

## Miyokard Enfarktüsü Hastalarının Tespitinde Doğrusal Olmayan Özniteliklerin Performans Analizi

\*Makale Bilgisi / Article Info

Alındı/Received: 29.01.2024

Kabul/Accepted: 07.08.2024

Yayımlandı/Published:02.12.2024

### Performance Analysis of Nonlinear Features in Detection of Myocardial Infarction Patients

Ali NARİN\* , Merve KESER 

Zonguldak Bülent Ecevit Üniversitesi, Mühendislik Fakültesi, Elektrik Elektronik Mühendisliği Bölümü, Zonguldak, Türkiye

© Ayfon Kocatepe Üniversitesi

#### Öz

Kalp rahatsızlıklarından biri olan miyokard enfarktüsü (ME), kalbin bölgelerine kısmen veya tamamen kan akışının kesilmesi sonucunda kalp kaslarına zarar vermesi durumudur. Bu durum kalbe kalıcı hasar vermekte ve hayati risk oluşturmaktadır. ME tespiti için kolay ve ucuz elde edilebilen elektrokardiyogram (EKG) sinyalleri uzmanlar tarafından kullanılmaktadır. Fakat bazı EKG sinyalleri üzerinde ME ile ilişkili anormallikler gözden kaçırılmakta hatta farklı yorumlanabilmektedir. Karşılaşılan problemlere çözüm olması amacıyla yapay zekâ tabanlı karar destek sistemleri ile otomatik ME tespiti üzerinde çalışmalar devam etmektedir. Bu çalışmada 52 sağlıklı ve 148 ME bireye ait 12 derivasyonlu EKG sinyallerinden lead-II derivasyonu analiz edilmiştir. Shannon entropi, Renyi entropi, Dalgacık entropi, Kolmogorov-Sinai entropi ve Bulanık entropi olmak üzere beş farklı yöntem ile elde edilen öznitelikler kullanılarak sağlıklı ve ME tespitindeki başarımlar araştırılmıştır. Her bir entropi ölçümünün gürültülü ve gürültüsüz EKG sinyalleri üzerinde performansları karşılaştırılmıştır. K-en yakın komşu (kNN), Naive Bayes ve topluluk sınıflandırıcı algoritmaları kullanılarak ME tespiti üzerinde performansları analiz edilmiştir. Beş farklı yöntemden elde edilen özniteliklerin sınıflandırılması sonucu en yüksek doğruluk değeri %87,72 ile Bulanık entropi kullanılarak elde edilmiştir. Bu değer, gürültülü sinyallerin üzerinde kNN sınıflandırıcısının kullanılması sonucunda elde edilmiştir. Tüm özniteliklerin birlikte kullanılarak sınıflandırılması ile %90,99 genel doğruluk, %95,58 hassasiyet, %71,55 özgünlük değerleri elde edilmiştir. En yüksek olan bu değere, gürültülü sinyal ve Topluluk sınıflandırıcısı kullanılarak ulaşılmıştır.

**Anahtar Kelimeler:** Miyokard enfarktüsü; Elektrokardiyogram; Öznitelik çıkarma; Topluluk sınıflandırıcı.

#### Abstract

Myocardial infarction (MI), one of the heart diseases, is a condition in which the heart muscle is damaged as a result of partial or complete interruption of blood flow to the regions of the heart. This condition causes permanent damage to the heart and poses a life-threatening risk. Electrocardiogram (ECG) signals, which can be obtained easily and cheaply, are used by experts for the detection of MI. However, MI-related abnormalities on some ECG signals may be overlooked or even interpreted differently. Work continues on automatic MI detection with artificial intelligence-based decision support systems in order to solve the problems encountered. In this study, lead-II derivation from 12-lead ECG signals of 52 normal and 148 MI individuals was analyzed. By using the features obtained by five different methods, namely Shannon entropy, Renyi entropy, Wavelet entropy, Kolmogorov-Sinai entropy and Fuzzy entropy, the performances in detecting healthy and MI were investigated. The performances of each entropy measure on noisy and noiseless ECG signals are compared. Performances on MI detection were analyzed using k-nearest neighbor (kNN), Naive Bayes and ensemble classifier algorithms. As a result of the classification of the features obtained from five different methods, the highest accuracy value belongs to Fuzzy entropy with 87.72%. This value is obtained as a result of using kNN classifier on noisy signals. By classifying all features together, 90.99% overall accuracy, 95.58% sensitivity and 71.55% specificity values were obtained. This highest value was achieved using the noisy signal and ensemble classifier.

