

İki Durumlu Bir Beyin Bilgisayar Arayüzünde Özellik Çıkarımı ve Sınıflandırma¹ Feature Extraction and Classification in A Two-State Brain-Computer Interface

Fatih Altındış^{1,2}, Bülent Yılmaz¹

¹Elektrik-Elektronik Mühendisliği Bölümü, Abdullah Gül Üniversitesi, Kayseri, Türkiye

²Elektrik-Elektronik Mühendisliği Bölümü, Bilkent Üniversitesi, Ankara, Türkiye

fatihaltindis@alumni.bilkent.edu.tr, bulent.yilmaz@agu.edu.tr

Özetçe- Beyin bilgisayar arayüzü (BBA) teknolojisi motor nöronlarının özelliğini kaybeden ve hareket kabiliyeti kısıtlanmış ALS ve felçli hastalar gibi birçok kişinin dış dünya ile iletişimini sağlamaya yönelik kullanılmaktadır. Bu çalışmada, Avusturya'daki Graz Üniversitesi'nde alınmış EEG veri seti kullanılarak gerçek zamanlı EEG işleme simülasyonu ile motor hayal etme sınıflandırılması amaçlanmıştır. Bu veri setinde sağ el ya da sol elin hareket ettirilme hayali esnasında 8 kişiden alınmış iki kanallı EEG sinyalleri bulunmaktadır. Her katılımcıdan 60 sağ ve 60 sol olmak üzere toplamda 120 adet yaklaşık 9 saniyelik motor hayal etme deneme sinyali kayıt edilmiştir. Bu sinyaller filtrelemeye tabi tutulmuştur. Yirmi dört, 32 ve 40 elemanlı özellik vektörü bant geçiren filtreler kullanarak elde edilen göreceli güç değişim değerleridir (GGDD). Bu çalışmada, lineer diskriminant analizi (LDA), k en yakın komşular (KNN) ve destek vektör makinaları (SVM) ile sınıflandırma yapılmış, en iyi sınıflandırma performansının 24 değerli özellik vektörüyle ve LDA sınıflandırma yöntemiyle elde edildiği gösterilmiştir.

Anahtar Kelimeler — *beyin bilgisayar arayüzleri; EEG; hareketi hayal etme; sınıflandırma; göreceli bant gücü.*

Abstract- Brain Computer Interface (BCI) technology is used to help patients who do not have control over motor neurons such as ALS or paralyzed patients, to communicate with outer world. This work aims to classify motor imageries using real-time EEG dataset, which was published by Graz University, Austria. The dataset consists of two-channel EEG signals of right-hand movement imagery and left-hand movement imagery of 8 subjects. There are a total of

120 motor imagery trials (60 left and 60 right) EEG signals recorded from each subject. EEG signals are filtered and feature vectors were extracted that consist of 24, 32 and 40 relative band power values (RBPV). In this work, feature vectors classified by three different methods, linear discriminant analysis (LDA), K nearest neighbor (KNN) and support vector machines (SVM). Results show that best performance was achieved by 24 RBPV feature vector and LDA classification method.

Keywords — *brain-computer interfaces; EEG; motor imagery; classification; relative band power.*

I. GİRİŞ

Amyotrofik Lateral Skleroz (ALS) hastalığı insanların istemli hareketlerini engellemekte olup, zeka, hafıza, karakter, görme, duyma, koklama gibi özelliklerini etkilememektedir. Dünyada insidansı yaklaşık 100.000'de ikidir. 50-60 yaş arası bu oran 3 ila 4'e çıkmaktadır. ALS hastaları dışında diğer motor nöronlarının özelliğini kaybeden (beyinkökü felci olan ve ileri omurilik hasarı olan) felçli hastaların sayısı da azımsanmayacak seviyelerdedir. Uzunlarını oynatamayan bu kişilerin büyük bir çoğunluğu da kendisine bakanlarla sözlü iletişime geçememektedir.

