

MÜZİK SINIFLANDIRMASI BEYİN BİLGİSAYAR ARAYÜZÜ UYGULAMALARI İÇİN BİR ALTERNATİF OLABİLİR Mİ?

*Nurhan GÜRSEL ÖZMEN **

*Ebru DURMUŞ ***

*Zhaleh SADREDDİNİ ****

Alınma: 12.02.2016; düzeltme: 08.03.2017; kabul: 03.05.2017

Öz: İnsan beyninin çalışma mekanizmasını değerlendirmek için yapılan nörolojik çalışmalar, müziğin bu konuda değerlendirilebilecek önemli bir araç olduğunu göstermektedir. Bu çalışmada, müzik dinleme görevlerinin, beyin bilgisayar arayüzü (BBA) sisteminde kullanılabilirliği araştırılmıştır. Müzik görevlerinin diğer zihinsel ve motor görevlerle sınıflandırma performansları değerlendirilmiştir. Üç sağlıklı katılımcı ile gerçekleştirilen deneysel çalışmada, yedi farklı görevin ikili sınıflandırma sonuçları değerlendirilmiştir. Bu görevler, iki farklı müzik türünü dinleme, rahat durum, zihinden problem çözme, sağ el hareket hayali, sol el hareket hayali ve A harfi hayali görevleridir. Elde edilen EEG verilerinden Öz bağlanım (AR) parametreleri, Hjorth parametreleri, güç spektral yoğunluk (PSD) parametreleri ve PSD+frekans karakteristikleri öznitelik olarak çıkarılmış ve performansları Destek Vektör Makinesi (DVM), k-En Yakın Komşuluk (k-NN) ve Yapay Sinir Ağları (ANN) sınıflandırıcıları ile değerlendirilmiştir. Öznitelikler olarak AR parametreleri kullanılması durumunda, en yüksek sınıflandırma başarıları %100 DVM ve % 100 ANN olarak elde edilmiştir. Sınıflandırma başarımları beyin farklı bölümlerini temsil eden farklı elektrotlar açısından da değerlendirilmiş ve müzik görevlerinin ayrıştırılmasında C3 kanalının daha başarılı olduğu görülmüştür. Elde edilen sonuçlara bağlı olarak, müzik dinleme görevinin beyinde farklı frekanslarda etki yarattığı ve bu farklılığın tıbbi, askeri ya da e-oyun gibi beyin bilgisayar ara yüzü uygulamalarında kullanılması önerilmektedir.

Anahtar Kelimeler: BBA, EEG, müzik dinleme görevi, öznitelik çıkarma, sınıflandırma

Can Music Classification be an Alternative for Brain Computer Interface Applications?

Abstract: Neurological studies on human brain show that, music is an important tool that can be assessed for understanding the mechanism of the brain. In this study, the availability of music classification for brain computer interface systems was studied. Moreover, classification performances of music tasks with other mental and motor tasks are evaluated. An experimental study was carried out with three different subjects executing seven different tasks. These tasks are; listening to music, relax, mental arithmetic, imagery right hand movement, imagery left hand movement and the letter A imagination task. Autoregressive (AR) parameters, Hjorth parameters, power spectral density (PSD) values and PSD+ frequency characteristics were extracted as features from the resulting EEG data. Their classification performances are tested with Support Vector Machines (SVM), k-nearest neighborhood (k-NN) and Neural Network (ANN) classifiers. By using AR parameters as features, the highest classification performances were obtained as 100% SVM and 100% ANN. Classification performances were also evaluated for different electrodes representing different sections of the brain and it is observed that, C3 channel has the highest performance for music tasks. As a result, we can conclude that music tasks affect

* Karadeniz Teknik Üniversitesi, Mühendislik Fakültesi, Makina Mühendisliği Bölümü, 61080, Trabzon

** Nişantaşı Üniversitesi, Meslek Yüksekokulu, Makine Programı, Kağıthane, İstanbul

*** Karadeniz Teknik Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, 61080, Trabzon
İletişim Yazarı: Nurhan Gürsel Özmen (gnurhan@ktu.edu.tr)

different frequencies in the brain, and that difference can be used in different brain computer interface applications like medical, military or e-gaming applications.

Key Words: BCI, EEG, music listening tasks, feature extraction, classification

1. GİRİŞ

Müzik, insan ruhu üzerinde en derin etkiyi bırakan sanat dalıdır. Yapılan araştırmalar, ses dalgalarının insanların nörolojik sisteminde büyük etkisinin olduğunu göstermiştir. Düzenli olarak müzik dinlemek, nöron ve sinapsları daha aktif hale getirirken, sevilen müzikleri dinlemek zihinsel yorgunluğu azaltmaya yardımcı olmaktadır. Dolayısıyla insan beyninin çalışma mekanizmasını değerlendirmek için yapılan nörolojik çalışmalar, müziğin bu konuda değerlendirilebilecek önemli bir araç olduğunu göstermektedir (Peretz ve Zatorre, 2005). Müzik türlerinin her birinin insan beyninde farklı bölümlerde, farklı frekans bantlarında ortaya çıktığı bilinmektedir. Beyindeki elektriksel potansiyeldeki bu değişimleri de Elektroansefalogram (EEG) ile ölçüp incelemek mümkündür (Asada ve diğ.,1999).

