

Kalp Hızı Değişkenliği ve Elektrodermal Aktivite Verilerinden Anestezi Durumlarının Makine Öğrenmesi Tabanlı Sınıflandırılması

Nesrin ALTUNTAŞ^{1,a}, Buse Nur DEMİR^{1,b}, Demet YEŞİLBAŞ^{2,c}, Ayşegül GÜVEN^{1,d}

¹Erciyes Üniversitesi, Mühendislik Fakültesi, Biyomedikal Mühendisliği Bölümü, Kayseri, Türkiye

²Erciyes Üniversitesi, Fen Bilimleri Enstitüsü, Biyomedikal Mühendisliği Anabilim Dalı, Kayseri, Türkiye

^aORCID: 0009-0007-4240-9516; ^bORCID: 0009-0002-3993-513X; ^cORCID: 0000-0001-9070-4439;

^dORCID: 0000-0001-8517-3530

Makale Bilgileri

Geliş : 04.09.2025

Kabul : 01.07.2026

DOI: 10.21605/cukurovaumfd.1777100

Sorumlu Yazar

Demet YEŞİLBAŞ

demetyesilbass@gmail.com

Anahtar Kelimeler

Nosisepsiyon

Anestezi

Elektrodermal aktivite

Kalp hızı değişkenliği

Makine öğrenmesi

Atf şekli: ALTUNTAŞ, N., DEMİR, B.N., YEŞİLBAŞ, D., GÜVEN, A., (2026). Kalp Hızı Değişkenliği ve Elektrodermal Aktivite Verilerinden Anestezi Durumlarının Makine Öğrenmesi Tabanlı Sınıflandırılması. Çukurova Üniversitesi, Mühendislik Fakültesi Dergisi, 41(3), 533-544.

ÖZ

Anestezi esnasında nosisepsiyonun doğru şekilde değerlendirilmesi, ameliyat sırasında ilaçların yetersiz veya aşırı dozda uygulanmasının önüne geçmesi açısından kritiktir. Çalışmada yaşları 28–77 arasında değişen 101 hastaya ait anestezi sürecinde kaydedilmiş Elektrodermal Aktivite (EDA) ile Kalp Hızı Değişkenliği (HRV) sinyallerini içeren açık erişimli bir veri seti kullanılmıştır. Bu verilerden ortalama, çarpıklık, basıklık ve Shannon entropisi gibi lineer ve non-lineer özellikler çıkarılmıştır. Çıkarılan özellikler makine öğrenmesi yöntemleri kullanılarak sınıflandırılmıştır. En yüksek performans karar ağaçları yöntemi ile elde edilmiş olup %90,3 doğruluk ve %90 F1-skor değerine ulaşılmıştır. Çıkarılan özelliklerden, EDA özelliklerinin nosisepsiyona daha doğrudan yanıt verdiği, HRV'nin ise özellikle non-lineer parametreler aracılığıyla otonom sinir sistemi değişikliklerini yansıttığı görülmüştür. Sonuçlar, multimodal EDA-HRV temelli makine öğrenmesi modellerinin nosisepsiyon varlığının objektif olarak sınıflandırılmasında klinik karar destek açısından potansiyel taşıdığını ortaya koymaktadır.

Machine Learning-Based Classification of Anesthesia States from Heart Rate Variability and Electrodermal Activity Data

Article Info

Received : 04.09.2025

Accepted : 01.07.2026

DOI: 10.21605/cukurovaumfd.1777100

Corresponding Author

Demet YEŞİLBAŞ

demetyesilbass@gmail.com

Keywords

Nociception

Anesthesia

Electrodermal activity

Heart rate variability

Machine learning

How to cite: ALTUNTAŞ, N., DEMİR, B.N., YEŞİLBAŞ, D., GÜVEN, A., (2026). Machine Learning-Based Classification of Anesthesia States from Heart Rate Variability and Electrodermal Activity Data. Çukurova University, Journal of the Faculty of Engineering, 41(3), 533-544.

ABSTRACT

Accurate evaluation of nociception stages during anesthesia is critical to preventing under- or overdosing of drugs during surgery. In this study, an open-access dataset comprising Electrodermal Activity (EDA) and Heart Rate Variability (HRV) signals recorded during the anesthesia process from 101 patients aged between 28 and 77 years was utilized. Linear and non-linear features, including mean, skewness, kurtosis, and Shannon entropy, were extracted from these signals. The extracted features were subsequently classified using machine learning methods. The highest performance was achieved with the decision tree algorithm, reaching an accuracy of 90.3% and an F1-score of 90%. Among the extracted features, EDA features were found to respond more directly to nociception, while HRV stood out due to its nonlinear parameters. The results demonstrate that multimodal EDA-HRV-based machine learning models provide a promising objective framework for classifying nociception states and may support future clinical decision-support applications.

1. GİRİŞ

Genel anestezi, cerrahi işlemler sırasında hastada bilinç kaybı, analjezi, amnezi ve kas gevşemesi (hareketsizlik) oluşturan, farmakolojik olarak indüklenen geçici bir durumdur ve modern cerrahinin temel bileşenlerinden biridir [1]. İntraoperatif farkındalık, genel anestezi altındaki bir hastanın cerrahi işlem sırasında bilincinin kısmen veya tamamen açık olması ve bu süreçte çevresindeki olayları, konuşmaları, dokunma ya da ağrı hissini algılaması durumudur. Her yıl dünya genelinde milyonlarca hasta ameliyat sırasında istemsiz intraoperatif farkındalık yaşamaktadır ve bu durum hastaların yaklaşık %1'ini etkilemektedir [2]. İntraoperatif farkındalık, hastanın fizyolojisi ve psikolojisi üzerinde ciddi etkilere neden olabilir. Bunun aksine, aşırı derin anestezi ise, ameliyat sonrası iyileşme süresinin uzaması, karaciğer hasarı, bulantı, kusma, deliryum, inme ve hatta ölüm gibi çeşitli fizyolojik yaralanmalara yol açabilir. Dolayısıyla, anestezi sürecini doğru şekilde izlemek ve anestezi uzmanını ilaçları makul dozlarda uygulama konusunda yönlendirmek, klinik cerrahilerin güvenli bir şekilde gerçekleştirilmesi için kritik öneme sahiptir [3]. Günümüzde klinik cerrahilerde, Richmond Agitation–Sedation Scale (RASS) kriterleri doğrultusunda anestezi derinliği genellikle anestezi uzmanları tarafından belirli aralıklarla manuel olarak değerlendirilmektedir. Bu süreç, cerrahi işlem sırasında karmaşık bir uyarı–tepki prosedürünün dikkatle uygulanmasını gerektirir [4]. Anestezi derinliği kalp atış hızı, solunum paternleri, kan basıncı, kandaki ilaç konsantrasyonu gibi fizyolojik göstergeler üzerinden ölçülür. Fizyolojik sinyallerin analizi, anestezi derinliğinin doğru şekilde belirlenebilmesi için anestezi uzmanlarının ileri düzeyde klinik deneyim ve alan bilgisine sahip olmasını gerektirir [5]. Ancak, öznel değerlendirmeleri destekleyebilecek ve fizyolojik sinyallere dayalı olarak anestezi/nosisepsiyon durumlarının daha objektif değerlendirilmesine katkı sağlayabilecek makine öğrenmesi tabanlı karar destek yaklaşımlarının geliştirilmesi önemli bir gerekliliktir. Elektrodermal aktivite (EDA), ter bezlerindeki ter birikiminin, bu bezleri aktive eden sempatik sinir sistemi uyarısıyla ilişkili olarak ölçülmesidir. Ter bezlerinde sıvı biriktikçe cildin elektriksel iletkenliği artar. Ter bezleri tamamen dolup ter cilt yüzeyine ulaştığında, bu durum galvanik cilt tepkisi (GSR) veya EDA sinyalinde “darbe” şeklinde kaydedilebilen kısa süreli bir iletkenlik artışına yol açar [6]. Anestezik ajanların ter bezlerinde kuruma etkisi yaratarak ter bezi aktivitesini azalttığı bilinmektedir [7]. Ayrıca, EDA’nın cerrahi işlemlerde anestezi indüksiyonu sırasında tutarlı ve güvenilir bir non-invaziv biyobelirteç olarak kullanılabileceği gösterilmiştir [8]. Kalp hızı değişkenliğinin (heart rate variability-HRV) ölçümü, otonomik aktiviteye erişilebilen bir pencere sunar. HRV’nin tipik spektral dağılımı, iki ana tepe içerir: hem sempatik hem de parasempatik aktiviteden etkilenen düşük frekans (low frequency-LF) bölgesi ile parasempatik aktiviteyle ilişkili ve solunum frekansına odaklanmış yüksek frekans (high frequency-HF) bölgesi. HRV, anestezik ilaç uygulamasını takiben meydana gelen otonomik modülasyonlar hakkında doğrudan bilgi sağlar [9]. HRV ve EDA, invaziv olmayan, düşük maliyetli ve basit bir yöntem olup otonomik aktivite hakkında hasta başı monitörü üzerinden bilgi sağlayarak anestezik ilaçların meydana getirdiği fizyolojik değişiklikler hakkında bilgi sağlar [10]. Bu iki metodun birlikte kullanımı fizyolojik durumun değerlendirmesinde daha güvenilir ve kararlı bir ölçüm sağladığı gösterilmiştir [9].

