



Yapay Zeka DAI'nin Tedavisinde Nasıl Rol Oynayabilir



Prof. Dr. Derya Öztürk Engin

Şehit Prof. Dr. İlhan Varank Eğitim ve Araştırma Hastanesi


İnfeksiyon Hastalıkları ve Klinik Mikrobiyoloji Kliniği

14.Eylül.2024

- Uluslararası Diyabet Vakfı, 2021 yılında dünya çapında 20 ila 79 yaşları arasındaki 537 milyon yetişkinin diyabetle yaşadığını tahmin ediyor

DAİ önemli morbidite ve mortalite nedeni

- Günlük yara bakımı
- Antimikrobiyal tedavi
- Cerrahi prosedürler
- Ayak amputasyonu



Bu yükü azaltmak mümkün mü?

Diyabetik ayak ülserlerinin prognozu

- Hastaların klinik özellikleri
- Yaradaki infeksiyon durumu
- Eşlik eden hastalıklar
- Görüntüleme yöntemlerinden elde edilen bilgiler



Klinisyenlerin çok fazla zihinsel ve manuel emek harcamasını gerektirir

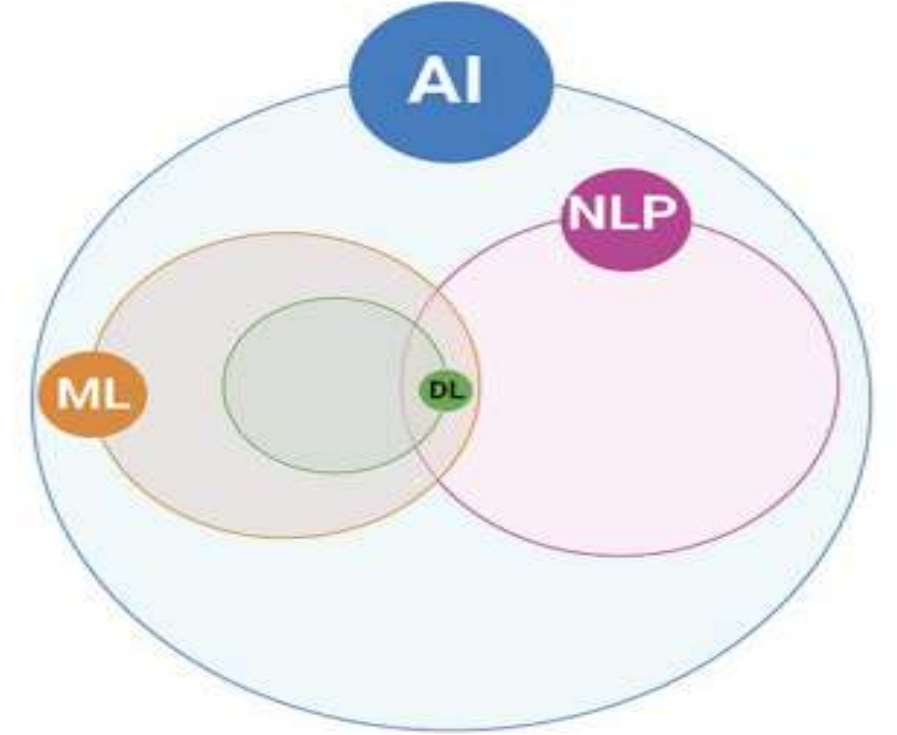
.

Diyabetik ayak infeksiyonu olan hastalar için yapay zeka kullanılabilir mi?



Yapay zeka (AI) nedir?

- ❖ Öğrenme
- ❖ Problem çözme
- ❖ Kalıpları tanıma
- ❖ Karar verme gibi insan zekası gerektiren görevleri yerine getirebilen makinelerin yapımıyla ilgilenen bilgisayar bilim alanı




Makine öğrenimi (ML), derin öğrenme (DL) ve doğal dil işleme (NLP) gibi çeşitli teknikleri içerir.

Makine öğrenimi (ML)

- Büyük veri kümelerini analiz ederek öğrenir
- İstatistiksel teknikler kullanır
- Verilerden algoritmalar geliştirir



- Daha fazla veriyi analiz ettikçe anlayışını geliştirir
- Sürekli öğrenme süreci, modelin giderek daha doğru ve güvenilir olmasını sağlar




Theodosiou AA, Read RC. J Infect.. 2023 Oct;87(4):287-294
Bal T. Viral Hepatitis Journal 2024;30(1):1-6

Doğal Dil İşleme (NLP)

Bilgisayarların insan dilini anlamasını, oluşturmasını ve işlemesini sağlayan yapay zekanın bir dalı (Siri, Alexa gibi...)

Derin öğrenme (DL)

- Verilerden öğrenmek için yapay sinir ağlarını kullanır
- Geleneksel makine öğrenimi algoritmalarıyla karmaşık kalıpları ve ilişkileri öğrenebilirler
- Yüksek hacimli ve boyutlu verileri içeren karmaşık görevlerde üstün



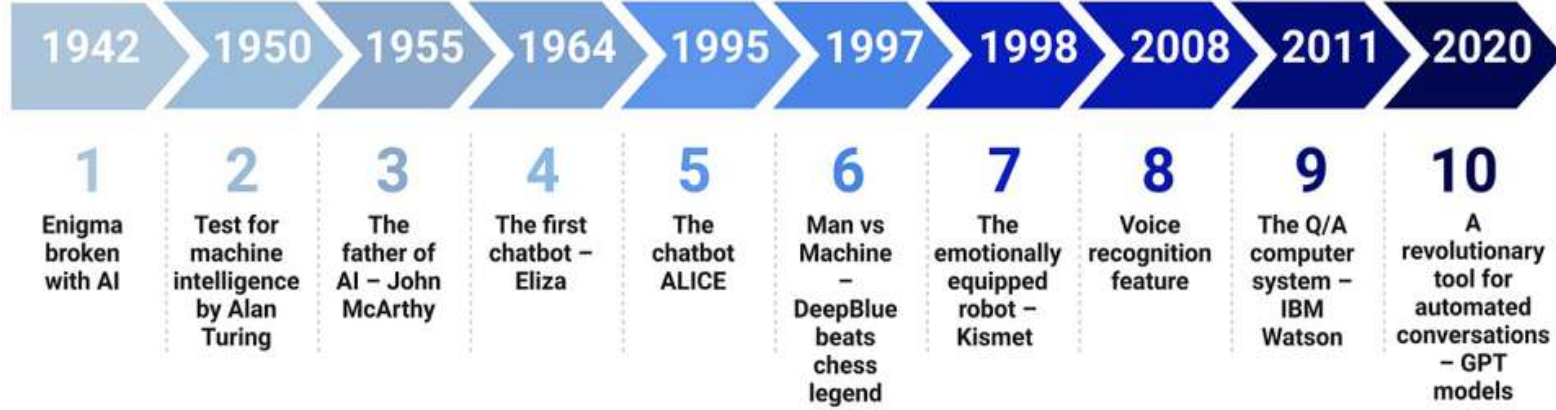
Büyük Dil Modelleri (LLM)

- Metin tabanlı içeriği anlamak, özetlemek, oluşturmak, tahmin etmek için derin öğrenme tekniklerini ve çok büyük veri kümelerini kullanan bir tür yapay zeka algoritması
- İnsan benzeri metin üretmek için büyük veri hacimleri üzerinde eğitilen modeller



Theodosiou AA, Read RC. J Infect. 2023 Oct;87(4):287-294
Alowais SA, et al. BMC Med Educ. 2023 Sep 22;23(1):689.

