

## Reklam İzlenimi Sırasında Fizyolojik Parametrelerin Analizine Dayalı Tüketici Tercihlerinin Sınıflandırılması

Eda Dağdevir\*<sup>1</sup>

\*<sup>1</sup>Kayseri Üniversitesi, Teknik Bilimler Meslek Yüksekokulu, Elektronik ve Otomasyon Bölümü, Biyomedikal Cihaz Teknolojisi Programı KAYSERİ

(Alınış / Received: 24.05.2024, Kabul / Accepted: 19.08.2024, Online Yayınlanma / Published Online: 30.08.2024)

### Anahtar Kelimeler

Nöropazarlama,  
Fizyolojik Sinyal,  
Sinyal İşleme,  
Sınıflandırma,  
Makine Öğrenimi

**Öz:** Son yıllarda nöropazarlama, tüketici davranışlarını anlamak için nörobilim yöntemlerini pazarlamaya entegre eden önemli bir strateji olarak ortaya çıkmıştır. Bu alanda, elektroensefalografi gibi beyin sinyali analiz yöntemleri ve vücut sıcaklığı, fotopletizmografi, kardiyak ritim, elektro dermal aktivite, yüz ifadeleri gibi çeşitli fizyolojik ve fiziksel parametreler kullanılarak tüketici tercihleri analiz edilmektedir. Bu çalışmada, "NeuroBioSense" veri seti kullanılarak 18-70 yaş arasındaki 58 katılımcıya, kozmetik ve moda, araba ve teknoloji, gıda ve market kategorilerine ait 35 farklı reklam izletilirken toplanan; kalp hacmi basıncı, elektro dermal aktivite ve vücut sıcaklığı gibi fizyolojik parametreler farklı makine öğrenimi algoritmalarıyla sınıflandırılarak analiz edilmiştir. Sonuçlar, segmentasyon teknikleri kullanılarak çıkarılan kalp hacmi basıncı özniteliklerinin yer aldığı öznitelik setinin ham verilerin yer aldığı öznitelik setine göre daha yüksek sınıflandırma doğruluğu sağladığını göstermektedir. Önerilen yöntem ve DVM sınıflandırıcı ile en iyi sınıflandırma doğruluğu; kozmetik ve moda, araba ve teknoloji, gıda ve market, hepsi kategorileri için sırasıyla %82.2, %86.6, %84.6, %82.9 olarak elde edilmiştir. Bu çalışma, nöropazarlamada fizyolojik sinyallerin analizinin tüketici tercihlerini anlamada etkili bir yöntem olduğunu ortaya koymakta ve "NeuroBioSense" veri setini kullanacak araştırmacılara karşılaştırma olanağı sunmaktadır.

## Classification of Consumer Preferences Based on Analysis of Physiological Parameters During Advertising Viewing

### Keywords

Neuromarketing,  
Physiological Signal,  
Signal Processing,  
Classification,  
Machine Learning

**Abstract:** In recent years, neuromarketing has emerged as a significant strategy that integrates neuroscience methods into marketing to understand consumer behaviour. In this field, consumer preferences are analysed using brain signal analysis methods such as electroencephalography and various physiological and physical parameters such as body temperature, photoplethysmography, cardiac rhythm, electrodermal activity, and facial expressions. In this study, physiological parameters such as Blood Volume Pulse, Electrodermal Activity, and Body Temperature, collected while 58 participants aged 18-70 watched 35 advertisements from the categories of cosmetics and fashion, cars and technology, and food and market, were analysed using different machine learning algorithms with the "NeuroBioSense" dataset. The results show that the feature set containing the heart volume pressure features extracted using segmentation techniques provides higher classification accuracy than the feature set containing the raw data. The best classification accuracy with the proposed method and SVM classifier is obtained as 82.2%, 86.6%, 84.6%, 82.9% for the categories of cosmetics and fashion, car and technology, food and market, and all, respectively. This study demonstrates that the analysis of physiological signals in neuromarketing is an effective method for understanding consumer preferences and provides a comparison opportunity for researchers using the "NeuroBioSense" dataset.

\*İlgili Yazar, email: edakaracaoglan@gmail.com

## 1. Giriş

Son yıllarda, pazarlama dünyası geleneksel araçlarına ek olarak nörobilim ve bilgisayar biliminden yararlanarak yeni stratejilere yönelmiştir. Bu stratejilerden biri de "Nöropazarlama" olarak adlandırılan alanın yükselişidir. Nöropazarlama, tüketicilerin gerçek düşüncelerini ve duygularını anlamak için fizyolojik aktivite ölçerek pazarlama stratejilerini optimize etmeyi amaçlar. Bu alanda yapılan çalışmalar, tüketici tercihlerini anlamak için elektroensefalografi (EEG) gibi beyin sinyali analiz yöntemlerinin kullanılmasını öne çıkarmaktadır [1],[2]. EEG'nin yanı sıra vücut sıcaklığı, fotopletizmografi, kardiyak ritim, elektro dermal aktivite, mimik ve yüz ifadesi gibi fizyolojik ve fiziksel parametreler de tüketici tercihlerini belirlemede kullanılmaktadır.

