQC practice. The goal of this study is approached via the probabilistic framework of GPML.

In our study, we use the GPML approach to learn from time series control data and to predict both past and future OOCE's. In the control data vs time series, one would expect observations that stand closer to each other in time should be more similar to each other than to those that stand farther away. We can imagine two consecutive observations separated from each other by time-distance Δt . Assume Δt is made smaller and smaller approaching the limit to zero. As Δt assumes smaller and smaller values, two observations would be expected to get more and more similar to each other in magnitude. In the limit, two observations should be identical. If Δt is now moved in the reverse direction and it gets larger and larger, two observations would be less similar in magnitude. We can generalize this phenomenon so that control observations are correlated to each other in a statistical sense. The form of this correlation is important and constitutes the basis of the predictive models presented in this work.

The main outcome of this research, PQCA, has several attractive characteristics in comparison to classical rule-based quality control procedures:

1. PQCA enables proactive control of analytical methods' performance. It is capable of predicting future OOCE's. In case of a future OOCE either a new observation is planned for just before the OOCE or immediate corrective action is started.
2. PQCA can predict past OOCE's. In the case of OOCE's in the past, recovery and correction procedures are recommended to be started.
3. PQCA is a simple control procedure with a single rule. PQCA links raw control measurements and OOCE easy-use, obvious, and direct.
4. PQCA can easily model shifts in expected values of control measurements, i.e., systematic errors.
5. Laboratories wishing to meet different quality goals may set CI accordingly. Larger CI values would indicate tighter quality goals.
6. PQCA can start making accurate predictions with as few as one observation. Classical rule-based control procedures require a minimum number of observations, e.g., 20, to generate valid results.
7. PQCA can easily work with a non-deterministic target mean, e.g., peer group means.

Figure 3 is intended to justify the use of the RBF kernel for FSH control data. PQCA is applied to each prefix of the

time series data and a prediction is made for the next observation point. Predictions are marked as hollow blue circles and the corresponding observations are marked as solid black circles. All observations fall within the 95% CI of their respective predictions. This process might constitute the basis for choosing the appropriate kernel function for controlling data. To make the kernel selection process more principled, cosine similarity between the observation and prediction vectors may be used, e.g., a cosine value of 0.99 or greater may be deemed to indicate a good kernel for the analyte under study.

There are a few limitations to the study. PQCA is not tested in real-time in routine IQC procedures. IQC data used in the study is evaluated retrospectively. The number and types of analytes included in the study are limited to a small group used in clinical laboratory routines.

Classical TAE calculation model, such as that proposed by Westgard (4), is based on a univariate Gaussian model (21). GPML, which the current approach is based on, is generalized by a multivariate Gaussian. In this respect, the computational view proposed in this work, PQCA, is a generalization of the classical IQC model.

CONCLUSIONS

The model we proposed is the first study that employs a ML approach to the analytical perspective of clinical laboratory practice by predicting past and future OOCEs in IQC practice. PQCA empowers clinical laboratories to evaluate the past, present, and future of the IQC data, collectively. The use of PQCA can improve the quality of laboratory service delivery, especially by enabling earlier detection of systematic errors. In this way, faster and more effective delivery of health services can be possible. Although it is possible to use it as a separate application, the integration of the PQCA into laboratory information systems may be a more accurate approach in terms of ease of use. This work might pioneer computational and laboratory sciences cooperation in quality management giving way to a new area of study, computational laboratory medicine. We believe that it will contribute significantly to the improvement of laboratory processes of the present as well as the future of laboratory medicine in general.


Acknowledgements

We thank Fethan Us for his assistance in conducting experiments and generating the graphics presented in this article. Authors declare that there is no conflict of interest.

