

Smart EEG Tasarımı

Design of Smart EEG

İbrahim DURSUN^{1*}, Mehmet AKIN², M. Ali ARSERİM³

¹ Dicle Üniversitesi, Elektrik Elektronik Mühendisliği Bölümü, Diyarbakır, ibrahimdursun02@gmail.com, ORCID 0000-0003-4689-1972

² Dicle Üniversitesi, Elektrik Elektronik Mühendisliği Bölümü, Diyarbakır, makin @dicle.edu.tr

³ Dicle Üniversitesi, Elektrik Elektronik Mühendisliği Bölümü, Diyarbakır, marserim @dicle.edu.tr

MAKALE BİLGİLERİ

Makale geçmişi:

Geliş: 3 Şubat 2020
Düzeltilme: 5 Mart 2020
Kabul: 6 Mart 2020

Anahtar kelimeler:

BBA, DSP, KNN, DVM

ÖZET

Beyin bilgisayar arayüzü (BBA) yaygın olarak Elektroensefalografi (EEG) sinyal tabanlı olup insan beyni ile bilgisayar arasında iletişim kurmayı sağlar. Günümüzde BBA tekniği ile hastalık teşhisi, engellilerin yaşam konforunu yükseltme, eğlence gibi birçok alanda çalışma yapılmaktadır. Bilgisayar ve nöroloji bilimindeki gelişmeler birçok araştırmacıyı bu alana yöneltmekte ve yaşam standartlarının artmasıyla her geçen gün BBA ile ilgili çalışmalar daha fazla önem kazanmaktadır. Bu çalışmada, basit bir program arayüzü ile Epilepsi ve Şizofreni hastalığı, Uyku-Uyanıklık durumu ve Sağ-Sol imleç hareketinin tespiti çıktı olarak gösterilmesi hedeflenmektedir. Bu dört farklı durumun en yakın komşu (KNN) ve destek vektör makinaları (DVM) modelleri oluşturulup doğruluk oranı yüksek olan model bir dijital sinyal işleme (DSP) kartına yüklenerek offline veya online bir şekilde tespiti yapılmaya çalışılmıştır. Çalışmada Matlab Simulink, Matlab GUI ve TMS320F28335 DSP kartı kullanılarak modeller DSP'de işlenip sonuçlar bu program arayüzünde gösterilmiştir. Bu BBA sistemi farklı hastalık veya durumların EEG sinyallerini sınıflandırma sonucu tek bir uygulama ile kullanıcıya göstermektedir.

Doi: 10.24012/dumf.683519

ARTICLE INFO

Article history:

Received: 3 February 2020
Revised: 5 March 2020
Accepted: 6 March 2020

Keywords:

BCI, DSP, KNN, SVM

ABSTRACT

The brain computer interface (BBA) is widely Electroencephalography (EEG) signal-based and enables communication between the human brain and the computer. Nowadays, with BBA, disease diagnosis, increasing the life comfort of the disabled, entertainment, etc. work is done in many fields. Developments in computer science and neurology have directed many researchers to this field and with the increase of living standards, studies related to BBA are gaining more importance day by day. In this study, it is aimed to show Epilepsy and Schizophrenia disease, Sleep - Awake status and Right - Left cursor movement with a simple program interface. These four different situations, k nearest neighbor (KNN) and support vector machines (SVM) models were created and the model with high accuracy was uploaded to a digital signal processing (DSP) card and tried to be detected offline or online. In the study, using Matlab Simulink, Matlab GUI and TMS320F28335 DSP card and models are processed in DSP the results are shown in this program interface. This BBA system classifies the EEG signals of different diseases or conditions and shows the result to the user with a single application.

