

Yapay Zekâ ile Antibiyotik Seçimi: Karar Destek Sistemleri

Dr. Selcan Arslan Özel

SBÜ Derince Eğitim ve Araştırma Hastanesi

Enfeksiyon Hastalıkları ve Klinik Mikrobiyoloji



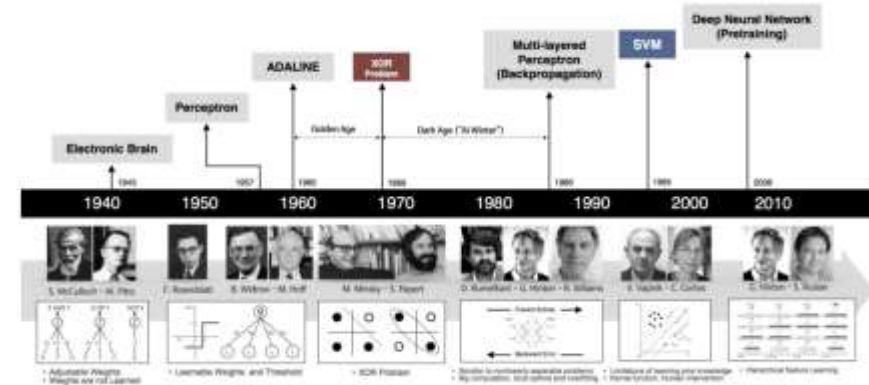

Sunum Planı

- Tanımlar
 - Problem
 - Yapay Zekanın Rolü
 - Literatür
 - Sınırlayıcı Faktörler
 - Türkiye'deki durum
-

Yapay Zekâ

❖ Yapay zekâ (Artificial Intelligence/AI)

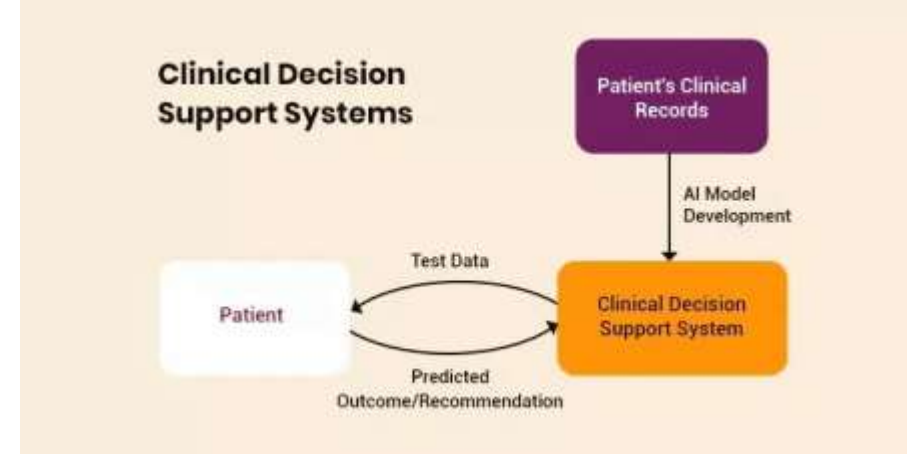
- Bilgisayarların insan benzeri düşünme, öğrenme ve karar verme yeteneklerini taklit etmesini sağlayan bilgisayar biliminin bir alt dalıdır
- Yapay zekâ, kural tabanlı sistemlerden öğrenen ve üreten modellere evrilmiştir
- Yapay Zekanın alt dalları;
 - Makine öğrenmesi (ML)
 - Derin öğrenme (DL)
 - Doğal dil işleme (NLP)



Karar Destek Sistemleri

❖ Karar Destek Sistemleri (Clinical Decision Support Systems - CDSS) Nedir?

- Hasta verilerini analiz ederek hekime tanı ve tedavi sürecinde öneriler sunan sistemlerdir
- Hekimin yerine karar veren değil
- Hekimin klinik kararını veriyle güçlendiren, öneri sunan sistemler

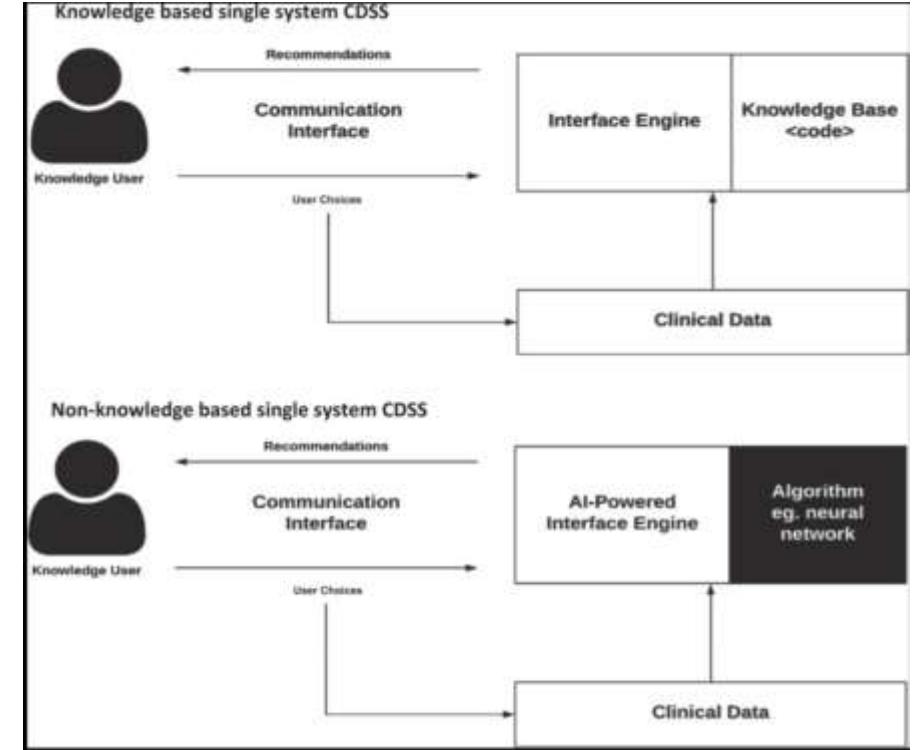


Klinik Karar Destek Sistemleri

Kural tabanlı (Knowledge-based CDSS) ;

