



EEG İşaretlerinin k-NN ile Sınıflandırmasında Dalgacıklara İlişkin Performansların Karşılaştırılması

The Comparison of the Performances Related to Wavelets in Classifying EEG Signals with k-NN

Ömer TÜRK¹, Mehmet Sıraç ÖZERDEM²

¹ Midyat Meslek Yüksekokulu, Mardin Artuklu Üniversitesi
omerturk@artuklu.edu.tr

² Mühendislik Fakültesi, Dicle Üniversitesi
sozerdem@dicle.edu.tr

Özetçe

Elektroensefalogram (EEG) işareti, beyindeki elektriksel aktivite hakkında bilgi edinmek ve epileptik aktivitelerin tespitinde yaygın olarak kullanılmaktadır. Bu çalışmada sağlıklı ve epileptik hastalığa sahip WAG/Rij türündeki farelerin EEG kayıtları sınıflandırılmaya çalışılmıştır. Çalışmada Ayrık Dalgacık Dönüşümü kullanılarak her bir EEG veri seti 5. seviyeye kadar ayrıştırılmış, ayrıştırma sonucu elde edilen yaklaşım katsayılarının istatistiksel özellikleri alınarak K En Yakın Komşu (k-NN) yöntemi ile sınıflandırılmıştır. Haar, sym6 ve db2 dalgacıkları kullanılarak yapılan 5. seviye ayrıştırma sonucu elde edilen özellikler k-NN ile sınıflandırılmış ve dalgacıkların sınıflandırma performansları karşılaştırılmıştır. Ayrıca bu üç sınıflandırma için karışıklık matrisi kullanılarak model başarımları ölçümlenmiştir. Her üç dalgacık için elde edilen başarımların en az %81.25 olduğu saptanmıştır.

Abstract

Elektroensefalogram (EEG) sign is widely used to get information about electrical activity in the brain and to detect epileptic activities. In this study, the EEG records of WAG/Rij species rats having normal and epileptic disease were classified. The records has been decomposed until the 5th level through Discreet Wavelet Transform and the statistical features of the results of the decomposition were obtained and the finally the statistical features were classified with k-Nearest Neighbor (k-NN) method. The features obtained by the 5th level decomposition by using Haar, sym6 and db2 has been classified through k-NN and classification performances of wavelets have been compared. The confusion matrix was used for determining the performance of classifications of wavelets. The performance of classification having at least 81.2% was determined for the wavelets.

1. Giriş

EEG, beynin elektriksel aktiviteğini içeren işaretlerdir. Farklı canlılardan EEG kayıtları alınarak AR-GE çalışmaları yapılabilmektedir. Bu işaretler beyindeki epileptik aktiviteğin tespitinde de yaygın olarak kullanılmaktadır. Spektral analiz EEG işaretlerinin karakteristiğini frekans düzlemlerinde incelemek amacıyla kullanılan etkin yöntemlerin başında gelir [1]. Epileptik nöbet tespiti ve sınıflandırılmasında Dalgacık Dönüşümü (DD) ideal bir bant geçiren filtre gibi kullanılmaktadır [2-3]. DD sonucu

elde edilen katsayılar ve/veya katsayılardan elde edilen istatistiksel öznitelikler kullanılarak, EEG işaretleri farklı sınıflandırıcılar ile ayrıştırılabilmektedir.

Literatürde EEG işaretlerinin sınıflandırılmasında; EEG sinyallerinden epilepsi teşhisi için entropi özelliği kullanımı [4], hızlı Fourier dönüşümü ve karar ağaçları sınıflandırmasına bağlı hibrit sistem kullanımı [5], dalgacık özellik çıkarma tabanlı uzman model kullanımı [6], K-Means kümeleme ve çok katmanlı yapay sinir ağı kullanımı [7], çapraz korelasyon ve destek vektör makinesi (DVM) kullanımı [8-9] ile birlikte çok aşamalı yaklaşım, boyut indirgeme algoritmaları, çoklu denetimsiz kümeleme algoritmaları ve çeşitli denetimli sınıflandırma algoritmaları gibi sınıflandırıcılarının kullanıldığı gözlenmektedir. Bu çalışmada da literatürde görülen benzer bir uygulama gerçekleştirilmiştir. Çalışmada, k-NN algoritması kullanılarak farelerin EEG işaretlerine ilişkin öznitelikler sınıflandırılmış ve sınıflandırma performansı üzerinde farklı dalgacık ailelerinin etkisi de incelenmiştir.