Nöropazarlama, bir bireyin çeşitli ürünler ve medya ile olan deneyimlerine ve pazar reklamlarına verdiği yanıtlara içgörüler sağlamayı amaçlar. Tüketici duygularının karar verme sürecini etkilediği bilinen bir gerçektir. Öte yandan, tüketici duyguları birçok içsel ve dışsal faktörden güçlü bir şekilde etkilenebilir. Dolayısıyla, bir tüketicinin duygusal durumunun tespiti ve tanınması gerçek tüketici tercihlerini ortaya çıkarır [3]. Bu alandaki çalışmalar, tüketici tercihlerini ve davranışlarını anlamamıza yardımcı olurken, bir alışveriş kararı nasıl alındığını anlamamıza da yardımcı olur. Ayrıca, pazarlamaçıların ve kuruluşların müşteri memnuniyetini, olumlu müşterileri deneyimlerini, tüketici sadakatini ve geliri artırmak için harekete geçmelerine yardımcı olur [3],[4]. EEG tabanlı duygu tanıma üzerine birçok çalışma yapılmış olmasına rağmen [4],[5], tüketicilerde tercihleri tespit etmek için fiziksel ve fizyolojik veri ölçüm tabanlı çalışmalar henüz çok erken aşamada [6]. Her ne kadar nöropazarlama alanı son yıllarda önemli ölçüde gelişmiş olsa da bu alan pazarlama araştırma alanlarında henüz tam olarak uygulanmamıştır [5]. Bu durum, pazarlama araştırmacılarının nörobilimde sistematik bilişsel uygulamalar konusunda eğitim eksikliğinden kaynaklanmaktadır. Ayrıca, pazarlama araştırmacıları daha önce, nörobilim teknolojilerinin ticari amaçlar için kullanılması durumunda etik kuralların ihlal edilmesinin ve tüketicilerin gizliliğinin sonuçları konusunda şüpheler taşımaktadır. Gerekli etik kuralların çerçevelerinin belirlenmesi ile bu şüpheler azalsa da pazarlama araştırmacılarının hala nöropazarlama kullanımına karşı hala çekinceleri bulunmaktadır [7]. Dolayısıyla, ürün tercihlerini çıkarmak için pasif gözlemler sırasında EEG verilerinin kullanılması hala açık bir tartışma konusudur [8],[9]. Bu çekince de göz önüne alınarak, EEG ölçümüne alternatif metotlar geliştirilme ihtiyacı duyulmuştur.


Reklamlar arasındaki farkları karşılaştırmak amacıyla, Murugappan ve arkadaşları [10], EEG sinyalini kullanarak, güç spektral yoğunluğu (GSY), spektral enerji ve spektral merkez ile ilgili öznitelikler ile her katılımcının en sevdiği ürünü belirlemeyi amaçlamıştır. K-EYK gibi makine öğrenimi (MÖ) ve olasılıksal sinir ağı (OSA) algoritmaları gibi derin öğrenme modelleri oluşturarak kullanıcının en çok tercih ettiği ürünü tespit etmede %96.6'ya kadar doğruluk elde etmişlerdir. Benzer bir amaçla, Hakim ve arkadaşları [11] tarafından frontal bant gücü ve hemisferik simetri tabanlı öznitelik çıkarımı ve DVM, Lojistik Regresyon (LR), K-EYK ve Karar Ağaçları (KA) gibi MÖ algoritmalarını kullanarak ikili sınıflandırmada %68.51 maksimum doğruluk elde etmişlerdir. Nöropazarlama çalışmalarındaki bir diğer hedef, reklamın kullanıcılarda yarattığı ilgiyi veya beğeniyi tahmin etmektir. Bu amaçla yapıldığı bilinen ilk çalışma, Soria ve arkadaşları [12] tarafından gerçekleştirilmiştir ve EEG sinyalinin ham verilerinden Yapar Sinir Ağı (YSA) tabanlı bir analizini yaparak, belirli bir reklamın kullanıcı tarafından beğenilip beğenilmediğini tespit etmede %68 doğruluk elde etmişlerdir. Guixeres ve arkadaşları [13] EEG'ye KHB ve Göz izleme (Gİ) parametrelerini de eklemişlerdir. EEG sinyalinden elde edilen bilgiler, GSY kullanılarak güç tabanlı ve Gİ sinyali için İlgi Alanı (İA) hesaplamışlardır. Bu bilgilerle, kullanıcının beğendiği ürünleri tanımak için YSA tabanlı bir model ile %82.9 doğruluk elde etmişlerdir. Garczarek [14] EEG, EKG, EDA ve Gİ olmak üzere dört farklı fizyolojik sinyali 21 katılımcıdan toplamışlardır ve farklı yöntem kombinasyonlarında en fazla %65.8 doğruluk elde etmişlerdir. Son olarak, Yadava ve arkadaşları [15] EEG sinyalinden ilgili bilgi çıkarmak için Ayrık Dalgacık Dönüşümü (ADD) uygulayıp Gizli Markov Modeli (GMM) algoritmasını kullanarak satın alma tercihlerini sınıflandırmışlardır. Bu algoritma seçimiyle, sınıflandırma doğruluğunu %95.33'e çıkarmışlardır. Her ne kadar nörolojik değişimlerin değerlendirilmesinde altın standart olan EEG kadar yüksek başarımlar elde edilemese de EEG yerine tüketici davranışları konusunda bilgi içeren diğer fizyolojik parametrelerden yararlanılabilir.

