

YAPAY ZEKA ve TANISAL YÖNETİŞİMDEKİ UYGULAMALARI

Asistan Dr. Mikail BÜLBÜL



SUNUM PLANI

- YAPAY ZEKA NEDİR?
- VERİ BİLİMİ
- GÖRÜNTÜ SINIFLANDIRMA
ve TANIMA
- TIP ve YAPAY ZEKA
- TANISAL YÖNETİŞİMDE
YAPAY ZEKA
UYGULAMALARI



Yapay Zeka (AI) Nedir?

İnsan zekasını taklit eden,
verilerden öğrenen ve
sürekli gelişen
algoritmalar bütünüdür




AI is the new electricity.
Andrew NG


"Yapay zeka ilerledikçe, makine öğrenmesi ve insan öğrenmesi arasındaki sınır gitgide daha da belirsizleşiyor." - Demis Hassabis, DeepMind



"Yapay zeka insanların yerini alamaz. Ancak, onların yanında çalışabilir." - Ginni Rometty, IBM



Alan M. Turing (1912-1954)



YAPAY ZEKANIN TARİHÇESİ

- **Yapay Zeka kavramı**, ilk olarak 1956'da bir konferans sırasında ortaya atıldı. Ancak, Yapay zekanın tarihçesi çok daha eski dönemlere dayanmaktadır.
- Antik dönemlerden bu yana insanlar, yapay zekayı andıran makineler veya otomatlar yaratma düşüncesini keşfettiler.
- 20. yüzyılın başlarından itibaren, bilim adamları ve matematikçiler, mantıksal hesaplama ve makine öğrenimi alanlarında önemli çalışmalar yaptılar.
- Alan Turing'in 1936'da geliştirdiği "**Turing makinesi**" kavramı, bilgisayar biliminde temel bir adımdı ve yapay zeka çalışmalarına büyük etkisi oldu.

YAPAY ZEKANIN TARİHÇESİ



1950'lerde, yapay zeka resmen bir araştırma alanı olarak tanımlandı. Alanının öncülerinden olan **John McCarthy**, "**Yapay Zeka**" terimini ilk kez kullanarak, makinelerin düşünce yeteneklerini taklit edebileceğini öne sürdü. Bu dönemde, sembolik yapay zeka yaklaşımı, mantıksal çıkarılma ve dil işleme gibi alanlarda önemli gelişmeler kaydedildi.



1960'lar ve 1970'lerde, yapay zeka arařtırmaları ivme kazandı. Expert sistemler, doğal dil işleme ve görüntü tanıma gibi alt alanlarda çalışmalar yapıldı. Ancak, o dönemde yapay zekanın çok hızlı bir şekilde başarıya ulaşması beklenirken, beklenen ilerleme gerçekleşmedi ve '**Yapay zeka kışı**' adı verilen bir durgunluk dönemi başladı.



1980'lerden itibaren, yapay sinir ağları ve istatistiksel öğrenme gibi yeni yaklaşımların ortaya çıkmasıyla yapay zeka alanında bir canlanma yaşandı. Bilgisayarların işlem gücü arttıkça ve veri toplama yöntemleri geliştikçe, yapay zekanın daha da ilerlemeye başladı.



2000'li yılların başından itibaren, büyük veri analitiği, derin öğrenme ve bulut bilişim gibi teknolojilerin gelişmesi, yapay zekanın hızla yayılmasına ve uygulama alanlarının genişlemesine yol açtı. Özellikle görüntü ve ses tanıma, otomatik çeviri, oyunlar

VOL. LIX. No. 236.]

[October, 1950

MIND

A QUARTERLY REVIEW

OF

PSYCHOLOGY AND PHILOSOPHY


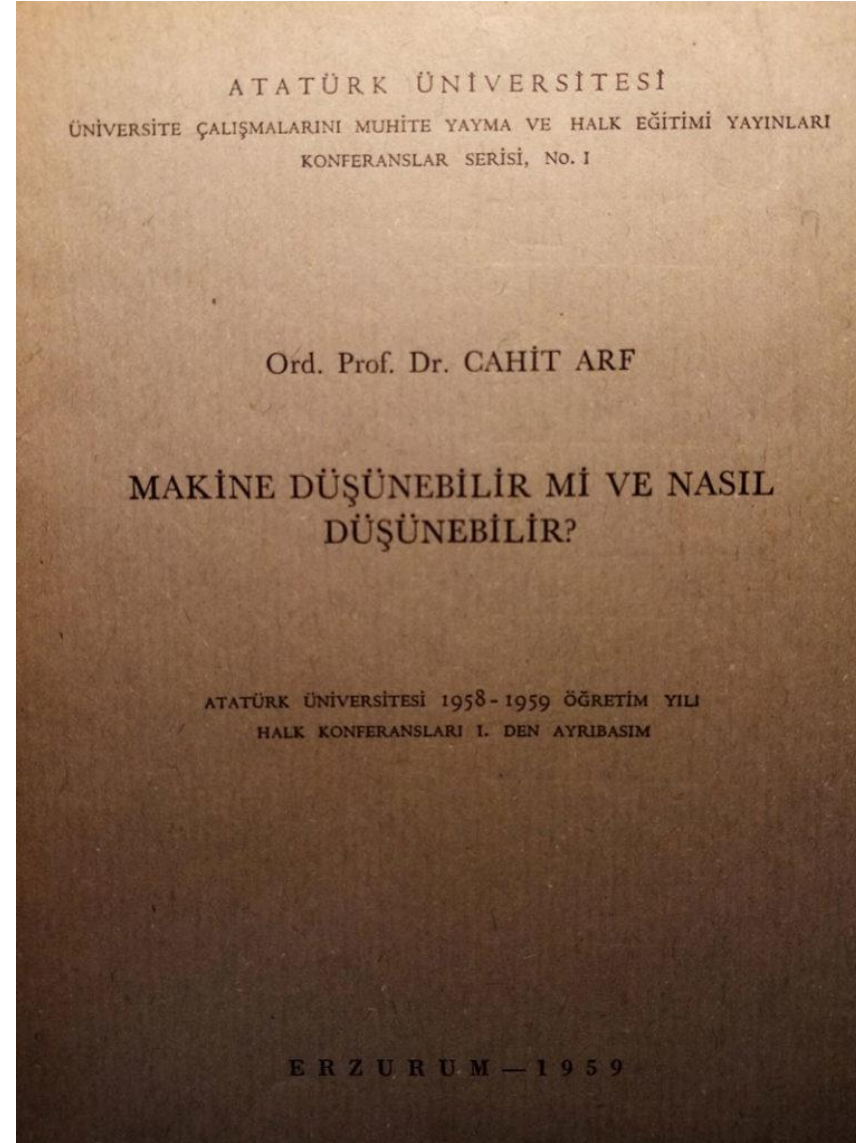


I.—COMPUTING MACHINERY AND
INTELLIGENCE


BY A. M. TURING

1. *The Imitation Game.*


I PROPOSE to consider the question, 'Can machines think?' This should begin with definitions of the meaning of the terms 'machine' and 'think'. The definitions might be framed so as to reflect so far as possible the normal use of the words, but this attitude is dangerous. If the meaning of the words 'machine' and 'think' are to be found by examining how they are commonly used it is difficult to escape the conclusion that the meaning