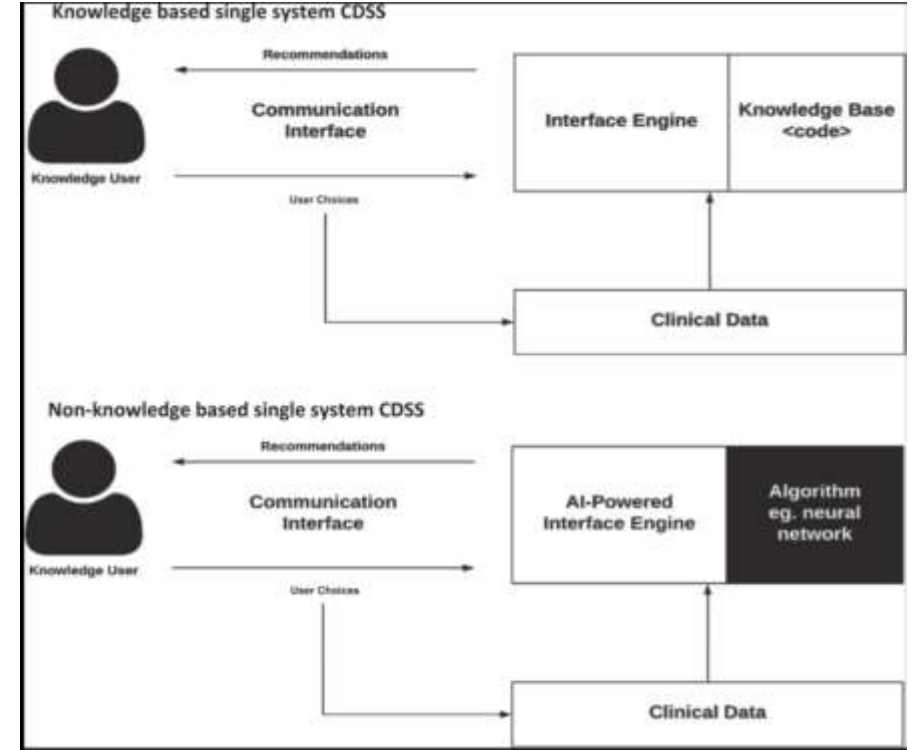
❖ MYCIN;

- 1970'lerde Stanford Üniversitesi'nde geliştirilen ilk sistem;
 - ✓ Kural tabanlı sistem (≈450 kural)
 - ✓ Klinik rehberleri kullanıyor; Uygun antibiyotiği, dozunu öneriyor
 - ✓ Uzman kuralları ("eğer-ise")
 - ✓ Belirsizlikle başa çıkabiliyor
- ✓ Dezavantajları;
 - Klinik entegrasyon yok
 - Hukuki sorumluluk belirsiz
 - Kullanımı zor
 - Güncellemesi zor
 - Karmaşık durumlarda yetersiz



Klinik Karar Destek Sistemleri

- Veri Tabanlı (Non-knowledge-based / AI-CDSS) ;
 - Klinik veri kullanır
 - Algoritma (neural network vb.)
 - Sistem veriden öğrenir
 - Kendi kurallarını oluşturur

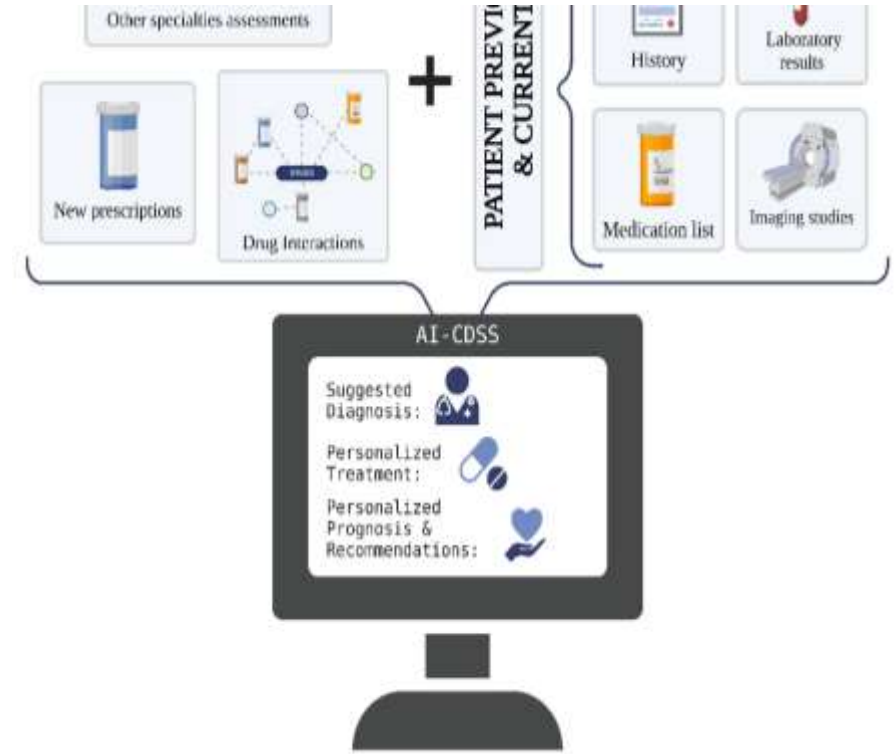


Antimikrobiyal Direnç: Küresel Tehdit

- Dünya Sağlık Örgütü'ne göre antimikrobiyal direnç, insanlığın karşı karşıya olduğu en büyük halk sağlığı tehditlerinden biridir
- Antibiyotik dirençli enfeksiyonların, 2050 yılına kadar yılda 10 milyon ölüme ve 100 trilyon dolar ekonomik kayba yol açacağı öngörülmektedir
- Dirençli mikroorganizmaların sıklığı artmaktadır
- Yeni antimikrobiyal ajan geliştirme süreci yetersizdir
- Antibiyotik direnci, çağdaş tıbbın temel kazanımlarını tehdit etmektedir;
 - ✓ Organ nakli
 - ✓ Kemoterapi
 - ✓ Sezaryen ve majör cerrahiler
- CDC antibiyotik yönetimini (stewardship) dirençle mücadelede en kritik müdahale olarak tanımlamaktadır

Antibiyotik Seçiminde Neden Yapay Zekâ

- AMB insanın tek başına gerçek zamanlı ve bütüncül yönetemeyeceği kadar **karmaşık ve hızlı**
- **Zaman kritik:** Kültür ve antibiyogram sonuçları gecikir
- **Veri yükü fazla:** Klinik, mikrobiyolojik ve epidemiyolojik veriler kompleks
- **Direnç öngörüsü:** Lokal direnç paternleri hızlı değişir
- **Uygun tedavi ihtiyacı:** Gereksiz geniş spektrum kullanımı yaygın
- **Kişiselleştirilmiş yaklaşım:** Her hasta farklı risk profiline sahiptir
- Artan veri yükü ve zaman baskısı nedeniyle antibiyotik yönetişiminde yapay zekâ artık bir gereklilik haline gelmektedir



Antimikrobiyal Yönetişimde Yapay Zekânın Kullanım Alanları

- Antibiyotik Reçeteleme Analizi;
 - ✓ Dozlama hatalarının önlenmesi
 - ✓ Gereksiz geniş spektrumlu antibiyotik kullanımının azaltılması
 - ✓ Tedavi süresinin optimize edilmesi sağlar
- Antibiyotik Direnç Öngörüsü ve Eğilim İzleme;
 - ✓ Antimikrobiyal kullanım politikalarının dinamik olarak güncellenmesini
 - ✓ Riskli alanlara yönelik hedeflenmiş müdahalelerin uygulanmasını sağlar
- **Kişiselleştirilmiş Antibiyotik Seçimi;**
 - ✓ Hasta bazlı antibiyotik önerileri sunabilmektedir
- Klinik Eczacılık ve AMY Ekipleri ile Entegrasyon;
 - ✓ Otomatik öneriler sunarak iş yükünü azaltır
 - ✓ Daha fazla hastanın değerlendirilmesini sağlar
- İzlem, Geri Bildirim ve Performans Göstergeleri;
 - ✓ Aşırı antibiyotik reçetelemesinin önüne