* Sorumlu yazar / Correspondence

İbrahim DURSUN

✉ ibrahimdursun02@gmail.com

Giriş

BBA nöroloji biliminin özel bir alanını oluşturmaktadır. Bu alan Zihinsel süreçlerde oluşan değişimleri anlamlandırıp insan bilgisayar iletişimi için arayüzler geliştirmeyi amaçlayan bir araştırma alanıdır [1]. BBA araştırmalarının bir kısmı, nöronlar arasındaki değişimlere direkt iletişim ve kontrol metotları geliştirmek üzerine yoğunlaşırken, Araştırmanın diğer bir kısmı algılayıcılarla elde edilen görme veya duyum verilerinin beyin ve beyindeki nöral sistemleri doğrudan elde ederek fonksiyonel olmayan duyu organlarının eksikliklerini gideren yöntemler üzerine yoğunlaşmaktadır.

İlk BBA çalışmalarına 1960'lı yıllarda rastlanmaktadır. Fetz vd. [2] tarafından, bireyler üzerinde yapılan deneylerde nöral aktivitelerin anlamlandırılabilceği gösterilmiştir. Diğer bir çalışmada ise S. Sutton vd.[3] bireyin bir uyarıcıya odaklandığında uyarı geldikten 300-500 ms sonra cevap olarak beynin yan lobunun EEG sinyalinde büyük bir sapma olduğunu keşfetmişlerdir. Bu olay-ilişkili potansiyel (event-related potential, ERP) diye adlandırılan buluş kullanılarak, felçli insanlardan “evet-hayır” olarak ayrılan sinyalleri algılamak için 1980-1990 yılları arasında bir yöntem olarak önerilmiştir.[4] P300 çözücü olarak adlandırılan bu yöntemde, harfler sırayla gösterilip birey tarafından dikkat verilen harfleri P300 sistemi kullanılmak suretiyle belirleyip, bireyin söylemek istediği kelime ve cümleler ortaya çıkarılmıştır. [5]

2000'li yıllardan sonra ise BBA çalışmaları hız kazanmış olup birçok araştırmacı bu alanda farklı çalışmalar yapmıştır. Bu çalışmalar ihtiyaca göre EEG verileriyle birlikte başka veri türleri de kullanılarak amaca yönelik sonuçlar elde edilmeye çalışılmıştır. Örençin; J. Klonovs vd.[6] bir kimlik doğrulama sisteminde, yüz tanıma ve yakın alan iletişimi (NFC, Near Field Communication) gibi teknolojilerle birlikte EEG kayıtlarını kullanarak bir mobil biyometrik kimlik doğrulama sistemi geliştirmeye çalışırken, Hastalık teşhisinden Epilepsi hastalığının tespit edilmesi için Kaya vd. [7] yapay sinir ağlarını kullanarak kişilerin sağlıklı

veya epilepsi hastası olduğunu belirlemeye çalışmışlardır. Sürücülerde uyku halini tespit etmek ve uyku halinde artan alfa frekansını tespit etmek için Seda vd. [8] EEG sinyallerini kullanarak LabVIEW yazılımıyla grafiksel kullanıcı arabirimi oluşturmuşlardır. Çalışmalarında 19 kanal kullanmış olup, bu kanallardan en iyi sonuç alınan kanalları belirlemişlerdir. Yine BBA ve makine öğrenmesini kullanarak Mehmet [9] EEG sinyalleri ile insansız hava aracını kontrol etmeye çalışmışlardır. Sinyaller EEG algılayıcı kulaklık ile alınıp bluetooth ile aktarılmıştır. Bu sinyaller C# yazılımıyla bilgisayar ortamına alınmış ve sonuçlar Matlab ortamında %78 başarı oranıyla elde etmiştir. Diğer bir çalışmada ise Priyanka vd. [10] bir EEG algılayıcı kulaklığı ile BBA sistemi geliştirerek, insan göz hareketlerinin dikkat ve odaklanma değerlerine göre %95 doğrulukla bir tekerlekli sandalyenin dinamik olarak kontrolünü sağlamışlardır. Yukarıdaki çalışmalarda noninvazif yöntem uygulanmış olup insan vücuduna herhangi bir yan etkisi bulunmamaktadır. Fakat invazif yöntemler ciddi cerrahi müdahale gerektirip zamanla dokuda yaralara ve sinyal kalitesinin düşmesine sebep olabilmektedir. Noninvazif yöntemle elde edilen veriler kullanılarak yapılan bu çalışmamızın kullanıcılara herhangi bir olumsuz etkisi olmamıştır.

