



İmleç Hareketlerine Ait EEG Sinyallerinin Sınıflandırılmasında Adaptif ve Adaptif Olmayan Filtrelerin Uygulamaları

Zeynelabidin SEVGİLİ

Dicle Üniversitesi, Elektrik Elektronik Mühendisliği Bölümü, Diyarbakır
zeynel.sevgili@gmail.com ORCID: 0000-0002-5638-1864, Tel: 0(532) 566 2959

Mehmet AKIN*

Dicle Üniversitesi, Elektrik Elektronik Mühendisliği Bölümü, Diyarbakır
makin@dicle.edu.tr ORCID: 0000-0001-5439-4824, Tel: 0(412) 241 10 00 (3506)

Geliş: 29.06.2019, Revizyon: 29.10.2019, Kabul Tarihi: 27.01.2020

Öz

Beyin Bilgisayar Arayüzü(BBA), herhangi fiziksel bir yeteneğe ihtiyaç duymadan insanın niyetinin veya kasıtlı düşüncesinin sınıflandırılmasını esas alınır. BBA çalışmalarında, veriler elektroensefalografi(EEG) yöntemi kullanılarak elde edilirken çevre kaynaklı(şebeke gürültüleri vs.) veya içsel(göz hareketleri, ECG vs.) bazı gürültülere maruz kalır. EEG verilerinin hassas bir şekilde sınıflandırılmasını önemli derecede etkileyebilecek gürültülerden biri de elektrookulografik(EOG) gürültülerdir. Bu çalışmada, Graz Üniversitesi tarafından yapılan BCI-IV yarışmasının 2a veri seti kullanılmıştır. 4 sınıflı veri seti 2 sınıfa indirgenerek sadece sağ ve sol imleç hareketlerinin offline sınıflandırılması amaçlanmıştır. 22 kanaldan alınan EEG verileri ile eş zamanlı, göz çevresine montajı yapılan 3 elektrottan da EOG verileri elde edilmiştir. Kullanılan veri setinde, EOG gürültülerini EEG sinyallerinden arındırmak için geleneksel bant geçiren filtreler ve recursive least square(RLS) adaptif filtresi kullanılmıştır. Motor hareket hayali ile uygun bantlara filtrelenmiş sinyallerden, ortak uzamsal örüntüler(CSP) metodu ile çıkarılan öznitelik vektörleri, lineer diskriminant analizi(LDA), destek vektör makinaları(DVM), naive bayes(NB) ve k-NN sınıflandırma algoritmalarının girişlerine uygulanmıştır. Chebyshev tip 2 ve DVM kombinasyonu %72'lik ortalama doğruluk oranı ile en yüksek sınıflandırma performansını sağlamıştır. Ayrıca RLS adaptif filtresi ile elde edilen sınıflandırma sonuçları bant geçiren filtrelerin sonuçları ile mukayese edilmiştir. RLS algoritması ve LDA kombinasyonu, %64 doğruluk oranı ile geleneksel bant geçiren filtreler ile elde edilen sonuçlardan daha düşük performans göstermiştir. Çalışmada elde edilen bulgular literatürü destekler niteliktedir. Çalışmanın bulguları, gelecekte yapılacak çalışmalara da ışık tutabilecek niteliktedir.

Anahtar Kelimeler: Adaptif filtre, Recursive least square, Beyin bilgisayar arayüzü, Elektrookulogram, Elektroensefalografi, Geleneksel bant geçiren filtreler, Ortak uzamsal örüntüler

* Yazışmaların yapılacağı yazar

Giriş

İnsanoğlu olağanüstü donanımlar ile teçhiz edilmiş ve doğada tasarruf yeteneğine sahip tek canlıdır diyebiliriz. Diğer canlılar kendi habitatları içerisinde, genel ekosisteme kabiliyetleri ölçüsünde katkı yaparken insanoğlu akıllı, vücut uzuvları ve diğer kabiliyetleri ile dünya dışı yaşamı bile etkileyebilecek donanımlara sahiptir. Bu donanımların en önemli olanlarından biri de şüphesiz iletişim yeteneğidir. İnsan sahip olduğu beyin, dil, gırtlak vs. gibi organların koordinasyonu ile diğer insanlar hatta gelişen teknoloji vasıtasıyla cihazlar dahi iletişim kurabilir. Bu şekilde hayatı için lazım olan ihtiyaçlarını karşılamaya çalışır. Fakat bu durum bütün insanlar için geçerli değildir. ALS(Amyotrophic Lateral Sclerosis), felç, MS (Multiple Skleroz) vs. gibi hastalıklar insanın motor becerilerinin tamamen kısıtlanmasına neden olabilir. Bunun sonucunda kişi, kasıtlı kas hareketlerinden mahrum kalır. Bu durumda beyin normal aktivitesine devam ederken beyinden uzuvlarına komutlar aktarılamaz. Yani diğer bir deyişle beyin her şeyin farkındadır. Akıncı (2010) Fakat her hangi bir uzvunu hareket ettirecek kabiliyetten mahrum kalmıştır. Beyin bilgisayar arayüzü(BBA) bu tarz hastalara çözümler sunmak için geliştirilen önemli teknolojilerden biridir. Bunun haricinde BBA, sanal gerçeklik, etkin ifade, internete erişim, tekerlekli sandalye kontrolü, video oyunları gibi bir çok alan için uygulamalar geliştirmektedir.

