

# EEG Sinyallerinden Fraktal Boyut Ve Dalgacık Dönüşümü Kullanılarak Duygu Tanıma

## Emotion Recognition from EEG Signals Using Fractal Dimension And Wavelet Transform

Hüseyin Atasoy<sup>1</sup>, Serdar Yıldırım<sup>1</sup>, Esen Yıldırım<sup>1</sup>, Yakup Kutlu<sup>1</sup>

<sup>1</sup>Bilgisayar Mühendisliği Bölümü  
Mustafa Kemal Üniversitesi  
{hatasoy,serdar,eyildirim,ykutlu}@mku.edu.tr

### Özet

*Bu çalışmada, EEG sinyallerinden duygu tanıma fraktal boyut değerleri ile dalgacık dönüşümünden elde edilen öznelikler birleştirilerek yapılmıştır. Teta, alfa, beta ve gama frekans bantlarını taşıyan detay sinyallerinden elde edilen istatistiksel veriler (ortalama, standart sapma, maksimum ve minimum değerler), her bandın enerjisinin toplam enerjiye oranı, entropiler ve her bir kanalda hesaplanan fraktal boyut değerleri öznelik olarak kullanılmıştır. Özneye bağımlı sınıflandırma, değerlendirme ve baskınlık için ayrı ayrı ikili olarak (yüksek-düşük) en yakın k komşu algoritması ile yapılmıştır. Özneye bağımlı sınıflandırma sonunda elde edilen ağırlıklandırılmış ortalama duyarlılık-özgünlük değerleri, değerlendirme, uyarılma ve baskınlık için sırasıyla 0.684-0.656, 0.647-0.553 ve 0.602-0.555 olarak hesaplanmıştır.*

### Abstract

*In this study, emotion recognition from EEG signals was performed using fractal dimension and wavelet transform. Statistical information (mean, standard deviation, maximum and minimum values) obtained from signals' theta, alpha, beta and gamma frequency bands, ratios of energy in each band to the total energies, entropies and fractal dimension values were used as features. Subject-dependent binary (high-low) classification was performed for valence, arousal and dominance separately using k-nearest neighbor algorithm. Weighted average sensitivity-specificity values obtained as 0.684-0.656, 0.647-0.553 and 0.602-0.555 for valence, arousal and dominance respectively.*

### 1. Giriş

İnsan hayatında önemli bir yeri olan makinelerin insanlar ile etkileşiminin güçlendirilmesinin önemi giderek artmaktadır. Bu amaçla makinelere insanların duygularını ayırt edebilme yetisi kazandırılmaya çalışılmaktadır. Yüz görüntüsü, konuşma, vücut sıcaklığı, kalp atış hızı gibi, insanların duygu durumlarına göre değişebilen işaretler kullanılarak yapılan çalışmalar [1, 2, 3] bulunmakla birlikte beyin hücrelerinin elektriksel aktivitelerinin analizi ile de duygu tanıma problemine çözümler getirilebilmektedir [4, 5, 6].

Beyin hücrelerinin elektriksel aktivitelerinin kafa derisi üzerinde meydana getirdiği potansiyel farkları ölçme yöntemi olan elektroensefalografi (EEG), başlarda yalnızca medikal amaçlı kullanılmış olsa da kablosuz, kolay taşınabilir, düşük maliyetli EEG ölçüm cihazlarının geliştirilmiş olması bu konuda yapılan çalışmaların hızlanmasını sağlamıştır [7, 8, 9].

EEG sinyalleri ile duygu durumunun analizi konusunda farklı yöntemlerle yapılmış çeşitli çalışmalar bulunmaktadır [10, 11, 12]. Petrantonakis tarafından yapılan çalışmada duygular HOC yöntemi ile elde edilen öznelikler kullanılarak sınıflandırılmıştır [10]. Nie'in çalışmasında frekans bantlarının enerjilerinin logaritması öznelik olarak kullanılmıştır [11]. Bir diğer çalışmada Murugappan, öznelik çıkarımı için dalgacık dönüşümünü kullanmıştır [12].