Bu çalışmada, EEG sinyalleri ile 4 farklı durumun online veya offline bir şekilde tespiti yapılmaya çalışılmıştır. Offline çalışmada veriler daha önce elde edilmiş olup Offline Veri butonu aracılığıyla bilgisayar ortamında sisteme aktarılıp sınıflandırma işlemi yapılmaktadır. Online çalışmada ise veriler sensör aracılığıyla gerçek zamanlı olarak elde edilip sisteme aktarılıp sınıflandırma işlemi yapılmaktadır. BBA kullanıcı grafik arayüzü oluşturularak uyku – uyanıklık, epilepsi şizofreni hastalığı ve sağ-sol imleç hareketi verileri sınıflandırma algoritmaları ile sınıflandırılmış, sonuçlar bu arayüzde gösterilmiştir. Makine öğrenme yöntemleri olarak DVM ve KNN sınıflandırma yöntemleri birlikte kullanılarak sistemin performansı kıyaslanmaya çalışılmıştır. KNN sınıflandırmasında her durum için farklı komşu sayısı ve uzaklık ölçütü belirlenirken, DVM

sınıflandırmasında RBF/Gaussian çekirdeği ve ödünleme değeri 0.5 seçilerek en iyi sonuçlar elde edilmiştir.

Çalışmada Kullanılan Materyaller

Çalışmada 4 farklı veri seti kullanılmıştır. Uyku tespiti için kullanılan veri seti, Ankara Gülhane Askeri Tıp Akademisi Ruh Sağlığı ve Hastalıkları Anabilim Dalı Uyku Laboratuvarında tedavi gören bazı deneklerden alınmıştır. Verinin kayıt işlemlerinde gümüş yüzey elektrotlar kullanılmış ve bu elektrotlar C3-A2 standart yerleşimi esas alınarak deneklere uygulanmıştır. Veriler 150 Hz örnekleme frekansında bilgisayara aktarılmıştır. Daha sonra bu veriler 10 sn'lik bölümler halinde gruplandırılmış ve bu bölümlere güç yoğunluk spektrumu uygulanarak REM ile NREM evreleri tespit edilmeye çalışılmıştır.

Epilepsi hastalığı tespiti için Bonn Üniversitesi Epileptoloji Bölümü tarafından sağlanan veri setleri kullanılmıştır. 5 farklı sınıftan oluşan (A,B,C,D,E) bu veri seti 23,6 saniye ve 100 örnekten oluşmaktadır. Örnekleme frekansı 173,61 Hz ve her bir veri 4096 tane değer içermektedir. A ve B bölümüne ait veriler sağlıklı bireylerden sırasıyla gözü açık ve kapalı durumda alınmış olan verilerdir. C bölümüne ait veriler ise epileptojenik bölgenin karşısına yerleştirilen elektrotla nöbet halinde olmadıkları anda alınmıştır. D sınıfına ait veriler nöbet öncesi epileptojenik bölgeden alınmıştır. E bölümüne ait veriler ise nöbet sırasında alınmıştır. Bu çalışma ile sağlıklı ve hasta olan bireylerin tespiti yapıldığından dolayı A ve E bölümüne ait veriler kullanılmıştır.

Şizofreni hastalığı tespiti için Açık Öğrenme platformu adı altında Polonyalı CEONREPOD internet sitesinden elde edilmiştir. Paranoid şizofreni tanısı konulmuş 14 hasta ve 14 sağlıklı kontrol grubundan oluşan bu veri seti 19 kanallı 10-20 standardına uygun olarak 250 Hz örnekleme frekansıyla alınmıştır. Hastalıklı grup (7 erkek: $27,9 \pm 3,3$ yıl, 7 kadın $28,3 \pm 4,1$ yıl) ve kontrol grubu (7 erkek: $26,8 \pm 2,9$, 7 kadın $28,7 \pm 3,4$ yıl)'dan oluşmaktadır. Hastalar paranoid şizofreni için Uluslararası Hastalık Sınıflandırması ICD-10 kriterlerini karşılamaktadırlar. Hastalarda şizofreni dışında

hamilelik, organik beyin patolojisi, ciddi nörolojik hastalıklar (Epilepsi, Alzheimer veya Parkinson vb.) görülmemiştir.

