

Zihinsel İş Yükü Seviyelerinin EEG Alt Bantlarına Dayalı Sınıflandırılması

Classification of Mental Workload Levels Based on EEG Sub-Bands

Müge Dolu^{1*}, **Şerife Genç Benli²**

^{1*} ORCID: 0000-0002-7886-3098, ²ORCID: 0000-0002-5527-8574

^{1,2}Erciyes Üniversitesi, Biyomedikal Mühendisliği Bölümü, 38280, Talas, Kayseri, Türkiye

Geliş / Recieved: 30.06.2025 Kabul / Accepted: 22.07.2025 Yayımlanma / Published: 30.07.2025

Özet

EEG sinyalleri kullanılarak beyinde farklı durumlara verilen farklı yanıtlar ölçülerek analiz edilebilir. Bu çalışmada, NASA tarafından geliştirilen MATB-II görev tabanlı deney düzeneği kullanılarak elde edilen açık erişimli ve literatürde çok az incelenmiş bir EEG veri seti kullanılmıştır. Çalışmada, üç oturuma ait kolay, orta ve zor olmak üzere üç farklı zorluk seviyesi değerlendirilmiştir. Öncelikle veriler 0.5 Hz ile 45 Hz aralığına filtrelenmiş ve faz kayması giderilmiştir. Sonrasında verilere 4. dereceden ayrık dalgacık dönüşümü uygulanmış ve elde edilen katsayıların her birinden zaman, frekans ve entropi tabanlı 26 özellik olmak üzere toplam 130 özellik çıkarılmıştır. Ardışık ileri seçim yöntemi kullanılarak özellik çıkarımına gidilmiştir. Yapay sinir ağları, k-en yakın komşu ve rastgele orman algoritmaları kullanılarak kolay, orta ve zor seviyeler için sınıflandırmalar gerçekleştirilmiştir. En yüksek doğruluk oranı ikili sınıflandırma için kolay-orta sınıflandırma grubunun birinci oturumunda, rastgele orman algoritması ile %86,67 olarak elde edilmiştir. Tüm oturumların bir arada sınıflandırılmasında ise kolay-orta sınıflandırma grubunda rastgele orman algoritması ile %85,10 oranında en yüksek doğruluk görülmüştür. Genel olarak değerlendirildiğinde ise en yüksek sınıflandırma başarımları kolay-orta sınıf ayrımında elde edilirken, en yüksek doğruluk oranları ise k-en yakın komşu algoritması ile sağlanmıştır.

Anahtar kelimeler: Makine öğrenmesi, zihinsel iş yükü, EEG analizi

Abstract

Using EEG signals, different brain responses to varying conditions can be measured and analyzed. In this study, an open-access EEG dataset, obtained using the task-based experimental setup developed by NASA, MATB-II, and scarcely studied in the literature, was used. Three different difficulty levels (easy, medium, difficult) belonging to three sessions were evaluated in the study. First, the data were band-pass filtered between 0.5 Hz and 45 Hz, and phase distortion was eliminated. Next, a fourth-order discrete wavelet transform was applied, and from each of the resulting coefficients, 26 time-, frequency-, and entropy-based features were extracted 130 features in total. Feature extraction was then refined using the sequential forward selection method. Classifications were conducted for easy, medium, and difficult levels using artificial neural networks, k-nearest neighbor, and random forest algorithms. The highest accuracy rate for binary classification was 86.67% in the first session of the easy-medium classification group, achieved with the random forest algorithm. In the combined classification of all sessions, the highest accuracy rate was 85.10% with the random forest algorithm in the easy-medium classification group. Overall, the highest classification performance was achieved in the easy-medium class distinction, while the highest accuracy rates were achieved with the k-nearest neighbor algorithm.

Keywords: Machine learning, mental workload, EEG analysis

1. Giriş

Beyin fonksiyonları, birbirleriyle bağlantılı çalışan hücrelerden meydana gelmektedir [1]. EEG sinyalleri

beyindeki elektriksel aktiviteyi ölçer ve bu ölçümlerden faydalanılarak analizler yapılabilir. Bu sayede çeşitli hastalıklar, bilişsel durumlar, zihinsel iş yükü seviyeleri ve

* Sorumlu yazar/ Corresponding author, e-posta / e-mail: mugeedolu@gmail.com (M. Dolu)

duygu durumlarıyla ilgili çıkarımlar yapılabilmesine olanak tanınmış olur [2].

Bilişsel iş yükü; bir görevi, bir işi veya durumu gerçekleştirmek için meydana gelen zihinsel aktivite yoğunluğunu ifade eder. Bilişsel iş yükünün yönetimi, yapılan iş veya görevdeki hataların minimize edilmesine katkı sağlar [3]. İnsanların gerçekleştirdiği farklı aktivitelerde farklı bilişsel iş yükü seviyeleri meydana gelir. Aynı görevi gerçekleştiren farklı kişilerde de psikolojik durumlar, çevresel faktörler, kişinin yapılan iş konusundaki tecrübesine dayalı olarak da bilişsel iş yükü seviyelerinde farklılıklar görülebilmektedir [4].

Beynin farklı durumlarda ürettiği yanıtların incelenmesi geniş bir araştırma alanı oluşturmaktadır. Yapılan analiz ve değerlendirmeler iş kazalarının önlenmesini, araç ve ortam düzenlemelerinin iyileşmesini sağlayabilmektedir [5]. Bu konuda yapılmış farklı çalışmalar mevcuttur.