2. Veri Seti

Çalışmada, WAG/Rij türü erkek farelere ilişkin sağ ve sol frontal korteks'ten (iki kanallı) alınan 5 saniyelik EEG kayıtları kullanılmıştır [10]. Veri setleri 1-100 Hz filtrelenmiş ve 200 Hz 'de sayısallaştırılmıştır. A, B, C, D ve E olarak adlandırılan veri setlerinin her biri 2 kayıttan oluşmakta olup, toplam 10x1000 EEG kaydı bu çalışmada kullanılmıştır. A normal EEG işareti ifade eder. B, C, D ve E ise farklı nitelikte epileptik belirtisini içeren EEG işaretlerdir. Bu belirti Diken Dalga Aktivitesi/Deşarjı (Spike discharge) epileptik bir belirtidir. Doğru ölçüm yapıldığı zaman sara hastalığının belirtisini içermektedir. A,B,C,D ve E kayıtları için örnek işaretler Şekil 1'de verilmiştir.

3. Tasarlanan Sınıflandırma Sistemi

Sınıflandırma işlemlerinin yapılabilmesi için izlenen işlem akışı aşağıda verilmiştir.

EEG → ADD → Öznitelik çıkartımı → k-NN sınıflandırma

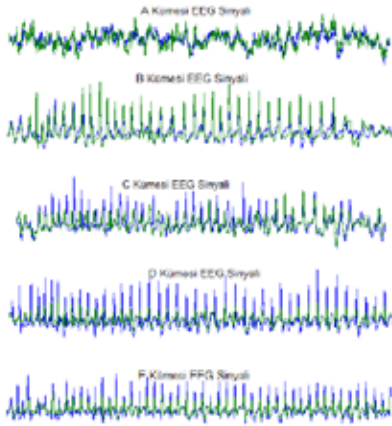
EEG kayıtları iki sınıfa ayrıştırılmıştır. Örneğin, A sağlıklı işaret bir sınıf olup, sağlıklı diğer işaretler (BCDE) ise ikinci sınıfa atanmaya çalışılmıştır. Sağlıksız olan örneklerin ayrıştırılabilir

Tıbbi Tanı ve Tedavi Sistemlerinde Sinyal İşleme Uygulamaları

2. Gün 26 Eylül 2014 Cuma (14.45-16.15)

olduklarını görmek amacıyla yapılan diğer çalışmalar B-CDE, C-BDE, D-BCE ve E-BCD' dir.

Akıшта yer alan işlemlerin detayları sonraki bölümlerde anlatılmıştır.



Şekil 1: Örnek EEG kayıtları

3.1 Dalgacık Dönüşümü

Fourier analizi, sabit veri kümeleri için çok uygun olmasına rağmen, farklı frekans düzeyindeki sinyalleri yeniden oluşturmada başarısız olur. Dalgacık dönüşümü incelenen sinyalin frekans içeriğinin zamanla değişimini incelemek için en etkin metotlardan biridir. Bu değişimler dalgacık fonksiyonu ile birlikte farklı ölçek (scale) ve kaydırma (shift) değerleri kullanılarak hesaplanır [1]. Dalgacık dönüşümünde en iyi çözünürlüğü sağlamak amacıyla, yüksek frekanslar için küçük; düşük frekanslar için de büyük boyutlu ölçek kullanılır. Böylece incelenen işaret değişik ölçeklerde analiz edilmektedir. Sürekli Dalgacık dönüşümü (SDD) ayrıştırma işlemi:

$$DD(a, u) = \frac{1}{\sqrt{|a|}} \int_{-\infty}^{+\infty} x(t) \psi\left(\frac{t-u}{a}\right) dt \quad (1)$$

Burada $x(t)$ sinyali, $DD(a, u)$ dalgacık dönüşümü, ψ ana dalgacık fonksiyonu, a ölçek ve u kaydırma parametresini ifade eder.

