

# Parmak hareketlerine ilişkin ECoG örüntülerin AR tabanlı öznitelikler ile sınıflandırılması

Mehmet Sıraç ÖZERDEM<sup>\*1</sup>, Kerim KARADAĞ<sup>2</sup>,

<sup>1</sup> Dicle Üniversitesi, Elektrik Elektronik Mühendisliği Bölümü, Diyarbakır

<sup>2</sup> Harran Üniversitesi, Elektrik Elektronik Mühendisliği Bölümü, Şanlıurfa

Makale Gönderme Tarihi: 17.06.2013

Makale Kabul Tarihi: 12.05.2014

## Öz

*Bu çalışmada, ECoG kayıtları kullanılarak parmak hareketlerinin sınıflandırılması amaçlanmıştır. Çalışmada BCI Competition IV yarışmasında sunulan Data set IV isimli veri kümesi kullanılmıştır. Veri kümesinde üç epilepsi hastasına ilişkin ECoG kayıtları ve parmak hareketlerini gösteren elektronik eldiven kayıtları yer almaktadır. Eldiven kayıtları referans alınarak, parmak hareketlerinin yer aldığı ECoG bölümleri belirlenmiştir. Farklı uzunluklardaki belirlenen bölümlerin öznitelik vektörleri, özbağlanımlı (AR) modelleme ile elde edilmiştir. Öznitelik vektörleri kNN ve DVM yöntemleri ile sınıflandırılmıştır.*

*Sınıflandırıcı açısından bakıldığında, DVM yönteminin kNN sınıflandırıcısına göre daha iyi bir performans sergilediği görülmektedir. DVM ile yapılan sınıflandırılma işleminde, her üç denek için iki parmağın sınıflandırma başarı ortalaması %87.35, üç parmağın sınıflandırma başarı ortalaması %66.97, dört parmağın sınıflandırma başarı ortalaması %50.06 ve tüm parmakların sınıflandırma başarı ortalaması %34.41 olarak elde edilmiştir. kNN ile yapılan sınıflandırılma işleminde, her üç denek için iki parmağın sınıflandırma başarı ortalaması %75.35, üç parmağın sınıflandırma başarı ortalaması %55.50, dört parmağın sınıflandırma başarı ortalaması %39.00 ve tüm parmakların sınıflandırma başarı ortalaması %31.90 olarak elde edilmiştir.*

*AR katsayıları açısından bakıldığında, çoğunlukla  $m=3$  katsayı ile en yüksek başarımların elde edildiği görülmüştür. Denekler açısından bakıldığında, tüm sınıflandırma işlemlerinde denek 1'in en yüksek sınıflandırma performansına sahip olduğu görülmektedir. Denek 2 ve denek 3'ün sınıflandırılacak parmak sayısına göre farklı performanslar sergiledikleri görülmektedir.*

*Sınıflandırılan parmak sayısı açısından bakıldığında, ayrıştırılacak parmak sayısının artması ile başarı oranı dramatik olarak düştüğü görülmektedir. Sınıf sayısının artması ile hem DVM hem de kNN sınıflandırıcı performanslarının oldukça düşük seviyelerde yer aldığı görülmektedir.*

**Anahtar Kelimeler:** ECoG; Parmak hareketleri; özbağlanımlı modelleme; DVM; kNN; Sınıflandırma;

\*Yazışmaların yapılacağı yazar: Mehmet Sıraç ÖZERDEM. sozerdem@dicle.edu.tr; Tel: (412) 241 10 00 (3508)

## Giriş

1970'li yıllardan günümüze bilişsel veya duysal motor fonksiyonlarına yardımcı olmak veya tedavi etmek amacıyla Beyin-bilgisayar arayüzü (BBA) konusu araştırılmaktadır. Bu alanda çalışmaların temelinde, beyin ile iyi bir iletişimin sağlanması yer almaktadır. Bir BBA sistemi; beyin etkinliğinin algılanıp, yorumlandığı bir süreç olarak tanımlanır. Beyin ile iletişim kurabilme işlemini gerçekleştirebilmek için, günümüzde kullanılan teknolojiler: Elektroensefalografi (EEG), Elektrokortikografi (ECoG), Fonksiyonel Manyetik Rezonans Görüntüleme (fMRI), Pozitron Emisyon Tomografisi (PET)' dir (Wolpaw vd., 2002).

