NÖHÜ Müh. Bilim. Derg. / NOHU J. Eng. Sci., 15 (2026), 1737373

Niğde Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi
Niğde Ömer Halisdemir University Journal of Engineering Sciences

Araştırma makalesi / Research article

www.dergipark.org.tr/tr/pub/ngumuh / www.dergipark.org.tr/en/pub/ngumuh

Nöropazarlama araştırmaları için EEG bağlantısallık analizi ile tüketici karar alma tercihlerinin belirlenmesi

Determining consumer decision-making preferences with EEG connectivity analysis for neuromarketing research

Nagihan İlhan[1], Eda Dağdevir[2,*]

[1] *Kayseri Üniversitesi, Lisansüstü Eğitim Enstitüsü, Elektrik Elektronik Mühendisliği Anabilim Dalı, 38280, Kayseri Türkiye*
[2] *Kayseri Üniversitesi, Teknik Bilimler Meslek Yüksekokulu, Elektronik ve Otomasyon Bölümü, 38280, Kayseri Türkiye*

Öz

Bu çalışmada, EEG sinyallerinden çıkarılan işlevsel bağlantısallık ölçümleri kullanılarak bireylerin satın alma kararlarının sınıflandırılmasını amaçlamaktadır. NeuMa veri seti kullanılarak, her deneğe ait EEG kayıtlarından üç farklı bağlantısallık ölçütü olan Faz Kilitleme Değeri (FKD), Koherens ve Karşılıklı Bilgi (KB) öznitelikleri elde edilmiştir. Elde edilen öznitelikler, Destek Vektör Makineleri (DVM), K-En Yakın Komşu (KEYK), Rastgele Orman (RO) ve Yapay Sinir Ağları (YSA) gibi dört farklı makine öğrenme yöntemiyle sınıflandırılmıştır. Sınıflandırma performansı, doğruluk, duyarlılık, kesinlik ve F1-skoru ve sınıflandırma eğitim süresi metrikleri kullanılarak değerlendirilmiştir. Elde edilen sonuçlara göre, en yüksek doğruluk oranı %89.93 ile RO algoritmasında ve tüm özniteliklerin birlikte kullanıldığı durumda elde edilmiştir. En hızlı eğitim süresi ise FKD özniteliklerinin kullanıldığı model de DVM sınıflandırıcısı ile 3.2 s olarak elde edilmiştir. Sonuç olarak, EEG tabanlı bağlantısallık ölçümlerinin tüketicilerin karar alma durumlarının modellenmesinde oldukça etkim olduğu ortaya konmuştur. Bu nedenle bu çalışmada oluşturulan model, özellikle nöropazarlama, zihinsel sağlık takibi ve beyin-bilgisayar arayüzü uygulamalarında potansiyel kullanım alanlarına sahiptir.

Anahtar kelimeler: Nöropazarlama, EEG, Sinyal işleme, Yapay zekâ, Makine öğrenmesi

Abstract

This study aims to classify decisions of consumer using functional connectivity measures extracted from EEG signals. Three different connectivity measures, such as; Phase Locking Value (PLV), Coherence and Mutual Information (MI) are obtained from the EEG signals of each subject in the NeuMa dataset. The obtained features are classified by four different machine learning methods such as Support Vector Machines (SVM), K-Nearest Neighbour (KNN), Random Forest (RF) and Artificial Neural Networks (ANN). Classification performance is evaluated using accuracy, sensitivity, precision and F1-score and classification training time metrics. According to the results, the highest accuracy rate of 89.93% was obtained in the RF algorithm and when all features were used together. The fastest training time is obtained as 3.2 s with the SVM classifier in the model with only PLV features. Consequently, EEG-based connectivity measurements are quite effective in modelling consumer decision-making process. Therefore, the signal processing model developed in this study has potential areas of use, especially in neuromarketing, mental health monitoring and brain-computer interface applications.

Keywords: Neuromarketing, EEG, Signal processing, Artificial intelligence, Machine learning

1 Giriş

Pazarlama stratejileri, teknolojik ve bilimsel gelişmeler doğrultusunda evrim geçirmekte olup, son dönemde nörobilim ve bilgisayar bilimi gibi alanlarla etkileşime girerek daha bütüncül ve bilim temelli stratejiler geliştirmeye yönelmiştir. Bu bağlamda, tüketici davranışlarını daha derinlemesine analiz etmeyi amaçlayan nöropazarlama disiplini, pazarlama araştırmalarında önemli bir alanı ortaya koymuştur. Nöropazarlama, tüketicilerin bilinçdışı tepkilerini fizyolojik ölçümler aracılığıyla inceleyerek, pazarlama stratejilerinin daha etkili biçimde şekillendirilmesini amaçlayan yenilikçi bir yaklaşımdır. Bu alanda gerçekleştirilen araştırmalar, tüketici tercihlerini daha derinlemesine anlamak amacıyla elektroensefalografi (EEG) gibi beyin sinyali analiz yöntemlerinin kullanımını ön plana çıkarmaktadır [1-3].

Nöropazarlamanın amacı, tüketici davranışlarını yönlendiren nörofizyolojik süreçleri (örneğin dikkat, hafıza, duygulanma) ölçümleyerek geleneksel pazarlama araştırmalarının sınırlılıklarını aşmak ve daha güvenilir, objektif veri elde etmektir. Nöropazarlama araştırmaları, tüketicilerin satın alma kararlarının yalnızca mantıksal ve bilinçli değerlendirmelere dayanmadığını, aynı zamanda duygusal süreçlerden büyük ölçüde etkilendiğini ortaya koymaktadır. Tüketiciler bir ürünü değerlendirirken, o ürünle ilgili hissettikleri duygular (örneğin güven, heyecan, hoşlanma ya da kaygı) kararlarını doğrudan

* Sorumlu yazar / Corresponding author, e-posta / e-mail: edadagdevir@kayseri.edu.tr (E. Dağdevir)
Geliş / Received: 08.07.2025 Kabul / Accepted: 19.10.2025 Yayımlanma / Published: 15.01.2026
doi: 10.28948/ngumuh.1737373

etkileyebilmektedir. Bu duygusal tepkiler, çoğu zaman bireyin farkında olmadan verdiği kararları şekillendirir. Nöropazarlama, bu tür bilinçdışı tepkileri anlamak için EEG gibi nörofizyolojik verileri analiz eder. Bu alanda yapılan bilimsel araştırmalar, tüketicilerin belirli ürün veya markalara yönelme eğilimlerini açıklamakla kalmayıp, aynı zamanda bir alışveriş kararı alma sürecinde hangi duygusal ve bilişsel faktörlerin etkili olduğunu anlamamıza da katkı sağlamaktadır [4, 5]. Her ne kadar EEG temelli duygu tanıma üzerine kapsamlı araştırmalar yapılmış olsa da mevcut çalışmaların çoğu sınırlı deneysel koşullarda gerçekleştirilmiş olup, gerçek yaşam senaryolarına genellenebilirlik açısından önemli sıkıntılar taşımaktadır.

