.

Gürültünün İçinde Gizli: Yoğun Bakım Ünitesinde Koroner Arter Hastalığının Saptanmasında Açıklanabilir EKG-Yapay Zeka Modeli

Dr. Hüseyin Emre Cebeci, Prof. Dr. Mevlüt Serdar Kuyumcu

Gürültünün İçinde Gizli: Yoğun Bakım Ünitesinde Koroner Arter Hastalığının Saptanmasında Açıklanabilir EKG-Yapay Zeka Modeli

Orjinal Başlık: Hidden in the noise: explainable ECG-AI for coronary artery disease detection in the ICU

Hazırlayan: Dr. Hüseyin Emre Cebeci, Prof. Dr. Mevlüt Serdar Kuyumcu

Süleyman Demirel Üniversitesi Tıp Fakültesi, Kardiyoloji Anabilim Dalı, Isparta, Türkiye

Yazarlar: D Borg[1], L Butler[1], K Scerri[1]

[1]*Malta Üniversitesi, Msida, Malta*

Erişim Linki: https://esc365.escardio.org/presentation/335787

Arka Plan ve Amaç

Yoğun bakım hastalarında altta yatan koroner hastalığının (KAH/KKH) erken tanınması, hastalık ilerlemeden önce koruyucu girişimlerin hedeflenmesine olanak sağlayabilir. Ancak EKG-yapay zeka araştırmalarının çoğu ayaktan ya da servis ortamında alınmış temiz kayıtlara odaklanmış olup; gürültülü ve çoklu patolojinin bir arada bulunduğu yoğun bakım ortamı büyük ölçüde araştırılmamıştır.

Bu boşluğu doldurmak amacıyla, KAH olasılığını doğrudan yoğun bakım EKG'lerinden tahmin eden açıklanabilir bir derin öğrenme çerçevesi araştırmacılar tarafından geliştirilmiştir. Çalışmanın iki amacı mevcuttur: karmaşık kardiyovasküler arka plan içinden zayıf koroner sinyalleri ortaya çıkarmak ve klinik kullanımı desteklemek üzere dalga formu düzeyinde yorumlanabilirlik sağlamak.

Yöntemler ve Bulgular

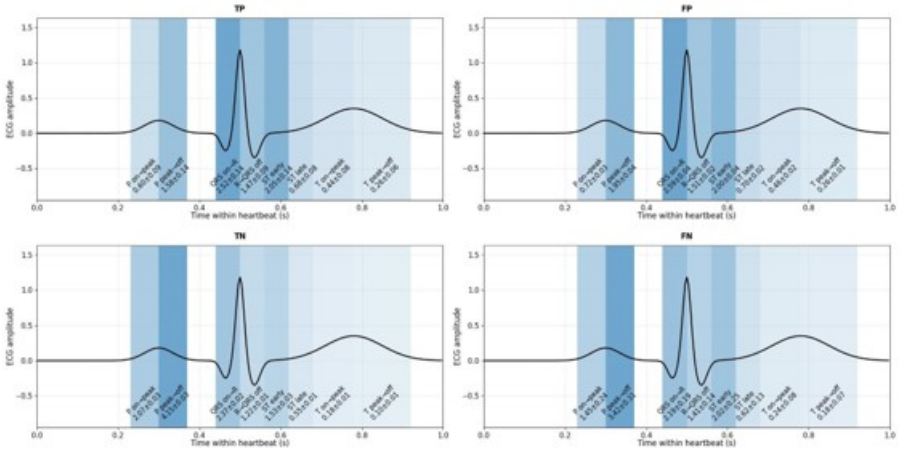
MIMIC-IV klinik verileriyle bağlantılı MIMIC-IV-ECG veri tabanından her hastanın en güncel EKG'si alınarak 161.352 kayıt elde edilmiştir. Bunlardan 4.800 hastada KAH/KKH için ICD kodu mevcuttu (olgular). Geri kalan hastalar kontrol grubunu oluşturdu ve geniş bir yelpazede başka kardiyovasküler patolojilere sahip oldukları izlenmiştir. EKG'ler 250 Hz'e alt örneklenmiş olup, bant geçiren filtreden geçirildi ve her derivasyon ayrı ayrı normalize edilmiştir. Değiştirilmiş bir ResNet50-v2 evrişimli sinir ağı, verinin %80'i üzerinde hasta düzeyinde tabakalandırılmış beş katlı çapraz doğrulama ile eğitilmiştir ve bağımsız %20'lik ayrılmış (holdout) veri setinde değerlendirilmiştir.