EEG, kafatası üzerinden beyin dalgalarının elektriksel yöntemle ölçülmesi olarak tanımlanır. Kafatası, beyni çevreleyen ve oldukça güçlü ve sert bir kemik yapısına sahiptir. Kafatasının yapısı ve malzeme içeriğinden dolayı, üzerinden alınan işaretlerin ölçümünü etkilemektedir. Kafatasını aşip doğrudan beyin yüzeyinden işaretin alınması, işaretin kalitesini artıracak ve ölçülen işaretin içerdiği bilginin büyük çapta artacağı düşünülmektedir. ECoG, doğrudan beyin yüzeyi üzerine yerleştirilen elektrotlar aracılığıyla beyindeki elektriksel aktivitelerin ve bu aktiviteler de meydana gelen değişimlerin ölçülmesi anlamına gelmektedir.

Paradigma tabanlı EEG/ECoG uygulamalarının yer aldığı beyin dinamiği çalışmaları, literatürde yer almaktadır. Genel olarak yapılan çalışmaları iki gruba ayırmak mümkündür. Birinci grupta, beyin dinamiğini etkileyen hasta-liklara sahip kişiler ile sağlıklı kişilerden alınan EEG/ECoG kayıtların karşılaştırılmalarını içeren çalışmalar yer almaktadır (Üstün vd., 2003; Kıymık, 2003; Gürsoy ve Subaşı, 2008; Tekin vd., 2011). İkinci grupta ise beyin dinamiğinin anlaşılmasını sağlamak amacıyla, çeşitli paradigmlar ile kayıtlar alınmış ve sınıflandırma işlemlerini içeren çalışmalar yer almaktadır (Benimeli ve Sharman, 2007; Bougrain ve Liang, 2009; Flamary ve Rakotomamonjy, 2012).

Bu çalışmada kullanılan veriler, (Bougrain ve Liang, 2009; Flamary ve Rakotomamonjy, 2012) referanslarda kullanılmıştır. Söz konusu parmak hareketlerinin, ECoG verileri ile korelasyonunun saptanmasının oldukça zor bir problem olduğu makalelerdeki yaklaşımlardan ve elde edilen başarımlardan gözlenebilmektedir. Çalışmalarda çoğunlukla, ECoG verilerine bakılarak, parmak hareketinin varlığı belirlenmeye çalışılmış ve akabinde hareketin hangi parmak olduğu saptanmaya çalışılmıştır. Bu çalışmanın diğer çalışmalara göre farkı, parmak hareketlerine ilişkin ECoG verileri elektronik eldiven kayıtları kullanılarak doğrudan ayrıştırılmış ve ayrılan örüntüler sınıflandırılmıştır. Bu çalışmada, hareketin varlığını saptamaktan çok, mevcut parmak hareketlerinin sınıflandırılması hedeflenmiştir. Bu çalışmada, sınıflandırma işlemi için sırasıyla izlenen yol; 1) elektronik eldiven ile parmak hareketlerinin bulunduğu kesitlerin belirlenmesi, 2) her kesitin süresi farklı olması nedeniyle AR katsayılarının hesaplanması, 3) parmak hareketlerine ilişkin AR katsayılarının DVM ve kNN ile sınıflandırılması 4) Sınıflandırma performanslarının karşılaştırılması