Nöropazarlama alanında yapılan çalışmalardan, Javid Farhadi Sedehi ve arkadaşları [6] satın alma tercihlerini belirlemek için yaptıkları sinyal işleme çalışmasında; ön işleme aşamasında EEG ve EKG sinyallerini gürültü ve istenmeyen sinyallerden arındırmışlardır ve hesaplama yükünü azaltmak için örnekleme frekansı düşürmüşlerdir. Daha sonra EEG kanalları ortalamaya göre yeniden referanslanmıştır. Sinyaller 5 saniyelik kayma pencereleriyle bölünerek, durağanlık testi yapılmış ve segmentlerin geçerliliği kontrol edilmiştir. Öznitelik çıkarma aşamasında EEG-EKG etkileşimi, 3 etkili bağlantı (Effective Connectivity, EC) yöntemi ile belirlenmiştir. Bu yöntemlerden elde edilen 3 etkili bağlantı matrisleri, 35x35 boyutlarında renkli görüntüler olarak CNN giriş verisine dönüştürülmüştür.5 farklı frekans bandında (delta, theta, alpha, beta, gamma) işlem yapılmıştır. Sınıflandırma aşamasında, ResNet-18, MobileNetV2 modelleri kullanılmıştır. Sınıflandırma aşaması, 4 duygu için; mutluluk, korku, iğrenme ve üzüntü, 5-kat çapraz doğrulama (5-fold CV) yöntemi ile test edilmiştir ve sınıflandırma doğruluk değeri 97.34% ± 1.19 olarak alpha frekans bandında DTF yöntemiyle elde edilmiştir. Mounir Ouzir ve arkadaşları [7] satın alma tercihlerini analiz etmek amacıyla yaptıkları sinyal işleme çalışmasında; ön işleme aşamasında 14 kanallı EEG cihazı kullanmışlardır. EEG verileri, Savitzky-Golay filtresi ile gürültüden arındırılmıştır. Öznitelik çıkarımı için Dalgacık Dönüşümü yöntemi uygulanmış ve Daubechies 4 (DB4) dalgacığı kullanılmıştır. Bu işlemde 5 farklı frekans bandı elde edilmiştir: delta (1–4 Hz), theta (4–8 Hz), alpha (8–13 Hz), beta (13–22 Hz) ve gamma (32–100 Hz). Öznitelik çıkarım aşamasında, zaman serisi EEG verileri doğrudan sınıflandırıcılar için giriş olarak kullanılmıştır ve herhangi bir öznitelik seçimi yapılmadan tüm kanallardan gelen EEG verileriyle modelleme yapılmıştır. Sınıflandırma aşamasında, 4 farklı makine öğrenme algoritması kullanılmış ve bu modeller ile 10 katlı çapraz doğrulama yöntemiyle test edilmiştir. Sınıflandırma başarıları, farklı beyin bölgelerine göre değerlendirilmiştir. Elde edilen en yüksek sınıflandırma doğruluk oranı %75.7 olarak bulunmuştur. Aditya Amancharla ve arkadaşları [8] satın alma tercihlerini belirlemek amacıyla yaptıkları sinyal işleme çalışmasında; ön işleme aşamasında EEG ve EKG sinyalleri, gürültü ve istenmeyen sinyallerden temizlenmiştir. EEG için 0.5–100 Hz aralığında bir bant geçiren filtre uygulanmıştır. Ayrıca 50 Hz güç hattı paraziti, çentik filtre ile giderilmiştir. Bozucu etkiye sahip göz kırpma sinyalleri BBA (Bağımsız Bileşen Analizi) yöntemiyle kaldırılmıştır. EKG için, temel kaymalar DB4 dalgacığı ile düzeltilmiştir. Öznitelik çıkarım aşamasında, EEG sinyalleri için güç spektral yoğunluğu hesaplanarak her frekans bandında güç hesaplanmış ve özellikle alfa ve beta bandı güçleri Fp1, Fp2, Pz kanalları değerlendirilmiştir. EKG sinyalleri için ise R-R aralıkları tespit edilerek KHD (Kalp Hızı Değişkenliği) öznitelikleri çıkarılmıştır. Ayrıca her iki sinyal için de permütasyon entropisi hesaplanmış ve EEG ile EKG entropileri arasındaki Pearson korelasyonu kullanılmıştır. Sınıflandırma aşamasında, görev ve uyarana bağlı sinyal tepkisi analizi yapılmış, aromaterapi ve bilişsel görevler sırasında etkinlik veya rahatlama durumu belirlenmiştir. Bu aşamada, karar verme sürecine dair psikolojik çıkarımlar yapılmıştır. Doğruluk ve korelasyon verilerine bakıldığında, EEG ve EKG arasındaki korelasyon değerleri şu şekilde belirlenmiştir; Fp1 ve EKG: %93.2, Fp2 ve EKG: %92.4, Pz ve EKG:%91.76 ortalama korelasyon değeri ise %92.94 olarak elde edilmiştir. Cong Liu ve arkadaşları [9] satın alma tercihlerini belirlemek amacıyla yaptıkları sinyal işleme çalışmasında; ön işleme aşamasında EEG sinyalleri 30 saniyelik pencerelere ayrılmıştır. EEMD (Ensemble Empirical Mode Decomposition) yöntemi ile her sinyalden 7 adet Intrinsic Mode Function (IMF) çıkarılmış ve her IMF üzerinde gürültü azaltmak amacıyla ortalama alma işlemleri uygulanmıştır. Öznitelik çıkarım aşamasında, orijinal sinyal ve her bir IMF için istatistiksel, zaman alanı, kaotik analiz ve sembolik analiz yapılmıştır. Her epok için toplamda 88 öznitelik çıkarılmıştır. Sınıflandırma aşamasında, XGBoost algoritması kullanılmıştır. Eğitim ve test verileri, her veri kümesinde %80 eğitim ve %20 test olarak ayrılmıştır. Değerlendirme 5-kat çapraz doğrulama (5-fold CV) yöntemi ile yapılmıştır. Sonuç olarak, en yüksek doğruluk %93.1 olarak Sleep-EDF verisiyle 4 sınıf sınıflandırmada elde edilmiştir. Marian Núñez-Cansado ve arkadaşları [10] satın alma tercihlerini belirlemek amacıyla yaptıkları sinyal işleme çalışmasında; ön işleme aşamasında EEG ve Galvanik Deri Direnci (GDD) verileri toplanmıştır. EEG için kullanılan cihaz Emotiv Epoc olup, 128–256 Hz örnekleme frekansı ile 14 kanal üzerinden kaydedilmiştir. Katılımcılar, sırasıyla yüksek duygusal içerikli ve nötr içerikli reklamlara maruz bırakılmış ve EEG ile GDD sinyalleri eş zamanlı olarak kaydedilmiştir. Öznitelik çıkarım aşamasında, EEG verilerinden Frontal Alpha Asimetrisi (FAA) hesaplanmış, GDD verilerinden ise duygusal uyarılma düzeyleri çıkarılmıştır. Sınıflandırma aşamasında, katılımcılar iki gruba ayrılmıştır: Kontrol grubuna, sadece nötr içerikli 3 reklam izletilmiş, deney grubuna ise yüksek duygusal içerikli 3 reklam ve ardından nötr reklamlar izletilmiştir. Sınıflandırma, doğrudan bir makine öğrenme algoritması ile yapılmamış, bunun yerine FAA ve GDD sinyal analizine dayanarak karar verme eğilimi değerlendirilmiştir. Nöropazarlama alanında yapılan derleme çalışmada, Antiopi Panteli ve arkadaşları [7] bu alanda EEG verileri üzerinde genellikle şu işlemleri uygulandığını ortaya koymuştur. Ön işleme aşamasında; istenmeyen sinyallerin temizliği, bant geçiren filtreleme, zaman serisi segmentasyonu gibi adımlar, öznitelik çıkarımı aşamasında; Zaman Frekans Analizi, Güç Spektrumu

