

Türkçe Dil Modeli Kullanan ilk Beyin-Bilgisayar Arayüzü

The First Brain-Computer Interface Utilizing a Turkish Language Model

Çağdaş Ulaş ve Müjdat Çetin
Mühendislik ve Doğa Bilimleri Fakültesi
Sabancı Üniversitesi
Orhanlı, Tuzla, 34956 İstanbul
{çagdulas, mçetin}@sabanciuniv.edu

Özetçe—Yaygın olarak üzerinde çalışılmış olan elektroensefalografi (EEG) tabanlı Beyin-Bilgisayar Arayüzü (BBA) düzeneklerinden birisi, kullanıcıların öngörülemeyen uyarılara karşı beyinlerinde cevap olarak oluşan ve P300 diye bilinen sinyallere dayalı bir şekilde harf yazmalarını içerir. EEG sinyallerinin düşük sinyal-gürültü oranı nedeniyle, mevcut BBA heceleme sistemleri kabul edilebilir doğruluk oranı elde etmek için fazla sayıda uyarı tekrarlamasına ihtiyaç duymakta, bu da düşük yazma hızı ile sonuçlanır. Ancak, belirli bir dildeki kelimeler içinde yer alan harfleri dikkate aldığımızda, komşu harflerin de mevcut harfin durumu hakkında bilgi verdiği söylenebilir. Bu gözleme dayanarak, Türkçe dil modeli tarafından eğitilmiş Saklı Markov Modeli (SMM) yapısı aracılığıyla BBA tabanlı hecelecinin içine dil modeli bilgisinin dahil edildiği bir yaklaşım öneriyoruz. Böyle bir model üzerinde çıkarsama yapmak için kullandığımız yumuşatma ve Viterbi algoritmalarını tanımlıyoruz. Laboratuvarlarda gerçek EEG verileri üzerinde gerçekleştirdiğimiz deneyler, dil modelinin bu şekilde karar sürecine dahil edilmesinin sınıflandırma doğruluğu ve bit hızında önemli iyileştirmelere yol açtığını gösteriyor.

Anahtar Kelimeler—P300 Hecelecinisi, Beyin-Bilgisayar Arayüzü, dil modeli, Saklı Markov Modeli, İleri-geri yönlü algoritma

Abstract—One of the widely studied electroencephalography (EEG) based Brain-Computer Interface (BCI) set ups involves having subjects type letters based on so-called P300 signals generated by their brains in response to unpredictable stimuli. Due to the low signal-to-noise ratio (SNR) of EEG signals, current BCI typing systems need several stimulus repetitions to obtain acceptable accuracy, resulting in low typing speed. However, in the context of typing letters within words in a particular language, neighboring letters would provide information about the current letter as well. Based on this observation, we propose an approach for incorporation of such information into a BCI-based speller through a Hidden Markov Model (HMM) trained by a Turkish language model. We describe smoothing and Viterbi algorithms for inference over such a model. Experiments on real EEG data collected in our laboratory demonstrate that incorporation of the language model in this manner leads to significant improvements in classification accuracy and bit rate.

Keywords—P300 speller, Brain-Computer Interface, language model, Hidden Markov Model, Forward-Backward algorithm

Bu çalışma TÜBİTAK'ın 111E056 ve Sabancı Üniversitesi'nin IACF-11-00889 sayılı projeleri ile TÜBİTAK BİDEB yüksek lisans bursu tarafından desteklenmiştir.

978-1-4673-5563-6/13/\$31.00 ©2013 IEEE

1. GİRİŞ

Beyin-Bilgisayar Arayüzü (BBA), felçli ve benzeri engelli kişilerin beyin aktiviteleri ile dış dünyaya iletişim kurmaları için kullanılmak üzere yeni bir çıkış kanalının oluşturulması fikrini içerir. Son 20 yılda yapılan çalışmalar, müdahalesiz bir şekilde elektroensefalografi (EEG) yoluyla kaydedilmiş elektrik sinyallerinin, BBA sistemleri için temel oluşturabileceğini göstermektedir. Bir EEG tabanlı BBA sisteminde, EEG kuvvetlendiricisinden toplanan sinyaller işlenir ve kullanıcının ihtiyaç duyduğu işlevi açığa çıkarmak için sınıflandırılır [1].