Makine öğrenmesi (MÖ), bağımsız ve bağımlı değişkenler arasındaki karmaşık ilişkileri ortaya çıkarmak amacıyla desen tanıma ve hesaplamalı öğrenme teorilerini kullanan yapay zekâ alanıdır. MÖ, karmaşık verilerin işlenmesinde etkileyici sonuçlar göstermiştir [11]. Anestezi alanında MÖ metotlarının kullanımı diğer alanlarla kıyaslandığında görece yenidir [12]. MÖ metotlarının anestezi aşamalarının izlenmesinde kullanan çalışma sayısı oldukça sınırlı olup bu çalışmaların odaklandıkları veriler yakın infra-red spektroskopisi [3], elektroensefalografi, elektrokardiyografi (EKG) verileridir [13]. Öte yandan, anestezinin izlenilmesinde doğrudan bilgi sağlayan metotlar olan EDA ve HRV’nin sınıflandırıldığı çalışma sayısı oldukça yetersizdir [14]. Niu ve arkadaşları [15], HRV ve klinik veriler kullanarak yaptıkları sınıflandırmada ameliyat sonrası dönemde gelecekte klinik sonuçları öngörmeye hem uygulanabilir hem de etkili olduğunu savundular. Fauchereau ve arkadaşları [16] EKG ile anesteziyi MÖ metotları ile izledikleri çalışmada, HRV’nin anestezi sırasında bilinç durumlarını ayırt etmede önemli bir özellik olduğu bulundu. Analjezi Nosisepsiyon İndeksi’nin algılayamadığı birçok nosiseptif yanıtın multimodal HRV-EDA tabanlı modeller ile başarılı bir şekilde saptanabilmesi, bu yöntemin klinik uygulamalardaki güçlü potansiyelini açıkça göstermektedir [14]. Bu çalışmada multimodal HRV-EDA yöntemi ile elde edilmiş verileri MÖ metotları kullanarak anestezi aşamalarının sınıflandırılmasını öneriyoruz. HRV ve EDA verilerinde karmaşık ve istatistiksel özellikler çıkartıp bu özellikler üzerinden model eğitimi gerçekleştirdik.


Bu çalışmada, anestezi sürecinde nosisepsiyonun objektif olarak değerlendirilmesi amacıyla EDA ve HRV sinyallerini birlikte ele alan multimodal bir yaklaşım önerilmektedir. Açık erişimli bir veri seti kullanılarak elde edilen bu sinyallerden hem lineer hem de non-lineer özellikler çıkarılmış ve bu özellikler farklı makine

öğrenmesi yöntemleri ile sınıflandırılmıştır. Çalışmanın temel katkısı, EDA ve HRV sinyallerinin birlikte değerlendirilmesi ile nosisepsiyonun daha etkin şekilde izlenebileceğini göstermesidir. Literatürde HRV ve EDA sinyallerinin ayrı ayrı ya da birlikte kullanıldığı çalışmalar bulunmakla birlikte, bu çalışmada söz konusu iki modaliteden elde edilen istatistiksel ve kompleksite temelli özelliklerin sistematik biçimde karşılaştırılması ve farklı makine öğrenmesi yöntemleriyle performans analizinin yapılması hedeflenmiştir. Bu yönüyle çalışma, multimodal EDA-HRV sinyallerinden elde edilen lineer ve non-lineer özelliklerin nosisepsiyon durumlarını ayırt etmedeki potansiyelini ortaya koymakta ve makine öğrenmesi tabanlı sınıflandırma yaklaşımlarının gelecekte geliştirilebilecek klinik karar destek sistemleri için uygulanabilir bir ön değerlendirme çerçevesi sunabileceğini göstermektedir.

2. YÖNTEM

2.1. Veriler

Çalışmada physionet.org web sayfasının sunduğu hazır HRV ve EDA sinyalleri kullanılmıştır [14]. HRV verileri 3 kanallı elektrokardiyogram sinyallerinden elde edilmiştir. Sol elin iki parmağından EDA sinyalleri Thought Technology Neurofeedback Sistemi kullanılarak elde edilmiştir. Anestezik Nosiseptif İndeks (ANİ) verisi nosisepsiyon durumunu değerlendirmek amacıyla alınmıştır. Veri toplanması, anestezinin indüksiyonundan önce başlatılıp ekstübasyondan sonraya kadar devam ettirilmiştir. Verilerin örnekleme frekansı 256 Hz'dir [14]. Veriler 28 ila 77 yaşları arasında ve 53'ü kadın ve 48'i erkek olmak üzere toplam 101 kişiye ait olup bu kişilerin yaş dağılımı Şekil 1-A'da yer almaktadır. Veri setini içeren ameliyatlardan toplam süresi 18.582 dakika olup, sürelerinin dağılımı ise Şekil 1-B'de yer almaktadır.




Şekil 1. Çalışmada kullanılan verilerin yaş cinsiyet ve ameliyat süresi dağılımı. Şekil 1-A'da mavi renk erkek hastaları gösterirken açık turuncu renk kadın hastaları ifade etmektedir. Her iki cinsiyet ise kahverengidir. Şekil 1-B'de çalışmadaki ameliyatlardan süresini göstermektedir [14]

Çalışmada kullanılan veri setine ait temel özellikler Çizelge 1'de özetlenmiştir. Elde edilen HRV ve EDA sinyalleri için, nosiseptif uyaran durumları (noc_stim = 1) ve nosiseptif olmayan durumlar (noc_stim = 0) belirlenerek sınıflandırılmada kullanılmak üzere uygun sınıf etiketleri hazırlanmıştır.