Mahsa ve ark zihinsel iş yükü ve stres düzeyinin sınıflandırmasını üzerine bir çalışma gerçekleştirmişlerdir. Çalışmada 18 katılımcıya ait 64 kanallı EEG verileri kullanılmıştır. 500 Hz örnekleme frekansına sahip veriler 1 Hz-45 Hz aralığında filtrelenmiştir. Alt bantlar kullanılarak özellik çıkarımı yapılmış ve transfer öğrenme tekniği ile zihinsel iş yükü için ortalama %77, stres durumu için ise ortalama %84 oranında başarımlar elde edilmiştir [6].

Jung Ho ve ark EEG verilerini kullanarak tehlike değerlendirmesi amacıyla sanal gerçeklik ile inşaat tehlikeleri üzerine bir sınıflandırma çalışması gerçekleştirmişlerdir. Yapılan çalışmada sanal gerçeklik yardımıyla inşaat kazaları simüle edilmiş ve EEG kayıtları alınmıştır. Bu verilerden istatistik ve frekans tabanlı özellikler çıkarılmıştır. LightGBM algoritması ile sınıflandırma yapılmış ve en yüksek başarımlar %82,3 olarak elde edilmiştir [7].

Houtan ve ark yapmış oldukları çalışmada EEG verilerini kullanarak inşaat işçilerindeki stres seviyelerini incelemişlerdir. Üç farklı inşaat sahası veri toplamak için kullanılmış, 14 kanallı EEG ile verilerin elde edilmesi sağlanmıştır. EEG sinyallerinden elde edilen zaman ve frekans tabanlı özellikler çıkarıldıktan sonra destek vektör makineleri kullanılarak gerçekleştirilen sınıflandırmada %80,32 oranında doğruluk elde edilmiştir [8].

Dehais ve ark zihinsel iş yükü seviyelerini değerlendirmek için 2 oturumda gerçekleşen uçuş simülatörü deneti yapmış ve 32 kanal içeren EEG veri seti elde etmişlerdir. Alt bant gücü özelliklerini kullanarak öznelik vektörü elde edildikten sonra sınıflandırma yapılmış ve %89,1 oranında zihinsel iş yükünün ayırt edilmesini sağlamışlardır [9].

Bu çalışma, birinci yazar tarafından Erciyes Üniversitesi, Fen Bilimleri Enstitüsü'nde yapılan 'Farklı Uyarın Türlerinin EEG Sinyalleri Üzerinden Analizi' isimli tezden üretilmiştir [10]. Çalışmada açık erişimli veri setinden [11] elde edilen görev tabanlı EEG veri setinden MATB görev tabanlı çalışmasına ait EEG verileri alınmış ve 0.5 Hz ile 45 Hz aralığında butterworth filtre uygulanmıştır. Çalışmada örnekleme frekansı 125 Hz olarak seçilmiştir. Filtreleme işleminden sonra ayırık dalgacık dönüşümü kullanılarak özellik çıkarma işlemine gidilmiş, böylece sinyalin daha detaylı incelenmesi sağlanmıştır. Özellik çıkarma işleminde

ayırık dalgacık dönüşümü katsayılarının (cA,cD) her birinden 26 adet olmak üzere toplam 130 özellik içeren öznelik matrisi elde edildikten sonra ardışık ileri seçim (sequential forward selection, SFS) ile özellik seçimine gidilmiştir. Rastgele orman, k-EYK ve yapay sinir ağları algoritmaları ile sınıflandırmaya gidilmiştir.


Açık erişimli ve literatürde henüz pek az kullanılmış olan veri seti ile çalışılması, oturumların ayrı ayrı değerlendirildiği gibi toplu halde tek bir oturum gibi değerlendirilmiş olması, özellik çıkarımında çok sayıda özelliğin değerlendirilmesi, özellik seçiminde ardışık ileri seçim algoritmasının tercih edilmesiyle aşırı öğrenmenin engellenmesi bu çalışmayı özgün kılan unsurlardır. Ayrıca ayırık dalgacık dönüşümü kullanılarak EEG sinyallerinin alt bantlarının da incelenmesiyle, orijinal EEG verilerinden elde edilemeyen ayırt edici özelliklerin değerlendirilmesine olanak tanımıştır.

2. Yöntem

Bu çalışmada açık erişimli veri seti elde edildikten sonra veriler filtrelenmiş ve faz kayması engellenmiştir. Filtrelenmiş verilere ayırık dalgacık dönüşümü uygulanarak elde edilen cA, cD katsayılarından özellik çıkarımı ve özellik seçimi yapılmış sonrasında yapay sinir ağları, k-en yakın komşu ve rastgele orman algoritmaları ile sınıflandırmaya gidilmiştir.