Beyin Bilgisayar Arayüzü(BBA) çalışmalarında, beynin aktivitelerini anlamlandırma esastır. Bu aktiviteler ile insanın niyeti anlamlandırılmaya çalışılır. Bu şekilde vücudun diğer organlarına ihtiyaç duymadan insanın niyetinin okunması amaçlanır. Yine Sinyal işleme teknikleri(DSP) ve çeşitli sınıflandırma algoritmaları ile insanın isteklerinin komutları, harici bir cihaza aktarılması amaçlanır. Bunlar büyük oranda başarılı olduğu takdirde BBA, insanların hayatlarını kolaylaştıracak çok büyük gelişimlere kapı

açabilir. Dolayısıyla bu teknoloji hayata hizmet hususunda büyük anlamlar kazanır.

BBA çalışmaları ile ilgili ilk girişimler 1964'te başlamıştır. Fakat bu alanla ilgili dikkate değer çalışmalar,1990'lı yılların başında yoğunlaşmıştır. Bu süreçle birlikte her yıl, yapılan çalışma ve yayınlanan yayın sayısında önemli derecede artışlar olmuştur.

Bu bağlamda, bazı çalışmalarda regresyon ve ICA yöntemi sentezlenerek EOG gürültüleri giderilmiştir. (Cheok, N. S., ve Raveendran, P. 2008). Kai Keng Ang vd. (2008), çalışmalarında, Graz Üniversitesi tarafından yapılan yarışmanın BCI III-IVa veri setini kullanarak EEG sinyallerinden elde edilen sağ el ve sol ayak motor hayali hareketlerini sınıflandırmışlardır. Önerilen çalışmada, deneğe özel frekans verileri için bir algoritma(FBCSP) geliştirilmiştir. Bu algoritma ile farklı frekans bantlarındaki verilerden CSP ile otomatik özellik seçimi yapılmıştır. Bir kısım araştırmacılar, EEG sinyallerinden EOG gürültülerini arındırmak için tek veya çift referanslı, işlem maliyeti düşük ve hızlı RLS adaptif filtrelerini kullanmışlardır (He, P., Wilson, vd; Kumar, P. S. vd. 2009). Bazı araştırmacılar sınıflandırma performansını artırmak için ICA(independent component analysis) yöntemini kullanmışlardır (Hsu, W. Y. vd. 2012). Bazı çalışmalarda, sınıflandırma performanslarını arttırmak için kişinin spektral özelliklerine uygun adapte olabilen filtreler geliştirilmiştir (Belwafi, K. vd. 2014). LI Ming-Ai vd. (2009), çalışmalarında, geleneksel CSP yöntemini modifiye ederek sınıflandırma performansı daha yüksek bir yöntem sunmuşlardır. Akıncı ve Güneri(2010), yapmış oldukları çalışmada, çevrimiçi ipucu-bazlı sağ ve sol el motor hayallerini sınıflandırmaya yönelik bir BBA sistemi geliştirmişlerdir. Neethu Robinson ve Cuntai Guan (2011), yapmış oldukları çalışmada, el hareketinin yönünü tespit eden wavelet tabanlı CSP(common spatial pattern) algoritmasını sunmuşlardır. Önder Aydemir (2016), CSP

teknîği ile öznitelik vektörleri çıkarılan EEG sinyallerinin sınıflandırma performanslarını yükseltmek için EEG sinyallerindeki en iyi zaman aralığını seçecek bir algoritma geliştirmiştir. BBA çalışmalarında karşılaşılan zorluklardan biri olan kişiye özgü öznitelik vektörlerini seçme hususuna bir alternatif sunmuştur.

Bu çalışmada, Graz Üniversitesi tarafından yapılan BCI IV-2a EEG veri seti kullanılmıştır. Normalde dört sınıftan oluşan veri seti, sağ ve sol imleç motor hayali olmak üzere iki sınıfa indirgenerek veri üzerinde analizler gerçekleştirilmiştir. EEG ve EOG verilerinin ayrı ayrı kaydedildiği veri setinin EOG ile gürültülü EEG sinyali primer girişe ve göz çevresinden alınan EOG1 verisi de RLS adaptif filtresinin referans girişine uygulanmıştır. Filtrenin çıkışında da gürültüden arındırılmış temiz bir sinyal elde edilmiştir. Adaptif filtre ile yapılan çalışmada kullanılan RLS algoritması, filtre katsayılarını güncelleyerek hatayı minimize etme tekniğine dayalıdır. Yapılan çalışma, motor hareket hayali sinyallerinin, adaptif filtre ve geleneksel filtreler ile filtrelendikten sonra farklı algoritmalar ile sınıflandırma sonuçlarının mukayesesi amaçlanmaktadır.