P300 hecelecinisi kullanıcının bilgisayar ekranına metin yazmasını sağlayabilen en yaygın BBA türlerinden biridir. P300 hecelecinisi paradigması ilk olarak [2]'de Farwell ve Donchin tarafından ortaya konmuştur. P300, deneğin görsel veya işitsel bir uyarı tarafından uyarılmasına karşılık beyin sinyallerinde cevap olarak oluşan bir olay-ilişkili potansiyeldir. Kullanıcı hedef bir karaktere odaklanırken Şekil 1'de gösterilen karakter matrisinin satır ve sütunları rastgele yanıp söner. Hedef karakteri içeren satır veya sütunun yanıp sönmelerine karşı beyinde bir P300 tepki sinyali oluşması beklenir. Düşük sinyal-gürültü oranı ve EEG sinyallerinin değişkenliği nedeniyle sınıflandırma başarımını artırmak için uyarı tekrarlamasının fazla sayıda olması gerekir ki bu da sistemin düşük sembol hızı ile çalışmasına neden olur [3]. Geçmiş çalışmalarda P300 hecelecinisinin performansını artırmak için elektrot seçimi, uyarı şekli ve zamanlaması, öznel çıkarma ve sınıflandırma algoritması gibi yönler ele alınsa da belli bir dil modelinin sınıflandırıcı algoritmasına entegre edilerek karar vermede kullanılma fikri pek yaygın değildir. Bu fikri ele alan çalışmalardan [4]'te NLP yöntemi önerilmiştir. Orhan ve arkadaşları ise [3]'te RSVP klavyesi denilen yeni bir yanıp-sönme paradigması üzerinde önerdikleri özyinelemeli Bayes yaklaşımı ile EEG sınıflandırma skorlarını bağlam temelli harf olasılıkları ile birleştirmişlerdir. Bu iki fikir, dil alanından gelen önsel bilgilerin eklenmesiyle BBA haberleşme sisteminin daha yüksek hızlara ulaştığını kanıtlamıştır.

Biz ise bu makalede, ikinci dereceden bir Saklı Markov Modeli (SMM)'ni temel alarak Türkçe dil modeliyle EEG skorlarını birleştiren yeni bir yaklaşım öneriyoruz. Önerdiğimiz model ileri-geri yönlü ve Viterbi algoritmalarını kullanarak kullanıcının yazmak istediği harfler üzerinde karar verir. [4]'te önerilen NLP, mevcut bir harfin tahmininde sadece sınıflandırıcı tarafından geçmişte karar verilmiş harfleri doğru olarak kabul edip kullanılan fırsatçı bir yaklaşımdır. Bizim önerdiğimiz

A	B	C	D	E	F
G	H	I	J	K	L
M	N	O	P	Q	R
S	T	U	V	W	X
Y	Z	1	2	3	4
5	6	7	8	9	-

Şekil 1. Çalışmada kullanılan uyarı matrisi.

yöntem ise tamamen olasılıksal bir yaklaşım ile daha önceki kararların belirsizlikler içerebileceğini hesaba katar ve bu nedenle geçmiş zamanda hesaplanmış bütün olasılıkları dikkate alıp yeni harfi tahmin etmede bunları kullanır. Aynı zamanda, [3] ve [4]'teki yaklaşımlar, mevcut harfin tahmininde sadece geçmiş harflerden gelen bilgileri kullanırken, bizim yaklaşımımız ise hem geçmiş hem de gelecekte gelen bilgileri kullanır. Bu yolla, yeni bir bilgi geldiği anda daha önce bildirilen harfler güncelleştirilebilir. Bu teknik katkılara ek olarak, çalışmamız Türkçe bir dil modeli kullanan ilk BBA sistemi olma özelliğini taşımaktadır. Yaptığımız çevrimdışı deneyler, önerdiğimiz yaklaşımın P300 tabanlı BBA sisteminin başarımında kayda değer gelişmelere olanak sağladığını göstermektedir.