Bu çalışmada öznelikler dalgacık dönüşümü ve fraktal boyut analizi yöntemleri kullanılarak çıkarılmış ve en uygun öznelikler, sınıflarla korelasyonu en yüksek belli sayıda öznelik seçilerek belirlenmiştir. Duygular belirlenen özneliklerle özneye bağımlı olarak sınıflandırılmıştır.

### 2. Kullanılan EEG veri seti

Çalışmada DEAP EEG veri seti [13] kullanılmıştır. DEAP veri seti, duygu analizlerinde kullanılmak üzere yaşları 19 ile 37 arasında olan yarısı erkek 32 gönüllü üzerinde, 32 kanallı olarak kaydedilmiştir. Her bir kanaldan 512 Hz frekansı ile örneklenmiş 63 saniyelik sinyal kaydedilmiştir. 1280 kayıt içeren veri seti oluşturulurken, duygu uyarımı için gönüllülere birer dakikalık 40 adet müzik klipi izletilmiştir. Kliplerin her bir katılımcıda uyandırdığı duygular, katılımcılar tarafından değerlendirme, uyarılma, baskınlık ve beğenilme ölçütlerinde 1-9 aralığında değerlendirilmiştir.

Veri setinde kullanılan değerlendirme-uyarılma-baskınlık modeli [14], duyguların ifadesinde yaygın olarak kullanılmaktadır. Değerlik, hoşnutluğun bir ölçüsü olarak kullanılır. Düşük değerlendirme, üzüntü gibi negatif duyguları, yüksek değerlendirme mutluluk gibi pozitif duyguları ifade eder. Düşük uyarılma, heyecansız, sakin duyguları, yüksek uyarılma, daha aktif, heyecanlı duyguları ifade eder. Baskınlık ise duyguların ne yoğunlukta hissedildiğinin ölçüsüdür.


DEAP veri setindeki kayıtlar bazı ön işlemlerden geçirilmiş

olarak sunulmaktadır. Yapılmış olan ön işleme esnasında 512 Hz ile örneklenen sinyallerin örnekleme frekansı 128 Hz’de düşürülmüştür. Böylece kanal başına toplanan örnek sayısı  $128 \times 63 = 8064$  olmuştur. Göz hareketlerinin sinyallerde neden olduğu dalgalanmalar temizlenmiştir. Sinyaller kesme frekansları 4 ve 45 Hz olan bant geçiren filtre ile filtrelenmiş ve birer dakikalık pencereler öncesinde kaydedilen 3 saniyelik temel kayıtlar sinyallerden çıkarılmıştır [13].

### 3. Metot

Çalışmada EEG verileri yüksek ve düşük duyu bileşenlerine göre her bir katılımcı ve her bir bileşen için (uyarılma, değerlik ve baskınlık) ayrı ayrı ikili olarak sınıflandırılmıştır. 5’ten büyük değerler yüksek, diğerleri düşük kabul edilmiştir.

Etiketleme işleminin ardından, sınıflara ait örnek sayılarının dengeleri kontrol edilmiş ve örnek sayılarının sınıflardan birinde yeterli olmadığı gözlenen öznelerle ait kayıtlar, yalnızca o duyu bileşeni için veri setinden çıkarılmıştır. Çalışmada 5 parçalı çapraz doğrulama kullanıldığından, her bir parçada sınıflara ait en az ikişer örnek olabilmesi için, her sınıftan en az 10 örnek bulunması, yeterlilik ölçütü olarak belirlenmiştir. Bu ölçütü değerlik bileşeni için tüm öznelerle ait kayıtlar sağlarken, uyarılma bileşeni için 3 (33 düşük/7 yüksek), 12 (8/32), 13 (8/32), 21 (9/31), 23 (31/9), baskınlık bileşeni için 4 (31/9), 9 (32/8), 18 (9/31), 20 (31/9), 25 (6/34), 27 (1/39), 32 (3/27) numaralı öznelerle ait kayıtlar sağlayamamıştır. Bu aşamadan sonra izlenen adımlar aşağıdaki akış diyagramı ile özetlenmiştir.



Şekil 1: Akış diyagramı.

#### 3.1. Öznitelik çıkarımı

Öznitelikler dalgacık dönüşümü [15] ve fraktal boyut [16] değerleri kullanılarak elde edilmiştir.