Bu çalışma Kalp hacmi basıncı (KHB), Elektro dermal aktivite (EDA), Vücut sıcaklığı gibi fizyolojik parametreleri kullanarak nöropazarlamada tercih tespitine yol göstermeyi amaçlamaktadır. Seçilen parametreler, tüketici tercihinin birden fazla fizyolojik parametreyle bağlantılı olduğu gerçeği doğrultusunda tercih edilmiştir [1]. Parametrelerin tüketici tercihindeki etkisini göstermek üzere elde edilen öznitelikler, makine öğrenimi algoritmaları kullanılarak tüketici tercihlerini sınıflandırmak için eğitilmiştir. Kullanılan geleneksel sınıflandırma algoritmaları arasında k-en yakın komşu (K-EYK), destek vektör makinesi (DVM) ve rastgele orman (RO) yer almaktadır.

Çalışmanın geri kalanı şu şekilde düzenlenmiştir: Bölüm 2, bu çalışmanın ana kavramlarını ve araştırma metodolojisini ve materyalleri tanımlar ve sunar; Bölüm 3, değerlendirme sonuçlarını ve tüm bulguları sunar ve son olarak, Bölüm 4, gelecek çalışmaları tartışır, sonucu gösterir.

## 2. Materyal ve Metot

Sinyal işleme açısından, tüketici tercihlerinin tespiti ve bu tespitin sonuçları, öznitelik çıkarma ve sınıflandırma algoritmalarının seçimlerine bağlıdır. Bu çalışmada, 7 farklı duygusal düzeyi (Sevinç, Şaşkınlık, Öfke, Tikslenme, Üzüntü, Korku, Nötr) ayırt edebilmek için sinyal işleme metotlarının kullanılabilirliği araştırılmıştır. Deneklerden toplanan KHB, EDA, vücut sıcaklığı gibi fizyolojik parametreler kullanılarak farklı özellik çıkarma-sınıflandırma algoritmalarının duygusal düzeyleri ayırt edebilme performansı karşılaştırılmıştır. Fizyolojik parametrelerden öznitelik çıkarma için fizyolojik verilerden istatistiksel öznitelik çıkarma metotları kullanılmıştır. Katılımcı tercihlerini etkili bir şekilde yansıtabildiği için geleneksel sınıflandırıcılar olan K-EYK, DVM ve RO sınıflandırma amacıyla kullanılmıştır. Veri işleme prosedürünün tamamı MATLAB R2023b aracılığı ile gerçekleştirilmiştir. Çalışmaya ait akış şeması Şekil 1’de gösterilmiştir.



Şekil 1. Çalışmanın akış şeması

### 2.1. Veri seti

Bu çalışmada kullanılan veri seti, dikkatle planlanmış bir deney tasarımı uygulanarak 18 ila 70 yaş arasındaki 58 katılımcıdan elde edilmiştir. Katılımcılara kozmetik ve moda, araba ve teknoloji, gıda ve market olmak üzere üç kategoriye ayrılmış 35 reklam gösterilmiştir. Her bir kategoride yer alan denek ve reklam sayıları ve isimlendirmeleri Tablo 1’de verilmiştir.

Reklam kategorisi	Denek No.	Reklam No.
Kozmetik ve moda	1-18(18 denek)	A01-A15(15 reklam)
Araba ve teknoloji	19-38(20 denek)	A01-A10(10 reklam)
Gıda ve market	39-58(20 denek)	A01-A10(10 reklam)

“Empatica e4” giyilebilir sensör cihazı ile KHB, EDA, vücut sıcaklığı, üç eksenli ivmelenme gibi fizyolojik sinyalleri kaydedilmiştir. Aynı anda, reklamları izleme süreçlerinde yüz ifadelerinin yakalanma işlemi yüksek çözünürlüklü kameralar kullanılarak gerçekleştirilmiştir. Katılımcıların duygusal değerlendirmeleri duygu değerlendirme ölçeği kullanılarak değerlendirilirken, demografik bilgiler anketler aracılığıyla toplanmıştır. Katılımcıların duygusal yanıtları, Yüz İfadeleri Çözme Sistemi (Facial Action Coding System -FACS) kullanılarak değerlendirilmiştir. 7 farklı duygu (Sevinç, Şaşkınlık, Öfke, Tikslenme, Üzüntü, Korku, Nötr) sınıfı için değerlendirme yapılmıştır. Bu duygu durumlarının belirlenmesi için kullanılan, deneklerin reklam izlemesi sırasındaki video kayıtlarından rastgele elde edilen örnek görseller Şekil 2’de yer almaktadır.



**Şekil 2.** Reklam izlenimi sırasında deneklerin video kayıtlarından elde edilen örnek görseller

Bu çalışmada veri setindeki bazı özel işlemler ve sinyaller hariç tutularak, tüm katılımcılar için, KHB, EDA, Sıcaklık parametreleri ile oluşturulan öznitelikler, veri seti oluşturucuları tarafından belirlenen duygu yanıtları ile sınıflandırılmıştır. Detaylı bilgi “NeuroBioSense” veri seti açıklamalarında yer almaktadır [16].