Analizi, Bant Gücü Öznitelikleri, Frontal Asimetri vb. teknikler ve sınıflandırma aşamasında DVM, Yapay Sinir Ağları gibi tekniklerin yaygın kullanıldığını göstermişlerdir. Duygusal içerikli reklamlara verilen tepkiye göre "satın alma" tahminleri Ortalama %88–93 oranında doğruluk ile sinyal işleme algoritmaları sayesinde tespit edilebilmektedir, sonucuna varılabilir. Ayrıca literatürde, NeuMa veri setini kullanarak yapılan nöropazarlama çalışmaları kapsamında, Syed Muhammad Usman ve arkadaşları [3] satın alma tercihleri için ön işleme aşamasında EEG verilerini, 0.5–45 Hz Butterworth band geçiren filtreden geçirmişlerdir, daha sonra Artifact Subspace Reconstruction (ASR), Fast Orthogonal Regression (FORCE) algoritmaları ile istenmeyen sinyallerin giderimi gerçekleştirmişlerdir. Göz Takibi (GT) verisinin ön işleme aşamasında ise Lineer interpolasyon ve Segmentasyon (1 saniyelik, %50 örtüşen pencereler) işlemleri yapmışlardır. Öznitelik Çıkarma aşamasında EEG için Spektral ve Zaman-frekans öznitelikleri ET için ise ilk bakış süresi, toplam bakış süresi, bakış ısısı haritası ve göz hareketlerinin sırası vb. öznitelikleri kullanılmıştır. Sınıflandırma aşamasında Stacking Ensemble Classifier ile %84.01 doğruluk elde etmişlerdir. Fotis P. Kalaganis ve arkadaşları [11] satın alma tercihleri için ön işleme aşamasında EEG verilerini 0.1–30 Hz bant geçiren filtreden geçirmişlerdir, ayrıca BBA algoritmaları ile istenmeyen sinyallerin giderimi gerçekleştirmişlerdir. GT verisinin ön işleme aşamasında zaman senkronizasyonu, hatalı verilerin temizlenmesi ve bakış noktalarının ilgi alanlarına eşleştirilmesi (2 saniye, %50 örtüşen pencereler) işlemleri yapılmıştır. Öznitelik çıkarma aşamasında EEG için güç spektral yoğunluğu öznitelikleri, ET için ise bakış süresi, bakış sayısı ve bakış sırası öznitelikleri kullanılmıştır. Sınıflandırma aşamasında SPDNet (simetrik pozitif tanımlı) algoritması kullanarak %72.18 doğruluk elde etmişlerdir.

Bu çalışmada ise NeuMa veri seti kullanılarak katılımcıların satın alma tercihlerinin EEG sinyal analizi ile belirlenmesi amaçlanmıştır. Bu amaçla, açık erişimli NeuMa veri setinden elde edilen EEG sinyalleri ön işleme aşamasında geçirilmiş ve daha sonra öznitelik çıkarımı için bağlantısallık temelli, FKD, Koherens, KB değerleri hesap edilmiştir. Son aşamada DVM, KEYK, RO, YSA modelleri ile sınıflandırma yapılarak oluşturulan modellerin başarımı ortaya konulmuştur.

Çalışmanın geri kalanı, gereçler ve yöntemler bölümünde veri seti açıklaması ve uygulanan sinyal işleme ve sınıflandırma prosedürünü içerecek şekilde; bulgular bölümü sinyal işleme prosedürü sonunda elde edilen öznitelik sınıflandırılması sonu elde edilen sonuçları açıklayacak şekilde ve tartışma ve sonuç bölümü, bu çalışmanın literatüre katkısını ve gelişmeye açık yönlerini vurgulayacak şekilde oluşturulmuştur.

2 Gereç ve yöntemler

2.1 Veri seti

NeuMa veri seti, çalışması S01,02,…,S42 olarak adlandırılan 42 katılımcıdan oluşmaktadır. Çalışmaya katılan kişilerin demografik dağılım ise 23 erkek ile 19 kadındır. NeuMa veri seti kapsamında süpermarketlerdeki 144 faklı ihtiyaç ürünlerini kapsayan broşürler kullanılmıştır. Bu broşürlerin her bir sayfasında 24 ürün bulunup altı ayrı broşür sayfası biçiminde sunulmuştur [12].

Tablo 1. NeuMa veri setinin özeti

Katılımcı sayısı	42 (23 erkek, 19 kadın)
Ürün sayısı	144
Sayfa sayısı	6 (her sayfada 24 ürün)
Ortalama seçim sayısı	Katılımcı başına 18 ürün
EEG cihazı	Wearable Sensing DSI24
EEG sinyali örnekleme frekansı	300 Hz
EEG elektrotları	21 kuru elektrot
Göz takip (ET) cihazı	Tobii Pro Fusion
Göz takip sinyali örnekleme frekansı	120 Hz

NeuMa veri seti ait detaylı bilgiler Tablo 1'de yer almaktadır. Katılımcıların 28 inç büyüklüğündeki LCD monitörden ortalama olarak 50 cm uzaklıkta pozisyonlandırılmıştır. Katılımcıların broşür sayfaları arasında geçiş yapmaları ve ilgili ürünü almaları, katılımcının farenin sol tuşuna tıklaması ile ilişkilendirilmiştir. Veri seti oluşturulması aşamasında kullanılan broşür sayfalarına ait örnekler Şekil 1'de verilmiştir [12]. NeuMa veri setinde EEG ve GT sinyalleri fare tıklamaları ve imleç hareketleri veri olarak toplanmıştır. Deney süreci bittikten sonra, katılımcılardan bireysel verilerini içeren bir çalışma anketi de alınmıştır. Elde edilen anket sonuçlarıyla katılımcıların kişisel bilgileri, satın alma tercihleri, broşürdeki ürünlere olan bilinme oranları ve bu ürünlerin satın alma sıklığı gibi çeşitli demografik ve davranışsal değişkenler hakkında bilgiler toplanmıştır. EEG, DSI-24 nörofizyolojik ölçüm cihazıyla bilgileri kaydedilmiştir. EEG sinyalleri 10-20 sistemine göre yerleştirilmiş P3, C3, F3, Fz, F4, C4, P4, Cz, Pz, Fp1, Fp2, T3, T5, O1, O2, F7, F8, T6, T4, (A1, A2 referanslar) olmak üzere 21 elektrottan 300 Hz örnekleme frekansı ile kaydedilmiştir. Veri seti üreticileri tarafından, veriler hem ham biçimde hem de ön işlenmiş şekilde sunulmuştur. Ön işleme kapsamında EEG sinyalleri 0.5–45 Hz bant geçiren filtre uygulanarak işlenmiş, ardından istenmeyen sinyallerin giderilmesi için ASR ve FORCE yöntemleri kullanılmıştır. GT verileri 120 Hz örnekleme frekansı ile göz hareketleri (x, y koordinatları ve pupil büyüklüğü) ve Tobii Pro Fusion göz izleme cihazıyla hem sol hem sağ göz için veriler toplanmıştır [3, 12].

Bu çalışma kapsamında, katılımcıların broşürleri inceleme ve sol fare tuşu seçimi ile satın almaya niyetlenme bilgilerinin nöropazarlama açısında değerlendirilmesi ve objektif bir çerçeve sunulması için açık erişimle NeuMa veri setine ait yalnızca EEG sinyalleri kullanılmıştır.