John McCarthy (1927-2011)
“akıllı makineler yapmanın bilimi ve
mühendisliği»




WABOT-1, Japonya, 1972



1996, 1997- Garry Kasparov Deep Blue'ya karşı

NEW YORK TIMES ÇOK SATANLAR LİSTESİNDE 1 NUMARA

Zihnın Geleceği




**MICHIO
KAKU**

Bilimin Zihni Anlamaya ve
Geliştirmeye Yönelik Arayışları

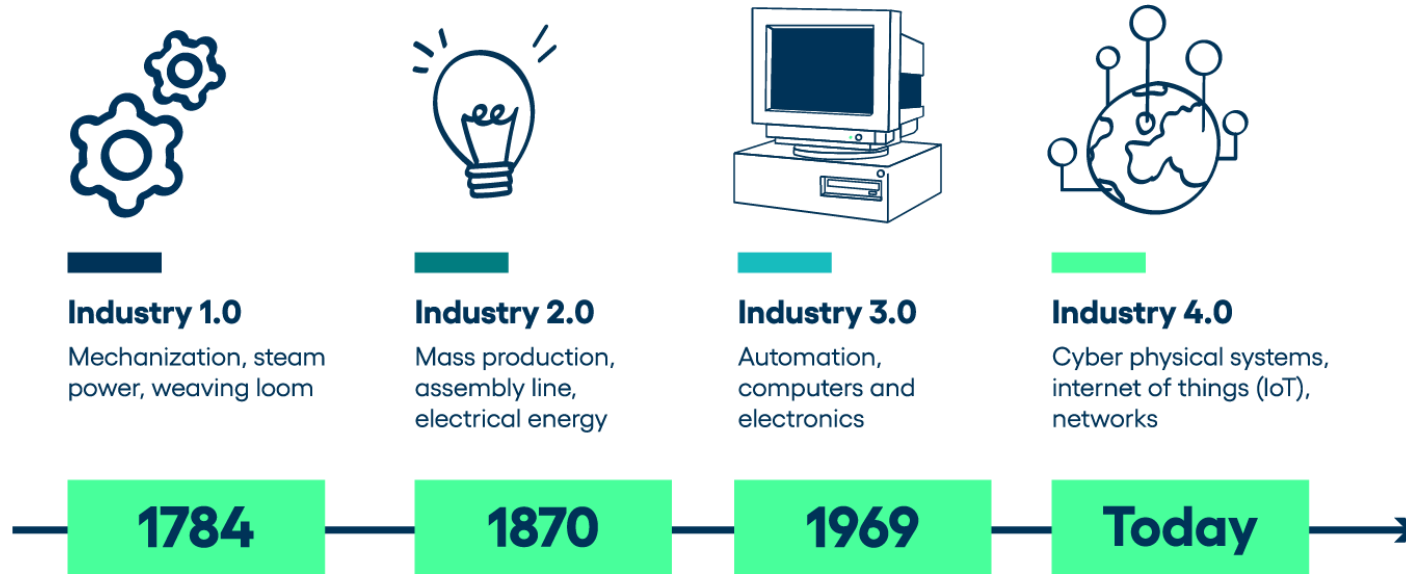
 ODTÜ YAYINCILIK

2. basım

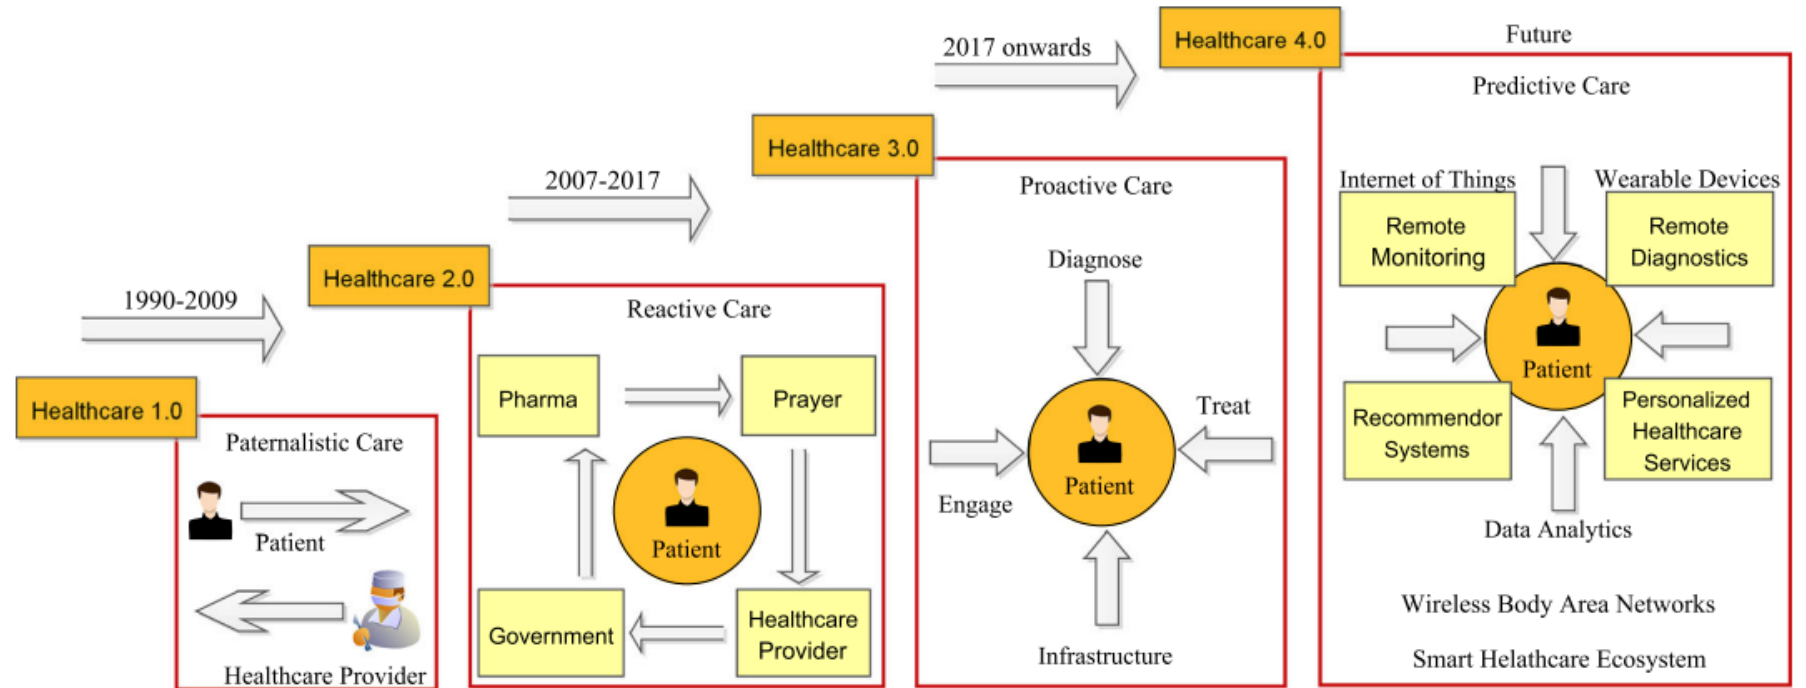


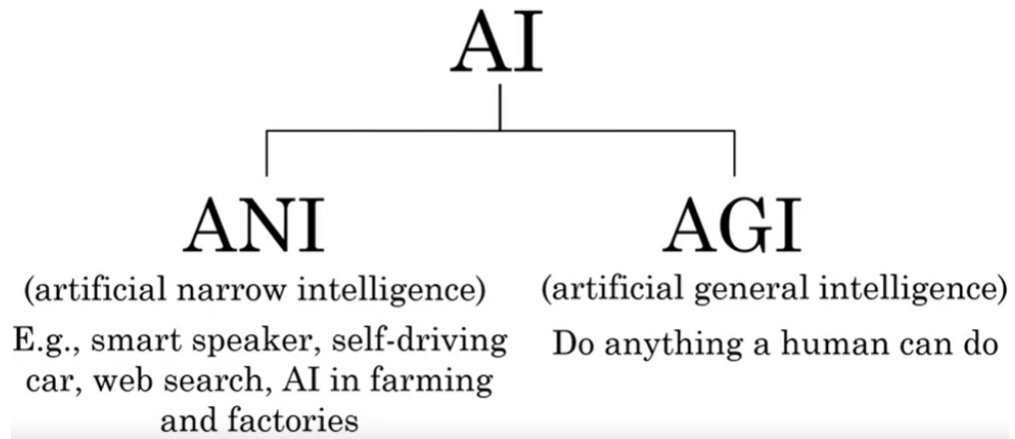
KAKU

Endüstri 4.0



Sağlık 4.0








VS



VS



M

gram pozitif kokların önemli özellikleriyle beraber tablo halinde gösterimi



Tablo halinde, gram pozitif kokların önemli özelliklerini aşağıda bulabilirsiniz:




Gram Pozitif Koklar	Özellikler
Staphylococcus	- Küme halinde veya tek olarak bulunabilir. - Katalaz pozitif (katalaz enzimini üretir). - Koagülaz testi ile türleri ayrılabilir.
Streptococcus	- Zincir halinde veya küme halinde bulunabilir. - Katalaz negatif. - Hemoliz özelliklerine göre sınıflandırılır. - Lancefield sınıflandırması ile gruplandırılabilir.
Enterococcus	- Çift zincirli veya zincir şeklinde bulunabilir. - Katalaz negatif. - Escherichia coli'ye benzer şekilde fermentasyon yapabilir. - Enterokok enfeksiyonlarına dirençli olabilir.
Micrococcus	- Küme halinde bulunabilir. - Katalaz pozitif. - Koagülaz negatif. - Endokardit ve deri enfeksiyonlarına sebep olabilir.

Bu tabloda sadece bazı gram pozitif kok türlerinin özellikleri verilmiştir. Mikroorganizmaların detaylı olarak tanımlanması ve sınıflandırılması için daha spesifik testler ve analizler yapılması gerekmektedir.

gram pozitif kokların önemli özellikleriyle beraber tablo halinde gösterimi

Kanka hemen **Gram pozitif kokları** en kritik özellikleriyle birlikte **tıp öğrencisine / asistanına göre tam net, ezbere uygun** bir tablo halinde hazırladım. Hem klinik hem laboratuvar ayırtıcı noktalarını koydum.

