T.C.
DİCLE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

YUKARI – AŞAĞI İMLEÇ HAREKETİNE İLİŞKİN EEG KAYITLARININ AYRIK DALGACIK, KNN VE DVM İLE SINIFLANDIRILMASI

ÖMER EMHAN

YÜKSEK LİSANS TEZİ

ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ
ANABİLİM DALI

DİYARBAKIR

Nisan 2017

T.C.

DİCLE ÜNİVERSİTESİ

FEN BİLİMLERİ ENSTİTÜSÜ MÜDÜRLÜĞÜ

DİYARBAKIR

Ömer EMHAN tarafından yapılan "Yukarı – Aşağı İmleç Hareketine İlişkin EEG Kayıtlarının Ayrık Dalgacık, kNN ve DVM ile Sınıflandırılması" konulu çalışma jürimiz tarafından Elektrik-Elektronik Mühendisliği Anabilim Dalında YÜKSEK LİSANS tezi olarak kabul edilmiştir.

Jüri Üyeleri

Başkan : Doç. Dr. Mehmet Siraç ÖZERDEM

Üye : Prof. Dr. Mehmet AKIN

Üye : Yrd. Doç. Dr. Ömer Faruk ERTUĞRUL

Tez savunma sınavı tarihi: 05.04.2017

Yukarıdaki bilgilerin doğruluğunu onaylarım.

..../..../2017

Doç. Dr. Sevtap SÜMER EKER

ENSTİTÜ MÜDÜRÜ

TEŞEKKÜR

Bu tez çalışmasının başlangıcından sonuna kadar kusursuz şekilde rehberlik eden, durakladığım zamanlarda bile tetikleyip arkadan iten, engellerle karşılaştığımda gerekli desteği sağlayarak engelleri aşmamı sağlayan Doç. Dr. Mehmet Siraç ÖZERDEM hocama ve fikirlerinden ötürü Arş. Gör. Hasan POLAT'a teşekkür ederim.

Öğrenim hayatım boyunca benden desteğini esirgemeyen Anneme ve Babama sonsuz teşekkürlerimi sunar kendilerine hayırlı ömürler dilerim.

İÇİNDEKİLER

Sayfa

TEŞEKKÜR I

İÇİNDEKİLER II

ÖZET IV

ABSTRACT V

TABLO LİSTESİ VI

ŞEKİL LİSTESİ VII

KISALTMA VE SİMGELER IX

1. GİRİŞ 1

1.1. Elektroensefalogram 1

1.2. Beyin Bilgisayar Arayüzü & EEG İlişkisi ve BBA'nın Temel Bileşenleri 6

2. KAYNAK ÖZETLERİ 9

3. MATERYAL VE METOT 17

3.1. Veri Seti 17

3.2. Dalgacık Dönüşümü 19

3.2.1. Fourier Dönüşümü ve Kısa Zamanlı Fourier Dönüşümü 19

3.2.2. Dalgacık Modeli 21

3.2.3. Sürekli Dalgacık Dönüşümü 25

3.2.4. Ayrık Dalgacık Dönüşümü 28

3.3. k-En Yakın Komşuluk Algoritması 30

3.3.1. k-NN Algoritmasının Eğitim-Test Aşamaları 31

3.4. Destek Vektör Makinaları Algoritması 34

3.4.1 DVM'de Çekidek Fonksiyonu 35

3.4.2. Yapısal Risk Minimizasyonu 36

3.4.3. Doğrusal Destek Vektör Makinaları 36

3.4.4. Doğrusal Olmayan DVM 38

3.4.5. Çok Sınıflı DVM 39

4. İMLEÇ HAREKETLERİNİN SINIFLANDIRILMASI İÇİN ÖNERİLEN YÖNTEM 41

4.1. k-NN ile Kanal Seçimi 41

4.2. Ön İşlem 43

4.3. Özniteliklerin Elde Edilmesi 44

4.3.1. Yaklaşım Katsayılarından Üretilen Öznitelikler 44

4.3.2. Alt Bantlardan Yeniden Oluşturulan İşaretlerden Üretilen Öznitelikler 48

4.3.3. Hibrid Yaklaşım (Dalgacık Katsayılarından ve Yeniden Oluşturulan İşaretlerden Üretilen Özniteliklerin Birlikte Kullanılması) 52

5. ARAŞTIRMA BULGULARI 53

6. SONUÇLAR VE TARTIŞMA 57

7. KAYNAKLAR 61

EKLER 64

ÖZGEÇMİŞ 83

ÖZET

YUKARI – AŞAĞI İMLEÇ HAREKETİNE İLİŞKİN EEG KAYITLARININ DALGACIK, KNN VE SVM TABANLI SINIFLANDIRILMASI

YÜKSEK LİSANS TEZİ

Ömer EMHAN

DİCLE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI
2017

Bu çalışmada, Yukarı-Aşağı imleç hareketlerine ilişkin Elektroensefalogram (EEG) verilerinin sınıflandırılması amaçlanmıştır. 2003 yılındaki BCI Competition II yarışmasında sunulan Data set Ia veri kümesi kullanılmıştır.