Exploring the Historical Journey of Artificial Intelligence



1951'de Christopher Strachey, ilk yapay zeka programı

1956'da John McCarthy, "Yapay Zeka" terimi

2000'li yıllar Apple'ın Siri'si ve Amazon'un Alexa'sı

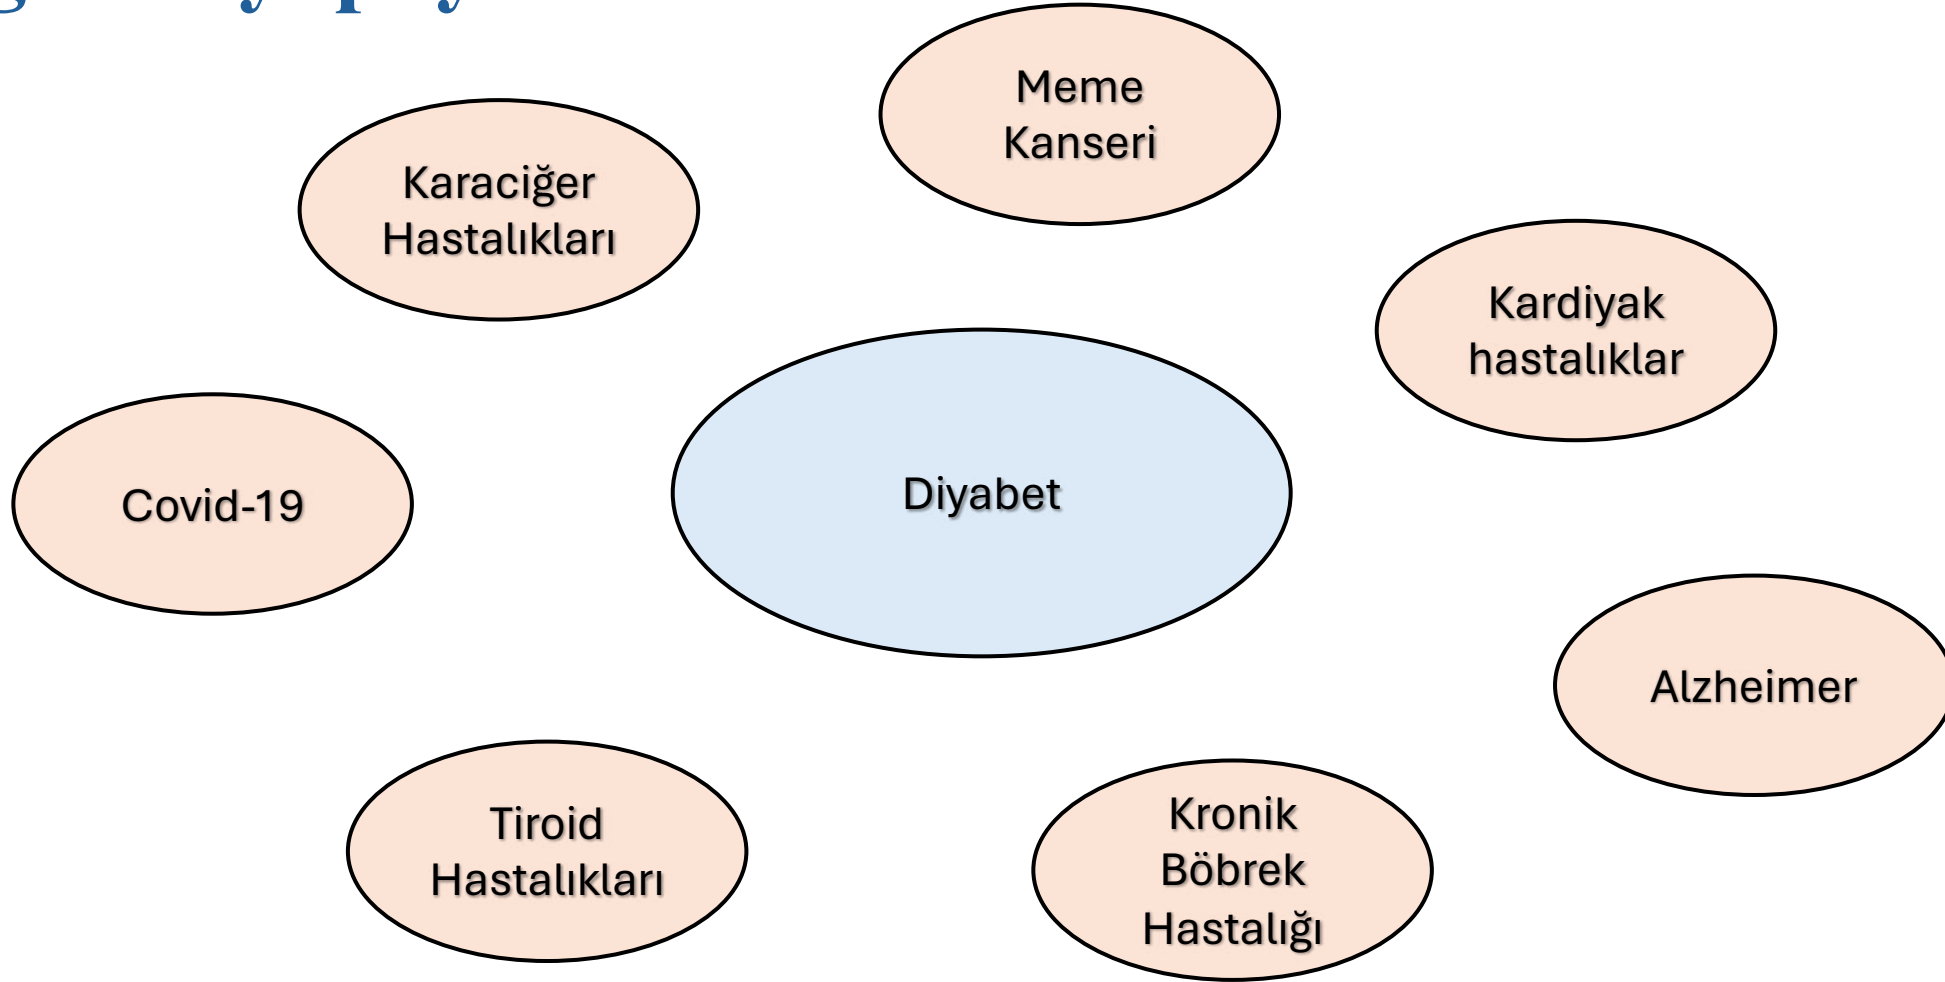
GAME OVER

KASPAROV AND THE MACHINE |

- 1996 yılında dünya satranç şampiyonu Garry Kasparov, IBM (International Business Machines) tarafından geliştirilen Deep Blue adlı bilgisayarı yener
- Şirket, makineyi geliştirilir
- Deep Blue, 1997'de dünya şampiyonunu yenmeyi başarır