2. ÖNERİLEN YÖNTEM

Bu çalışmada EEG veri toplama işleminde kullanılan uyarın yazılımı ve gerçekleştirilen veri ön işleme yaklaşımları [5]'te detaylı bir şekilde anlatılmıştır. Önerdiğimiz sınıflandırma algoritması iki adımdan oluşmaktadır: 1. Herhangi bir harf sıralaması içindeki birbirinden bağımsız her harf için sınıflandırma skorları, Bayes Doğrusal Ayırtaç Analizi (BDAA) kullanılarak hesaplanır, 2. İlk adımda elde edilen skorlar, trigram dil modelini kullanan bir SMM'ne entegre edilir ve sınıflandırıcı harf dizisindeki her bir harfin sonucuna karar vermek için İleri-Geri yönlü ve Viterbi algoritmalarını kullanır.

2.1. Bayes Doğrusal Ayırtaç Analizi (BDAA)

Bu bildiriye önerilen sınıflandırma algoritmasının ilk aşaması, [6]'da bahsedilen BDAA'nın, laboratuvar ortamında kaydedilen EEG verisi üzerinde uygulanmasını içerir. Ele aldığımız sınıflandırma problemi iki sınıftan oluşmaktadır. Bu sınıflar, eğitim verisindeki her bir epokun (bir satır veya sütunun yanması periyodunda kaydedilen EEG verisi) hedef karakteri içerip içermediğidir. Eğitim verisindeki her bir epok, bu iki sınıftan herhangi birini içermesine göre etiketlenir ve sonrasında BDAA test verilerindeki her bir epok için eğitim kümesindeki sınıflara olan benzerliğini sırasınan bir skor hesaplanır.

Heceleatici matris içindeki her bir karakterin skoru, o karakterin yer aldığı satır ve sütunların kendi bireysel skorlarının toplanması ile elde edilir. Bir karakterin yazılması sırasında oluşan ardışık sına gruplarının (12 defa tüm satır ve sütunların bir kere yanıp sönmesi) skorları birbirleriyle toplanarak o anki sına grubuna ait skorlar elde edilir. Skorların toplamı her sına grubu sonunda kontrol edilmekte ve maksimum skora sahip karakter sınıflandırıcı cevabı olarak seçilmektedir.

2.2. Dil Modeli Destekli BBA

Bir BBA tabanlı heceleme sisteminde başarımların artışı sağlamak için BDAA skorlarının Türkçe dil modeline dayalı bir şekilde elde edilen koşullu harf olasılıklarıyla birleştirilmesinin yararlı olabileceğini düşündük. Bu çalışmada bu amaca uygun bir SMM yapısı öneriyoruz. Bu SMM'nde, heceleatici matris içinde yer alan her bir sembol (karakter) gizli değişkenimizi ve her bir akışa (tek bir hedef harf yazımında yer alan belirli sayıdaki sına grubu) ait BDAA skorları ise gözlemlenen değişkenimizi oluşturur. Bölüm 2.2.1 ve 2.2.2'de önerdiğimiz SMM yapısını oluşturan denklemlerden ve İleri-geri yönlü ve Viterbi algoritmalarının bu yapı içerisinde nasıl kullanıldığından bahsedeceğiz.

2.2.1 İleri-Geri Yönlü Algoritması

$t \in \{1, 2, \dots, T\}$ olacak şekilde bir t zamanındaki durumu S_t ile ifade edelim ve $O = O_1 O_2 \dots O_T$ olacak şekilde bir gözlem sırası tanımlayalım. Burada her bir O_k , hedef bir kelimedeki k . harf (akış) için heceleatici matris üzerindeki her bir karakterin BDAA skorlarını temsil eder. İleri-geri yönlü algoritması ilk aşamada, bütün

$t \in \{1, 2, \dots, T\}$ için belirli bir t zamanına kadar geçen süreçteki kısmi gözlem sırasını ve t zamanında i durumunda olma olasılığını ifade eden ileri yönlü olasılık değerlerini hesaplar. Burada, her bir i heceleatici matriste yer alan karakterleri ifade eder. İkinci aşamada ise, bu algoritma geri yönlü olasılık değerlerini hesaplar. Bu olasılık değerleri ise t zamanında i durumunda olma durumu verildiğinde, $t+1$ zamanından T zamanına kadarki kısmi gözlem sırasının görülme olasılığıdır. Yukarıda bahsedilen iki yönlü olasılık skorlarının bir araya gelmesiyle herhangi bir zamandaki durumun olasılık değeri şu şekilde hesaplanır :

$$P(S_t = i | O_{1:T}) \propto P(O_{1:t}, S_t = i) P(O_{t+1:T} | S_t = i) \quad (1)$$