Çizelge 1. Çalışmada kullanılan veri setine ilişkin bilgiler

Özellik	Açıklama
Veri kaynağı	PhysioNet açık erişimli veri tabanı
Katılımcı sayısı	101 hasta
Yaş aralığı	28–77
Cinsiyet dağılımı	53 kadın, 47 erkek
Toplam kayıt süresi	18.582 dakika
Kayıt süreci	Anestezi indüksiyonu öncesinden ekstübasyon sonrasına kadar
Örnekleme frekansı	256 Hz

Bu çalışmada, EDA ve HRV sinyallerinden çıkarılan istatistiksel ve kompleksite temelli özellikler kullanılarak nosisepsiyon varlığı ve yokluğu MÖ yöntemleriyle sınıflandırılmıştır. Önerilen yaklaşım; veri ön işleme, özellik çıkarımı, model eğitimi ve çapraz doğrulama ile performans değerlendirme adımlarından oluşan bir sınıflandırma iş akışı Şekil 2’de yer almaktadır.



Şekil 2. Çalışmada uygulanan adımların şeması

2.2. Ön İşleme

Veriler için literatürde uygun görülen filtreler ile ön işleme adımları uygulanmıştır. EKG verilerinde HRV analizi için öncelikle R tepelerinin doğru şekilde çıkarılması hedeflenmiştir. Bunun için yüksek artefaktlı bölümler 20 Hz düşük geçiren filtre ve eşikleme yöntemleriyle sıfırlanmış, ardından Pan-Tompkins algoritması uygulanmıştır. Artefakt nedeniyle oluşan boşluklar PPG’den elde edilen tepelerle ve gecikme düzeltilmesi yapılarak doldurulmuş, tek atımlık yanlışlıklar ise nokta-işlem tabanlı algoritmalarla düzeltilmiştir. Son olarak, düzensiz bölgeler farklı sinyal versiyonları üzerinden optimize edilerek R tepeleri kesinleştirilmiş ve bireysel HRV modelleri hiperparametre taramalarıyla en uygun şekilde uyarlanmıştır.

EDA verilerinde elektrokoter kaynaklı artefaktlar temizlendikten sonra sinyal tonik ve fajik bileşenlere ayrılmış, fajik bileşenden darbeler çıkarılmıştır. Daha sonra darbe zamanlaması ve genlik yapısını modellemek için dört dinamik model uygulanmıştır: geçmişe bağlı ters Gauss (History-Dependent Inverse Gaussian model-HDIG), geçmişe bağlı lognormal (History-Dependent Lognormal model-HDL), uyarlanabilir pencere uzunluğuna sahip HDIG ve darbe genlikleri için HDIG modeli. Bu modeller, EDA darbelerinin hız ve genlik özelliklerini zaman içinde sürekli olarak tahmin edecek şekilde hiperparametre taramalarıyla optimize edilmiştir.

Çalışmada kullanılan veriler toplamda 15 kanallı olup her kanalın ifade ettiği özellikler şunlardır: kalp atım hızının ortalama değeri (the mean value of the heart rate – MuHR), kalp atım hızı varyasyonunun standart sapması (the standard deviation of the heart rate – SigmaHR), HRV spektrumunun toplam gücü (the total power of HRV spectrum – TotalPower), yüksek frekans bandı gücü (high-frequency band power – HF), normalize edilmiş düşük frekans değeri (low-frequency normalized unit – LFnu), normalize edilmiş yüksek frekans değeri (high-frequency normalized unit – HFnu), VLF dışarıda bırakılarak hesaplanan normalize edilmiş LF değeri (low-frequency normalized unit without VLF – LFnu_noVLF), LF/HF oranı (the ratio of low to high frequency – LF/HF), tonik deri iletkenliği (tonic electrodermal activity – TonicEDA), EDA tepki genliklerinin ortalama değeri (the mean amplitude of skin conductance responses – MuAmp), EDA tepki genliklerinin standart sapması (the standard deviation of skin conductance responses – SigmaAmp), log-normal dağılıma göre uyarlanmış tepki büyüklüklerinin ortalama değeri (the mean of phasic responses fitted to log-normal distribution – MuPR_LogN), log-normal dağılıma göre uyarlanmış tepki büyüklüklerinin standart sapması (the standard deviation of phasic responses fitted to log-normal distribution – SigmaPR_LogN), inverse Gaussian dağılıma göre uyarlanmış tepki büyüklüklerinin ortalama değeri (the mean of phasic responses fitted to inverse Gaussian distribution – MuPR_IG) ve inverse Gaussian dağılıma göre uyarlanmış tepki büyüklüklerinin standart sapması (the standard deviation of phasic responses fitted to inverse Gaussian distribution – SigmaPR_IG).

Bu özelliklerden HRV özellikleri aşağıda açıklanmıştır:

MuHR (Mean Heart Rate): Kalp atış hızı sinyalinin ortalama değeridir. Genel kardiyak aktiviteyi yansıtır ve stres, anksiyete veya anestezi düzeyi gibi durumlarda temel bir karşılaştırma ölçütü sağlar.

SigmaHR (Standard Deviation of Heart Rate): Kalp hızı sinyalindeki değişkenliğin standart sapmasıdır. Otonom sinir sistemi (OSS) aktivitesine duyarlıdır ve kalp atımındaki kısa süreli dalgalanmaları gösterir.

Total Power: HRV spektrumunun toplam gücüdür (VLF + LF + HF). Otonom sinir sistemi aktivitesinin genel bir ölçüsüdür; düşük total power genellikle stres, yorgunluk veya patolojik durumlarla ilişkilidir.

HF (High Frequency Power): Parasempatik (vagal) aktiviteyi temsil eder. Solunum kaynaklı kalp hızı değişkenliğiyle (RSA) güçlü bir şekilde ilişkilidir.

LFnu (Low Frequency Power, normalized): LF bileşeninin normalize edilmiş değeri olup hem sempatik hem de parasempatik etkileri içerir. Stres yanıtlarının ve barorefleks duyarlılığının bir göstergesi olabilir.

HFnu (High Frequency Power, normalized): HF bileşeninin normalize edilmiş değeri. Saf vagal tonusun daha net değerlendirilmesine olanak sağlar.

LFnu_noVLF: Çok düşük frekans (VLF) bileşeni çıkarıldıktan sonra hesaplanan LF gücünün normalize edilmiş değeri. VLF'nin belirsiz etkilerini elimine ederek LF değerlendirmesini iyileştirir.

LF/HF Ratio: LF ve HF güçleri arasındaki orandır. Sempatik-parasempatik dengeyi temsil eden klasik bir göstergedir; yüksek değerler genellikle artmış sempatik aktivite veya azalmış parasempatik aktivite ile ilişkilidir.

EDA özellikleri ve açıklamaları aşağıdaki gibidir:

TonicEDA: Elektrokutanöz aktivitenin tonik, yani bazal seviyesini gösterir. Genel arousal (uyanıklık/uyarılmışlık) durumunun göstergesidir.

MuAmp (Mean Amplitude): Tüm EDA olaylarının ortalama amplitüdü. Daha güçlü fizyolojik tepkiler (örneğin stres veya ağrıya karşı) genellikle daha yüksek amplitüdlerle ifade edilir.

SigmaAmp (Standard Deviation of Amplitude): EDA amplitüdlerinin değişkenliğini gösterir; bireysel farklılıkları ve olayların heterojenliğini ortaya koyar.

MuPR_LogN (Mean Periodic Event Rate, Log-normal): Log-normal dağılıma göre modellenmiş periyodik EDA olaylarının ortalama sıklığıdır. Otonom aktivitenin düzenliliği hakkında bilgi verir.