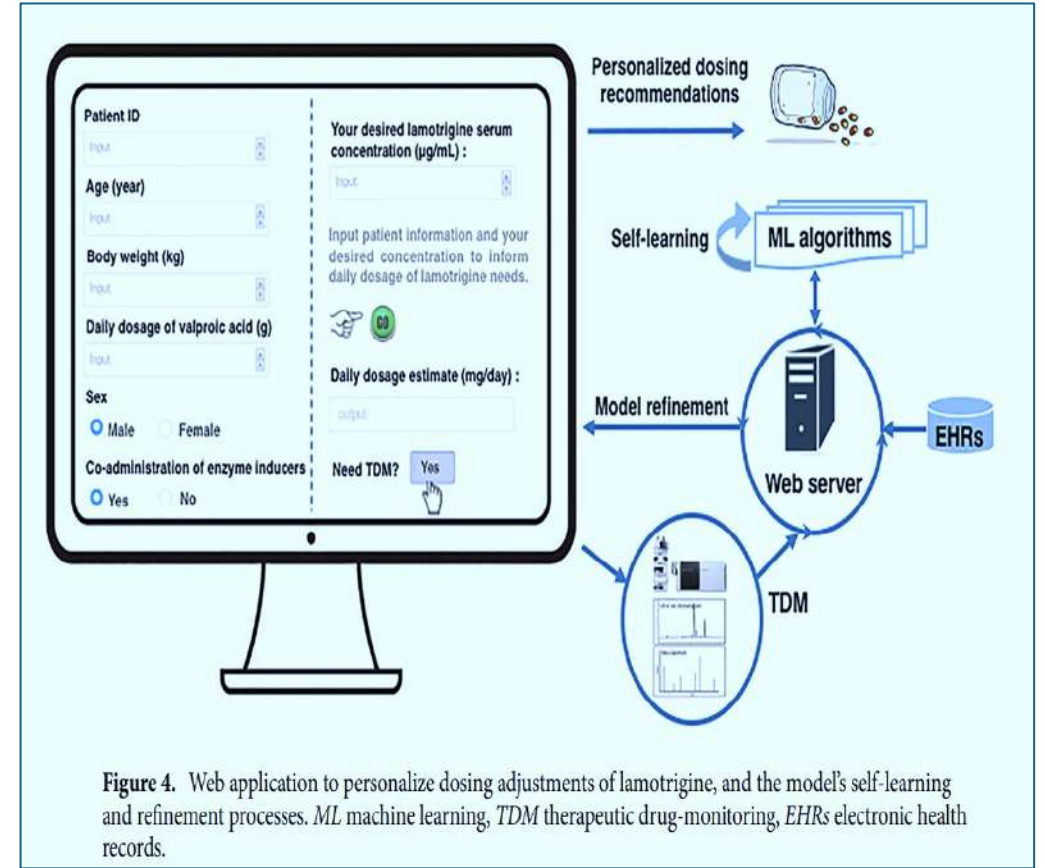
Sağlıkta yapay zeka



Sağlıkta yapay zeka

- Tanı (Röntgen, MRI, retinopati)
- Genotipik değerlendirme (hastalığa yatkınlığın değerlendirilmesi)
- İlaç geliştirilmesi, mevcut ilaçların kullanım alanlarında farklılıklar

- Bireyselleştirilmiş tedavi yaklaşımları (ilaç dozu monitörizasyonu, ilaç etkileşimleri, genetik yapı, medikal öykü, çevre, yaşam tarzı...)



Tablo 3. Diyabet hastalığı Alanında Yapılan Makine Öğrenmesi Çalışmaları.

Yazar ve Yayın Yılı	Algoritma	Ele Alınan Problem	Sonuçlar	Karşılaştırma Yapılan Algoritmalar	Doğruluk (%)
Nguyen vd. (2019)	SMOTE	Diyabet başlangıcı olan hastaları tahmin etmek	Makine öğrenmesi modelleriyle iyi sonuçlar elde etmişlerdir.	-	82,12
Tiggaa vd. (2020)	RF	Diyabet riskini tahmin etmek	Random Forest (RF) en iyi tahmincidir.	LR, K-NN, SVM, NB, DT, RF	94,1
Lukmanto vd. (2019)	SVM	Diyabet hastalığını sınıflandırmak	Diyabet hastaları tahmin etmede %89,02 doğruluk göstermektedir.	-	89,02
Viloria vd. (2020)	SVM	Hastaların diyabet hastası olma ihtimali tahmin etmek	En iyi sonucu Support Vector Machine (SVM) algoritması vermiştir.	-	99,2
Kumar vd. (2020)	DNN	Diyabet hastalarına doğru ilacı önermek	DNN hastalara doğru ilacı teşhis etmeye yardımcı olmaktadır.	K-NN, DT	98,16
Reddy vd. (2020)	RF	İnsandaki diyabeti maksimum doğrulukla öngören bir model tasarlamak	Random Forest diğer sınıflandırıcılara kıyasla en yüksek performansı göstermiştir	SVM, K-NN, LR, NB	98,48
Mujumdar vd. (2019)	AdaBoost	Diyabet sınıflandırması için bir diyabet tahmin modeli önermek	En iyi çözüm veren algoritmanın AdaBoost algoritması olduğunu bulmuşlardır.	AdaBoost, Gradient Boost, RF, LR, DT, LDA	98,8
Baig vd. (2020)	RF	Makine öğrenmesi algoritmaları kullanarak diyabet hastalığını erken teşhis etmek	En iyi çözüm veren algoritmanın Random Forest algoritması olduğunu bulmuşlardır.	Linear Regression, DT, K-NN, RF	99

Diyabet ve Yapay Zeka



Fig. 2. AI Enhances Eight Domains of Diabetes Management.

304 adet makele taraması ve sonuçta 43 makalenin değerlendirilmesi

Diyabetik ayak ülserleri ve yapay zeka

Further evidence that wound size and duration are strong prognostic markers of diabetic foot ulcer healing

David J. Margolis, MD PhD¹, Nandita Mitra, PhD¹, D. Scott Malay, DPM², Ziad K. Mirza, MD³, John C. Lantis, MD⁴, Hadar A. Lev-Tov, MD⁵, Robert S. Kirsner, MD PhD⁵, Stephan R. Thom, MD PhD⁶

- Prospektif kohort çalışması
- 204 diyabetik ayak ülseri
- 16 haftalık takip
- Modeller önceki literatüre dayandırılmış ve makine öğrenme algoritması kullanılmış
- Yara alanı ve yara süresi yara iyileşmesini tahmin etmek için kullanılabilir



Contents lists available at [ScienceDirect](https://www.sciencedirect.com)

Diabetes Research and Clinical Practice

journal homepage: www.journals.elsevier.com/diabetes-research-and-clinical-practice



Artificial intelligence for automated detection of diabetic foot ulcers: A real-world proof-of-concept clinical evaluation



Bill Cassidy^{a,*}, Moi Hoon Yap^a, Joseph M. Pappachan^b, Naseer Ahmad^c, Samantha Haycocks^d,
Claire O'Shea^e, Cornelious J. Fernandez^f, Elias Chacko^g, Koshy Jacob^h, Neil D. Reevesⁱ

- 81 diyabetik hastanın akıllı telefon ile çekilen 203 ayak fotoğrafı
- 162 en az bir ülseri gösteren görüntü, 41 ülser olmayan görüntü
- 1775 diyabetik ayak ülseri fotoğrafı ile makine öğrenimi sağlanmış



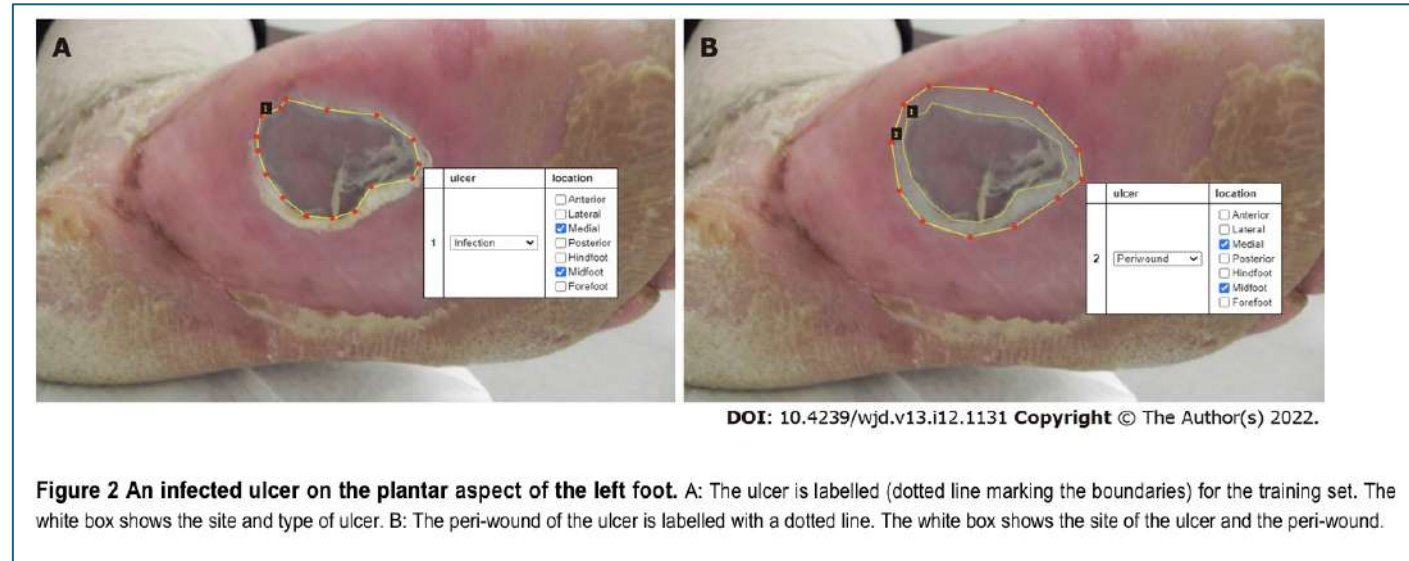
- Uzman klinisyen görüşü ile yapay zeka sonuçları karşılaştırılmış
- Mükemmel duyarlılık (0,9157) ve yüksek özgüllük (0,8857) saptanmış



Fig. 1. Illustration of the main data-capture screens in the smartphone app and the clinical procedure for its use in patient appointments during the proof-of-concept clinical evaluation.