Burada eşitliğin sağ tarafındaki ilk terim t zamanında hesaplanan ileri yönde olasılık değerlerini, ikinci terim ise yine t zamanındaki geri yöndeki olasılık değerlerini ifade eder ve sırasıyla $\alpha_t(i)$ ve $\beta_t(i)$ olarak gösterilir.

İkinci dereceden bir SMM'ni dikkate alalım. Bu durumda $\alpha_t(i)$ ve $\beta_t(i)$ özyinemeli bir şekilde aşağıdaki gibi hesaplanır [7].

$$\alpha_1(i) = P(S_1 = i) P(O_1 | S_1 = i) \quad (2)$$

$$\alpha_2(j) = \sum_i \alpha_1(i) P(S_2 = j | S_1 = i) P(O_2 | S_2 = j) \quad (3)$$

$$\alpha_t(k) = \sum_j \sum_i \alpha_{t-1}(i, j) a_{ijk} P(O_t | S_t = k) \quad (4)$$

Burada $a_{ijk} = P(S_t = k | S_{t-1} = j, S_{t-2} = i)$, $3 \leq t \leq T$, ve her bir i, j, k heceleatici matrisin herhangi bir elemanını temsil eder. Aynı şekilde geri yönde olasılıklar şu şekilde hesaplanır :

$$\beta_T(i) = 1 \quad (5)$$

$$\beta_t(i) = \sum_j \sum_k \beta_{t+1}(j, k) a_{ijk} P(O_{t+1} | S_t = k) \quad (6)$$

Burada $T-1 \geq t \geq 1$ şartı sağlanmaktadır.

Herhangi bir akış içindeki epoklar için elde edilen BDAA skorlarının birbirinden koşulca bağımsız olduğunu varsayarsak, $t \in \{1, 2, \dots, T\}$ ve N tane sına grubu için, $P(O_t | S_t = k)$ olasılık değerleri aşağıdaki gibi hesaplanır :

$$P(O_t | S_t = k) = \prod_{n=1}^N p(O_t(x_k, n)) \left(\prod_{n=1}^N \prod_{k'} p(O_t(x_{k'}, n)) \right) \quad (7)$$

Burada $O_t(x_k, n)$, k karakterini içeren epok skorlarını ve $O_t(x_{k'}, n)$, k karakterini içermeyen epok skorlarını göstermektedir. Epokların ait olduğu sınıfı l_k ile ifade edersek, bu sınıfların verildiği durumdaki $p(O_t(x_k, n) | l_k)$ ve $p(O_t(x_{k'}, n) | l_{k'})$ yoğunluk fonksiyonlarının normal dağılıma sahip olduğu, eğitim kümesindeki epok skorlarının dağılımı üzerinde yapılan analizler sonucunda gözlenmiştir. Epok skorlarının oluşturduğu Gauss yoğunluğunun iki farklı sınıftaki parametrelerini tahmin etmek için eğitim kümesindeki epok skorları kullanılmıştır.

Başlangıç olasılığı, $\pi_i = P(S_1 = i)$, ve geçiş olasılıkları, $a_{ij} = P(S_2 = j | S_1 = i)$ ve a_{ijk} 'nin tahmininde ikinci dereceden SMM yapısına uygun olarak trigram dil modeli kullanılmıştır [8]. Türkçe dil yapısından oluşturulan trigramların elde edilmesinde Harry Potter kitabının Türkçe çevirisinden yararlanıldı. Bu çeviri, farklı kelime yapı ve türlerini içinde barındıracak şekilde 300.000'den fazla kelimededen ve 2 milyondan fazla karakterden oluşmaktadır. Bu kaynak içinde yer alan harf karakterleri dışındaki karakterler silinerek sadece

Tablo 1. Farklı sına ma grubu sayıları üzerinden ortalama alınarak hesaplanmış ortalama performans deęerleri. F-B ve Viterbi yöntemleri bu çalışmada önerilen modele dayalıdır.