## 2.2. Ön işleme

Tüm katılımcılar için, KHB, EDA, Sıcaklık parametreleri sırasıyla 64,4,4 Hz örnekleme frekansı ile kaydedilmiştir. Öznitelik çıkarımından kullanılacak tüm parametreler, her bir katılımcı için reklam ve sınıf etiketi bilgisini içerecek şekilde düzenlenmiştir. Katılımcıların çoğu bir reklam için birden fazla duygu yanıtı verdiği için, veri seti oluşturucuları da yanıtları ve diğer parametreleri dikkate alarak bazı reklamlar için birden fazla sınıf etiketi oluşturmuşlardır. Bu nedenle toplam sınıf sayısı, katılımcıların izlediği toplam reklam sayısından daha fazladır.

## 2.3. Öznitelik çıkarımı

Fizyolojik sinyalleri kullanarak farklı uygulamalara yönelik özniteliklerin elde edilmesi için önerilen birçok yaklaşım vardır [17]. Bu çalışmada, KHB, EDA, Sıcaklık parametreleri özelinde etkin özniteliklerin elde edilebileceği aşağıda hesapları yer alan öznitelikler kullanılmıştır [18].

Öznitelik setlerinden birincisi, KHB parametresi, pencere uzunluğu sinyalin uzunluğunun dörtte biri ve dörtte bir örtüşme olacak şekilde pencerelere ayrılarak bir öznitelik seti oluşturulmuştur. Pencere uzunluğu ve örtüşme uzunluğuna karar vermek amacıyla farklı pencere ve örtüşme uzunlukları seçimi için optimizasyon çalışması ile tüm sınıflandırma süreci tekrar edilmiştir [19]. Bu amaçla, belirlenen pencere uzunluğu ve örtüşme uzunluğu parametreleri ve onların seviyeleri Tablo 2’de verilmiştir. Optimum pencereleme sürecine ait detaylar [19]’de yer almaktadır. Deneyler sonucunda DVM sınıflandırıcısı için, en yüksek sınıflandırma doğruluğu ve en düşük zamanlama maliyeti için optimum pencere uzunluğu 3 s, örtüşme miktarı 1 s olacak şekilde seçilmiştir.

Öznitelik setlerinden ikincisi ise, KHB parametresine herhangi bir pencereleme ve örtüşme uygulanmadan oluşturulmuştur. Ayrıca her iki öznitelik setinde, EDA ve vücut sıcaklığı parametrelerine pencereleme ve örtüşme uygulanmadan öznitelikler elde edilmiştir.

**Tablo 2.** Veri seti kategorine göre denek ve reklam sayıları

Parametreler	Seviyeler		
	1	2	3
Pencere Uzunluğu (s)	3	5	7.5
Örtüşme Uzunluğu (s)	0	1	2

Maksimum değer:

$$Maks = \max (x_1, x_2, \dots, x_n) \quad (1)$$

Minimum değer:

$$Min = \min (x_1, x_2, \dots, x_n) \quad (2)$$

Ortalama değer:

$$Ort = \frac{1}{n} \sum_{i=1}^n x_i \quad (3)$$

Ortalama mutlak değer:

$$Ort Mut = \frac{1}{n} \sum_{i=1}^n |x_i| \quad (4)$$

Standart sapma değeri:

$$Std Sapma = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - Ort)^2} \quad (5)$$

Varyans değeri:

$$Var = \frac{1}{n} \sum_{i=1}^n (x_i - Ort)^2 \quad (6)$$

Entropi değeri:

$$Ent = - \sum_{i=1}^n p_i \log_2(p_i) \quad (7)$$

Eşitlik 1, Eşitlik 2 ve Eşitlik 3'te  $x_1, x_2, \dots, x_n$   $n$  örneklemden oluşan sinyalin zaman serisi örnekleridir. Eşitlik 4 ve Eşitlik 5 ve Eşitlik 6'da  $x_i$  sinyalin zaman serisi örneklerini temsil eder. Eşitlik 5 ve Eşitlik 6'da  $Ort$  örneklemin ortalama değeridir. Eşitlik 7'de  $p_i$  sinyaldeki farklı değerlerin olasılıklarını temsil eder ve değer  $i$ 'nin sinyalde görülme sayısının toplam sinyaldeki örnek sayısına oranını gösterir.

Pik tespiti: Pik tespiti yöntemleri sinyaldeki yerel maksimum veya minimum noktalarını belirler. Pik tespiti yalnızca KHB parametresi için hesaplanmıştır.

Sonuç olarak, tüm kategorilerin toplamı (Hepsi) için, birinci öznitelik setinin boyutu 1288 x 118 iken ikinci öznitelik setinin boyutu 1288 x 22'dir. Burada, katılımcılara 670 video izletilmiş olsa da katılımcıların çoğu bir reklam için birden fazla duygu yanıtı verdiği için, bazı reklamlar için birden fazla sınıf etiketi mevcuttur. Bu nedenle etiketli video sayısı her iki öznitelik seti için de 1288'dir. KHB parametresine 3s pencere uzunluğunda 1s örtüşme ile segmentleme uygulanması durumunda sinyal 13 epoktan oluşmaktadır. EDA ve sıcaklık için pik tespiti anlamlı bir öznitelik yansıtmayacağından yalnızca KHB parametresi için pik tespiti hesabı da öznitelik olarak kullanılmıştır. Bunun yanı sıra KHB ve diğer parametreler için yukarıda açıklanan 7 öznitelik hesaplanmıştır. Bu durumda, birinci öznitelik seti için toplam öznitelik sayısı 118'dir. İkinci öznitelik setinde ise ham veriler kullanıldığından KHB, EDA ve sıcaklık için sırasıyla öznitelik sayısı 8,7,7 olarak belirlenmiştir ve etiketli video sayısı da yine 1288'dir.