Çalışmada öncelikle en etkin kanal belirlenmiştir. En etkin kanal belirleme sürecinde, işaret bütün olarak alınmış ve Ayrık Dalgacık Dönüşümü (ADD) ile farklı (3., 4., 5. ve 6.) seviyeler için dalgacık katsayıları elde edilmiştir. Her seviyenin ayrı ayrı istatistiksel parametreleri (toplam, varyans, enerji, entropi, maksimum, minimum, ortalama ve standart sapma) hesaplanmıştır. Her parametre ayrı ayrı k-En Yakın Komşu (k-NN) ile sınıflandırılmıştır. En iyi başarımın 3. seviyede toplam ve ortalama parametreleri ile elde edildiği görülmüştür. Buna göre en etkin kanalın A1 olduğu belirlenmiştir.

İkinci aşamada belirlenen kanal üzerinden, yukarı-aşağı imleç hareketine ilişkin öznitelik çıkarma ve sınıflandırma işlemi yapılmıştır. EEG işaretlerinden üç farklı yaklaşım uygulanarak öznitelikler elde edilmiştir. Bu yaklaşımlar aşağıda özetlenmiştir.

Birinci yaklaşımda, farklı (3., 4., 5. ve 6.) seviyeler için yaklaşım katsayıları elde edilmiştir. Her seviyenin ayrı ayrı ortalama değer ve maksimum mutlak değerleri hesaplanmış ve bu değerler bir vektörde birleştirilerek öznitelik vektörü olarak kullanılmıştır. Bu vektörler k-NN ve Destek Vektör Makinaları (DVM) ile sınıflandırılmıştır. Bu sınıflandırma işlemi, farklı zaman aralıkları için denenmiş ve en yüksek başarımın DVM ile elde edildiği görülmüştür.

İkinci yaklaşımda, alt bantlardan yeniden oluşturulan yukarı imleç hareketi (YİH) ve aşağı imleç hareketi (AİH) işaretlerinin eğim bilgisinin (1-400 örnek aralığı) öznitelik olarak kullanılabileceği görülmüştür. Bu eğim en iyi 8. seviyede gözlemlenmiştir. Yeniden oluşturulan işaret 3 eşit bölüte ayrılmıştır. Bu bölütlerden; *max(Bölüt1)/max(Bölüt2)* ve *max(Bölüt2)/max(Bölüt3)* değerleri birleştirilerek öznitelik olarak kullanılmıştır. Bu vektörler k-NN ve DVM ile sınıflandırılmıştır. Bu sınıflandırma işlemi, farklı örnek aralıkları için denenmiş ve en yüksek başarımın DVM ile elde edildiği görülmüştür.

Üçüncü yaklaşımda, yukarıda sözü edilen birinci ve ikinci öznitelikler birleştirilerek (Hibrid yaklaşım) nihai öznitelik vektörleri olarak kullanılmıştır. Elde edilen nihai öznitelik vektörleri k-NN ve DVM ile sınıflandırılmıştır. Bu sınıflandırma işlemi, farklı örnek aralıkları için denenmiş ve en yüksek başarımın DVM ile elde edildiği görülmüştür.

Ayrıca Hibrid yaklaşımda tüm örnek aralıkları çalışılmış ve başarımın nasıl değiştiği araştırılmıştır. Tüm örnek aralığının k-NN ile analizi yapıldığında, en yüksek başarımın %93.52 ile 2. saniyede elde edildiği görülmüştür. Tüm örnek aralığının DVM ile analizi yapıldığında ise, en yüksek başarımın %94.88 ile 1.55. saniyede elde edildiği görülmüştür.