Gram Pozitif Kokların Özellikleri – Özet Tablo



Grup / Bakteri	Morfoloji	Katalaz	Koagülaz	Hemoliz	Ayırt Edici Noktalar	Klinik Önem
Staphylococcus aureus	Üzüme benzer dizilimde koklar	Pozitif	Pozitif	Genelde β-hemolitik	Mannitol fermente eder; tuza dayanıklı	Cilt enfeksiyonları, pnömoni, endokardit, toksik şok
Koagülaz-negatif stafilokoklar (KNS) – S. epidermidis, S. saprophyticus	Üzüm salkımı	Pozitif	Negatif	Genelde γ	S. saprophyticus novobiyosine dirençli	Kateter enf., protez enf., sistit (S. saprophyticus)
Streptococcus pyogenes (Grup A)	Zincir şeklinde koklar	Negatif	—	β-hemolitik	Basitrasine duyarlı , PYR pozitif	Farenjit, erizipel, nekrotizan fasiit, ARF
Streptococcus agalactiae (Grup B)	Zincir	Negatif	—	β-hemolitik (zayıf)	CAMP pozitif , hippurat pozitif	Yenidoğan sepsisi, menenjit
Streptococcus pneumoniae	Lancet şeklinde diplokok	Negatif	—	α-hemolitik	Safra çözüdür, optokine duyarlı	Pnömoni, otitis media, menenjit
Viridans streptokoklar	Zincir	Negatif	—	α-hemolitik	Safra çözüdür değil, optokine dirençli	Endokardit (özellikle S. mutans)
Enterococcus faecalis / faecium	Zincir	Negatif	—	Genelde γ	Safra-eskulin pozitif, NaCl (%6.5) üreme	İYE, yara enf., VRE nozokomiyal enfeksiyonlar
Peptostreptococcus spp. (Anaerop)	Zincir / çift	Negatif	—	Non-hemolitik	Anaerop kok	Diş enf., intraabdominal, pelvik enf.
Micrococcus spp.	Tetrad / küme	Pozitif	Negatif	Genelde sarı pigment	Oksidaz pozitif, kontaminant olabilir	Düşük virülans; enfeksiyon nadir



VERİ BİLİMİ



VERİ BİLİMİ

Veri bilimi, verileri analiz ederek anlamlı bilgi ve öngörü üreten; istatistik, matematik ve makine öğrenimi tekniklerini kullanan bir disiplindir.