Hareket kabiliyeti çok kısıtlı olan bu kişilerin dış dünyaya gönderdiği iletilerde kas sistemlerini ve motor sinir sistemlerini kullanmadan, çevresindeki kişilerle iletişim kurabilmelerini mümkün kılan sistemlere ihtiyaç bulunmaktadır. Bu sistemlere beyin bilgisayar (ya da makina) arayüzü (BBA ya da BMA) adı verilmektedir. Bu teknolojide, bireylerin beyninden doğrudan ya da kafa derisi üzerinden alınan genellikle çok kanallı elektrofizyolojik dalgalar (ElektroKortikoGrafı, ECoG ya da ElektroEnsefaloGrafı, EEG) kullanılır [1].

Motor niyet EEG'ye dayalı BBA, vücudun bir bölgesini (kollar, bacaklar ve dil) hareket ettirme isteğine bağlı olarak beyinde oluşan fizyolojik durum esnasında alınan EEG sinyallerinin gerçek zamanlı toplanması, işlenmesi, sinyallerden özellik çıkarılarak dışarıda kontrol edilmek istenen cihaz ya da sistemde istemin/işlemin başlatılması hedefleyen bir yaklaşımdır. Kişinin hareketi henüz gerçekleştirilmeden EEG sinyallerinde meydana gelen değişime motor niyet dalgaları adı verilir. Motor niyet dalgaları harekete başlamadan 2 saniye önce oluşmaya başlar ve hareket gerçekleşmeye başladıktan sonra azalarak kaybolur.

Mu dalgaları, beyinde posterior parietal ve premotor kortekslerinde dinlenme esnasında (herhangi bir hareket ya da istemi yokken) ve gözler açıkken 7.5 – 12.5 Hz aralığında tekrar eden bir dalga çeşididir. Hareket esnasında ya da hareket niyeti/hayali oluştuğunda genliği azalmaktadır. Buna olaya ilişkin desenkronizasyon (event related desynchronization, ERD) denmektedir. Hareket hayali ya da hareket bittiğinde mu dalgasının genliği tekrar artmaya başlamaktadır. Buna da olaya ilişkin senkronizasyon (event related synchronization, ERS) denmektedir [2].

Bu çalışmada kullanılan BBA, kişinin sağ ya da sol el hareketini hayal ederken EEG sinyallerinde meydana gelen değişimlerin analizini ve sınıflandırmasını yapmayı amaçlamaktadır. Çalışmada kullanılan EEG verileri, elektrotları beyindeki ilgili kortekste el ve ayak bölgelerine denk gelen alanlara yerleştirilerek elde edilmiştir [2]. Bu çalışmanın amacı, C3 ve C4 elektrotlarından alınan EEG sinyallerinde meydana gelen ERD'nin tespitine yönelik ön işleme, sinyal işleme ve sınıflandırma gibi yaklaşımların performansa etkisinin araştırılmasıdır.


II. YÖNTEMLER

A. Denekler ve Verilerin Kaydedilmesi

Bu çalışmada kullanılan EEG sinyalleri, Graz Üniversitesi'nde alınmıştır [3]. Sekiz hastanın (5 erkek ve 3 kadın) katılımlarıyla veri seti kaydedilmiştir. Tüm katılımcılar sağlıklı olup görme duyularında herhangi bir eksiklik bulunmamaktadır. Her katılımcı sandalyeye oturtulmuş ve karşılarında bir metre mesafede sabitlenmiş LCD ekran bulunmaktadır.

Katılımcıların kafasında elektrot kepi (Easycap, Germany) sabitlenmiş olup, EEG elektrotları (Ag/AgCl) uluslararası 10-20 sistemine göre yerleştirilmiştir. C3 ve C4 bipolar elektrotları kayıt için kullanılmıştır. Sinyaller analog bant geçirci filtre (0,5 – 100 Hz) ve çentik (notch) filtre (50 Hz) ile filtrelenmiştir. Veri örnekleme frekansı 250 Hz'dir [3].