Bu çalışmanın ilk bölümünde materyal ve metod kısımlarına değinilecektir. Çalışmanın ikinci kısmında, veri setine çalışmada kullanılan yöntemlere değinilmiştir. Çalışmanın üçüncü bölümünde, uygulama esnasındaki prosesler açıklanmıştır. Çalışmanın son kısmı olan sonuç ve öneriler kısmı ise, elde edilen bulgularla ilgili yorumları ve çalışmanın gelecek projeksiyonunu içermektedir.

Materyal ve Yöntem

Materyal

Kullanılan veri seti 2008 de Graz Üniversitesi tarafından sağlanan yarışmada(BCI Competition 2008) kullanılan veri setlerinden biridir. Tablo 1'de dosya isimleri verilen ve Dataset Ila olarak adı geçen veri seti, 9 farklı


denekten alınan EEG verilerini kapsamaktadır. Her bir denek sandalyeye oturur vaziyette ve ekrandan 1 m göz uzaklıkta bulunacak şekilde konumlandırılmıştır. Her bir denek için 2 oturum gerçekleştirilmiştir. Her bir oturum 6 süreçten oluşmaktadır. Her bir süreç 48 denemeden oluşmaktadır. Her bir oturum için toplamda 288 deneme mevcuttur. Sağ el hareket hayali, sol el hareket hayali, ayak hareket hayali ve dil hareket hayali olmak üzere veri seti 4 sınıfı kapsamaktadır. Yapılan çalışmada, deneklerin kayıtlarından sağ ve sol el imleç hareketlerini içeren denemeler çekilmiştir. Dolayısıyla yapılan çalışma, sağ el motor hayali ve sol el motor hayalini kapsamaktadır. (University of Graz 2008) Oturum dosyaları ve isimleri Tablo 1'de belirtilmiştir.

Tablo 1


ID	Eğitim Verileri	Test Verileri
1	A01T.gdf	A01E.gdf
2	A02T.gdf	A02E.gdf
3	A03T.gdf	A03E.gdf
4	A04T.gdf	A04E.gdf
5	A05T.gdf	A05E.gdf
6	A06T.gdf	A06E.gdf
7	A07T.gdf	A07E.gdf
8	A08T.gdf	A08E.gdf
9	A09T.gdf	A09E.gdf

Her bir denemenin başında($t = 0$ s), deneğin hazırlanması için siyah ekranda bir (+) işareti belirir. Denek ekranda (+) işaretiyle eşzamanlı bir bip sesi duyar. 2 saniye sonra 1.25 saniye sürecek şekilde ilgili sınıfın imleç hareketini(sağ, sol, yukarı ve aşağı) belirten bir ok deneğe gösterilir. Bu imleç hareketleri sırasıyla sağ el hareket hayali, sol el hareket hayali, ayak hareket hayali ve dil hareket hayali sınıflarına aittir. Bu ok işareti deneğin motor hareket hayali için hazırlanması gerektiğini belirten bir işarettir. İlgili ok işareti ekrandan kaybolana kadar($t = 6$

sn) deneğin ilgili motor hareket hayalini gerçekleştirilmesi istenir. Ekranın tekrardan siyah olmasıyla denekten yaklaşık 2 saniyelik bir ara vermesi istenir. Yarışmada sunulan paradigma Şekil 1'de gösterilmiştir.




Şekil 1. Örnek bir denemenin zamana bağlı olaylar silsilesi (University of Graz, 2008)



Şekil 2. Üç Monopolar EOG kanalının elektrot Montajı

EEG verileri Şekil 3'te gösterilen elektrot lokasyonlarından 250 Hz örnekleme frekansı ile kaydedilmiştir. Veriler, 22 EEG ve 3 EOG kanalından kaydedilirken 0.5 Hz ve 100 Hz spektral aralığı kapsayacak şekilde bandpass filtreden geçirilmiştir. Buna ek olarak şebeke frekansını baskılamak için 50 Hz'lik Notch filtresi kullanılmıştır. Fz elektrot lokasyonu, referans elektrotu olarak kullanılmıştır.




Şekil 3. 22 kanallı elektrot lokasyonları

EOG kanallarından ise Şekil 2'de gösterildiği gibi 3 monopolar elektrot ile kayıtlar alınmıştır.

Yöntem

a. Adaptif Filtre

Adaptif filtre, belli değişkenler ile kontrol edilebilen bir transfer fonksiyonuna sahip ve bir optimizasyon algoritması ile bu değişkenleri optimize edilebilen lineer bir filtredir. Bir sinyale karışmış gürültüyü çıkaracak veya minimize edecek adaptif filtrenin blok diyagramı şekil 4'te verilmiştir.