**Keywords:** Myocardial Infarction; Electrocardiogram; Feature extraction; Ensemble classifier.

#### 1. Giriş

2019 yılında Dünya Sağlık Örgütü'nün yayınladığı istatistiklere göre kalp hastalıkları, dünya genelindeki ölümlerin %16'sını oluşturarak dünya çapında en büyük ölüm nedeni olarak ifade edilmiştir. Son yıllarda toplam ölüm sayısı 2 milyondan 8,9 milyona çıktığı belirtilmiştir (İnt. Kyn. 1). Kardiyovasküler hastalıklar arasında miyokard enfarktüsü (ME), ölümlerin en büyük yüzdesini meydana getirmektedir (Benjamin et al. 2019). Koroner

kan akışının büyük ölçüde azaldığı veya sağlanmadığı durumlarda miyokard hücrelerin uzun süreli iskemisine neden olduğu ve miyokard hücre hasarına yol açtığı hastalık, miyokard enfarktüsü ya da kalp krizi olarak ifade edilmektedir (Hasbullah et al. 2023, Miranda et al. 2018). Bu nedenle, olası bir ME'nin erken tespiti ve önlenmesi, bireylerin hayati risklerini en aza indirmek için büyük önem taşımaktadır. ME'nin erken uyarı ve teşhisi için önemli bir gösterge olan elektrokardiyogram (EKG)

sinyalleri, hem hızlı sonuç alınması hem de düşük maliyetle uygulanması sayesinde yaygın olarak kullanılmaktadır. EKG sinyalleri üzerinde okumalar, deneyime dayalı tanımlamalar klinisyenler ve EKG uzmanları tarafından gerçekleştirilmektedir. Bilişim teknolojisinin gelişimi ile EKG'nin otomatik analizi yaygınlaştırılmıştır. Bilgisayar destekli analiz sistemlerinin gerçekleşmesi ile sağlık ekiplerinin bireysel teşhis farklılığı en aza indirilmektedir. Bu durum aynı zamanda, uzun süreli iş yüklerinin azaltılmasına da yardımcı olmaktadır.

ME'nin otomatik teşhisi ve lokalizasyonu için literatürde çeşitli çalışmalar gerçekleştirilmiştir. Bu çalışmalar; zaman alanı tabanlı yaklaşımlar (Arif et al. 2012), dalgacık dönüşümü tabanlı yöntemler (Acharya et al. 2016), ST-segment tabanlı yöntemler (Gong et al. 2024), gizli Markov model tabanlı yaklaşımlar (Chang et al. 2012), polinom uydurma tabanlı yöntemler (Liu et al. 2015), doğrusal olmayan ölçümler (Kumar et al. 2017, Han et al. 2019), sinir ağı tabanlı yöntemler (Papaloukas et al. 2002) ve derin öğrenme tabanlı yaklaşımlardır (Chen et al. 2022, Attallah and Ragab 2023, Degerli et al. 2024).

Bu çalışmada doğrusal olmayan ölçümlerin ME tespitindeki performansları araştırılmaktadır. Çalışmada sunulan ME'nin otomatik tespiti Şekil 1'de gösterilmiştir. Öncelikle EKG sinyallerinin gürültüsü ayırık dalgacık dönüşümü ile yok edilmiştir. Ardından Shannon entropi, Renyi entropi, Dalgacık entropi, Kolmogorov-Sinai entropi ve Bulanık entropi olmak üzere beş farklı doğrusal olmayan yöntem ile sinyallerin düzensizlikleri ölçülerek öznitelikler elde edilmiştir. Aynı durum ham (gürültülü) EKG sinyalleri üzerinde de tekrarlanmış ve ME tespiti üzerindeki performansları karşılaştırılmıştır. Böylelikle doğrusal olmayan yöntemlerin gürültülü ve gürültüsüz EKG işaretleri üzerindeki ME tespit başarımları detaylı bir şekilde incelenmiştir.

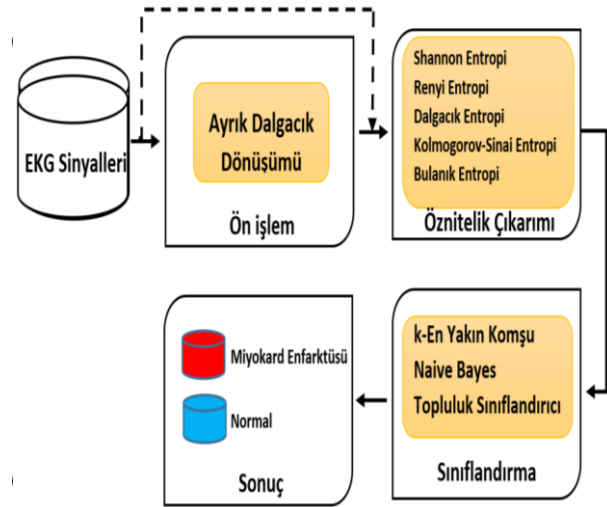
Çalışmanın devamında; veri seti, ayırık dalgacık dönüşümü ile gürültü eliminasyonu, entropi tabanlı öznitelik çıkarma, sınıflandırma algoritmaları, performans ölçütleri, bulgular, son olarak tartışma ve sonuç bölümlerine yer verilmiştir.

## 2. Materyal ve Metot

### 2.1 Veri Seti

Bu çalışmada, PhysioNet.org internet sitesinde halka açık olarak sunulan Physikalisch-Technische Bundesanstalt (PTB) veri tabanı kullanılmıştır (Bousseljot et al. 2004). Veri tabanında 209'u erkek, 81'i kadın olmak üzere 290 bireye ait 549 EKG kaydı bulunmaktadır. Bu kayıtlarda 22 bireye ait kaydın klinik bilgileri yer almamaktadır.