Müzik dinlemenin insan beyni üzerinde yarattığı etkilerden yola çıkılarak, müzikle ilişkili beyin bilgisayar arayüzü uygulamaları geliştirme fikri doğmuştur. Beyin bilgisayar arayüzü (BBA) sistemi, insanların düşüncelerini ve isteklerini dış dünyaya iletirken beynin olağan iletim sistemleri olan sinirleri kullanmak yerine, beyin bünyesinde bulunan sinyal türlerinin aktivasyonları tespit edilerek, bunların dış ortama bir cihaz vasıtasıyla aktarılmasını sağlayan iletişim sistemidir (Wolpaw ve diğ., 2000). Bu sayede insanlar, bir bilgisayar veya başka bir cihazla dış dünyayla iletişim kurabilecek veya belli ihtiyaçlarını karşılayabileceklerdir. Son yıllarda tıbbi ve askeri uygulamalarda ve bilgisayar dünyasında sanal oyun uygulamalarında denenmesine rağmen, beyin bilgisayar arayüzü çalışmaları hala kişiye özgü geliştirilen teknolojilerle sınırlıdır (Mühl ve diğ.,2014). EEG işaretlerinden saklı bilgiyi ortaya çıkarabilmek ve onları doğru bir şekilde sınıflandırabilmek için çok çeşitli öznitelik çıkarma ve sınıflandırma yöntemleri denenmiştir (Bashashati ve Fatourehchi,2007), (Lotte ve diğ.,2007).

Literatürdeki, EEG tabanlı müzik çalışmaları üç açıdan ele alınmıştır. Birincisinde, müzik dinletilerek ve müzik dinletilmeden zihinsel görevleri yerine getirenler incelenmiş (Dey ve diğ.,2013), ikincisinde ise müzisyen ve müzisyen olmayan insanlar arasında müzik türlerine göre farklılıklar EEG sinyallerinden ayırt edilmeye çalışılmıştır (Kristeva ve diğ.,2003, Bhattacharya ve diğ., 2001) . Üçüncüsünde ise, farklı müzik türleri ile kişilerin duygusal durumları arasındaki ilişki araştırılmıştır (Makeig ve diğ., 2011). Beyin Bilgisayar Arayüzü (BBA) uygulaması olarak müzikten faydalanılması ise Grierson(2008) tarafından başlatılan düşünce gücüyle beste yapma çalışmasıdır. Hinterberger ve diğ., (2005), Lin ve diğ., (2009) ve Hamadicharef ve diğ., (2010), müzik ve insanlarda ortaya çıkardığı duygular etkileşiminden faydalanan çalışmalar yürütmüşlerdir.

Günümüze kadar yapılan EEG çalışmalarında, beynin farklı bölümlerinin müziğin yorumlanmasında ne derece etkili oldukları konusunda bir uzlaşmaya varılamamıştır (Bhattacharya ve diğ.,2001). Bu çalışmalarda daha çok insan beyninin sesli uyarılarla ilgili bölümlerinin tespitine çalışılmış, zaman domayninde analizler yapılmıştır. Müziğin algılanması işlemi yalnızca beyindeki farklı kortikal bölgelerin aynı anda aktive olmasıyla değil aynı zamanda bu bölümler arasında yüksek oranda fonksiyonel koordinasyona ve iletişime ihtiyaç duyar (Wu ve diğ.,2012).

(Durmuş ve diğ., 2014) bir çalışmalarında zihinsel ve motor görevler için farklı öznitelik yöntemleri ve sınıflandırıcıların başarılarını araştırmışlardır. Bir başka çalışmada ise (Durmuş ve Özmen, 2015) yine zihinsel ve motor görevler için Bağımsız Bileşen Analizi ve Sürekli Dalgacık Dönüşümü yöntemleriyle öznitelik çıkarma yöntemlerinin performanslarını değerlendirmişlerdir. Bu çalışmada, literatürdeki uygulamalardan farklı olarak, müzik dinleme görevinin BBA uygulamalarında etkin bir ayırt edici görev olarak kullanılabilirliği araştırılmıştır. Müzik görevi, zihinsel ve motor görevler gibi ayrı bir görev olarak ele alınarak, farklı öznitelik çıkarma yöntemleri ve farklı sınıflandırıcılar ile analiz edilmiştir. Ayrıca farklı

müzik türlerinin (klasik, rock) kendi aralarındaki ve diğer zihinsel ve motor görevlerle aralarındaki sınıflandırma performansları karşılaştırılmıştır. Elde edilen sonuçlarla, müzik görevlerine dayalı BBA uygulamalarının, örneğin sanal oyun geliştirme ve nöropsikiyatri alanları için alternatif birer yöntem olarak sunulması hedeflenmektedir.

2. DENEYSEL ÇALIŞMA

Bu çalışmada kullanılan EEG verilerinin tamamı Karadeniz Teknik Üniversitesi Makine Mühendisliği Bölümü'nde bulunan Biosemi Active Two EEG Sistemi ile gerçekleştirilen ölçümlerden elde edilmiştir.

2.1. Katılımcılar ve İşlem Adımları

Deneyssel çalışma, gönüllü üç katılımcı ile gerçekleştirilmiştir. Bu katılımcılar, ortalama 22.33 (± 0.57) yaşlarında, herhangi bir nörolojik, psikolojik, kronik hastalık tanısı olmayan ve sağ elini kullanan, Karadeniz Teknik Üniversitesi Makine Mühendisliği öğrencileridir. EEG kayıtları sessiz, sakin, gün ışığı ile aydınlatılmış bir odada gerçekleştirilmiştir. Deney esnasında katılımcılar, gözleri açık olarak ve hareket etmeden rahat bir sandalyede oturmaktadırlar. Katılımcılara, işlem adımları ölçümler öncesinde araştırmacı tarafından anlatılır (Özmen ve Gümüşel, 2010, Özmen ve Gümüşel, 2011, Durmuş ve diğ., 2014). Katılımcılar zihinsel, motor ve müzik görevlerinden oluşan yedi farklı görevi yerine getirmişlerdir. Zihinsel ve motor görevler Anderson ve diğ., (1995) ve Anderson ve Sijercic (1996)'dan hareketle belirlenmiştir. Diğer çalışmalardan (Özmen ve Gümüşel, 2010, Özmen ve Gümüşel, 2011, Durmuş ve diğ., 2014 ve Durmuş ve Özmen, 2015) farklı olarak, bu çalışmada görevler arasında müzik görevleri de eklenmiştir (Sadreddini ve diğ., 2014). Görevlerin gerçekleştirilmesi esnasında, her bir deneme 10 saniyelik bir kaydı içermektedir ve ardışık deneyler arasında 2-3 saniyelik ara verilmektedir. Yedi farklı görev için 7 x 100 (Görev sayısı x Deneme sayısı) farklı kayıt gerçekleştirilmiştir. Tüm görevler gözler açık iken kaydedilmiştir.