Her katılımcı sırasıyla işaret tabanlı (cue-based) ve görsel geri besleme seanslarına katılmışlardır. İşaret tabanlı seanslar sağ el hareket niyeti ve sol el hareket niyeti olmak üzere iki farklı niyet sınıfına dayalı yapılmıştır [4]. Katılımcılar her seansta 60 sağ ve 60 sol olmak üzere 120 deneme gerçekleştirmiş ve iki hafta arayla birer seansa katılmıştır. Her deneme katılımcının ekranda sabitlenmiş çarpıya odaklanmasını sağlar ve katılımcılar bip sesliyle işaret ekranda belirlenmeden kısa bir süre önce uyarılır. Yaklaşık 1,25 saniye boyunca işaret ekranda kaldıktan sonra işaret ekrandan kaldırılır ve katılımcının 4 saniyelik periyot boyunca işaret edilen el hareketini hayal etmesi



Şekil 1. İşaret tabanlı seansların zaman diyagramı.

beklenir. Her deneme 1.5-2.5 saniye arası değişen dinlenme periyoduyla sonuçlanır (Şekil 1).

B. Sinyal İşleme ve Özellik Çıkarımı


Özellik çıkarımı için kaydedilen EEG sinyalleri öncelikle dijital sıralı filtrelerden geçirilmiştir. Sıralı filtre sayısı çıkarılacak özellik vektörünün uzunluğuna bağlı olarak değişmektedir. Sıralı filtreler Butterworth IIR 20. dereceden filtrelerdir.

24 özellik vektörü çıkarmak için her elektrotta 6 adet alfa ve düşük beta bandına yönelik, 6 adet beta bandına yönelik dijital sıralı filtre kullanılmıştır. Alfa ve düşük beta bandına yönelik dijital sıralı filtreler 2 Hz genişliğinde ve 1 Hz örtüşen bant geçiren filtrelerden (8-10, 9-11, 10-12, ..., 13-15 Hz arası) oluşmuştur. Beta bandına yönelik dijital sıralı filtreler 5 Hz genişliğinde ve 3 Hz örtüşen bant geçiren filtrelerden (15-20, 17-22, 19-24, ..., 25-30 Hz arası) oluşmuştur. Otuziki özellikli vektörü çıkarmak için her elektrotta 8 adet alfa ve düşük beta bandına yönelik, 8 adet beta bandına yönelik yukarıdaki sisteme benzer dijital sıralı filtre kullanılmıştır. Kırk özellikli vektörü çıkarmak için her elektrotta 10 adet alfa ve düşük beta bandına (8-10, 9-11, 10-12, ..., 17-19 Hz arası) yönelik, 10 adet beta bandına yönelik (15-20, 17-22, 19-24, ..., 33-38 Hz arası) dijital sıralı filtre kullanılmıştır.

Daha sonra sıralı filtrelerden geçirilmiş EEG sinyalleri zaman domainine göre karelenmiştir. Karelenmiş sinyallerden göreceli bant gücü hesaplamak için ortalama değer çıkarımı yapılmıştır [5]. Karelenmiş her denemenin 0,6-1,6 saniyeleri arasında referans alfa bant gücü hesaplanmıştır (Şekil 2, kırmızı kutu). Bu zaman aralığında denenin herhangi bir hareketi hayal etmediği bilinmektedir. Aynı denemenin 4,5-6,5 saniyeleri arası hareketin hayal edildiği zaman dilimindeki alfa bant gücü de aynı yöntemle hesaplanmıştır (Şekil 2, mor kutu). Elde edilen bant güçleriyle göreceli bant gücü değişimi değeri (GGDD) hesaplanarak özellik vektörü oluşturulmuştur. Her elektrot için toplamda sayısı 12 ile 20 arasında değişen, farklı filtrelerden çıkarılan özellik değerleri bir vektör oluşturulmuştur. Toplamda 24 ile 40 adet arası değişen özellik değerlerinden oluşan vektör her bir deneme için çıkarılmıştır. O denemedeki sağ el ya da sol el hareket hayali de etiket olarak sonraki süreçte (sınıflandırmada) kullanılmıştır.

$$RP_{ij} = \frac{(E_{ij} - R_{ij})}{R_{ij}} \cdot 100 \quad (1)$$

Denklem (1)'deki bağıl bant gücü değişimin hesaplanmasında 'i' tekrar sayısını belirtirken 'j' sıralı filtrelerin numarasını temsil etmektedir.