Çalışmanın konusu olan sağlıklı ve ME bireylere ait sırasıyla 52 ve 148 kayıt mevcuttur. Her sinyal 16-bit çözünürlüğünde ve 1000 Hz örnekleme hızında örneklenmiştir.



Şekil 1. Çalışmanın akış şeması.

EKG veri tabanında bulunan sağlıklı ve ME bireylere ait kayıtların tamamı çalışmaya dahil edilmiştir. Her bir kaydın lead-II sinyalleri üzerinde çalışılmıştır. Her bir kayıt 10000 uzunluğunda parçalara ayrılarak 928 sağlıklı ve 3934 ME kayıt elde edilmiştir.


### 2.2 Ayırık Dalgacık Dönüşümü ile Gürültü Eliminasyonu

Ayrık dalgacık dönüşümü (ADD), zaman alanı ve frekans alanı dönüşümü analiz yöntemlerinden biridir. Bu yöntem ile sinyaller yüksek geçiş ve düşük geçiş filtreleme yoluyla farklı frekans bileşenlerine ayrıştırılmaktadır (Subha et al. 2010). Alçak geçiren filtrenin çıktısı sinyalin düşük frekans bilgisini ifade eden yaklaşık katsayıdır. Yüksek geçiren filtrenin çıktısı ise sinyalin yüksek frekans bilgisini ifade eden detay katsayıdır. Bu çalışmada EKG sinyallerindeki gürültünün giderilmesi için 6 seviyeli ayrışım, Daubechies 6 (dB6) dalgacık fonksiyonu kullanılmıştır. Bu dönüşüm sonucunda katsayılar daha düzgün ve sinyal orijinal forma daha yakın olmaktadır. ADD'nin matematiksel ifadesi:

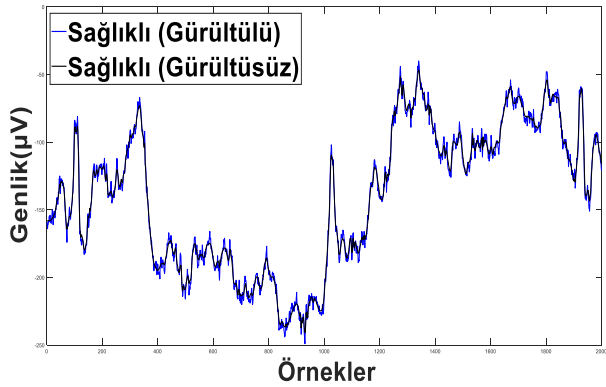
$$DWT(m, n) = 2^{-\frac{m}{2}} \int y(t) \cdot \psi(2^{-m} \cdot t - n) dt \quad (1)$$

şekindedir. Burada m parametresi ile frekans ölçeklendirme, n parametresi ile zamanda kaydırma ifade edilmektedir.

ME ve sağlıklı bireylere ait orijinal sinyal ile gürültüsü giderilmiş sinyallerin görselleri Şekil 2 ve Şekil 3'te gösterilmiştir.



Şekil 2. ME bireye ait gürültülü (kırmızı) ve gürültüsüz (siyah) EKG sinyallerinin örtüşme durumu.



Şekil 3. Sağlıklı bireye ait gürültülü (mavi) ve gürültüsüz (siyah) EKG sinyallerinin örtüşme durumu.

### 2.3 Entropi Tabanlı Öznitelik Çıkarma

Entropi, genel olarak zaman serilerinin karmaşıklığının ölçüsü olarak tanımlanmaktadır. Fizyolojik sinyallerin yapısal bileşenleri hastalık ve yaşlanma ile bozulmaktadır. EKG sinyallerinin karmaşıklığı da bu bozuklukların eşleşmesi ile oluşmaktadır. Entropi yöntemleri kullanılarak hesaplanan sağlıklı bireylerin karmaşıklığı, hastalıklı bireylerden daha yüksektir. Bu karşılaştırmanın nedeni; sağlıklı bireylerdeki tüm yapısal bileşenler ve aralarındaki bağlantı işlevlerinin düzgün çalışmasıdır. Aynı zamanda iletişim için birbirlerine bağlı olması da bu fikri desteklemektedir. Bu bağlılık entropi değerlerini ve karmaşıklığı artırmaktadır.

#### i. Shannon Entropi (Shannon Entropy-ShEn)

Shannon Entropisi, bir bilgi kaynağından alınan bir verinin düzensizliğini veya belirsizliğini gösteren bir belirteçtir (Shannon 1948). Yüksek çıkan entropi değeri, belirsizlik oranının daha fazla olduğu anlamına gelmektedir. Bu çalışmada, Shannon Entropisi EKG sinyalinin spektral karmaşıklığını ölçmek için kullanılmıştır. Shannon Entropisi genel matematiksel formülü şu şekildedir:

$$H(x) = \sum_{i=1}^n P(x_i) \log_2 P(x_i) \quad (2)$$

Burada,  $P(x_i)$   $x_i$  sembolünün olasılığını,  $n$  değeri toplam sembol sayısını göstermektedir.