Anahtar Kelimeler: EEG, İmleç Hareketi, Dalgacık Dönüşümü, Destek Vektör Makinaları, k-En Yakın Komşu, Sınıflandırma,

ABSTRACT

CLASSIFICATION OF UP-DOWN CURSOR MOVEMENTS' EEG RECORDS WITH DISCRETE WAVELET TRANSFORM, KNN AND SVM METHODS

MSc THESIS

Ömer EMHAN

DEPARTMENT OF ELECTRICAL ELECTRONICS ENGINEERING
INSTITUTE OF NATURAL AND APPLIED SCIENCES
UNIVERSITY OF DICLE
2017

In this study, it is aimed to classify Electroencephalogram (EEG) data related to Up-Down cursor movements. Data set Ia presented in the 2003 BCI Competition II was used.

Firstly the most effective channel was determined. In the most efficient channel estimation process, the signal was taken as a whole and the wavelet coefficients for the different (3rd, 4th, 5th and 6th) levels were obtained by Discrete Wavelet Transform (DWT). Statistical parameters (summation, variance, energy, entropy, maximum, minimum, mean and standard deviation) were calculated for each level separately. Each parameter related to the different levels is classified by k-Nearest Neighbor (k-NN), separately. It has been seen that the best performance is obtained with summation and average parameters at level 3. Accordingly, it has been determined that the most efficient channel is A1.

In the second step, feature extraction and classification related to up-down cursor movement were performed over the channel specified. Features were extracted from EEG signals by applying three different approaches. These approaches were summarized below.

In the first approach, approximate coefficients for the different (3rd, 4th, 5th and 6th) levels were obtained. The average value and maximum absolute value of each level were calculated separately, and these values are combined into one vector and used as the feature vector. These feature vectors were classified by k-NN and Support Vector Machines (SVM). This classification process has been tried for different time intervals and the highest performance was obtained with SVM.

In the second approach, it is seen that the slope information (1-400 sample interval) of the reconstructed up cursor movement (UCM) and down cursor movement (DCM) can be used as a feature. This slope is best observed at level 8. The reconstructed signal was divided into 3 equal parts. From these segments; *max(Segment1) / max(Segment2)* and *max(Segment2) / max(Segment3)* have been combined and used as feature vectors. These vectors were classified by k-NN and SVM. This classification process has been tried for different sample intervals and the highest performance was obtained by SVM. In the third approach, the above-mentioned first and second features were combined (Hybrid approach) and used as the final feature vectors. These final feature vectors obtained were classified by using k-NN and SVM. This classification process has been tried for different sample intervals and the highest performance is obtained with SVM.

In addition, all sample intervals were studied in the hybrid approach and it was investigated that how the performance was changed. When the all sample interval was analyzed with k-NN, it was seen that the highest performance was achieved at 93.52% at 2 seconds. When the all sample interval is analyzed with SVM, it was seen that the highest performance was achieved at 94.88% at 1.55 seconds.

Keywords: EEG, Cursor Movements, Wavelet Transform, Support Vector Machine, k-Nearest Neighbor, Classifications

TABLO LİSTESİ

Tablo No		Sayfa
Tablo 2.1.	BCI 2003 yarışmasında Dataset Ia veri seti için elde edilen performansların özetleri	**12**
Tablo 3.1.	EEG kanal numaraları ve etiketleri	**17**
Tablo 4.1.	Dalgacık katsayılarının seviyelerine göre bulundukları frekans aralıkları	**45**
Tablo 5.1.	Yaklaşım Katsayılarından üretilen öznitelik vektörlerinin sınıflandırılması ile elde edilen başarımlar	**53**
Tablo 5.2.	Yeniden oluşturulmuş İşaretlerden üretilen öznitelik vektörlerinin sınıflandırılması ile elde edilen başarımlar	**54**
Tablo 5.3.	Hibrid yaklaşım ile elde edilen başarımlar	**54**