##### 3.1.1. Dalgacık dönüşümü ile öznitelik çıkarımı

Dalgacık dönüşümü, sinyallerin aşamalı olarak yüksek ve düşük frekans bileşenlerine ayrılmasını sağlayan bir yöntemdir. Frekans analizinde kullanılan bir diğer yöntem olan Fourier dönüşümü, sinyallerin frekans bileşenlerinin zamanla değişmediği varsayımı ile uygulanır. Ancak bu varsayım EEG sinyalleri gibi durağan olmayan sinyaller için geçerli değildir. Dalgacık dönüşümü ile durağan olmayan sinyallerde zaman-frekans bilgileri elde edilebildiğinden bu yöntem EEG gibi sinyallerin frekans analizi için daha uygundur.

Dönüşüm yapılırken sinyal, bir dalgacığın  $\Psi(t)$  ötelenip ölçeklenmesi ile elde edilen dalgacıklarla ifade edilir (1). Ölçeklenen dalgacık denklemi a öteleme ve b ölçekleme katsayıları olacak şekilde denklem (2)’de verilmiştir.

$$\Psi_{a,b}(t) = \frac{1}{\sqrt{a}} \Psi\left(\frac{t-a}{b}\right) \quad (1)$$

Seçilecek dalgacıkların denklem (3)’teki ifadesi sağlaması gerekir. Burada  $\Psi(w)$ ,  $\Psi_{a,b}(t)$ ’nin Fourier dönüşümüdür.

$$\int_{-\infty}^{+\infty} \frac{|\Psi(w)|^2}{w} dw < \infty \quad (2)$$

Ayrışım aşamalı olarak yapılır. Her aşamada yüksek frekans bileşenleri taşıyan detay ve düşük frekans bileşenleri taşıyan yaklaşım sinyalleri elde edilir. İlk aşamadan sonra ayrışım, yaklaşım sinyalleri üzerinde uygulanır (Şekil 1).

Çalışmada sinyaller, db4 dalgacığı kullanılarak teta, alfa, beta ve gama frekans bantlarını taşıyan parçalara ayrıştırılmıştır. Db4, EEG sinyallerindeki dalga formuna benzediği için seçilmiştir. Veri setindeki sinyallerin örnekleme frekansı 128 Hz olduğundan 4 seviyeli ayrışım yapılmıştır.

Çizelge 1: Sinyallere uygulanan 4 seviyeli dalgacık dönüşümü

Ayrışım Seviyesi	Frekans Aralığı	Bant
Detay 1	64-32	gama
Detay 2	32-16	beta
Detay 3	16-8	alfa
Detay 4	8-4	teta
Yaklaşım 4	4-0	delta

Detay sinyallerinin her birinin en büyük ve en küçük değeri, standart sapması, ortalaması ve enerjisinin toplam enerjiye oranı ile birlikte her bir kanal üzerinde hesaplanan entropiler de birer öznitelik olarak değerlendirilmiştir. Böylece dalgacık dönüşümünden elde edilen öznitelik sayısı  $32 \times 4 \times 5 + 32 = 672$  olmuştur. 4. seviyedeki yaklaşım sinyali 0-4 Hz’lik frekans aralığını taşıdığından ve bu frekans aralığı ön işleme esnasında 4-45 Hz bant geçiren filtre tarafından elendiğinden bu sinyal değerlendirmeye alınmamıştır.

Shannon entropisi [17] sinyallerin bağıl enerjileri kullanılarak hesaplanır. Dalgacık dönüşümü ile elde edilen j. sinyal  $S_j$  ile gösterilirse, sinyalin enerjisi  $E_j$  denklem (3) ile elde edilir.

$$E_j = \sum_k |S_j(k)|^2 \quad (3)$$

$S_j$  sinyalinin enerjisinin bağıl değeri  $p_j$ , sinyallerin toplam enerjileri  $E_t$  ile gösterilirse,  $p_j$  değeri ve sinyalin Shannon entropisi  $SE$  sırasıyla denklem (4) ve (5) ile elde edilir [18, 19].