SigmaPR_LogN (Standard Deviation of Periodic Event Rate, Log-normal): Log-normal dağılıma göre periyodik EDA olay frekansının değişkenliğini gösterir. OSS'nin stabilite/dengesizlik durumlarını yansıtır.

MuPR_IG (Mean Periodic Event Rate, Inverse Gaussian): İvers Gaussian dağılımına göre modellenmiş periyodik EDA olaylarının ortalamasıdır. Farklı dağılım varsayımlarına göre OSS yanıtlarını değerlendirmeye imkân verir.

SigmaPR_IG (Standard Deviation of Periodic Event Rate, Inverse Gaussian): İvers Gaussian dağılımına göre EDA olaylarının frekans değişkenliğini gösterir; OSS'nin olay bazlı aktivitesindeki çeşitliliği ortaya koyar.

2.3. Özellik Çıkarma

Çalışmada EDA-HRV endekslerinden başarısı veren lineer ve non-lineer özellikler çıkarılmıştır. Çalışmada ortalama, Shannon entropisi, basıklık ve çarpıklık özellikleri çıkarılmış ve bu özellikler tek bir matris üzerinde birleştirilmiştir. Çalışmada kullanılan özellikler aşağıda açıklanmıştır [17].

2.3.1. Ortalama

Ortalama, bir veri setinin merkezi eğilim ölçüsüdür ve bir veri kümesindeki tüm değerlerin toplamının, toplam veri sayısına bölünmesiyle hesaplanır. Genelde "aritmetik ortalama" olarak bilinir ve en yaygın kullanılan istatistiksel ölçütlerden biridir. N verinin uzunluğu, $x = \{x_1, x_2, \dots, x_N\}$ zaman serisi için ortalama hesaplaması Eşitlik (1)'de yer almaktadır.

$$\mu = \frac{1}{N} \sum_{i=1}^N x_i \quad (1)$$

2.3.2. Çarpıklık

Çarpıklık, bir veri setinin simetrik olup olmadığını veya dağılımının bir tarafa eğimli olup olmadığını ölçen bir istatistiksel ölçüttür. Veri dağılımının merkezi eğiliminden sapmalarını incelemek için kullanılır. Ortalama μ ve standart sapma σ olduğu durumda çarpıklık hesaplaması Eşitlik (2)'de yer almaktadır.

$$\text{Çarpıklık} = \frac{\frac{1}{N} \sum_{i=1}^N (x_i - \mu)^3}{\sigma^3} \quad (2)$$

2.3.3. Basıklık

Basıklık, bir veri setindeki dağılımın uç değerlerinin (kuyruklarının) yoğunluğunu ve dağılımın tepe noktasının yüksekliğini ölçen bir istatistiksel ölçüttür. Verinin uç değerlerine ne kadar odaklandığını anlamaya yardımcı olur. Ortalamanın μ ve standart sapmanın σ olduğu durumda basıklık hesaplaması Eşitlik (3)'de yer almaktadır.

$$\text{basıklık} = \frac{\frac{1}{N} \sum_{i=1}^N (x_i - \mu)^4}{\sigma^4} \quad (3)$$

2.3.4. Entropi

Entropi, bilgi teorisi ve istatistikte kullanılan bir ölçüt olup, bir sistemdeki belirsizliği veya düzensizliği ifade eder. Claude Shannon tarafından geliştirilen bu kavram, veri setindeki bilgi miktarını ve rastgeleliği analiz etmek için yaygın olarak kullanılır. Veri M farklı olasılık değerine sahipse her bir olasılık değeri p_i olmak üzere Shannon entropi H Eşitlik (4)'te yer almaktadır.

$$H = - \sum_{i=1}^M p_i \log(p_i) \quad (4)$$

2.4. Sınıflandırma

Bu bölümde, EDA-HRV verilerinden elde edilen özelliklerin nosisepsiyon varlığı ve yokluğunu ayırt etmedeki sınıflandırma performansı değerlendirilmiştir. Çalışmadaki veriler Matlab (R2023a-deneme sürümü) kullanarak sınıflandırılmıştır. Model, 60 öznitelik kullanılarak eğitildi ve 5 katlı çapraz doğrulama ile test edilmiştir. Çalışmada literatürde fizyolojik verilerin sınıflandırılmasında sıklıkla kullanılan algoritmalar ile sınıflandırılmış olup bu metotlar aşağıda açıklanmıştır [17,18].

2.4.1. Karar Ağaçları

Karar ağaçları (KA), veri setini yinelemeli bölerek sınıf etiketini tahmin eden temel sınıflandırıcılardandır. Sınıflandırma, karar ağaçlarını temel öğrenici olarak kullanan bagging tabanlı bir topluluk (bagged trees) ile gerçekleştirilmiştir. Topluluktaki her bir ağaç, eğitim setinin değiştirilmiş bir veri örneği olan bootstrap

örnekleriyle oluşturulur. İlk olarak, orijinal veri seti V 'den N örnek alınarak, her biri N 'nin uzunluğunda olan B farklı bootstrap veri seti oluşturulur, bu işlem Eşitlik (5)'te yer almaktadır.

$$V_b = \{x_1, x_2, \dots, x_{N'}\}, \quad b = 1, 2, 3, \dots, B \quad (5)$$

Her bootstrap örneği için bir karar ağacı büyütülür. Karar ağacındaki her düğüm için tüm özellikler adaydır. En iyi bölme noktası, seçilen safsızlık ölçütüne göre (bu çalışmada Gini indeksi) belirlenir ve düğüm iki alt düğüme ayrılır. Bu işlem, minimum düğüm boyutu koşuluna ulaşıncaya kadar tekrarlanır. Bir düğüm D 'deki sınıf dağılımı p_k , bu durumda Gini safsızlığı Eşitlik (6)'da yer almaktadır.

$$I_{\text{Gini}} = \sum_{k=1}^K p_k(1 - p_k) \quad (6)$$

Öncelikle ebeveyn düğümdeki Gini değeri hesaplanır. Ardından, S düğüm, S_1 ve S_2 iki alt düğüme ayrıldığında, her bir alt düğüm için Gini değeri bulunur ve bu değerler, alt düğümdeki örnek sayısının toplam örnek sayısına oranı ile ağırlıklandırılarak ortalaması alınır. Bilgi kazancı ebeveyn düğümün Gini değeri ile bu ağırlıklı ortalama arasındaki fark olarak tanımlanır. N ebeveyn düğümdeki örnek sayısı ve N_1 , N_2 ise alt düğümdeki örnek sayılarını göstermek üzere bilgi kazancı Eşitlik (7)'de yer almaktadır.

$$\Delta I = I_{\text{Gini}}(S) - \left(\frac{N_1}{N} I_{\text{Gini}}(S_1) + \frac{N_2}{N} I_{\text{Gini}}(S_2) \right) \quad (7)$$

Her bir karar ağacı, yaprak düğümde çoğunluk sınıfa göre tahmin üretmektedir. Çalışmada kullanılan bagging yönteminde ise, bootstrap örneklerinden elde edilen tüm ağaçların tahminleri bir araya getirilmekte ve nihai sınıflandırma, çoğunluk oyu prensibine göre belirlenmektedir. Böylece kararlı ve genellenebilir sonuçlar elde edilmektedir [19].