Sınama Grubu Sayısı	Ortalama Sınıflandırma Doğruluk Oranı (%)				Ortalama Bit hızı (bit/dk)			
	BLDA	NLP	F-B	Viterbi	BLDA	NLP	F-B	Viterbi
3	44.23	49.36	65.38	67.52	13.31	15.53	22.66	23.76
5	56.66	60.90	74.10	76.15	15.38	17.15	22.78	23.88
7	64.65	67.95	80.04	80.95	15.95	17.27	21.98	22.85
10	72.69	75.77	85.64	85.96	15.77	16.88	20.60	21.18

harflerden oluşan anlamlı kelime grupları elde edilmiştir. Heceletici matris içinde yer alan rakam karakterlerine ve Türkçe'de yer almayan fakat matris içinde yer alan harflere olasılık deęerleri atamak amacıyla Laplace yumuşatma yöntemi kullanılmıştır [9].

Denklem (4) ve (5)'te elde edilen ileri ve geri yönlü olasılıklar yardımıyla, gözlem sırası O verildiği durumda, herhangi bir t zamanında i durumunda bulunma olasılığı (8)'deki gibi hesaplanır [10].

$$P(S_t = i | O_{1:T}) = \gamma_t(i) = \frac{\alpha_t(i)\beta_t(i)}{\sum_i \alpha_t(i)\beta_t(i)} \quad (8)$$

Denklem (8)'deki ifadeyi kullanarak, ileri-geri yönlü algoritması herhangi bir t zamanında en yüksek olasılık skoruna sahip durumu veya karakteri sınıflandırma sonucu olarak seçmektedir.

$$\tilde{S}_t = \arg \max_i [\gamma_t(i)] \quad , \quad 1 \leq t \leq T \quad (9)$$

2.2.2 Viterbi Algoritması

Bir SMM'nde ileri-geri yönlü algoritması, belli bir hedef kelimedeki herhangi bir harf için en yüksek olasılık skorunu sağlayan karakteri belirleyebilir, fakat her durumda algoritmanın vermiş olduğu bu harf dizisi söz konusu hedef kelime için oluşturabilecek en yüksek olasılıktaki dizi olmayabilir. Harf dizisi içindeki her bir harf için elde edilen çok-sınamalı EEG verisi ve Bölüm 2.2.1'de anlattığımız trigram dil modeline dayalı olarak Viterbi algoritması hedef kelimeyle ilişkili en yüksek olasılıklı harf dizisini sınıflandırma sonucu olarak verir. Bu amaçla, önerdiğimiz SMM'e uygun olarak oluşturulmuş Viterbi algoritması kullanıldı [11].

3. DENEYSEL SONUÇLAR

Bu çalışmada, çevrimdışı analizlerde kullanılmak amacıyla yaşları 18 ile 30 arasında deęişen 6 sağlıklı denekten veri toplanmıştır. Bu deneklerden yalnızca 2 tanesinin BBA tecrübesi vardır. Araştırmada, en yaygın olarak bilinen uyaran tipi olan 6×6 'lık bir matris kullanılmıştır. Matristeki satır ve sütunlar bloklar halinde rastgele aydınlatılır, başka bir ifadeyle, 12 yanıp sönmeye her satır ve sütun mutlaka birer defa yanıp sönmüş olur. Bir yanıp sönmeye yanar satır veya sütun 50 ms yanık kalır, ardından 75 ms boyunca hiç bir satır veya sütun yanmaz. Bu şekilde uygulanan toplam uyaran süresi 125 ms'dir. Bu çalışmada her bir denek, bir oturum kümesinde biri eğitim biri de test olmak üzere iki oturum uygulamasına tabi tutulmuştur. Bütün denekler için eğitim oturumu, "KALEM YOLCULUK" şeklinde 2 Türkçe kelime içerisinde 14 karakter içerir. Test oturumu ise, "KITAP MASA AGLAMAK SIKINTI" şeklinde 4 Türkçe kelime içerisinde 26 karakterden oluşur. Önceden belirlenmiş sayıda

sınama grubu bir araya gelerek bir akış oluşturur. Bu çalışmada, sına ma grubu sayısı her hedef harf için en fazla 15 olarak belirlenmiştir. Veriler 64 kanallı BioSemi ActiveTwo EEG kuvvetlendiricisi aracılığıyla kaydedilmiş ve sayısal ortama aktarılmıştır. Çevrimdışı sınıflandırma analizleri için MATLAB kullanılmıştır.

