

PAPER DETAILS

TITLE: Ayrik Dalgacık Dönüşümü ve Welch Yöntemini Kullanarak EEG Sinyallerinden Zihinsel İş Yükünün Derin Öğrenme ile Tespiti

AUTHORS: Hüseyin Can Ay, Osman Çetin, Sükrü Kitis

PAGES: 134-139

ORIGINAL PDF URL: <https://dergipark.org.tr/tr/download/article-file/2966054>

Ayrık Dalgacık Dönüşümü ve Welch Yöntemini Kullanarak EEG Sinyallerinden Zihinsel İş Yükünün Derin Öğrenme ile Tespiti

Hüseyin Can Ay^{1*}, Osman Çetin², Şükrü Kitiş³

^{1*} Dumlupınar Üniversitesi, Simav Teknoloji Fak., Elektrik Elektronik Müh. Bölümü, Kütahya, Türkiye (ORCID: 0000-0002-0333-4992), huseyin.ay1@ogr.dpu.edu.tr

² Dumlupınar Üniversitesi, Simav Teknoloji Fak., Elektrik Elektronik Müh. Bölümü, Kütahya, Türkiye (ORCID: 0000-0001-8988-5025), osman.cetin@dpu.edu.tr

³ Dumlupınar Üniversitesi, Simav Teknoloji Fak., Elektrik Elektronik Müh. Bölümü, Kütahya, Türkiye (ORCID: 0000-0003-3302-3359), sukr.kitis@dpu.edu.tr

(İlk Geliş Tarihi 21 Şubat 2023 ve Kabul Tarihi 22 Mayıs 2023)

(DOI: 10.5281/zenodo.10646796)

ATIF/REFERENCE: Ay, H. C., Çetin, O. & Kitiş, Ş. (2024). Ayrık Dalgacık Dönüşümü ve Welch Yöntemini Kullanarak EEG Sinyallerinden Zihinsel İş Yükünün Derin Öğrenme ile Tespiti. *Avrupa Bilim ve Teknoloji Dergisi*, (53), 134-139.

Öz

Zihinsel iş yükünü ölçmek için taşınabilirliği, kullanım pratikliği ve sinyal alımının kolaylığı gibi sebeplerle çoğunlukla Elektroensefalogram (EEG) sinyalleri kullanılmaktadır. EEG sinyallerinden özellik çıkartmak ve sınıflandırmak önemli bir konudur. Bu çalışmada, EEG sinyallerinin güç spektral yoğunluğu değerleriyle oluşturulan özniteliklerin, derin öğrenme ve makine öğrenmesi yöntemleriyle sınıflandırılması yapılmıştır. Derin öğrenme algoritmasıyla elde edilen sonuçların, klasik makine öğrenmesi algoritmalarına göre üstün olduğu gösterilmiştir. Öncelikle, katılımcılara matematiksel olarak iki farklı sayının birbirinden çıkartılması gibi aritmetik görevler verilmiştir. Katılımcıların dinlenme durumlarındaki ve aritmetik görev verildiği esnasındaki EEG sinyalleri kaydedilmiştir. EEG sinyallerine ayrık dalgacık dönüşümü (DWT) uygulanarak alt bandlar elde edilmiştir. Bandlara ait güç değerleri Welch yöntemiyle hesaplanmıştır. Her bir banddan gelen güç değerleri birleştirilerek öznitelik vektörleri oluşturulmuştur. Bu öznitelik vektörlerinin, uzun kısa dönem hafıza (LSTM) derin öğrenme algoritması ile destek vektör makinesi (SVM), doğrusal diskriminant analizi (LDA), k en Yakın Komşuluk (k-NN) gibi farklı makine öğrenmesi algoritmaları kullanılarak sınıflandırma işlemi yapılmıştır. Sınıflandırma sonucunda, her bir kanal için hesaplanan doğruluk, duyarlılık, özgüllük, F1 skoru ve kesinlik gibi performans metriklerinin ortalaması alınmıştır ve tablo halinde sınıflandırma algoritmalarının üstünlükleri karşılaştırılmıştır.