Sağ-Sol imleç hareketi tespiti için 2008 de Graz Üniversitesi tarafından yapılan yarışmada (BCI Competition 2008) kullanılan veri seti kullanılmıştır. 9 farklı denekten alınan EEG verilerini içermektedir. Veriler 250 Hz örnekleme frekansı ile kaydedilmiştir. 22 EEG ve 3 EOG kanalından kaydedilen veriler 0,5 Hz ve 100 Hz spektral aralığı kapsayacak şekilde bandpass filtreden geçirilip ayrıca şebeke frekansından arındırmak için 50 Hz'lik Notch filtresi kullanılmıştır. Çalışmada EEG verilerinden sağ ve sol el imleç hareketlerini içeren denemeler çekilmiştir. Dolayısıyla sonuçlarda sağ el motor hayali ve sol el motor hayalinin sonuçları elde edilmiştir.


Oluşturulan modellerin çalıştırılması için Texas Instruments firmasının TMS320F28335 DSP uygulama geliştirme kartı kullanılmıştır. Çok amaçlı kullanılabilen bu uygulama kartı, TI C2000 DSP çekirdek ailesine ait 32 bit kayan noktalı (floating-point), 150 MHz gücünde işlem yapabilen TMS320F28335PGFA DSP yongası kullanılarak tasarlanmıştır. Bu Dijital Sinyal İşleme (DSP) kartı, 18 adet motor kontrol ve genel amaçlı PWM, 6 adet sinyal yakalama (CAP) ve 2 adet enkoder (QEP), 3 adet UART (SCI), 2 adet McBSP seri haberleşme protokolü, 88 adet genel amaçlı giriş-çıkış (I/O) birimi, 16 adet 12 bit 25,5 Mhz örnekleme hızında ADC, 3 adet 32 bit Timer, 1 adet 6 kanallı DMA(Direct Memory Acces) birimi ve 1 adet 32 veya 16 bit EMIF (External Memory Interface) çevresel birimlerine sahiptir.

Çalışmada Uygulanan Metotlar

K en yakın komşu (KNN) sınıflandırma algoritması

KNN algoritması, mevcut durumları saklayıp benzerlik ölçüsüne göre yeni durumları sınıflandıran basit bir algoritmadır. Bu algoritma ile temel olarak sınıflandırılacak verinin komşularıyla olan mesafesine bakıp, en uygun etiket ile sınıflandırma işlemi yapılabilmektedir. Kendisine en yakın olan sınıfı belirlemek için bir k değişkeni kullanan

algoritma, sonuçları bu k değişkenine göre tahmin eder.



Şekil 1 KNN sınıflandırma algoritması grafik gösterimi

Şekil 1’de görüldüğü üzere X1 ve X2 verileri bulunmaktadır. Bu veriler A (Yuvarlak) ve B (Kare) olmak üzere iki sınıfa ayrılmıştır. Daha önce A ve B sınıfına ayrılmış olan X1 ve X2 verilerine bakarak kırmızı renkli yıldızın hangi sınıfa ait olduğunu tahmin edebiliriz. KNN algoritmasının isminden de anlaşılacağı üzere yeni bir verinin hangi sınıfa ait olduğunu bulmak için çevresindeki verilerin mesafelerine bakmamız gerekir. Örneğin k değerini 3 olarak belirlediğimizde kendisine en yakın olan 2 kare ve bir tane yuvarlak olduğunu görmekteyiz. Böylelikle k=3 olduğunda yıldızın B sınıfına ait olduğuna karar vermiş oluruz. K değerini 6 olarak seçtiğimizde ise yıldıza en yakın 4 tane yuvarlak ve 2 tane kare olduğunu görmekteyiz. Bu durumda ise yıldızın A sınıfına ait olduğuna karar veririz. Komşu sayısının doğru seçilmesiyle hatayı en aza indirebiliriz. KNN sınıflandırma algoritmasında uzaklık hesaplamaları için genellikle 3 tip uzaklık fonksiyonu kullanılmaktadır. Bunlar;