Şekil 2. 8-10 Hz arası bantgeçiren filtreden geçirilmiş EEG sinyalinde, kırmızı bölge referans alınan sinyal parçasını, mor bölge hareket hayalinin gerçekleştiği zaman dilimini temsil etmektedir.

C. Sınıflandırma Yöntemleri

Yukarıda bahsedildiği üzere, iki kanallı EEG sinyallerinden elde edilen bağıl bant gücü değişimi değerleri, doğrusal diskriminant analiz (LDA), en yakın K komşuluk (KNN) ve destek vektör makinaları (SVM) yöntemleriyle sağ el ya da sol el hareket hayali diye sınıflandırılmıştır. LDA sınıflandırma yöntemi girdi verilerinden elde edilen dağılımların lineer bir doğru üzerinde sınıflara ayrılmasını esas almaktadır. Bu çalışmada MATLAB 2016a versiyonu 'fitcdiscr' fonksiyonu kullanılarak oluşturulan LDA sistemi 'lineer' özelliğiyle kullanılmıştır [7]. KNN sınıflandırma yöntemi en yakın komşuya olan uzaklığı hesaplayarak sınıflandırmayı amaçlamaktadır. Bu yöntemle oluşturulan sınıflandırma sistemi için MATLAB 2016a 'fitcknn' metodu kullanılmıştır. Mesafe hesaplaması için Öklit uzaklığı hesaplaması ve bir komşu (k=1) kullanılmıştır [8]. SVM sınıflandırma yöntemi girdileri bir düzleme haritalayarak hiper düzlemlerle girdileri sınıflandırmaya çalışan bir yöntemdir. SVM yöntemi ikili sınıflandırmalar için oldukça pratik bir metod olduğu için bu çalışmada kullanılmıştır. MATLAB 2016a 'fitcsvm' metodu bu yöntemin uygulanması için kullanılmıştır [9].

Yukarıda belirtilen yöntemlerin eğitim aşamalarında iki farklı öğreticiyle öğretim yolu izlenmiştir. Birinci yolda, sistem her tekrarda yeni EEG verisinden oluşturulan özellik vektörüyle eğitilmiştir. 10 kere çapraz geçerlilik testi uygulayarak sistemin performansı test edilmiştir. Dolayısıyla her tekrarda 120 denemeden 108 tanesi sistemi eğitmek için kullanılırken, geriye kalan 12 deneme de sistemi test etmek için kullanılmıştır.

Sistemi eğitmek için izlenen ikinci yol ise daha farklı bir şekilde işlemektedir. 120 denemeden çıkarılmış özellik vektörleri etiketlerine göre ayrılmıştır. Sistemi eğitmek için kullanılacak vektör her tekrarda kendinden önce sistemi eğitmek için kullanılmış özellik vektörleriyle ortalanmış ve sistem bu ortalanmış vektörle eğitilmiştir. Örneğin, ilk sağ el hareket vektörü ile eğitilmiş sistem ikinci kez eğitileceği sırada ikinci sağ el hareket vektörüyle ilk sağ el hareket vektörü toplanarak ortalaması alınmıştır. Sonra, bu ortalaması alınmış vektörle sistem eğitilmiştir. Eğitilme işlemi devam eden tekrarlar da aynı şekilde uygulanarak 120 denemenin tamamıyla sistem eğitilmiştir. Sistem ilk özellik vektörü dışındaki hiçbir vektörle doğrudan eğitilmediği için sapma (bias) değeri düşük kalmaktadır. Dolayısıyla sistem 120 denemenin tamamıyla test edilebilmektedir. Denklem (2)'de göster-

ildiği gibi k'ncı tekrarda kullanılacak özellik vektörü ilk vektörden k'ya kadar olan vektörlerin toplamının ortalamasıyla elde edilmiştir.