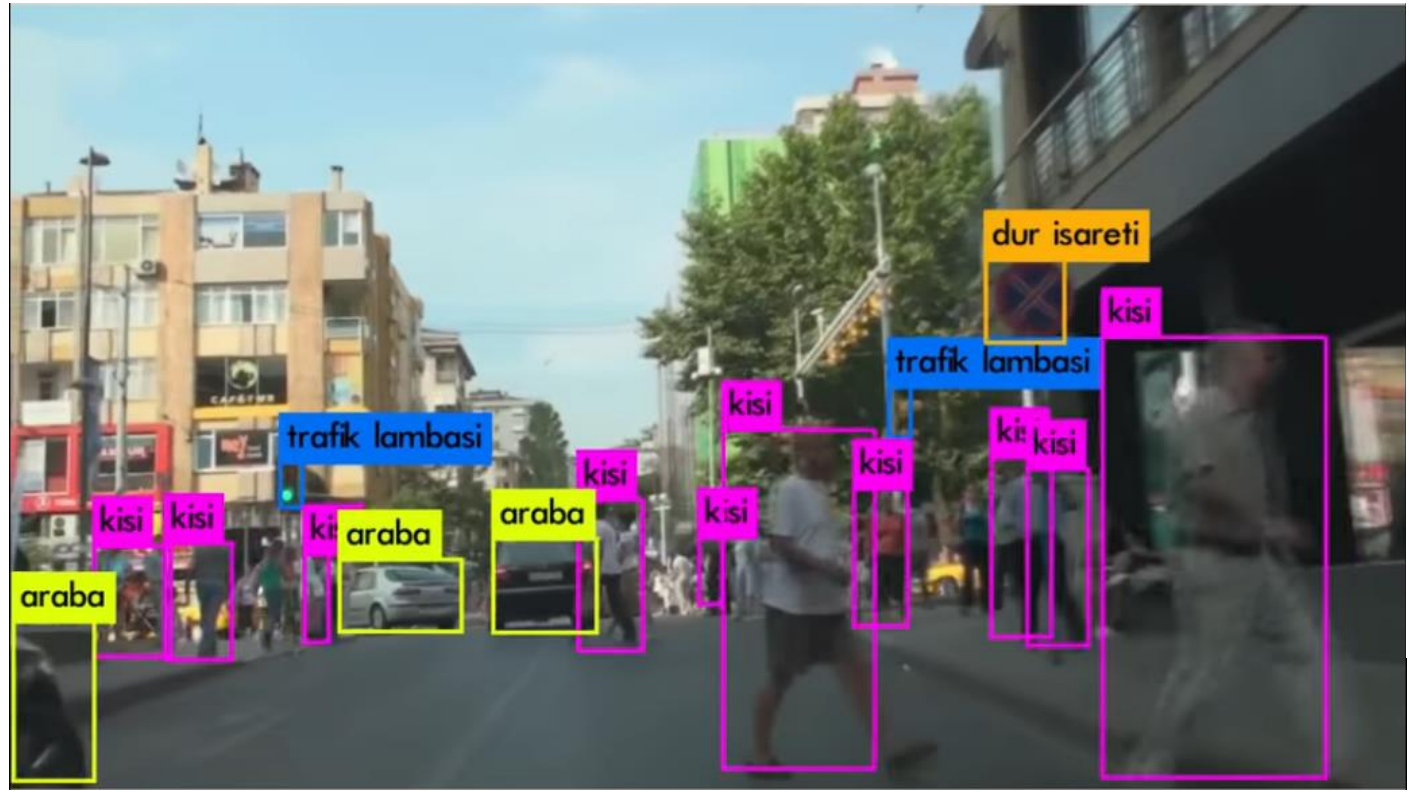
Şirketlerin pazarlama stratejilerini geliştirmesi veya sağlık kurumlarının hastalık tahminleri yapması gibi birçok alanda kullanılır




VERİ BİLİMİ

- Veri bilimi süreci genellikle aşağıdaki adımları içerir:
- **1. Veri toplama**
- **2. Veri hazırlama**
- **3. Veri analizi**
- **4. Modelleme**
- **5. Model eğitimi**
- **6. Model değerlendirilmesi**
- **7. Sonuç çıkarma**
- **8. Sunum ve görselleştirme**
- Veri bilimi, birçok sektörde uygulanabilir ve geniş bir etki alanına sahiptir. Örneğin, sağlık, finans, pazarlama, perakende, ulaşım ve enerji gibi birçok alanda veri biliminden yararlanılarak veri odaklı kararlar alınabilir ve işletmelerin performansı iyileştirilebilir.

Görüntü Sınıflandırma ve Tanıma


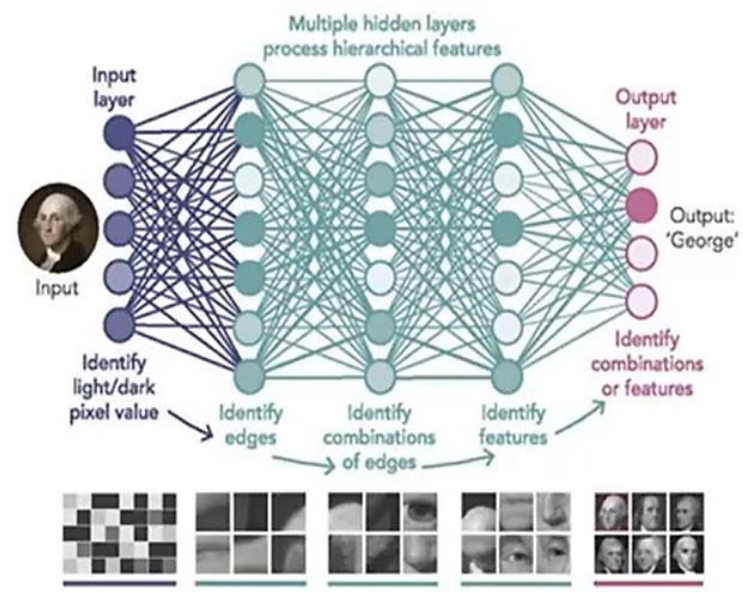


1980S-ERA NEURAL NETWORK




Links carry signals from one node to another, boosting or damping them according to each link's 'weight'.