## 2.4. Sınıflandırma

Bu çalışmada, "NeuroBioSense" veri setinden elde edilen veriler için 7 duygu durumu (Sevinç, Şaşkınlık, Öfke, Tiksinme, Üzüntü, Korku, Nötr) tespit edilmiştir. Temel olarak, geleneksel sınıflandırıcılar karşılaştırılmıştır. En iyi doğruluğu ve en uygun sınıflandırıcıyı bulmak için K-EYK, DVM ve RO sınıflandırıcıları 5 kat çapraz doğrulama ile uygulanmıştır.

K-EYK, temelde bir sınıflandırma ve regresyon algoritmasıdır. Bu algoritmanın temel prensibi, veri noktalarının etiketlerinin, çevrelerindeki  $k$  komşusunun etiketlerine bakılarak belirlenmesidir. Sınıflandırma durumunda, bir noktanın sınıfını, ona en yakın olan  $k$  komşusunun etiketlerine bakarak belirler. Bu çalışmada  $k$ , 5 seçilmiştir.

Regresyon durumunda ise, komşuların ortalama değerlerini kullanarak tahmin yapar [20]. K-EYK algoritması, özellikle çok karmaşık olmayan problemlerde oldukça etkilidir.

DVM, özellikle sınıflandırma problemleri için kullanılan bir makine öğrenmesi algoritmasıdır. DVM, veri noktalarını sınıflar arasında bir hiper düzlemlerle en iyi şekilde ayırarak çalışır. Bu, sınıflar arasındaki marjleri maksimize etmeye çalışırken, aynı zamanda sınıflandırma hatasını minimize etmeyi hedefler [21]. DVM, özellikle yüksek boyutlu veri setlerinde ve doğrusal olmayan sınıflandırma problemlerinde güçlü performans gösterir. Bu algoritma, farklı çekirdek fonksiyonları kullanarak veri noktalarını daha yüksek boyutlu bir uzaya yansıtabilir, bu da sınıflandırma doğruluğunu artırır. Bu nedenle çoğu sınıflandırma problemi için başarılı bir modeldir.

RO, hem sınıflandırma hem de regresyon problemleri için kullanılan bir makine öğrenmesi algoritmasıdır. RO, birden çok karar ağacının bir araya gelerek bir tahmin yapmasını sağlar. Her bir ağaç, rastgele örnekleme ve rastgele öznelik seçimi yaparak eğitilir, böylece aşırı uyum riski azalırken, tahmin performansı artar. Bu yöntem, özellikle büyük ve karmaşık veri setlerinde güçlü bir genel performans sunar. Rastgele Orman algoritması, veri setindeki çeşitli değişkenlerin önem derecesini değerlendirebilme yeteneği sayesinde, öznelik seçimi ve sınıflandırma modelinin açıklanabilirliği açısından da değerli bir araçtır [22].

Yöntemin sınıflandırma performansını ölçmek için sınıflandırıcıların doğruluk, duyarlılık, kesinlik ve F1-skoru değerleri hesaplanmıştır. Gerçek Pozitif (GP): Doğru şekilde o sınıfa ait olarak sınıflandırılan öznelikler, Gerçek Negatif (GN): Doğru şekilde o sınıfa ait olmayan olarak sınıflandırılan öznelikler, Yanlış Pozitif (YP): Yanlış şekilde o sınıfa ait olarak sınıflandırılan öznelikler ve Yanlış Negatif (YN): Yanlış şekilde o sınıfa ait olmayan olarak sınıflandırılan öznelikler olmak üzere:

Doğruluk, sınıflandırıcının doğru sınıflandırdığı örneklerin toplam örnek sayısına oranı temsil eder. Eşitlik 8'de gösterildiği gibi hesaplanır.

$$\text{Doğruluk} = \frac{GP + GN}{GP + GN + YP + YN} \quad (8)$$

Duyarlılık, gerçek pozitiflerin doğru bir şekilde tahmin edilme oranını ölçer. Eşitlik 9'da gösterildiği gibi hesaplanır.

$$\text{Duyarlılık} = \frac{GP}{GP + YN} \quad (9)$$

Kesinlik, sınıflandırıcının pozitif olarak tahminlediği örneklerin ne kadarının gerçekten pozitif olduğunun ölçüsüdür. Eşitlik 10'da gösterildiği gibi hesaplanır.

$$\text{Kesinlik} = \frac{GP}{GP + YP} \quad (10)$$

F1 skoru, kesinlik ve duyarlılığın harmonik ortalamasını ifade eder. Eşitlik 11'de gösterildiği gibi hesaplanır.

$$F1 - \text{skoru} = 2 \frac{\text{Duyarlılık} \cdot \text{Kesinlik}}{\text{Duyarlılık} + \text{Kesinlik}} \quad (11)$$

Bu çalışmada 7 farklı sınıf olduğundan sınıflandırıcı performansları, tüm sınıflar için toplam GP, GN, YP ve YN değerleri kullanılarak mikro ortalama ile hesap edilmiştir.