$$RP_{kj} = \left(\sum_{i=1}^k RP_{ij} \right) \div k \quad (2)$$

III. SONUÇLAR

Özellik çıkarımı aşamasının sonucunda C3 ve C4 kanallarının her birinden alfa bandından 6 (8-15 Hz arası), 8 (8-17 Hz arası) ve 10 (8-19 Hz arası), beta bandından 6 (15-30 Hz arası), 8 (15-34 Hz arası) ve 10 (15-38 Hz arası) göreceli güç değişim değerleri hesaplanmıştır. Böylece, ilk olarak C3 kanalından 6 alfa, 6 beta, C4 kanalından 6 alfa, 6 beta GGDD çıkarılarak 24 adet özellik elde edilmiştir.

Bu 24 özellik kullanılarak, 8 denekte, üç ayrı sınıflandırma yaklaşımının performansına bakıldığında; LDA yöntemiyle %51-81, KNN yöntemiyle %51-65 ve SVM yöntemiyle %47-76 arasında doğruluk değerleri elde edilmiştir (Tablo 1). Tüm sınıflandırma yaklaşımlarında özellik sayısı 32 ve 40'a çıkarıldığında ya çok yakın doğru sınıflandırma yüzdesi elde edildiği ya da performansın düştüğü belirlenmiştir. Tüm deneklerin LDA ile farklı sayıda özellik değeri kullanılarak elde edilen doğruluk oranları Şekil 3'te verilmiştir. B01, B04 ve B06 nolu deneklerdeki performansın tüm yöntemlerde diğerlerine göre ciddi oranda daha yüksek olduğu görülmüştür.

Eğitim sürecini ortalama olarak gerçekleştirdiğimizde sınıflandırma performansında; LDA'da 8 denegin 6'sında %1 ila 10 arası bir artış, KNN'de deneklerin tümünde %3 ila 17 arası bir artış, SVM'de deneklerin tümünde %1 ila 17 arası bir artış gözlenmiştir (Tablo 1).

IV. TARTIŞMA VE DEĞERLENDİRME

EEG'ye dayalı BBA çalışmalarında, görsel uyarılmış potansiyeller [6], yavaş kortikal potansiyeller [7], P300 uyarılmış potansiyelleri [8] ve sensorimotor ritimler [9] kullanılmaktadır. Günümüzde kullanılan BBA uygulamaları kelime işleyiciler, uyarlanmış web tarayıcılar, tekerlekli sandalye ve nöroprotezlerin kullanımı ve oyunlar [10] olarak sayılabilir. BBA'ların evde kullanımına dönük çalışmalarda epey mesafe alınmıştır. Ancak bu çalışmalar, henüz laboratuvar çalışmaları ya da pilot hasta çalışmaları seviyesindedir ve yaygın kullanıma geçen bir ürün piyasada bulunmamaktadır.

Bu çalışmada hareketin hayal edilmesi esnasında alınan EEG sinyallerinden gerçek zamanlı olarak hangi uzvun hareket ettirilmek istendiği tahmin edilmeye çalışılmıştır. Doğru tahmin edilerek dışarıdaki bir sistemin kontrol edilmesi hedeflenmektedir. Üzerinde çalıştığımız veri setindeki EEG sinyallerinden daha az sayıda göreceli bant gücü değeri özellik olarak çıkarılıp, LDA sınıflandırma yöntemi kullanılarak %80'lere varan doğru tahmin oranları yakalanmıştır.

Sonuç olarak bu çalışma sonuçları, daha önce önerilen [1] yöntemlerde kullanılan özellik vektör sayısından çok daha düşük sayıda özellik vektörü kullanarak ve sadece iki elektrottan alınan EEG değerlerini yorumlayarak yük-

sek doğruluk oranında çalışan BBA tasarlamanın mümkün olduğunu göstermektedir. Sınıflandırma yöntemleri ve BBA performansı katılımcıların performansıyla doğrudan ilişkili olduğu halde, ortalama alınarak oluşturulan özellik vektörleri bu değişkenin etkisini azaltmıştır.