#### ii. Renyi Entropi (RnEn)

Renyi entropisi (Rényi 1961), Shannon entropinin farklı değişkenler üzerinde genellemesi olarak kabul edilmektedir. Renyi entropinin gücü, Shannon entropi gücünün devamı olarak ifade edilmektedir (Savaré and Giuseppe 2014). Renyi Entropisi genel matematiksel formülü şu şekildedir:

$$H_a(x) = \frac{1}{1-a} \log_2 \sum_{i=1}^n P(x_i)^a \quad (3)$$

Burada,  $P(x_i)$   $x_i$  sembolünün olasılığını,  $n$  değeri toplam sembol sayısını,  $a$  Rényi parametresini ( $a \neq 1$ ), göstermektedir.

#### iii. Dalgacık Entropi (Wavelet Entropy -WaEn)

Dalgacık entropisi, durağan olmayan sinyallerin kısa zamanlı özelliklerini detaylandırma yeteneğine sahiptir. Dalgacık entropisi, genellikle bir sinyalin dalgacık dönüşümünde elde edilen dalgacık katsayıları arasındaki düzensizliği ölçer. Bu entropi, sinyalin zaman ve frekans düzlemlerindeki özelliklerini yakalamak için kullanılır. EKG ve elektroensefalogram gibi fizyolojik sinyalleri detaylandırılması ve önemli klinik bilgilerin elde edilmesi için dalgacık entropi yaygın olarak kullanılmaktadır.

#### iv. Kolmogorov-Sinai Entropi (KsEn)

Kolmogorov-Sinai Entropisi, dinamik sistemlerin karmaşıklığını ifade etmeye yarayan bir matematiksel kavramdır. Bu entropi, bir dinamik sistemdeki kaotik davranışın bir ölçüsü olarak kabul edilir. Bir faz uzayında yörünge üzerinde birbirine daha yakın olan ve zamanla ilişkilendirilmeyen noktaların bulunmasıyla hesaplanmaktadır. Kolmogorov-Sinai Entropisi matematiksel gösterimi şu şekildedir:

$$h_{KS} = \log_{t \rightarrow \infty} \log_{\epsilon \rightarrow 0} \frac{1}{t} H(\epsilon, t) \quad (4)$$

Burada;  $t$  zamanı,  $\epsilon$  sistemdeki hassasiyet parametresini,  $H(\epsilon, t)$  sistemdeki hassasiyet  $\epsilon$  ve zamanda  $t$  boyunca ölçülen entropi değerini ifade etmektedir.

#### v. Bulanık Entropi (Fuzzy Entropy -FzEn)

Bulanık Entropi, bulanık bir küme veya sistemden elde edilen verinin ölçüsü olarak bilinmektedir (Ramer 1990). Bilinmezlik miktarının da bir bilgi ölçüsü olduğu varsayılmaktadır. Karışıklıkları ve belirsizlikleri içermekle

birlikte üyelik fonksiyonu fikri kullanılarak tanımlanmaktadır.

#### 2.4 K-En Yakın Komşu

K-en yakın komşu (kNN) algoritması sınıflandırma ve regresyon için kullanılan parametrik olmayan bir yöntemdir. Bir verinin bulunduğu sınıf, en yakın komşu verilerin sınıfları ile aynı olduğu ifade edilmektedir. Burada k parametresi, algoritmanın adından anlaşılacağı üzere komşu sayısını ifade etmektedir. Belirlenen komşu sayısı ile hesaplama adımlarının sayısı doğru orantılıdır. Bu nedenle hesaplama adımlarının artması eğitim seti üzerindeki gürültüye karşı hassasiyeti azaltmaya neden olacak ve test verilerine olan uyumu artıracaktır. Veri setinde bulunan veriler, geçmiş gözlemlere dayalı eğitim setine ait durumların sonucuna bağlı olarak belirlenir. Geleceğe yönelik tahminler ise eğitim verilerindeki en yakın öğelerin sonuçlarının ortalamasına eşit olacaktır. En yakın gözlemeleme, iki boyutlu çözüm kümesine göre Öklid uzaklığı:

$$d(x_i, y_i) = \sum_{i=1}^n \sqrt{(x_i, y_i)^2} \quad (5)$$

#### 2.5 Naive Bayes

Naive Bayes (NB) sınıflandırıcısı, Bayes teoremine dayanan olasılıksal sınıflandırma algoritmasıdır. Sınıfları belirli olan mevcut örnek verileri kullanarak yeni bir verinin var olan sınıflardan birine ait olma olasılığını hesaplayan bir yaklaşımdır. NB sınıflandırıcısında özellikler birbirinden bağımsız ve aynı dereceye sahip kabul edilir. Ayrıca bu özellikler birbirleri hakkında bilgi içermez. NB sınıflandırıcısı formülü:

$$P(C_1, C_2, \dots, C_n | E_i) = \prod_{k=1}^n P(C_k | E_i) \quad (6)$$

Burada; C değeri giriş örnek sayısı, n özellik sayısı,  $P(C_k | E_i)$  C'nin koşullu olasılık yoğunluk fonksiyonu,  $E_i$  i. olası çıkış durumudur.