Şekil 4. Adaptif filtre sisteminin blok diyagramı

Blok diyagramı verilen adaptif filtre sistemi iki girişe sahiptir. Birincil giriş $x(n)$, istenmeyen bir $m(n)$ gürültüsü ile kirlenmiş $v(n)$ istenilen sinyalini temsil eder. Referans sinyali, $r(n)$, bir şekilde birincil girişteki $m(n)$ sinyali ile korelasyonu vardır. Gürültü giderici adaptif filtrenin amacı, birincil girişteki gürültü oranı tahmin edilerek ve tahmin edilen gürültünün birincil sinyalden çıkarılmasıdır. Bu çalışmada, birincil girişe EOG ile kirlenmiş EEG sinyali, referans girişine ise üç monopolar EOG

kanalından alınan herhangi bir EOG sinyali uygulanarak birincil girişteki gürültülü EEG sinyalinin EOG'den arındırılması amaçlanmıştır.

b. RLS Algoritması

RLS yönteminde, Lineer Regresyondaki gibi cost fonksiyonu kullanılır. MSE(Mean Squared Error) kademeli olarak azaltma esasına dayanır. Least Mean Square(LMS)'den farklı olarak rasgelelik yoktur. Çözüme hızlı ulaşan bir algoritmadır. Bu yönüyle online işlemlerde de kullanılabilir.

RLS algoritması;

$$\pi(i) = P(i - 1)x(i) \quad (1)$$

$$k(i) = \frac{\pi(i)}{\lambda + x^H(i)\pi(i)} \quad (2)$$

$$\varepsilon(i) = d(i) - w^H(i - 1)x(i) \quad (3)$$

$$w(i) = w(i - 1) + k(i)\varepsilon^*(i) \quad (4)$$

$$P(i) = \lambda^{-1}P(i - 1) - \lambda^{-1}k(i)x^H(i)P(i - 1) \quad (5)$$

denklemleri ile ifade edilir. Her bir i anında tahmin edilen ağırlıklar, $i+1$ zamanına adapte olarak çözüme gidilir. RLS algoritmasında matrislerin tersini almaya gerek duyulmaz. Bu yüzden RLS algoritmasının işlem maliyeti düşüktür.

c. Ortak Uzamsal Örüntüler(Common Spatial Patterns)

Motor hayali çalışmalarında, öznitelik vektörü çıkarma hususunda en yaygın kullanılan metot, ortak uzamsal örüntüler metodudur. CSP metodu, bir sınıfın varyansını maksimuma çıkarırken aynı anda diğer sınıfın varyansını minimize eden bir algoritmadır (Aydemir Ö. 2016). EEG sinyalinin normalize edilmiş uzamsal kovaryans matrisi aşağıdaki şekilde hesaplanır;

$$M = \frac{DD^T}{\text{trace}(DD^T)} \quad (6)$$

D , bir denemenin $C \times S$ (C , kanal sayısı ve S örnek sayısı) matrisini belirtir. trace , DD^T diagonal elemanların toplamını temsil eder. Uzamsal kovaryans matrisi her bir sınıfın denemesinin ortalaması ile hesaplanır. Ortaya çıkan iki sınıflı matris toplanır ve aşağıdaki kompozit kovaryans matrisi M_C elde edilir.

$$M_C = M_1 + M_2 \quad (7)$$

M_C , öz vektörleri ve özdeğerlerini içerecek şekilde aşağıdaki gibi tekrardan düzenlenebilir.

$$M_C = E_C \lambda_C E_C^T \quad (8)$$

Denklem 8'de E_C matrisin öz vektörleri ve λ diagonal matrisin özdeğerlerini temsil eder. Varyansları eigen düzleminde birbirine eşitleyen dönüşüm,

$$W = \sqrt{\lambda_C^{-1}} E_C^T \quad (9)$$

formülü ile hesaplanır. W , ortalama kovaryans matrislerinin dönüşümünde,

$$K_1 = W M_1 W^T \quad K_2 = W M_2 W^T \quad (10)$$

şeklinde kullanılır. K_1 ve K_2 ortak öz vektörlerini paylaşır ve iki matrisin özdeğerlerinin toplamı her zaman 1'e eşittir.

$$K_1 = U \lambda_1 U^T \quad K_2 = U \lambda_2 U^T \quad (11)$$

$$\lambda_1 + \lambda_2 = I \quad (12)$$

Yukarıdaki denklemde I eş matristir. Son olarak projeksiyon matrisinde,

$$P = (U^T W)^T \quad (13)$$

Kolonlar P^{-1} , ortak uzamsal örüntülerdir. Projeksiyon matrisi ile birlikte, her bir denemenin ayrıştırılması,

$$V = \frac{\sum(Z_R - \bar{Z}_R)^2}{L-1}$$

(14)

Denklem 13'te Z_R , Z matrisinin bir satırı ve L ise bu satırın uzunluğudur.

d. Sınıflandırma Algoritmaları ve Performans Kriterleri

Bu çalışmada, Sınıflandırma algoritması olarak Linear Diskriminant Analizi(LDA), Naive Bayes(NB), K En Yakın Komşu Algoritması(k-NN) ve Destek Vektör Makinaları(DVM veya SVM) kullanılmıştır. Kullanılan sınıflandırma algoritmalarının lineer veya non-linear olması durumlarına göre çıkarımlar yapılmıştır.