V. TEŞEKKÜR

Bu çalışma Abdullah Gül Üniversitesi Bilimsel Araştırma Projeleri Koordinasyon Birimi tarafından desteklenmiştir. Proje Numarası: TOA-2015-31.

KAYNAKÇA

[1] Wolpaw J. R., Birbaumer, N., McFarland, D. J., Pfurtscheller, G., and Vaughan, T. M. "Brain-computer interfaces for communication and control", *Clin. Neurophysiol.*, 113(6):767-91, 2002.

[2] Pfurtscheller, G. and Lopes Da Silva, L. H. "Event-related EEG/MEG synchronization and desynchronization: basic principles". *Clin. Neurophysiol.* 110(11):1842-1857, 1999.

[3] Leeb, R., Brunner, C., Müller-Putz G. R., Schlögl, A., and Pfurtscheller, G. "BCI Competition 2008–Graz data set B". *Graz University of Technology, Austria*, 2008.

[4] R. Leeb, F. Lee, C. Keinrath, R. Scherer, H. Bischof, G. Pfurtscheller. "Brain-computer communication: motivation, aim, and impact of exploring a virtual apartment", *IEEE Trans Neural Syst and Rehabil Eng.*, 15, 473-482, 2007.

[5] Zhang, A., Yang, B., and Huang, L. "Feature extraction of EEG signals using power spectral entropy", *2008 International Conference on BioMedical Engineering and Informatics.* 2, 2008.

[6] Brodu, N., Lotte, F. and Lécuyer, A. "Comparative study of band-power extraction techniques for motor imagery classification", *Computational Intelligence, Cognitive Algorithms, Mind, and Brain (CCMB), IEEE Symposium on.* 2011.

[7] Fisher, R. A. "The Use of Multiple Measurements in Taxonomic Problems", *Annals of Eugenics*, 7:179–188, 1936. Available at <http://digital.library.adelaide.edu.au/dspace/handle/2440/15227>.

[8] Documentation: K-nearest Neighbor Classification. 22 Temmuz 2016. <http://www.mathworks.com/help/stats/classificationknn-class.html>.

[9] Suykens, J.A.K., Van Gestel, T., De Brabanter, J., De Moor, B., and Vandewalle, J., *Least Squares Support Vector Machines*, *World Scientific*, Singapore, 2002.

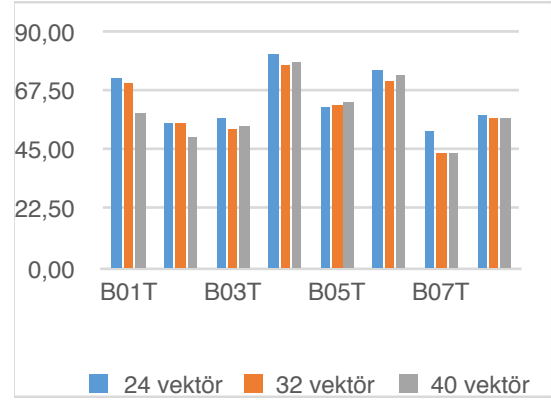
[6] Cao, T. Wang, X. Wang, B., Wong, C.M., Wan, F., Mak, P.U., Mak, P.I., and Vai, M.I. "A high rate online SSVEP based brain-computer interface speller", *5th International IEEE/EMBS Conference on Neural Engineering (NER)*, 465–468, 2011.

[7] Birbaumer, N. "Just short of telepathy: can you interact with the outside world if you can't even blink an eye?" *Psychology Today*, 2003.

[8] Piccione, F., Giorgi, F., Tonin, P., Priftis, K., Giove, S., Silvoni, S., Palmas, G., Beverina, F. "P300-based brain computer interface: Reliability and performance in healthy and paralysed participants", *Clin Neurophysiol.* 117(3): 531-537, 2006.