#### 2.6 Topluluk Sınıflandırıcısı

Topluluk sınıflandırıcısı (ENS) farklı öğrenme modellerini birlikte kullanarak yeni örneklerin tahminlerini birleştiren ayrı ayrı eğitilmiş bir dizi sınıflandırıcıdan oluşmaktadır. Böylelikle biriktirme rastgele veri kümelerinden oluşur. Sınıflandırmada modeller paralel olarak eğitilir, oylama ile birleştirilir. Yapılan bir çalışmada bireysel sınıflandırma sonucunda farklı hatalar üretilebileceğinden bahsedilmiştir. Bundan dolayı sınıflandırıcıların birleştirilmesi, bir sınıflandırıcı tarafından üretilen hatanın

başka bir sınıflandırıcı tarafından telafi edilebilmesi açısından bireysel sınıflandırıcıya göre daha yüksek doğruluk oranı sağlamaktadır.

#### 2.7 Performans Ölçütleri

Yapay zekâ algoritmalarının performanslarının tespit edilmesi için Şekil 4'te verilen hata matrisinden yararlanılmıştır. Hata matrisi, gerçek değerler ile algoritma tespitinin sunulduğu bir tablodur.

		Tahmin	
		0	1
Gerçek	0	TN	FP
	1	FN	TP

Şekil 4. Hata matris gösterimi.

Burada True Positive-TP, gerçek değeri pozitif olan ve algoritma tarafından da pozitif olarak tespit edilen değerleri ifade etmektedir. False Negative-FN, gerçek değeri negatif olan ancak algoritma tarafından pozitif olarak tahmin edilen değerleri ifade etmektedir. False Positive-FP, Gerçek değeri pozitif olan ancak algoritma tarafından negatif olarak tespit edilen değerleri ifade etmektedir. True Negative-TN ise gerçek değeri negatif olan ve algoritma tarafından da negatif olarak tespit edilen değerleri ifade etmektedir. Bu değerleri kullanarak doğruluk (Accuracy-Acc), kesinlik (Precision-Pre), duyarlılık (Recall-Rec) performans değerleri hesaplanmıştır. Doğruluk değeri sadece doğru tahmin edilen örneklerin toplam örnek sayısına oranını gösterir. Kesinlik değeri, doğru tahmin edilen pozitif örneklerin toplam tespit edilen pozitif örneklere oranını gösterir. Duyarlılık değeri, doğru tahmin edilen pozitif örneklerin gerçek sınıftaki tüm örneklere oranını ifade eder. Tüm elde edilen metriklerin matematiksel gösterimi şu şekildedir (Narin 2020):

$$Acc = (TP+TN)/(TP+TN+FP+FN) \quad (7)$$

$$Rec = (TP)/(TP+FN) \quad (8)$$

$$Spe = (TN)/(TN+FP) \quad (9)$$

### 3. Bulgular

Bu çalışmada, PTB veri tabanında bulunan 52 sağlıklı ve 148 ME bireyin EKG kayıtları (lead-II) kullanılmıştır. Tüm

işlemler 2.5 Ghz i5-8265U işlemcili 8 GB RAM özelliklerine sahip bilgisayar üzerinden gerçekleştirilmiştir.


Ön işlem adımında ayırık dalgacık dönüşümü ile EKG işaretlerinin gürültüleri giderilmiştir. Shannon entropi, Renyi entropi, Dalgacık entropi, Kolmogorov-Sinai entropi ve Bulanık entropi yöntemleri kullanılarak beş farklı öznitelik elde edilmiştir. Her bir özneliğin orijinal (gürültülü) ve gürültüsüz EKG sinyalleri üzerinde sağlıklı ve ME birey tespitinin başarımları; kNN, NB ve ENS sınıflandırıcıları kullanılarak tespit edilmiştir. 10-katlı çapraz doğrulama (Cross validation-CV) yöntemi kullanılmış olup tüm yöntemlere ait sonuçlar Çizelge 1’de detaylı bir şekilde sunulmuştur. Üç farklı algoritmanın her bir entropi kullanımıyla ortalama eğitim süresi sırasıyla kNN algoritması için 35sn, NB algoritması için 31sn ve ENS algoritması için 83sn olarak tespit edilmiştir.

Doğrusal olmayan öznitelikler içerisinde en yüksek performans, gürültülü sinyaller üzerinden alınan Bulanık entropi ölçüm sonuçlarından elde edilmiştir. Bu sonucun kNN sınıflandırıcı ile %87,72 olduğu Çizelge 1’de açıkça görülmektedir. Çizelge 1’de bazı sonuçların oluşmadığı görülmektedir. Bu durumda; sınıflandırıcı, sonucu sadece bir sınıfa ait olarak tespit ettiği görülmektedir. Bu nedenle sağlıklı bir sonuç alınamamaktadır.