2.4.2. Yapay Sinir Ağları

İnsan beynindeki sinir hücrelerini taklit ederek, karmaşık verilerdeki ilişkileri öğrenme ve örüntü tanıma yeteneği ile sınıflandırma, tahmin gibi görevleri gerçekleştiren çok katmanlı yapay öğrenme modelleridir. Sinir ağı; bir giriş katmanı, gizli katman(lar) ve bir çıkış katmanından oluşur ve her katmanda bir dizi nöron bulunur. Nöronlar, belirli kurallara sahip olacak şekilde katmanlara paralel biçimde bağlanmıştır. Giriş katmanı, $x = [x_1, x_2, x_3, \dots, x_n]$ şeklinde tanımlanan özellik matrisini alır. Eğer K 'inci katmanda olduğumuz ve her gizli katmanda n nöron bulunduğunu varsayılırsa, girdilerin w ağırlık değeriyle çarpılması ve b bias teriminin eklenmesiyle elde edilen ağırlıklı toplam hesaplanır; bu Eşitlik (8)'de verilmiştir.

$$z_i^K = \sum_{j=1}^{n^{K-1}} w_{ij}^K a_j^{K-1} + b_i^K \quad (8)$$

Burada a aktivasyon fonksiyonu ve çalışmada ReLU fonksiyonu kullanıldı. Çıkış katmanında sigmoid fonksiyonu ile sınıf etiketinin hangi sınıfa ait olduğu p olasılık değeri elde edilir [18].

2.4.3. Destek Vektör Makineleri

Sınıflandırma yapılırken en yakın değerler arasındaki mesafeyi ifade eden marjini maksimize eden hiper düzlemi tanımlama prensibine dayalı bir MÖ algoritmasıdır. Veri kümesi (x_i, y_i) , olarak tanımlandığında ve $i = 1, 2, \dots, l$, $x_i \in R^n$ ve $y_i \in \{+1, -1\}$ olmak üzere. Burda l veri sayısını ve n özellik sayısını göstermektedir. Çok boyutlu uzayda verileri ayırabilecek pek çok hiper düzlem tanımlanabilir. SVM'in temel prensibi, bu belirsizliği ortadan kaldırarak marjini maksimize eden ve böylece sınıfları en iyi şekilde ayıran optimal hiper düzlemi seçmektir. Bu çalışmada farklı kernel fonksiyonları test edilmiş; ancak sınıflandırma performansı açısından en iyi sonuç lineer çekirdek (kernel) fonksiyonu ile elde edilmiştir. Bu nedenle analizlerde lineer kernel tercih edilmiştir. İki destek düzlemi arasında ortada kalan düzlem, iki sınıfı ayıran karar sınırını oluşturur ve şu şekilde ifade edilir: $W_t X + b = 0$. Burada W ağırlık vektörünü, b ise

bias terimini göstermektedir. Destek düzlemleri ise şu şekilde tanımlanır: $W_t X + b = 1$ and by $W_t X + b = -1$. İki destek düzlemi arasındaki mesafe marjın olarak adlandırılır. SVM'in optimal hiper düzlemi belirlemesi için marjini maksimize eden bir W bulması gerekir. Maksimum marjın şu şekilde tanımlanır: $maxMargin = \frac{2}{\|w\|} = \frac{2}{w^t w}$ Dolayısıyla minimize edilmesi gereken değer $\frac{w^t w}{2}$ olur [20]. Bu optimizasyon problemi, iki sınıflı durum için Lagrange Eşitlikleri kullanılarak çözülür. Bu işlem Eşitlik (9)'da yer almaktadır.

$$\mathcal{L} = \frac{1}{2} \sum_{i=1}^l \alpha_i - \frac{1}{2} \sum_{i=1}^l \sum_{j=1}^l \alpha_i \alpha_j y_i y_j x_i^T x_j \quad (9)$$

Sonuçta, iki sınıfı ayıran sınıflandırma fonksiyonu Eşitlik (10)'da yer aldığı üzere ifade edilir.

$$f(x) = \text{sign} \left(\sum_{i=1}^l y_i \alpha_i x_i^T x \right) \quad (10)$$

2.4.4. K-En Yakın Komşular Algoritması

K-en yakın komşular algoritması, yeni gelen bir verinin hangi sınıfa ait olduğunu belirlemek için, veriye en yakın k adet komşuya bakarak karar veren basit ve sezgisel bir yöntemdir. Bu algorithma önce yeni örnek ile eğitim verisindeki tüm örnekler arasındaki mesafe hesaplanır, ardından en yakın k komşu seçilir ve bu komşuların çoğunluk oyu alınarak sınıf belirlenir. Bu çalışmada komşular arasındaki mesafe, kosinüs mesafesi kullanılarak hesaplanmıştır. Veri kümesi (x_i, y_i) , olarak tanımlandığında ve $i = 1, 2, \dots, l$, $x_i \in R^n$ ve $y_i \in \{+1, -1\}$ olmak üzere. Burda l veri sayısını ve özellik sayısını göstermektedir. Özellik sayısı n olsun ve noktaların i . özelliği sırasıyla x_i ve y_i ile gösterilsin. Kosinüs mesafesi Eşitlik (11)'de yer almaktadır.

$$d(i, j) = 1 - \frac{\sum_{i=1}^n x_i y_i}{\sqrt{\sum_{i=1}^n x_i^2} \cdot \sqrt{\sum_{i=1}^n y_i^2}} \quad (11)$$

K-en yakın komşu algoritması algoritmasında uygun komşu sayısının seçimi önemli bir parametredir; çünkü bu seçim, aykırı değerlere karşı hassasiyet ile önemli örüntülerin gözden kaçırılması riski arasında denge sağlar. Bu çalışmada komşu sayısı 10 olarak belirlenmiştir. Daha sonra, komşuların sınıf etiketleri çoğunluk oylaması yöntemiyle değerlendirilmiş ve en fazla oyu alan sınıf, test örneği için tahmin edilen sınıf olarak atanmıştır [19].

2.5. İstatistiksel Analiz

İstatistiksel analizler Matlab (R2023a-deneme sürümü) ortamında gerçekleştirilmiştir. Nosisepsiyon varlığı ve yokluğu arasındaki farklar Paired Samples t-test kullanılarak değerlendirilmiştir. Tüm istatistiksel testlerde anlamlılık düzeyi $p < 0.05$ olarak kabul edilmiştir.

3. ARAŞTIRMA BULGULARI

Çalışmada her 15 kanallı veriden çıkarılan özellikler neticesinde 60 özellik kullanılarak sınıflandırılmıştır. Çalışmada kullanılan sınıflandırıcılar karar ağaçları, lineer regresyon, destek vektör makineleri, yapay sinir ağları olup bu sınıflandırıcıların performansını ölçmek için doğruluk, hassasiyet, duyarlılık, özgüllük, F1-skor, AUC değerlerine bakılmış olup sonuçlar Çizelge 2'de yer almaktadır. Sonuçlar sınıflandırmanın dengeli şekilde gerçekleştiğini göstermektedir. Sınıflandırıcılardan en yüksek sınıflandırma başarısı olup karar ağaçları ile elde edildi. Karar ağaçlarının doğruluk, hassasiyet, duyarlılık, özgüllük, F1-skor, AUC % değerleri sırasıyla 90,3, 93,1, 87,1, 93,5, 90, 95 idi. Karar ağaçlarından sonra ikinci en iyi sınıflandırma doğruluğu %88,2 ile yapay sinir ağları oldu. Destek vektör makineleri ve k-en yakın komşular sınıflandırıcılarının doğruluk değerleri ise sırasıyla %87,1 ve %86,6 idi.