## Materyal ve Yöntem


### Veri Toplama

Bu çalışmada BCI Competition IV yarışmasında sunulan Data set IV isimli veri kümesi kullanılmıştır. Kullanılan kayıtlar, Washington Harborview hastanesinden üç epilepsi hastasından elde edilmiştir. Beynin iç yüzeyine 4mm yarıçapında elektrotlar konumlandırılarak ölçümler yapılmıştır. 62, 48 ve 64 ızgara (mesh) yapıda elektrot dizisi konumlandırılan üç hastanın kayıtları alınmıştır. Elektrot ızgara yapısı, elektrot sayısına göre 8x8 veya 8x6 boyutlarında olabilmektedir. Sağ motor kortekse yerleştirilen 8x8 veya 8x6'lık ECoG platin elektrot ızgarası ile elektriksel beyin aktivitelerinin kayıtları alınmıştır. Izgaranın boyutu 8cmx8cm veya 8cmx6cm olduğundan dolayı, sağ motor korteksi tamamen kapladığı varsayılmaktadır. Alt ve üst limitleri 0.15-200Hz'lik olan bir bant geçiren filtre ile kayıtlar filterden

geçirilmiş olup, potansiyeller 1000Hz'de örnekleme yapılarak bilgisayara aktarılmıştır. Parmak hareketlerinin kaydı için elektronik veri eldiveni kullanılmıştır (Schalk, 2007).

### Paradigma

Tasarlanan kayıt düzeneği Şekil 1'de gösterilmiştir. Kayıtlarda izlenen paradigma; A) Deneğe uyarı olarak ekranda gösterilen parmak ismi, bir komut niteliğindedir. 2 saniye boyunca ekranda görüntülenir. B) Denekten bu süre içinde ekranda belirtilen (komut) parmağı 3-5 kez hareket ettirmesi istenir. C) Süre sonunda, ekranda yer alan komut silinir ve 2ms süre ekran bir komut belirmez. D) Toplam kayıt süresi 10 dakikayı aşmadıysa, işlem tekrarı için adım A'ya dönlür.



Şekil 1. ECoG verileri için kayıt düzeneği

### Önişlem

Veri kümesinde üç epilepsi hastasının kayıtları yer almakta olup, kayıtlar parmak hareketlerine ilişkili ECoG verilerini ve elektronik eldiven kayıtlarını içermektedir. Önişlem olarak, eldiven kayıtları referans alınarak, parmak hareketlerinin yer aldığı ECoG kesitleri belirlenmiştir. Bu kesitler (örüntüler) analizlerde kullanılmak üzere çıkarılmıştır.

### Öznitelik Çıkartma

Parmak hareketlerini içeren örüntülerin boyutları farklı uzunlukta olup kanal sayıları ile birlikte düşünüldüğünde, oluşturulan örüntülerin hala analiz etmek için yeterince büyük oldukları gözlenmiştir. İşaretlerin karakteristiklerini yakalamak üzere, her örüntünün AR katsayıları hesaplanmıştır.

Örneğin birinci deneğin parmak 1'e ilişkin çıkarılan örüntü boyutu 62x2120 dir. Her kanal için m adet AR katsayısının hesaplanması ile örüntü 62xm boyutlarına indirgenmiştir. Bu katsayılar bir vektör (1,62xm) haline getirilerek, parmak 1'in öznitelik vektörü olarak kullanılmıştır.

Öznitelik hesabında kullanılan Özbağlanımlı Modelleme (Autoregressive Model, AR) yöntemi aşağıdaki bölümünde açıklanmıştır.

### Özbağlanımlı (AR) Modelleme

Spektral içeriğin belirlenmesi spektral analizi gerektirir. Spektral analiz, Parametrik olmayan (klasik) ve parametrik (model tabanlı) yöntemler olmak üzere iki farklı yaklaşımı vardır. Parametrik yöntemlerde, işaret fonksiyonel formu bilinen modele uygulanır ve bu modele ilişkin parametrelerin kestirimi yapılır. Literatürde yer alan parametrik modeller; özbağlanımlı modelleme (autoregressive model, AR modeli), yürüyen ortalamalı model (moving average model, MA modeli) ve bunların birleşimi olan özbağlanımlı yürüyen ortalamalı modeldir. (autoregressive moving average model, ARMA modeli) (Übeyli ve Güler, 2002).