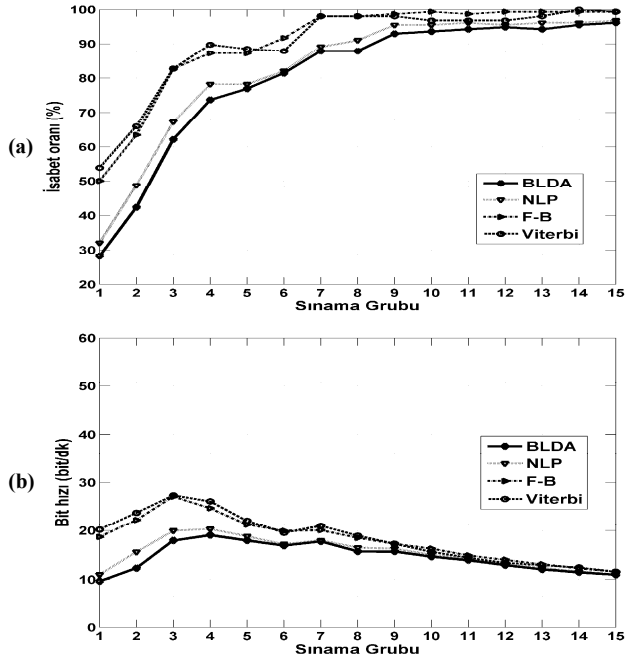
Çalışmada kullandığımız P300 tabanlı BBA sistemimizin başarımlı deęerlendirmesi için doğruluk oranı ve bit hızı gibi iki önemli ölçütü kullandık. Doğruluk oranı, test oturumundaki her bir sına ma grubunda doğru bilinen karakter sayısının toplam karakter sayısına oranıdır. Bit bölü sembol formülünün hesaplanma yöntemi ise [1]'deki gibidir.

$$B = \log_2 N + P \log_2 P + (1 - P) \log_2 \frac{1 - P}{1 - N} \quad (10)$$

Formülde P , sınıflandırmanın doğruluk oranını, N ise Şekil 1'de gösterilen matristeki eleman sayısını ifade eder. Denklem (10)'da ifade edilen formülü dakikada seçilen sembol sayısı ile çarpığımızda bit hızını, bit bölü dakika cinsinden elde ederiz. Bir sına ma grubu 1.5 sn sürmektedir, deneęe bir sonraki harfi göstermek için 3.5 sn gerektiği düşünülürse, bir dakika içinde azami 12 harf yazılabilmektedir. Bu şekilde, sistemimizin %100 doğruluk sağlayacak şekilde mümkün olan azami bit hızı 62.04 bit/dk olmaktadır.

Bu çalışmada 4 farklı yöntemin sınıflandırma analizleri gerçekleştirilip birbirleriyle karşılaştırılmıştır. Bunlardan ilki tablo ve grafiklerde BLDA yöntemi olarak tanımlanan ve harf tahmin etmede dil modeli kullanmayan algoritma; ikincisi [4]'te önerildiği şekilde önceki harflerin sınıflandırmasında verilen kararları doğru kabul edip sonraki harflerin tahmininde bu kararları kullanan NLP yöntemi; üçüncü ve dördüncü yöntem ise bu çalışmada önerilen SMM yapısına uygun olarak geliştirilmiş İleri-geri yönlü ve Viterbi algoritmalarıdır. Bu yöntemlerin sonuçları ise tablo ve grafikler üzerinde sırasıyla F-B ve Viterbi olarak belirtilmiştir.