Görev tanımları aşağıdaki şekildedir:

Rahat durum (Görev 1): Temel görev olarak adlandırılan bu görev esnasında deneklerin rahat bir şekilde hiçbir şey düşünmeden beklemeleri istenmektedir.

Matematiksel işlem (Görev 2): Bu görevde deneklerden zihinden iki basamaklı bir çarpma problemini çözmeleri istenir (24x72 gibi). İşlemler her defasında değişkendir ve 10 saniye sonunda denneğin sonucu bulup bulamadığı kontrol edilir.

Sağ el hareketi hayali (Görev 3): Bu esnada deneklerin sağ ellerini ardışık hareket ettirdiklerini hayal etmeleri istenir. Bu hareketlerin seçilme nedeni, motor görevlerle sezgisel görevler arasındaki ayrımları fark etmek amaçlıdır.

Sol el hareketi hayali (Görev 4): Bu görev sağ el hareketi hayali ile aynıdır.

A harfi hayali (Görev 5): Bu görev esnasında deneklerin zihinlerinde yanıp sönen veya bir ekrana yazılmış şekilde A harfini canlandırmaları istenir.

Klasik müzik dinleme (Görev 6): Bu görev esnasında denek kulaklık ile sözsüz klasik müzik dinlemektedir.


Rock müzik dinleme (Görev 7): Bu görev de klasik müzik dinleme görevine benzer şekilde uygulanır.

Bu yedi görev, çalışmanın devamında birbirleriyle karşılaştırılırken kullanım kolaylığı sağlaması için sırasıyla Görev1, Görev2, Görev3, Görev4, Görev5, Görev6 ve Görev7 olarak adlandırılmıştır.

2.2. EEG Veri Kaydı ve Önileme

EEG verileri, Biosemi ActiveTwo EEG sistemi ile, Uluslararası 10-20 elektrot yerleşim düzenine göre yerleştirilmiş başlık kullanılarak kaydedilmiştir. Kaydedilen veriler sayısal ortama 512 Hz ile aktarılmıştır. Verilerin analizi MATLAB programı ile yapılmıştır. Sinyal analizi için 64 kanal arasından seçilen belirli 6 elektrot kanalına ait EEG verileri kullanılmıştır. Bu 6 kanal, (C3, C4, P3, P4, O1 ve O2 kanalları), beynin her iki yarıküresindeki merkezi

(Central), yan (parietal) ve arka (oksipital) bölümlerini temsil etmektedir. Farklı zihinsel aktiviteler ve özellikle müzik dinleme esnasında farklı türden işaretler üretildiği bilindiğinden, o bölgeleri kapsayacak şekilde seçilmiştir. Tek numaralar sol yarıküreyi, çift numaralar sağ yarıküreyi göstermektedir. Seçilen her bir elektrot kanalının sınıflandırmadaki etkilerini görebilmek amacıyla, sınıflandırma başarımları elektrot bazında incelenmiştir (Özmen ve Gümüşel, 2013, Durmuş ve Özmen 2015). Şekil 1’de 64 kanalın Biosemi elektrobaşıklık üzerindeki yerleşim düzeni görülmektedir.




Şekil 1:

64 kanallı Biosemi elektrot yerleşim düzeni

Müzik dinleme esnasında sesler, işitsel korteksde algılandıktan sonra beyin korteksinde diğer alanlarla etkileşim kurulur ve duyu merkezlerinden daha önce alınmış verilere ulaşarak müziğin daha önce dinlendiği anda kaydedilen tatlar, kokular ve duyularla bağdaştırılır. Bu nedenle, her bireyin beyinde aynı müziğin tam olarak ne yaptığını nörofizyolojik bir mekanizma ile açıklamak kolay değildir. Fakat müziğin insan beyinde değerlendirilmesinde, beyin farklı merkezlerinin birbiriyle ortak çalıştığı bilinmektedir. Bu durum Şekil 2’de sunulmuştur. Ayrıca, müzik dinleme anında çoğunlukla beyin merkezi ve parietal bölümlerinin aktif olduğu Bhattacharya ve diğ.,(2001), Hadjidimitrou ve Hadjileontiadis (2012) ve Dey ve diğ. (2013) tarafından ortaya konmuştur.

Söz konusu deneysel çalışma, beyin bilgisayar ara yüzlerinde kullanılabilirlik açısından incelendiğinden, kaydedilen verilerin hepsi analize tabi tutulmuş, herhangi bir veri atılmamıştır. Öncelikle, kaydedilen EEG işaretlerinden doğru ve yüksek performanslı bir sınıflandırma sonucu elde edebilmek için EEG işaretine dâhil olan bozucuların ayıklanması gerekir. Bu nedenle bu çalışmada bozucuların etkisini azaltabilmek için deneklerden gözlerinin açık fakat deney esnasında (her bir 10 saniyelik periyotta) gözlerini mümkün olduğunca hareket ettirmemeleri istenmektedir. Kaydedilen işaretleri, bozucu ve gürültülerden ayıklamak için 1-30 Hz aralığını geçiren Eliptik bant geçiren süzgeç kullanılarak, filtreleme işlemi gerçekleştirilmiştir.




Şekil 2:

İnsan beyninde müziğin algılanması ve işlenmesi

(<http://muzisyenbeyin.blogspot.com.tr/2013/10/muzigin-vucudumuzdaki-hormonlar-ve.html>)

EEG verisine uygulanan analiz adımları Şekil 3'de gösterilmektedir.