2.1. Veri seti

Bu çalışmada analiz edilen veri seti, farklı uyarınların bir arada bulunduğu ve farklı bilişsel durumları içeren EEG sinyallerinden oluşan veriler içermektedir. Her bir katılımcının birer haftalık arayla toplamda 3 oturuma dahil edildiği görev tabanlı veri seti, Toulouse Üniversitesi'nde 11 kadın ve 18 erkekten oluşan toplam 29 katılımcının 64 kanallı EEG verilerinden meydana gelmektedir. Yaş ortalamaları 23,9 olan katılımcılardan 14 katılımcı lisans derecesine sahipken 13 katılımcı ise yüksek lisans derecesine sahiptir. Verilerin örnekleme frekansı 500 Hz'dir. Aynı testlerin birer haftalık arayla üç oturumda gerçekleştirilmesi, farklı zamanlarda elde edilmiş aynı göreve ait üç verinin incelenmesine olanak tanımaktadır. Çalışmada kullanılan 64 kanallı EEG'den TP9 kanalı çıkarılarak 63 kanallı bir EEG veri seti elde edilmiştir. Farklı oturumlarda elektrot konumlarının değişmemesi için 3D tarama kameraları ve elektrot lokalizasyonunu destekleyen eklentilere yer verilmiştir [11]. Elektrot konumları Şekil 1'de gösterilmiştir.



Şekil 1. EEG elektrot konumları [11]

Bu çalışmada kullanılan veri setinden Multi-Attribute Task Battery-II (MATB-II) görev tabanlı 3 oturumluk kolay, orta ve zor olmak üzere 3 zorluk seviyesinden oluşan veri seti bölümü kullanılmıştır. MATB-II görev tabanlı çalışmasına ait deney düzeneği Şekil 2’de verilmiştir.



Şekil 2. MATB-II deney düzeneği [11]

NASA tarafından görev dağılımı değişiminde zihinsel iş yükü seviyelerinin ölçülmesi amacıyla tasarlanmıştır. Katılımcılara tamamlamaları için 4 görev belirtilir. Burada 4 ana görevin deneye dahil edilip edilmemesi ve her bir ana görevin kendi içerisindeki zorluk seviyelerinin değişmesi, katılımcıların bu süreçlerdeki zihinsel iş yüklerinin saptanmasına olanak sağlar. Deney düzeneğinde belirtilen 4 görev: izleme, sistem izleme, iletişim ve kaynak yönetimidir. İzleme görevi sağ üst bölümde yer alır, ekranda hareketli bir hedef bulunur ve katılımcıların joystick yardımıyla hedefin merkezde kalmasını sağlamaları gerekmektedir. Sistem izleme görevi sol üst bölümde yer alır. Katılımcıların buradan gösterge ışıklarını kontrol etmesi ve belirtilen tuşlara basarak tepki vermeleri beklenmektedir. İletişim görevi sol alt kısımda yer alır. Burada katılımcıların belirli

radio frekansları seçmeleri, kendilerine iletilen mesajlara göre ilgili tuşlara basıp kendileri ile alakalı olmayan mesajları göz ardı etmeleri beklenmektedir. Son olarak kaynak yönetimi görevinde ise 8 adet pompa, 2 adet yakıt tankı ve 4 adet yardımcı tank bulunmaktadır. Katılımcılardan iki yakıt tankında da eşit yakıt kalmasını sağlamaları istenmektedir. Bunu gerçekleştirirken de 8 adet pompayı etkinleştirmeleri veya devre dışı bırakmaları gerekmektedir. Görevlerin seviyesine göre kolay, orta ve zor olmak üzere 3 farklı deney düzeneği oluşturulmuştur. Kolay deney düzeneğinde kullanıcılar izleme ve sistem izleme görevlerini gerçekleştirmişlerdir. Orta zorluk seviyesinde izleme, sistem izleme ve kaynak yönetimi görevi kullanılarak 3 alt görev belirlenmiştir. Zor seviyede bulunan deney düzeneğinde ise tüm alt görevler dahil edilip kullanıcı bu görevlerin tamamını gerçekleştirmektedir [11].

Veri setinden MATB görevine ait veriler elde edildikten sonra sinyaller filtelenmiş ve filtrelenmiş sinyallere 4. dereceden ayırık dalgacık dönüşümü uygulanarak özellik çıkarımına gidilmiştir.

2.2. Butterworth filtre ile sinyallerin filtelenmesi

EEG verilerinde istenmeyen gürültüler görülebilmektedir. Sinyal analizi yapılırken doğru sonuçlar elde edebilmek için sinyaldeki bu bölümlerin filtelenmesi gerekmektedir [12]. Bu çalışmada 4. dereceden Butterworth bant geçiren filtre ile EEG sinyali 0.5 Hz ile 45 Hz aralığına filtelenmiştir. Böylelikle sinyal gürültüden arındırılmıştır. Sinyal işleme sırasında faz kaymasını engellemek için, filtreleme işlemi ileri ve geri yönde iki kez uygulanmış böylelikle sıfır faz gecikmesi sağlanmıştır.


2.3. Ayırık dalgacık dönüşümü

EEG sinyallerinde düşük frekans bilgisi önemlidir. Bu gibi durumlarda büyük zaman aralıklarının kullanımını sağlayan ve farklı bölgelere sahip pencereleme tekniği olan dalgacık analizi sıkça tercih edilmektedir [13].

Dalgacık dönüşümü 2 parametreden oluşmaktadır. Bunlardan birincisi dalgacığın zaman boyunca ötelenmesini sağlayan öteleme parametresi, ikinci ise fonksiyonun genişleyip daralmasını gerçekleştiren ölçek fonksiyonudur [14].

Sinyaller frekans spektrumlarına ayrıldığı için her bir bölge kendi içerisinde değerlendirilebilmektedir. Bu da durağan olmayan sinyallerin belirli bölgelerinin zaman frekans domeninde işlenmesi için avantaj sağlamaktadır [15].