Tablo 1'de 6 denekten alınan verilerle elde edilmiş ortalama doğruluğu ve bit hızlarını sınıflandırıcının kullanımı için sağlanan sına ma grubu sayısına göre görmekteyiz. Sonuçlara baktığımız zaman, bu çalışmada önerilen F-B ve Viterbi yöntemleri ile hem BLDA hem de dil modeli kullanılmış NLP yönteminden daha yüksek başarımlı elde edebiliyoruz. Tablo 1'de belirtilen ortalama deęerler sına ma grubu sayısına göre hesaplanırken o ana kadarki bütün sına ma grupları üzerinden ortalama hesaplanmıştır. Örneğin, 5 tane sına ma grubu için {1,2,3,4,5} numaralı sına ma grupları kullanılarak ortalama deęer hesaplanmıştır. Tablo 1'deki sonuçlara baktığımız zaman önerdiğimiz F-B ve Viterbi yöntemlerini kullanan bir BBA sisteminin BLDA yöntemine kıyasla özellikle az sayıda sına ma grubu kullanılan durumlarda çok daha yüksek hızlara ulaştığını görmekteyiz. Mesela, ilk 3 sına ma grubundan ortalama alındığında BLDA yöntemine göre F-B yönteminde ortalama doğruluk oranı ve bit hızı artışı sırasıyla %47.82 ve %70.25'dir. Bu artış Viterbi yöntemi için sırasıyla %52.66



Şekil 2. Sınama grubu sayısına göre (a) Ortalama isabet (doğruluk) oranı. (b) Ortalama bit hızı.

ve %78.51 olmuştur. Aynı şekilde ilk 5 sınama gurubundan elde edilmiş sonuçlar kıyaslanırsa performans artışının F-B yöntemi için %30.78 ve %48.11, Viterbi için ise sırasıyla %34.40 ve %55.27 olduğu gözlenir. Sınama grubu sayısı arttıkça elde edilen başarımlar artışı düşüş olmaktadır fakat tipik bir gerçek zamanlı BBA sisteminde hız en önemli kriter olduğundan özellikle ilk sınama gruplarında BLDA yöntemine kıyasla yüksek doğruluk oranlarına ulaşılması umut vericidir ve önerilen dil modelinin başarısını göstermektedir.

Şekil 2 (a) ve (b)'de sırasıyla 6 denekten elde edilmiş ortalama isabet (doğruluk) oranı ve bit hızlarının sınama grubu sayısına göre değişimini görmekteyiz. Şekil (a)'da gördüğümüz üzere, ortalama en az %90 doğru sınıflandırma oranı elde edebilmek için BLDA yönteminde 9, F-B yönteminde 6, Viterbi'de ise 4 sınama grubuna ihtiyaç duyarız. Bir sınama grubunun süresinin 1.5 sn olduğu göz önünde bulundurulursa bir harf ortalama olarak bu yöntemlerle sırasıyla 13.5 sn, 9 sn ve 6 sn'de %90 doğru sınıflandırılacaktır. Yazılacak bir sonraki harfi göstermek için 3.5 sn gibi bir zaman harcandığı varsayılırsa önerilen F-B ve Viterbi yöntemleri sırasıyla 4.8 harf/dk ve 6.32 harf/dk hızına ulaşmaktadır. BLDA yönteminde ise bu hız 3.53 harf/dk'dır. Şekil 2 (b)'de ise bu hızların BLDA, F-B ve Viterbi yöntemleri için sırasıyla 15.69 bit/dk, 19.92 bit/dk ve 26.08 bit/dk'ya tekabül ettiğini görmekteyiz. Ayrıca Şekil 2 (b), önerilen dil modelinin sistemin bit hızına BLDA yöntemine kıyasla olan katkısını özellikle ilk sınama gruplarında açıkça vurgulamaktadır.

[4]'te önerilen NLP yönteminin Tablo 1'de verilen sonuçlarına bakarsak, bu çalışmada önerilen modelin daha yüksek sonuçlara ulaştığını rahatlıkla gözlemleyebiliriz. En basit haliyle, Viterbi yönteminin NLP yöntemine göre ilk 3 ve 5 sınama grubunu dikkate aldığımızda ortalama doğruluk oranı ve bit hızı için sırasıyla (%36.79, %25) ve (%52.99, %39.24) artış oranları sağladığını görürüz. Farkedilebilir derecedeki bu farkların oluşma nedeni, NLP yönteminde, şayet önceki harflerin sınıflandırılmasında bir hata olduysa daha sonraki harflerin tahmininde sınıflandırıcının geçmiş yanlış kararları dikkate almasıdır. Fakat bu çalışmada önerilen modelde, sınıflandırıcı geçmiş zamandaki bir harf için gerçekleştirebilecek bütün karakter olasılıklarını saklar ve bunları

sonraki bir harfi tahmin etme aşamasında kullanır. Bu şekilde sonraki harflerin karar aşamasında sınıflandırıcının hata yapma ihtimali azalır.