The role of artificial intelligence technology in the care of diabetic foot ulcers: the past, the present, and the future

Diyabetik ayak ülserlerinin fotoğraf makinesi ve cep telefonu kamerası ile takibi yapılabilir mi?



- Kameranın ayaktan uzaklığı
- Aydınlatma koşulları
- Yetersiz odaklanma, aydınlatma
- Hareket bozuklukları
- Arka ışıktan kaynaklanan düşük kaliteli görüntüler
- Ayak/ayak parmaklarındaki deformasyonlar
- Ülserlerin boyutu ve şekli görüntü kalitesinde etkili



- Yapay zeka teknolojisini kullanarak tahmin modelleri geliştirilebilir



Recognition of ischaemia and infection in diabetic foot ulcers: Dataset and techniques

Manu Goyal^a, Neil D. Reeves^b, Satyan Rajbhandari^c, Naseer Ahmad^d, Chuan Wang^e,



(a) Infection



(b) No Infection



(c) Ischaemia



(d) No Ischaemia

Table 1

The number of infection and ischaemia cases, number of DFU patches and augmented patches using Natural Data-augmentation in DFU Dataset.

Category	Definition	Cases	DFU patches	Augmented patches
Ischaemia	Absent	1249	1431	4935
	Present	210	235	4935
Total images		1459	1666	9870
Bacterial infection	None	628	684	2946
	Present	831	982	2946
Total images		1459	1666	5892

1459 olgunun fotoğrafları

2 uzman tarafından değerlendirme yapılmış

Farklı görüş durumunda kıdemli uzmanın

görüşü kabul edilmiş

DA ülserlerinde infeksiyon ve iskemi varlığını belirlemek için yeni bir veri seti ve bilgisayarlı görüş teknikleri araştırılmış

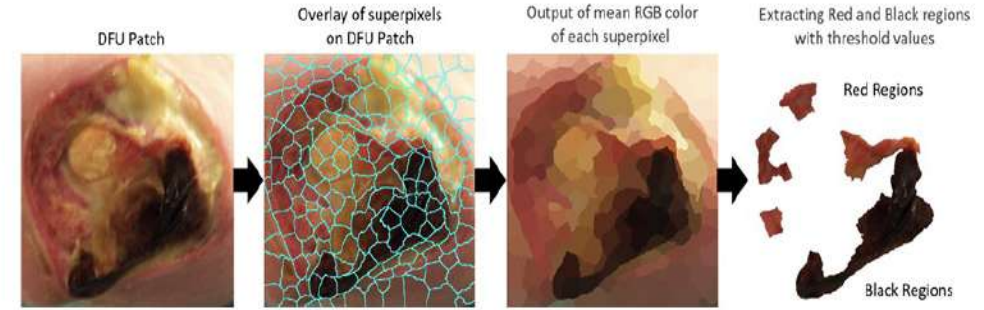


Fig. 6. Example of extracting red and black regions from DFU patch with proposed Superpixel Colour Descriptor algorithm which was then used to inform identification of ischaemia and infection. The k value of 200 for superpixel algorithm effectively oversegmented the DFU patches.

El yapımı makine öğrenimi için, süperpiksel renk tanımlayıcısı kullanılmış

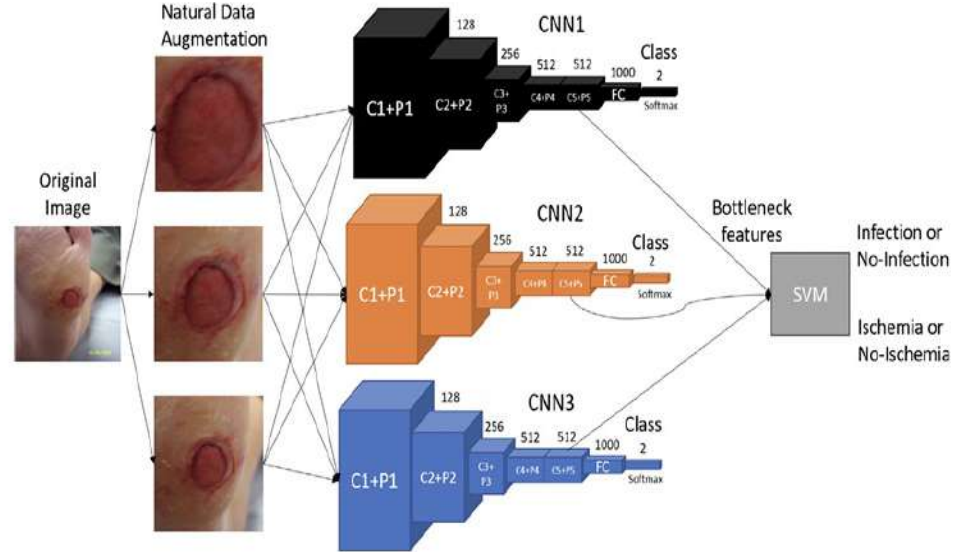


Fig. 7. Extracting bottleneck features from CNNs and fed into SVM classifier to perform binary classification of ischaemia and infection, where C1-C5 are convolutional layers, P1-P5 are pooling layers and FC is fully connected layer. Note: The CNNs in this figure are just representations of general CNNs architecture and do not represent the original CNN architectures of Inception-V3, ResNet50, and InceptionResNetV2.

Hem infeksiyon hem de iskemi veri setleri

- %70 eğitim için
- %10 doğrulama
- %20 test seti olarak

Table 2

The performance measures of binary classification of ischaemia by our proposed handcrafted traditional machine learning and CNN approaches.


	<i>Accuracy</i>	<i>Sensitivity</i>	<i>Precision</i>	<i>Specificity</i>	<i>F-measure</i>	<i>MCC score</i>	<i>AUC score</i>
BayesNet	0.785 ± 0.022	0.774 ± 0.034	0.809 ± 0.034	0.800 ± 0.027	0.790 ± 0.020	0.572 ± 0.044	0.783
Random forest	0.780 ± 0.041	0.739 ± 0.049	0.872 ± 0.029	0.842 ± 0.034	0.799 ± 0.033	0.571 ± 0.078	0.780
Multilayer perceptron	0.804 ± 0.022	0.817 ± 0.040	0.787 ± 0.046	0.795 ± 0.031	0.800 ± 0.023	0.610 ± 0.045	0.804
InceptionV3 (CNN)	0.841 ± 0.017	0.784 ± 0.045	0.886 ± 0.018	0.898 ± 0.022	0.831 ± 0.021	0.688 ± 0.031	0.840
ResNet50 (CNN)	0.862 ± 0.018	0.797 ± 0.043	0.917 ± 0.015	0.927 ± 0.017	0.852 ± 0.022	0.732 ± 0.032	0.865
InceptionResNetV2 (CNN)	0.853 ± 0.021	0.789 ± 0.054	0.906 ± 0.017	0.917 ± 0.019	0.842 ± 0.027	0.714 ± 0.039	0.851
Ensemble (CNN)	0.903 ± 0.012	0.886 ± 0.035	0.918 ± 0.019	0.921 ± 0.021	0.902 ± 0.014	0.807 ± 0.022	0.904

Table 3

The performance measures of binary classification of infection by our proposed handcrafted traditional machine learning and CNN approaches.