Anahtar Kelimeler: Ayrık Dalgacık Dönüşümü, Zihinsel İş Yükü, Derin Öğrenme, Welch Yöntemi

Detection of Mental Workload with Deep Learning from EEG Signals Using Discrete Wavelet Transform and Welch Method

Abstract

Electroencephalogram (EEG) signals are mostly used to measure mental workload for reasons such as portability, practicality of use and ease of signal reception. Extraction and classification of features from EEG signals is an important issue. In this study, the features created by the power spectral density values of the EEG signals are classified by deep learning and machine learning methods. It has been shown that the results obtained with the deep learning algorithm are superior to the classical machine learning algorithms. Firstly, the participants were given arithmetic tasks such as subtracting two different numbers from each other mathematically. The EEG signals of the participants at rest and during the arithmetic task were recorded. Subbands were obtained by applying discrete wavelet transform (DWT) to EEG signals. The power values of the bands were calculated with the Welch method. Feature vectors were created by combining the power values from each band. These feature vectors were classified using different machine learning algorithms such as long short-term memory (LSTM) deep learning algorithm and support vector machine (SVM), linear discriminant analysis (LDA), k-Nearest Neighborhood (k-NN). As a result of the classification, the performance metrics such as accuracy, sensitivity, specificity, F1 score and precision calculated for each channel were averaged and the superiority of the classification algorithms were compared in table.

Keywords: Discrete Wavelet Transform, Mental Workload, Deep Learning, Welch Method.

* Sorumlu Yazar: Dumlupınar Üniversitesi, Simav Teknoloji Fak., Elektrik Elektronik Müh. Bölümü, Kütahya, Türkiye (ORCID: 0000-0002-0333-4992) huseyin.ay1@ogr.dpu.edu.tr

1. Giriş

Zihinsel iş yükü, psikolojik, bilişsel veya motor bir eylemi gerçekleştirebilmek için gereken bilişsel kapasite miktarı olarak adlandırılmaktadır. Genellikle bir görevin gerçekleştirildiği şartlar ve kişilerin becerileri, davranışları ve algıları arasındaki etkileşimden meydana gelir. Zihinsel iş yükü genellikle, askeri pilotların, gemi mürettebatındaki kişilerin, hava trafik yönetim merkezlerinde çalışanların, cerrahi operasyon yapan doktoların ve otomobil kullanıcılarının vb. mesleklerdeki kişilerin zihinsel iş yüklerinin değerlendirilmesinde kullanılır. Son yıllarda, teknolojinin gelişmesiyle birlikte araştırmacılar tarafından beyin- bilgisayar arayüzü (BCI) sistemlerinde de kullanıcı performanslarını değerlendirmek için kullanılmaktadır [1-2].


Zihinsel iş yükünün değerlendirilmesinde çoğunlukla kişilerin fizyolojik ölçümlerine dayanan yöntemler kullanılır. Bu yöntemler, kişilere verilen zorlu ve kolay görevler esnasında kaydedilen fizyolojik verilerin değerlendirilmesi prensibine dayanmaktadır. Zihinsel iş yükünün değerlendirilmesinde kullanılan fizyolojik ölçüm teknikleri; kalp aktivitesi, solunum hızı, göz hareketleri ve göz kırpması hızı, termal aktivite, kas aktiviteleri ve beyin aktivitesi olarak sıralanabilir [3]. Çeşitli bilişsel aktiviteler sonucunda beyinde oluşan biyoelektriksel değişimleri yakalayabilme kabiliyeti sayesinde EEG tekniği, zihinsel iş yükü değerlendirmelerinde sıklıkla kullanılan bir tekniktir [4].

EEG tekniğinde, kişilerin kafa derisi üzerine belirli aralıklarla konumlandırılan elektrotlardan düşük genlikli biyoelektriksel sinyaller elde edilir. Amplifikatörler aracılığıyla elektrotlardan gelen bu düşük genlikli sinyaller yükseltilerek bilgisayar ortamında kaydedilir [5]. Yükseltilmiş sinyallerden öznitelik elde etmek için çeşitli istatistiksel, spektral veya zaman-frekans analizi yöntemleri kullanılır. Elde edilen bu öznitelikler herhangi bir yapay ağı algoritmasının girişine uygulanarak sınıflandırma işlemi gerçekleştirilir.