- **Yapay Zekânın Yeni Dünyası: Antimikrobiyal Yönetimde Kullanımı – Sistematik Derleme**

- **Toplam 18 çalışma;**

- 2016 yılından itibaren yayımlanmış
- Bir çalışmada 10 ülkeden, tamamı yüksek gelirli ülkelerde
- 2'si prospektif, 16'si retrospektif gözlemsel tasarıma sahip

Bu derlemede yer alan çalışmalar, yapay zekâ destekli yaklaşımların antimikrobiyal yönetim süreçlerini iyileştirme ve antimikrobiyal direncin kontrolüne katkı sağlama potansiyelini ortaya koymaktadır

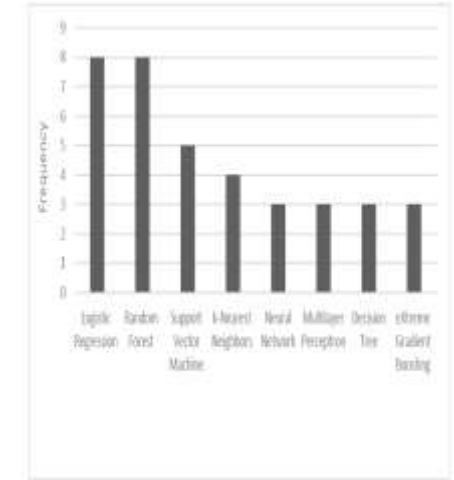
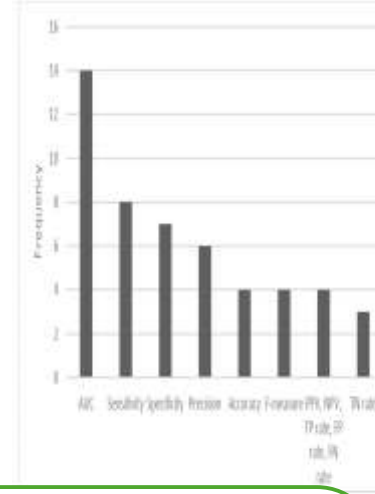


Figure 2. Frequency of the most used AI Algorithms

an performans ölçütü
ler **0.64–0.992** arasında

Table 1. Cont.

Study	Year of Publication	Country	No. Centers	Study Time Frame	Target Population	No. Patients	Infection Site	No. Features	Objective	Algorithm	Performance Measurement	Main Results
[34]	2020	Singapore	1	June 2016 to November 2018	Patients with uncomplicated URTI at the emergency department at Tan Tock Seng Hospital	715	Upper respiratory tract infections	50 (univariate analysis), 8 included in the algorithm	To develop prediction models based on local clinical and laboratory data to guide antibiotic prescribing for adult patients with uncomplicated upper respiratory tract infections	LR models, LASSO, and CART	AUC, sensitivity, specificity, PPV, NPV	The AUC on the validation set for the models was similar: LASSO: 0.70 [95% CI: 0.62–0.77], LR: 0.72 [95% CI: 0.65–0.79], decision tree: 0.67 [95% CI: 0.59–0.74].
[35]					Patients presenting with uncomplicated		UTI	8	To predict antibiotic susceptibility using electronic health record data and build a decision algorithm for recommending the narrowest possible antibiotic to which a specimen is susceptible	LR, decision tree, and RF models	AUROC, FN rates	Decision trees and RF were excluded based on their poor validation set performance and relative lack of interpretability. The LR model provided antibiotic stewardship for a common infectious syndrome by maximizing reductions in broad-spectrum antibiotic use while maintaining optimal treatment outcomes. The algorithm achieved a 67% reduction in the use of second-line antibiotics relative to clinicians and reduced inappropriate antibiotic therapy by 18%, close to the rate of clinicians.
[36]	2019	Cambodia	1	February 2013 to January 2016	Children with at least one positive blood culture from Angkor Hospital for Children	195 (training set); 48 (model validation)	Bloodstream	35	To predict Gram stains and whether bacterial pathogens could be treated with standard empiric antibiotic regimens	RF, LR, decision trees constructed via recursive partitioning, boosted decision trees using adaptive boosting, linear SVM, polynomial SVM, radial SVM, and k-NN	AUROC	The RF method had the best predictive performance overall: AUC of 0.80 (95% CI 0.66–0.94) for predicting susceptibility to ceftriaxone, 0.74 (0.59–0.89) for susceptibility to ampicillin and gentamicin, 0.85 (0.70–1.00) for susceptibility to neither, and 0.71 (0.57–0.86) for Gram stain result.

Amac; gram boyama sonuçları bakteriyel patojenlerin standart ampirik antibiyotik tedavileriyle tedavi edilip edilemeyeceğini öngörmek
 Random Forest (RF) yöntemi genel olarak en iyi öngörü performansını göstermiş
 AUC değerleri: Seftriakson → **0.80**, Amp + Gent → **0.74**, Direnç → **0.85**, Gram → **0.71**
 Bu model, hem tedavi seçimini hem de mikrobiyolojik öngörüğü aynı anda yapabilmektedir

Table 1. Cont.

Study	Year of Publication	Country	No. Centers	Study Time Frame	Target Population	No. Patients	Infection Site	No. Features	Objective	Algorithm	Performance Measurement	Main Results
[23]	2020	Greece	1	January 2017–December 2018	ICU patients in a public tertiary	345	Invasive, respiratory, urinary, mucocutaneous, and wound infections	23,067 (binary, numerical, and categorical in total)	To compare the performance of eight ML algorithms to assess antibiotic susceptibility predictions	ML toolkit: WEKA—Data Mining Software in Java Workbench; LIBLINEAR LR and linear SVM; SVMs; SMO; instance-based learning (k-NN); J48; RF; RIPPER; MLP	TP rate, FP rate, precision, recall, F-measure, mmc, AUROC, precision-recall plot	The best performances were obtained with the RIPPER algorithm (F-measure of 0.678) and the MLP classifier (AUROC of 0.726).
[24]	2022	Taiwan	25	May 2013 to May 2014	healthcare-associated infections receiving at least one antimicrobial drug	7377	Healthcare-associated infection (blood-stream, urinary, pneumonia and surgical site infection).	26	To develop accurate and efficient ML models for auditing appropriate surgical antimicrobial prophylaxis	Supervised ML classifiers (Auto-WEKA (Bayesian optimisation method), MLP (artificial neural network), decision tree, Simple Logistic (LogitBoost e CART algorithm), bagging, SMOTE and AdaBoost)	TP rate, TN rate, FP, FN, AUC, precision, specificity, sensitivity, weighted average for the multiclass model, execution time	The ML technique with the best performance metrics was the MLP, with a sensitivity of 0.967, specificity of 0.992, precision of 0.967, and AUC of 0.992.
[25]	2022	Israel	1	June 2007 to January 2019	Patients with UTI and wound infections from Maccabi Healthcare Services (MHS) with at least one record of a positive wound infection culture	140,349 UTI and 7365 wound infections.	UTI and wound	Not specified	To understand and predict the personal risk of treatment-induced gain of resistance	ML	Personal predicted risk	Choosing the antibiotic treatment with the minimal ML-predicted risk of emergence of resistance reduces the overall risk of emergence of resistance by 70% for UTIs and 74% for wound infections compared to the risk for physician-prescribed treatments.