Bu çalışmada, parmak hareketlerine ilişkin örüntülerin zamanla değişimi özbağlanımlı (AR) modelleme ile modellenmiştir.

$$a_k(t) = -\sum_{j=1}^P b_{k,j}^* a_{k,j}(t-j) \quad k = 1,2,\dots,M \quad (1)$$

Bağıntıda, P model derecesini,  $b_{k,j}$  model katsayılarını ifade eder. Model katsayılarının hesaplanması olarak en küçük kareler yöntemi kullanılmıştır. Bu modelleme tüm örüntüler için gerçekleştirilmiştir. En yüksek performansın kaç AR katsayısı ile elde edildiğini görebilmek için katsayısı adedi olan m değeri [3 10] sayı aralığında alınmıştır.

### Sınıflandırma ve Başarı Ölçütü

Her harekete ilişkin değişimlerin AR katsayıları hesaplanarak öznitelikler elde edilmiştir. Hareketlere ilişkin öznitelikler Destek Vektör

Makinaları (DVM) ve K en yakın komşu algoritması (kNN) ile sınıflandırılmıştır.

a) Destek Vektör Makinaları (DVM)

Birbirleriyle ilişkisi karmaşık sayılabilecek ve direk doğrusal bir ilişki bulunamayan öznelik vektörlerinin arasındaki ilişkiyi çok boyutlu uzayda bulan bir yöntemdir. DVM, Vladimir N. Vapnik tarafından ortaya konulmuş istatistiksel bir öğrenme algoritmasıdır (Borges, 1998). DVM’de genel olarak ikili sınıflandırma işlemi yapılır. İkili sınıflandırma probleminde doğrusal olarak ayrılabilen bir veri seti için sonsuz sayıda hiper-düzlem vardır. DVM karar yüzeyini oluştururken, iki sınıfa olan uzaklığı maksimum yapmaya çalışır. Düzlemler arasında maksimum sınıra sahip sadece bir hiper-düzlem bulunmaktadır. Sınır genişliğini hiperdüzlem noktalarına destek vektörleri adı verilir (Küçük vd., 2013). DVM en büyük sınır genişliğine sahip ayırıcı hiper-düzlem ile sınıflandırma yaparak eğitim hatasını minimize etmeye çalışır. Yöntem, sınıfları birbirinden ayıran özel bir hiper-düzlemin bulunmasını amaçlar. Lineer olarak ayrılabilen örneklerde veriler daha yüksek boyutlu başka bir uzaya taşınır ve sınıflandırma o uzayda yapılır. Bu çalışmada da kullanılan özneliklerin karmaşıklığı ve çok boyutlu olmasından ötürü, bu yöntem kullanılmıştır.

b) K en yakın komşu Algoritması (kNN)

kNN yöntemi en basit örüntü tanıma yöntemlerindedir (Alpaydin, 2004). Algoritmanın temel mantığı, sınıflandırılacak verinin en yakınındaki k adet örneğin sınıf bilgisine bakarak yeni veriyi çoğunluğun ait olduğu sınıfa atamaktır. Algoritmanın sınıflandırma işlemindeki başarısını etkileyen faktörlerden biri k değerinin doğru seçilmesidir. k değerinin çok büyük veya çok küçük seçilmesi, aynı sınıfta bulunması gereken örüntülerin farklı sınıflara atanabilmesine neden olabilmektedir. Farklı k değerleri ile deneyerek en başarılı olan k değerinin belirlenmesi en yaygın yöntemdir, ancak bu işlem zaman açısından maliyetli bir işlemdir. Sınıflandırılacak örüntülerin boyutları, kNN

işlem hızını etkileyen diğer bir parametredir (Özger ve Amasyalı, 2013).

c) Başarı Ölçütü

Doğru saptanan örüntü sayısının, toplam test örüntü sayısına oranı ile performans (B) hesabı yapılır.

$$B = 100 \cdot \frac{\text{Doğru saptanan örüntü sayısı}}{\text{Toplam örüntü sayısı}}$$

Uygulama ve Başarımlar

Bu çalışmada, parmakların hareketleri ile ilişkili Elektrokortikografi (ECoG) verilerinin sınıflandırılması amaçlanmıştır. BCI Competition IV yarışmasında sunulan Data set IV isimli veri kümesi kullanılmıştır. Harekete ilişkin verilerin bölütleri belirlenerek, örüntüler elde edilmiştir. Her örüntünün öznelik vektörleri, özbağımlı (AR) modelleme yöntemi ile elde edilmiştir.