Bu çalışmada, öznitelik çıkarma işleminde DWT ile birlikte Welch yöntemleri kullanılmıştır. EEG sinyallerinin frekansa bağlı güç spektral yoğunluğu değerleri hesaplanarak öznitelik vektörleri oluşturulmuştur. Bu öznitelikler, LSTM derin ağı ve SVM, LDA, k-NN ve RF gibi makine öğrenmesi algoritmalarının eğitimi için kullanılmıştır. Eğitim sonucunda LSTM derin ağının diğer makine öğrenmesi algoritmalarına karşı üstünlüğü görülmüştür.

2. Materyal ve Metot

Şekil 1’de, önerilen yöntemin blok diyagramı gösterilmiştir. Ham EEG sinyallerinden özellik çıkarmak için DWT ile birlikte Welch yöntemi kullanılmıştır. 21 kanallı ve 500 Hz örnekleme frekansı ile alınan EEG verilerine DWT uygulanarak, 4 farklı frekans bandı (delta, teta, alfa ve beta) elde edilmiştir. Ardından bu bandların Welch yöntemiyle güç değerleri hesaplanmıştır. Elde edilen güç değerleriyle öznitelik vektörleri oluşturulmuştur. DWT ile Welch yöntemlerini kullanılarak elde edilen öznitelik vektörleri, LSTM derin ağı ile birlikte k-NN ve karar ağacı gibi makine öğrenmesi algoritmaları kullanılarak sınıflandırılmıştır. Sınıflandırma sonucunda dinlenme ve zihinsel iş yükü sınıflarına karşılık gelen çıktılar elde edilmiştir.



Şekil 1. Önerilen yöntemin blok diyagramı

2.1. EEG Veri Kaydı

Bu çalışmada, Zyma ve arkadaşları tarafından kaydedilen mental aritmetik görevlerin yerine getirilmesinden önce ve bu görevleri yerine getirilmesi sırasında kaydedilen EEG veri seti kullanılmıştır. Veri seti, EEG görsel muayenesinde uzman bir nörofizyolog tarafından 36 katılımcıdan (27 kadın, 9 erkek) kaydedilen verileri içermektedir. Kullanılan EEG veri seti, Kiev Taras Shevchenko Ulusal Üniversitesi “Biyoloji ve Tıp Enstitüsü” Eğitim ve Bilim Merkezi Biyoetik Komisyonu tarafından onaylanmış ve Dünya Tabipler Birliği (WMA) Helsinki Bildirgesi uyarınca her denekten yazılı bilgilendirilmiş onam alınmıştır. Bu çalışmada kullanılan EEG verilerinde Neurocom monopolar EEG 23-kanal sistemi kullanılmıştır. Elektrotlar simetrik şekilde kafa derisine Uluslararası 10-20 sistemine göre yerleştirilmiştir [6].

2.2. Ayırık Dalgacık Dönüşümü (DWT)

Ölçek ve öteleme parametreleri olan a ve b değişkenleri sürekli dalgacık dönüşümünde devamlı değişmektedir. Değişken olan a ve b parametrelerinin olası her bir değeri için dalgacık katsayılarının hesaplanması çok fazla işlem gerektiren bir süreçtir. Bu soruna etkili bir çözüm olarak sürekli dalgacık dönüşümündeki a ve b değişkenleri 2^r nin kuvveti olarak seçilir. Bu şekilde yapılan dönüşüm, ayırık dalgacık dönüşümü (DWT) olarak isimlendirilir. Giriş sinyalindeki veri sayısının çok fazla olduğu durumlarda DWT kullanmak oldukça hızlı ve verimlidir. Herhangi bir ölçek ve öteleme değeri olan dalgacık fonksiyonu ifadesi Eşitlik 1' deki gibi gösterilir [7].

$$\Psi_{a,b}(t) = \frac{1}{\sqrt{|a|}} \Psi\left(\frac{t-b}{a}\right) \quad (1)$$