Literatürde, ağrı ve noisepsiyonun değerlendirilmesine yönelik olarak EDA ve HRV gibi fizyolojik sinyallerin hem ayrı ayrı hem de birlikte kullanıldığı çeşitli çalışmalar bulunmaktadır. Bunlardan Zhan ve arkadaşları [21] sadece HRV özellikleri kullanarak yüksek frekans gücü, düşük frekans gücü, yüksek-düşük frekans gücü oranı ve örnek entropisi dahil olmak üzere dört özellik çıkarılarak yaptıkları çalışmada derin sinir ağları ile %90,1 sınıflandırma doğruluğu elde ettiler. Posada ve arkadaşları [22] EDA'nın spektral analiz, zaman alanı ayrıştırma ve diferansiyel özelliklere dayalı ağrı uyarım yoğunluğu üç seviyede sınıflandırıldı ve neticede uygulanan uyarının yoğunluğuyla ilişkili olduğuna dair fizyolojik kanıtlar sağladılar. Bu çalışmalar HRV ve EDA modalitelerinin noisepsiyon süreçlerini sınıflandırmadaki potansiyelini gösterse de hibrit EDA ve HRV sinyallerinin birlikte kullanıldığı çalışmalar da literatürde yer almaktadır. Örneğin Subramanian arkadaşları [14] multi modal EDA-HRV metodunun supervised ve unsupervised metotları kullanarak anestezi süreçlerini takip etmedeki potansiyelini araştırdılar. Ayrıca bu multimodal yöntemin Analjezi Noisepsiyon İndeksi'nden daha güvenilir sonuçlar ortaya koyduğunu savundular. Bununla birlikte, mevcut çalışmaların büyük bir kısmı sınırlı sayıda özellik veya tek bir model yaklaşımı üzerine odaklanmaktadır. Bu çalışmada ise, multimodal EDA-HRV sinyallerinden elde edilen lineer ve non-lineer özellikler birlikte ve sistematik bir şekilde değerlendirilmiş ve farklı makine öğrenmesi algoritmaları kullanılarak karşılaştırılmıştır. Bu yönüyle çalışma, fizyolojik özelliklerin ayırt edici gücünün daha kapsamlı biçimde analiz edilmesine olanak tanımakta ve noisepsiyonun belirlenmesine yönelik potansiyel biyobelirteçlerin ortaya konmasına katkı sağlamaktadır.

Çizelge 2. Sınıflandırma performans karşılaştırması

Sınıflandırıcı	Doğruluk	Hassasiyet	Duyarlılık	Özgüllük	F1-skor	AUC
Karar ağaçları	90,3	93,1	87,1	93,5	90	95
Sinir ağları	88,2	88,2	88,2	88,2	88,2	93
Destek vektör makineleri	87,1	85,6	89,2	84,9	87,4	95
K- en yakın komşular	86,6	84,7	89,2	83,9	86,9	95

Çalışmada, noisepsiyon varlığında gözlenen fizyolojik değişikliklerin lineer ve non-lineer özellikler üzerinden incelenmesi amacıyla, noisepsiyon varlığı ve yokluğu durumları Paired Samples t-test ile istatistiksel olarak karşılaştırılmıştır. İki durumda anlamlı şekilde farklı bulunan özellikler ($p < 0,05$) Çizelge 3'te sunulmuştur.

Çizelge 3. Çalışmada çıkarılan özelliklerin noisepsitif durumda ve noisepsitif olmayan durumdaki istatistiksel karşılaştırılması

Özellik	Parametre	Noisepsiyon var	Noisepsiyon yok	p değeri	t-istatistiği
Entropi	MuHR	-176,96 ± 267,68	-1041,40 ± 1132,57	0,0000	7,642
	SigmaHR	-313,63 ± 604,80	-1649,07 ± 2464,67	0,0000	5,122
	TotalPower	-1131,88 ± 3083,56	-2540,83 ± 5458,69	0,0436	2,046
	HF	-1022,52 ± 2674,95	-2383,65 ± 4882,70	0,0275	2,241
	LFnu	-175,63 ± 192,97	-309,38 ± 334,47	0,0005	3,597
	LFnu_noVLF	-100,36 ± 72,50	-274,69 ± 312,89	0,0000	5,082
	LF/HF	-1066,97 ± 2198,25	-2325,07 ± 3054,48	0,0028	3,073
	TonicEDA	-396,12 ± 1083,16	-2693,19 ± 2362,26	0,0000	8,478
	MuPR_LogN	-140,40 ± 242,84	-287,80 ± 601,69	0,0222	2,327
	MuPR_IG	-177,80 ± 460,34	-492,21 ± 1337,00	0,0358	2,131
Ortalama	MuHR	-0,26 ± 0,36	0,74 ± 0,84	0,0000	-11,434
	SigmaHR	0,03 ± 0,37	0,48 ± 0,60	0,0000	-5,537
	TotalPower	0,06 ± 0,29	0,26 ± 0,44	0,0008	-3,475
	HF	0,06 ± 0,33	0,21 ± 0,44	0,0192	-2,383
	LFnu	-0,03 ± 0,26	0,10 ± 0,38	0,0071	-2,753
	HFnu	0,02 ± 0,41	-0,26 ± 0,46	0,0000	4,323
	LFnu_noVLF	-0,01 ± 0,31	0,30 ± 0,48	0,0000	-4,956
	LF/HF	0,01 ± 0,21	0,32 ± 0,43	0,0000	-5,674
	TonicEDA	-0,06 ± 0,56	-0,59 ± 1,51	0,0008	3,479
	MuAmp	0,22 ± 0,46	0,37 ± 0,43	0,0204	-2,360
	SigmaPR_LogN	0,03 ± 0,40	0,17 ± 0,44	0,0177	-2,414

Çizelge 3. devamı

Özellik	Parametre	Nosisepsiyon var	Nosisepsiyon yok	p değeri	t-istatistiği
Çarpıklık	SigmaHR	2,72 ± 1,38	1,95 ± 1,18	0,0000	4,333
	TotalPower	5,43 ± 3,18	4,36 ± 2,59	0,0111	2,590
	HFnu	0,94 ± 0,94	1,24 ± 0,76	0,0057	-2,833
	LFnu_noVLF	0,30 ± 0,83	-0,08 ± 0,62	0,0000	4,626
	SigmaPR_LogN	1,34 ± 1,12	0,77 ± 1,49	0,0023	3,138
Basıklık	MuHR	9,02 ± 8,67	5,85 ± 6,18	0,0034	3,010
	SigmaHR	12,66 ± 9,79	7,79 ± 8,29	0,0004	3,649
	TotalPower	45,98 ± 52,05	31,52 ± 36,95	0,0305	2,198
	LFnu_noVLF	2,93 ± 1,72	2,41 ± 1,09	0,0122	2,556
	TonicEDA	9,34 ± 6,73	3,58 ± 2,66	0,0000	7,349
	MuAmp	6,24 ± 7,57	4,13 ± 2,55	0,0120	2,564
	SigmaAmp	8,20 ± 13,78	4,93 ± 7,02	0,0475	2,009
	MuPR_LogN	4,76 ± 3,62	5,90 ± 4,22	0,0487	-1,998

Bu çalışmada, nosisepsiyon varlığı ile yokluğu arasında HRV ve EDA kaynaklı toplam 34 parametrede anlamlı farklılık bulunmuştur. Nosisepsiyon varlığında HRV parametreleri incelendiğinde, LF/HF oranı ($0,01 \pm 0,21$ vs $0,32 \pm 0,43$, $p < 0,001$) ve LFnu ($-0,03 \pm 0,26$ vs $0,10 \pm 0,38$, $p = 0,007$) anlamlı olarak daha düşük, HFnu ise daha yüksek bulunmuştur ($0,02 \pm 0,41$ vs $-0,26 \pm 0,46$, $p < 0,001$). Ayrıca HRV'den türetilen entropi değerleri (ör. MuHR: $-176,96 \pm 267,68$ vs $-1041,40 \pm 1132,57$, $p < 0,001$) ile çarpıklık ve basıklık ölçütleri nosisepsiyon sırasında anlamlı artış göstermiştir.