References

- Clinical and Laboratory Standards Institute (CLSI). Statistical Quality Control for Quantitative Measurement Procedures: Principles and Definitions; Approved Guideline—Third Edition. CLSI document C24-A3 (ISBN 1-56238-613-1). 2006 Vol. 26 No. 25. Clinical and Laboratory Standards Institute, 950 West Valley Road, Suite 2500, Wayne, Pennsylvania 19087 USA, 2006. Clinical & Laboratory Standards Institute C24-A3. Statistical Quality Control for Quantitative Measurement Procedures: Principles and Definitions; Approved Guideline—Third Edition.
- United States Department of Health and Human Services. Medicare, Medicaid, and CLIA programs: regulations implementing the Clinical Laboratory Improvement Amendments of 1988 (CLIA). Final rule. 57 Federal Register 7002-7186; 1992. Available at: www.phppo.cdc.gov/clia/regs/toc.aspx. Accessed February 11, 2020.
- Westgard JO, Barry PL, Hunt MR, Groth T. A multi-rule Shewhart chart for quality control in clinical chemistry. *Clin Chem* 1981;27:493-501.
- Westgard JO, Westgard SA. Measuring Analytical Quality: Total Analytical Error Versus Measurement Uncertainty. *Clin Lab Med* 2017;37 (1):1-13.
- <https://www.westgard.com/biodatabase1.htm>. Accessed December 27, 2022.
- Rasmussen CE, Williams CKI. Gaussian processes for machine learning, Cambridge (MA): the MIT Press, 2006, p. 13-21, ISBN 026218253X.
- Pedregosa F, Varoquaux G, Gramfort A, Michel V, Thirion B, Grisel O, et al. Scikit-learn: machine learning in Python. *Journal of machine learning research* 2011;12:2825-30.
- Futoma J, Sendak M, Cameron CB, Heller K. Scalable modeling of multivariate longitudinal data for prediction of chronic kidney disease progression. *Machine Learning and Healthcare Conference*, Los Angeles, CA. 2016, eprint arXiv:1608.046152016arXiv160804615F
- Colopy GW, Pimentel MAF, Roberts SJ, Clifton DA. Bayesian gaussian processes for identifying the deteriorating patient. *38th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, Orlando, FL. 2016, 5311-4 p. doi: 10.1109/EMBC.2016.7591926
- Forouzanfar MH, Liu P, Roth GA, Ng M, Biryukov S, Marczak L, et al. Global burden of hypertension and systolic blood pressure of at least 110 to 115 mm Hg, 1990-2015. *JAMA*. 2017;317(2):165–82. doi:10.1001/jama.2016.1904.
- Rasmussen CE, Williams CKI. Gaussian processes for machine learning, Cambridge (MA): the MIT Press, 2006, p. 79-85, ISBN 026218253X.
- Challen R, Denny J, Pitt M, Gompels L, Edwards T, Tsaneva-Atanasova. Artificial intelligence, bias and clinical safety. *BMJ Qual Saf* 2019;28:231–237.
- 510(K) Summary: DiffMaster Octavia. https://www.accessdata.fda.gov/cdrh_docs/pdf/K003301.pdf. Accessed February 11, 2020.
- Pancholi P, Carroll KC, Buchan BW et al. Multicenter evaluation of the accelerate phenotest BC kit for rapid identification and phenotypic antimicrobial susceptibility testing using morphokinetic cellular analysis. *J Clin Microbiol* 2018;56:4:1-21.
- Cao Y, Cheng M, Hu C. UrineCART, a machine learning method for establishment of review rules based on UF-1000i flow cytometry and dipstick or reflectance photometer. *Clin Chem Lab Med* 2012;50:2155-61.
- Durant TJS, Olson EM, Schulz WL et al. Very deep convolutional neural networks for morphologic classification of erythrocytes. *Clin Chem* 2017;63:1847-55.
- Wilkes EH, Rumsby G, Woodward GM. Using machine learning to aid the interpretation of urine steroid profiles. *Clin Chem* 2018;64(11):1586-95.
- Demirci F, Akan P, Kume T et al. Artificial neural network approach in laboratory test reporting: learning algorithms. *Am J Clin Pathol* 2016;146:227-37.
- Luo Y, Szolovits P, Anand S, Dighe AS, Baron JM. Using Machine Learning to Predict Laboratory Test Results. *Am J Clin Pathol* 2016;145:778-88.
- Guncar G, Kukar M, Notar M, Brvar M, et al. An application of machine learning to haematological diagnosis. *Sci Rep* 2018;8:411.
- Yardim, M. Total analytical error assessment of Yerköy State Hospital biochemistry laboratory. *International Journal of Medical Biochemistry* 2022, 5(1), 60-6.

SAĞLIK BİLİMLERİNDE YAPAY ZEKA DERGİSİ



Journal of Artificial Intelligence in Health Sciences