Ölçek parametresi $a = 2^r$ ve öteleme parametresi $b = k2^r$ olmak üzere, bu parametreler Eşitlik 1' de yerine yazılırsa Eşitlik 2' de verilen dalgacık fonksiyonu elde edilir [7].

$$\Psi_{r,k}(t) = \frac{1}{\sqrt{|2^r|}} \Psi\left(\frac{t-k2^r}{2^r}\right) \quad (2)$$

Eşitlik 2' deki fonksiyon, sürekli dalgacık dönüşümü formülünde yerine yazılırsa, elde edilen ayırık dalgacık dönüşümü ifadesi Eşitlik 3' deki gibi gösterilir [8].

$$DWT_{r,k} = \frac{1}{\sqrt{|2^r|}} \int_{-\infty}^{\infty} x(t) \Psi\left(\frac{t-k2^r}{2^r}\right) dt \quad (3)$$

2.3. Welch Yöntemi

Spektral analiz yöntemlerinden biri olan Welch yönteminde, ilk olarak giriş sinyali istenen uzunluktaki segmentlere ayrılır. Bu segmentlere ait sinyaller, herhangi bir pencere fonksiyonuyla çarpılır ve hızlı Fourier dönüşümü uygulanarak yumuşatılmış periodogramlar elde edilir. Yumuşatılmış i. periodogram ifadesi Eşitlik 4' de ifade edilmiştir [9].

$$\hat{P}_i(f) = \frac{1}{M} \frac{1}{H} \left[\sum_{n=0}^{M-1} w[n] x_i[n] e^{-j2\pi f n} \right]^2 \quad (4)$$

Eşitlik 4' deki $w[n]$ parametresi pencere fonksiyonuna karşılık gelir. Çoğunlukla “hamming” adı verilen pencere seçilir. M değişkeni, segmentlerin uzunluğudur. H ise normalize edilen pencere fonksiyonudur. Normalize edilen pencere fonksiyonu ifadesi Eşitlik 5' te verilmiştir [9].


$$H = \frac{1}{M} \sum_{n=0}^{M-1} w[n]^2 \quad (5)$$

Yumuşatılmış periodogramların ortalaması alınarak Welch'in güç spektral tahmini elde edilir. Welch'in spektral tahmini Eşitlik 6' da gibi ifade edilir [9].

$$\hat{P}_{welch}(f) = \frac{1}{S} \sum_{i=1}^S \hat{P}_i(f) \quad (6)$$

2.4. Uzun Kısa Dönem Hafıza (LSTM)

Uzun Kısa Süreli Bellek (LSTM), 1997'de Hochreiter ve Schmidhuber tarafından bulunan, tekrarlayan sinir ağının (RNN) özel bir türü olarak bilinmektedir. RNN modelinin eğitim aşamasında ortaya çıkan gradyan kaybolması gibi sıkıntılar LSTM'de tamamiyle giderilmiştir. LSTM ağları, gizli katmanında hücre olarak adlandırılan bir yapıya sahiptir. Bir LSTM hücresi, bilgi iletimini kontrol eden unutmaya kapısı, giriş kapısı ve çıkış kapısı olmak üzere üç kapıdan oluşmaktadır [10]. Şekil 2' de LSTM hücresi gösterilmiştir.



Şekil 2. LSTM hücresinin yapısı [11]

Unutmaya kapısındaki sigmoid fonksiyonunun çıktısı 0 ise mevcut bilgi silinir, sigmoid fonksiyonunun çıktısı 1 ise bilgiler üzerinde herhangi bir değişiklik yapılmaz ve bilgilerin iletilmesi gerçekleştirilir. Giriş kapısı iki kısımdan oluşmaktadır. Sigmoid aktivasyon

fonksiyonu bulunan katmanda hangi değerlerin kullanılması gerektiğine karar verilir. Tanh aktivasyon fonksiyonu kullanan katmanda ise hücre durumu üzerine eklenecek olan değerlerden bir vektör oluşturulur. Sigmoid katman ve tanh katmanından gelen bu iki vektör çarpılarak hücre durumu üzerine eklenir. Çıkış kapısında, güncellenen hücre durumu bilgileri tanh aktivasyon fonksiyonu bulunan katmanından geçirilir. Önceki hücrenin çıktısı ile giriş bilgileri sigmoid aktivasyon fonksiyonu olan katmandan geçirilir. Son adımda, bu iki katmandan gelen bilgiler çarpılır ve hücrenin çıktısı hesaplanır [11-12].