DEEP LEARNING NEURAL NETWORK



Cambridge Analytica

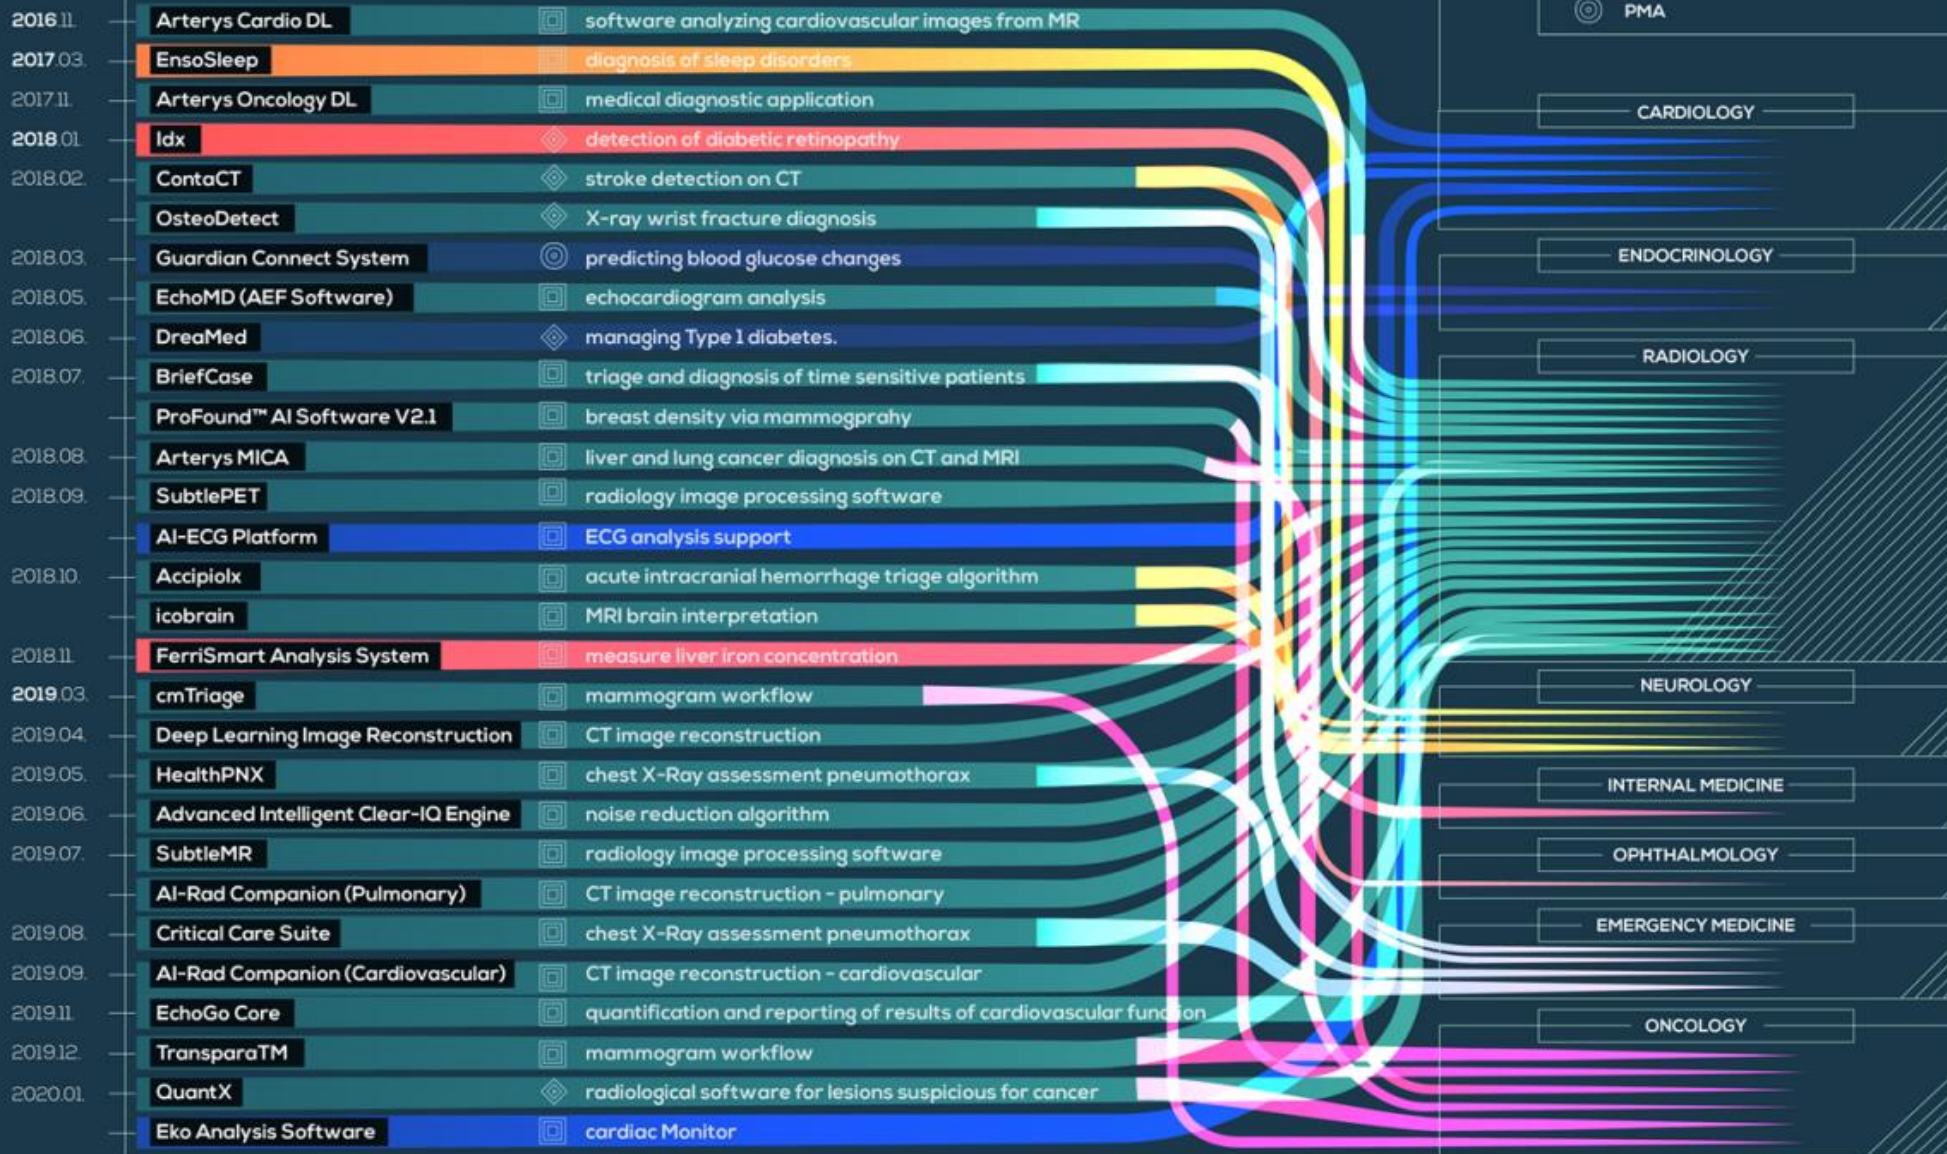


TIP ve YAPAY ZEKA

Neler yapılabilir?

- Birçok veri aynı anda değerlendirilebilir
- Laboratuvar parametrelerinden hastalık tanı-prognoz-risk durumu belirlenebilir
- Yeni biyomarkerlar keşfedilebilir
- Preanalitik hatalar yakalanabilir
- Gereksiz test istemi azaltılabilir
- Referans aralıklar belirlenebilir (hatta genetik profil de eklenerek)
- Görüntülü sonuçlar otomatik tanımlanabilir
- ...

FDA APPROVALS FOR ARTIFICIAL INTELLIGENCE-BASED DEVICES IN MEDICINE



TANISAL YÖNETİŞİMDE YAPAY ZEKA



TANISAL YÖNETİŞİMDE YAPAY ZEKA

Yapay zeka, tanısal ve antimikrobiyal yönetişime yardımcı olabilecek güçlü bir araçtır.

- Antibiyotik seçimi
- Uygunsuz reçete tespiti
- Direnc gelişimi öngörüsü
- Profilaksi doğruluğu
- Ampirik tedavi kesilme kararları gibi alanlarda fayda sağlar.

MALDI-TOF

- MALDI-TOF, büyük moleküllerin kütlesini ölçen, özellikle mikroorganizma türlerini hızlıca belirlemede kullanılan hassas bir kütle spektrometresi cihazıdır.
- Bu cihaz, numunenin protein "parmak izini" çıkararak saniyeler içinde analiz sağlar.
- Elde edilen karmaşık spektrumlar, yüksek doğrulukta otomatik tanımlama ve sınıflandırma yapmak için Yapay Zekâ (YZ) ve makine öğrenimi algoritmaları tarafından işlenir.



VITEK

- **VITEK** sistemi, klinik mikrobiyolojide bakteri ve mayaların tür tanımlamasını (ID) ve antibiyotik duyarlılık testlerini (AST) tam otomatik olarak gerçekleştiren bir cihazdır.
- Cihaz, özel kartlar ve dinamik okuma yöntemleri kullanarak bu kritik sonuçları sadece 5-8 saat gibi kısa bir sürede otomatik olarak raporlayarak laboratuvar verimliliğini artırır.
- VITEK 2'deki **Advanced Expert System (AES)** gibi yerleşik yazılımlar ve sürekli güncellenen veritabanları, direnç fenotiplerini yorumlamak ve en iyi sonucu önermek için gelişmiş algoritmalar (YZ/Makine Öğrenimi temelleri) kullanır.



Review

Image analysis and artificial intelligence in infectious disease diagnostics