Sınıflandırma işleminde, özellikle hangi parmağın ayrıştırılmasının zor olduğunu görebilmek amacıyla Tablo 1’de gösterildiği şekilde bir sınıflama işlemi yapılmıştır.

Tablo 1. Uygulamalarda kullanılan parmaklar ve elde edilmesi istenen sınıf sayıları

Uygulama	Kullanılan Parmaklar	Sınıf Sayısı
1	P1 – P5	2
2	P1 – P2 – P5	3
3	P1 – P2 – P3- P5	4
4	P1 – P2 – P3- P4 – P5	5

kNN ile sınıflandırma işleminde izlenen akış aşağıda açıklanmıştır.

Denek 1, denek 2 ve denek 3 için AR katsayıları m=3:10 aralığının da ve kNN sınıflandırıcısının farklı komşu sayıları k=1:10 aralığının da dikkate alınarak sınıflandırma işlemi yapılmıştır. Her analiz 10 kez tekrarlanmış olup, elde edilen sonuçların ortalaması hesaplanmıştır. Tüm deneklerde elde edilen maksimum başarımlar sonuçları Tablo 2’de gösterilmiştir.

**Tablo 2.** kNN ile parmak hareketlerinin sınıflandırılması

a) P1 ve P5 kümelerinin sınıflandırılmasında, tüm deneklerde elde edilen max. başarı sonuçları

	Komşu sayısı (k)	Toplam AR katsayısı (m)	Performans (%)	RMS
Denek 1	1	3	82,60	0,37
	2	3	82,60	0,37
Denek 2	7	9	69,13	0,55
	8	9	69,13	0,55
Denek 3	1	3	74,33	0,50
	2	3	74,33	0,50

b) P1, P2 ve P5 kümelerinin sınıflandırılmasında, tüm deneklerde elde edilen max. başarı sonuçları

	Komşu sayısı (k)	Toplam AR katsayısı (m)	Performans (%)	RMS
Denek 1	6	3	68,6	0,73
	7	3	68,2	0,74
Denek 2	7	3	46,39	1,02
	8	3	45,83	1,02
Denek 3	5	3	51,50	0,81
	6	3	50,83	0,79

c) P1, P2, P3 ve P5 kümelerinin sınıflandırılmasında, tüm deneklerde elde edilen max. başarı sonuçları

	Komşu sayısı (k)	Toplam AR katsayısı (m)	Performans (%)	RMS
Denek 1	3	3	46,70	1,09
	4	3	46,00	1,12
Denek 2	7	9	38,20	1,37
	8	9	37,80	1,32
Denek 3	4	4	32,02	1,21
	5	3	30,95	1,21

d) Tüm parmakların sınıflandırılmasında, deneklerde elde edilen max başarı sonuçları

	Komşu sayısı (k)	Toplam AR katsayısı (m)	Performans (%)	RMS
Denek 1	3	3	41,40	1,42
	1	5	40,40	1,51
Denek 2	9	7	29,26	1,64
	10	7	30,15	1,62
Denek 3	6	4	23,70	1,53
	7	4	24,07	1,57

DVM ile sınıflandırma işleminde izlenen akış aşağıda açıklanmıştır.

DVM için Kernel tipi Radial Base Function (RBF) seçilmiştir. Eğitim sürecinde kernel genişlik parametresi  $\sigma=260$  ve regülarizasyon parametresi  $\gamma=2246$  olarak seçilmiştir. Sistemin performansının doğru saptanması için Cross validation oranı 10 olarak alınmış ve 100 kez rastgele eğitim ve test küme örüntüleri değiştirilmiştir.