Performans ölçümleri 2 kritere göre yapılmıştır. Bu kriterlerden birincisi Doğruluk(Accuracy), ikincisi ise Kappa Skor'dur. Sınıflandırma işlemlerinde daha gerçekçi başarımlar elde etme amacıyla Cohen tarafından 1960 yılında sunulan Kappa Skor hem çoklu hem de 2 sınıflı uygulamalarda sıkça kullanılmaktadır.

Uygulama


4 sınıflı ve 288 deneme olan veri seti, Matlab ortamında belli proseslerden geçirilerek 2 sınıflı(sağ ve sol el) ve dolayısıyla 144 deneme haline getirilmiştir. Bu şekilde bir eğitim veya test verisi, 144 denemeden oluşmaktadır. Her bir denemenin içerisinde 22 EEG kanalı ve 3 EOG kanalı mevcuttur. Veri ön işleme kısmının ikinci aşamasında her bir deneye ait her bir denemenin 22 kanalı ayrı ayrı bandpass ve adaptif filtrelerinden geçirilmiştir. Motor hayali verilerinin bulunduğu spektral aralık 8-30 Hz olduğundan veriler, bandpass filtreleri ile 8-30 Hz frekans aralığına filtrelenmiştir. Bu şekilde EOG'den kaynaklı yüksek frekans bileşenleri de toplamda 22 kanallı her bir EEG denemesinden temizlenmiştir. Adaptif filtre ile temizleme aşamasında EOG1 kanalı(23. Kanal), adaptif filtrenin referans girişine, gürültülü her bir EEG denemesinin 22 kanalı, adaptif filtrenin birincil girişine(Primary Input) sırayla uygulanmıştır.

Adaptif filtrenin çıkışında her bir EEG denemesinin 22 kanalı EOG'den arındırılmıştır. Temizlenmiş deneme verileri ayrı ayrı CSP metoduna tabi tutulmuştur. Bu şekilde her bir denemenin 22 kanalı CSP algoritmasına giriş olarak uygulanmıştır. CSP algoritmasının çıkışında her bir denemeden 4 öznitelik vektörü elde edilmiştir. CSP ile çıkarılan bu 4 öznitelik vektörü, Naive Bayes, SVM, k-NN ve LDA sınıflandırıcılarının girişlerine uygulanmıştır. Konfüzyon matrisleri elde edilen verilerin her bir sınıflandırıcı ile ilgili accuracy ve kappa metrik performans değerleri elde edilmiştir.

Şekil 5 ve Şekil 6'da sınıflandırmaya dahil edilecek sağ ve sol el motor hareket hayali EEG verilerinin C3 kanalı verisi ve bu EEG sinyallerinden temizlenecek EOG sinyallerinin 3 saniyelik örnek kesitleri Matlab ortamında zaman domeninde çizdirilmiştir. 3 saniye, 250 Hz ile örneklenmiş frekansın 750-1500 sample(örnek) aralığını kapsıyor.

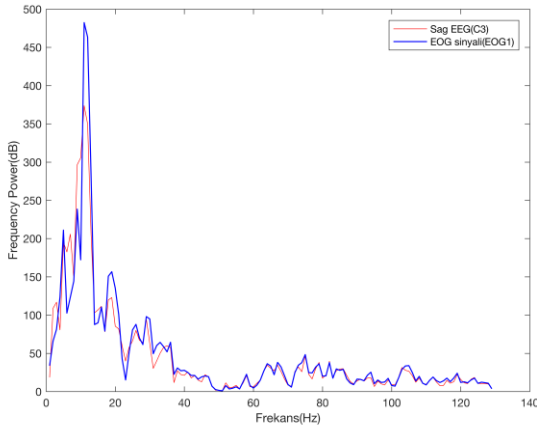


Şekil 5. Örnek sağ el motor hayali EEG ve EOG sinyali




Şekil 6. Örnek sol el motor hayali EEG ve EOG sinyali

Şekil 7 ve Şekil 8'de, yukarıda, zaman domeninde çizdirilen sağ ve sol motor hareket hayali sinyalleri, welch psd yöntemiyle frekans domeninde çizdirilmiştir. Bu şekilde sinyallerin güç yoğunluklarının hangi bantlara yayıldığı gözlemlenebilir.