SDD önemli bilgiler üretir, ancak çok fazla hesaplama ve çevirmeden dolayı karmaşık hesaplamalara neden olmaktadır [1]. SDD Fonksiyonunun temel özelliklerini temsil eden bazı örnekler seçilirse, ayrık dalgacık dönüşümü elde edilmiş olur. Sürekli dalgacık formülünde ölçek ve kaydırma parametreleri sırasıyla $a = 2^m$ ve $u = n \cdot 2^m = n \cdot a$ olarak alınır ve elde edilen Ayrık Dalgacık dönüşüm (ADD) bağıntısı:

$$D(j, k) = \sum_j \sum_k x(n) 2^{-m/2} \psi(2^{-m} n - k) \quad (2)$$


İşareti farklı frekans aralıklarına ayrıştırmak, işaretin ard arda yüksek ve alçak geçiren filtrelerden geçirilmesi ile sağlanır. İşaret $x(t)$, önce yarım bantlı yüksek geçiren $g(k)$ filtresinden ve ardından alçak geçiren $h(k)$ filtresinden geçirilir.

Bu işlemde kullanılan filtrelerin matematiksel ifadeleri (3) ve (4) eşitliklerinde verilmiştir.

$$g(k) = \sum_n x(t) g(2k - t) \quad (3)$$

$$h(k) = \sum_n x(t) h(2k - t) \quad (4)$$

ADD ile işaret alçak ve yüksek frekans bileşenlerine ayrıştırılır. Bu bileşenler yaklaşım (approximation) ve detay (detail) bileşenleri olarak adlandırılır. Burada yaklaşım bileşeni yüksek ölçek değerlerine sahip olmakla beraber işaretin alçak frekans değerlerini temsil eder. Detay bileşenleri ise düşük ölçek değerlerine sahip işaretin yüksek frekans değerlerini temsil eder [4].



Şekil 2: ADD ile $x[n]$ işaretinin alt bantlara ayrıştırılması

3.2 K En Yakın Komşu (k-NN) Algoritması

Örüntü tanımda, özel uzayda en yakın eğitim örneklerine dayalı nesnelere sınıflandırmak için k-NN algoritması kullanılan bir yöntemdir. Bu yöntemde, sınıflandırma yapılacak verilerin örnek kümesindeki normal veri kümelerine yakınlıkları hesaplanarak; en yakın olduğu düşünülen k tane veride bulunan en fazla sınıfa göre sınıflandırma yapılır. Burada esas olan sınıflandırma yapılmadan önce, her bir sınıfın özelliklerinin önceden net bir şekilde belirtilmiş olmasıdır [11].

Bu sınıflandırmada ilk olarak, bir test seti elemanından her bir örnek seti elemanına olan mesafe ölçülür. Önceden belirtilmeyen bir öznitelik vektörü kendisine en yakın k komşularının çoğunluğunun sahip olduğu etiket ile etiketlenir.

Kısaca K-NN olarak ifade edilen K-Nearest Neighbor (K-En Yakın Komşu) sınıflandırma algoritmasının temelinde "birbirine yakın olan nesnelere muhtemelen aynı kategoriye aittir" mantığı yatar [12]. K-NN sınıflandırma algoritmasının işlem basamakları şu şekilde özetlenebilir:

1. Adım: Sınıfı saptanmak istenen test örneğinin, eğitim örneklerine olan uzaklıkları hesaplanır.
2. Adım: En yakın olan k tane örnek seçilir.
3. Adım: k tane örneğin çoğunluğu hangi sınıfa girer ise test örneği çoğunluk sınıfına atanır.

3.3 Özelliklerin Elde Edilmesi

İstatistiksel yöntemler dalgacık katsayılarının özelliklerini elde etmek için kullanılmaktadır [1]. Dalgacık Dönüşümü uygulamalarında spektral bant ayrıştırması için uygun bir ayrıştırma seviyesinin kullanılması çok önemlidir. Bu çalışmada EEG sinyallerinin analizi ve özellik çıkarımı için 5. Seviye ADD kullanılımasının uygunluğu deneme yanılma yoluyla tespit edilmiştir. Uygulamalarda elde edilen A5 dalgacık yaklaşım katsayısı kullanılmıştır. Elde edilen yaklaşım katsayılarının varyans, ortalama, standart sapma, maksimum, mod, minimum, enerji ve Shannon entropi değerleri hesaplanarak her EEG kaydın öznitelik vektörü oluşturulmuştur.