K.P. Smith ^{1,2}, J.E. Kirby ^{1,2,*}

¹⁾ Department of Pathology, Beth Israel Deaconess Medical Center, USA

²⁾ Harvard Medical School, Boston, MA, USA

A B S T R A C T

Background: Microbiologists are valued for their time-honed skills in image analysis, including identification of pathogens and inflammatory context in Gram stains, ova and parasite preparations, blood smears and histopathologic slides. They also must classify colony growth on a variety of agar plates for triage and assessment. Recent advances in image analysis, in particular application of artificial intelligence (AI), have the potential to automate these processes and support more timely and accurate diagnoses.

Objectives: To review current AI-based image analysis as applied to clinical microbiology; and to discuss future trends in the field.


Sources: Material sourced for this review included peer-reviewed literature annotated in the PubMed or Google Scholar databases and preprint articles from bioRxiv. Articles describing use of AI for analysis of images used in infectious disease diagnostics were reviewed.

Content: We describe application of machine learning towards analysis of different types of microbiologic image data. Specifically, we outline progress in smear and plate interpretation as well as the potential for AI diagnostic applications in the clinical microbiology laboratory.

Implications: Combined with automation, we predict that AI algorithms will be used in the future to prescreen and preclassify image data, thereby increasing productivity and enabling more accurate diagnoses through collaboration between the AI and the microbiologist. Once developed, image-based AI analysis is inexpensive and amenable to local and remote diagnostic use. **K.P. Smith, Clin Microbiol Infect 2020;26:1318**


© 2020 European Society of Clinical Microbiology and Infectious Diseases. Published by Elsevier Ltd. All rights reserved.