Şekil 3:

EEG verisi için analiz adımları

2.3. Öznitelik Çıkarma

Öznitelik çıkarmanın temel amacı kaydedilen EEG verilerinin ayırt edici özelliklerinin çıkarılıp öznitelik vektörünün elde edilmesidir. Bu çalışmada, öznitelik vektörleri olarak, Öz bağlantım katsayıları (AR), Hjorth parametreleri, güç spektral yoğunluğu (PSD) ve EEG işaretlerinin güç spektral yoğunluğundan elde edilen alfa ve beta frekans bantlarına ait genlik değerleri (PSD+frekans) (Sadreddini ve diğ.2014) kullanılmıştır. Bu dört öznitelik çıkarma yöntemi ile elde edilen sınıflandırma performansları karşılaştırılarak, sonuçlar değerlendirilmiştir (Sadreddini ve diğ.,2014).

AR Parametreleri: Mertebesi p olan Öz bağlanım modeli (AR), Eşitlik 1 ile hesaplanmaktadır. Bu eşitlikte $x(n)$ çıkış dizini, $e(n)$ varyansı σ^2 olan beyaz gürültü dizini, $a(k)$ ise Öz bağlanım (AR) parametrelerini ve/veya öznitelikliğini belirtmektedir. $AR(p)$ modeli, $\{a[1], a[2], \dots, a[p], \sigma^2\}$ AR model parametreleri ile karakterize edilir.

$$x[n] = -\sum_{k=1}^p a[k]x[n-k] + e[n] \quad (1)$$

Hjorth parametreleri: Hjorth tanımlayıcıları, üç alt parametrenin birleşmesiyle oluşturulmuştur. Bu parametreler şu şekildedir: işleklik, taşınırlık ve karmaşıklık. İşleklik en sade haliyle sinyalin enerjisi (σ_x) olarak tanımlanır. Taşınırlık ise Eşitlik 2 ile ifade edildiği gibi, x sinyalinin birinci türevinin standart sapmasının sinyalin standart sapmasına oranı şeklindedir.

$$T = \frac{\sigma_{x'}}{\sigma_x} \quad (2)$$

Karmaşıklık diğer adıyla biçim faktörü (BF) sinyalin formu ile ilgili hesaplanabilir bir değer verir.

$$BF = \frac{Tx'}{Tx} = \frac{\sigma_{x''} / \sigma_{x'}}{\sigma_{x'} / \sigma_x} \quad (3)$$

Güç spektral yoğunluğu (PSD): Öznitelik olarak literatürde de yaygın olarak kullanılan güç spektral yoğunluğu Welch periodogramı kullanılarak ortaya koyulmuştur. S_{xx} iyileştirilmiş periyodogram, f normalize frekans, L zaman serisinin uzunluğu olmak üzere, güç spektral yoğunluğu kestirimi (4) eşitliğindeki gibi tanımlanır.

$$\hat{P}_{Welch}(f) = \frac{1}{L} \sum_{i=0}^{L-1} \hat{S}_{xx}^{(i)}(f) \quad (4)$$

PSD+ frekans değerleri: EEG verilerinin güç spektral yoğunlukları hesaplandıktan sonra frekans domeninde en yüksek alfa tepesi genliği ve ardışık en yüksek iki beta tepesi genlikleri belirleyici öz nitelik olarak hesaplanmıştır (Özmen ve Gümüşel, 2013).

2.4. Sınıflandırma

Bilinmeyen bir sinyali tanıyabilmek için öznitelik çıkarımı ve öznitelik seçimi işlemlerinin ardından sınıflandırma işlemi gerçekleştirilir. Sınıflandırmada, kullanılan algoritmaya bağlı olarak giriş öznitelik vektörleri incelenir ve sınıflandırma sonucu belirlenir (Özmen ve Gümüşel, 2013, Kwak ve Choi, 2002). Sınıflandırma işleminde ilk aşama, hangi sınıfa ait olduğu önceden bilinen belirli sayıdaki öznitelik vektörünün oluşturduğu veri kümelerinin eğitim aşamasıdır. Bir sonraki aşama olan test aşamasında ise, eğitim sonucunda bilinmeyen sinyali uygun sınıfa atamakta kullanılan bir karar mekanizması oluşturulur (Duda ve diğ., 2001). Bu çalışmada sınıflandırma performansları, Destek Vektör Makinesi, k-En Yakın Komşuluğu ve Yapay Sinir Ağları yöntemleri kullanılarak test edilmiştir. Yedi farklı görevin kendi aralarında ikili sınıflandırma performansları değerlendirilmiştir. Sınıflandırma yapılırken, tüm sınıflandırıcılar için aynı oranda eğitim, doğrulama ve test verileri kullanılmıştır. Sınıflandırma performansları, yüzdesel olarak hesaplanmış ve yedi farklı görevde her bir kanal için ayrı ayrı elde edilmiştir.

2.4.1. Destek Vektör Makinesi (SVM) İle Sınıflandırma

Destek Vektör Makinesi, farklı iki sınıfı temsil eden örnekler arasındaki ayrımlık mesafesini en çoklayarak bir sınıflandırıcıyı eğitmeyi amaçlayan bir çeşit örüntü tanıma yöntemidir (Boser ve diğ., 1992). SVM için ikili sınıflandırmada etiketlenmiş eğitim verisi (5) eşitliğindeki gibi belirtilir. Burada l ; örnek sayısı x_i ; örnekler, y_i ; bu örneklere ait etiketleri temsil etmektedir.

$$\{x_i, y_i\}^l \quad i=1 \quad x_i \in R, \quad y_i \in \{-1, +1\} \quad (5)$$

İkili sınıflandırma probleminde doğrusal olarak ayrılabilen bir veri setinin olduğu düşünülürse, bu veri setini ayırabilen sonsuz sayıda hiper-düzlem vardır. SVM karar yüzeyini oluştururken iki sınıfa olan uzaklığı maksimum yapmaya çalışır. Bu düzlemler arasında maksimum sınıra sahip sadece bir hiper-düzlem bulunmaktadır. Sınır genişliğini sınırlandıran noktalara destek vektörleri adı verilir. Destek vektör algoritması en büyük sınır genişliğine sahip ayırıcı hiper-düzlem ile sınıflandırma yaparak eğitim hatasını minimize etmeye çalışır. Sınıfları birbirinden ayıran marjini en büyük, doğrusal bir ayırt edici fonksiyon bulmayı amaçlar. Doğrusal olarak ayrılamayan örnekler için, örnekler doğrusal olarak ayrılabilen daha yüksek boyutlu başka bir uzaya taşınır ve sınıflandırma o uzayda yapılır.