	<i>Accuracy</i>	<i>Sensitivity</i>	<i>Precision</i>	<i>Specificity</i>	<i>F-measure</i>	<i>MCC score</i>	<i>AUC score</i>
BayesNet	0.639 ± 0.036	0.619 ± 0.018	0.653 ± 0.039	0.660 ± 0.015	0.622 ± 0.079	0.290 ± 0.070	0.643
Random forest	0.605 ± 0.025	0.608 ± 0.025	0.607 ± 0.037	0.601 ± 0.069	0.606 ± 0.012	0.211 ± 0.051	0.601
Multilayer perceptron	0.621 ± 0.026	0.680 ± 0.023	0.622 ± 0.057	0.570 ± 0.023	0.627 ± 0.074	0.281 ± 0.055	0.619
InceptionV3 (CNN)	0.662 ± 0.014	0.693 ± 0.038	0.653 ± 0.015	0.631 ± 0.034	0.672 ± 0.019	0.325 ± 0.029	0.662
ResNet50 (CNN)	0.673 ± 0.013	0.692 ± 0.051	0.668 ± 0.023	0.654 ± 0.051	0.679 ± 0.019	0.348 ± 0.028	0.673
InceptionResNetV2 (CNN)	0.676 ± 0.015	0.688 ± 0.052	0.672 ± 0.015	0.664 ± 0.039	0.680 ± 0.024	0.352 ± 0.031	0.678
Ensemble (CNN)	0.727 ± 0.025	0.709 ± 0.044	0.735 ± 0.036	0.744 ± 0.050	0.722 ± 0.028	0.454 ± 0.052	0.731

Ensemble Convolutional Neural Network (CNN) derin öğrenme algoritması ile iskemi sınıflandırmasında %90 ve infeksiyon sınıflandırmasında %73 doğrulukla makine öğrenimi algoritmalarına kıyasla daha iyi performans gösterdiği bulunmuş



A Machine Learning Model for Prediction of Amputation in Diabetics

Journal of Diabetes Science and Technology

2024, Vol. 18(4) 874–881

© 2022 Diabetes Technology Society

Article reuse guidelines:

sagepub.com/journals-permissions

DOI: 10.1177/19322968221142899

journals.sagepub.com/home/dst



- 326.853 diyabetik ayak infeksiyonu ile yatan hasta
- %5,9 majör amputasyon
- Gangren, periferik vasküler hastalık, kilo kaybı, sistemik infeksiyon ve osteomyelit risk faktörleri