**Çizelge 1.** Her bir entropinin sınıflandırıcı başarımları.

Entropi	Model	Orijinal (Gürültülü) Sinyal (%)			Gürültüsüz Sinyal (%)		
		Acc	Rec	Spe	Acc	Rec	Spe
ShEn	kNN	79,43	96,14	8,62	-	-	-
	NB	81,04	99,95	0,86	-	-	-
	ENS	81,02	99,95	0,75	-	-	-
RnEn	kNN	78,73	96,24	4,53	79,04	96,49	5,06
	NB	80,58	99,47	0,54	-	-	-
	ENS	80,93	99,92	0,43	80,83	99,87	0,11
WaEn	kNN	-	-	-	78,30	96,34	1,83
	NB	-	-	-	80,56	99,47	0,43
	ENS	-	-	-	80,97	99,92	0,65
KsEn	kNN	86,88	94,56	54,31	69,74	81,49	19,94
	NB	86,90	94,56	54,42	-	-	-
	ENS	86,84	94,53	54,20	69,99	81,88	19,61
FzEn	kNN	87,72	93,70	62,39	81,84	96,95	17,78
	NB	87,68	93,26	64,01	81,72	99,06	8,19
	ENS	87,33	93,24	62,28	81,74	99,34	7,11

Beş farklı doğrusal olmayan yöntem birlikte kullanıldığında en yüksek sonuç; %90,99 genel doğruluk, %95,58 hassasiyet, %71,55 özgünlük değerleridir. Bu değerler gürültülü sinyaller üzerinde Topluluk sınıflandırıcısı kullanılarak elde edilmiştir. Elde edilen sonuca ait hata matrisi ise Şekil 5’te verilmiştir. Burada, entropi ölçümlerinin hepsinin kullanımıyla ortalama eğitim süresi doğal olarak artış göstermiştir. Eğitim süreleri sırasıyla kNN algoritması için 48sn, NB algoritması için 46sn ve ENS algoritması için 121sn olarak kaydedilmiştir.



**Şekil 5.** Doğrusal olmayan özniteliklerin Topluluk sınıflandırıcı hata matrisi değerleri.

#### 4. Sonuçlar ve Tartışma

Bu çalışmada, karşılaştırılabilirlik ve güvenilirlik açısından halka açık internet sitesinden ME hastalarına ait veriler ile sağlıklı kişilere ait EKG verileri kullanılmıştır. Beş farklı doğrusal olmayan Entropi ölçümlerinin ME hastalarını ayırt etmesindeki performansları araştırılmıştır.

Literatürde ME hastalarının tespitine yönelik çalışmalar bulunmaktadır. Bunlardan bazıları Çizelge 2’de verilmiştir.

**Çizelge 2.** PTB veri tabanı ile gerçekleştirilmiş literatür çalışmaları.

Literatür	Yöntem	Başarımlar (%)
(Sharma et al. 2015)	ADD, 12 adet öznitelik (t-test) kNN	Acc: 98,80; Rec: 99,45; Spe: 96,27
(Sharma et al. 2018)	ADD- 10 adet öznitelik SVM	Acc: 98,84; Rec: 99,35; Spe: 98,29
(Padhy and Samarendra 2017)	Tekil değer ayrıştırması ve dalgacık enerjisi-35 adet öznitelik-SVM	Acc: 95,30; Rec: 94,60; Spe: 96,00
(Sopic 2018)	Zaman/Frekans Alanı 72 adet öznitelik Rastgele Orman Sınıflandırıcı	Acc: 82,36; Rec: 87,95; Spe: 78,82
(Diker 2018)	Morfolojik, zaman alanı ve ADD 9 adet öznitelik-SVM	Acc: 87,80; Rec: 86,97; Spe: 88,67
<b>Bu çalışma</b>	<b>5 adet öznitelik Topluluk Sınıflandırıcısı</b>	<b>Acc: 90,99; Rec: 95,58; Spe: 71,55</b>

Yapılan çalışmalara bakıldığında, farklı yöntem ve farklı sınıflandırıcılar ile genel doğruluk oranları %82-%98 arasında değişmektedir. Bu çalışmalarda sıklıkla zaman alanı ölçümleri ve frekans alanı ölçümleri kullanılmıştır. Bazı çalışmalarda doğrusal olmayan ölçümler de kullanılmıştır (Sharma et al. 2018). Bu çalışmalarda (Padhy and Samarendra 2017, Sopic 2018) öznitelik sayılarının fazlaca elde edildiği görülmektedir. Bazı çalışmalarda (Sharma et al. 2015) öznitelik sayısını azaltmak için öznitelik seçimi yapılmış ve öznitelik sayıları düşürülüp sonuçlar verilmiştir.