ŞEKİL LİSTESİ

Şekil No		Sayfa
Şekil 1.1	EEG işareti alt frekans bantları	**3**
Şekil 1.2	Örnek bir EEG ölçüm sistemi	**4**
Şekil 1.3	Uluslararası 10-20 sistemine göre elektrotların bağlanma şekli a) kafanın sol yüzey görünümü b) kafanın üst yüzey görünümü c) 75 elektrot için 2 boyutlu üst görünüm	**5**
Şekil 1.4	Örnek bir BBA sistemi ve temel bileşenleri	**6**
Şekil 3.1	Uluslararası 10-20 sistemine göre ilgili veri setinde kullanılan elektrotlar	**18**
Şekil 3.2	İmleç hareketine ilişkin EEG kaydında izlenilen zaman akışı	**18**
Şekil 3.3	En temel bazı işaretlerin zaman ve frekans alanındaki dönüşümleri	**19**
Şekil 3.4	FD, KZFD ve DD arasındaki Zaman-Frekans-Çözünürlük ilişkisi	**21**
Şekil 3.5	Sık kullanılan bazı dalgacık modelleri	**22**
Şekil 3.6	Haar Dalgacığı	**23**
Şekil 3.7	Daubechies Dalgacık Ailesi	**23**
Şekil 3.8	Meksika Şapkası Dalgacığı	**24**
Şekil 3.9	Meyer Dalgacığı	**24**
Şekil 3.10	Morlet Dalgacığı	**25**
Şekil 3.11	Symlet Dalgacık Ailesi	**25**
Şekil 3.12	Sinüs fonksiyonunun ölçeklenmesi	**26**
Şekil 3.13	db7 dalgacık modelinin zamanda ötelenmesi ve ölçeklenmesi	**26**
Şekil 3.14	Dalgacığın orijinal işaretin ilk kısmıyla karşılaştırılması	**27**
Şekil 3.15	Dalgacığın kaydırılarak karşılaştırılması	**27**
Şekil 3.16	Dalgacığın yeniden ölçeklenmiş halinin işaretle karşılaştırılması	**27**
Şekil 3.17	Ayrık dalgacık dönüşümünde filtreleme	**28**
Şekil 3.18	**(a)** İşaret filtrelendikten sonra elde edilen bileşenlerin uzunluğu **(b)** İşaret filtrelendikten sonra aşağı örnekleme ile oluşan bileşenlerin uzunluğu	**29**
Şekil 3.19	**(a)** Dalgacık ayrıştırma ağacı **(b)** Dalgacık paketi analizi	**30**
Şekil 3.20	k=3 için bilinmeyen bir nesnenin sınıflandırılması	**32**

Şekil 3.21	Eğitim veri setinin sınıflarının belirlenmesi	**31**
Şekil 3.22	Mesafe metriklerinin hesaplanması	**33**
Şekil 3.23	Bilinmeyen nesnenin atanması	**33**
Şekil 3.24	İki veri sınıfını ayıran optimum ayırıcı düzlemler	**35**
Şekil 3.25	VC boyutlarıyla sıralı iç içe geçmiş işlev altkümeleri	**36**
Şekil 3.26	Doğrusal olarak ayrılabilen veriler için hiper düzlem ve destek vektörleri	**37**
Şekil 3.27	Doğrusal olarak ayrılamayan veri sınıfları	**38**
Şekil 3.28	Doğrusal olarak ayrılamayan veriler ve ξ değişkeni ilişkisi	**39**
Şekil 4.1	Kanal seçimi için kullanılan işlem adımları	**42**
Şekil 4.2	Tez kapsamında sınıflandırma için izlenilen işlem akışı	**43**
Şekil 4.3	Dalgacık katsayılarından elde edilen özniteliklerin sınıflandırılması	**44**
Şekil 4.4	6. seviye yaklaşım katsayılarının od-mmd değişimi	**47**
Şekil 4.5	5. seviye yaklaşım katsayılarının od-mmd değişimi	**47**
Şekil 4.6	4. seviye yaklaşım katsayılarının od-mmd değişimi	**48**
Şekil 4.7	3. seviye yaklaşım katsayılarının od-mmd değişimi	**48**
Şekil 4.8	Örnek bir AİH örüntüsüne ilişkin ham EEG kaydı ve 5.,6.,7.,8. seviye katsayılardan elde edilen işaretin değişimleri.	**49**
Şekil 4.9	AİH sınıfına ilişkin rastgele seçilen 4 denemenin Ham EEG kaydı ve 8. seviye yeniden oluşturulan alt bant işaretlerinin üst üste çizimleri	**50**
Şekil 4.10	YİH sınıfına ilişkin rastgele seçilen 4 denemenin Ham EEG kaydı ve 8. seviye yeniden oluşturulan alt bant işaretlerinin üst üste çizimleri	**50**
Şekil 4.11	8. seviye alt bandına ait özniteliklerin elde edilip sınıflandırılmasına ilişkin akış şeması	**51**
Şekil 4.12	İki farklı sınıfa (AİH ve YİH) ilişkin örüntülerin *y1*-*y2* değişimleri	**52**
Şekil 4.13	*x8*'in *y1* ve *y2* ye göre değişimi	**52**
Şekil 5.1	Hibrid yaklaşım ile sınıflandırma için izlenilen işlem akışı	**55**
Şekil 5.2	k-NN'de performansın değerlendirmeye alınan veri uzunluğuna göre değişimi	**55**
Şekil 5.3	DVM'de performansın değerlendirmeye alınan veri uzunluğuna göre değişimi	**56**