### 3. Bulgular

Çalışmada elde edilen sınıflandırma sonuçları Tablo 3, Tablo 4 ve Tablo 5'te özetlenmiştir. Önerilen sınıflandırma yönteminin etkinliğini değerlendirmek amacıyla, pencerelere ayrılarak KHB verilerinden elde edilen özneliklerin yer aldığı sınıflandırma sonuçları, ham verilerden doğrudan elde edilen özneliklerin sonuçları ile karşılaştırılmıştır.

Tablo 3 pencerelere ayrılarak KHB verilerinden elde edilen öznelikler kullanılarak bulunan sınıflandırma sonuçlarını göstermektedir. Ham verilerden doğrudan elde edilen özneliklerle yapılan sınıflandırma sonuçları ise Tablo 4'te verilmiştir. Tablo 3 ve Tablo 4 analiz edildiğinde, pencerelere ayrılarak KHB verilerinden elde edilen öznelikler kullanılarak yapılan sınıflandırmanın doğruluk performansını artırdığı görülmektedir. Tablolarda sonuçların 4 kategoride değerlendirildiği görülmektedir. "Kozmetik ve moda", "Araba ve teknoloji", "Gıda ve

market"; 3 farklı kategorideki reklamları izleyen ayrı denek gruplarının 7 farklı duygu durumunun (Sevinç, Şaşkınlık, Öfke, Tiksinme, Üzüntü, Korku, Nötr) sınıflandırmasını gösterirken, "Hepsi" kategoriden bağımsız olarak tüm denek gruplarının sınıflandırma sonuçlarını birlikte göstermektedir.

Tablo 3 ve 4'teki sonuçları değerlendirirken, DVM sınıflandırma performanslarının diğer sınıflandırıcılara nazaran "Kozmetik ve moda" kategorisi hariç olmak üzere, daha yüksek olduğu görülmektedir. "Kozmetik ve moda" kategorisi için ise K-EYK ve DVM sınıflandırıcıları aynı performansı gösterirken RO sınıflandırma başarısı daha düşüktür. Ayrıca, "Hepsi" sınıflandırma performansının, "Araba ve teknoloji" sınıflandırma performansından daha düşük olduğu "Kozmetik ve moda" ve "Gıda ve market" sınıflandırma performanslarıyla ise yaklaşık aynı olduğu gözlemlenmiştir. KHB verilerinin pencerelere ayrıldığı öznelikler kullanılarak "Araba ve teknoloji" kategorisindeki reklamların; ham veriler kullanılarak ise "Gıda ve market" kategorisindeki reklamların diğer kategorilere göre daha yüksek doğruluk ile sınıflandırıldığı görülmektedir.

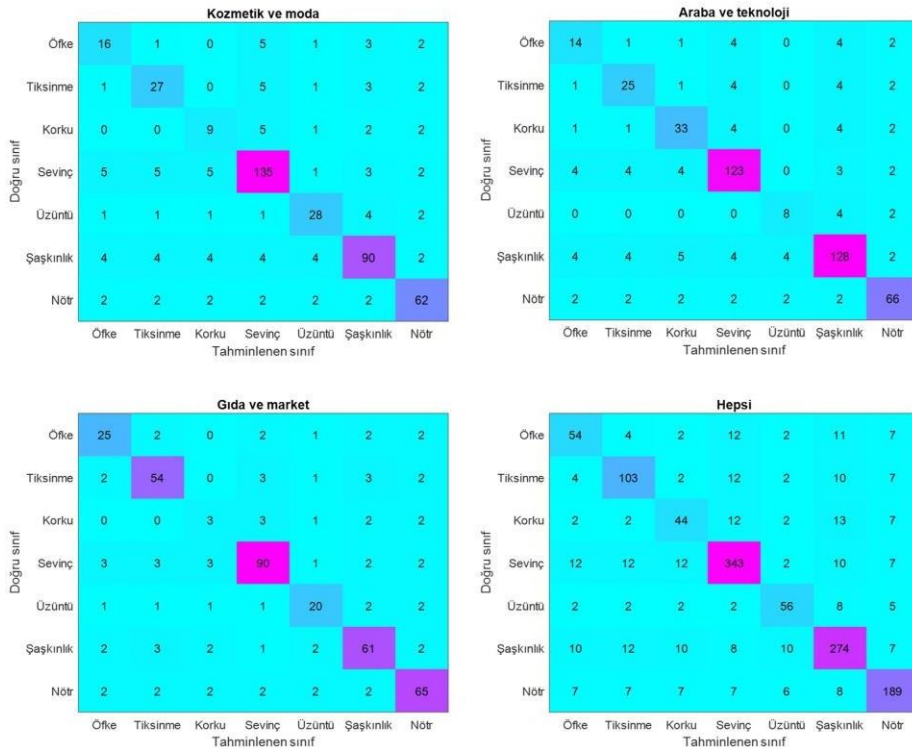
**Tablo 3.** KHB verilerinin pencerelere ayrıldığı öznelikler için sınıflandırma doğrulukları

	K-EYK	DVM	RO
Kozmetik ve moda	0.817	0.822	0.795
Araba ve teknoloji	0.845	0.866	0.845
Gıda ve market	0.817	0.846	0.827
Hepsi	0.820	0.829	0.802