4. VARGILAR

Bu makalede, Türkçe dil modeli üzerine kurulu bir SMM yapısına dayanan P300 tabanlı bir BBA sistemi geliştirilmiş ve sistemin eriştiği başarımların değerleri sunulmuştur. 6 sağlıklı denekle yapılan deneylerin sonucuna göre çalışmada önerdiğimiz model ile benzer geçmiş çalışmalara kıyasla daha yüksek hız ve doğruluk oranları elde edilmiş ve fikrin geçerliliği gösterilmiştir. Bundan sonraki çalışmalarımız, bu yöntemin gerçek zamanlı bir BBA sisteminde de benzer işlevi gösterdiğini gözlemlemeye çalışmak olacaktır.

TEŞEKKÜR

Yazarlar, veri ön işleme, uyarın yazılımı ve BDAA sınıflandırıcısı konularında bilgi ve kod paylaşımında bulunan Armağan Amcalar'a teşekkürlerini sunarlar.

KAYNAKÇA

- [1] J. R. Wolpaw, N. Birbaumer, D. J. McFarland, G. Pfurtscheller, ve T. M. Vaughan, "Brain-computer interfaces for communication and control," *Clin Neurophysiol*, say. 113, s. 767-91, Haz. 2002.
- [2] L. A. Farwell ve E. Donchin, "Talking off the top of your head: toward a mental prosthesis utilizing event-related brain potentials," *Electroencephalogr Clin Neurophysiol*, say. 70, s. 510-23, Ara. 1988
- [3] U. Orhan, D. Erdogmus, B. Roark, B. Oken, S. Purwar, K. E. Hild, A. Fowler, ve M. Fried-Oken, "Improved accuracy using recursive Bayesian estimation based language model fusion in ERP-based BCI typing systems," *34th Annual International IEEE EMBS Conference of the Engineering in Medicine and Biology Society*, San Diego, California, 2012.
- [4] W. Speier, C. Arnold, J. Lu, R.K. Taira, ve N. Pouratian, "Natural language processing with dynamic classification improves P300 speller accuracy and bit rate," *J. Neural Eng.*, 9(1):016004, Şub. 2012.
- [5] A. Amcalar ve M. Çetin, "Çevrimiçi Heceleme için bir Beyin-Bilgisayar Arayüzü Sistemi (A Brain-Computer Interface System for Online Spelling)," *IEEE Conference on Signal Processing, Communications, and their Applications*, Diyarbakır, Nis 2010.
- [6] U. Hoffmann, G. Garcia, J. Vesin, ve T. Ebrahimi, "Application of the evidence framework to brain-computer interfaces," *IEEE Eng Med Biol Soc (EMBC)*, say. 1, s. 446-9, 2004.
- [7] A. Kriouile, J. F. Mari, ve J. P. Haton, "Some Improvements in Speech Recognition Algorithms based on HMM," *IEEE International Conference on Acoustics, Speech, and Signal Processing (ICASSP)*, Albuquerque, s. 545-548, 1990.
- [8] F. J. Damerau, *Markov Models and Linguistic Theory*. Mouton. The Hague, 1971.
- [9] D. Jurafsky ve J. H. Martin, *Speech and Language Processing: An Introduction to Natural Language Processing, Computational Linguistics, and Speech Recognition*. Prentice Hall, 2009.
- [10] L. R. Rabiner, "A Tutorial on hidden Markov models and selected applications in speech recognition," *Proceedings of the IEEE*, say. 77, no. 2, s. 257-286, Şub. 1989.
- [11] Y. He, "Extended Viterbi algorithm for second-order hidden Markov process," *Proceedings of the IEEE 9th International Conference on Pattern Recognition (ICPR)*, s. 718- 720, 1988.