2.5. k en yakın komşuluk (k-NN)


k en yakın komşuluk (k-NN), herhangi bir veri setinin önceden belirlenmiş bir komşu sayısı parametresi kullanılarak sınıflandırma yapan gözetimli bir makine öğrenmesi algoritmasıdır. Sınıflandırılacak olan verilerin örneklem uzayındaki veri kümelerine olan uzaklığı belirlenir. Bu uzaklığın en yakın olduğu sınıfa ilgili verinin ataması yapılır. Buradaki esas nokta sınıflandırma yapılmadan önce, sınıflara ait özniteliklerin net bir şekilde tanımlanmış olması gerekmektedir. [13-14].

2.6. Destek Vektör Makinesi (SVM)

Destek vektör makineleri regresyon analizleri ve sınıflandırma problemleri için kullanılan gözetimli öğrenme modelleridir. DVM kullanılarak yapılan ikili sınıflandırmalarda genellikle sınıf etiketleri -1 ve +1 olarak atanır. Eğitim setindeki veriler ile elde edilen karar fonksiyonu aracılığıyla farklı sınıflara ait örneklerin birbirinden ayrılması gerçekleştirilir. İki sınıfa ait verileri birbirinden ayırabilen çok sayıda hiper düzlem çizilebilir. Fakat buradaki temel amaç, eğitim verilerini en doğru şekilde birbirinden ayırabilecek hiperdüzlemin bulunmasıdır. Başka bir deyişle farklı sınıflara ait verilerin birbirlerine olan en yakın noktaları arasındaki uzaklığı maksimuma çıkarmaktır [15].

2.7. Doğrusal Diskriminant Analizi (LDA)

Doğrusal diskriminant analizi (LDA), 1936 yılında R. A. Fisher tarafından ikili sınıflandırma problemlerinin çözümü için geliştirilmiş bir sınıflandırma algoritmasıdır. Farklı sınıflara ait öznitelikleri doğrusal bir şekilde birbirinden ayırır. LDA algoritmasındaki temel amaç, sınıflar arasındaki varyans değerlerini en üst düzeye çıkarmaktır. Böylece veri setindeki sınıflar arasında bir karar doğrusu çizilerek, verilerin dağılımı daha anlaşılabilir bir hale gelmektedir [16].



Şekil 3. Güç spektral yoğunluğu grafikleri

3. Araştırma Sonuçları ve Tartışma

500 hz örnekleme frekansıyla alınan ham EEG sinyallerine 6. seviye ayrık dalgacık dönüşümü uygulanmıştır. Dalgacık fonksiyonu olarak 'db8' dalgacığı seçilmiştir. Bu işlem sonucunda ham EEG sinyallerinin delta (0-4 hz), teta (4-8 hz), alfa (8-16 hz) ve beta (16-36 hz) bantları elde edilmiştir. Bantların güç spektral yoğunluğu değerleri Welch yöntemiyle elde edilmiştir. 0-36 hz frekans aralığına karşılık gelen güç değerleri birleştirilerek öznitelik vektörleri oluşturulmuştur. Şekil 3'te dinlenme ve mental iş yükü durumlarına ait 0-36 hz frekans aralığındaki güç spektral yoğunluğu grafikleri gösterilmiştir.