- Cerrahi antibiyotik profilaksisinin rehberine uygunluğunu değerlendiren ML modeli geliştirmek
- En iyi performans gösteren makine öğrenmesi yöntemi çok katmanlı neural network (MLP) olmuştur; duyarlılık 0.967, özgüllük 0.992, precision 0.967 ve AUC 0.992 olarak bulunmuştur

Table 1. Cont.

Study	Year of Publication	Country	No. Centers	Study Time Frame	Target Population	No. Patients	Infection Site	No. Features	Objective	Algorithm	Performance Measurement	Main Results
[35]	2020	USA	2	2007 to 2016	Patients presenting with uncomplicated UTI at Massachusetts General Hospital and the Brigham and Women's Hospital in Boston	10,053 (training dataset); 3629 (test set)	UTI	8	To predict antibiotic susceptibility using electronic health record data and build a decision algorithm for recommending the narrowest possible antibiotic to which a specimen is susceptible	LR, decision tree, and RF models	AUROC, FN rates	Decision trees and RF were excluded based on their poor validation set performance and relative lack of interpretability. The LR model provided antibiotic stewardship for a common infectious syndrome by maximizing reductions in broad-spectrum antibiotic use while maintaining optimal treatment outcomes. The algorithm achieved a 67% reduction in the use of second-line antibiotics relative to clinicians and reduced inappropriate antibiotic therapy by 18%, close to the rate of clinicians.
[36]	2019	Cambodia	1	February 2013 to January 2016	Children with at least one positive blood culture from Angkor Hospital for Children	195 (training set); 48 (model validation)	Bloodstream	35	To predict Gram stains and whether bacterial pathogens could be treated with standard empiric antibiotic regimens	RF, LR, decision trees constructed via recursive partitioning, boosted decision trees using adaptive boosting, linear SVM, polynomial SVM, radial SVM, and k-NN	AUROC	The RF method had the best predictive performance overall: AUC of 0.80 (95% CI 0.66–0.94) for predicting susceptibility to ceftriaxone, 0.74 (0.59–0.89) for susceptibility to ampicillin and gentamicin, 0.85 (0.70–1.00) for susceptibility to neither, and 0.71 (0.57–0.86) for Gram stain result.

• Elektronik sağlık kayıtlarını kullanarak antibiyotik duyarlılığını tahmin etmek ve en dar spektrumlu uygun antibiyotiği önermek

• Decision Trees ve Random Forest , doğrulama setindeki düşük performansları nedeniyle çalışma dışı bırakılmıştır

• En iyi model: Lojistik regresyon

• %67 ↓ ikinci basamak antibiyotik kullanımı

• %18 ↓ uygunsuz antibiyotik kullanımı

• Tedavi başarısı korunmuş

Kişiselleştirilmiş antibiyogramlar ile makine öğrenmesine dayalı antibiyotik seçimi

- Bu çalışmada;

- ✓ Standart antibiyogramların ötesine geçilerek hastaya özgü antibiyotik duyarlılığı tahmini yapılmış ve ampirik tedavi seçiminde optimizasyon hedeflenmiş
- ✓ Kişiselleştirilmiş antibiyogramlar ile ampirik tedavi, tahmine değil veriye dayalı hale getirilmiş

ARTICLE

 Check for updates

<https://doi.org/10.1038/s43856-022-00094-8>

OPEN

Personalized antibiograms for machine learning driven antibiotic selection

Conor K. Corbin¹, Lillian Sung², Arhana Chattopadhyay¹, Morteza Noshad¹, Amy Chang³, Stanley Deresinski³, Michael Baiocchi¹ & Jonathan H. Chen¹


- **Stanford**
- 2009–
acil
başvuları
8342

- Veri
üçer

✓ **Eğitim**
→ 5

✓ **Doğrulama**
(validation): 2018 →
1218 enfeksiyon

✓ **Test seti**: 2019 → 1320
enfeksiyon



g to 69,069 unique adult patients admitted from Stanford emergency rooms
admissions had a microbial culture and intravenous or intramuscular empiric
antibiotic order placed within the first 24 h of the encounter. **c** Admissions were excluded if microbial cultures had been ordered in the 2 weeks leading up
to the encounter. **d** Admissions resulting in negative microbial cultures were excluded in the primary analysis, leaving 8342 infections from 6920 unique
patients.

- AUC: 0.61 – 0.73 aralığında
- Model performansı orta-iyi düzeyde
- Model makul düzeyde ayırt edicilik göstermektedir

Table 3 Antibiotic susceptibility classifier performance.

Antibiotic selection	Best model class	Prevalence	Average precision	AUROC
Vancomycin	Gradient Boosted Tree	0.23	0.46 [0.40, 0.52]	0.72 [0.68, 0.75]
Ampicillin	Gradient Boosted Tree	0.43	0.54 [0.49, 0.58]	0.62 [0.59, 0.65]
Cefazolin	Gradient Boosted Tree	0.59	0.72 [0.68, 0.76]	0.67 [0.64, 0.70]
Ciprofloxacin	Random Forest	0.63	0.73 [0.70, 0.76]	0.61 [0.58, 0.64]
Ceftriaxone	Gradient Boosted Tree	0.66	0.79 [0.77, 0.82]	0.69 [0.66, 0.72]
Cefepime	Random Forest	0.80	0.87 [0.84, 0.89]	0.65 [0.61, 0.69]
Vancomycin + Ceftriaxone	Gradient Boosted Tree	0.81	0.87 [0.84, 0.89]	0.67 [0.63, 0.71]
Meropenem	Gradient Boosted Tree	0.82	0.90 [0.88, 0.92]	0.69 [0.65, 0.72]
Pip-Tazo	Random Forest	0.90	0.94 [0.92, 0.95]	0.64 [0.59, 0.69]
Vancomycin + Pip-Tazo	Random Forest	0.96	0.98 [0.97, 0.99]	0.70 [0.62, 0.77]
Vancomycin + Cefepime	Random Forest	0.97	0.98 [0.98, 0.99]	0.70 [0.62, 0.78]
Vancomycin + Meropenem	Gradient Boosted Tree	0.98	0.99 [0.99, 0.99]	0.73 [0.65, 0.81]