- Euclidean Uzaklığı
- Manhattan Uzaklığı
- Minkowski Uzaklığı’dır.

$$\text{Euclidean} = \sqrt{\sum_{i=1}^k (x_i - y_i)^2} \quad (1)$$

$$\text{Manhattan} = \sum_{i=1}^k |x_i - y_i| \quad (2)$$

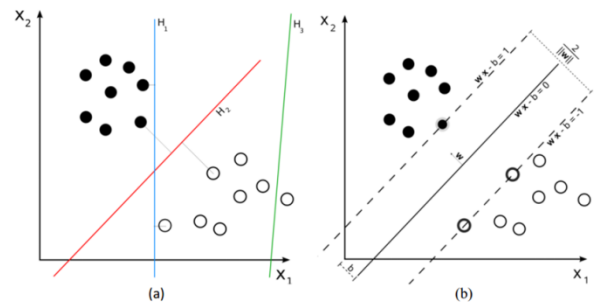
$$\text{Minkowski} = (\sum_{i=1}^k (|x_i - y_i|^q))^{1/q} \quad (3)$$

Uzaklık fonksiyonlarının matematiksel ifadeleri ise (1) – (3) denklemlerinde verilmiştir.

Destek vektör makinaları (DVM) sınıflandırma algoritması

DVM algoritması, sınıflandırmada kullanılan bir denetimli öğrenme yöntemidir. Bu sınıflandırma yöntemi oldukça etkili ve basit bir algoritmadır. DVM’nin temelinde istatistiksel öğrenme teorisi ve yapısal risk minimizasyonu bulunmaktadır. DVM’nin tarihine baktığımızda, geçmişinin 1936 yıllarında R.A.Fisher’in örüntü tanıma problemlerine çözüm arayışına kadar dayandığını görmekteyiz.

DVM algoritmasında sınıflandırma işlemi nesnelerin -1 ve 1 olarak etiketlenmesine dayanır. DVM, sınıflandırma için bir düzlemde bulunan iki grup arasında bir sınır çizerek verileri iki gruba ayırmaya çalışır. Bu sınır çizgisi iki gruba en uzak mesafede olmalıdır. Şekil 2’de gösterildiği gibi pozitif ve negatif verileri birbirinden ayıran aşırı bir düzlem olsun. Bu düzlem üzerindeki noktalar $wx+b=0$ denklemini sağlayacaktır. Burada yer alan w aşırı düzleme olan normal ve $|b|/||w||$ aşırı düzleme olan dik uzaklıktır. Aşırı düzleme en yakın pozitif ve negatif veriler arasındaki mesafeye, ayırıcı aşırı düzlemin “tolerans”ı dersek, DVM bu toleransın en yüksek olduğu bir aşırı düzlemi bulmaya çalışır.



Şekil 2 (a) Toleransın belirlenmesi, (b) Grupların düzlemde gösterilmesi

Bu düzlemin bulunması için iki veri kümesine de yakın ve birbirine paralel iki sınır çizgisi çizilir. Bu iki sınır çizgisine paralel ve eşit mesafede ortak sınır çizgisi çizilerek veriler sınıflandırılır. Şekil 2'deki düzlemde her bir noktanın tanımı (4)'teki denklemle yapılabilir.

$$D = \{(x_i, c_i) | x_i \in \mathbb{R}^p, c_i \in \{-1, 1\}\}_{i=1}^n \quad (4)$$

Geliştirilen sistemin akış şeması Şekil 3'te gösterilen adımlardan oluşmaktadır.



Şekil 3 BBA Sisteminin yapısı

Şekil 3'te görüldüğü üzere EEG verileri öncelikle filtrelenmektedir. Filtre ile gürültüden arındırılan verilerin boyutunu küçültmek için bir takım istatistiksel yöntemlerle (ortalama, medyan, çarpıklık, basıklık, entropi ve standart sapma) özellik vektörleri elde edilmektedir. Özellik vektörü elde edildikten sonra sinyalin DSP kartında yüklü olan modelin girişine verilmek suretiyle elde edilen sonuçlar, geliştirmiş olduğumuz arayüz programında gösterilmektedir.