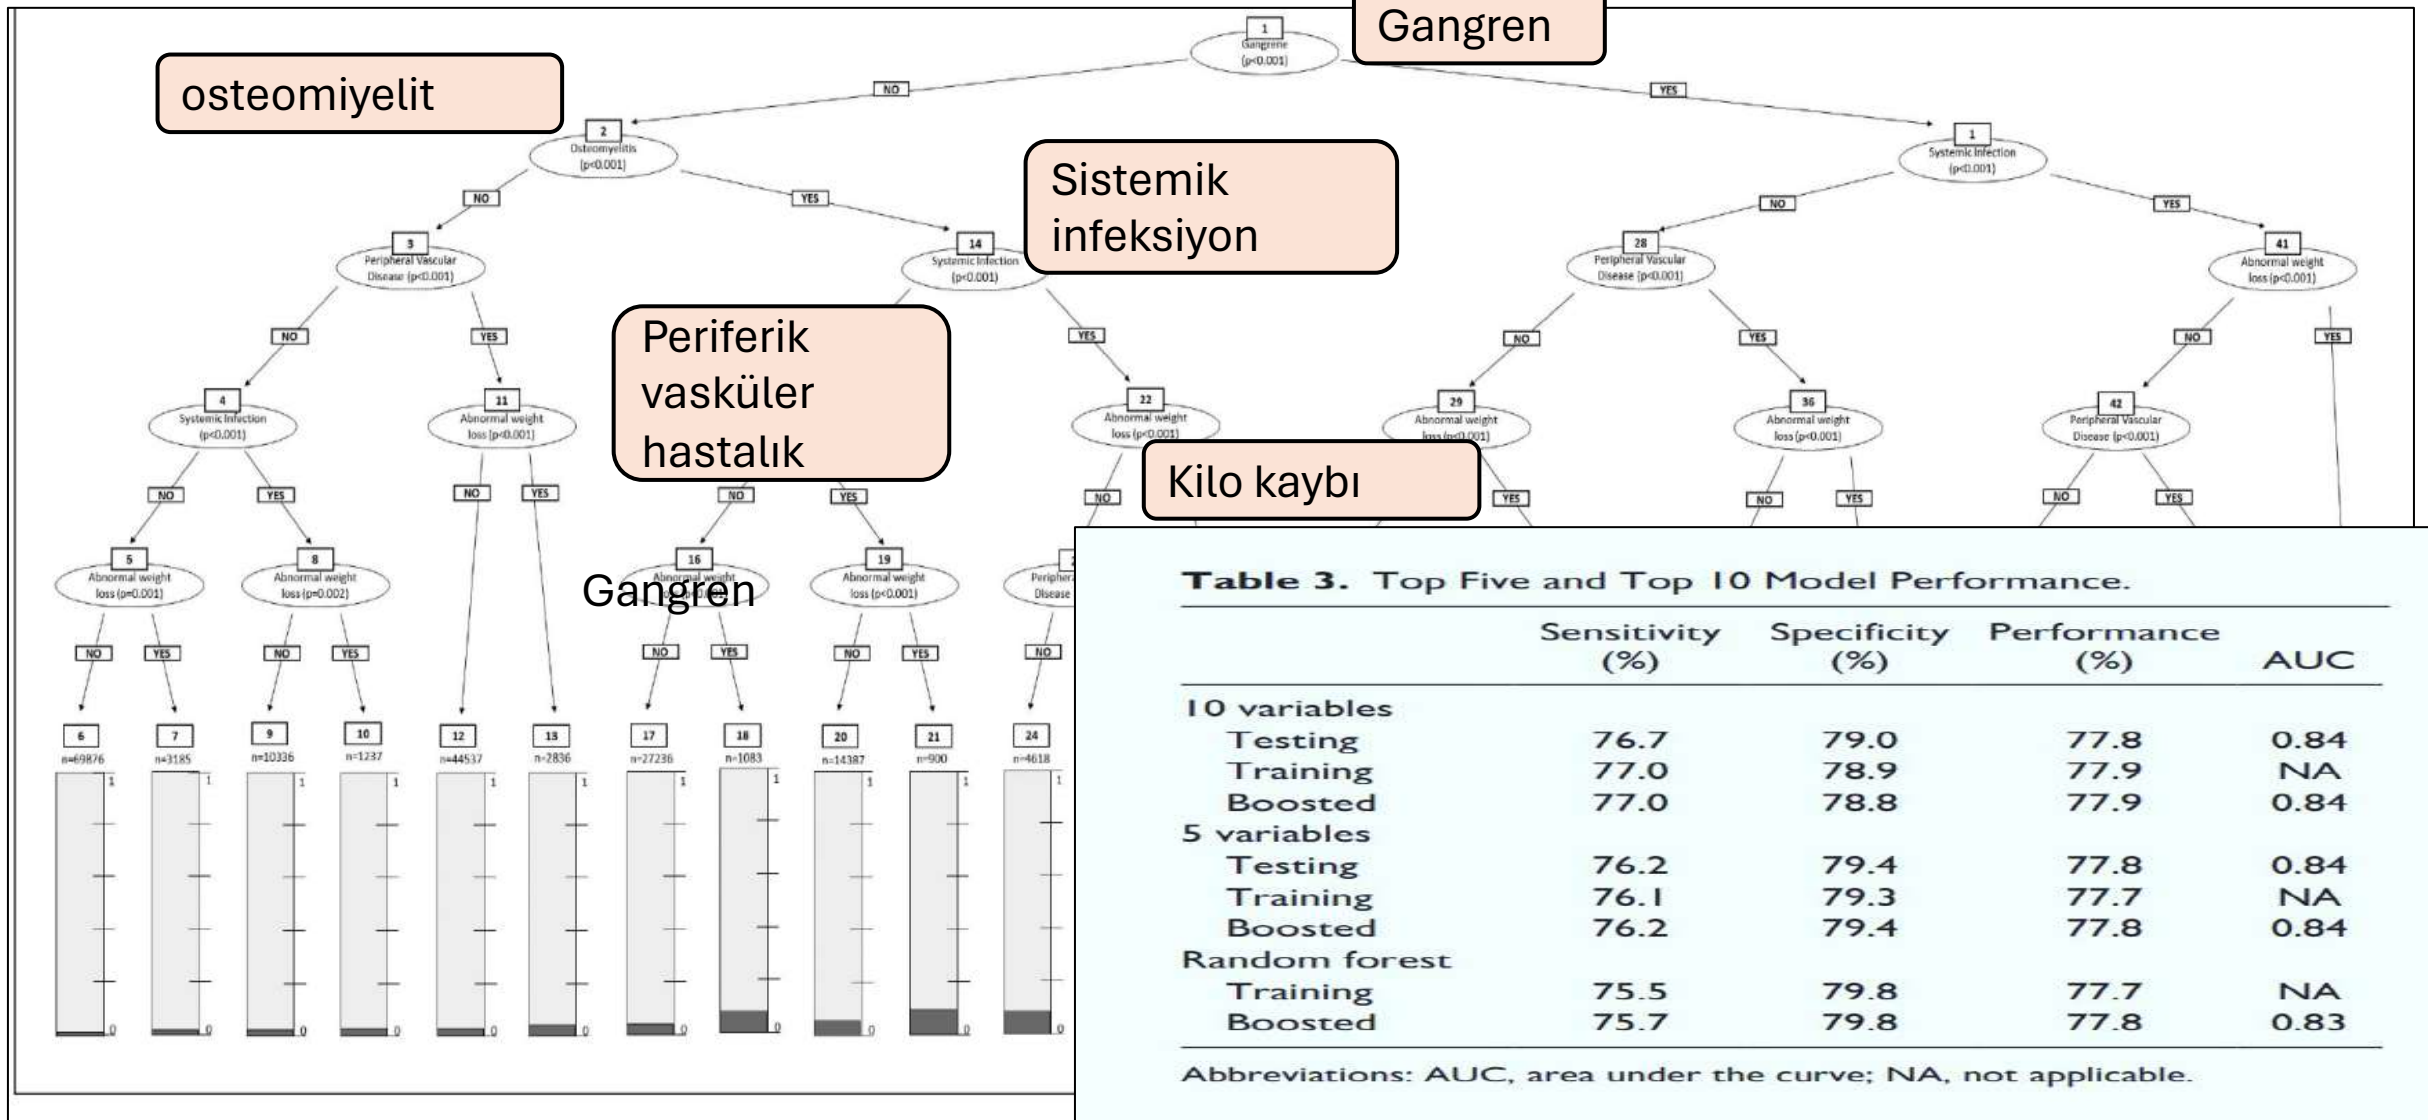


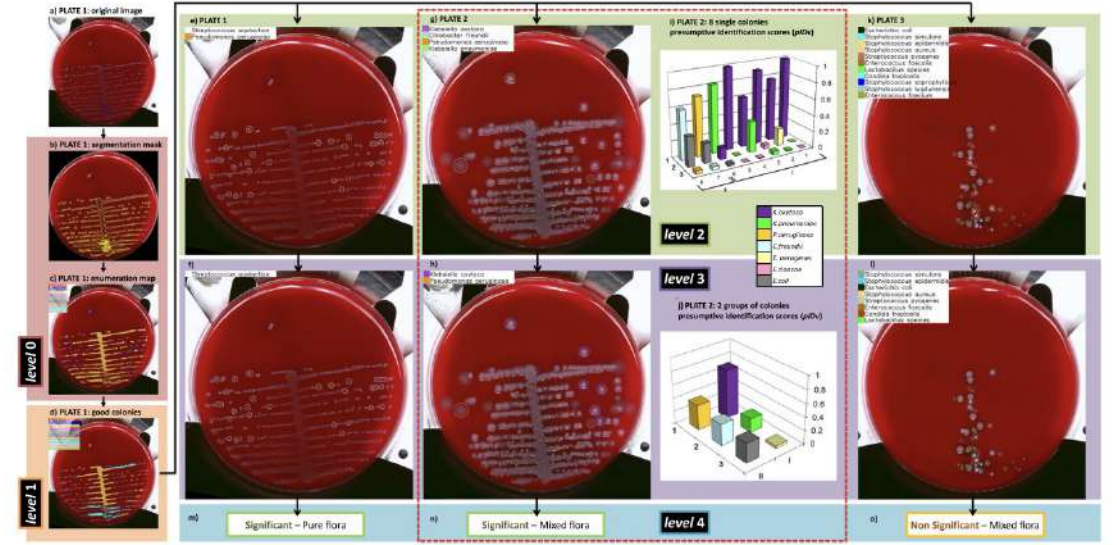
Figure 2. Decision tree model (CTREE).

- Makine öğrenimi yöntemlerini kullanarak, amputasyon riski

%77,8 doğrulukla tahmin eden bir algoritma

ML ve DL algoritmaları

- Mikroorganizmanın tespiti
- Üreme yoğunluğunun belirlenmesi
- Antimikrobiyal direnç profili



Signoroni A et al. Nat Commun. 2023 Oct 28;14(1):6874.

Theodosiou AA, et al. J Infect. 2023 Oct;87(4):287-294.

- Kltr plakalarının dijital grnt analizi, mikrobiyologlar tarafından yapılan geleneksel yntemle karılatırılmı
- Sistem iin duyarlılık %90,8 ve zgllk %92,8



> Nat Med. 2022 Jan;28(1):164-174. doi: 10.1038/s41591-021-01619-9. Epub 2022 Jan 10.

Direct antimicrobial resistance prediction from clinical MALDI-TOF mass spectra using machine learning

- 300.000'den fazla MALDI-TOF ve 750.000'den fazla antimikrobiyal direnç fenotipi içeren bir veri kümesi
- MALDI-TOF ile birleştirilen makine öğrenimi
- *S. aureus*, *E. coli* ve *K. pneumoniae* da dahil olmak üzere dirençli patojenlerin tespit edilebileceği bildirilmiş (sırasıyla AUROC 0,80, 0,74 ve 0,74)

Machine Learning for Antimicrobial Resistance Prediction: Current Practice, Limitations, and Clinical Perspective