**Tablo 4.** Ham verilerle elde edilen öznelikler için sınıflandırma doğrulukları

	K-EYK	DVM	RO
Kozmetik ve moda	0.796	0.803	0.782
Araba ve teknoloji	0.807	0.827	0.808
Gıda ve market	0.824	0.831	0.823
Hepsi	0.795	0.797	0.785

Pencerelere ayrılarak KHB verilerinden öznelikler kullanılarak elde edilen sonuçlara göre sınıflandırıcıların diğer performans metrikleri Tablo 5'te gösterilmiştir. Ayrıca her bir reklam kategorisinde en iyi doğruluk sonuçlarının elde edildiği DVM sınıflandırıcısı için konfüzyon matrisleri Şekil 3'te verilmiştir. Çalışma yer alan tüm sınıflandırıcılar için doğruluk, duyarlılık, kesinlik ve F1-skoru performans metrikleri verilmiştir. Doğrulukta olduğu gibi diğer metriklerde de DVM sınıflandırıcısının başarımı daha yüksektir. Tablolardaki sonuçları değerlendirerek, katılımcıların beğeni durumlarının, çıkarılan öznelikler kullanılarak doğruluk, duyarlılık, kesinlik ve F1-skoru metrikleri açısından başarıyla sınıflandırıldığı sonucuna varılmaktadır.



**Şekil 3.** Her reklam kategorisi için DVM sınıflandırıcısına ait konfüzyon matrisleri

**Tablo 5.** Önerilen öznitelikler ile elde edilen sınıflandırma performans metrikleri

Performans Metriği	Doğruluk			Duyarlılık			Kesinlik			F1-skoru		
	K-EYK	DVM	RO	K-EYK	DVM	RO	K-EYK	DVM	RO	K-EYK	DVM	RO
Kozmetik ve moda	0.82	0.82	0.80	0.81	0.81	0.78	0.81	0.81	0.78	0.78	0.81	0.78
Araba ve teknoloji	0.85	0.87	0.85	0.84	0.85	0.84	0.84	0.85	0.84	0.84	0.85	0.84
Gıda ve market	0.82	0.85	0.83	0.82	0.85	0.83	0.82	0.85	0.83	0.82	0.85	0.83
Hepsi	0.82	0.83	0.80	0.82	0.82	0.79	0.82	0.82	0.79	0.82	0.82	0.79

#### 4. Tartışma ve Sonuç

Bu çalışmada, nöropazarlama uygulamalarında kullanılmak üzere duygu durumunun tespiti için farklı öznitelik çıkarma ve sınıflandırma yöntemleri önerilmiştir. 58 denek, 18,20,20 denekten oluşan 3 farklı gruba ayrılarak 3 farklı kategoride reklam videolarını izlemeleri sağlanmıştır. Bu sırada deneklerden alınan fizyolojik parametrelerden KHB, EDA, Sıcaklık parametreleri bu sınıflandırma çalışması için öznitelik oluşturmak amacıyla kullanılmıştır.

Ham verilerden doğrudan elde edilen öznitelikler ile önerilen pencereleme ve segmentasyon ile çıkarılan KHB ve diğer öznitelikler K-EYK, DVM, RO gibi geleneksel sınıflandırıcılarla sınıflandırılmıştır. Tablo 3 ve 4'ü karşılaştırdığımızda, önerilen öznitelik çıkarma yaklaşımının sınıflandırma performansını artırdığını gözlemlenmektedir. Her iki yöntemde de en yüksek sınıflandırma doğruluğunu DVM sınıflandırıcısı sağlamıştır. Şekil 3'te DVM sınıflandırıcısıyla her bir kategori için elde edilen konfüzyon matrisleri önerilen yöntemin en iyi sevinç duygusunu ardından ise şaşkınlık ve nötr duyguları ayırt edebildiğini göstermektedir.

Bu çalışmada, tüketicilerin reklamlara karşı duygu durumu tahmini için fizyolojik sinyallerinin analizi amacıyla bir öznitelik çıkarma ve sınıflandırma yöntemi önerilmektedir. Önerilen yöntemin ham sinyallere göre daha yüksek sınıflandırma performansı sağladığını görülmektedir. Bu çalışma, Nöropazarlama alanında "Neurobiosense" veri seti üzerinde fizyolojik parametrelerin analizi ve sınıflandırılmasıyla tüketici tercihlerinin tanınmasına yönelik yaklaşım sunmaktadır. Elde edilen bulgular, pazarlama stratejilerinin geliştirilmesi ve tüketici davranışlarının anlaşılması için değerli bir katkı sağlayabilir. Ancak, gelecekteki çalışmalarda daha geniş veri setlerinin kullanılması ve farklı öznitelik çıkarma tekniklerinin test edilmesi gerekmektedir.

Devam eden çalışmalarda, önerilen yaklaşım farklı öznitelikler dahil edilerek genişletilecektir. Ayrıca, öznitelik çıkarma ve sınıflandırma için yeni yöntemlerin geliştirilmesine çalışılmaktadır. Veri setinin oldukça yeni olması sebebiyle, her ne kadar bu çalışmada elde edilen sonuçlar literatür ile karşılaştırılamasa da bu çalışma ile literatüre ilgili veri seti için karşılaştırma olanağı katkısı sağlanmıştır.