2.4.2. K-En Yakın Komşuluk Algoritması ile Sınıflandırma

K-En Yakın Komşuluk (k-NN) algoritması öznitelik uzayındaki en yakın eğitim örneklerine dayanarak nesneleri sınıflandıran, en basit örüntü tanıma yöntemlerinden birisidir (Alpaydin, 2004). Bu algoritma verilen k değeri kadar en yakın komşunun sınıfına göre sınıflandırma işlemi yapmaktadır. Bu çalışmada uygun k değeri denemeler sonucunda üç olarak belirlenmiştir. K-En Yakın Komşuluk algoritmasında bir vektörün sınıflandırılması, sınıfı bilinen vektörler kullanılarak yapılmaktadır. Test edilecek örnek, eğitim kümesindeki her bir örnek ile tek tek işleme alınmıştır. Test edilecek örneğin sınıfını belirlemek için eğitim kümesindeki o örneğe en yakın k adet örnek seçilir ($k=3$). Seçilen örneklerden oluşan küme içerisinde hangi sınıfa ait en çok örnek varsa test edilecek olan örneğin o sınıfa ait olduğuna karar verilir. Örnekler arası uzaklıklar Öklid (Euclidean) uzaklığı ile hesaplanmıştır.

2.4.3. Yapay Sinir Ağları İle Sınıflandırma

Yapay sinir ağları yöntemi pek çok bilimsel alanda yaygın kullanımı olan güçlü bir makine öğrenme algoritmasıdır (Lal ve diğ., 2005). Bu çalışmada EEG sınıflandırmalarındaki benzer (Pfurtscheller ve diğ., 1996) tek katmanlı bir ANN modeli Matlab ortamında oluşturulmuştur. Oluşturulan modelde öğrenme kuralı olarak geri yayılım algoritması (*trainingdx*) kullanılmış ve bu öğrenme kuralındaki parametrelerden öğrenme oranı (*learning rate*, lr), maksimum iterasyon sayısı (*itnum*) parametreleri için en uygun değerler araştırılmıştır. Bunun yanı sıra ara katmandaki gizli nöron sayısı için de benzer bir araştırma işlemi gerçekleştirilerek, uygun gizli nöron sayısı belirlenmiştir. Sınıflandırma işlemi esnasında toplam veri seti, eğitim, doğrulama ve test verileri olmak üzere üçe ayrılmıştır. Her bir denemeye ait verilerin %70'i eğitime, %5'i doğrulamaya ve %25'i ise test kümesine yerleştirilerek bir çözüm yapılmıştır.

3. BULGULAR VE TARTIŞMA

Bu çalışma kapsamında üç farklı kişiden elde edilen EEG verileri hem seçilen görevler, hem öznitelik yöntemleri, hem de sınıflandırıcı performansları açısından değerlendirilmiştir. Öncelikle öz nitelik yöntemlerinin performansını değerlendirmek amacıyla Tablo 1'de üç denek için sınıflandırma sonuçları kişi ortalamaları ve görev ortalamaları ile birlikte verilmiştir.

Hjorth parametreleri kullanılması durumunda, ortalama sınıflandırma doğrulukları SVM ile %83 ve ANN ile %81, AR ile sırasıyla %91-%95, PSD ile %91- %88 ve PSD+frekans değerleri ile de %92-%90 civarındadır. AR parametreleri ve PSD+ frekans karakteristikleri kullanılması durumunda elde edilen ortalama değerlerin oldukça yüksek olduğu görülmektedir.

Görev ortalamaları dikkate alındığında, %95'lik sınıflandırma performansı AR parametreleri ile ANN sınıflandırıcı kullanılması durumunda elde edildiğinden, müzik görevlerinin sınıflandırma işlemine öznitelik olarak AR parametreleri seçilerek devam edilmiştir. Yedi görev için sınıflandırma sonuçları Tablo 2'de seçilen elektrotlar için verilmiştir.

Tablo 1. Dört farklı öznelik çıkarma yöntemi ile elde edilen sınıflandırma sonuçları

Deneme Seti (Görev)	Yöntem	% Sınıflandırma Performansı															
		Kisi1				Kisi2				Kisi3				Ortalama			
		AR	Hjorth	PSD	Frek	AR	Hjorth	PSD	Frek	AR	Hjorth	PSD	Frek	AR _{ort}	Hjorth _{ort}	PSD _{ort}	Frek _{ort}
1 / 2	SVM	99	90	92	94	90	78	78	80	85	81	85	83	91	83	85	86
	ANN	100	91	88	86	85	70	80	85	90	77	85	87	92	82	84	86
1 / 3	SVM	100	97	99	100	100	97	99	99	70	85	100	100	85	93	99	99
	ANN	91	74	83	89	99	77	88	90	95	85	90	92	95	79	87	89
1 / 4	SVM	100	100	100	100	90	87	89	90	100	74	87	88	95	87	92	94
	ANN	100	100	100	100	100	78	97	95	98	82	96	98	99	87	98	99
1 / 5	SVM	100	100	100	100	90	95	100	100	85	93	100	100	92	96	100	100
	ANN	96	88	92	95	94	86	78	78	85	73	79	78	92	82	83	85
2 / 3	SVM	60	66	76	78	100	77	89	88	100	100	100	100	87	69	73	75
	ANN	92	84	88	90	97	89	93	95	100	63	82	87	96	79	88	90
3 / 4	SVM	100	80	100	100	94	97	100	100	84	67	84	85	93	81	95	96
	ANN	93	78	86	90	94	85	90	92	100	74	87	85	96	77	88	90
Ort	SVM													91	83	91	92
	ANN													95	81	88	90