Ayrılmış kohortta model, KAH/KKH ayrımında 0,76 eğri altında kalan alan (EAA) değerine ulaştığı izlenmiştir (%95 GA 0,75–0,77). Performans kadınlarda erkeklere göre anlamlı olarak daha yüksek izlenmiş olup bu bulgu, KAH patofizyolojisinde bilinen cinsiyete özgü farklılıklarla uyumludur. Ayırt edicilik, diyabet öyküsü olan ve olmayan hastalarda benzerdi; bu da modelin farklı metabolik profillerde tutarlı (robust) olduğunu desteklemektedir. Gradyan Ağırlıklı Sınıf Aktivasyon Haritalaması (Grad-CAM), otomatik morfoloji işaretlemeleriyle birlikte doğrudan EKG dalga formlarının üzerine yerleştirilmiştir. Gerçek pozitif tahminlerde modelin dikkati, ST segmenti ve repolarizasyon bölgelerinde, yani klinisyenlerin iskemiyle ilişkilendirdiği dalga formu bölgelerinde yoğunlaşmıştır. Tahmin edilen olasılık, toplam kardiyovasküler komorbidite yüküyle birlikte arttığı tespit edilmiştir (Spearman ρ=0,16 genel; olgular içinde ρ=0,29). Olgular arasında model, komorbidite yükü daha fazla olanları öncelikli olarak saptamıştır (medyan komorbidite sayısı: doğru saptananlarda 2,0, yanlış negatiflerde 1,0; p < 0,001). Kontrol grubunda yanlış pozitifler, gerçek negatiflere göre daha fazla komorbidite taşıdığı görülmüştür (p < 0,001). Bu örüntüler birlikte değerlendirildiğinde, EKG-yapay zeka modelinin, KAH/KKH'nin güçlü ancak tek olmayan bir bileşeni olduğu daha geniş bir kardiyovasküler risk imzasını öğrendiği anlaşılmaktadır. Dalga formu düzeyindeki bu açıklanabilirlik, klinisyenlere model akıl yürütmesine ilişkin mekanistik temele dayanan bir bakış sunmaktadır; bu da klinik uygulamada şeffaflığın ön koşuludur.

Tablo 1. Ayrılmış veri setinde alt gruplara göre EAA değerleri (%95 GA) ve DeLong testi p değerleri

Alt gruplar		EAA (%95 GA)	DeLong testi p değeri
Cinsiyet	Kadın	0,788 (0,768–0,809)	< 0,001
	Erkek	0,729 (0,711–0,748)	
Diyabet	Yok	0,745 (0,726–0,764)	0,860
	Var	0,741 (0,713–0,771)	
Atriyal fibrilasyon	Yok	0,735 (0,718–0,753)	0,002
	Var	0,670 (0,633–0,707)	
Kardiyak arrest	Yok	0,762 (0,748–0,775)	0,885
	Var	0,752 (0,623–0,881)	
Kardiyomegali	Yok	0,764 (0,751–0,777)	0,534
	Var	0,681 (0,418–0,943)	
Kalp yetersizliği	Yok	0,721 (0,704–0,740)	0,001
	Var	0,644 (0,602–0,685)	
HFpEF	Yok	0,756 (0,741–0,771)	< 0,001
	Var	0,621 (0,561–0,681)	
HFrEF	Yok	0,745 (0,730–0,759)	0,005
	Var	0,644 (0,576–0,712)	
Hipertansiyon	Yok	0,771 (0,747–0,796)	0,003
	Var	0,720 (0,697–0,744)	
Miyokard enfarktüsü	Yok	0,759 (0,744–0,773)	0,012
	Var	0,614 (0,501–0,726)	

EAA: eğri altında kalan alan; GA: güven aralığı; HFpEF: korunmuş ejeksiyon fraksiyonlu kalp yetersizliği; HFrEF: azalmış ejeksiyon fraksiyonlu kalp yetersizliği.



Şekil 1. Ayrılmış kohortta tahmin sınıfına göre (TP, FP, TN, FN) gruplandırılmış, temsili bir kalp atımı üzerindeki EKG morfoloji bölgelerinde Grad-CAM dikkat yoğunluğu

TP: gerçek pozitif; FP: yanlış pozitif; TN: gerçek negatif; FN: yanlış negatif. Grafik içi etiketler: P on→peak: P başlangıcı→tepe; P peak→off: P tepe→bitiş; QRS on→R: QRS başlangıcı→R; R→QRS off: R→QRS bitişi; ST early/late: erken/geç ST; T on→peak: T başlangıcı→tepe; T peak→off: T tepe→bitiş; ECG amplitude: EKG amplitüdü; Time within heartbeat (s): Atım içindeki zaman (sn).

Sonuçlar ve Değerlendirme

Açıklanabilir EKG-yapay zeka modeli, çoklu patolojili yoğun bakım EKG'lerinden zayıf koroner sinyalleri ortaya çıkarabilir; bu hasta grubunda fırsatçı KAH/KKH saptama açısından klinik olarak değerlidir. Erken tespit; yaşam tarzı değişikliği, farmakolojik risk azaltımı ve daha erken revaskülarizasyon planlaması için fırsatlar yaratmaktadır. Bu çerçeve, yorumlanabilir yapay zekanın dalga formu düzeyinde kardiyovasküler risk değerlendirmesini destekleyebileceğini göstermekte ve yoğun bakımda klinik kullanım için bir temel oluşturmaktadır.