- Gram boyamada %99'dan fazla doğruluk
- Nugent kriterlerine göre sınıflandırma
- İdrar kültürlerinde "üreme var/yok" ayrımı
- Kromojenik agarlarda renk indikatörlerine dayalı olarak MRSA, VRE ve Grup A Streptokok taraması başarıyla yapılabilmektedir



Gram Stain Blood
 MRN 0901XXX
 Spec 537XXXX25A

Prob.	Diagnosis
<input checked="" type="checkbox"/> 97%	Gram-positive cocci in chains suggesting streptococci
<input type="checkbox"/> 2.5%	Gram-positive cocci in pairs and chains suggesting enterococci
<input type="checkbox"/> 0.4%	Gram-positive cocci in pairs
<input type="checkbox"/> 0.1%	Gram-positive cocci in pairs suggesting pneumococci



The Role of Artificial Intelligence and Machine Learning Models in Antimicrobial Stewardship in Public Health: A Narrative Review

Flavia Pennisi ^{1,2}, Antonio Pinto ¹, Giovanni Emanuele Ricciardi ^{1,2}, Carlo Signorelli ¹
and Vincenza Gianfredi ^{3,*}

Abstract: Antimicrobial resistance (AMR) poses a critical global health threat, necessitating innovative approaches in antimicrobial stewardship (AMS). Artificial intelligence (AI) and machine learning (ML) have emerged as transformative tools in this domain, enabling data-driven interventions to optimize antibiotic use and combat resistance. This comprehensive review explores the multifaceted role of AI and ML models in enhancing antimicrobial stewardship efforts across healthcare systems. AI-powered predictive analytics can identify patterns of resistance, forecast outbreaks, and guide personalized antibiotic therapies by leveraging large-scale clinical and epidemiological data. ML algorithms facilitate rapid pathogen identification, resistance profiling, and real-time monitoring, enabling precise decision making. These technologies also support the development of advanced diagnostic tools, reducing the reliance on broad-spectrum antibiotics and fostering timely, targeted treatments. In public health, AI-driven surveillance systems improve the detection of AMR trends and enhance global monitoring capabilities. By integrating diverse data sources—such as electronic health records, laboratory results, and environmental data—ML models provide actionable insights to policymakers, healthcare providers, and public health officials. Additionally, AI applications in antimicrobial stewardship programs (ASPs) promote adherence to prescribing guidelines, evaluate intervention outcomes, and optimize resource allocation. Despite these advancements, challenges such as data quality, algorithm transparency, and ethical considerations must be addressed to maximize the potential of AI and ML in this field. Future research should focus on developing interpretable models and fostering interdisciplinary collaborations to ensure the equitable and sustainable integration of AI into antimicrobial stewardship initiatives.

Keywords: antimicrobial resistance; antimicrobial stewardship; artificial intelligence; machine learning; personalized antibiograms; diagnostic innovation; predictive models; public health

- Son arařtırmalar, AMR'nin 2050 yılına kadar yılda 10 milyona kadar ölüme yol açabileceğini ve küresel sađlık sistemleri ve ekonomileri için önemli bir tehdit oluşturabileceğini tahmin etmektedir.
- Bizler olabildiğince geniş spektrumlu antibiyotik kullanımından kaçınmamız gerekiyor.
- Yapay zekâ destekli öngörücü analizler ;
 - **direnç modellerini** belirleyebilir ,
 - **salgınları tahmin** edebilir
 - büyük ölçekli klinik ve epidemiyolojik verilerden yararlanarak **kişiselleştirilmiş antibiyotik tedavilerine** rehberlik edebilir.

Kullanılan Modeller ve Geleneksel Yöntemlerle Karşılaştırma

Klasik istatistiksel yöntemler (Lojistik Regresyon - LR) ile modern ML modellerini kıyaslıyor:

- Modeller:** Karar Ağaçları (Decision Trees), Random Forest (RF), XGBoost, Support Vector Machine (SVM) ve Neural Networks(NN) incelenmiş.
- Performans:** ML modelleri, LR'ye göre daha üstün performans gösteriyor.
 - Örneğin, MRSA kültür pozitifliğini tahmin etmede derin öğrenme modelleri (AUC: 0.911), LR'ye (AUC: 0.857) göre daha başarılı bulunmuş.
 - Benzer şekilde, yanık hastalarında akut böbrek hasarı tahmininde XGBoost, LR'den daha yüksek özgüllük ve duyarlılık sunmuş.
- Yorumlanabilirlik (Black Box Sorunu)**

Hızlı Tanı ve Kişiselleştirilmiş Antibiyogramlar

- **Hızlı Patojen Tanımlama:** Yapay zeka, MALDI-TOF kütle spektrometresi verilerini işleyerek direnç profillerini saatler içinde (günler yerine) belirleyebiliyor.
 - Örneğin, *K. pneumoniae* karbapenem direncini 0.85 üzeri AUC değerleriyle tespit edebildiği gösterilmiş.
- **Kişiselleştirilmiş Antibiyogramlar:** Geleneksel, popülasyon bazlı kümülatif antibiyogramların aksine; **hastanın geçmişi, komorbiditeleri ve demografik verilerini kullanan** ML modelleri "kişiselleştirilmiş antibiyogramlar" oluşturuyor.
 - *Örnek Çalışma:* Stanford ve Boston'da yapılan bir çalışmada, kişiselleştirilmiş antibiyogramların geniş spektrumlu antibiyotik (Vancomycin + Pip-Tazo) kullanımını %69 oranında azalttığı, ancak tedavi kapsayıcılığını düşürmediği (hatta bazı durumlarda artırdığı) görülmüş.



Kefoxitin'in Tedavi Seçenyilic

Article

Artificial Intelligence Can Guide Antibiotic Choice in Recurrent UTIs and Become an Important Aid to Improve Antimicrobial Stewardship

Tommaso Cai ^{1,2,*}, Umberto Aneschi ³, Francesco Prata ⁴, Lucia Collini ⁵, Anna Brugnolli ⁶, Serena Migno ⁷, Michele Rizzo ⁸, Giovanni Liguori ⁸, Luca Gallelli ⁹, Florian M. E. Wagenlehner ¹⁰, Truls E. Bjerklund Johansen ^{2,11,12}, Luca Montanari ¹³, Alessandro Palmieri ¹⁴ and Carlo Tascini ¹³

Abstract: Background: A correct approach to recurrent urinary tract infections (rUTIs) is an important pillar of antimicrobial stewardship. We aim to define an Artificial Neural Network (ANN) for predicting the clinical efficacy of the empiric antimicrobial treatment in women with rUTIs. Methods: We extracted clinical and microbiological data from 1043 women. We trained an ANN on 725 patients and validated it on 318. Results: The ANN showed a sensitivity of 87.8% and specificity of 97.3% in predicting the clinical efficacy of empirical therapy. The previous use of fluoroquinolones (HR = 4.23; $p = 0.008$) and cephalosporins (HR = 2.81; $p = 0.003$) as well as the presence of *Escherichia coli* with resistance against cotrimoxazole (HR = 3.54; $p = 0.001$) have been identified as the most important variables affecting the ANN output decision predicting the fluoroquinolones-based therapy failure. A previous isolation of *Escherichia coli* with resistance against fosfomicin (HR = 2.67; $p = 0.001$) and amoxicillin-clavulanic acid (HR = 1.94; $p = 0.001$) seems to be the most influential variable affecting the output decision predicting the cephalosporins- and cotrimoxazole-based therapy failure. The previously mentioned *Escherichia coli* with resistance against cotrimoxazole (HR = 2.35; $p < 0.001$) and amoxicillin-clavulanic acid (HR = 3.41; $p = 0.007$) seems to be the most influential variable affecting the output decision predicting the fosfomicin-based therapy failure. Conclusions: ANNs seem to be an interesting tool to guide the antimicrobial choice in the management of rUTIs at the point of care.