Tablo 2. Yedi farklı görevin üç farklı denek için ikili sınıflandırma sonuçları

Görev /öntem		(%) Sınıflandırma Performansı																	
		Kisi1						Kisi2						Kisi3					
		C3	C4	P3	P4	O1	O2	C3	C4	P3	P4	O1	O2	C3	C4	P3	P4	O1	O2
1 / 6	k_NN	40	27	63	67	57	77	63	43	24	50	47	63	77	37	43	50	47	57
	SVM	60	37	47	60	70	50	57	40	53	37	63	60	60	43	53	57	50	67
	ANN	95	83	80	85	61	76	80	85	77	82	57	67	84	80	82	76	53	76
2/ 6	k_NN	100	100	90	93	100	100	95	87	85	90	90	93	90	95	82	82	90	77
	SVM	100	97	47	70	94	94	92	85	77	85	97	95	97	98	87	63	78	80
	ANN	96	95	95	92	96	93	76	98	90	90	93	90	85	87	90	76	80	83
3 / 6	k_NN	93	93	90	100	90	93	87	83	82	90	94	98	100	90	85	87	87	94
	SVM	97	97	80	100	80	94	97	95	87	82	90	100	95	90	87	82	80	97
	ANN	90	96	96	94	98	94	93	93	90	90	90	90	96	94	98	90	94	96
4 / 6	k_NN	93	93	77	90	93	90	90	79	80	87	78	78	87	80	78	67	77	89
	SVM	80	67	84	97	80	94	78	63	78	76	74	84	77	73	68	67	67	80
	ANN	95	93	96	100	95	96	85	87	87	85	80	82	100	77	77	78	80	85
5 / 6	k_NN	93	93	93	93	93	93	78	56	68	70	72	78	70	60	66	68	66	76
	SVM	97	94	94	94	94	94	93	92	90	89	80	89	78	76	56	60	68	72
	ANN	72	77	77	89	86	80	80	75	75	75	76	78	80	56	78	78	70	82
1/ 7	k_NN	97	6	60	80	60	87	79	76	54	46	34	80	79	77	75	75	75	75
	SVM	97	9	50	94	74	97	67	56	58	70	72	78	70	72	68	66	64	56
	ANN	100	94	84	93	90	86	96	86	86	67	78	90	92	94	94	90	92	96
2 / 7	k_NN	100	63	63	73	80	87	88	76	66	66	66	76	45	56	60	66	64	66
	SVM	100	74	24	57	84	84	68	37	55	68	56	78	74	70	70	70	72	76
	ANN	92	82	85	80	85	84	85	83	77	78	83	85	90	80	83	83	83	85
3 / 7	k_NN	83	93	80	80	80	77	68	66	66	66	66	75	78	67	56	56	23	72
	SVM	100	100	87	94	87	84	98	86	67	67	56	84	89	77	72	67	70	78
	ANN	98	100	98	98	91	98	90	88	88	88	88	88	86	85	85	88	86	86
4 / 7	k_NN	87	70	67	77	67	83	66	63	63	66	66	77	77	76	56	60	56	60
	SVM	90	97	97	90	77	90	88	83	83	85	78	94	78	77	24	67	77	80
	ANN	91	75	83	82	81	74	90	87	83	87	87	93	89	87	87	76	54	88
5 / 7	k_NN	100	100	100	100	100	100	100	88	88	89	90	95	89	90	90	90	90	96
	SVM	100	100	100	100	100	100	100	77	87	87	98	100	99	90	91	92	90	99
	ANN	93	91	92	95	87	95	100	100	99	97	97	99	100	100	100	100	100	100
6 / 7	k_NN	77	90	90	90	90	90	78	78	69	94	96	98	89	80	81	82	80	87
	SVM	100	100	100	100	100	100	100	90	91	97	98	98	99	98	98	99	99	100
	ANN	90	96	95	94	95	96	89	88	89	89	89	89	91	86	84	88	75	94

Tablo 2 incelendiğinde, en yüksek sınıflandırma performanslarının ANN kullanılması durumunda, daha sonra sıralanacak olursa SVM ve en son da k-NN sınıflandırıcısı olduğu görülmektedir. ANN ve SVM yöntemleri ile elde edilen sınıflandırma performansları birbirine çok yakındır. Bu yöntemlerin uygulama kolaylığı dikkate alındığında, işlem süresinin kısalığı açısından SVM yönteminin daha üstün olması nedeniyle gerçek zamanlı uygulamalarda tercih

edilme olasılığı daha yüksektir. En uygun sınıflandırıcı seçimine, uygulamanın türüne ve katılımcılara göre karar verilebilir.

Tablo 3. Elektrot bazında 3 katılımcı için ortalama sınıflandırma sonuçları

Görev	Yöntem	(%) Sınıflandırma Performansı					
		Ortalama					
		C3	C4	P3	P4	O1	O2
1 / 6	k_NN	60	35	43	56	50	66
	SVM	59	40	51	51	61	59
	ANN	86	83	80	81	57	73
2 / 6	k_NN	95	94	86	88	95	90
	SVM	96	93	70	73	90	90
	ANN	86	93	93	86	90	89
3 / 6	k_NN	93	89	86	92	90	95
	SVM	96	94	84	88	85	97
	ANN	93	94	95	91	94	93
4 / 6	k_NN	90	84	78	81	83	86
	SVM	78	68	77	80	74	86
	ANN	95	86	87	88	85	88
5 / 6	k_NN	80	70	76	77	77	82
	SVM	89	87	80	81	81	85
	ANN	77	70	77	81	77	80
1 / 7	k_NN	85	53	63	67	56	81
	SVM	78	46	59	77	70	77
	ANN	96	91	88	83	87	91
2 / 7	k_NN	78	65	63	70	70	76
	SVM	81	60	50	65	71	79
	ANN	89	82	82	80	84	85
3 / 7	k_NN	76	75	67	67	56	75
	SVM	94	88	75	76	71	81
	ANN	91	91	90	91	88	91
4 / 7	k_NN	77	70	62	68	63	73
	SVM	85	86	68	81	77	88
	ANN	90	81	85	82	74	85
5 / 7	k_NN	95	92	92	95	95	97
	SVM	100	89	93	93	96	100
	ANN	97	96	97	97	91	98
6 / 7	k_NN	81	83	80	87	87	92
	SVM	100	96	96	99	99	99
	ANN	90	90	89	90	86	93