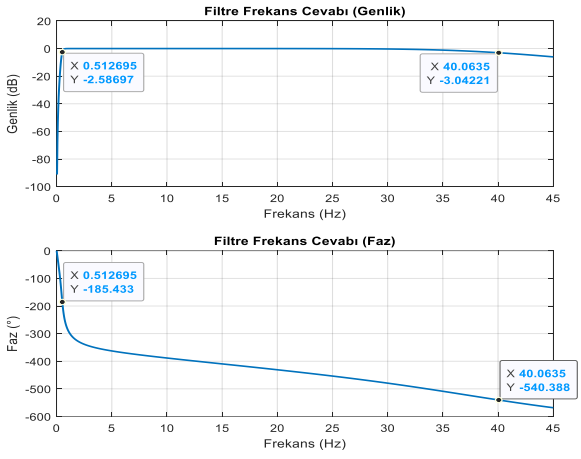
2.2 Ön işleme

Veri seti üreticilerinin uyguladığı analog ve dijital filtreleme adımlarına ek olarak bu çalışmada kullanılan tüm EEG verileri 50 Hz çentik filtreden ve 0.5-40 Hz aralığından



Şekil 1. Veri setinin oluşturulma sürecinde kullanılan broşürlerden örnek sayfa görseli ve EEG sinyali [12]

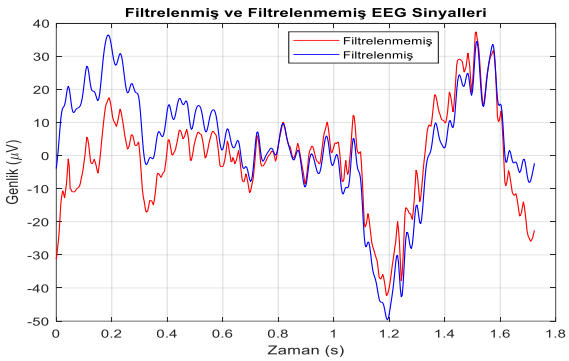
Şekil 2'de transfer fonksiyonu verilen 4. Dereceden Butterworth filtreden geçirilmiştir. Örneğin, çalışmada kullanılan 21 EEG kanalından biri olan F3 kanalı için filtrelenmiş ve ham sinyale 42 denekten biri olan S03 numaralı denek için Şekil 3'te gösterilmiştir. Ön işlemede EEG sinyali istenilen frekans bandında filtrelenir, böylece kanallar üzerindeki gürültü, istenmeyen sinyaller ve göz hareketleri temizlenir.



Şekil 2. 0.5-40 Hz bant geçiren Butterworth filtreye ait transfer fonksiyonu grafiği

2.3 *Öznitelik çıkarımı*

Ön işleme aşamasından sonra, katılımcıların EEG sinyallerinden anlamlı bilgi çıkarılmamak amacıyla, EEG sinyalleri arasındaki bağlantısallık analizi yaklaşımları kullanılmıştır. Bu amaçla, FKD, Koherens değeri ve KB öznitelikleri kanallar arasında hesaplanmıştır. Bu öznitelikler ilki olan FKD; iki EEG kanalı fazlarının zaman içinde ne kadar eş zamanlı olduğunu ölçer. Bu yöntem, yalnızca sinyalin faz bileşenine odaklanmaktadır. Duygusal uyarıcılara karşı farklı beyin bölgeleri arasındaki fazsal iletişimi ortaya koyar. FKD özellikle zihinsel aktiviteler de yüksek düzey bilişsel süreçlerde beyin bölgeleri arasındaki iletişimi değerlendirmek için kullanılır. FKD aşağıdaki işlem adımları ile hesap edilir.



Şekil 3. S03 numaralı deneğin F3 kanalı için filtrelenmiş ve filtrelenmemiş EEG kaydı

$H\{x(t)\}$, $x(t)$ zaman serisi sinyalinin Hilbert Dönüşümü olmak üzere; $\phi(t)$, sinyalin anlık fazıdır. Denklem 1 ve 2'de t sürekli zamanı, Denklem 3 ve 4'te k ise örnekleme frekansı ile elde edilen ayrık zamanı göstermektedir. $\Delta\phi_k$ faz farkı hesabını, k, her bir zaman örneğini, $\phi_1(k)$ve $\phi_2(k)$ indisleri iki farklı EEG kanalından elde edilen faz açılarını ifade eder. $e^{j(\Delta\emptyset k)}$, denklemdeki faz farkının belirli bir zaman noktasındaki karmaşık düzlemdeki temsil etmekle faz farklarının zaman içerisindeki ortalaması alınarak tutarlılığı hesaplanır ve mutlak değerin sonucu alındığında FKD, 0 ve 1 arasında ölçeklendirilir. ϕ_1 ve ϕ_2 indisleri iki farklı EEG kanalından elde edilen faz açılarını ifade etmektedir [15].

$$z(t) = x(t) + jH\{x(t)\} \quad (1)$$

$$\phi(t) = \arg\big(z(t)\big) = \arctan\left(\frac{x(t)}{H\{x(t)\}}\right) \quad (2)$$

$$\Delta\phi_k = \phi_1(k) - \phi_2(k) \quad (3)$$

$$FKD = \left|\frac{1}{N}\sum_{k=1}^{N} e^{j(\Delta\phi_k)}\right| \quad (4)$$

Koherens, EEG analizinde özellikle bağlantısallık ölçümlerinde sık kullanılan bir yöntemdir ve FKD'ye göre daha frekans alanı odaklıdır. Kanal sinyalleri için Fourier dönüşümü yapılır ve güç spektrumu ve çapraz-spektrum hesaplanır. Koherens, iki sinyal arasındaki spesifik bir frekans aralığına ne kadar benzer veya eşzamanlı olduklarını ölçen bir ölçüttür; başka bir değişle EEG'nin farklı elektrotlarından elde edilen sinyallerin frekans bandına özgü uyumunu sayısal olarak ifade eder. Böylece faz ve genlik bilgilerini dikkate alarak dikkat, karar verme ve duygusal bütünlük gibi bilişsel süreçlerin frekans bandına özgü beyin bölgeleri arası senkronizasyonunu değerlendirmektedir. İki zaman serisi x(t) ve y(t) (iki EEG kanalı) için güç spektral yoğunluğu ve çapraz spektral yoğunluk sırasıyla Denklem 5 ve 6 gösterildiği gibi tanımlanmıştır. Burada, $X_k(f)$ ve $Y_k(f)$ sırasıyla, K adet segmente ayrılmış x(t) ve y(t) sinyallerinin her bir segmenti için hesaplanan Ayrık Fourier dönüşümünü temsil etmektedir.

Güç Spektral Yoğunluğu (PSD):

$$S_{xx}(f) = \frac{1}{K}\sum_{k=1}^{K} X_k(f)X_k^*(f) \quad (5)$$

Çapraz spektral yoğunluk:

$$S_{xy}(f) = \frac{1}{K}\sum_{k=1}^{K} X_k(f)Y_k^*(f) \quad (6)$$

Pratikte, sonlu uzunluktaki EEG kayıtlarında bu operatör, sinyalin segmentlere ayrılmasıyla elde edilen Fourier katsayılarının ortalaması üzerinden tahmin edilmektedir. Bu çalışmada her EEG kaydı yaklaşık 2 saniye uzunluğundadır. Bu nedenle segment sayısı K=1 seçilmiştir ve Fourier dönüşümü doğrudan tüm segment üzerinden uygulanmıştır. Koherens fonksiyonu ise Denklem 7'de gösterildiği gibi ifade edilmektedir.