Bu çalışmada dalgacık çeşitlerinden biri olan Daubechies dalgacık türünden Db4 dalgacı kullanılmıştır. Şekil 3’te 4. dereceden ayırık dalgacık dönüşümü uygulanan sinyal verilmiştir.



Şekil 3. Ayırık dalgacık dönüşümü uygulanmış sinyal

Ayırık dalgacık dönüşümü sonrası elde edilen katsayılar kullanılarak özellik çıkarımı yapılmış ve elde edilen bu verilerle sınıflandırmaya gidilmiştir.

2.4. Öznitelik vektörünün elde edilmesi

Özellik çıkarma, elde edilen EEG sinyallerinden belirli özelliklerin çıkarılmasıyla öznitelik vektörünün elde edilmesidir. EEG sınıflandırma çalışmalarında çok sayıda öznitelik çıkarma yöntemi kullanılmaktadır. Çıkarılan her öznitelik sınıflandırmada etkili sonuç vermeyebilir, bundan dolayı sınıflandırmaya doğrudan etki edecek spesifik özelliklerin seçilmesi gerekmektedir [16].

Bu çalışmada filtrelenmiş ve ayırık dalgacık dönüşümü uygulanmış sinyallerden çıkarılan özellikler: Aritmetik ortalama, alt bant gücü oranları, Hjorth parametreleri, medyan, birinci ve ikinci fark, normalize birinci ve ikinci fark, çarpıklık, basıklık, maksimum ve minimum değerler, autoregressive model katsayıları, ortalama eğri uzunluğu, medyan, birinci ve ikinci fark, normalize birinci ve ikinci fark, ardışık varyasyon logaritmik kök toplamı, varyans, enerji, standart sapma, aralık, shannon entropi, sıralı varyans toplamıdır.

EEG sinyallerinden özellik çıkarımı için ilk olarak 4. dereceden ayırık dalgacık dönüşümü uygulanmış ve böylelikle cA ve cD (cD1,cD2,cD3,cD4) katsayıları elde edilmiştir. Zaman, frekans ve entropi özelliklerini elde edebilmek için toplamda 26 özellik, dalgacık dönüşümünden elde edilen 5 alt banda uygulanmıştır. Böylelikle toplamda 130 özellik içeren bir öznitelik vektörü elde edilmiştir.


Elde edilen öznitelik vektöründen en uygun özelliklerin seçilebilmesi için sequential feature selection algoritması [17] uygulanmıştır. Böylelikle en belirgin özellikler seçilerek sınıflandırmaya gidilmesi sağlanmıştır. Her

sınıflandırmada seçilen özellikler değişmekle birlikte 130 özelliğin toplamda %15 kadarı seçilmiştir.

Elde edilen öznitelik matrisi kullanılarak yapay sinir ağları (YSA), k- en yakın komşu (k-EYK) ve rastgele orman (RO) algoritmaları ile sınıflandırmaya gidilmiştir.

2.5. K-en yakın komşu algoritması

Eğitim ve sınıflandırma algoritmalarını içeren k-EYK, eğitim algoritmasında veri setinin bu kısmında yer alan her bir veriyi eğitim örnekleri sınıfına dahil ederken, sınıflandırma algoritmasında ise veriye en yakın olan k adet örneği veriyi temsil edecek şekilde etiketler. Oluşturulan sınıf etiketlerine göre veri, kendisine yakın olan sınıfa dahil olur [18]. K-EYK algoritmasının çalışma prensibi Şekil 4'te verilmiştir.




Şekil 4. k-EYK algoritması

Bu çalışmada k-EYK algoritması kullanılırken öklidyen mesafe kullanılmış ve k değeri 11 olarak seçilmiştir. 10 kat çapraz doğrulama ile çalıştırarak doğruluk ve F skoru elde edilmiştir.

2.6. Yapay sinir ağları

Yapay sinir ağları, beynin çalışma prensibine göre tasarlanmış bir algoritmadır. Nöronlardan oluşan algoritma eğitim, sınıflandırma ve veri ilişkilendirme işlemlerini gerçekleştirmektedir [19].

Öğrenmenin matematiksel olarak algoritmaya dönüştürülmesiyle oluşmuştur. Nöronlar işlemci elemanı, dendritler toplama fonksiyonu ve hücre gövdesi de transfer fonksiyonu olarak özdeşleştirilebilir [20]. Yapay sinir ağlarının çalışma prensibi [21] Şekil 5'te gösterilmiştir.




Şekil 5. Yapay sinir ağı algoritması

Bu çalışmada 10 katmanlı yapay sinir ağı algoritması kullanılmış ve 10 kat çapraz doğrulama ile doğruluk ve F skoru değerleri elde edilmiştir.

2.7. Rastgele Orman Algoritması

Karar ağaçları algoritması dallar, yapraklar ve karar düğümlerinden meydana gelmektedir. Ağacın yaprakları olarak belirtilen verilerin test edilmesine dayalı bir yöntemdir. Rastgele orman algoritmasında birden çok karar ağacı kullanılır ve her bir ağaç farklı bir etiket üzerinde eğitilerek çeşitli modeller oluşturulur, böylelikle sınıflandırma gerçekleştirilir [22].