EDA parametreleri değerlendirildiğinde, TonicEDA ortalama değeri ($-0,06 \pm 0,56$ vs $-0,59 \pm 1,51$, $p < 0,001$) nosisepsiyon varlığında daha yüksek bulunmuş; ayrıca entropi ($-396,12 \pm 1083,16$ vs $-2693,19 \pm 2362,26$, $p < 0,001$) ve basıklık ($9,34 \pm 6,73$ vs $3,58 \pm 2,66$, $p < 0,001$) değerleri de anlamlı şekilde artmıştır.

Bu sonuçlar hem HRV hem de EDA'dan elde edilen lineer ve non-lineer parametrelerin nosisepsiyon varlığında anlamlı farklılıklar gösterdiğini ortaya koymuştur. HRV açısından incelendiğinde, entropi ve yüksek moment değerlerinin (çarpıklık, basıklık) artması, kalp atım dinamiklerinde daha karmaşık ve değişken bir yapının ortaya çıktığını işaret etmektedir. Bu durum, ağrıya verilen otonomik yanıtın daha kaotik bir desenle karakterize olduğunu düşündürmektedir [23]. Öte yandan, ortalama LF/HF oranı ve LFnu değerlerinin nosisepsiyon sırasında daha düşük olması, klasik olarak beklenen sempatik baskınlıkla tam örtüşmemektedir. Bu bulgu, intraoperatif koşullarda kullanılan anestezi ve analjezik ajanların sempatik yanıtı baskılayıcı etkisi ile açıklanabilir. Buna rağmen, HRV'den türetilen kompleksite göstergelerinin nosisepsiyona duyarlı olması, bu parametrelerin farmakolojik etkilerden bağımsız olarak otonomik sistemdeki değişiklikleri yansıtmaya potansiyelini ortaya koymaktadır [24].

EDA parametreleri incelendiğinde ise nosisepsiyon sırasında ortalama değerlerin yanı sıra entropi ve basıklık ölçütlerinde de anlamlı artış gözlenmiştir. Bu bulgular, nosisepsiyonun cilt iletkenliği sinyalinde daha yüksek amplitüdü ve ani yanıtlarla karakterize olduğunu ve sempatik aktivitenin güçlendiğini ortaya koymaktadır. Literatürde de EDA'nın perioperatif stres ve nosisepsiyonun güvenilir bir belirteci olduğu, özellikle tonik ve fazik yanıtların bu süreçte duyarlı göstergeler sunduğu vurgulanmaktadır [25,26].

Genel olarak bu bulgular değerlendirildiğinde, EDA parametreleri nosisepsiyonun varlığını daha doğrudan ve tutarlı şekilde yansıtırken, HRV özellikleri farmakolojik etkilerden etkilense de özellikle entropi ve yüksek moment temelli ölçütler aracılığıyla nosisepsiyona yanıtı ortaya koyabilmektedir. Subramanian ve arkadaşları [14], EDA indekslerinin genel olarak HRV indekslerinden daha önemli olduğunu öne sürdüler. Bu neticenin beklendiğini ve sebebinin de kardiyovasküler ilaçlar doğrudan HRV'yi etkilerken, periferik terleme aktivitesini etkilememesi olduğunu belirttiler. Neticede, HRV'yi etkileyen ilaçlar (ör. beta blokerler) verildiğinde bile EDA indeksleri nosisepsiyonun daha güvenilir göstergeleri olmasına neden olmuştur. Sonuçlarımız bu yönüyle, Subramanian ve arkadaşlarının [14] çalışmasıyla paralellik göstermektedir. Bu sonuçlar, intraoperatif nosisepsiyonun objektif değerlendirilmesinde EDA'nın güçlü bir biyobelirteç olduğunu, HRV'nin ise özellikle kompleks özellikleri aracılığıyla tamamlayıcı rol üstlenebileceğini göstermektedir.

4. SONUÇLAR

Nosisepsiyonun, bilinçsizlik sırasında bile sinir sistemi boyunca izlenmesi, cerrahi sırasında uygun anestezi bakımı için kritik öneme sahiptir. Günümüzde bu izleme, kalp atış hızı ve kan basıncının gözle takip edilmesiyle yapılmaktadır. Bir hastanın nosiseptif durumunu objektif olarak izlemek hâlâ zorluk teşkil etmekte ve bu durum, ameliyat sırasında ilaçların sıklıkla aşırı ya da yetersiz dozda verilmesine neden olmaktadır. Cerrahi nosisepsiyonun hatalı yapılması, daha karmaşık postoperatif ağrı yönetimine ve özellikle yaşlı hastalarda postoperatif bilişsel bozukluk gibi yan etkilere yol açabilir [14]. Bu nedenle, nosisepsiyonun objektif ve güvenilir şekilde değerlendirilmesine katkı sağlayabilecek fizyolojik sinyal temelli makine öğrenmesi yaklaşımlarının geliştirilmesi önem taşımaktadır.

Çalışmamızda iki temel bulgu elde ettik. Birincisi, cerrahi işlem sırasında ameliyathane ortamında kaydedilen fizyolojik verilerin, nosisepsiyonun invaziv olmayan indeksler aracılığıyla tahmin edilmesinde kullanılabileceğini göstermektedir. Çalışmada nosisepsiyon varlığında meydana gelen fizyolojik değişiklikler multimodal EDA-HRV sinyalleri üzerinden sınıflandırılması neticesinde en sınıflandırma doğruluğu %90,3 doğrulukla gerçekleştirilmiştir. Bu sonuç, MÖ tabanlı yöntemlerin klinik koşullarda nosisepsiyonun değerlendirilmesi için uygulanabilir ve potansiyel olarak güvenilir bir yaklaşım sunduğunu göstermektedir.

Çalışmamızdaki ikinci bulgu ise nosisepsiyon varlığında yaşanan fizyolojik değişiklikleri lineer ve non-lineer özellikler aracılığıyla nosisepsiyon varlığındaki potansiyel biyobelirteçleri tanımladık. Bu amaçla nosisepsiyon varlığında ve yokluğu durumlarının istatistiksel açıdan karşılaştırılması yapılmış sonuçlar Çizelge 3'te sunulmuştur. Nosisepsiyon varlığında elde edilen bulgular hem HRV hem de EDA özelliklerinde anlamlı farklılıklar ortaya çıktığını göstermektedir. HRV sinyallerinde entropi ve çarpıklık, basıklık değerlerinin artışı, EDA parametrelerinde ise yalnızca ortalama değerlerin, entropi ve basıklık ölçütlerinin de artması, nosisepsiyon varlığına işaret eden potansiyel biyobelirteç rolü üstlenebileceğini göstermektedir.

Neticede, cerrahi sırasında invaziv olmayan fizyolojik indeksler olan multimodal EDA-HRV verileri kullanılarak nosisepsiyon varlığı ve yokluğu MÖ yöntemleriyle sınıflandırılmıştır. Çalışmada lineer ve non-lineer özellikler çıkarılmış bu özellikler üzerinden nosisepsiyon durumlarını ayırt eden potansiyel biyobelirteçler tanımlanmıştır. Elde edilen bulgular, multimodal EDA-HRV verilerine dayalı MÖ yaklaşımının, nosisepsiyonun objektif sınıflandırılmasında kullanılabildiğini ve gelecekte geliştirilebilecek klinik karar destek sistemleri için ön değerlendirme niteliğinde bir modelleme çerçevesi sunabileceğini göstermektedir.