Şekil 7. Örnek sağ el motor hareket hayali C3 kanalı verisi ve EOG1 sinyalinin spektral gösterimi



Şekil 8. Örnek sol el motor hareket hayali C3 kanalı verisi ve EOG1 sinyalinin spektral gösterimi

Şekil 7 ve Şekil 8'de motor hayali sinyallerinin alfa ve beta bandına yayıldığı gözlemlenebiliyor. EOG sinyalleri farklı durumlarda 1-2 Hz, 2-4 Hz, 4-8 Hz, 8-16 Hz, 16-30 Hz ve az da olsa 30 Hz üstünde spektral değişimler gösterir (Daud, W. B. W., ve Sudirman, R. 2011). EOG sinyallerinin 8-16 Hz spektral özellikler sergilemesi, motor hayali EEG sinyallerini de etkiler. Çünkü motor hayali sinyallerinde spektral öznitelikler çıkarılırken çoğunlukla 8-30 Hz frekans bandı öznitelik olarak seçilir. Şekil 7 ve Şekil 8'de eşzamanlı alınan EOG gürültüsünün spektral karakteristiklerinin bazı noktalarda EEG sinyallerini etkilediği gözlemlenebiliyor. Bu noktada veri ön işleme kısmında yapılması gereken iş sınıflandırılabilir esas ayırt edici bilgiye zarar vermeden gürültü bileşenini ortadan kaldırmaktır. Bu durum için RLS algoritması ve klasik bant geçiren filtrelerden chebyshev I, chebyshev II ve Eliptik filtreler seçilerek sonuçları karşılaştırılmıştır.

Başarımlar


Tablo 2'de, 9 denek için kullanılan bütün filtrelerin ortalama sınıflandırma performansları gösterilmiştir. Chebyshev II filtresi SVM ile %72 ortalama sınıflandırma performansı ile bütün filtrelere kıyasla en yüksek sonuçlara ulaşmıştır. Chebyshev I filtresi en yüksek sınıflandırma performansını, %69 ortalama sınıflandırma performansı ile LDA

sınıflandırıcısı ile elde etmiştir. Elliptic filtre %68 ortalama sınıflandırma performansını %68 ile elde etmiştir. Adaptif filtre, %64 ortalama sınıflandırma performansını LDA kombinasyonu ile elde etmiştir. Tablo 2'ye bakarak sınıflandırıcı bazında en yüksek performansın lineer sınıflandırıcılara (SVM ve LDA) ait olduğu çıkarımı yapılabilir. Naive Bayes ve k-NN algoritması lineer sınıflandırıcılara göre daha düşük performans göstermiştir. Tablo 2'de belki de en çok dikkat edilen noktalardan biri adaptif filtrenin diğer sınıflandırıcılara göre düşük performans sergilemesidir. Bunun önemli nedenlerinden biri motor hareket hayali bilgisinin 7.5-30 Hz arasında olmasıdır. Yüksek performans elde edebilmek için yapılan bant geçiren filtre kalibrasyonlarında en yüksek performans sonuçları, 7.5 Hz ile 21 Hz aralığına kalibre edilen bant geçiren filtrelerden elde edildi. Bu aslında motor hareket hayali bilgisinin 7.5-30 Hz arasında olmasını teyit eder niteliktedir. Şekil 9 ve Şekil 10'da örnek bir sol el ve sağ el motor hareket hayalinin frekans güç yoğunlukları çizdirilmiştir. Her iki çizelge de adaptif filtrenin EOG sinyalini temizlediği görülebiliyor. Fakat adaptif filtrenin 30 Hz üzerindeki frekansları baskılamadığı ve adaptif filtre ile temizlenen sinyalin 30-130 Hz aralığında frekans bileşenlerine sahip olduğu görülüyor. Yapılan bant geçiren filtre kalibrasyonlarından anlaşılacağı gibi 30 Hz üzerindeki frekans bileşenleri genel anlamda sınıflandırma performansını düşürecek niteliktedir.


Tablo 2. 4 filtre ile elde edilen ortalama sınıflandırma performansları

CHEB. TYPE I	k-NN	NB	SVM	LDA
DOĞRULUK	0,62	0,67	0,68	0,69
KAPPA SKOR	0,24	0,35	0,36	0,37
CHEB. TYPE II	k-NN	NB	SVM	LDA
DOĞRULUK	0,67	0,68	0,72	0,71
KAPPA SKOR	0,38	0,40	0,43	0,42
ELLİPTİK FİLTRE	k-NN	NB	SVM	LDA

DOĞRULUK	0,62	0,66	0,67	0,68
KAPPA SKOR	0,24	0,33	0,34	0,36
ADAPTİF FİLTRE	k-NN	NB	SVM	LDA
DOĞRULUK	0,59	0,60	0,62	0,64
KAPPA SKOR	0,20	0,22	0,29	0,31



Şekil 9. Örnek sol el motor hareket hayalinin C3 kanalının frekans gücü yoğunluğu