$$p_j = \frac{E_j}{E_t} \quad (4)$$

$$SE = -p_j \ln(p_j) \quad (5)$$

##### 3.1.2. Fraktal Boyut

Fraktal boyut değerleri, EEG sinyalleri gibi doğrusal olmayan sinyallerin karmaşıklıklarının analizinde kullanılabilir. Yapılan çalışmalar, fraktal boyut değerlerinin EEG sinyalleri için ayırt edici olduğunu göstermektedir [20]. Teorik fraktal boyutları bilinen fonksiyonlar üzerinde fraktal boyut ölçme yöntemleri ile yapılan testler, Higuchi algoritmasının teorik değerlere daha yakın sonuçlar ürettiğini gösterdiğinden [21] bu çalışmada da fraktal boyut değerlerinin hesaplanması için Higuchi algoritması kullanılmıştır [22].

Higuchi algoritması uyarınca  $X(1), X(2), \dots, X(N)$  bir sonlu zaman serisi iken bu seri kullanılarak k tane yeni zaman serisi

oluşturulur (6).

$$X_k^m: X(m), X(m+k), X(m+2k), \dots, X\left(m + \left\lfloor \frac{N-m}{k} \right\rfloor \cdot k\right) \quad (6)$$

Burada  $m=1,2,\dots,k$  değerlerini alır.  $\lfloor \cdot \rfloor$ , içerisindeki değeri ona eşit veya ondan küçük en büyük tamsayıya yuvarlanacağını gösterir. Bu ifade ile  $k$  tane yeni zaman serisi oluşturulduktan sonra, eğrilerin uzunlukları  $L_m(k)$ , denklem (7) ile hesaplanır.

$$L_m(k) = \frac{\sum_{i=1}^{\lfloor \frac{N-m}{k} \rfloor} |x(m+ik) - x(m+(i-1)k)|^{(N-1)}}{\left\lfloor \frac{N-m}{k} \right\rfloor^k} \quad (7)$$

$L_m(k)$  değerleri  $k = 1,2,3, \dots, k_{max}$  için bulunur ve ardından bu değerlerin ortalaması  $\langle L(k) \rangle$  hesaplanır. Fraktal boyut  $D$  ile simgenirse  $\langle L(k) \rangle$ ,  $k^{-D}$  ile doğru orantılıdır (8).  $D$  değeri,  $\ln(1/k)$ 'ya karşılık  $\ln(L(k))$  noktalarına en iyi uyan doğrunun eğimi hesaplanarak bulunur.

$$\langle L(k) \rangle \propto k^{-D} \quad (8)$$

Çalışmada EEG kayıtlarındaki her bir kanaldan 1'er saniye örtüşmeli, 3.36 saniye genişliğinde 25 pencere çıkarılmış ve pencerelerin fraktal boyut değerleri Higuchi algoritması ile hesaplanmıştır. Pencerelerden hesaplanan fraktal boyut değerleri, her bir kanaldaki pencerelerin fraktal boyut değerlerinin ortalaması ve tüm kanalların fraktal boyut değerlerinin ortalaması birer öznitelik olarak kullanılmıştır. Bu yöntemle  $32 \times 25 + 32 + 1 = 833$  öznitelik daha elde edilmiştir.

### 3.1.3. Öznitelik Seçimi

Dalgacık dönüşümü ve fraktal boyut değerleri kullanılarak elde edilen toplam öznitelik sayısı 1505'dir. Öznitelik sayısını azaltmak ve sınıflarla çok ilişkili olan öznitelikleri belirlemek amacıyla özniteliklerin sınıflarla korelasyonları hesaplanmıştır. Daha sonra öznitelikler, yüksek korelasyonlu olanlar başta olacak şekilde sıralanmış ve ilk 250 öznitelik dışındaki öznitelikler öznitelik vektöründen çıkarılmıştır.

Seçilen öznitelikler,  $O_i$  i. öznitelik,  $O_i(j)$  bu özniteliğin j. örnekteki değeri olmak üzere, denklem (9) ile normalize edilmiştir.

$$O_i(j) = \frac{O_i(j) - \min(O_i)}{\max(O_i) - \min(O_i)} \quad (9)$$

Öznitelik seçimi ve normalizasyon, 5 parçalı çapraz doğrulama esnasında, test verilerinin eğitim aşamasında dışarıda tutulması amacıyla her adımda sınıflandırıcı model oluşturulurken kullanılan 4'er parçanın birleşimi üzerinde uygulanmıştır.