4. Sınıflandırma Sonuçları

Bu çalışmada dalgacık ailelerinin sınıflandırma üzerindeki etkilerini karşılaştırmak için haar, db2 ve sym6 dalgacıkları kullanılarak her bir veri seti için 5. Seviye ayrıştırma yapılmıştır. Bu ayrıştırma sonucu her bir veri setinden elde edilen yaklaşım katsayıları için ayrı ayrı olmak üzere her bir sinyalden 8 özellik çıkarılmıştır. Çıkarılan bu özelliklerle her bir sinyalin öznitelik



Tıbbi Tanı ve Tedavi Sistemlerinde Sinyal İşleme Uygulamaları

2. Gün 26 Eylül 2014 Cuma (14.45-16.15)

vektörü oluşturulmuştur. Haar, db2 ve sym6 için elde edilen istatistiksel değerler sırasıyla Tablo 1, Tablo 2 ve Tablo 3'de verilmiştir.

Tablo 1: Haar Dalgacığı ile Elde Edilen Özellik İstatistikleri

Veri Seti	Varyans	Ort.	Std Sp.	max	mode	min	Enerji	Entropi
A _{L(AS)}	0.355	0.090	0.596	0.870	-1.276	-1.276	32.496	4.642
A _{R(AS)}	0.462	0.093	0.680	1.754	-1.061	-1.061	31.058	1.279
B _{L(AS)}	0.773	0.114	0.879	2.044	-1.554	-1.554	6.610	-4.961
B _{R(AS)}	1.199	0.156	1.095	2.290	-2.204	-2.204	5.400	-17.150
C _{L(AS)}	1.146	0.112	1.070	1.321	-3.397	-3.397	14.330	-55.041
C _{R(AS)}	0.672	0.088	0.819	1.401	-1.963	-1.963	13.385	-50.097
D _{L(AS)}	0.442	0.040	0.665	1.501	-1.134	-1.134	2.244	-0.806
D _{R(AS)}	0.240	0.018	0.490	1.324	-0.993	-0.993	4.831	0.633
E _{L(AS)}	0.248	0.068	0.498	0.914	-1.230	-1.230	2.341	2.894
E _{R(AS)}	0.156	0.002	0.396	0.851	-0.881	-0.881	4.468	5.888

Tablo 2: Db2 Dalgacığı İle Elde Edilen Özellik İstatistikleri

Veri Seti	Varyans	Ort.	Std sp.	max	mode	min	Enerji	Entropi
A _{L(AS)}	0.363	0.072	0.602	1.073	-1.425	-1.425	33.885	3.752
A _{R(AS)}	0.423	0.087	0.650	1.795	-1.223	-1.223	29.826	3.291
B _{L(AS)}	0.809	0.193	0.899	1.739	-2.236	-2.236	7.489	-2.310
B _{R(AS)}	0.871	0.261	0.933	1.345	-2.360	-2.360	4.369	-1.784
C _{L(AS)}	0.707	0.002	0.841	1.540	-1.861	-1.861	9.214	-29.524
C _{R(AS)}	0.490	0.036	0.700	1.207	-1.635	-1.635	10.013	-33.284
D _{L(AS)}	0.490	0.006	0.700	1.579	-1.026	-1.026	2.615	-1.811
D _{R(AS)}	0.329	0.074	0.574	1.227	-1.071	-1.071	7.035	0.577
E _{L(AS)}	1.174	0.138	1.083	3.573	-3.370	-3.370	10.389	-29.633
E _{R(AS)}	0.609	0.062	0.780	2.808	-2.299	-2.299	15.751	-43.674

Tablo 3: Sym6 Dalgacığı İle Elde Edilen Özellik İstatistikleri

Veri Seti	Varyans	Ort.	Std sp.	max	mode	min	Enerji	Entropi
A _{L(AS)}	0.313	0.019	0.559	1.229	-1.139	-1.139	34.977	3.674
A _{R(AS)}	0.317	0.096	0.563	2.013	0.770	0.770	27.187	1.8449
B _{L(AS)}	0.585	0.291	0.764	1.296	-2.085	-2.085	7.061	0.998
B _{R(AS)}	1.070	0.520	1.034	1.411	-2.231	-2.231	7.311	0.944
C _{L(AS)}	1.445	0.313	1.202	1.379	-3.068	-3.068	21.035	-92.447
C _{R(AS)}	0.570	0.050	0.755	1.232	-1.878	-1.878	13.530	-50.851
D _{L(AS)}	0.638	0.176	0.799	2.037	-1.024	-1.024	4.242	-18.720
D _{R(AS)}	0.447	0.285	0.669	1.671	-0.749	-0.749	12.480	-25.212
E _{L(AS)}	0.863	0.259	0.929	0.894	-2.884	-2.884	9.754	3.986
E _{R(AS)}	0.520	0.017	0.721	1.413	-1.618	-1.618	15.625	3.255

Bu öznelik vektörler Tablo 4'de gösterildiği şekilde k-NN kullanılarak 2 sınıfa ayrıştırılmıştır.