KISALTMA VE SİMGELER

ADD	: Ayrık Dalgacık Dönüşümü
AİH	: Aşağı İmleç Hareketi
ALS	: Amiyotrofik Lateral Sklerozis
BBA	: Beyin Bilgisayar Arayüzü
cA1	: Birinci seviye yaklaşım dalgacık katsayıları
cD1	: Birinci seviye detay dalgacık katsayıları
CSP	: Common Spatial Patterns
DARPA	: Defense Advanced Researh Project Agency
dB	: Desibel
DD	: Dalgacık Dönüşümü
DVM	: Destek Vektör Makinaları
ECoG	: Elektrokortigografi
EEG	: Elektroensefalogram
EKG	: Elektrokardiyogram
ELM	: Extreme Learning Machine
EMG	: Elektromiyograf
EOG	: Elektrookülograf
FD	: Fourier Dönüşümü
fMRI	: Fonksiyonel Manyetik Rezonans Görüntüleme
fMRI	: Fonksiyonel manyetik rezonans görüntüleme
fs	: Örnekleme frekansı
GA	: Genetik Algoritma
GHZ	: Giga Hertz
Hz	: Frekans
k-NN	: k En Yakın Komşu
KZFD	: Kısa Zamanlı Fourier Dönüşümü
LDA	: Linear Discriminant Analysis
MEG	: Magnetoensefolografi
MMD	: Maksimum Mutlak Değer
NSA	: National Security Agency
OD	: Ortalama Değer
PCA	: Principal Component Analysis
PET	: Pozitron yayılımlı tomografi
PET	: Pozitron Yayılımlı Tomografi
PNN	: Probabilistic Neural Network
SAM	: Self Assesment Manikins

SDD	: Sürekli Dalgacık Dönüşümü
SPECT	: Tekil Foton Yayılımlı Bilgisayar Tomografi
SPECT	: Tekil Foton Yayılımlı Bilgisayar Tomografi
VC	: Vapnik Chervonenkis dimension
YİH	: Yukarı İmleç Hareketi
YKP	: Yavaş Kortikal Potansiyeller
YRM	: Yapısal Risk Minimizasyonu
YSA	: Yapay Sinir Ağı
α	: Alfa
β	: Beta
γ	: Gamma
δ	: Delta
θ	: Teta
μV	: Mikro volt
$\psi(t)$	: Dalgacık fonksiyonu
σ	: Sigma

1. GİRİŞ

Düşüncelerin okunması, beyin faaliyetleri, beynin vücudun kontrol işlevini nasıl icra ettiği gibi konular insanlık tarih boyunca merak konusu olmuştur. Bu meraktan esinlenerek beyindeki elektriksel değişimlerin çeşitli yöntemlerle izlenmesi ile yapılan çalışmalar günümüze kadar gelmektedir. Bu izleme yöntemleri arasında finansal ve zamansal açıdan diğer ölçüm yöntemlerine göre daha avantajlı olan Elektroensefalogram (EEG); beynin içerisinde meydana gelen fonksiyonel ve psikolojik değişimlerin analizi amacıyla kullanılmaktadır. Bu değişimler aynı zamanda kafa derisinde bir takım elektriksel değişikliklere de neden olur. EEG ölçümü kafa derisine sistematik olarak yerleştirilen elektrotlar yardımıyla elektriksel değişimlerin gözlenmesi şeklinde yapılır.

Günlük hayatta sağlıklı bir kişi makinalarla fare, klavye, dokunmatik ekran, mikrofon gibi birçok ara eleman aracılığıyla iletişim kurmaktadır. Beyin Bilgisayar Arayüzü (BBA) sistemleri EEG işaretlerini kullanarak bu ara elemanların yerini almak amacıyla kullanılmaktadır. Bu durum göz önüne alınınca, BBA sistemlerinin Amiyotrofik Lateral Sklerozis (ALS) gibi fiziksel aktivitelerini kullanamayan ancak zihinsel faaliyetleri sorunsuz olan hastalar için son derece önem arz ettiği anlaşılmaktadır.

Bu çalışmada bir BBA sisteminin, öznitelik çıkarma ve sınıflandırmadan oluşan işaret işleme kısmı ele alınmıştır. Bu tez kapsamında, imlecin yukarı/aşağı hareketine ilişkin EEG kayıtlarından özniteliklerin çıkarılması ve sınıflandırılması amaçlanmıştır.