### 3.2. Sınıflandırma

Sınıflandırmalar, 5 parçalı çapraz doğrulama yöntemi ve farklı  $k$  değerleri kullanılarak en yakın  $k$  komşu algoritması ( $k$ -NN) ile yapılmıştır. Her bir özne ve duygu bileşeni için en uygun  $k$  değeri izgara-arama yöntemi kullanılarak elde edilmiştir. Farklı  $k$  değerleri için  $k$ -NN sınıflandırma performansı hesaplanmış ve en iyi sonucu veren  $k$  değeri o özne ve ona ait duygu bileşeni için seçilmiştir.

En yakın  $k$  komşu algoritması test edilen veriler ile eğitim verileri arasındaki mesafeyi dikkate alır. Eğitim kümesinde, test edilen örneğe ait en yakın  $k$  tane örnek bulunur ve en çok hangi

sınıfa ait örnek bulunmuşsa, bu sınıf test edilen örneklerin sınıfı kabul edilir. Çalışmada yakınlıklar ölçülürken öklid uzaklığı kullanılmıştır:

$$d(i, j) = \sqrt{\sum_k (x_{ik} - x_{jk})^2} \quad (10)$$

Sınıflandırma başarıları, ağırlıklandırılmış duyarlılık ve özgünlük ortalamaları ile değerlendirilmiştir.  $i$ . sınıf için doğru sınıflandırılan pozitiflerin bütün pozitiflere oranı  $TPR_i$ , doğru sınıflandırılan negatiflerin bütün negatiflere oranı  $TNR_i$  ve  $i$ . sınıfa ait örneklerin sayısı  $S_i$  olmak üzere, ağırlıklandırılmış ortalama duyarlılık ve özgünlük AOD ve AOO sırasıyla denklem (11) ve (12) ile hesaplanmıştır.

$$AOD = \frac{\sum_i (TPR_i \times S_i)}{\sum_i S_i} \quad (11)$$

$$AOO = \frac{\sum_i (TNR_i \times S_i)}{\sum_i S_i} \quad (12)$$

## 4. Sonuçlar

En yakın  $k$  komşu algoritması, en uygun  $k$  değerleri ile kullanıldığında elde edilen ortalama duyarlılık-özgünlük değerleri, değerlik, uyarılma ve baskınlık bileşenleri için sırasıyla 0.684-0.656, 0.647-0.553 ve 0.602-0.555 olmuştur.

Çizelge 2: Her bir özne ve duygu bileşeni için ağırlıklandırılmış ortalama duyarlılık ve özgünlük değerleri

Özne No	Değerlik		Uyarılma		Baskınlık	
	AOD	AOO	AOD	AOO	AOD	AOO
1	0.675	0.675	0.575	0.527	0.6	0.3683
2	0.575	0.575	0.6	0.613	0.65	0.602
3	0.7	0.713	-	-	0.7	0.633
4	0.6	0.627	0.575	0.287	-	-
5	0.625	0.667	0.675	0.625	0.675	0.547
6	0.6	0.575	0.625	0.572	0.525	0.522
7	0.625	0.695	0.575	0.572	0.525	0.462
8	0.675	0.712	0.55	0.55	0.6	0.6
9	0.7	0.64	0.7	0.7	-	-
10	0.775	0.775	0.75	0.76	0.75	0.717
11	0.725	0.755	0.625	0.46	0.675	0.658
12	0.675	0.635	-	-	0.65	0.627
13	0.75	0.663	-	-	0.5	0.5
14	0.7	0.7	0.65	0.397	0.6	0.62
15	0.8	0.797	0.8	0.633	0.725	0.675
16	0.7	0.642	0.7	0.71	0.775	0.712
17	0.575	0.588	0.725	0.703	0.6	0.653
18	0.775	0.74	0.625	0.562	-	-
19	0.775	0.775	0.575	0.568	0.55	0.52
20	0.75	0.733	0.675	0.577	-	-
21	0.625	0.618	-	-	0.4	0.422
22	0.75	0.648	0.65	0.63	0.7	0.63
23	0.6	0.638	-	-	0.775	0.595
24	0.625	0.602	0.675	0.37	0.425	0.425
25	0.675	0.523	0.7	0.53	-	-
26	0.575	0.572	0.675	0.358	0.6	0.6
27	0.8	0.843	0.7	0.683	-	-
28	0.675	0.705	0.6	0.577	0.55	0.552
29	0.725	0.755	0.65	0.687	0.5	0.513
30	0.65	0.593	0.6	0.535	0.575	0.452
31	0.7	0.700	0.65	0.623	0.6	0.6
32	0.7	0.683	0.65	0.517	-	-