Cross validation uygulanması nedeniyle tüm örüntüler hem eğitim hem de test sürecinde kullanılmıştır. Bu uygulama 100 kez tekrarlanarak, olası tüm kümeler oluşturulmuş ve başarı oranları test edilmiştir. Tüm deneklerde elde edilen maksimum başarı sonuçları Tablo 3’de gösterilmiştir.

**Tablo 3.** DVM ile parmak hareketlerinin sınıflandırılması

a) P1 ve P5 kümelerinin sınıflandırılmasında, tüm deneklerde elde edilen max. başarı sonuçları

	Toplam AR katsayısı (m)	Performans (%)	RMS
Denek 1	3	93,30	0,17
Denek 2	3	77,67	0,45
Denek 3	3	91,07	0,27

b) P1, P2 ve P5 kümelerinin sınıflandırılmasında, tüm deneklerde elde edilen max. başarı sonuçları

	Toplam AR katsayısı (m)	Performans (%)	RMS
Denek 1	3	88,8	0,37
Denek 2	3	52,67	0,91
Denek 3	3	59,43	0,72

c) P1, P2, P3 ve P5 kümelerinin sınıflandırılmasında, tüm deneklerde elde edilen max. başarı sonuçları

	Toplam AR katsayısı (m)	Performans (%)	RMS
Denek 1	3	67,00	0,81
Denek 2	4	50,00	1,15
Denek 3	3	33,19	1,16

d) Tüm parmakların sınıflandırılmasında, deneklerde elde edilen max başarı sonuçları

	Toplam AR katsayısı (m)	Performans (%)	RMS
Denek 1	3	52,80	1,17
Denek 2	3	30,35	1,43
Denek 3	3	20,07	1,58

## Sonuçlar ve Tartışma

Bu çalışmada, ECoG kayıtları kullanılarak parmak hareketlerinin sınıflandırılması amaçlanmıştır. Çalışmada BCI Competition IV yarışmasında sunulan Data set IV isimli veri kümesi kullanılmıştır. Veri kümesinde üç epilepsi hastasına ilişkin ECoG kayıtları ve parmak hareketlerini gösteren elektronik

eldiven kayıtları yer almaktadır. Eldiven kayıtları referans alınarak, parmak hareketlerinin yer aldığı ECoG bölümleri belirlenmiştir. Farklı uzunluklardaki belirlenen bölümlerin öznitelik vektörleri, özbağlanımlı (AR) modelleme ile elde edilmiştir. Öznitelik vektörleri kNN ve DVM yöntemleri ile sınıflandırılmıştır.

**Tablo 4.** Öznetelik olarak AR katsayılarının kullanılmasıyla, k-NN ve DVM sınıflandırıcılarının en yüksek başarı performansları

Sınıflandırılan Parmak		k-NN			DVM		
		m	Performans (%)	RMS	m	Performans (%)	RMS
P1-P5	Denek 1	3	82,60	0,37	3	<b>93,30</b>	0,17
	Denek 2	9	69,13	0,55	3	77,67	0,45
	Denek 3	3	74,33	0,50	3	91,07	0,27
P1-P2-P5	Denek 1	3	68,60	0,73	3	<b>88,80</b>	0,37
	Denek 2	3	46,39	1,02	3	52,67	0,91
	Denek 3	3	51,50	0,81	3	59,43	0,72
P1-P2-P3-P5	Denek 1	3	46,70	1,09	3	<b>67,00</b>	0,81
	Denek 2	9	38,20	1,37	4	50,00	1,15
	Denek 3	4	32,02	1,21	3	33,19	1,16
P1-P2-P3-P4 P5	Denek 1	3	41,40	1,42	3	<b>52,80</b>	1,17
	Denek 2	7	30,15	1,62	3	30,35	1,43
	Denek 3	4	24,07	1,57	3	20,07	1,58