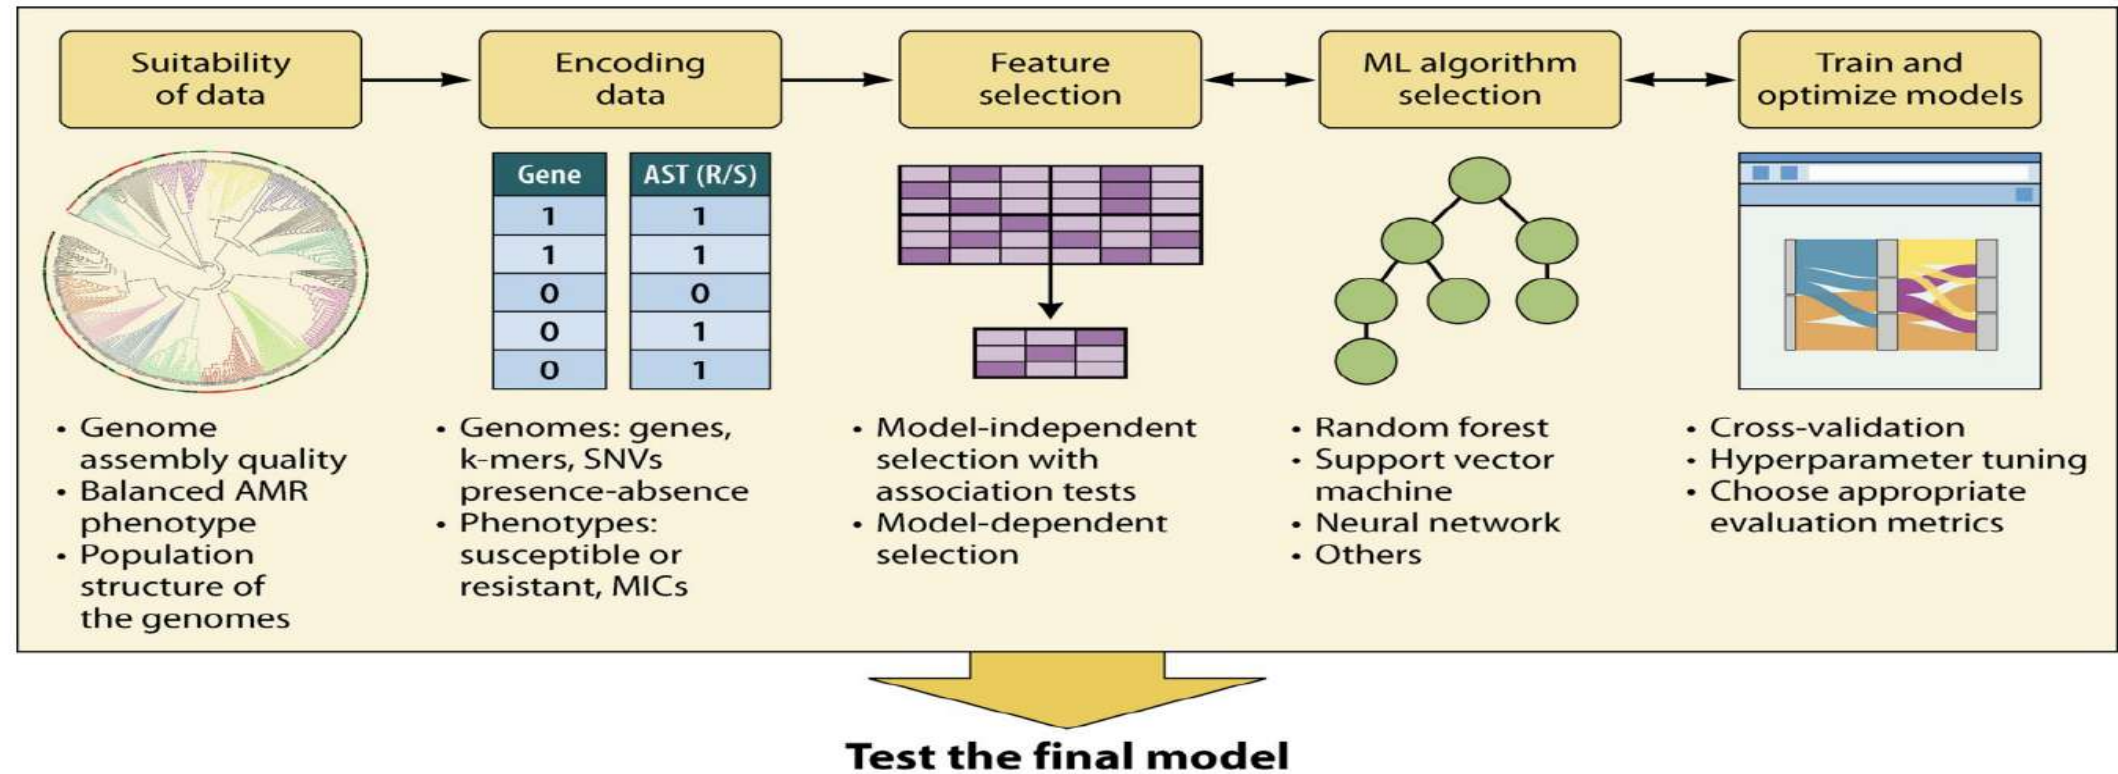


FIG 1 Workflow for ML prediction of AMR.