Koherens fonksiyonu:

$$C_{xy}(f) = \frac{\left|\hat{S}_{xy}(f)\right|^2}{\hat{S}_{xx}(f).\hat{S}_{yy}(f)} \quad (7)$$

burada, $S_{xx}(f)$ Güç Spektral Yoğunluğunu, $S_{xy}(f)$ Çapraz spektral yoğunluğu, $S_{yy}(f)$ Güç Spektral Yoğunluğu, $C_{xy}(f)$ koherens fonksiyonunu ifade eder [16]. Çalışmada kullanılan 21 kanaldan ikisi referans olmak üzere 19 kanal için her bir kanal çiftinden olmak üzere 171 farklı koherens değeri hesaplanmıştır. Koherens hesaplaması, alt frekans bantları (4–8 Hz Teta, 8–13 Hz Alfa, 13–30 Hz Beta) için yapılmıştır. Her bantta elde edilen koherens spektrumu, ilgili frekans aralığındaki tüm değerlerin ortalaması alınarak tek bir skaler öznitelik hâline getirilmiştir. Böylece her kanal çifti ve her alt bant için bir sayısal değer elde edilmiş, bu değerler sınıflandırıcıya girdi olarak kullanılmıştır.

KB, iki sinyal arasındaki ilişkisel durumu anlatan bir göstergedir. KB, hem lineer hem lineer olmayan bağımlılıkları tespit edebilir. KB değeri ile iki sinyal arasındaki bağımsızlık ve bağımlılık ilişkilerini vurgulamaktadır. KB değeri sıfır olduğunda sinyaller bağımsızdır, yüksek KB değeri ise sinyallerin birbirine bağımlı olduğunu ve yüksek bilgi paylaştığını göstermektedir. KB doğrusal olmayan bağımlılıkları inceleme, beyin ağı analizleri ve nörobiyolojik sinyallerin analizinde kullanılan bir yöntemdir.

İki kanal iki ayrık rastgele değişken olarak kabul edilmek üzere; X ve Y için KB aşağıdaki gibi hesap edilir.

$$I(X;Y) = \sum_{x\in X}\sum_{y\in Y} p(x,y)\, log\left(\frac{p(x,y)}{p(x)p(y)}\right) \quad (8)$$

Burada, $p(x,y)$, X ve Y'nin ortak olasılık dağılımını, $p(x)$ ve $p(y)$, X ve Y'nin tekil dağılımlarını ifade etmektedir. Bu çalışmada, EEG sinyalleri MATLAB ortamında "discretize" fonksiyonu ile eşit genişlikteki binlere ayrılarak ayrıklaştırılmıştır. Daha sonra her bin kombinasyonu için gözlenen frekanslar sayılarak $p(x,y)$ elde edilmiştir. $p(x)$ ve $p(y)$ ise ortak dağılımdan marjinal alınarak bulunmuştur. Bu şekilde elde edilen olasılık değerleri kullanılarak Denklem 8'e göre uygulanmış ve KB değerleri her kanal çifti için hesaplanmış ve simetrik bir matris oluşturulmuştur. Her matrisin üst üçgeni (diyagonal hariç) alınarak 1 boyutlu vektör hâline getirilmiştir ve bu vektör her denek için ayrı ayrı olmak üzere sınıflandırıcılara girdi olarak verilmiştir. Sonuç olarak bu üç metrik de beyin sinyalleri, biyosinyaller ve nörobiyolojik veriler üzerindeki etkileşimleri anlamada ve her biri farklı türdeki bağımlılıkları ölçmeye yarayan araçlardır. FKD, sinyallerin faz senkronizasyonunu, Koherens frekans düzeyindeki doğrusal ilişkiyi ve KB ise daha geniş bir açıdan bilgi paylaşımını ölçer. Bu çalışmada; FKD, Koherens ve KB değerleri her bir kanal çifti için hesap edilip öznitelik matrisi oluşturulmuştur.

2.4 Sınıflandırma

Elde edilen öznitelik matrisi MATLAB Classification Learner ToolBox aracılığı ile farklı sınıflandırıcılarla sınıflandırılmıştır. Bu amaçla, DVM, KEYK, RO, YSA sınıflandırıcıları kullanılmıştır.

2.5 Destek vektör makineleri

DVM, verileri farklı sınıflara ayırmak için kullanılan ve sonuçlardan en iyi sınır bulmaya çalışan sınıflandırmadır. DVM sınıflar arasındaki mesafeyi mümkün olduğunca büyük tutmaktadır ve doğrusal ya da doğrusal olmayan ayrım yapabilmektedir. Doğrusal olmayan ayrım için Kernel fonksiyonları kullanılmaktadır. Özellikle küçük-orta ölçekli veri setlerinde çok başarılı olduğu görülmüştür. Bu sınıflandırmanın avantajı karmaşık veriyle iyi çalışabilmek iken dezavantajları büyük veri kümelerinde eğitim süresinin uzun olması ve parametre seçiminin hassas olmasıdır [13-15].

2.6 K-En yakın komşu algoritması

KEYK algoritması yeni bir veriyi sınıflandırmak için en yakın k komşunun etiketine bakar ve çoğunluğa göre sınıflandırma yapar. Bu algoritmada eğitim süreci hızlı, tahmin süreci yavaştır. KEYK algoritmasında veriler arasında mesafe ölçümü önemlidir. Bu algoritma parametre ayarı dışında fazla ayar gerektirmez. Özellikle düşük boyutlu veri setlerinde daha hızlı ve anlamlı sonuçlar verir. Yüksek boyutlu verilerde bellek kullanımı fazla olduğundan dolayı performansı düşer ve tahminleme zamanı uzar. Test örneği x^{test} için, k- en yakın komşuyu bulmak amacıyla x_i^{train}ile x^{test} arasındaki mesafeyi hesaplayan $x_j{}^{test}$ve $x_{ij}{}^{train}$ sırasıyla test örneği ve eğitim verisinin j-inci özelliği Denklem 9'da verilmektedir. Burada n, karşılaştırılan veri noktalarının sahip olduğu öznitelik sayısını temsil eder [1, 13-17].

$$d(x^{test}, x_i^{train} = \sqrt{\sum_{j=1}^{n}(x_j{}^{test} - x_{ij}{}^{train})^2} \quad (9)$$

2.7 Rastgele orman algoritması

RO Algoritması bir sınıflandırma topluluğudur. Çeşitli alt veri setleri üzerinde eğitim yapan çok sayıda karar ağacından oluşmaktadır ve her karar ağacı, rastgele örneklem ile seçilen eğitim veri seti üzerinde eğitilir. Her düğümde bölünme için yalnızca özelliklerin rastgele seçilmiş bir alt kümesi kullanılır. Her ağacın tahmini $y_k$ile tüm topluluk sınıflandırması gerçekleştirilir. Burada, k toplam ağaç sayısı olmak üzere, y_k k-inci karar ağacının tahminini ifade eder. Toplam tahmin, her ağacın verdiği bireysel tahminlerin çoğunluğu ile belirlenir. RO her sınıf arasındaki korelasyonu düşürerek daha güçlü bir topluluk modeli oluşturur [13-15, 17]. Denklem 10'da y Rastgele Orman algoritmasının giriş örneği için verdiği toplu tahmini ifade etmektedir. çoğunluk, k tane karar ağacının verdiği tahminler arasında en fazla tekrar eden sınıf etiketini ifade eder.