5. TEŞEKKÜR

Bu çalışma, Türkiye Bilimsel ve Teknolojik Araştırma Kurumu (TÜBİTAK) 2209-A Üniversite Öğrencileri Araştırma Projeleri Destekleme Programı kapsamında, 2024/1 döneminde 1919B012405886 başvuru numarasıyla desteklenmiştir. Yazarlar, sağladığı destekten dolayı TÜBİTAK'a teşekkür eder.

6. KAYNAKLAR

1. Becker, D.E. & Haas, D.A. (2007). Management of complications during moderate and deep sedation: Respiratory and cardiovascular considerations. *Anesthesia Progress*, 54(2), 59-68.
2. Avidan, M.S., Jacobsohn, E., Glick, D., Burnside, B.A., Zhang, L., Villafranca, A., Karl, L., Kamal, S., Torres, B., O'Connor, M., Evers, A.S., Gradwohl, S., Lin, N., Palanca, B.J. & Mashour, G.A. (2011). Prevention of intraoperative awareness in a high-risk surgical population. *New England Journal of Medicine*, 365(7), 591-600.
3. Liu, Z., Si, L., Shi, S., Li, J., Zhu, J., Lee, W.H., Lo, S.L., Yan, X., Chen, B., Fu, F., Zheng, Y. & Wang, G. (2024). Classification of three anesthesia stages based on near-infrared spectroscopy signals. *IEEE Journal of Biomedical and Health Informatics*, 28(9), 5270-5279.
4. Boucsein, W. (2012). *Electrodermal activity*. Springer Science & Business Media, Berlin.
5. Wang, Q., Liu, F., Wan, G. & Chen, Y. (2022). Inference of brain states under anesthesia with meta learning based deep learning models. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 30, 1081-1091.
6. Boucsein, W. (2012). Principles of electrodermal phenomena. In *Electrodermal activity*, 1-86. Springer.

7. Kirnő, K., Kunimoto, M., Lundin, S., Elam, M. & Wallin, B. G. (1991). Can galvanic skin response be used as a quantitative estimate of sympathetic nerve activity in regional anesthesia? *Anesthesia & Analgesia*, 73(2), 138-142.
8. Tseng, B., Subramanian, S., Barbieri, R. & Brown, E.N. (2022). Tonic electrodermal activity is a robust marker of psychological and physiological changes during induction of anesthesia. In *2022 44th Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC)*, 418-421. IEEE.
9. Jeanne, M., Logier, R., De Jonckheere, J. & Tavernier, B. (2009). Heart rate variability during total intravenous anesthesia: Effects of nociception and analgesia. *Autonomic Neuroscience*, 147(1-2), 91-96.
10. Mazzeo, A.T., La Monaca, E., Di Leo, R., Vita, G. & Santamaria, L.B. (2011). Heart rate variability: A diagnostic and prognostic tool in anesthesia and intensive care. *Acta Anaesthesiologica Scandinavica*, 55(7), 797-811.
11. Matava, C., Pankiv, E., Ahumada, L., Weingarten, B. & Simpao, A. (2020). Artificial intelligence, machine learning and the pediatric airway. *Pediatric Anesthesia*, 30(3), 264-268.
12. Lee, H.C., Ryu, H.G., Chung, E.J. & Jung, C.W. (2018). Prediction of bispectral index during target-controlled infusion of propofol and remifentanyl: A deep learning approach. *Anesthesiology*, 128(3), 492-501.
13. Tu, Z., Zhang, Y., Lv, X., Wang, Y., Zhang, T., Wang, J., Yu, X., Chen, P., Pang, S., Li, S., Yu, X. & Zhao, X. (2025). Accurate machine learning-based monitoring of anesthesia depth with EEG recording. *Neuroscience Bulletin*, 41(3), 449-460.
14. Subramanian, S., Purdon, P., Barbieri, R. & Brown, E. (2021). Behavioral and autonomic dynamics during propofol-induced unconsciousness. *PhysioNet*.
15. Niu, J., Lu, Y., Xu, R., Fang, F., Hong, S., Huang, L., Xue, Y., Fei, J., Zhang, X., Zhou, B., Zhang, P. & Jiang, R. (2023). The prognostic value of intraoperative HRV during anesthesia in patients presenting for non-cardiac surgery. *BMC Anesthesiology*, 23(1), 160.
16. Fauchereau, C., Carimalo, F., Merienne, A., Laffon, M., Godat, E. & Aude, J.C. (2025). Heart rate fragmentation improves general anesthesia state classification using machine learning. *medRxiv*, 2025.01.07.25320157.
17. Yeşilbaş, D., Batbat, T., Altınkaynak, M., Uğurgöl, E., Güven, A., Dolu, N., Demirci, E. & Izzetoglu, M. (2025). An efficient multimodal electroencephalography and functional near-infrared spectroscopy approach using Stroop task to evaluate internet gaming disorder with machine learning methods: A comprehensive study. *Engineering Applications of Artificial Intelligence*, 159, 111772.
18. Yeşilbaş, D. ve Güven, A. (2021). Kütle spektrometresi verileri kullanılarak yumurtalık kanserinin yapay sinir ağlarıyla sınıflandırılması. *Çukurova Üniversitesi Mühendislik Fakültesi Dergisi*, 36(3), 781-790.
19. Çavdar, F., Günen, A. ve Sert, M. (2024). Borlanmış AISI H11 takım çeliğinin kaplama özellikleri ve korozyon oranının makine öğrenmesi temelli modellenmesi. *Çukurova Üniversitesi Mühendislik Fakültesi Dergisi*, 39(3), 625-638.
20. Akça, Ş. ve Şanlı, F.B. (2022). Kıyı çizgisinin makine öğrenmesi tabanlı Mean-Shift, rastgele orman ve destek vektör makinaları ile belirlenmesi. *Çukurova Üniversitesi Mühendislik Fakültesi Dergisi*, 37(3), 835-842.
21. Zhan, J., Wu, Z.X., Duan, Z.X., Yang, G.Y., Du, Z.Y., Bao, X. H. & Li, H. (2021). Heart rate variability-derived features based on deep neural network for distinguishing different anaesthesia states. *BMC Anesthesiology*, 21(1), 66.
22. Posada-Quintero, H.F., Kong, Y. & Chon, K.H. (2021). Objective pain stimulation intensity and pain sensation assessment using machine learning classification and regression based on electrodermal activity. *American Journal of Physiology-Regulatory, Integrative and Comparative Physiology*, 321(2), R186-R196.
23. Riganello, F., Dolce, G. & Sannita, W.G. (2012). Heart rate variability and the central autonomic network in the severe disorder of consciousness. *Journal of Rehabilitation Medicine*, 44(6), 495-501.
24. Chouchou, F. & Desseilles, M. (2014). Heart rate variability: A tool to explore the sleeping brain? *Frontiers in Neuroscience*, 8, 402.
25. Ledowski, T., Pascoe, E., Ang, B., Schmarbeck, T., Clarke, M.W., Fuller, C. & Kapoor, V. (2010). Monitoring of intra-operative nociception: Skin conductance and surgical stress index versus stress hormone plasma levels. *Anaesthesia*, 65(10), 1001-1006.
26. Storm, H., Myre, K., Rostrop, M., Stokland, O., Lien, M.D. & Ræder, J.C. (2002). Skin conductance correlates with perioperative stress. *Acta Anaesthesiologica Scandinavica*, 46(7), 887-895.