En yüksek duyarlılık-özgünlük değerleri aynı sırayla 0.8-0.843

(özne 27), 0.75-0.76 (özne 10) ve 0.75-0.717 (özne 10) olarak hesaplanmıştır.

Çizelge 2’de her sınıfta en az 10 örnek bulunmadığı için veri setinden çıkartıldığı belirtilen öznelere ait sonuçlara yer verilmemiştir.

EEG verileri kaydedilirken, işlenirken izlenen yollar, kullanılan uyaranlar, öznelite çıkarma yöntemleri, sınıflandırma başarısı ölçütleri başka çalışmalarda farklılıklar gösterse de, bu çalışma sonunda elde edilen sonuçlar, benzer uyaranlarla değerlik, uyarılma ve/veya baskınlık için, çift sınıflı ve özneye bağımlı olarak yapılan sınıflandırma sonuçları ile karşılaştırılabilir. Aynı veri seti üzerinde farklı öznelitelerle yapılan çalışmada, sınıflandırma kesinlikleri değerlik ve uyarılma için 0.576 ve 0.62 olarak hesaplanmıştır [13]. Yine müzik videolarının uyaran olarak kullanıldığı bir başka çalışmada [23], ortalama sınıflandırma başarısı değerlik ve uyarılma bileşenleri için %58.8 ve %55.7 olarak bulunmuştur.

Benzer çalışmalar sınıflandırma başarılarının çok yüksek olmadığını göstermekte ve sonuçları etkileyen pek çok etkenden bahsedilebileceği için sonuçların direkt olarak kıyaslanması güçleşmektedir. Veri seti oluşturulurken öznelerden az sayıda kayıt alınmış olmasının da sınıflandırma başarılarını olumsuz etkilediği düşünülmektedir. Sınıflandırma başarılarının yüksek olmayışı, EEG verilerinin farklı verilerin de dahil edilebileceği duyu tanıma sistemleri için destekleyici olarak kullanılabilceği fikrini doğurmaktadır.