Şekil 3'te bir kanala ait verilen güç spektral yoğunluğu grafiklerine göre mental iş yükü esnasında özellikle alfa bandında belirgin bir artış görülmektedir. Bu çalışmada kullanılan veri setinde 36 kişinin her birine ait 21 kanal olduğundan zihinsel iş yükü ve dinlenme durumları için 756'şar adet öznitelik vektörü bulunmaktadır. Fakat derin öğrenme algoritmalarının eğitimleri aşamasında çok fazla sayıda veri gerektiğinden oluşturulan öznitelik vektörlerinin sayısı 0.90, 0.95 ve 1.1 değerleriyle çarpılarak 3 kat artırılmıştır. Arttırılmış veri seti 3024 mental iş yükü ve 3024 dinlenme durumlarına ait toplamda 6048 adet öznitelik vektöründen oluşmaktadır. Bu veri seti sıfırlandırıcılara uygulanmadan önce k çapraz doğrulama yöntemi kullanılarak eğitim ve test olmak üzere iki bölüme ayrılmıştır. Kullanılan k parametresi olarak 10 değeri seçilmiştir. LSTM derin ağında kullanılan eğitim parametreleri ise Tablo 1'de verilmiştir.

Tablo 1. LSTM ağında kullanılan parametreler

LSTM Parametreleri	Değer
Epoch sayısı	100
Mini batch size	128
Öğrenme oranı	0.005
Optimizasyon algoritması	Adam

LSTM ağına eğitimi için epoch sayısı 100 olarak girilmiştir ve her bir epochta 50 iterasyon yapılmıştır. Toplamda ise 5000 iterasyon yapılmıştır. Mini batch size parametresi 128 olarak seçildiği için her bir epochta eğitim veri setinden alınan 128 adet öznitelik vektörü ile eğitim yapılmıştır. Öğrenme oranı parametresi için 0.005 değeri girilmiştir. Optimizasyon algoritması olarak “adam” seçilmiştir.

Tablo 2. Tüm kanallara ait performans metriklerinin ortalaması

Sınıflan dırıcı	Acc	F1	Sensitivity	Specificity	Precision
LSTM	0.9540	0.9541	0.9634	0.9470	0.9455
SVM	0.7025	0.7104	0.7295	0.6756	0.6922
LDA	0.6982	0.7005	0.7057	0.6908	0.6953
k-NN	0.7693	0.7773	0.8049	0.7338	0.7515

Tablo 2’ de tüm kanallara ait doğruluk, F1 skoru, duyarlılık, özgüllük ve kesinlik gibi performans metriklerinin ortalamaları alındığında elde edilen sonuçlar gösterilmiştir. En yüksek sınıflandırma başarısı LSTM ağı kullanılarak %95.40 olarak elde edilmiştir. En düşük sınıflandırma başarısı %69.82 ile LDA algoritması olmuştur. En yüksek F1 skoruna 0.9541 ile LSTM ağında, en düşük F1 skoruna ise 0.7005 ile LDA algoritmasında ulaşılmıştır. Duyarlılık parametresi en yüksek LSTM ağında 0.9634 olarak, en düşük ise LDA algoritmasında 0.7057 olarak elde edilmiştir. En yüksek özgüllük değeri 0.9470 ile LSTM ağı kullanılarak, en düşük özgüllük değeri ise 0.6756 ile SVM kullanılarak hesaplanmıştır. En yüksek kesinlik değerine 0.9455 ile LSTM ağında, en düşük kesinlik değerine ise 0.6922 ile SVM algoritmasında ulaşılmıştır. Tablo 2’ de yer alan tüm performans metrikleri göz önünde bulundurulduğunda, LSTM derin ağına diğer makine öğrenmesi algoritmalarına kıyasla daha başarılı sonuçlar verdiği gözlemlenmiştir. Tablo 3’te EEG sinyallerinden zihinsel iş yükünün tespitiyle ilgili yapılmış olan bazı çalışmaların sonuçları verilmiştir.

Tablo 3. Literatürde yapılan bazı çalışmaların karşılaştırılması

Yazar	Yöntem	Doğruluk
Lim vd. [17]	FFT, SVR	69.20
Chakladar vd. [18]	FFT, İstatistiksel özellik, LSTM	86.33
Aghajani vd. [19]	PSD, PLV, PAC, SVM	93.80
Aydın [3]	HFB, SVM	95.39
Roy vd. [20]	ERP, CCA, LDA	98.00