$$y = \text{çoğunluk}(y_1, y_2 \dots y_k) \quad (10)$$

2.8 Yapay sinir ağları

YSA, mantığını biyolojik sinir ağlarından örnek alarak geliştirilmiş bir sınıflandırıcı türüdür. Yapay sinir ağları, birçok yapay düğümden oluşan katmanlar içerir ve her nöron, girdi sinyallerini işleyerek çıktı üretir. Yapay düğümler içerisindeki gizli katmanlar aracılığıyla doğrusal olmayan durumlar öğrenilir. Denklem 11'de bir nöronun aktivasyon giriş toplamını ifade etmektedir. Her bir nöron, ağırlıklı girişler ve bir aktivasyon fonksiyonu kullanarak bir çıkış üretir. Giriş katmanından gizli katmanlara doğru veri akışı sağlanarak matematiksel formülü oluşturulur, burada w ağırlıklar, x^{in} giriş vektörü ve b bias terimleri verilmiştir [13-15]. Bu çalışmada YSA sınıflandırması için aktivasyon fonksiyonu olarak ReLu kullanılmıştır. ReLU fonksiyonu, yapay zekâ metotlarında yaygın olarak kullanılan doğrusal olmayan bir aktivasyon fonksiyonudur. ReLU fonksiyonu, negatif girişleri sıfıra eşitleyerek etkisiz hale getirir, pozitif girişleri ise herhangi bir değişikliğe uğratmadan çıktıya aktarır.

$$z = w.x^{in} + b \quad (11)$$

2.9 Sınıflandırma performans metrikleri

Sınıflandırma yöntemlerinin başarımlarını ölçmek amacıyla karmaşıklık matrisleri temelinde, doğruluk, duyarlılık, kesinlik ve F1 skoru parametreleri hesaplanmıştır. Burada, Gerçek Pozitif (GP): pozitif sınıfa ait bir örneğin doğru şekilde pozitif olarak tahmin edilmesi durumları, Gerçek Negatif (GN): negatif sınıfa ait bir örneğin doğru şekilde negatif olarak tahmin edilmesi durumları, Yanlış Pozitif (YP): negatif bir örneğin yanlışlıkla pozitif olarak tahmin edilmesi durumları ve Yanlış Negatif (YN): Pozitif bir örneğin yanlışlıkla negatif olarak tahmin edilmesi durumları olmak üzere:

Doğruluk, sınıflandırıcının doğru sınıflandırdığı örneklerin toplam örnek sayısına oranı temsil eder. Bu durum aşağıdaki gibi hesaplanır [2].

$$Doğruluk = \frac{GP + GN}{GP + GN + YP + YN} \quad (12)$$

Duyarlılık, gerçek pozitiflerin doğru bir şekilde tahmin edilme oranını ölçer. Bu durum aşağıdaki gibi hesaplanır.

$$Duyarlılık = \frac{GP}{GP + YN} \quad (13)$$

Kesinlik, sınıflandırıcının pozitif olarak tahmin edilgi örneklerin ne kadarının gerçekten pozitif olduğunun ölçüsüdür. Bu durum aşağıdaki gibi hesaplanır.

$$Kesinlik = \frac{GP}{GP + YP} \tag{14}$$

F1 skoru, kesinlik ve duyarlılığın harmonik ortalamasını ifade eder.

$$F1\ skoru = 2\frac{Duyarlılık.Kesinlik}{Duyarlılık + Kesinlik} \tag{15}$$

Sonuç olarak sınıflandırıcıların performans değeri için GP, GN, YP ve YN değerleri kullanılarak elde edilmiştir.

3 Bulgular ve sonuçlar

Bu çalışmada, 42 farklı deneğin market broşür sayfalarındaki ürün görselleri içerisinden satın almak üzere ürün seçimi sırasında EEG sinyalleri toplanmıştır. Bu EEG sinyalleri ile satın alma durumları arasındaki ilişkinin belirlenerek, nöropazarlama çalışmaları açısından EEG analizlerinin faydası ortaya konmuştur. Bu amaçla, toplanan EEG sinyalleri, önişleme, öznitelik çıkarımı aşamalarında geçirilerek, veri seti oluşturucuları tarafından sağlanan satın alma durumları bilgisi ile sınıflandırmaya tabi tutulmuştur. Ön işleme aşamasında 50 Hz çentik filtre ve 4. Dereceden Butterworth bant geçiren filtre kullanılmıştır. Öznitelik matrisi; her denek, her broşür sayfası ve her sayfadaki ürünlerin görsellerini izlenmesi sırasındaki 19 EEG kanalı kombinasyonlarının FKD, Koherens, KB özniteliklerinden oluşmaktadır. Burada, 42 denek, 6 broşür sayfası ve her sayfada 24 farklı ürün için çalışma yürütülmüştür. Her ürünü deneklerin izlemesi ve/veya fare imleci tıklaması ile satın alması sırasında 19 kanal EEG kaydı verileri kullanılmıştır. 19 EEG kanalının kombinasyonundan bağlantısallık analizi amacıyla hesaplanan FKD, Koherens, KB değerlerinin her biri için 171 farklı kanal kombinasyonu oluşturulmuştur. Deneklerin ilgili ürünü fare imlecine tıklama durumu satın alma durumunu göstermek üzere bu bilgi, gerçek referans değer (ground truth) olarak sınıflandırma aşamasında kullanılmıştır.

Çalışmada elde edilen sınıflandırma sonuçları Tablo 2, Tablo 3, Tablo 4 ve Tablo 5'te özetlenmiştir. Tablo 2'de yalnızca FKD özniteliklerinin kullanıldığı, Tablo 3'te yalnızca Koherens özniteliklerinin kullanıldığı, Tablo 4'te yalnızca KB özniteliklerinin kullanıldığı, Tablo 5'te ise tüm özniteliklerin birlikte kullanıldığı sınıflandırma sonuçlarını göstermektedir.

Tablo 2. FKD öznitelikleri kullanılarak elde edilen sınıflandırma sonuçları

	DVM	KEYK	RO	YSA
Doğruluk	0.8021	0.6027	**0.8694**	0.8227
Duyarlılık	0.7657	0.2723	**0.8480**	0.8090
Kesinlik	0.8253	0.7991	**0.8855**	0.8312
F1-skoru	0.7943	0.4062	**0.8664**	0.8200
Eğitim süresi (s)	**3.2018**	5.4143	**27.018**	8.0243

Tablo 3. Koherens öznitelikleri kullanılarak elde edilen sınıflandırma sonuçları

	DVM	KEYK	RO	YSA
Doğruluk	0.7610	0.6876	**0.8513**	0.7514
Duyarlılık	0.7410	0.6319	**0.8753**	0.7293
Kesinlik	0.7712	0.7102	**0.8347**	0.7623
F1-skoru	0.7558	0.6687	**0.8545**	0.7454
Eğitim süresi (s)	3.7558	3.707	33.240	**1.0156**