Kişilerin sağ ve sol lobdaki performanslarının değerlendirilmesi açısından, her üç denek için kanallara göre ortalama sınıflandırma başarıları Tablo 3'te sunulmuştur. Elektrotlar açısından değerlendirildiğinde, on bir ikili görev arasından, on tanesinde C3 kanalındaki ortalama sınıflandırma performansının yüksek olduğu gözlenmiştir. C3 kanalındaki bu üstün başarı yüzdesi, Hadjidimitrou ve Hadjileontiadis (2012)'de ifade edilen hoş a giden müzik türlerinin dinlenmesi esnasında beynin sol bölgesinin aktif olması bilgisi ile örtüşmektedir. Genellikle, müzik dinleme görevinin beynin sol ön ve sol merkezi bölümlerinde olduğu ortaya koyulmuştur (Bhattacharya ve diğ., 2001). İkili görevler dikkate alındığında, Görev5-Görev7 (A

harfi-Rock müzik) performansı % 100 ve Görev 6 - Görev7(Klasik-Rock müzik) performansı %100 olarak elde edilmiştir. Tüm zihinsel ve motor görevlerin en yüksek ortalama sınıflandırma performansları % 86'nın üzerindedir. Tablo 3 değerlendirildiğinde, görevlerin karşılaştırmasında yedi görev için sol bölge elektrotlarında en yüksek başarı performansı gözlenirken, yalnızca dördünde sağ bölge elektrotlarında performans daha yüksektir. Ayrıca Klasik ve Rock müzik dinleme esnasında, EEG sinyallerinde farklılık olduğu ve bu farklılığın sınıflandırma başarımlarına yansıdığı görülmüştür. Dolayısıyla, BBA sistemleri için, görev tanımlaması yaparken müzik dinleme görevinin de uygun bir seçim olacağı düşünülmektedir.

4. SONUÇLAR

Bu çalışmada, BBA uygulamaları için müzik görevlerinin kullanılabilirliği araştırılmıştır. Bu amaçla, üç farklı kişi ile müzik dinleme, zihinsel ve motor hareket hayal etme görevleri gerçekleştirilmiş ve farklı öznelik yöntemleri ve sınıflandırıcılar açısından performansları değerlendirilmiştir. Seçilen öznelik yöntemleri olan Öz bağlantı katsayıları (AR), Hjorth parametreleri, güç spektrum yoğunluğu (PSD) ve PSD+ frekans karakteristikleri arasından en yüksek sınıflandırma başarısı AR parametreleri ile elde edilmiştir. Sınıflandırıcılar açısından ise ANN sınıflandırıcısı az farkla SVM'den daha başarılı olmuştur. İki farklı müzik türünün ayırt edilmesinde, müzik türlerinin farklı frekanslarda olduğu ve bu farklılığın ortaya koyulabileceği anlaşılmıştır. Elde edilen sonuçlar ışığında, müzik dinleme görevinin BBA sistemlerinde kullanılması önerilebilir. Öncelikle kişiye özgü web-destekli öğrenme ya da sanal oyun uygulamaları üzerinde denenerek, karar verilebilir. Son olarak, en başarılı kanal C3 olarak gözlenmiştir. Bu sonuca göre, tekil kanal uygulamalı bir BBA sistemi geliştirilebilir.

KAYNAKLAR

1. Asada, H., Fukuda, Y., Tsunoda, S., Yamaguchi, M., Tonoike, M. (1999) "Frontal midline theta rhythms reflect alternative activation of prefrontal cortex and anterior cingulate cortex in humans." *Journal of Neurophysiology* (50), 324 – 328. doi:10.1016/S0304-3940(99)00679-5
2. Anderson, C.W., Devulapalli, S.V., Stolze, A., (1995) Determining mental state from EEG signals using parallel implementations of neural networks. *Scientific Programming IOS Press*, 4, 3: 171-183. CCC 10.58-9244/95/030171-t:3
3. Anderson C.W. ve Sijercic, Z., (1996) Classification of EEG signals from four subjects during five mental tasks. *Solving Engineering Problems with Neural Networks Proc. Int.Conf. on Engineering Applications of Neural Networks (EANN'96)*.
4. Alpaydin, E. (2004) "Introduction to Machine Learning", MIT Press.
5. Bashashati, A.ve Fatourechi, M., (2007) A survey of signal processing algorithms in brain-computer interfaces based on electrical brain signals, *Journal of Neural Eng.*, 4, 32-57. doi:10.1088/1741-2560/4/2/R03
6. Bhattacharya, J., Petsche, H., Pereda, E.,(2001) "Interdependencies in the spontaneous EEG while listening to music" *International Journal of Psychophysiology*, Volume 42, Issue 3, November, 287–301. PMID:11812395
7. Boser, B. E., Guyon, I. M., ve Vapnik, V. N. (1992, July). A training algorithm for optimal margin classifiers. In *Proceedings of the fifth annual workshop on Computational learning theory*,144-152. ACM. doi:10.1145/130385.130401
8. Dey, A. , Palit, S.K., Bhattacharya, D.K., Tibarewala, D.N., Debraj D.,(2013) "Study of the effect of music on central nervous system through long term analysis of EEG signal in time domain" *International Journal of Engineering Sciences & Emerging Technologies*, Volume 5, Issue 1, 59-67, Apr. 2013.