Sonuçlar

Bu çalışmada EEG tabanlı bir BBA sistemi tasarlanmaya çalışılmıştır. Bu sistemde Matlab GUI ortamında bir kullanıcı grafik arayüzü oluşturulup, buton yardımı ile seçilen veriler DSP kartına gönderilerek sınıflandırılmıştır. Şekil 4'te görüldüğü gibi program arayüzü oldukça sadedir. Sınıflandırılmak istenen veri offline veya online veri butonlarından biri ile seçildikten sonra program aracılığı ile seçili modelin girişine verilmekte ve uygula butonuna basıldıktan sonra sonuç yazılı olarak arayüz programında gösterilmektedir. Çalışmadaki amaç EEG yöntemiyle hastalık veya diğer durumların tespitini yapmada karmaşıklıktan kurtulmak ile online veya offline bir şekilde verileri işleyip kullanım kolaylığı sağlamaktır. Çalışmadan elde edilen sonuçlar farklı başlıklar altında Hata (Confusion) Matrisleri ve performans değerleri şeklinde verilmiştir.



Şekil 4 BBA sistemi kullanıcı arayüzü

Uyku verisi için sonuçlar

Uyku verilerine KNN algoritmasında k komşu sayısı 3 seçilmiş olup uzaklık ölçütü Öklid (Euclidean) olarak belirlenmiştir. DVM algoritması için RBF/Gaussian çekirdeği kullanılmıştır. KNN sınıflandırma sonuçları Hata (Confusion) Matrisi şeklinde tablo 1'de DVM sonucu ise tablo 2'de gösterilmiştir.

Tablo 1 Uyku ve uyanıklık verilerinin KNN algoritması ile sınıflandırılması sonucu elde edilen hata matrisi

		Tahmin	
		Uyku	Uyanıklık
Gerçek	Uyku	18	2
	Uyanıklık	0	20

Tablo 2 Uyku ve uyanıklık verilerinin DVM algoritması ile sınıflandırılması sonucu elde edilen hata matrisi

		Tahmin	
		Uyku	Uyanıklık
Gerçek	Uyku	19	1
	Uyanıklık	0	20

Uyku ve Uyanıklık verilerinin sınıflandırılmasına ilişkin Doğruluk (Accuracy), Duyarlılık (Sensitivity), Özgüllük (Specificity), Kesinlik (Precision), Duyarlılık (Recall) ve F-Skor (F-Score) performans parametreleri tablo 3'te gösterilmiştir.

Tablo 3: Uyku verisi için sınıflandırma algoritmalarının performans değerleri

	DVM	KNN
Doğruluk	0.97	0.95
Duyarlılık	0.95	0.9
Özgüllük	1	1
Kesinlik	1	1
Duyarlılık (Recall)	0.95	0.9
F-Skor	0.97	0.95

Tablo 3'te görüldüğü üzere Uyku-Uyanıklık tespiti %97 oranla en yüksek doğruluk değeri DVM sınıflandırıcısıyla elde edilmiştir. Bu sınıflandırma modelinin Simulink modeli oluşturulup DSP kartına yüklenmiştir.

Epilepsi verisi için sonuçlar

Epilepsi verilerine KNN algoritmasında k komşu sayısı 3 seçilmiş olup uzaklık ölçütü Öklid olarak belirlenmiştir. DVM algoritmasında ise RBF/Gaussian çekirdeği kullanılmıştır. Epilepsi verisi KNN sınıflandırma sonuçları Hata (Confusion) Matrisi şeklinde tablo 4'de, DVM sonucu ise tablo 5'de gösterilmiştir.