Antimikrobiyal direnç ile savaşta makine öğrenimi

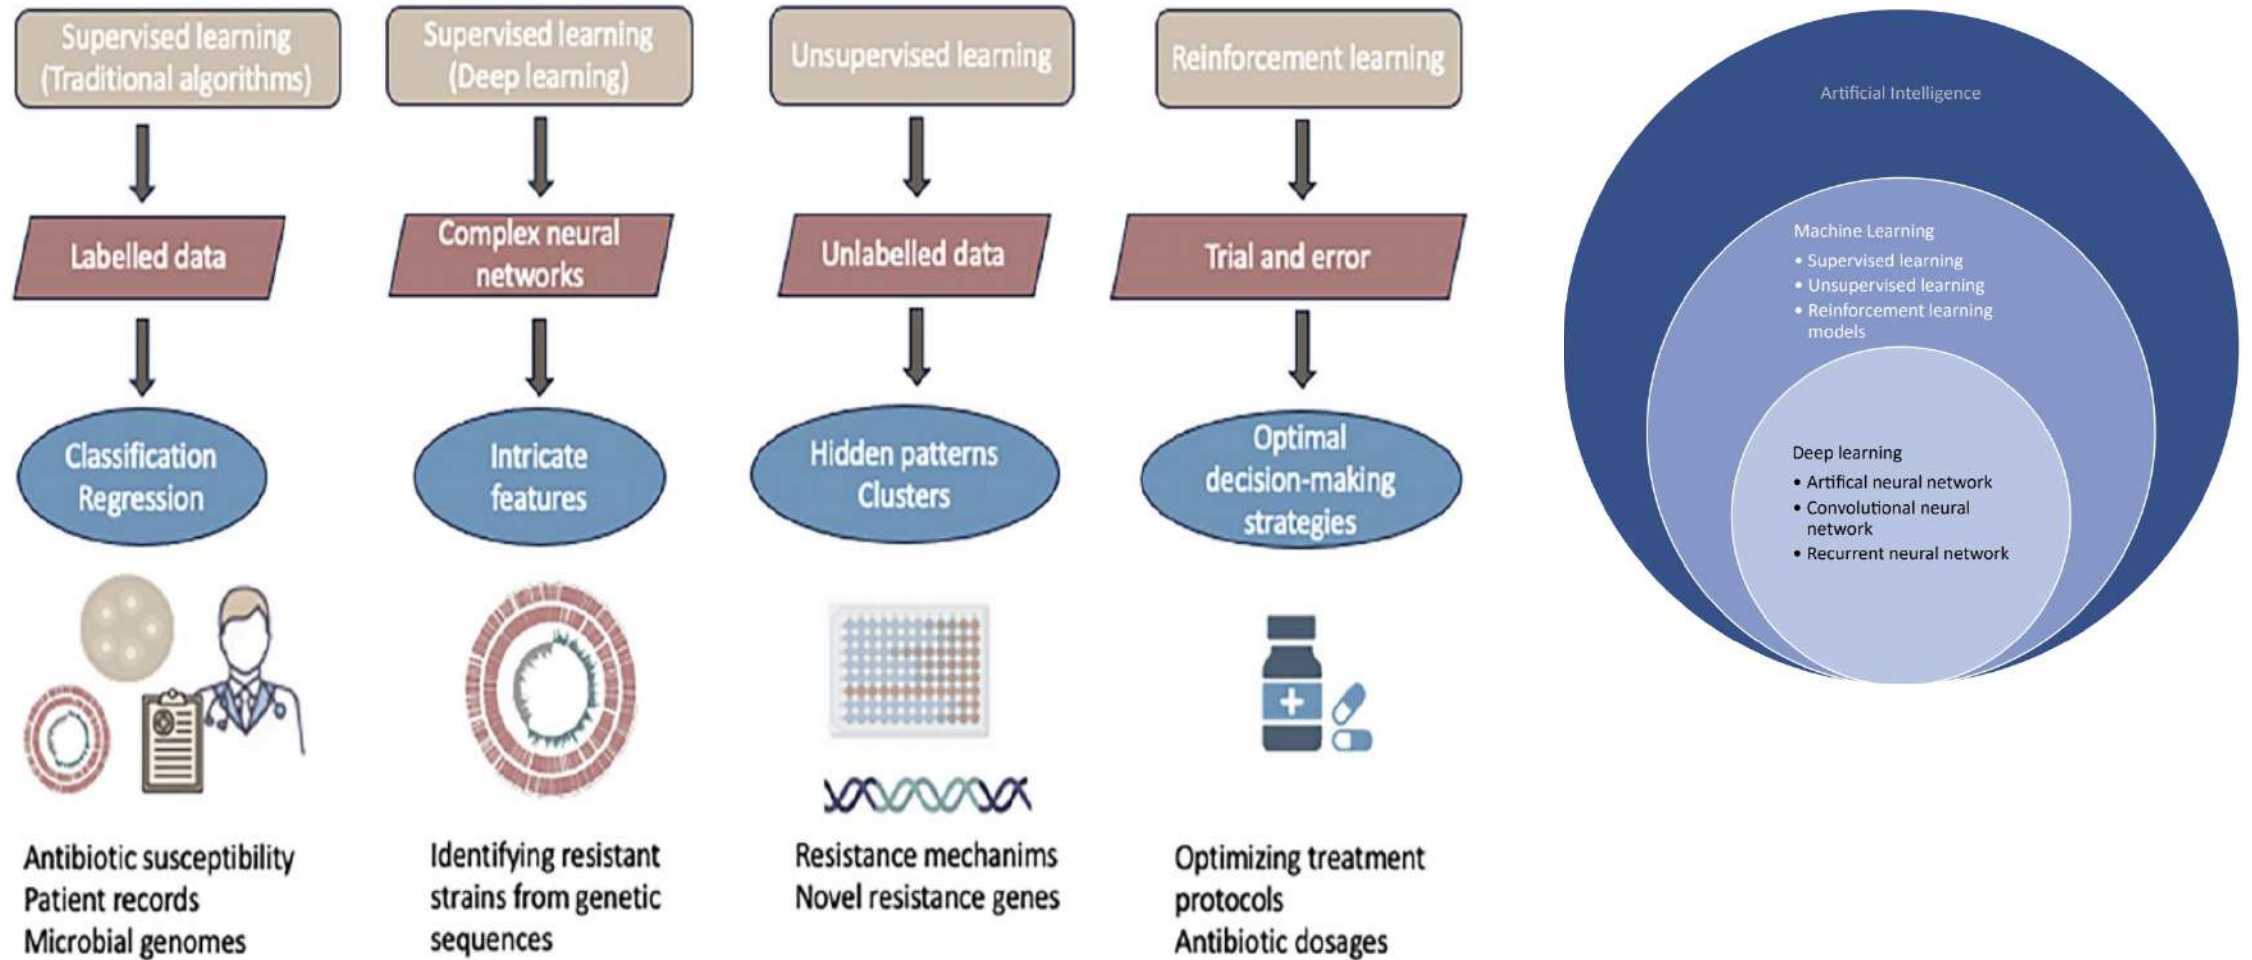


Fig. 1 ML methods and applications in the fight against antimicrobial resistance

Lastra JM et al. Journal of Medical Systems (2024) 48:71
Ahmad et al. JVS-Vascular Insights 2024

From Data to Decisions: Leveraging Artificial Intelligence and Machine Learning in Combating Antimicrobial Resistance – a Comprehensive Review

José M. Pérez de la Lastra¹ · Samuel J. T. Wardell² · Tarun Pal³ · Cesar de la Fuente-Nunez^{4,5,6,7} · Daniel Pletzer²

Manuel test ihtiyacını azaltır ve insan hatasını en aza indirir

- ❖ Yüksek kaliteli ve kapsamlı veri kümelerinin elde edilmesi ve entegrasyonu zor
- ❖ Gizlilik ve hasta güvenliği endişeleri
- ❖ Karmaşık modeller ve büyük veri kümeleri uzmanlık gerektirir
- ❖ Sistemlerin geliştirme ve uygulama maliyetleri yüksek
- ❖ Mikroorganizmanın dinamik yapısı, modellerin sürekli olarak güncellenmesini ve yeniden eğitilmesini gerektirir

Commentary

Revolutionizing antimicrobial stewardship, infection prevention, and public health with artificial intelligence: the middle path

- Hasta verilerini analiz ederek
- Hastanın önceki antimikrobiyal kullanımını bilgisini değerlendirerek
- Kültür ve duyarlılık verilerini göz önünde bulundurarak
- Ampirik veya hedefe yönelik en uygun tedaviyi seçerek
- İlaçlarda doz optimizasyonunu sağlayarak
- Direnç geliştirme riskini en aza indirebilmek için bireyselleştirilmiş tedavi önerileri sunarak antimikrobiyal yönetimine katkıda bulunur

Yapay zekanın faydaları


Verimlilik

Doğruluk




Yapay Zeka ve Sorunlar

- Mevcut klinik ve laboratuvar iş akışına nasıl entegre edileceğini tartışmalı
- Belirli bir veri kümesi kullanılarak geliştirilen modellerin diğer popülasyonlara ne ölçüde genelleştirilebileceği belirsiz

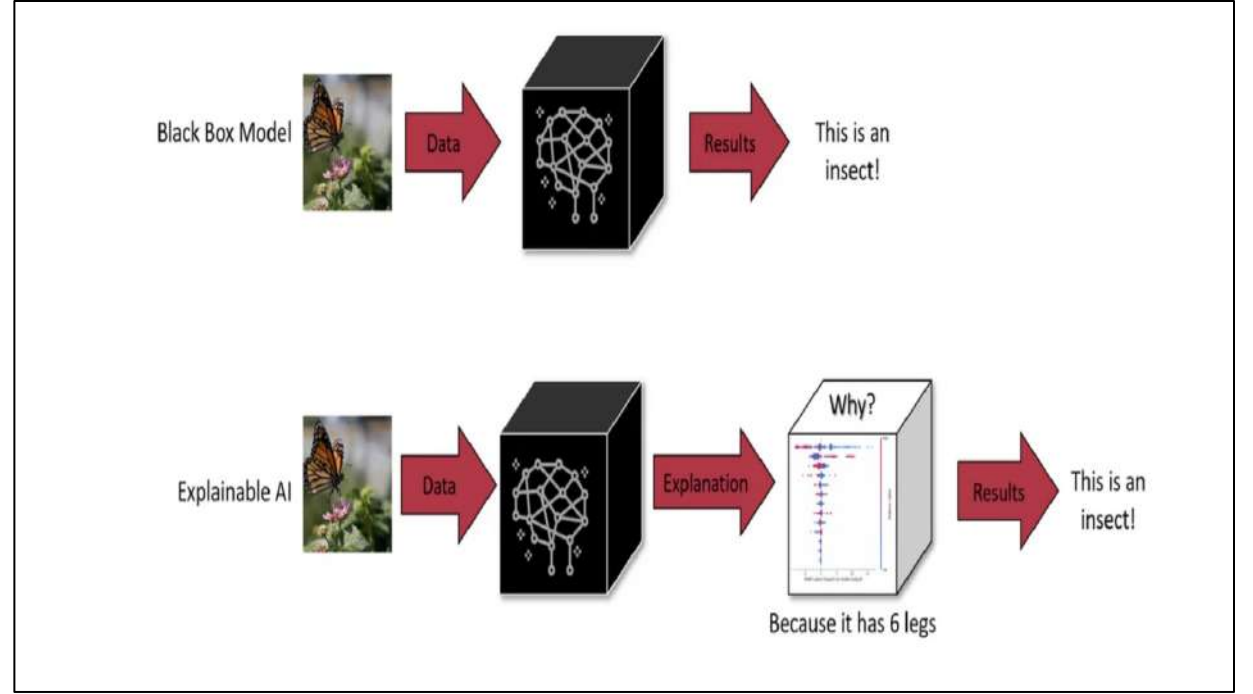



Yapay Zeka ve Sorunlar

- Eksik ve hatalı verilerin girilmesi
- Yapılandırılmış ve etiketlenmiş verilerin kullanılmaması
- Kullanılan modellerin performansının zaman içinde denetiminin yapılmaması



Yapay zekanın kara kutusu



Yapay zekada işleme katmanlarının çoğu insan kullanıcılarından gizli kalır

SONUÇ OLARAK

- Erken teşhisi sağlayarak ve tedavi sürecini hızlandırarak, hastaların ekstremitte kaybını azaltabilir.
- İnfeksiyonun seyrini tahmin edebilir, erken müdahaleler ile tedavi maliyetlerini düşürebilir ve hasta sonuçlarını iyileştirebilir.
- Kişiselleştirilmiş tedavi planları oluşturabilir, infeksiyonun en etkili şekilde yönetilmesini sağlar.





İlginiz için teşekkür ederim