Keywords: urinary tract infection; recurrence; artificial intelligence; antibiotic resistance

- Bu çalışma, kadınlarda sık görülen rekürren idrar yolu enfeksiyonlarında (riYE), ampirik antibiyotik tedavisinin klinik etkinliğini tahmin etmek için bir **Yapay Sinir Ağı (ANN)** modeli geliştirmeyi amaçlıyor.
- 1043 kadın hastanın verileri kullanılmış
- 725'i yapay zekayı eğitmek (training), 318'i ise test etmek (validation) için kullanılmış.
- **AUC Değeri: 0.867** (Yani model, doğru tedaviyi seçme konusunda %86.7'lik bir ayırt etme gücüne sahip).
- **Sensitivite: %87.8 Spesifite: %97.3**

Tedavi Başarısızlığını Tahmin Eden Kritik Faktörler

Yapay zeka, hangi durumlarda hangi antibiyotiğin **başarısız olacağını** şu parametrelerle öngörmüş:

A. Florokinolon Tedavisi Başarısızlığı İçin Riskler:

- Son 3 ayda **florokinolon** kullanımını (Risk 4.23 kat artıyor - HR: 4.23).
- Son 3 ayda **sefalosporin** kullanımını (Risk 2.81 kat artıyor - HR: 2.81).
- Hastada kotrimoksazol (Cotrimoxazole) dirençli *E. coli* varlığı.

B. Fosfomisin Tedavisi Başarısızlığı İçin Riskler:

- Hastada **kotrimoksazol** dirençli *E. coli* varlığı (Risk 2.35 kat artıyor).
- Hastada **amoksisilin-klavulanik asit** dirençli *E. coli* varlığı (Risk 3.41 kat artıyor).
- *İlginç Not:* Önceki fosfomisin kullanımını, fosfomisin başarısızlığı için bir risk faktörü olarak tanımlanmamış.
- **Çapraz Direnç Uyarısı:** Çalışma, sadece aynı sınıf antibiyotiğin değil, farklı sınıfların (örneğin sefalosporin kullanımının florokinolon direncini etkilemesi gibi) kullanımının da başarısızlığı öngördüğünü gösteriyor



Vevo

Brave New World of Artificial Intelligence: Its Use in Antimicrobial Stewardship—A Systematic Review

Rafaela Pinto-de-Sá¹, Bernardo Sousa-Pinto^{2,3} and Sofia Costa-de-Oliveira^{1,3,*}

Abstract: Antimicrobial resistance (AMR) is a growing public health problem in the One Health dimension. Artificial intelligence (AI) is emerging in healthcare, since it is helpful to deal with large amounts of data and as a prediction tool. This systematic review explores the use of AI in antimicrobial stewardship programs (ASPs) and summarizes the predictive performance of machine learning (ML) algorithms, compared with clinical decisions, in inpatients and outpatients who need antimicrobial prescriptions. This review includes eighteen observational studies from PubMed, Scopus, and Web of Science. The exclusion criteria comprised studies conducted only in vitro, not addressing infectious diseases, or not referencing the use of AI models as predictors. Data such as study type, year of publication, number of patients, study objective, ML algorithms used, features, and predictors were extracted from the included publications. All studies concluded that ML algorithms were useful to assist antimicrobial stewardship teams in multiple tasks such as identifying inappropriate prescribing practices, choosing the appropriate antibiotic therapy, or predicting AMR. The most extracted performance metric was AUC, which ranged from 0.64 to 0.992. Despite the risks and ethical concerns that AI raises, it can play a positive and promising role in ASP.

Keywords: artificial intelligence; machine learning; antimicrobial stewardship; antimicrobial resistance

- Bu derleme, 2010-2022 yılları arasında yayınlanan ve hastanede yatan veya ayaktan tedavi gören hastalarda antimikrobiyal reçete kararlarını destekleyen yapay zeka modellerini inceleyen **18 gözlemsel çalışmayı** kapsıyor.

- **Amaç:** Yapay zeka algoritmalarının, klinik kararlara kıyasla tahmin performansını (özellikle AUC, duyarlılık vb.) özetlemek
- Makale, AMS alanında en sık kullanılan algoritmaların **Lojistik Regresyon (%12.1)** ve **Random Forest (%12.1)** olduğunu belirtiyor.
- **Başarı Oranları (AUC):** Modellerin AUC değerleri 0.64 ile 0.992 arasında değişiyor. En yüksek performansı (AUC 0.992, Duyarlılık 0.967) cerrahi profilaksi denetiminde kullanılan "Multilayer Perceptron" algoritması göstermiş.

Klinik Uygulama Alanları

Yapay zeka modelleri Antimikrobiyal Yönetişim ekiplerine şu 3 ana görevde yardımcı oluyor:

1.Uygunsuz Reçeteleri Yakalama: Örneğin, **Piperasilin-tazobaktam** reçetelerindeki uygunsuzlukları tespit eden bir sistem, **%96 duyarlılık (sensitivity)** ve **%74 pozitif öngörü değeri (precision)** ile çalışmış.

2.Doğru Antibiyotiği Seçme: Random Forest modeli, seftriakson duyarlılığını **0.80 AUC** değeri ile tahmin edebilmiş.

3.Direnç Tahmini: Kişiselleştirilmiş antibiogramlar oluşturularak tedavi başarısızlığının ve direnç gelişimini öngörme.

Bir çalışmada, yapay zeka destekli karar algoritması kullanıldığında, klinisyenlere kıyasla ikinci basamak **antibiyotik kullanımında %67, uygunsuz tedavide ise %18 azalma** sağlandığı bildirilmiştir.



diagnosights

Sign in

mikail



....



Remember me

Sign in

• TEŞEKKÜRLER...