Şekil 10. Örnek sağ el motor hareket hayalinin C3 kanalının frekans gücü yoğunluğu

Tablo 3'te her bir deneğe ait filtre-sınıflandırıcı kombinasyonlarının en yüksek performans değerleri gösterilmiştir. 3. Denek, 10-20 Hz elliptik filtre kalibrasyonu ve LDA sınıflandırıcısıyla %100'lük bir doğruluk oranına yükselmiştir. Ayrıca belirtilen frekans kalibrasyonu ile 3. Denek üzerinde Naive Bayes sınıflandırıcısı da %100'lük doğruluk performansı göstermiştir. 3. Denek ile ilgili elliptik filtre sonuçları Tablo 4'te gösterilmiştir.

Bu oranlar, çalışmada yapılan bütün varyasyonlardan en başarılı performanslarıdır.

Tablo 3. En yüksek filtre-sınıflandırıcı performansları kombinasyonları

	ACCURACY	KAPPA	FİLTRE- SINIFLANDIRICI KOMBİNASYONU
1. DENEK	%80	0.60	(CHEB.II+LDA)
2. DENEK	%61	0.22	(CHEB.II + LDA)
3. DENEK	%100	1	(ELLIPTIC + LDA)
4. DENEK	%60	0.19	(CHEB.II + SVM)
5. DENEK	%58	0.15	(CHEB.I + NB)
6. DENEK	%57	0.13	(CHEB.I + NB)
7. DENEK	%72	0.43	(CHEB.II+ LDA)
8. DENEK	%94	0.88	(CHEB.II + SVM)
9. DENEK	%80	0.60	(CHEB.II+SVM)

Tablo 4. En yüksek sınıflandırma performansı (Elliptic filtre, 3. Denek)

	K-NN	NB	SVM	LDA
DOĞRULUK	%94	%100	%99	%100
KAPPA SKOR	%88	%100	%98	%100

Sonuç ve Öneriler

Bu çalışma, sağ ve sol motor hareket hayalinin, EEG verileri üzerinde oluşan etkilerini tespit etme amacıyla gerçekleştirilmiştir. Ayrıca, EOG verileri kullanılarak temizlenen adaptif filtreler ve non-adaptif filtreler ile temizlenen EEG verilerinin sınıflandırma sonuçlarına mukayesesi amaçlanmıştır.

Adaptif filtre olarak RLS algoritması ve bant geçiren filtre olarak Chebyshev I, Chebyshev II ve Elliptik filtreleri seçilmiştir. Bu filtrelemelerden elde edilen veriler öznitelik

çıkarma yöntemi olan CSP algoritmasına giriş olarak uygulanmıştır. Her bir denemenin 22 kanalı CSP algoritmasına giriş olarak verilmiştir. CSP algoritmasının çıkışında her bir deneme için 4 öznitelik vektörü elde edilmiştir. Elde edilen bu öznitelik vektörleri k-NN, Naive Bayes, SVM ve LDA sınıflandırma algoritmalarının girişine uygulanmıştır. Sınıflandırma sonuçları, Doğruluk, Kappa Skor performans kriterlerine göre değerlendirilmiştir.

9 deneğin ortalama performansı dikkate alındığında, en yüksek performans ortalamasını, %72'lik doğruluk performansı ve %43'lük kappa skoru ile chebyshev 2+LDA sınıflandırıcısı kombinasyonu göstermiştir. Sınıflandırıcı bazında ortalama başarımlarda LDA ve SVM, k-NN ve Naive Bayes'ten daha yüksek performans sergilemiştir. 3. denek üzerinde Elliptik filtre ve LDA kombinasyonu %100 doğruluk oranı ve 1 kappa skoru ile en yüksek başarımları sağlamıştır. RLS adaptif filtresi ile yapılan sonuçların diğer filtreler göre daha düşük olduğu gözlenmiştir.

Sonuçlardan da anlaşılacağı üzere, sağ ve sol motor hareket hayalini tespit, non-adaptif filtreler ile yapılan uygulama, adaptif filtre ile yapılan uygulamadan daha iyi sonuçlar vermiştir. Çünkü motor hareket hayali bilgisi frekans aralığının üzerindeki etki aralığı 8-30 Hz olduğu bilinmektedir. Bu aralığın belli olması ve non-adaptif filtrelerin kesim frekansı bölgesi bilindiği için non-adaptif filtre kullanım imkanı oluşmaktadır. Bu gerekçeden ötürü, yapılan çalışmamızda, non-adaptif filtre ile yapılan uygulama sonuçları, adaptif RLS filtresi uygulama sonuçlarına göre daha iyi sonuçlar vermektedir. Bu sonuçlara göre kesim frekansları belli olmayan gürültüleri gidermede adaptif filtreler önerilebilir.