Algoritmada her bir örnek için karar ağacı oluşturulur ve her bir karar ağacının tahmini sonucu verilir. Tahmin sonucunda ortaya çıkan tahmin değerleri arasından en çok oylanan değer sonucu oluşturur [23]. Şekil 6'da rastgele orman algoritmasının çalışma prensibi verilmiştir.



Şekil 6. Rastgele orman algoritması

Bu çalışmada 10 kat çapraz doğrulama yapılmış ve 300 ağaç seçilerek hesaplama yükü ve sınıflandırma başarımı açısından iyi bir denge yakalanmıştır.

3. Bulgular ve Tartışma

Yapılan çalışmada yapay sinir ağı, k-EYK ve rastgele orman algoritmaları kullanılarak öncelikle oturumlar kendi aralarında kolay, orta ve zor olmak üzere sınıflandırılmış böylelikle doğruluk ile F skoru değerleri elde edilmiştir. Sonrasında ise 29 kişiden oluşan 3 oturum birleştirilerek 87 kişilik bir veri aynı şekilde kolay, orta ve zor olmak üzere sınıflandırılmıştır.

Oturumlara ait sınıflandırma sonuçları Tablo 1-3'te verilmiştir.

Tablo 1. Birinci oturumun yüzde doğruluk ve F skoru değerleri

1.Oturum	YSA		k-EYK		RO	
	Doğruluk	F skoru	Doğruluk	F skoru	Doğruluk	F skoru
Kolay-orta	79	78	83	82	86,67	87
Kolay-zor	82,67	86	84,33	86	77,67	79
Orta-zor	53,33	61	58,67	58	48	54

Tablo 2. İkinci oturumun yüzde doğruluk ve F skoru değerleri

2.Oturum	YSA		k-EYK		RO	
	Doğruluk	F skoru	Doğruluk	F skoru	Doğruluk	F skoru
Kolay-orta	77,67	76	84	84	77	76
Kolay-zor	75,67	76	82,33	81	82	83
Orta-zor	50,33	56	60,67	61	50,33	54

Tablo 3. Üçüncü oturumun yüzde doğruluk ve F skoru değerleri

3.Oturum	YSA		k-EYK		RO	
	Doğruluk	F skoru	Doğruluk	F skoru	Doğruluk	F skoru
Kolay-orta	77	76	82,67	82	82,33	81
Kolay-zor	74,67	77	78	78	70,67	72
Orta-zor	54,33	58	56,67	61	63	68

Sınıflandırma sonuçlarında 1. oturum incelendiğinde kolay-orta sınıflandırmasında en yüksek sonuç rastgele orman algoritmasından %86,67 ile elde edilmiştir. Kolay-zor sınıflandırmasında ise en yüksek başarımlar %84,33 ile k-EYK algoritmasında görülmektedir. Orta-zor sınıflandırmasında en yüksek başarımın k-EYK algoritmasından elde edilmesiyle birlikte orta-zor sınıflandırma grubundaki başarımların diğer sınıflandırmalardan düşük olduğu görülmektedir.

2. oturum incelendiğinde ise en yüksek doğruluk oranları kolay-orta sınıflandırmasında %84, kolay-zor sınıflandırmasında %82,33 ve orta-zor sınıflandırmasında %60,67 olarak tüm sınıflandırmalarda k-EYK ile en yüksek başarımların elde edildiği görülmüştür. Bu sınıflandırma da en yüksek doğruluk oranı kolay-orta, en düşük doğruluk oranı orta-zor sınıflandırmasında elde edilmiştir.

3. oturum incelendiğinde ise kolay-orta sınıflandırmasında %82,67 ve kolay-zor sınıflandırmasında %78 doğruluk oranlarıyla en yüksek başarımlar k-EYK algoritmasında elde edilmiştir. Orta-zor sınıflandırmasında ise %63 olarak en yüksek doğruluk oranı rastgele orman algoritmasında görülmüştür.

Tüm oturumlar incelendiğinde kolay-orta sınıflandırmasındaki başarımların, kolay-zor ve orta-zor sınıflandırmalarındaki başarımlardan yüksek olduğu görülmektedir. Bununla birlikte tüm oturumlarda en düşük doğruluk oranları orta-zor sınıflandırmalarında görülmektedir.

Tüm oturumlar birlikte incelenmiş ve kolay, orta ve zor bölümlerin sınıflandırmaları yapılmıştır. Sınıflandırma sonuçları Tablo 4'te gösterilmiştir

Tablo 4. Tüm oturumların birlikte sınıflandırmasının yüzde doğruluk ve F skoru değerleri

Tüm oturumlar	YSA		k-EYK		RO	
	Doğruluk	F skoru	Doğruluk	F skoru	Doğruluk	F skoru
Kolay-orta	80,36	80	82,25	82	85,10	85
Kolay-zor	79,97	79	82,68	82	81,57	81
Orta-zor	46,60	45	55,33	57	53,66	53

Tüm oturumların birleştirildiği sınıflandırma sonuçları incelendiğinde, en yüksek doğruluk oranı %85,10 olarak kolay-orta sınıflandırmasında rastgele orman algoritmasında görülmektedir. Kolay-zor algoritmasında ise en yüksek doğruluk oranı %82,68 olarak k-EYK algoritmasında görülmektedir. Orta-zor sınıflandırması diğer sınıflandırmalarda olduğu gibi bu sınıflandırmada da diğer sınıflandırma gruplarına göre düşük doğruluk oranları içermektedir.