9. Duda, R. O., Hart, P. E., Stork, D.G.,(2001)Pattern classification, John Wiley & Sons Inc., USA, 654. ISBN: 978-0-471-05669-0
10. Durmuş E., Özmen N.G.,(2015)"Beyin Bilgisayar Arayüzü Sistemlerinde Uygun Elektrot Seçimi ve Performans Artırımı", IEEE 23. Sinyal İşleme ve İletişim Uygulamaları Kurultayı (SIU 2015), Malatya, Türkiye, 16-19 Mayıs 2015, 1142-1145.
11. Durmuş E., Sadreddini Z., Özmen N.G.,(2014) "Beyin Bilgisayar Arayüzü Sistemleri İçin Uygun Öznitelik Ve Sınıflandırıcı Seçimi", Otomatik Kontrol Ulusal Toplantısı TOK,, Kocaeli, Türkiye, 11-13 Eylül 2014, 651-656
12. Grierson,M. (2008) Composing With Brainwaves: Minimal Trial P300b Recognition as an Indication of Subjective Preference for the Control of a Musical Instrument, Proceedings of the ICMC, Belfast 2008
13. Hadjidimitrou S., ve Hadjileontiadis L., (2012), EEG-based discrimination of music appraisal judgements using ZAM time frequency distribution, 8th triennial conf of the European society for the cognition science of music, July 23-28, Greece, 380-381.
14. Hamadicharef, B. ; Mufeng Xu ; Aditya, S. (2010) Brain-Computer Interface (BCI) Based Musical Composition, International Conference on Cyberworlds (CW),20-22 Oct. 2010, 282–286, doi: 10.1109/CW.2010.32
15. Kwak, N., Choi, C.H., (2002) “Input feature selection for classification problems,” IEEE Transactions on Neural Networks, Vol. 13, No. 1, pp. 143-159, doi: 10.1109/72.977291 ·
16. Kristeva, R., Chakarov, V., Schulte-Monting, J., Spreer, J. (2003) Activation of cortical areas in music execution and imagining: a high-resolution EEG study, NeuroImage 20, 1872-1883. pmid:14642497.
17. Lal T.N, Schröder, M Hill, N. J., et. al.. (2005) A brain-computer interface with online feedback based on magnetoencephalography, Proceedings of the Int Conf on Machine Learning, 465–472, doi:10.1145/1102351.1102410.
18. Lin, Y.P., Wang, C.H., Wu, T.L., Jeng, S.K., Chen, J.H., (2009) EEG-based emotion recognition in music listening: A comparison of schemes for multiclass support vector machine. In ICASSP 2009, 489-492.
19. Lotte F, Congedo M, Lécuyer A, Lamarche F, Arnaldi B (2007) A Review of Classification Algorithms for EEG-based Brain-Computer Interfaces, Journal of Neural Engineering, 4, R1-R13. doi:10.1088/1741-2560/4/2/R01
20. Makeig, S., Leslie, G., Mullen T., Sarma ,D., Bigdely-Shamlo, N. ve Kothe, C.,(2011) "First demonstration of a musical emotion BCI." Affective Computing and Intelligent Interaction. Springer Berlin Heidelberg,. 487-496. doi: 10.3389/fnhum.2017.00213
21. Mühl C, Allison B, Nijholt A, Chancel G (2014) A survey of affective brain computer interfaces: principles, state-of-the-art, and challenges, Brain-Computer Interfaces, 1:2, 66-84, doi: 10.1080/2326263X.2014.912881
22. Özmen, N.G., Gümüşel, L.,(2010) Mental and Motor Task Classification by LDA”, MEDICON 2010, IFMBE Proceedings29, pp. 172-175, Chalkidiki, Greece , 28-29 May.
23. Özmen, N.G., Gümüşel, L.,(2011) “Discrimination between Mental and Motor Tasks of EEG Signals Using Different Classification Methods”, INISTA ,15-18 June, Istanbul, Turkey.
24. Özmen, N.G., Gümüşel, L., (2013) Classification of Real and Imaginary Hand Movements for a BCI Design, IEEE, TSP 2013. 978-1-4799-0404-4/13/\$31.00

25. Peretz, I., Zatorre, R., (2005) Brain Organization for Music Processing. Annual Review of Psychology, (56),89 – 114. doi:10.1146/56.091103.070225.
26. Pfurtscheller,G., Kalcher J., Neuper Ch., et. al. (1996) On-line EEG classification during externally-paced hand movements using a neural network-based classifier, Electroencephalography and Clinical Neurophysiology, 99, 5 ,416–425. doi: 10.1016/S0013-4694(96)95689-8
27. Sadreddini Z., Durmuş E., Özmen N.G.,(2014) "EEG Verilerinden Farklı Müzik Türü ve Zihinsel Görevlerin Ayırt Edilmesi", Akıllı sistemlerde Yenilik ve Uygulamaları, ASYU 2014, İzmir, Türkiye, 9-10 Ekim 2014, 44-48.
28. Wolpaw, J.R., Birbaumer, N., Heetderks, W.J.et al, (2000) Brain–computer interface technology: A review of the first international meeting. IEEE Trans. Rehab. Eng., 8, 2164-173.
29. Wu, J. , Zhang, J., Liu, C., Liu, D., Ding, X, Zhou, C. (2012) “Graph theoretical analysis of EEG functional connectivity during music perception”, Brain Research 1483, 71-81. doi: 10.1016/j.brainres.2012.09.014
30. <http://muzisyenbeyin.blogspot.com.tr/2013/10/muzigin-vucudumuzdaki-hormonlar-ve.html>
Erişim Tarihi: 01.02.2016, Konu: Müzik ve Beyin.