Kaynaklar

- Akinci B. (2010). Realization of a cue based motor imagery brain computer interface with its potential application to a wheelchair. Yüksek lisans tezi, Orta Doğu Teknik Üniversitesi Fen Bilimleri Enstitüsü, Ankara. 157
- Ang, K. K., Chin, Z. Y., Zhang, H., & Guan, C. (2008). Filter bank common spatial pattern (FBCSP) in brain-computer interface. IEEE International Joint Conference on Neural Networks, IEEE World Congress on Computational Intelligence, P. 2390-2397.
- Aydemir, Ö. (2016). Common spatial pattern-based feature extraction from the best time segment of BCI data. Turkish Journal of Electrical Engineering & Computer Sciences, 24(5), 3976-3986
- Belwafi, K., Djemal, R., Ghaffari, F., & Romain, O. (2014, December). An adaptive EEG filtering approach to maximize the classification accuracy in motor imagery. In 2014 IEEE Symposium on Computational Intelligence, Cognitive Algorithms, Mind, and Brain (CCMB) (pp. 121-126). IEEE.
- Cheok, N. S., & Raveendran, P. (2008). Removal of EOG artifacts using ICA regression method. In 4th Kuala Lumpur International Conference on Biomedical Engineering 2008 (pp. 226-229). Springer, Berlin, Heidelberg.
- Daud, W. B. W., & Sudirman, R. (2011, May). Time frequency analysis of electrooculograph (EOG) signal of eye movement potentials based on wavelet energy distribution. In 2011 Fifth Asia Modelling Symposium (pp. 81-86). IEEE.
- He, P., Wilson, G., & Russell, C. (2004). Removal of ocular artifacts from electro-encephalogram by adaptive filtering. Medical and biological engineering and computing, 42(3), 407-412.
- Hsu, W. Y., Lin, C. H., Hsu, H. J., Chen, P. H., & Chen, I. R. (2012). Wavelet-based envelope features with automatic EOG artifact removal: Application to single-trial EEG data. Expert Systems with Applications, 39(3), 2743-2749.
- Kumar, P. S., Arumuganathan, R., Sivakumar, K., & Vimal, C. (2009). An adaptive method to remove ocular artifacts from EEG signals using wavelet transform. J. Appl. Sci. Res, 5(7), 711-745.
- Robinson, N., Vinod, A. P., Guan, C., Ang, K. K., & Peng, T. K. (2011). A Wavelet-CSP method to classify hand movement directions in EEG based BCI system. In 2011 8th International Conference on Information, Communications & Signal Processing (pp. 1-5). IEEE.
- University of Colorado, (2019), Adaptive Filters, Chapter 8, 1-26

Applications of Adaptive And Non-Adaptive Filters For Classification Of EEG Signals of Motor Imagery

Extended abstract

Brain Computer Interface(BCI) is based on the classification of human intentions or intentional thought without the need for any physical ability. In BCI studies, signals which obtained using Electroencephalography(EEG) exposed to some environmental or internal noise (eye movements, ECG, etc.). One of the artifacts that can significantly affect classification accuracy is electrooculogram(EOG). In this study, BCI competition IV dataset 2a was used which was organized by the University of Graz. The data set with 4 classes was reduced to 2 classes and only the right and left motor imagery data were classified according to the offline paradigm. Training and test data were obtained from 9 subjects. Two sessions were conducted for each subject. Each session consists of 144 trials for two classes, right and left. Simultaneously with EEG data from 22 channels, EOG data were obtained from 3 electrodes mounted around the eye. The data was filtered through a bandpass filter to cover the spectral range of 0.5 Hz and 100 Hz. In addition, a 50 Hz Notch filter is used to suppress the grid frequency. Conventional bandpass filters and recursive least square (RLS) adaptive filters are used to remove EOG noise from EEG signals. In each trial, the 3-6 second time period of right and left hand motor imagery was included in the study. The specified time period (3 seconds) covers the 750-1500 sample range of the frequency sampled at 250 Hz. Feature vectors extracted from filtered signals by CSP method were applied to the inputs of linear discriminant analysis (LDA), support vector machines (SVM), naive bayes (NB) and k-NN classification algorithms. The combination of Chebyshev type 2 filter and SVM achieved the highest classification performance with an average accuracy of 72%. On a classifier basis, LDA and SVM outperformed k-NN and Naive Bayes in average performances. On the third subject, the elliptical filter and LDA

combination achieved the highest performance with 100% accuracy and 1 kappa score. Furthermore, the classification results obtained with the RLS adaptive filter were compared with those of the bandpass filters. The combination of the RLS algorithm and the LDA classifier showed lower performance than traditional bandpass filters with a 64% accuracy rate. In the study, it was confirmed by welch's power spectral density diagrams that the motor imaginary information was between 7-30 Hz. The findings of the study support the literature and may shed light on future studies.

Keywords: Adaptive filter, Recursive least square, Brain Computer Interface, Electrooculogram, Electroencephalography, Traditional bandpass filters