Kullanılan veri seti ile yapılan başka bir çalışma incelendiğinde, Wang ve arkadaşları tarafından yapılan çalışmada MATB ve n-back görev tabanlı çalışmalarına ait EEG verileri kullanılarak sınıflandırma yapılmıştır. Veri setindeki 29 kişinin 63 kanallı EEG verileri kullanılarak yapılan çalışmada güç spektral yoğunluğu ile öznelitektör vektörü elde edilmiş ve en yüksek başarımlar SCDA algoritması ile aynı görevin farklı oturumları arasında %75,39 $\pm$ %9,56 olarak elde edilmiştir [24].

Olivier ve arkadaşları, zihinsel iş yükü ile ilgili çalışmalarda hareket ve diğer yaygın artefaktların sinyal kalitesini etkilediğini ve bu durumun zihinsel iş yükünü değerlendirme performansını azalttığını belirtmiş ve MATB görev tabanlı çalışmasını kullanarak EEG sinyallerine filtreleme yapıp sınıflandırma gerçekleştirmişlerdir. 48 katılımcıdan görev sırasındaki EEG verileri elde edilmiş ve rastgele orman algoritması ile yapılan sınıflandırmada %95 doğruluk elde edilmiştir [25].

Chandra ve arkadaşları, NASA tarafından geliştirilen MATB-II tabanlı EEG veri seti ile çalışmışlardır. 10 kişiye ait 14 kanallı EEG veri seti kullanılmıştır. Kanallardan güç spektral yoğunluğu ile özellik çıkarılarak yapay sinir ağları ile sınıflandırmaya gidilmiştir. Başarımlar oranları %46,7 ile

%90 aralığında elde edilmiştir. En yüksek başarımlar oranı ise AF3 kanalından %90 olarak elde edilmiştir [26].

Zhang ve arkadaşları yapmış oldukları çalışmada 22-25 yaş aralığında 10 katılımcı ile MATB görev tabanlı çalışması üzerine çalışmışlardır. 32 kanallı EEG veri seti kullanılmıştır. Elde edilen verilere PCA uygulandıktan sonra farklı algoritmalarla sınıflandırmalar yapılmıştır. GCN spektral evrişim yöntemi kullanılarak yapılan sınıflandırmada %86,3 oranında en yüksek doğruluk elde edilmiştir. [27].

Bu çalışmada ise 29 kişinin 63 kanallı EEG verileri, diğer çalışmalara göre daha fazla sayıda özellik ile incelenmiş ve performansların kıyaslanarak değerlendirilmesi amacıyla farklı algoritmalar kullanılarak sınıflandırma işlemi gerçekleştirilmiştir. Elde edilen sonuçlar literatürdeki diğer çalışmalarla uyumludur. Veriler 3 oturumda ayrı ayrı değerlendirilmiş, sonrasında oturumlar birleştirilerek her bir zorluk seviyesine ait 87 veri içeren daha geniş bir veri seti oluşturulmuş ve bu veri seti üzerinden yeniden sınıflandırma işlemi yapılmıştır. Oturum sayısı ilerledikçe sınıflandırma başarımlarında düşüş görülmesine rağmen, farklı oturumlarda benzer bileşenler bulunması nedeniyle tüm oturumların birleştirilerek sınıflandırması da başarılı sonuçlar vermiştir.

Genel bir değerlendirme yapıldığında kolay-orta sınıflandırmasının doğruluk oranları diğer sınıflandırma gruplarına göre daha yüksektir. Orta-zor sınıflandırmasında da diğer sınıflandırma gruplarından daha düşük doğruluk değerleri elde edilmiştir. En yüksek başarımlar genel olarak k-EYK algoritmasından elde edilirken en düşük başarımlar ise yapay sinir ağları algoritmasından elde edilmiştir.

4. Sonuçlar

Görev tabanlı çalışmalar ve zihinsel iş yükü değerlendirmeleri çok derin bir araştırma alanı yaratır. Sınıflandırma sonuçlarını incelediğimizde görmekteyiz ki; insan beyni farklı durumlara farklı yanıtlar verse de farklı kişilerde aynı göreve ait zihinsel iş yükü seviyelerinde anlamlı benzerlikler görülmektedir. Deney düzeneklerinin tasarlanma şekli de bu konuda önemli bir detaydır. Deney düzeneklerinde katılımcıların tecrübeleri, deneydeki zorluk seviyelerindeki değişimler sınıflandırma sonuçlarına yansır. Sınıflandırma sonuçlarına göre bu çalışmada kullanılan veri setine ait deney düzeneği için bir değerlendirme yapıldığında, kolay-orta deney düzenekleri arasındaki farkın, orta-zor deney düzeneğine göre daha belirgin olduğu görülmektedir.

Dördüncü derece ayrık dalgacık dönüşümünden elde edilen katsayılardan özellik çıkarımıyla 130 özellik içeren bir öznetelik matrisi elde edilmiştir. Bu matrisi ardışık ileri seçim algoritması ile %15-20 seviyelerine indirilmiş fakat sınıflandırma performansında anlamlı bir düşüş yaşanmamıştır.

Sınıflandırma algoritmalarında yapay sinir ağları için katman sayısı, rastgele orman algoritması için ağaç sayısı ve k-EYK için komşu sayısı gibi parametrelerin doğru seçimi, model performansında belirleyici etkiye sahiptir.