Lim vd. [17], çalışmalarında hızlı Fourier dönüşümü (FFT) kullanarak EEG sinyalini ayırtmışlardır ve her band için güç spektral değerlerini öznitelik olarak kullanmışlardır. Elde ettikleri öznitelikleri, destek vektör regresyon (SVR) modelini kullanarak sınıflandırdıklarında %69.20’lik doğruluk değerine ulaşmışlardır. Chakladar vd. [18], EEG sinyallerinin güç spektral yoğunluğu, istatistiksel özellikleri ve yaklaşık entropi tabanlı özellikleri arasında en ayırt edici olanları belirlemişlerdir. LSTM derin ağı ile sınıflandırdıklarında %86.33 başarı elde etmişlerdir. Aghajani vd. [19], EEG ve fonksiyonel yakın kızılötesi spektroskopisi (fNIRS) tekniklerini kullanarak zihinsel iş yükünün tespitini amaçlayan hibrit bir çalışma yürütmüşlerdir. EEG sinyallerinin güç spektral yoğunluğu (PSD), faz kilit değeri (PLV) ve faz-genlik kuplajı (PAC) gibi değerlerini öznitelik olarak kullanmışlardır. Bu öznitelikleri SVM algoritmasıyla sınıflandırmışlardır. Yapılan sınıflandırma sonucunda ortalama %93.80 doğruluk elde etmişlerdir. Aydın [3], zihinsel iş yükü seviyelerinin düşük, orta ve yüksek olmak üzere sınıflandırmasını yapmıştır. Higuchi fraktal boyutu (HFB) algoritmasını kullanarak EEG sinyallerinden öznitelik çıkarma işlemini gerçekleştirmiştir. Bu öznitelikleri, SVM ile sınıflandırarak %95.39 doğruluk elde etmiştir. Roy vd. [20], EEG sinyalleri aracılığıyla zihinsel iş yükü tahmini üzerine bir çalışma yapmışlardır. Toplamda 20 katılımcıya ezberlemesi gereken iki ve altı basamaklı sayılar gösterilerek 2 farklı düzeyde zihinsel iş yükünün sınıflandırma işlemini gerçekleştirmişlerdir. Öncelikle her bir kişinin EEG kayıtlarından olay ilişkili potansiyelleri (ERP) elde etmişlerdir. Daha sonra kanonik

korelasyon analizi (CCA) ile ERP verilerini filtrelemişlerdir. Filtrelenmiş verilerin düşük ve yüksek iş yükü olmak üzere ikili sınıflandırma işlemini LDA algoritması kullanarak yapmışlardır. Sınıflandırma sonucunda %98.00 başarıya ulaşmışlardır.

4. Sonuç

Bu çalışmada kişilerin mental işi yükü ile dinlenme durumlarının ayırt edilmesinde EEG sinyalleri kullanılmıştır. Önerilen yöntemde ayrıştırılmış EEG sinyallerinin güç spektral yoğunluğu değerleri öznitelik vektörü olarak kullanılmıştır. Kişilere verilen aritmetik ve mental görevler esnasındaki EEG sinyallerinin güç spektral yoğunluklarında değişimler meydana geldiği görülmüştür. Şekil 3'te görüldüğü gibi, zihinsel iş yükü ile dinlenme görevlerinin özellikle delta ve alfa bandlarının güç değerlerinde belirgin farklar gözlemlenmiştir. En başarılı sınıflandırıcı LSTM, en başarısız sınıflandırıcı ise LDA algoritması olmuştur. Sonuç olarak, LSTM derin öğrenme algoritma ile elde edilen bu yüksek başarı, zihinsel iş yükünün EEG sinyalleri kullanılarak tespit edilmesinde gelecek çalışmalar için araştırmacılara umut olabilir.