#### Teşekkür

Bu çalışmada kullanılan veri seti için "Neurobiosense" veri seti sağlayıcılarına teşekkür ederim. Bu çalışmada yer alan tüm veriler için gerekli etik izinler "Neurobiosense" veri seti sağlayıcıları tarafından alınmıştır.

#### Kaynakça

- [1] Aldayel, M., Ykhlef, M., Al-Nafjan, A. 2021. Recognition of consumer preference by analysis and classification EEG signals. *Frontiers in Human Neuroscience*. 14, 604639.
- [2] Ceylan, B., TÜZÜN, S., Aydın, A. 2020. Detection of Consumer Preferences Using EEG Signals. *International Journal of Applied Mathematics Electronics and Computers*. 8 (4), 289–294.
- [3] Aldayel, M., Ykhlef, M., Al-Nafjan, A. 2020. Deep learning for EEG-based preference classification in neuromarketing. *Applied Sciences*. 10 (4), 1525.
- [4] Alsharif, A., Salleh, N.Z.M., Pileliené, L., Abbas, A.F., Ali, J. 2022. Current Trends in the Application of EEG in Neuromarketing: A Bibliometric Analysis. *Scientific Annals of Economics and Business*. 69 (3), 393–415.
- [5] Antiopi, P., Kalaitzi, E., Fidas, C.A. 2024. A Review on the Use of EEG for the Investigation of the Factors that Affect Consumer's Behavior. *Physiology & Behavior*. 114509.
- [6] Byrne, A., Bonfiglio, E., Rigby, C., Edelstyn, N. 2022. A systematic review of the prediction of consumer preference using EEG measures and machine-learning in neuromarketing research. *Brain Informatics*. 9 (1), 27.
- [7] Hammou, K.A., Galib, M.H., Melloul, J. 2013. The contributions of neuromarketing in marketing research.



- Journal of management research*. 5 (4), 20.
- [8] Telpaz, A., Webb, R., Levy, D.J. 2015. Using EEG to predict consumers' future choices. *Journal of Marketing Research*. 52 (4), 511-529.
- [9] Morin, C. 2011. Neuromarketing: the new science of consumer behavior. *Society*. 48 (2), 131-135.
- [10] Murugappan, M., Murugappan, S., Gerard, C. 2014. Wireless EEG signals based neuromarketing system using Fast Fourier Transform (FFT). içinde: 2014 IEEE 10th Int. Colloq. signal Process. its Appl., IEEE, ss. 25-30.
- [11] Hakim, A., Klorfeld, S., Sela, T., Friedman, D., Shabat-Simon, M., Levy, D.J. 2021. Machines learn neuromarketing: Improving preference prediction from self-reports using multiple EEG measures and machine learning. *International Journal of Research in Marketing*. 38 (3), 770-791.
- [12] Soria Morillo, L.M., García, J.A.A., Gonzalez-Abril, L., Ramirez, J.A.O. 2015. Advertising liking recognition technique applied to neuromarketing by using low-cost EEG headset. içinde: Bioinforma. Biomed. Eng. Third Int. Conf. IWBBIO 2015, Granada, Spain, April 15-17, 2015. Proceedings, Part II 3, Springer, ss. 701-709.
- [13] Guixeres, J., Bigné, E., Ausin Azofra, J.M., Alcaniz Raya, M., Colomer Granero, A., Fuentes Hurtado, F. 2017. Consumer neuroscience-based metrics predict recall, liking and viewing rates in online advertising. *Frontiers in psychology*. 8 1808.
- [14] Garczarek-Bąk, U. 2018. Explicit and implicit factors that determine private labels' possible purchase: Eyetracking and EEG research. *International Journal of Management and Economics*. 54 (1), 36-49.
- [15] Yadava, M., Kumar, P., Saini, R., Roy, P.P., Prosad Dogra, D. 2017. Analysis of EEG signals and its application to neuromarketing. *Multimedia Tools and Applications*. 76 19087-19111.
- [16] Kocaçınar, B., İnan, P., Zamur, E.N., Çalşımşek, B., Akbulut, F.P., Catal, C. 2024. NeuroBioSense: A Multidimensional Dataset for Neuromarketing Analysis. *Data in Brief*. 110235.
- [17] Murugappan, M., Nagarajan, R., Yaacob, S. 2011. EEG Sinyalleri Kullanarak İnsan Duygularını Sınıflandırmak için Mekansal Filtreleme ve Dalgacık Dönüşümünü Birleştirmek. *Tıbbi ve Biyoloji Mühendisliği Dergisi*. 31 (1), 45-51.
- [18] Singh, A.K. Krishnan, S. 2023. ECG signal feature extraction trends in methods and applications. *BioMedical Engineering OnLine*. 22 (1), 22.
- [19] Dagdevir, E., Tokmakci, M. 2021. Optimization of preprocessing stage in EEG based BCI systems in terms of accuracy and timing cost. *Biomedical Signal Processing and Control*. 67 102548.
- [20] Altman, N.S. (1992) An introduction to kernel and nearest-neighbor nonparametric regression. *The American Statistician*. 46 (3), 175-185.
- [21] Vapnik, V. 1995. Support-vector networks. *Machine learning*. 20 273-297.
- [22] Breiman, L. 2001. Random forests. *Machine learning*. 45 5-32.