kNN ve DVM ile yapılan sınıflandırma sonuçları sırasıyla Tablo 2 ve Tablo 3'de gösterilmiştir. Elde edilen sonuçların karşılaştırılabilirliği açısından, deneklere ilişkin sınıflandırma sonuçları Tablo 4'de birleştirilmiştir. Tablodan görüldüğü üzere, sınıflandırıcı açısından bakıldığında, DVM'in kNN sınıflandırıcısına göre daha iyi bir performans sergilediği görülmektedir. DVM ile yapılan sınıflandırılma işlemi, her üç denek için iki parmağın sınıflandırma başarı ortalaması %87.35, üç parmağın sınıflandırma başarı ortalaması %66.97, dört parmağın sınıflandırma başarı ortalaması %50.06 ve tüm parmakların sınıflandırma başarı ortalaması %34.41 olarak elde edilmiştir. kNN ile yapılan sınıflandırılma işlemi, her üç denek için iki parmağın sınıflandırma başarı ortalaması %75.35, üç parmağın sınıflandırma başarı ortalaması %55.50, dört parmağın sınıflandırma başarı ortalaması %39.00 ve tüm parmakların sınıflandırma başarı ortalaması %31.90 olarak elde edilmiştir.

AR katsayıları açısından bakıldığında, çoğunlukla m=3 katsayı ile en yüksek başarımların elde edildiği görülmüştür.

Denekler açısından bakıldığında, tüm sınıflandırma işlemlerinde denek 1'in en yüksek sınıflandırma performansına sahip olduğu görülmektedir. Denek 2 ve denek 3'ün sınıflandırılacak parmak sayısına göre farklı performanslar sergiledikleri görülmektedir.

Sınıflandırılan parmak sayısı açısından bakıldığında, ayrıştırılacak parmak sayısının artması ile başarı oranı dramatik olarak düştüğü görülmektedir. Sınıf sayısının artması ile hem DVM hem de kNN sınıflandırıcı performanslarının oldukça düşük seviyelerde yer aldığı görülmektedir.

### Teşekkür

Bu çalışma, Dicle Üniversitesi DÜBAP 11:MF:110 numaralı proje kapsamında desteklenmiştir.

### Kaynaklar

Wolpaw R. J., Birbaumer N., McFarland, D.J., Pfurtscheller, G., Vaughan, T.M. BCI for communication and control. Clinical Neurophysiology, 113, 2002

- Üstün, M.E., Güney, Ö., Genç, B.O., İlhan, N., Özkal, E. Genel Tıp Dergisi, 13(2):49-52, 2003
- Kıymık, M.K., “EEG işaretlerinde gürültü bastırılması için uyarlamalı wiener süzgecinin gerçekleştirilmesi”, Politeknik Dergisi, 6(1), 2003.
- Gürsoy, M.İ., Subaşı, A. “DVM ile EEG işaretlerinin sınıflandırılmasında TBA,BBA ve DAA'nın performansının karşılaştırılması”, IEEE 16. SIU2008, 2008.
- Tekin, R., Kaya, Y., Tağluk, M.E., “K-means ve YSA temelli Hibrit Bir Model ile Epileptik EEG İşaretlerinin Sınıflandırılması”, Elektrik Elektronik Bilgisayar Semp. Elazığ, 2011
- Benimeli, F., Sharman, “Electroencephalogram Signal Classification For Brain Computer Interfaces using wavelets and support vector machines”, 15. European Symposium on ANNs, Valencia, 2007.
- Bougrain, L., Liang,N., “Band specific features improve finger flexion prediction from ECoG”, Jornades Argentinas Sobre Interfaces Cerebro Computadora, 2009.
- Flamary, R., Rakotomamonjy, A. “Decoding finger movements from ECoG signals using switching linear models”, Front Neurosci. 6: 29, 2012
- Schalk, G., Kubanek, J., Miller, K.J., Anderson, N.R., Leuthardt, E.C., Ojemann, J.G., Limbrick, D., Moran, D.W., Gerhardt, L.A., and Wolpaw, J.R. Decoding Two-Dimensional Movement Trajectories Using Electrocortico-graphic Signals in Humans, J.Neural Eng.4:264-275, 2007.
- Übeyli E.D., Güler İ., “Cramer-Rao alt sınırı ile AR metodunda parametre kestirim performansının analizi”, Politeknik Dergisi, Cilt: 5 Sayı:1 s.1-11, 2002
- Burges, J.C., “A Tutorial on Support Vector Machines for Pattern Recognition”, Data Mining and Knowledge Discovery 2, 121-167, 1998.
- Küçük H., Tepe C., Eminoğlu İ., “K-En Yakın Komşu Algoritması ve Destek Vektör Makinesi Yöntemleri ile EMG İşaretlerinin Sınıflandırılması”, 21. Sinyal İşleme ve İletişim Uygulamaları, KKTC, 2013
- Alpaydin, E., “Introduction to Machine Learning”, MIT Press, 2004
- Özger Z.B., Amasyalı M.F., "Meta Öğrenme ile KNN Parametre Seçimi", IEEE 21. Sinyal İşleme ve İletişim Uygulamaları Kurultayı, KKTC, 2013