Tablo 4 Epilepsi verisi için hastalıklı ve sağlıklı verilerin KNN algoritması ile sınıflandırılması sonucu elde edilen hata matrisi

		Tahmin	
		Hastalıklı	Sağlıklı
Gerçek	Hastalıklı	100	0
	Sağlıklı	4	96

Tablo 5 Epilepsi verisi için hastalıklı ve sağlıklı verilerin DVM algoritması ile sınıflandırılması sonucu elde edilen hata matrisi

		Tahmin	
		Hastalıklı	Sağlıklı
Gerçek	Hastalıklı	100	0
	Sağlıklı	0	100

Epilepsi verisi için değerlendirme sonucu ise Tablo 6'da gösterilmiştir.

Tablo 6 Epilepsi verisi için sınıflandırma algoritmalarının performans değerleri

	DVM	KNN
Doğruluk	1	0.98
Duyarlılık	1	1
Özgüllük	1	0.96
Kesinlik	1	0.96
Duyarlılık (Recall)	1	1
F-Skor	1	0.98

Tablo 6'da görüldüğü üzere DVM sınıflandırıcısıyla, Epilepsi hastalığının %100

tespiti yapılarak en yüksek doğruluk değeri elde edilmiştir. Bu sınıflandırma modeli ile Simulink modeli oluşturulup DSP kartına yüklenmiştir.

Şizofreni Verisi İçin Sonuçlar

Şizofreni verilerine KNN algoritmasında k komşu sayısı 2 seçilmiş olup uzaklık ölçütü Öklid olarak belirlenmiştir. DVM algoritmasında ise RBF/Gaussian çekirdeği kullanılmıştır. Şizofreni verisi konusunda KNN sınıflandırma sonuçları Hata (Confusion) Matrisi şeklinde tablo 7’de, DVM sonucu ise tablo 8’de gösterilmiştir.

Tablo 7 Şizofreni verisi için hastalıklı ve sağlıklı verilerin KNN algoritması ile sınıflandırılması sonucu elde edilen hata matrisi

		Tahmin	
		Hastalıklı	Sağlıklı
Gerçek	Hastalıklı	11	3
	Sağlıklı	2	12

Tablo 8 Şizofreni verisi için hastalıklı ve sağlıklı verilerin DVM Algoritması ile sınıflandırılması sonucu elde edilen hata matrisi

		Tahmin	
		Hastalıklı	Sağlıklı
Gerçek	Hastalıklı	14	0
	Sağlıklı	1	13

Şizofreni verisi için değerlendirme sonucu ise Tablo 9’da gösterilmiştir.

Tablo 9 Şizofreni verisi için sınıflandırma algoritmalarının performans değerleri

	DVM	KNN
Doğruluk	0.96	0.84
Duyarlılık	1.00	0.79
Özgüllük	0.91	0.89
Kesinlik	0.92	0.87
Duyarlılık (Recall)	1.00	0.79
F-Skor	0.96	0.83

Tablo 9’da görüldüğü üzere DVM sınıflandırıcısı ile Şizofreni hastalığının %96 oranla tespiti yapılarak en yüksek doğruluk değeri elde edilmiştir. Bu sınıflandırma modeli ile Simulink modeli oluşturulup DSP kartına yüklenmiştir.

Sağ – sol imleç hareketi verisi için sonuçlar

KNN algoritmasında Sağ-Sol imleç hareketi verilerine k komşu sayısı 3 seçilmiş olup uzaklık ölçütü Öklid olarak belirlenmiştir. KNN sınıflandırma sonuçları Hata (Confusion) Matrisi şeklinde tablo 10’da, DVM sonucu ise tablo 11’de gösterilmiştir.

Tablo 10 Sağ – sol imleç hareketi verisi için verilerin KNN algoritması ile sınıflandırılması sonucu elde edilen hata matrisi

		Tahmin	
		Hastalıklı	Sağlıklı
Gerçek	Hastalıklı	69	3
	Sağlıklı	7	65

Tablo 11 Sağ – sol imleç hareketi verisi için verilerin DVM algoritması ile sınıflandırılması sonucu elde edilen hata matrisi

		Tahmin	
		Hastalıklı	Sağlıklı
Gerçek	Hastalıklı	69	3
	Sağlıklı	9	63

Şizofreni verisi için değerlendirme sonucu ise Tablo 12’de gösterilmiştir.