Tablo 4 : Sınıflara Ayrıştırma

Sınıf 1	Sınıf 2	Açıklama
A	BCDE	Sağlıklı ile hasta verilerinin ayrıştırılması
B	CDE	B hastalık türünün diğer türlere göre farklılığı
C	BDE	C hastalık türünün diğer türlere göre farklılığı
D	BCE	D hastalık türünün diğer türlere göre farklılığı
E	BCD	E hastalık türünün diğer türlere göre farklılığı

Tüm dalgacıklar için k-NN sınıflandırılmasında k=1 olarak seçilmiştir. Bire-çok (one-to-many) veri sınıflandırılmasında 10 çapraz doğrulama (cross-validation) yapılmıştır. Veritabanı rastgele (random) olarak seçilmiştir. Oluşturulan veritabanının 3/4 eğitim için 1/4 'ü de test için kullanılmıştır. Bu işlemler sonucu elde edilen sonuçlar Tablo 5' te listelenmiştir.

Tablo 5: Dalgacıkların Sınıflandırma Performansları

Haar Dalgacığı ile k-NN sınıflandırmada kullanılan		
S.No	Veri setleri	Performans(%)
1	A-BCDE	100
2	B-CDE	87.50
3	C-BDE	87.50
4	D-BCE	81.25
5	E-BCD	87.50
Db2 Dalgacığı ile k-NN sınıflandırmada kullanılan		
S.No	Veri Setleri	Performans(%)
1	A-BCDE	100
2	B-CDE	91.66
3	C-BDE	83.33
4	D-BCE	91.66
5	E-BCD	83.33
Sym6 Dalgacığı İle k-NN sınıflandırmada kullanılan		
S.No	Veri setleri	Performans(%)
1	A-BCDE	100
2	B-CDE	87.50
3	C-BDE	81.25
4	D-BCE	87.50
5	E-BCD	87.50

5. Model Başarım Ölçütleri

Model başarımı, doğru sınıfa atanan örnek sayısı ve yanlış sınıfa atılan örnek sayısı nicelikleriyle alakalıdır. Bu çalışmada model başarımı değerlendirmesi için doğruluk, kesinlik ve duyarlılık ölçüleri hesaplanmıştır. Hesaplama için kullanılan değerler Tablo 6 da verilmiştir.

Tablo 6: Karışıklık matrisi

Gerçek Sınıf	Tahmin Edilen Sınıf	
	Sınıf=1	Sınıf=0
Sınıf=1	TP	FN
Sınıf=0	FP	TN



Tıbbi Tanı ve Tedavi Sistemlerinde Sinyal İşleme Uygulamaları

2. Gün 26 Eylül 2014 Cuma (14.45-16.15)

Burada TP (True Positive), FP (False Positive), FN (False Negative), ve TN (True Negatif) sonuç sayılarını ifade etmektedir. Doğruluk, kesinlik ve duyarlılık ölçütleri aşağıdaki gibi hesaplanmaktadır:

$$\text{Doğruluk} = \frac{TP+TN}{TP+FP+FN+TN} \quad (5)$$

$$\text{Kesinlik} = \frac{TP}{TP+FP} \quad (6)$$

$$\text{Duyarlılık} = \frac{TP}{TP+FN} \quad (7)$$

Bu çalışmada her üç dalgacıyla yapılan sınıflandırma, model başarımları ölçümüyle elde edilen sonuçlar Tablo 7' de verilmiştir.

Tablo 7: Dalgacıların Model Başarımları Ölçümleri

Haar Dalgacı Model Başarımları Ölçümü			
S.No	Doğruluk	Kesinlik	Duyarlılık
1	100	100	100
2	87.50	100	83.33
3	87.50	100	83.33
4	91.66	100	88.88
5	87.50	85.71	100
Db2 Dalgacı Model Başarımları Ölçümü			
S.No	Doğruluk	Kesinlik	Duyarlılık
1	100	100	100
2	87.50	100	83.33
3	87.50	85.71	100
4	87.50	100	83.33
5	87.50	85.71	100
Sym6 Dalgacı Model Başarımları Ölçümü			
S.No	Doğruluk	Kesinlik	Duyarlılık
1	100	100	100
2	87.50	85.71	100
3	91.66	90.00	100
4	83.33	100	77.77
5	95.83	94.73	100

6. Sonuçlar

Bu çalışmada farelerin EEG kayıtları dikkate alınarak, farelere ilişkin sağlıklı ve epileptik EEG kayıtların ayrıştırılması amaçlanmıştır. Ayrıştırılma sürecinde farklı dalgacılar kullanılarak, performansın üzerindeki etkileri gözlemlenmiştir.