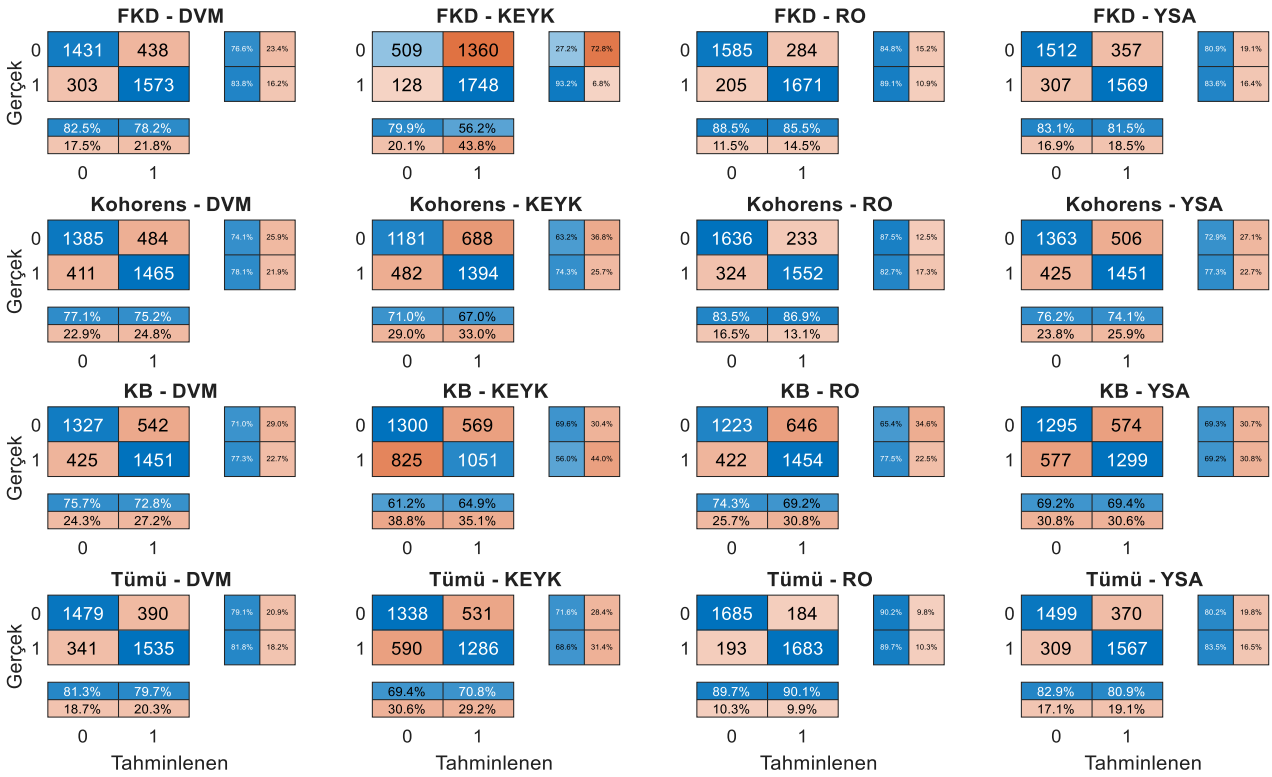
Tablo 4. KB öznitelikleri kullanılarak elde edilen sınıflandırma sonuçları

	DVM	KEYK	RO	YSA
Doğruluk	**0.7418**	0.6278	0.7148	0.6927
Duyarlılık	**0.7100**	0.6956	0.6544	0.6929
Kesinlik	**0.7574**	0.6118	0.7435	0.6918
F1-skoru	**0.7329**	0.6510	0.6961	0.6923
Eğitim süresi (s)	9.6174	3.4455	21.550	**2.1268**

Tablo 5. Üç bağlantısallık ölçütünün birlikte kullanılarak elde edilen sınıflandırma sonuçları

	DVM	KEYK	RO	YSA
Doğruluk	0.8048	0.7007	**0.8993**	0.8187
Duyarlılık	0.7913	0.7159	**0.9016**	0.8020
Kesinlik	0.8126	0.6940	**0.8972**	0.8291
F1-skoru	0.8018	0.7048	**0.8994**	0.8153
Eğitim süresi (s)	9.4268	**7.9349**	75.854	9.1515

Çalışmada kullanılan dört farklı sınıflandırıcı (DVM, KEYK, RO, YSA) ile üç farklı bağlantısallık ölçütü (FKD, Koherens, KB) ve tüm özniteliklerin birlikte kullanıldığı modellerde sınıflandırma performansları incelenmiştir. Burada, DVM sınıflandırıcısı lineer modelde kullanılmıştır, KEYK sınıflandırıcısının mesafe ağırlıkları eşit olacak şekilde mesafe metriği kosinüs ve komşuluk sayısı 10 seçilmiştir, YSA modeli tek katmanda 10 nöron olacak şekilde tasarlanmıştır. Ayrıca, tüm sınıflandırma modellerinde 5 kat çapraz doğrulama uygulanmıştır.



Şekil 4. Tüm modeller için karmaşıklık matrisleri

Elde edilen sonuçlar Tablo 2, 3, 4 ve 5'te verilmiştir. Ayrıca, sınıflar bazındaki başarı farklılıklarının ve genel sınıflandırma performanslarının karşılaştırmalı olarak sunulması amacıyla, Şekil 4'te kurulan tüm modeller için elde edilen karmaşıklık matrisleri yer almaktadır. Tablo 2'de görüldüğü gibi, FKD öznitelikleri kullanıldığında en yüksek başarı %86.94 doğrulukla RO modeline aittir. Tablo 3'te görüldüğü gibi Koherens özniteliklerinde yine RO modeli %85.13 doğrulukla öne çıkmıştır. Tablo 4'te görülmek üzere; KB öznitelikleriyle doğruluk genel olarak daha düşüktür; en yüksek başarı %74.18 ile DVM modeline aittir. Tablo 5'te ise tüm öznitelikler birlikte kullanıldığında en yüksek doğruluk %89.93 ile RO tarafından elde edilmiştir. Eğitim süresi açısından ise FKD öznitelikleri kullanıldığı durumda DVM, Koherens ve KB özniteliklerinin kullanıldığı durumda YSA, tüm özniteliklerin kullanıldığı durumda ise KEYK sınıflandırıcısı daha kısa sürede sınıflandırma işlemini tamamlamıştır.

Bu çalışmada elde edilen sonuçlar ile literatürde yer alan benzer çalışmaların karşılaştırılması Tablo 6'da sunulmuştur. Buna göre Liu vd [9] hariç olmak üzere literatürdeki diğer çalışmalardan daha yüksek doğruluk değeri ile tüketici karar alım tercihlerinin sınıflandırılması üzerine bir model önermektedir. Öte yandan bu çalışma literatürdeki diğer çalışmalardan farklı olarak nöropazarlama çalışmalarının nihai hedefi olan eş zamanlı sınıflandırma yeteneğinin önemli bir ölçüsü olan sınıflandırma süresini de dikkate alarak literatüre katkı sağlamaktadır.

Tablo 6. Literatürdeki çalışmalar ile bu çalışmanın karşılaştırılması

Çalışma	Öznitelik	Sınıflandırıcı	En yüksek Doğruluk (%)	En düşük Eğitim Süresi (s)
Ouzir vd. (2024) [7]	Dalgacık dönüşümü	YSA DVM, KEYK, RO	%75.7	-
Liu vd. (2021) [9]	EEMD + istatistiksel öznitelikler	XGBoost	%93.1	-
Usman vd. (2025) [3]	Zaman-frekans + ET öznitelikleri	Ensemble	%84.01	-
Kalaganis vd. (2023) [11]	PSD + ET öznitelikleri	SPDNet	%72.18	-
Bu çalışma	FKD, Koherens, KB	DVM, KEYK, RO, YSA	%89.93	1.0156

4 Tartışma ve öneriler

Elde edilen bulgular ışığında aşağıdaki sonuçlar elde edilmiştir:

- Tek başına kullanıldığında FKD ve Koherens öznitelikleri sınıflandırma başarısını artırırken, KB

öznitelikleri nispeten daha düşük performans sergilemiştir.