## **Classification of ECoG patterns related to finger movements with AR based features**

### **Extended abstract**

*Classification of electrocorticography (ECoG) records related to finger movement is the main purpose of this study. Data set IV presented in BCI Competition IV was used in this paper. This data set contains brain signals from three epileptic subjects and the data records consist of both ECoG and electronic glove data. ECoG segments related finger movements were extracted by means of finger movement records generated by electronic glove. Features of segments having different data points were extracted using autoregressive (AR) model. The AR coefficients were classified with Support Vector Machine (SVM) and K nearest neighbors (kNN) classifiers.*

*AR coefficients were calculated using the least squares method. To get the acceptable result, the AR coefficients were calculated in the range of [3-10] order. At the end of the analysis, the third-order AR coefficients produces acceptable results were observed.*

*k nearest neighbor (kNN) algorithm was introduced by Dasarathy in1991. It is a machine learning algorithm that reads a set of labeled training set, and then it is used to classify an unlabeled testing set. In order to classify a testing pattern, it computes the distance between testing pattern and all the training patterns. Then, the k training patterns of closest distance to the testing pattern are used to determine the class of testing pattern. To get the acceptable results in our classification problem, the distance of patterns were calculated with the k parameter in the range of [1-10] order. At the end of the analysis, generally the highest classification performances were observed with small k values.*

*Support vector machine (SVM) is a discriminative classifier formally defined by a separating hyperplane. In other words, SVMs are based on the concept of decision planes that define decision boundaries. A decision plane is one that separates between a set of objects having different class memberships. In our study, SVM was used to classify the ECoG patterns with the kernel of radial base function. At the end of the SVM classification, the*

*optimal values were obtained for regularization and sigma parameters of SVM.*

*To find the finger which is hardest to classify among all fingers, different applications were achieved. In the first application, it consists of two classes for P1 and P5. In the second application, it consists of three classes for P1, P2 and P5. In the third application, it consists of four classes for P1, P2, P3 and P5. In the last application, it consists of five classes for P1, P2, P3, P4 and P5. The results showed that performances were decreased with increasing of classes, which was also an expected result.*

*We listed the performances of SVM and kNN methods. We found that the SVM method yielded the best performance in classifying the ECoG pattern related to finger movements.*

*For the SVM classifier, the mean performances of three subjects were obtained as follows; classification rate 87.35% for two fingers, classification rate 66.97% for three fingers, classification rate 50.06% for four fingers and classification rate 34.41% for five fingers.*

*For the kNN classifier, the mean performances of three subjects were obtained as follows; classification rate 75.35% for two fingers, classification rate 55.50% for three fingers, classification rate 39.00% for four fingers and classification rate 31.90% for five fingers.*

*The results showed that we need different approaches to improve the performances. To get the higher performance, more effective methods should be improved. In the future work, we focused on this problem.*

**Keywords:** *ECoG, finger movements, AR, SVM, kNN, classifications*