Bu çalışmada, hem gürültülü hem gürültüsüz EKG sinyalleri üzerinden beş farklı doğrusal olmayan ölçüm sonuçlarının sağlıklı ve ME tespiti üzerindeki başarımlarını ayrı ayrı ifade edilmiştir. Böylece gürültü faktörünün de her bir Entropi üzerindeki başarımlarına etkileri analiz edilmiştir. Buna ek olarak tüm özniteliklerin performansları da elde edilmiştir. Ayrıca çalışmamız, literatürde yapılmış diğer çalışmaların çok fazla öznitelikle gerçekleştirdikleri yoğun işlemler sonucunda elde edilen doğruluk oranı ile karşılaştırıldığında öznitelik sayımızın az olması ile işlem süresinin kısa olması, herhangi bir veri seçimi yapılmadan verilerin tamamının çalışmada kullanılması ve yüksek doğruluk oranına sahip olması gibi avantajlara sahiptir.

Gelecek çalışmalarda, sınıflar arası ayrımı daha yüksek başarımla yapılabilmesi için lineer olmayan yaklaşımlar arttırılacaktır. Öznitelik sayısının çok fazla olması durumunda sezgisel algoritmalar ile öznitelik seçimi yapılması düşünülmektedir. Böylece daha az öznitelik ile daha yüksek performans elde edileceği öngörülmektedir. Bunlara ek olarak farklı merkezlerden ME ve Sağlıklı veriler araştırılarak daha fazla veri ile çalışma gerçekleştirilecektir. Bu sayede çalışma sonuçlarının daha kararlı olacağı beklenmektedir.

#### Etik Standartlar Bildirgesi

Yazarlar tüm etik standartlara uyduklarını beyan ederler.

#### Yazarlık Katkı Beyanı

Yazar 1: Kaynaklar, Araştırma, Fikir Sahibi, Deney tasarımı, Görselleştirme, Yazma –orijinal taslak, Düzenleme

Yazar 2: Kaynaklar, Araştırma, Deneyleme, Yazma – orijinal taslak, Doğrulama

#### Çıkar Çatışması Beyanı

Yazarların bu makalenin içeriğiyle ilgili olarak beyan edecekleri hiçbir çıkar çatışması yoktur.

#### Verilerin Kullanılabilirliği

Bu çalışma sırasında oluşturulan veya analiz edilen tüm veriler, yayınlanan bu makaleye dahil edilmiştir.

## 5. Kaynaklar

- Acharya, U. R., Fujita, H., Sudarshan, V. K., Oh, S. L., Adam, M., Koh, J. E. and San Tan, R., 2016. Automated detection and localization of myocardial infarction using electrocardiogram: a comparative study of different leads. *Knowledge-Based Systems*, **99**, 146-156.  
<https://doi.org/10.1016/j.knsys.2016.01.040>
- Arif, M., Malagore, I. A., and Afsar, F. A. 2012. Detection and localization of myocardial infarction using k-nearest neighbor classifier. *Journal of Medical Systems*, **36**, 279-289.  
<https://doi.org/10.1007/s10916-010-9474-3>
- Attallah, O., and Ragab, D. A. 2023. Auto-MyIn: Automatic diagnosis of myocardial infarction via multiple GLCMs, CNNs, and SVMs. *Biomedical Signal Processing and Control*, **80**, 104273.  
<https://doi.org/10.1016/j.bspc.2022.104273>
- Benjamin, E. J., Muntner, P., Alonso, A., Bittencourt, M. S., Callaway, C. W., Carson, A. P., and American Heart Association Council on Epidemiology and Prevention Statistics Committee and Stroke Statistics Subcommittee., 2019. Heart disease and stroke statistics—2019 update: a report from the American Heart Association. *Circulation*, **139**(10), e56-e528.  
<https://doi.org/10.1161/CIR.0000000000000659>
- Bousseljot, R., Kreiseler, D. and Schnabel, A., 2004. The PTB diagnostic ECG database. [physionet.org](http://physionet.org).
- Chang, P. C., Lin, J. J., Hsieh, J. C. and Weng, J. 2012. Myocardial infarction classification with multi-lead ECG using hidden Markov models and Gaussian mixture models. *Applied Soft Computing*, **12**(10), 3165-3175.  
<https://doi.org/10.1016/j.asoc.2012.06.004>
- Chen, Z., Lalande, A., Salomon, M., Decourselle, T., Pommier, T., Qayyum, A. and Couturier, R. 2022. Automatic deep learning-based myocardial infarction segmentation from delayed enhancement MRI. *Computerized Medical Imaging and Graphics*, **95**, 102014.  
<https://doi.org/10.1016/j.compmedimag.2021.102014>
- Degerli, A., Kiranyaz, S., Hamid, T., Mazhar, R., & Gabbouj, M. (2024). Early myocardial infarction detection over multi-view echocardiography. *Biomedical Signal Processing and Control*, **87**, 105448.  
<https://doi.org/10.1016/j.bspc.2023.105448>
- Diker, A., Cömert, Z., Avcı, E. and Velappan, S., 2018. Intelligent system based on Genetic Algorithm and support vector machine for detection of myocardial infarction from ECG signals. In *2018 26th Signal processing and communications applications conference (SIU)* (pp. 1-4). IEEE.  
<https://doi.org/10.1109/SIU.2018.8404299>