- Tüm özniteliklerin birlikte kullanımı, en yüksek doğruluk, duyarlılık, kesinlik ve F1-skorunu sağlamıştır. Bu da özniteliklerin birbirini tamamlayıcı bilgi taşıdığını göstermektedir.
- Rastgele Orman sınıflandırıcısı, dört modelin üçünde en yüksek doğruluk oranına ulaşmış, birinde ise ikinci sırada yer almıştır. Bu sonuç, RO'nun özellikle çok boyutlu ve karmaşık veri yapılarında güçlü genelleme kapasitesini ortaya koymaktadır.
- Yapay Sinir Ağı modelleri de yüksek performans sergilemiş, F1-skoru açısından RO ile yarışır düzeye ulaşmıştır.
- DVM, özellikle KB özniteliklerinde öne çıkmış ancak diğer modellerde RO ve YSA'nın gerisinde kalmıştır.
- KEYK, genel olarak düşük doğruluk ve F1-skoru değerleriyle en düşük başarıyı göstermiştir. Özellikle FKD öznitelikleriyle duyarlılık değeri yalnızca 0.27 seviyesinde kalmıştır.
- En uzun eğitim süresi RO sınıflandırıcısına ait olup, tüm özniteliklerle birlikte kullanıldığında 75.854 saniyeye ulaşmıştır.
- DVM ve KEYK, özellikle Koherens ve FKD öznitelikleriyle daha kısa sürelerde eğitilmiştir.
- YSA, orta seviyede eğitim süresiyle dengeli bir alternatif sunmuştur.

Tüm sonuçlar birlikte değerlendirildiğinde, RO sınıflandırıcısı yüksek başarı oranlarıyla öne çıkmaktadır. Ancak yüksek eğitim süresi göz önünde bulundurulduğunda, kaynak kısıtlı sistemlerde YSA veya DVM alternatif olarak tercih edilebilir. Ayrıca tüm bağlantısallık ölçütlerinin birlikte kullanılması, sınıflandırma performansını belirgin şekilde artırmaktadır. Bu nedenle çoklu öznitelik kombinasyonlarının kullanımı önerilmektedir. Özellikle nöropazarlama gibi gerçek zaman uygulamalarının önem taşıdığı alanlarda az öznitelik ile yüksek performans elde etmenin düşük zamanlarda yapılması oldukça önemlidir. Bu nedenle bu çalışmada modellerin eğitim süreleri de dikkate alınmıştır. Öte yandan, bu çalışma literatürdeki benzer araştırmalardan farklı olarak, nöropazarlama çalışmalarının nihai hedefi olan eşzamanlı sınıflandırma yeteneğinin önemli bir göstergesi durumundaki sınıflandırma süresini de dikkate almış ve bu yönüyle literatüre ek bir katkı sağlamıştır. Bu çalışma ilerleyen çalışmalarda, tüm bu kombinasyonların performans ve zaman açısından en optimum halini temsil edecek bir model kurularak geliştirebilir sonucuna varılmıştır.

Çıkar çatışması

Yazarlar çıkar çatışması olmadığını beyan etmektedir.

Benzerlik oranı (iThenticate): %7

Kaynaklar

[1] B. Ceylan, S. Tüzün and A. Aydın, Detection of consumer preferences using EEG signals. International Journal of Applied Mathematics Electronics and Computers,8(4), 289–294, 2020. https://doi.org/10.18100/ijamec.802214

[2] E. Dağdevir, Reklam izlenimi sırasında fizyolojik parametrelerin analizine dayalı tüketici tercihlerinin sınıflandırılması. Erciyes Üniversitesi Fen Bilimleri Enstitüsü Fen Bilimleri Dergisi, 40(2), 421–429, 2024.

[3] S. M. Usman, S. Khalid, A. Tanveer, A. S. Imran and M. Zubair, Multimodal consumer choice prediction using EEG signals and eye tracking. Frontiers in Computational Neuroscience, 18, 1516440, 2025. https://doi.org/10.3389/fncom.2024.1516440

[4] K. Georgiadis, F. P. Kalaganis, N. A. Laskaris, S. Nikolopoulos, and I. Kompatsiaris, Assessing video advertising engagement via nonlinear intersubject correlation analysis of EEG and eye tracking dynamics. 2024 32nd European Signal Processing Conference (EUSIPCO), pp. 957–961, 2024.

[5] I. Yfantidou, G. Tsourvakas, V. P. Oikonomou and I. Kompatsiaris, Consumer response to different discount sales promotional messages. An eye tracking and EEG experiment. 2024 32nd European Signal Processing Conference (EUSIPCO), pp. 962–966, 2024.

[6] J. F. Sedehi, N. J. Dabanloo, K. Maghooli, and A. Sheikhani, Develop an emotion recognition system using common connectivity between electroencephalogram and electrocardiogram signals. Heliyon, 11(2), 2025. https://doi.org/10.1016/j.heliyon.2025.e39811

[7] M. Ouzir, H. C. Lamrani, R. L. Bradley and I. El Moudden, Neuromarketing and decision-making: Classification of consumer preferences based on changes analysis in the EEG signal of brain regions. Biomedical Signal Processing and Control, 87, 105469, 2024. https://doi.org/10.1016/j.bspc.2023.105469

[8] A. Tyagi and V. Nehra, Classification of motor imagery EEG signals using SVM, k-NN and ANN. CSI Transactions on ICT, 4(2), 135–139, 2016. https://doi.org/10.1007/s40012-016-0091-2

[9] C. Liu, B. Tan, M. Fu, J. Li, J. Wang, F. Hou and A. Yang, Automatic sleep staging with a single-channel EEG based on ensemble empirical mode decomposition. Physica A: Statistical Mechanics and its Applications, 567, 125685, 2021. https://doi.org/10.1016/j.physa.2020.125685

[10] M. Núñez-Cansado, G. C. Méndez and D. Juárez-Varón, Analysis of the residual effect using neuromarketing technology in audiovisual content entrepreneurship. Sustainable Technology and Entrepreneurship, 3(3), 100069, 2024. https://doi.org/10.1016/j.stae.2023.100069

[11] K. Georgiadis, F. P. Kalaganis, V. P. Oikonomou, S. Nikolopoulos, N. A. Laskaris and I. Kompatsiaris, Harneshing the potential of EEG in neuromarketing with deep learning and Riemannian geometry. In International Conference on Brain Informatics, pp. 21-32, Switzerland,2023.

[12] K. Georgiadis, F. P. Kalaganis, K. Riskos, E. Matta, V. P. Oikonomou and I. Yfantidou, NeuMa—the absolute neuromarketing dataset en route to an holistic understanding of consumer behaviour. Scientific Data, 10(1), 508, 2023. https://doi.org/10.1038/s41597-023-02392-9

[13] M. Aldayel, M. Ykhlef and A. Al-Nafjan, Deep learning for EEG-based preference classification in neuromarketing. Applied Sciences, 10(4), 1525, 2020. https://doi.org/10.3390/app10041525

[14] O. Bazgir, Z. Mohammadi and S. A. H. Habibi, Emotion recognition with machine learning using EEG signals. IEEE 25th National and 3rd International Iranian Conference on Biomedical Engineering (ICBME), 1–5, 2018.

[15] J. P. Lachaux, E. Rodriguez, J. Martinerie and F. J. Varela, Measuring phase synchrony in brain signals. Human Brain Mapping, 8(4), 194–208, 1999. https://doi.org/10.1002/(sici)1097-0193(1999)8:4<194::aid-hbm4>3.0.co;2-c

[16] P. L. Nunez and R. Srinivasan, Electric Fields of the Brain: The Neurophysics of EEG, Oxford University Press, 2006.

[17] T. Cover and P. Hart, Nearest neighbor pattern classification. IEEE Transactions on Information Theory, 13(1), 21–27, 1967. https://doi.org/10.1109/TIT.1967.1053964