4.1. Kısıtlar ve Gelecekteki Çalışmalar

Kullanılan veri setinde katılımcı sayısı kısıtlıdır, daha geniş bir katılımcı grubu ile deneyin tekrarlanması önerilmektedir. Deney düzeneklerinin daha belirgin şekilde ayrılması zihinsel iş yükü farkını daha tutarlı bir şekilde ortaya çıkaracaktır. Zorluk derecelerinin veya iş yükü seviyelerinin daha net şekilde tanımlanması, katılımcıların tecrübe düzeyine uygun ve kontrollü ayrılmış deney düzenekleri geliştirilmesi, sınıflandırma performansının artmasına ve zihinsel iş yükü seviyelerinin daha hassas ve güvenilir şekilde belirlenmesine olanak tanıyacaktır.

Farklı ön işleme ve özellik çıkarma yöntemleri kıyaslanarak sınıflandırma performanslarına etkisi değerlendirilebilir, derin öğrenme yöntemleri ve farklı sınıflandırma algoritmaları ile elde edilen başarımlar kullanılarak en uygun modeller araştırılabilir.

Elde edilen sonuçlar, EEG verilerinden zihinsel iş yükü hesaplamaları yapılabileceğini göstermektedir. Bu durum iş kazalarının önlenmesinde, çevre ve çalışma koşullarının düzenlenmesinde, gerçek zamanlı kullanıcı durumu izleme sistemlerinde kullanılabilir.

Çıkar çatışması

Yazarlar çıkar çatışması olmadığını beyan etmiştir.

Benzerlik oranı (iThenticate): %5

Benzerlik oranı %5 olarak tespit edilmiştir.

Yapay Zeka Kullanım oranı:

Turnitin raporuna göre yapay zekâ kullanım oranı tespit edilmemiştir.

Araştırmacıların Katkı Oranı

Çalışma tasarımı Ş.G.B., veri analizi M.D., görselleştirme M.D., makale yazımı M.D., Ş.G.B.

Kaynaklar

- [1] Burke R. E.,2007. Sir Charles Sherrington's the integrative action of the nervous system: a centenary appreciation. *Brain : a journal of neurology*, 130(Pt 4), 887–894. [Doi:10.1093/brain/awm022](https://doi.org/10.1093/brain/awm022)
- [2] Üngüren, E.,2016. Beynin nöroanatomik ve nörokimsiyal yapısının kişilik ve davranış üzerindeki etkisi. *Akdeniz Üniversitesi, Uluslararası Alanya İşletme Fakültesi Dergisi*, 7(1).
- [3] Choi, M. K., Lee, S. M., Ha, J. S., Seong, P. H., 2018. Development of an EEGbased workload measurement method in nuclear power plants. *Annals of Nuclear Energy*, 111, 595-607. [Doi: 10.1016/j.anucene.2017.08.032](https://doi.org/10.1016/j.anucene.2017.08.032)
- [4] Lim WL, Sourina O, Wang LP., 2018 STEW: Simultaneous Task EEG Workload Data Set. *IEEE Trans Neural Syst Rehabil Eng.* 26(11),2106-2114. [Doi: 10.1109/TNSRE.2018.2872924](https://doi.org/10.1109/TNSRE.2018.2872924)
- [5] Wang, S., Gwizdka, J., Chaovalitwongse, W. A., 2016. Using wireless EEG signals to assess memory workload in the n-back task. *IEEE Transactions on HumanMachine Systems*, 46(3): 424-435. [Doi:10.1109/THMS.2015.2476818](https://doi.org/10.1109/THMS.2015.2476818)
- [6] Bagheri, M., Power, S. D., 2022. Simultaneous classification of both mental workload and stress level suitable for an online passive brain-computer interface. *Sensors (Basel)*, 22(2): 535. [Doi: 10.3390/s22020535](https://doi.org/10.3390/s22020535)
- [7] Jeon, J. H., Cai, H., 2022. Multi-class classification of construction hazards via cognitive states assessment using wearable EEG. *Advanced Engineering Informatics*, 53, 101646. [Doi: 10.1016/j.aei.2022.101646](https://doi.org/10.1016/j.aei.2022.101646)
- [8] Jebelli, H., Hwang, S., Lee, S. H., 2018. EEG-based workers' stress recognition at construction sites. *Automation in Construction*, 93: 315-324. [Doi:10.1016/j.autcon.2018.05.027](https://doi.org/10.1016/j.autcon.2018.05.027)
- [9] Dehais, F., Somon, B., Mullen, T., ve Callan, D. E., 2020. A neuroergonomics approach to measure pilot's cognitive incapacitation in the real world with EEG.