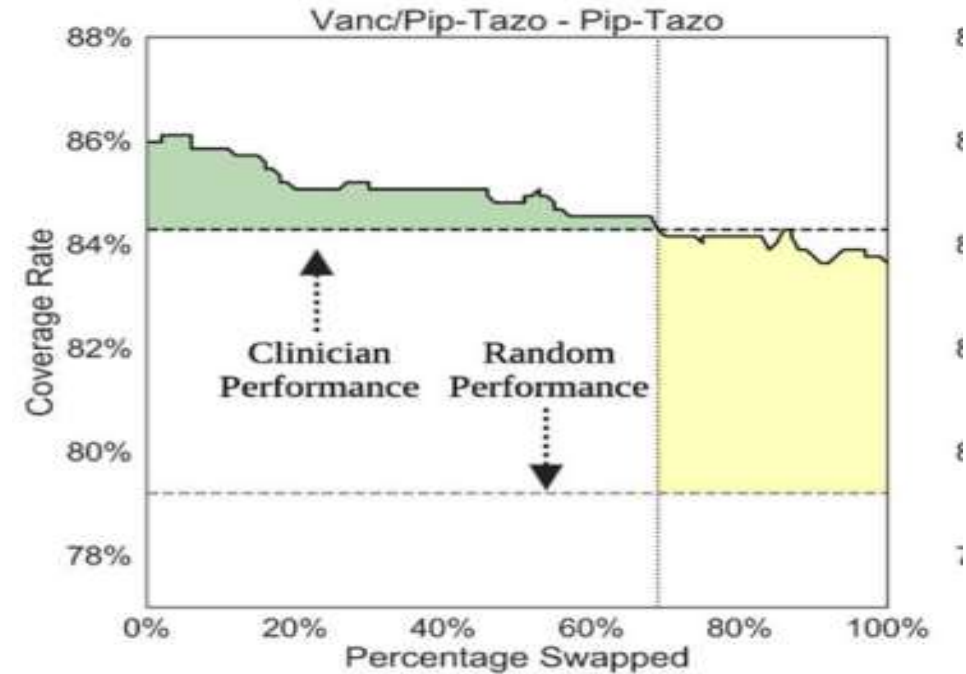
Pip-Tazo = piperacillin/tazobactam.

Personalized antibiograms for machine learning driven antibiotic selection

Conor K. Corbin¹✉, Lillian Sung², Arhana Chattopadhyay¹, Morteza Noshad¹, Amy Chang³, Stanley Deresinski³, Michael Baiocchi¹ & Jonathan H. Chen¹

Stanford Kohortunda;

- Kişiselleştirilmiş antibiyogramlar rehberliğinde yapılan antibiyotik seçimi kapsam oranı %85,9;
 - Bu oran rastgele tedavi seçiminde %79,2 ($p < 0,0001$)
 - Klinisyen performansı %84,3 ($p = 0,11$)
- Klinisyenlerin yaptığı geniş spektrumlu *vankomisin + piperasilin/tazobaktam* reçetelerinin %69'unun, kapsama oranından ödün vermeden sadece



Personalized antibiograms for machine learning driven antibiotic selection

Conor K. Corbin¹✉, Lillian Sung², Arhana Chattopadhyay¹, Morteza Noshad¹, Amy Chang³, Stanley Deresinski³, Michael Baiocchi¹ & Jonathan H. Chen¹

- **Boston Kohortu;**
- 2007–2016
- 13.862 kadın/ 15.806 komplike olmayan üriner sistem enfeksiyonu

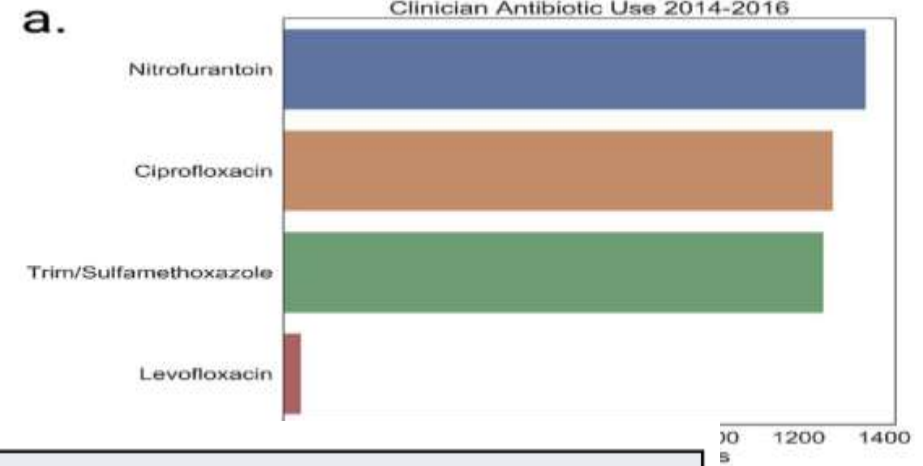



Table 4 Boston Model Performances.

Antibiotic selection	Best model class	Prevalence	Average precision	AUROC
Trime/Sulf	Gradient Boosted Tree	0.80	0.85 [0.84, 0.87]	0.60 [0.58, 0.62]
Nitrofurantoin	Gradient Boosted Tree	0.89	0.91 [0.90, 0.92]	0.57 [0.54, 0.61]
Ciprofloxacin	Lasso	0.94	0.95 [0.95, 0.96]	0.64 [0.60, 0.68]
Levofloxacin	Lasso	0.94	0.96 [0.95, 0.96]	0.64 [0.60, 0.67]

Trime/Sulf = trimethoprim/sulfamethoxazole.

AUC değerleri düşük-orta düzeyde olup, yüksek precision değerleri
Model, iyi tahmin yapıyor ama ayırt ediciliği sınırlı

Personalized antibiograms for machine learning



yüksektir

- Kapsama oranının altına düşmeden toplam siprofloksasin reçetelerinin %93'ünün nitrofurantoin ile değiştirilebileceği
- Toplam siprofloksasin reçetelerinin %48'inin ve nitrofurantoin reçetelerinin %62'sinin trimetoprim/sülfametoksazol ile değiştirilebileceği ortaya konmuştur

➤ Bu sistem aslında hızlı bir antibiogram gibi çalışmakta ve

KiŒiye özgü antibiyotik kesme kararında makine öğrenmesi ve sentetik sonuç analizi;

- Bu çalışma;
 - Retrospektif
 - 2008–2019 yılları arasında ABD’de Boston’da bir hastanede;
 - Yoğun bakımda yatışı sırasında 1–21 gün süreyle intravenöz antibiyotik tedavisi alan
 - 40.000’den fazla hastaya ait elektronik sağlık kayıtlarını incelemiŒ

frontiers | Frontiers in Digital Health

TYPE Original Research
PUBLISHED 21 November 2022
DOI 10.3389/fdigh.2022.997219

Check for updates

OPEN ACCESS

EDITED BY
Max Little,
University of Birmingham, United Kingdom

RECEIVED BY
Tyler John Loftus,
University of Florida, United States
Inmaculada Mora-Jiménez,
Rey Juan Carlos University, Spain

Machine learning and synthetic outcome estimation for individualised antimicrobial cessation

William J. Bolton^{1,2,3*}, Timothy M. Rawson^{1,4},
Bernard Hernandez^{1,5}, Richard Wilson^{1,4}, David Antcliffe^{6,7},

1. DATASET

(Veri hazırlama);

Veri güçlü → model güvenilirliği artar

2. AUTOENCODER (AI öğreniyor);

Karmaşık veriyi tek bir özet haline getiriyor, AI hastayı sıkıştırıp bir profil çıkarıyor.