Bu bölümde tezin hedefi olan çalışmanın anlaşılmasını kolaylaştırmak amacıyla EEG ve BBA ile ilgili temel bilgiler verilecektir. Bu bölüm iki aşamadan oluşmaktadır. Birinci aşamada; EEG'nin tanımı, tarihçesi, alt bantları ve ölçümü anlatılmıştır. İkinci aşamada ise BBA'nın tanımı yapılmış ve temel bileşenleri anlatılmıştır.

1.1 Elektroensefalogram (EEG)

İnsan sinir sisteminin en temel yapı taşı olan nöronlardaki elektriksel aktivitelerin varlığı yüz yılı aşkın bir süredir bilinmektedir. Sinir sisteminin en önemli elemanı olan beyindeki işlevsel aktiviteler kafa derisi yüzeyinin potansiyel dağılımında değişimlere neden olur. Bu potansiyel değişimler kafa derisine yerleştirilen elektrotlar vasıtası ile ölçülür, filtrelenir, kuvvetlendirilir ve sonrasında kaydedilir. Bu işlem sonucunda elde edilen düşük genlikli (1-400 μV) biyoelektrik işaretler EEG olarak adlandırılır (Ochoa ve ark. 2002)

Düşük genlikli işaretler olmasından ötürü kuvvetlendirilmelidir ki bu da dış etkenlerden etkilenme riskini arttıran en önemli faktördür. EEG işaretleri ayrıca ölçüm sırasında ışığın açık veya kapalı olması, elektromanyetik dalga yayan cihazlar, ölçüm alınan kişinin göz kırpması, vücut hareketleri veya kalp atışları gibi birçok fiziksel aktiviteden de etkilenmektedir.

EEG düşük maliyetli ve acısız bir yöntem olmasından ötürü birçok alanda kullanılır. En sık Tıp alanı olmak üzere, Biyomedikal Mühendisliğinde beynin aktivitelerini gözlemlemek, reklamcılık alanında ürün ve hizmetlerin insan üzerinde etkisini saptamak amacıyla ve oyun sektöründe joystick yerine EEG kayıtlarını değerlendirilmek amacıyla kullanılır.

i. EEG Kısa Tarihçesi

EEG işaretlerine ilişkin araştırmalar 140 yılı aşkın bir süredir devam etmektedir. Beyinde elektrik akımının varlığı ilk olarak 1875'te İngiliz fizikçi Richard Caton tarafından tavşan ve maymunların beyin aktiviteleri gözlenerek keşfedilmiştir. 1924'te Alman nörolog Hans Berger insanın kafatasını açmadan, kafa derisi üzerinden bir yükselteç aracılığıyla ölçüm yapmış ve alınan işaretleri bir kâğıda grafiksel olarak dökmüştür. Bu şekilde acısız bir yöntemle yapılmasına olanak sağlamış ve insan üzerinde EEG ile ilgili araştırmaların hızlanmasına ön ayak olmuştur. Sonradan 1934'te Adrian ve Matthews, "insanın beyin dalgaları" konseptini doğrulayacak şekilde 10-12 Hz civarında düzenli "alfa ritimleri" salınımlarını tanımlayarak, EEG alt bantları ile ilgili giriş niteliğinde bir çalışma yapmışlardır (Teplan, 2002). İlk epileptik EEG işaretleri 1934 yılında Fisher ve Lowenback tarafından incelenmiştir. 1936 yılında Massachusetts General Hospital Hastanesinde ilk EEG laboratuvarı kurulmuştur. W. G. Walter, 1950'de beyin yüzeyindeki elektriksel aktivitenin haritalandırılması için EEG topoğrafyasını geliştirmiş ve dolayısıyla bu konu 1950-1980 yılları arasında popüler bir çalışma alanı haline gelmiştir. 1980-2000 yılları arasında EEG kayıtlarından yararlanarak erken hastalık teşhisi üzerine pek çok çalışma gerçekleştirilmiştir. 2000 yılından bu yana beyin BBA sistemlerine yönelik çalışmaların hız kazandığı görülmektedir. (Başçıl 2015)

ii. EEG Alt Bantları

EEG işaretleri periyodik olmayıp, işaretin genlik, faz ve frekans bileşenleri değişken bir yapıya sahiptir. Çok geniş bir frekans bandında gözlemlenmesine karşın klinik ve fizyolojik ilgi 0.3 Hz. ile 30 Hz. aralığında olmuştur. Bu aralık ise 4 ana frekans bandı olarak sınıflandırılmıştır (Adeli ve ark. 2003).