- Applied Human Factors and Ergonomics, 111-117.
[Doi: 10.1007/978-3-030-51041-1_16](https://doi.org/10.1007/978-3-030-51041-1_16)
- [10] Dolu M.,2024. Farklı uyaran türlerinin EEG sinyalleri üzerinden analizi. Yüksek lisans tezi, Erciyes Üniversitesi Fen Bilimleri Enstitüsü.
- [11] Hinss, M. F., Jahanpour, E. S., Somon, B., et al., 2023. Open multi-session and multitask EEG cognitive dataset for passive brain-computer interface applications. Sci Data, 10, 85. [Doi: 10.1038/s41597-022-01898-y](https://doi.org/10.1038/s41597-022-01898-y)
- [12] Kang X., Handayani D., Yaacob H.,2021. Comparison between butterworth bandpass and stationary wavelet transform filter for electroencephalography signal. IOP Conference Series: Materials Science and Engineering. [Doi:10.1088/1757-899X/1077/1/012024](https://doi.org/10.1088/1757-899X/1077/1/012024)
- [13] Guo T., Zhang T., Lim, E., Lopez Miguel., Ma F., Yu L., 2022. A Review of Wavelet Analysis and Its Applications: Challenges and Opportunities. IEEE Access, 10, 1-1. [Doi:10.1109/ACCESS.2022.3179517](https://doi.org/10.1109/ACCESS.2022.3179517)
- [14] Kumar, S. G. S., Sampathila, N., Tanmay, T., 2022.Wavelet based machine learning models for classification of human emotions using EEG signal. Measurement: Sensors, 24: 1-8. [Doi:10.1016/j.measen.2022.100554](https://doi.org/10.1016/j.measen.2022.100554)
- [15] Haşiloğlu, A., 2001. Dalgacık dönüşümü ve yapay sinir ağları ile döndürmeye duyarsız doku analizi ve sınıflandırma. Turkish Journal of Engineering and Environmental Sciences, 25: 405-413.
- [16] Yu C., Wang M., 2022. Survey of emotion recognition methods using EEG information. Cognitive Robotics. 2. 132-146. [Doi:10.1016/j.cogr.2022.06.001](https://doi.org/10.1016/j.cogr.2022.06.001).
- [17] Alakuş, TB, & Türkoğlu, İ. 2019. EEG Sinyallerine Dayalı Duygu Tahmininden Sıralı İleri Seçim Algoritması ile Özellik Seçimi. Sakarya Üniversitesi Fen Bilimleri Dergisi, 23(6), 1096-1105. [Doi:10.16984/saufenbilder.501799](https://doi.org/10.16984/saufenbilder.501799)
- [18] Nurul, I., Amiza, A., Ilyas, M., Razalli, M., 2017. The performance analysis of k nearest neighbors (K-EYK) algorithm for motor imagery classification based on EEG signal. MATEC Web of Conferences, 147: 1-8. [Doi:10.1051/mateconf/201714001024](https://doi.org/10.1051/mateconf/201714001024)
- [19] Gu, Y., Liang, Z., Hagihira, S., 2019. Use of multiple EEG features and artificial neural network to monitor the depth of anesthesia. Sensors (Basel), 19(15): 1- 11. [Doi: 10.3390/s19112499](https://doi.org/10.3390/s19112499)
- [20] Subasi A., Kiymik M., Alkan A., Koklukaya E.,2005. Neural network classification of EEG signals by using AR with MLE preprocessing for epileptic seizure detection, Mathematical and computational applications, vol. 10, no. 1, pp. 57-70. [Doi: 10.3390/mca10010057](https://doi.org/10.3390/mca10010057)
- [21] Karimi M., Arab F., 2020. Machine Learning Based Framework for Estimation of Data Center Power Using Acoustic Side Channel. [Doi: 10.48550/arXiv.2008.02481](https://doi.org/10.48550/arXiv.2008.02481)
- [22] Priyama, A., Gupta, R., Ratheeb, A., Srivastava, S., 2013. Comparative analysis of decision tree classification algorithms. International Journal of Current Engineering and Technology, 3(2): 1710-1714. [Doi:10.1155/2022/9449497](https://doi.org/10.1155/2022/9449497)
- [23] Damodar E., Kunal M., Gauri D., Shubham D., 2018. Classification of EEG data for human mental state analysis using Random Forest Classifier. Procedia Computer Science. 132. 1523-1532. [Doi:10.1016/j.procs.2018.05.116](https://doi.org/10.1016/j.procs.2018.05.116).
- [24] Wang, T., Ke, Y., Huang, Y., He, F., Zhong, W., Liu, S., Ming, D., 2024. Using semi-supervised domain adaptation to enhance EEG-based cross-task mental workload classification performance, IEEE Journal of Biomedical and Health Informatics, 28(12):7032-7039. [Doi:10.1109/JBHI.2024.3452410](https://doi.org/10.1109/JBHI.2024.3452410)
- [25] Albuquerque, R. O., Cassani, R., Gagnon, J. F., Tremblay, S., Falk, T. H., 2021. Adaptive filtering for improved EEG-based mental workload assessment of ambulant users. Frontiers in Neuroscience, 15: 611962. [Doi:10.3389/fnins.2021.611962](https://doi.org/10.3389/fnins.2021.611962)
- [26] Chandra S., Verma K., Sharma G., Mittal A., Jha D., 2015. EEG based cognitive workload classification during NASA MATB-II multitasking. International Journal of Cognitive Research in Science, Engineering and Education. 3. 35-42. [Doi:10.23947/2334-8496-2015-3-1-35-41](https://doi.org/10.23947/2334-8496-2015-3-1-35-41)
- [27] Zhang Z., Zhao Z., Qu H., Liu C., Pang L.,2023. A mental workload classification method based on GCN modified by squeeze-and-excitation residual. Mathematics 11, 1189. [Doi:10.3390/math11051189](https://doi.org/10.3390/math11051189)