3. SYNTHETIC OUTCOME;

İki senaryo kuruyor: Devam et, Kes LOS

Mortalite

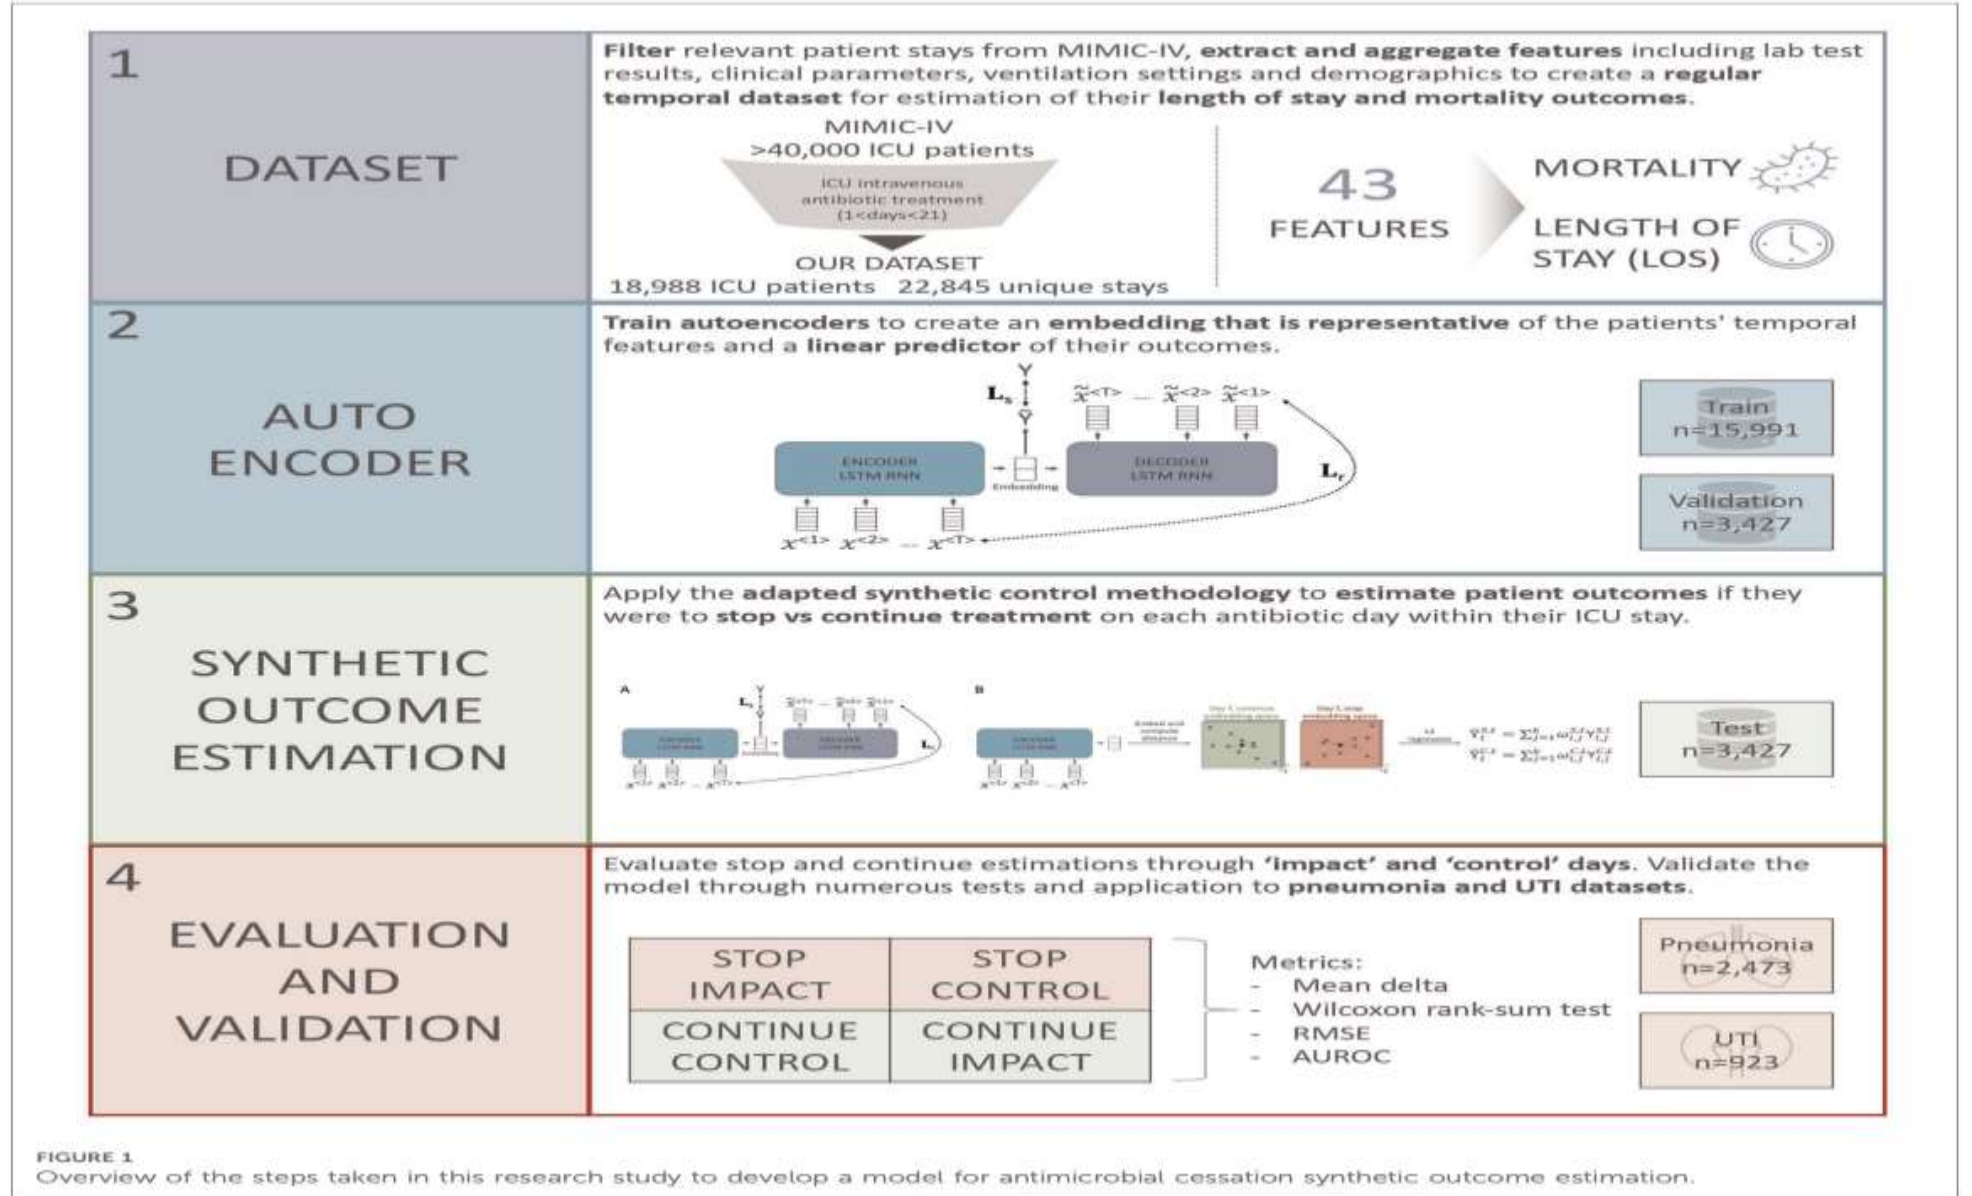
4. EVALUATION (doğrulama);