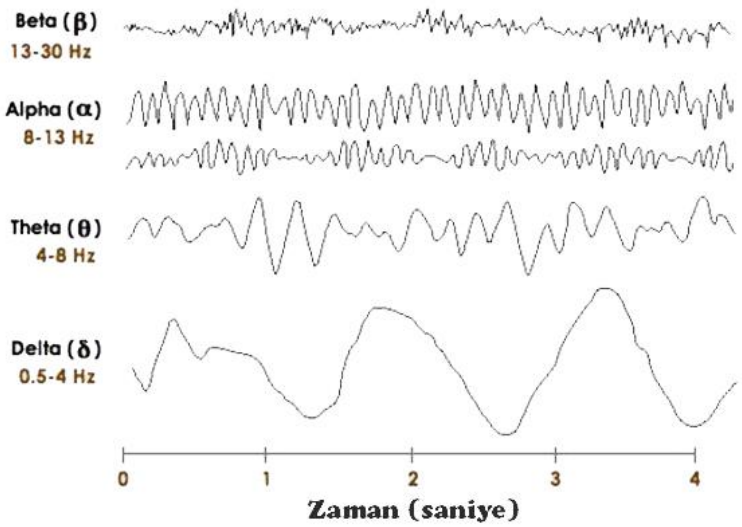
Delta Dalgaları ***(δ)*** : Yüksek genlikli olup 0.5-4 Hz. aralığındaki salınımlar Delta dalgaları olarak adlandırılır. Beyin aktivitesinin çok düşük olduğu durumlarda ve ağırlıklı olarak yetişkinlerin derin uyku hallerinde görülür.

Teta Dalgaları ***(θ)*** : 4-8 Hz. aralığında bulunan salınımlar, Teta dalgaları olarak adlandırılır. Bebeklerde, çocuklarda ve ayrıca yetişkinlerin uyuklama hallerinde görülür. Az da olsa yetişkinlerde uyanıkken görülebilen bir dalga türüdür.

Alfa Dalgaları ***(α)*** : 8-14 Hz. aralığında bulunan salınımlar, Alfa dalgaları olarak adlandırılır. Yetişkinlerde tam dinlenme hallerinde görülür. Yoğun şekilde oksipital bölgede ortaya çıkar ve genlikleri çoğunlukla 50 μV 'dan küçüktür. Alfa ritimleri görsel dikkat ve düşünce gibi mental aktivite durumunda yok olan bir dalga türüdür .

Beta Dalgaları ***(β)*** : 14-30 Hz. aralığında bulunan salınımlar, Beta dalgaları olarak adlandırılır. Beynin ön kısmında daha baskın ve alfa dalgalarına nispeten daha düşük genlik değerleriyle görülen bir dalga türüdür.

Söz konusu alt bantların örnek değişimleri Şekil 1.1.' de gösterilmiştir.



Şekil 1.1. EEG işareti alt frekans bantları

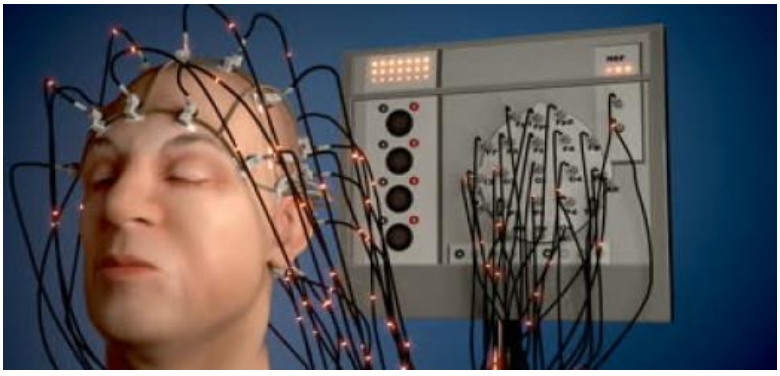
iii. EEG İşaretlerinin Ölçümü ve Elektrotların Bağlanma Şekilleri

EEG kayıtları ve ölçümü; İnsan vücudundan elde edilen işaretler ve görüntüler, çeşitli hastalıkların erken teşhisi, reklamcılık faaliyetleri veya oyun sektörü gibi birçok alanda kullanılmaktadır. Kullanılan en temel işaretler; kalpten alınan elektrokardiyografi (EKG), kaslardan alınan elektromiyogram (EMG), beyinden alınan EEG ve magnetoensefalogram (MEG), mideden alınan elektrogastrogram (EGG) ve göz sinirlerinden alınan elektrooptigramdır (EOG).