- Gong, M., Liang, D., Xu, D., Jin, Y., Wang, G. and Shan, P., 2024. Analyzing predictors of in-hospital mortality in patients with acute ST-segment elevation myocardial infarction using an evolved machine learning approach. *Computers in Biology and Medicine*, 107950. <https://doi.org/10.1016/j.combiomed.2024.107950>
- Han, C., and Shi, L., 2019. Automated interpretable detection of myocardial infarction fusing energy entropy and morphological features. *Computer Methods and Programs in Biomedicine*, **175**, 9-23. <https://doi.org/10.1016/j.cmpb.2019.03.012>
- Hasbullah, S., Mohd Zahid, M. S., and Mandala, S., 2023. Detection of Myocardial Infarction Using Hybrid Models of Convolutional Neural Network and Recurrent Neural Network. *BioMedInformatics*, **3(2)**, 478-492. <https://doi.org/10.3390/biomedinformatics3020033>
- Kumar, M., Pachori, R. B., & Acharya, U. R., 2017. Automated diagnosis of myocardial infarction ECG signals using sample entropy in flexible analytic wavelet transform framework. *Entropy*, **19(9)**, 488. <https://doi.org/10.3390/e19090488>
- Liu, B., Liu, J., Wang, G., Huang, K., Li, F., Zheng, Y. and Zhou, F., 2015. A novel electrocardiogram parameterization algorithm and its application in myocardial infarction detection. *Computers in Biology and Medicine*, **61**, 178-184. <https://doi.org/10.1016/j.combiomed.2014.08.010>
- Miranda, D. F., Lobo, A. S., Walsh, B., Sandoval, Y., and Smith, S. W., 2018. New insights into the use of the 12-lead electrocardiogram for diagnosing acute myocardial infarction in the emergency department. *Canadian Journal of Cardiology*, **34(2)**, 132-145. <https://doi.org/10.1016/j.cjca.2017.11.011>
- Narin, A., 2022. Detection of focal and non-focal epileptic seizure using continuous wavelet transform-based scalogram images and pre-trained deep neural networks. *IRBM*, **43(1)**, 22-31. <https://doi.org/10.1016/j.irbm.2020.11.002>
- Padhy, S., and Dandapat, S., 2017. Third-order tensor based analysis of multilead ECG for classification of myocardial infarction. *Biomedical Signal Processing and Control*, **31**, 71-78. <https://doi.org/10.1016/j.bspc.2016.07.007>
- Papaloukas, C., Fotiadis, D. I., Likas, A., & Michalis, L. K., 2002. An ischemia detection method based on artificial neural networks. *Artificial Intelligence in Medicine*, **24(2)**, 167-178. [https://doi.org/10.1016/S0933-3657\(01\)00100-2](https://doi.org/10.1016/S0933-3657(01)00100-2)
- Ramer, A., 1990. Concepts of fuzzy information measures on continuous domains. *International Journal Of General System*, **17(3)**, 241-248. <https://doi.org/10.1080/03081079008935109>
- Rényi, A., 1961. On measures of entropy and information. In *Proceedings of the Fourth Berkeley Symposium on Mathematical Statistics and Probability, Volume 1: Contributions to the Theory of Statistics*. *University of California Press*, **4**, 547-562.
- Shannon, C. E. 1948. A mathematical theory of communication. *The Bell System Technical Journal*, **27(3)**, 379-423. <https://doi.org/10.1002/j.15387305.1948.tb0138.x>
- Sharma, L. N., Tripathy, R. K. and Dandapat, S., 2015. Multiscale energy and eigenspace approach to detection and localization of myocardial infarction. *IEEE Transactions on Biomedical Engineering*, **62(7)**, 1827-1837. <https://doi.org/10.1109/TBME.2015.2405134>
- Subha, D. P., Joseph, P. K., Acharya U, R. And Lim, C. M., 2010. EEG signal analysis: a survey. *Journal of Medical Systems*, **34**, 195-212. <https://doi.org/10.1007/s10916-008-9231-z>
- Savaré, G., & Toscani, G., 2014. The concavity of Rényi entropy power. *IEEE Transactions on Information Theory*, **60(5)**, 2687-2693. <https://doi.org/10.1109/TIT.2014.2309341>
- Sharma, L. D. and Sunkaria, R. K., 2018. Inferior myocardial infarction detection using stationary wavelet transform and machine learning approach. *Signal, Image and Video Processing*, **12(2)**, 199-206. <https://doi.org/10.1007/s11760-017-1146-z>
- Sopic, D., Aminifar, A., Aminifar, A., and Atienza, D., 2018. Real-time event-driven classification technique for early detection and prevention of myocardial infarction on wearable systems. *IEEE Transactions on Biomedical Circuits and Systems*, **12(5)**, 982-992. <https://doi.org/10.1109/TBCAS.2018.2848477>

#### İnternet Kaynakları

- 1-<https://www.who.int/data/gho/data/themes/mortality-and-global-health-estimates> (27.12 2023)