[9] Kübler, A. and Müller, K.R. "An introduction to brain computer interfacing" In Guido Dornhege, Jose del R. Millán, Thilo Hinterberger, Dennis McFarland, and Klaus-Robert Müller, editors, *Toward Brain-Computer Interfacing*, pages 1-25. MIT press, Cambridge, MA, 2007.

[10] Liao, L.D., Chen, C.Y., Wang, I.J., Chen, S.F., Li, S.Y., Chen, B.W., Chang, J.Y., Lin, C.T. "Gaming control using a wearable and wireless EEG-based brain-computer interface device with novel dry foam-based sensors." *J Neuroeng Rehabil.*, 28(9):5, 2012.



Şekil 3. Bütün katılımcıların farklı özellik vektör sayılarına klasik eğitim ve LDA sınıflandırma yöntemine göre oluşan doğruluk oranları.

| 24 | LDA | KNN | SVM | LDA ORT | KNN ORT | SVM ORT |
|------|------|------|------|---------|---------|---------|
| B01T | 71,6 | 65,0 | 75,8 | 77,5 | 73,3 | 76,6 |
| B02T | 55,0 | 59,1 | 49,1 | 55,8 | 66,6 | 59,1 |
| B03T | 56,6 | 59,1 | 60,0 | 63,3 | 62,5 | 70,0 |
| B04T | 80,8 | 75,8 | 74,1 | 73,3 | 86,6 | 84,1 |
| B05T | 60,8 | 52,5 | 58,1 | 70,8 | 63,3 | 60,0 |
| B06T | 75,0 | 60,8 | 70,8 | 70,8 | 77,5 | 75,0 |
| B07T | 51,6 | 58,3 | 47,5 | 60,0 | 64,1 | 60,0 |
| B09T | 58,3 | 53,3 | 54,1 | 65,0 | 67,5 | 68,3 |
| 32 | LDA | KNN | SVM | LDA | KNN | SVM |
| B01T | 70,0 | 62,5 | 65,0 | 77,5 | 77,5 | 78,3 |
| B02T | 55,0 | 59,1 | 53,3 | 60,8 | 67,5 | 62,5 |
| B03T | 52,5 | 60,0 | 47,5 | 65,0 | 60,8 | 69,1 |
| B04T | 76,6 | 74,1 | 73,3 | 69,1 | 85,0 | 85,3 |
| B05T | 61,6 | 60,0 | 62,5 | 65,0 | 67,5 | 67,5 |
| B06T | 70,8 | 65,0 | 68,3 | 75,8 | 76,6 | 77,5 |
| B07T | 43,3 | 55,8 | 50,8 | 60,0 | 66,6 | 55,0 |
| B09T | 56,6 | 54,1 | 63,3 | 66,6 | 63,3 | 67,5 |
| 40 | LDA | KNN | SVM | LDA | KNN | SVM |
| B01T | 59,1 | 67,5 | 70,0 | 79,1 | 75,0 | 80,8 |
| B02T | 50,0 | 55,8 | 46,6 | 58,3 | 65,8 | 63,8 |
| B03T | 54,1 | 61,6 | 53,3 | 64,1 | 59,1 | 69,1 |
| B04T | 78,3 | 73,3 | 75,8 | 74,1 | 88,3 | 86,6 |
| B05T | 62,5 | 55,8 | 60,0 | 64,1 | 68,3 | 69,1 |
| B06T | 73,3 | 66,6 | 64,1 | 72,5 | 79,1 | 76,6 |
| B07T | 43,3 | 46,6 | 48,3 | 60,8 | 64,1 | 60,0 |
| B09T | 56,6 | 50,8 | 48,3 | 72,5 | 60,0 | 67,5 |

Tablo 1. Üç farklı özellik sayısı (24, 32 ve 40) üç farklı sınıflandırma tekniğiyle (LDA, KNN ve SVM), iki farklı eğitim yaklaşımıyla elde edilen doğru sınıflandırma değerleri % olarak verilmiştir.