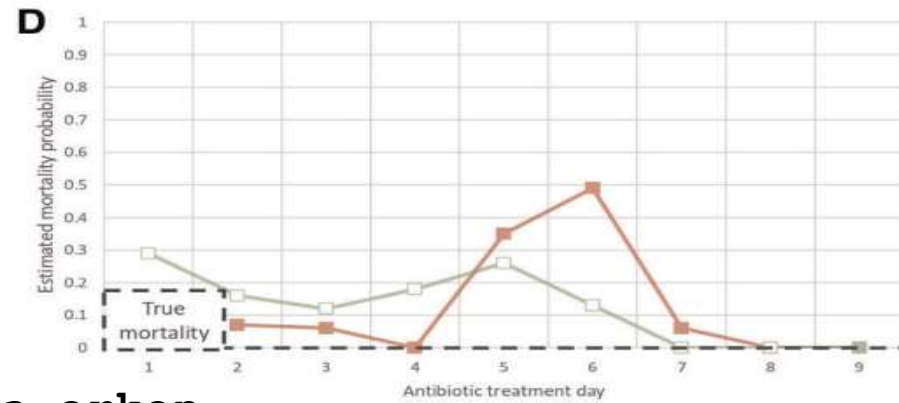
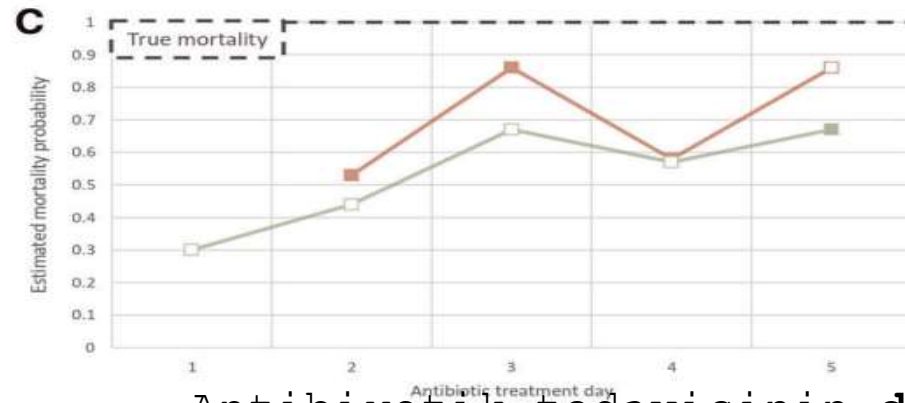
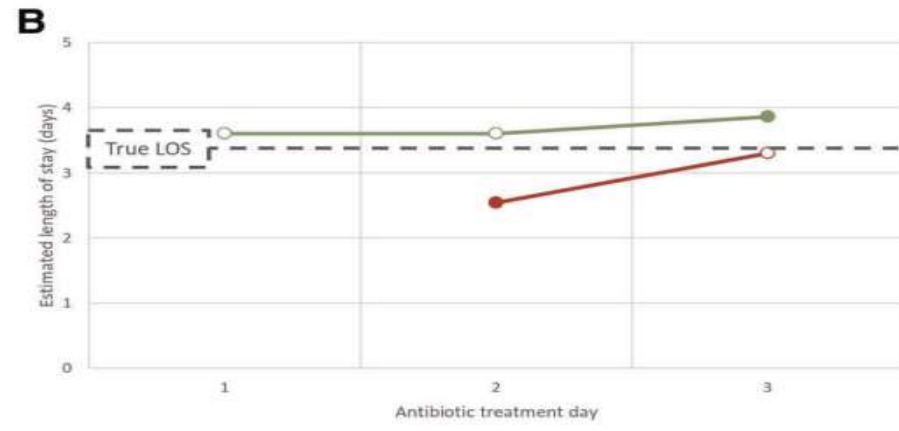
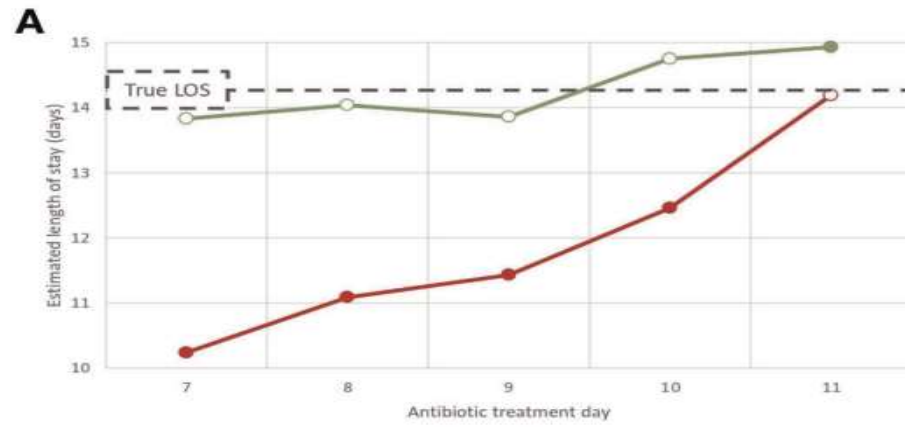
Control;

Gerçek sonuç var, Model doğruluğu test edilir

Impact;

Alternatif senaryo, Asıl klinik değerlendirme





Antibiyotik tedavisinin **daha erken kesilmesinin**, yoğun bakımda kalış süresini **istatistiksel olarak anlamlı şekilde azalttığı** gösterilmiştir (ortalama **2.71 gün azalma**, $p < 0.01$)

Mortalite üzerinde ise herhangi bir etkisi saptanmamıştır

FIGURE 5
LOS and mortality in
patient scenarios
patient survives
reduced LOS. R

illustrative examples of four distinct
antibiotics, (C) the patient dies, (D) the
stop impact estimations have a
between stop vs. continue.

▪ Sonuç olarak;

- Yoğun bakım ünitesinde antibiyotik tedavisinin kesilmesi veya sürdürülmesi durumlarında hasta sonuçlarını tahmin edebilen yapay zekâ destekli bir model geliştirilmiş
- Klinik karar destek sistemine entegre edilmesi ile;
 - ✓ Kişiselleştirilmiş antibiyotik sonlandırma kararlarını desteklenmesi
 - ✓ Gereksiz antibiyotik kullanımını azaltması
 - ✓ Antimikrobiyal dirençle mücadeleye katkı sağlaması ön görülmektedir



OPEN ACCESS

EDITED BY
Max Little,
University of Birmingham, United Kingdom

RECEIVED BY
Tyler John Loftus,
University of Florida, United States
Inmaculada Mora-Jiménez,
Rey Juan Carlos University, Spain

Machine learning and synthetic outcome estimation for individualised antimicrobial cessation

William J. Bolton^{1,2,3*}, Timothy M. Rawson^{1,4},
Bernard Hernandez^{1,5}, Richard Wilson^{1,4}, David Antcliffe^{6,7},

> Clin Infect Dis. 2021 Jun 15;72(12):2103–2111. doi: 10.1093/cid/ciaa383.