Kaynakça

1. Charles, R. L., & Nixon, J. (2019). Measuring mental workload using physiological measures: A systematic review. *Applied ergonomics*, 74, 221-232.
2. Di Stasi, L. L., Antolí, A., & Cañas, J. J. (2013). Evaluating mental workload while interacting with computer-generated artificial environments. *Entertainment Computing*, 4(1), 63-69.
3. Aydın, E. A. (2021). EEG sinyalleri kullanılarak zihinsel iş yükü seviyelerinin sınıflandırılması. *Politeknik Dergisi*, 24(2), 681-689.
4. Di Flumeri, G., Borghini, G., Aricò, P., Sciaraffa, N., Lanzi, P., Pozzi, S., ... & Babiloni, F. (2018). EEG-based mental workload neurometric to evaluate the impact of different traffic and road conditions in real driving settings. *Frontiers in human neuroscience*, 12, 509.
5. Siuly, S., Li, Y., Zhang, Y. (2016). Electroencephalogram (EEG) and Its Background. In *EEG Signal Analysis and Classification* (s. 3-21). Springer, Cham.
6. Zyma, I., Tukaev, S., Seleznev, I., Kiyono, K., Popov, A., Chernykh, M., & Shpenkov, O. (2019). Electroencephalograms during mental arithmetic task performance. *Data*, 4(1), 14.
7. Chen, D., Wan, S., Xiang, J., Bao, F. S. (2017). A high-performance seizure detection algorithm based on Discrete Wavelet Transform (DWT) and EEG. *PloS one*, 12 (3), e0173138.
8. Ocak, H. (2009). Automatic detection of epileptic seizures in EEG using discrete wavelet transform and approximate entropy. *Expert Systems with Applications*, 36 (2), 2027-2036.
9. Tosun, M., & Çetin, O. (2021). Ampirik Mod Ayrıştırması ve Welch Yöntemini Kullanarak Dört Sınıflı Motor Hayali EEG Sinyallerinin Derin Öğrenme ile Sınıflandırılması. *Avrupa Bilim ve Teknoloji Dergisi*, (26), 284-288.
10. Alhagry, S., Fahmy, A. A., & El-Khoribi, R. A. (2017). Emotion recognition based on EEG using LSTM recurrent neural network. *International Journal of Advanced Computer Science and Applications*, 8(10).
11. Er, M. B., & İbrahim, I. Ş. I. K. (2021). LSTM tabanlı derin ağlar kullanılarak diyabet hastalığı tahmini. *Türk Doğa ve Fen Dergisi*, 10(1), 68-74.
12. Yin, Y., Zheng, X., Hu, B., Zhang, Y., & Cui, X. (2021). EEG emotion recognition using fusion model of graph convolutional neural networks and LSTM. *Applied Soft Computing*, 100, 106954.
13. Manjusha, M., & Harikumar, R., "Performance analysis of kNN classifier and k-means clustering for robust classification of epilepsy from EEG signals", *International Conference on Wireless Communications, Signal Processing and Networking*, IEEE, pp. 2412-2416, 2016.
14. Türk, Ö., & Özerdem, M. S., "EEG İşaretlerinin k-NN ile Sınıflandırılmasında Dalgacıklara İlişkin Performansların Karşılaştırılması", *Tıp Teknolojileri Ulusal Kongresi*, 25-27, 2014.
15. Kavzoğlu, T., & Çölkesen, İ. (2010). Destek vektör makineleri ile uydu görüntülerinin sınıflandırılmasında kernel fonksiyonlarının etkilerinin incelenmesi. *Harita Dergisi*, 144(7), 73-82.
16. Çağhyan, B., & Utku, Köse., "Epilepsi EEG Verilerinin Makine Öğrenmesi Teknikleriyle Sınıflandırılması", *Avrupa Bilim ve Teknoloji Dergisi*, (23), 163-172, 2021.
17. Lim W. L., Sourina O., Wang L. P., "STEW: Simultaneous Task EEG Workload Data Set", *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 26 (11): 2106-2114, (2018).
18. Chakladar D.D., Dey S., Roy P.P., Dogra D.P., "EEGbased mental workload estimation using deep BLSTMLSTMnetwork and evolutionary algorithm", *Biomedical Signal Processing and Control*, 60 101989, (2020).
19. Aghajani, H., Garbey, M., & Omurtag, A. (2017). Measuring mental workload with EEG+ fNIRS. *Frontiers in human neuroscience*, 11, 359.
20. Roy, R. N., Bonnet, S., Charbonnier, S., Jallon, P., & Campagne, A. (2015, August). A comparison of ERP spatial filtering methods for optimal mental workload estimation. In *2015 37th annual international conference of the IEEE engineering in medicine and biology society (EMBC)* (pp. 7254-7257). IEEE.