## 5. Kaynaklar

- [1] Dhall, A., Asthana, A., Goecke, R., Gedeon, T., "Emotion recognition using PHOG and LPQ features", Automatic Face & Gesture Recognition and Workshops, 2011 IEEE International Conference, pp. 878-883
- [2] Yildirim, S., Narayanan, S., Potamianos, A., "Detecting emotional state of a child in a conversational computer game", Computer Speech & Language, vol. 25. no. 1, pp. 29-44, 2011
- [3] Quazi, M. T., Mukhopadhyay, S. C., Suryadevara, N. K., Huang, Y. M., "Towards the smart sensors based human emotion recognition", Instrumentation and Measurement Technology Conference (I2MTC), 2012 IEEE International, pp. 2365-2370
- [4] Ververidis, D., & Kotropoulos, C., "Emotional speech recognition: Resources, features, and methods", Speech communication, vol. 48, no. 9, pp. 1162-1181, 2006
- [5] Murugappan, Murugappan, Nagarajan Ramachandran, and Yaacob Sazali, "Classification of human emotion from EEG using discrete wavelet transform", Journal of Biomedical Science and Engineering 3.04 (2010): 390
- [6] Uzun, S. S., Oflazoglu, C., Yildirim, S., Yildirim, E. (2012, April). "Emotion estimation from EEG signals using wavelet transform analysis", In Signal Processing and Communications Applications Conference (SIU), 2012 20th (pp. 1-4). IEEE.
- [7] Berka, C., Levendowski, D. J., Cvetinovic, M. M., Petrovic, M. M., Davis, G., Lumicao, M. N., ... & Olmstead, R., "Real-time analysis of EEG indexes of alertness, cognition, and memory acquired with a wireless EEG headset", International Journal of Human-Computer Interaction, vol. 17, no. 2, pp. 151-170, 2004
- [8] Debener, S., Minow, F., Emkes, R., Gandras, K., & Vos, M., "How about taking a low-cost, small, and wireless EEG for a walk?", Psychophysiology, vol. 49, no. 11, pp. 1617-1621, 2012
- [9] Campbell, A., Choudhury, T., Hu, S., Lu, H., Mukerjee, M. K., Rabbi, M., & Raizada, R. D., "NeuroPhone: brain-mobile phone interface using a wireless EEG headset", In Proceedings of the second ACM SIGCOMM workshop on Networking, systems, and applications on mobile handhelds, pp. 3-8, 2010
- [10] Petrantonakis, P. C., Hadjileontiadis, L. J. "Emotion recognition from EEG using higher order crossings", Information Technology in Biomedicine, IEEE Transactions on, vol. 4, no. 2, pp. 186-197, 2010
- [11] Nie, D., Wang, X. W., Shi, L. C., Lu, B. L., "EEG-based emotion recognition during watching movies", Neural Engineering (NER), 2011 5th International IEEE/EMBS Conference, 2011, pp. 667-670
- [12] Murugappan, M., Ramachandran, N., Sazali, Y., "Classification of human emotion from EEG using discrete wavelet transform", Journal of Biomedical Science and Engineering, vol. 3, no. 4, pp. 390-396, 2010
- [13] Koelstra, S., Muhl, C., Soleymani, M., Lee, J. S., Yazdani, A., Ebrahimi, T., Pun, T., Nijholt, A., Patras, I., "Deap: A database for emotion analysis; using physiological signals", Affective Computing, IEEE Transactions on, vol. 3, no. 1, pp. 18-31, 2012
- [14] J. A. Russell, "A circumplex model of affect", Journal of Personality and Social Psychology, vol. 39, no. 6, pp. 1161-1178, 1980
- [15] Daubechies, I., "The wavelet transform, time-frequency localization and signal analysis", Information Theory, IEEE Transactions on, vol. 36, no. 5, pp. 961-1005, 1990
- [16] Paramanathan, P., Uthayakumar, R. "Application of fractal theory in analysis of human electroencephalographic signals", Computers in Biology and Medicine, vol. 38, no. 3, pp. 372-378, 2008
- [17] Shannon, C. E., "A mathematical theory of communication", ACM SIGMOBILE Mobile Computing and Communications Review, vol. 5, no. 1, pp. 3-55, 2001
- [18] Coifman, R. R., Wickerhauser, M. V., "Entropy-based algorithms for best basis selection", Information Theory, IEEE Transactions, vol. 38, no. 2, pp. 713-718, 1992.
- [19] Rosso, O. A., Blanco, S., Yordanova, J., Kolev, V., Figliola, A., Schürmann, M., Başar, E., "Wavelet entropy: a new tool for analysis of short duration brain electrical signals", Journal of neuroscience methods, vol. 105, no. 11, pp. 65-75, 2001
- [20] Sourina, O., Wang, Q., Liu, Y., Nguyen, M. K. "A Real-time Fractal-based Brain State Recognition from EEG and its Applications", Biosignals, pp. 82-90, 2011
- [21] Qiang, W., Sourina, O., Khoa, N. M., "A Fractal Dimension Based Algorithm for Neurofeedback Games", Proc. CGI, 2010
- [22] Higuchi, T., "Approach to an irregular time series on the basis of the fractal theory", Physica D: Nonlinear Phenomena, vol. 31, no. 2, pp. 277-283, 1988
- [23] Koelstra, S., Yazdani, A., Soleymani, M., Mühl, C., Lee, J. S., Nijholt, A., Pun T., Ebrahimi, T., Patras, I., "Single trial classification of EEG and peripheral physiological signals for recognition of emotions induced by music videos", In Brain Informatics, Springer Berlin Heidelberg, pp. 89-100, 2010