Bu çalışmada 5 ayrı EEG veri seti kullanılmıştır (A, B, C, D, E). Bu veri setleri için haar, db2 ve sym6 dalgacıları kullanılarak 5. seviye ayrıştırılması yapılmıştır. Ayrıştırma sonucu oluşan A5 yaklaşım katsayılarından 8 ayrı istatistiksel (varyans, ortalama, standart sapma, maksimum, mod, minimum, enerji ve Shannon entropi) özellik çıkarılmıştır. Bu öznelik vektörleri kullanılarak veri setleri k-NN algoritması ile sınıflandırılmıştır. Her üç dalgacı için elde edilen sınıflandırma sonuçlarının karışıklık matrisi kullanılarak model başarımları ölçümü hesaplanmıştır.

Sağlıklı EEG verilerinin hastalıklı olanlar ile ayrıştırılabilir olmasının yanında hastalık türlerinin bile kendi içinde yüksek oranda ayrıştırılabildiği saptanmıştır.

Elde edilen sonuçlara göre, haar, db2 ve sym6 dalgacılarının yüksek performans gösterdikleri görülmektedir. Birbirlerine göre çok fazla bir üstünlüklerinin olmadığı görülmüştür. Performansın yüksek olmasının önemli bir sebebi öznelik vektörünün doğru

seçimidir. Çalışmada kullanılan istatistiksel değerlerin doğru seçimler olduğu performanslardan anlaşılmaktadır.

7. Kaynakça

- [1] Falamarzi Y., Palizdan N., Huangb Y. F. & Lee, T.S. , “Estimating evapotranspiration from temperature and wind speed data using artificial and wavelet neural networks (WNNs)”, *Agricultural Water Management*, 140, 26–36, 2014.
- [2] Subasi A., “Epileptic seizure detection using dynamic wavelet network”, *Expert Systems with Applications*, vol.29, pp.343–355, 2005.
- [3] Adeli H., Ghosh-Dastidar S., and Dadmehr N., “A wavelet-chaos methodology for analysis of EEGs and EEG subbands to detect seizure and epilepsy”, *IEEE Trans. Biomed. Eng.*, vol. 54, pp. 205–211, 2007.
- [4] Kannathal, N., Choo, M. L., Acharya, U. R., & Sadasivan, “Entropies for detection of epilepsy in EEG”, *Journal of Medical Systems*, 80(3), 187–194., 2005.
- [5] Polat, K., & Gunes, S. “Classification of epileptiform EEG using a hybrid system based on decision tree classifier and fast Fourier transform”, *Applied Mathematics and Computation*, 187(2), 1017–1026., 2007.
- [6] Subaşı, A. “EEG signal classification using wavelet feature extraction and a mixture of expert model”, *Expert System with Applications*, 32(4), 1084–1093. 2007.
- [7] Orhan, U., Hekim, M., & Ozer, M., “EEG signals classification using k-means clustering and a multilayer perceptron neural network model”, *Expert Systems with Applications*, 38, 13475–13481, 2011.
- [8] Chandaka, S., Chatterjee, A., & Munshi, S., “Cross-correlation aided support vector machine classifier for classification of EEG signals”, *Expert System with Applications*, 36(2), 1329–1336. 2009.
- [9] Arnaud B., Tarik, A., ve Xavier D., “Phase space and powerspectral approaches for EEG-based automatic sleep-wake classification in humans: a comparative study using short and standard epoch lengths, Comput”, *Methods Programs Biomed.* 109 227–238. 2013.
- [10] The EEG signals can be downloaded from <http://www.vis.caltech.edu/~rodri/>
- [11] Lee, S., Kang, P., Cho S., “Probabilistic local reconstruction for k-NN regression and its application to virtual metrology in semi conductor manufacturing”, *Neurocomputing*-131, 427–439, 2014
- [12] Eren Ö., “Alerjen proteinlerin otomatik olarak sınıflandırılması”, *Başkent üniversitesi Fen Bilimleri Enstitüsü Y.Lisans Tezi*, 2008.