A Real-world Evaluation of a Case-based Reasoning Algorithm to Support Antimicrobial Prescribing Decisions in Acute Care

Timothy M Rawson^{1 2}, Bernard Hernandez³, Luke S P Moore^{1 2 4}, Pau Herrero³, Esmita Charani¹, Damien Ming¹, Richard C Wilson^{1 2}, Oliver Blandy¹, Shiranee Sriskandan¹, Mark Gilchrist², Christofer Toumazou³, Pantelis Georgiou³, Alison H Holmes^{1 2}

- Antimikrobiyal tedavi kararlarını desteklemek amacıyla Vaka Tabanlı Karar Destek Sistemlerinin (CBR = Case-Based Reasoning) gerçek yaşam verileriyle değerlendirilmesi;
- Geliştirilen kurum içi CBR algoritması bir KKDS'e entegre edilmiş
- Temmuz 2017 - Şubat 2019 tarihleri arasında İngilterede 3 hastanede, hibrid tasarım
- KKDS'in özellikle **ampirik tedavi aşamasındaki gerçek klinik kullanımını taklit edecek şekilde** planlanmış
- Çalışmaya dahil edilen hekimler:
 - ✓ Enfeksiyon hastalıkları uzmanları
 - ✓ Çalışma süresince nöbet listesinde aktif görev yapan
- Toplam **224 hasta**;
 - ✓ 145 *E. coli* bakteriyemisi olan hastası
 - ✓ 79 servis hastası

A Real-world Evaluation of a Case-based Reasoning Algorithm to Support Antimicrobial Prescribing Decisions in Acute Care

Timothy M Rawson^{1 2}, Bernard Hernandez³, Luke S P Moore^{1 2 4}, Pau Herrero³, Esmita Charani¹, Damien Ming¹, Richard C Wilson^{1 2}, Oliver Blandy¹, Shiranee Sriskandan¹, Mark Gilchrist², Christofer Toumazou³, Pantelis Georgiou³, Alison H Holmes^{1 2}

- Çalışmanın Sonucu;
- Vaka tabanlı KD sisteminin, hekim reçetelerine kıyasla daha dar spektrumlu antibiyotikleri önerdiği; (**p < 0.01**)
 - ✓ **CBR:** 110/224 (%49)
 - ✓ **Hekim:** 79/224 (%35)
- Algoritmanın antibiyotik önerilerinin %90 ve hekim reçetelerinin ise %83 oranında uygun olduğu bildirilmiştir
- KKDS' in;
 - Antibiyotik önerilerinin uygunluk düzeyinin hekimlerle **benzer olduğu,**
 - **Anlamlı derecede daha dar spektrumlu tedavi önerdiği**
 - **Başlangıç grubu antibiyotik kullanım oranını artırdığı** gösterilmiştir

ChatGPT-4 ve Büyük Dil Modelleri ile Karar Destek Sistemleri

- Cochin Üniversite Hastanesinde yürütülen prospektif gözlemsel bir çalışmada:
- Kan kültüründe üreme saptanan 44 hasta, 0. ve 3. günlerde bir enfeksiyon hastalıkları uzmanı ve ChatGPT-4 tarafından bağımsız olarak değerlendirilmiş;
 - ❖ ChatGPT-4'ün önerileri:
 - ✓ 1 (%2) hastada uygun ve optimal
 - ✓ 17 (%39) hastada uygun ancak optimal değil
 - ✓ 7 (%16) hastada zararlı
 - ✓ 17 (%39) hastada enfeksiyon hastalıkları uzmanına danışılması gerektiğini önermiş

ChatGPT-4 ve Büyük Dil Modelleri ile Karar Destek Sistemleri

- ChatGPT-4'ün:
 - Klinik uygulamada doğrudan karar verici olarak değil
 - Tıbbi asistan olarak
 - Özellikle ön yanıt (draft) oluşturma amacıyla
 - Klinik kullanım öncesinde daha fazla geliştirilmesi ve titizlikle test edilmesi gerektiği vurgulanmış

ChatGPT'nin Klinik Karar Süreçlerindeki Riskleri

- Hollanda'daki üçüncü basamak bir hastanede oluşturulan 40 klinik enfeksiyon senaryosuna yönelik ChatGPT tarafından üretilen tanı ve tedavi önerileri;
- Enfeksiyon Hastalıkları uzman görüşleri ile karşılaştırıldı
- Değerlendirme: 1 (kötü) - 5 (mükemmel)
 - ✓ Genel ortalama: 2,8
 - ✓ Pozitif kan kültürü yorumları: 3,3
 - ✓ Karmaşık enfeksiyonlar: → 1,3
(osteomyelit, protez eklem)

ChatGPT'nin Klinik Karar Süreçlerindeki Riskleri

❖ Saptanan Sorunlar;

- Klinik veriyi yeterince kullanmama
- Gereksiz ek tetkik önerileri
- Önceki görüntülemeleri göz ardı etme
- Gerçek olmayan kaynaklara atıf

- ChatGPT, basit klinik durumlarda orta düzey performans gösterirken, karmaşık enfeksiyonlarda belirgin şekilde yetersiz

Yapay Zekâ Uygulamalarında Sınırlayıcı Faktörler

- Yapay zekâ sistemleri klinik kararı destekler; ancak veri kalitesi, etik ve klinik bağlam sınırlılıkları nedeniyle tek başına karar verici olarak kullanılmamalıdır
- Algoritmaların eğitildiği veri setlerinin heterojenliği ve veri kalitesi, bu sistemlerin doğruluğunu ve genellenebilirliğini doğrudan etkilemektedir
- Eksik, hatalı veya standardize edilmemiş elektronik sağlık kayıtları, güvenilirliği olumsuz yönde etkileyebilmektedir
- Farklı sağlık sistemlerinde aynı modelin benzer performans göstermemesi
- Etik ve yasal boyut da göz ardı edilemez;

✓ Hasta mahremiyeti, veri güvenliği ve algoritmik yanlılık

Uluslararası Klinik Karar Destek Sistemlerinin Yerel Sağlık Sistemlerine Entegrasyonunda Karşılaşılan Sınırlılıklar

- Teorik olarak;
 - Klinik karar mantığı evrensel
 - AI algoritmaları taşınabilir
 - Yazılım kurulabilir
- Pratikte neden direkt çalışmaz;
 - En kritik sorun bölgesel direnç patern farklılıkları
 - Aynı algoritma → yanlış antibiyotik önerebilir
- Türkiye verisiyle yeniden eğitilmeli
- Klinik validasyon yapılmalı
- Hekim kontrolünde kullanılmalı
- Sonuç olarak;
 - ✓ Yapay zekâ sistemleri global olarak geliştirilebilir
 - ✓ Ancak klinik karar destek sistemlerinin etkinliği yerel veri ve direnç paternlerine uyumuna bağlıdır

Türkiye' de Mevcut Durum

- Klinik karar destek sistemleri;
 - Çoğunlukla hastane bilgi sistemlerine entegre temel uyarı mekanizmaları şeklinde kullanılmakta
 - Yapay zekâ temelli klinik karar destek sistemi kullanan hastaneler var;
 - Kullanım henüz yaygın ve standardize değil
 - Çoğu pilot, bölüm bazlı veya belirli alanlarla (özellikle radyoloji) sınırlı
 - Antibiyotik seçimi için rutin AI-CDSS kullanan hastane yok (?)
-

Sonuç Olarak

- Yapay zekâ, antimikrobiyal yönetim süreçlerini dönüştürme potansiyeline sahip kritik bir araçtır
 - Yapay zekâ, klinik karar verme sürecinde klinisyenin yerini almaz; onu tamamlayan ve güçlendiren bir eşlikçidir
-



Teşekkürler...