Tablo 12 Sağ – sol imleç hareketi verisi için sınıflandırma algoritmalarının performans değerleri

	DVM	KNN
Doğruluk	0.91	0.93
Duyarlılık	0.95	0.95
Özgüllük	0.87	0.90
Kesinlik	0.88	0.90
Duyarlılık (Recall)	0.95	0.95
F-Skor	0.92	0.93

Tablo 12’de görüldüğü üzere Sağ – Sol imleç hareketi tespiti %93 oranla en yüksek doğruluk değeri KNN sınıflandırıcısıyla elde edilmiştir. Bu sınıflandırma modelinin Simulink modeli oluşturulup DSP kartına yüklenmiştir.

Tartışma

Bu çalışmada EEG verileri kullanılarak Epilepsi, Şizofreni, Uyku-Uyanıklık, Sağ-Sol imleç hareketlerinin tespiti KNN ve DVM sınıflandırma yöntemleri kullanılarak yapılmış olup elde edilen modeller bir DSP kartına yüklenmiş ve sonuçlar bir kullanıcı arayüzünde gösterilmiştir.

Literatürü incelediğimizde araştırmacılar yapılan çalışmalarda tek bir durum üzerine yoğunlaşırken bu çalışmada farklı durumları bir araya getirerek basit bir arayüz aracılığıyla sonuçlar elde edilmeye çalışılmıştır. Bu çalışmadaki amaç farklı durumları tek bir program aracılığıyla işleyip DSP yardımıyla taşınabilir hale getirmektir.

Kaynaklar

- [1] Murat Kaya, Mustafa Cömert, Yuriy Mishchenko, “Beyin Bilgisayar Arayüzü için DVM Makine Öğrenme Yöntemi Kullanılarak EEG Verilerinden Sağ ve Sol El Hareket Düşüncülerinin Tespiti”, TÜBAV Bilim 10 (3) 2017 s.1-20.
- [2] E. E. Fetz, “Operant conditioning of cortical unit activity.”, Science, c. 163, sayı 3870, ss. 955–8, 1969.
- [3] S. Sutton, M. Braren, J. Zubin, ve E. R. John, “Evoked-Potential Correlates of Stimulus Uncertainty”, Science (80-.), c. 150, sayı 3700, s. 1187, 1965.
- [4] E. Donchin, K. M. Spencer, ve R. Wijesinghe, “The mental prosthesis: Assessing the speed of a P300-based brain- computer interface”, IEEE Trans. Rehabil. Eng., c. 8, sayı 2, ss. 174–179, 2000.
- [5] L. A. Farwell ve E. Donchin, “Talking off the top of your head: toward a mental prosthesis utilizing eventrelated brain potentials”, Electroencephalogr. Clin. Neurophysiol., c. 70, sayı 6, ss. 510–523, 1988.
- [6] Development of a Mobile EEG-based Biometric Authentication System. J. Klonovs, C. Kjeldgaard Petersen, H. Olesen, A. Hammershøj.
- [7] Kaya, D., Türk, M., (2017). Biyoelektiriksel İşaretlerde Rahatsızlık Teşhisinin Yorumlanması. Fırat Üniversitesi Mühendislik Bilimleri Dergisi, 29(1),261-267.
- [8] Seda GÜZEL, Turgay KAYA, Hasan GÜLER,” Uyku Evrelerinin Belirlenmesinde EEG Sinyallerinin LabVIEW Tabanlı Analizi”, SiU-2015 Sinyal İşleme ve İletişim Uygulamaları Kurultayı, Mayıs 2015.
- [9] Mehmet Demir, “Yapay Sinir Ağlarını Kullanarak EEG sinyalleri ile İnsansız Hava Aracı Kontrolü”, Yüksek Lisans Tezi, Sakarya Üniversitesi Uygulamalı Bilimler Üniversitesi Lisansüstü Eğitim Enstitüsü, Sakarya, 2019
- [10] Priyanka D. Girase, M. P. Deshmukh, (2015). Mindwave Device WheelchairControl, International Journal of Science and Research (IJSR) ISSN (Online):2319-7064 Index Copernicus Value (2013): 6.14 | Impact Factor (2015): 6.391.