EEG işaretlerinin ilk kaydı, basit galvanometre kullanılarak gerçeklenmiştir. Sonraları EEG sistemleri, bir dizi hassas elektrottan, bir dizi diferansiyel amplifikatörden ve ardından filtrelerden geçirilerek bir kâğıda çizilmiştir. Bu sistem pazara girdikten kısa süre sonra, araştırmacılar işaretleri sayısallaştırıp depolayabilen bilgisayarlı sistemler arayışına girmişlerdir.

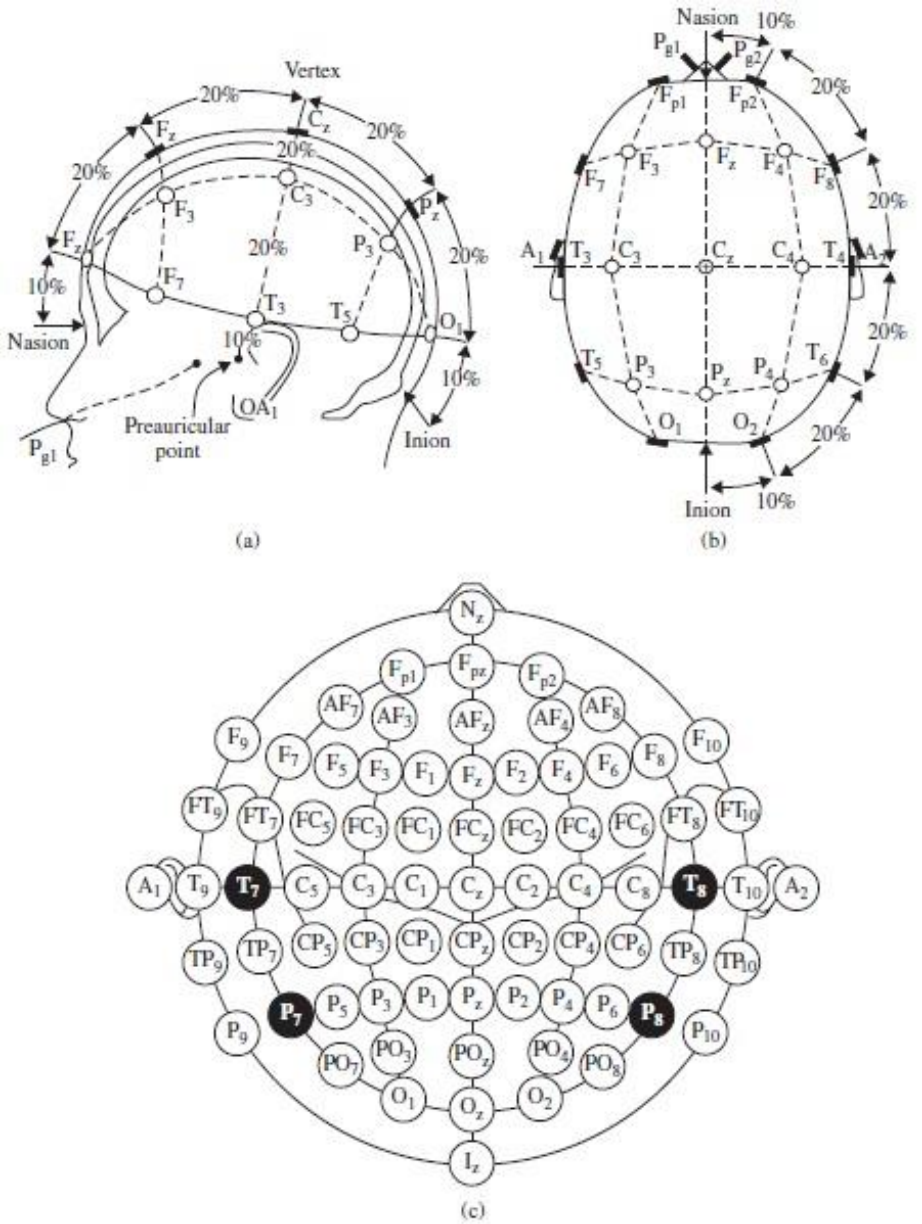
Bu gelişimlerin sonucu olarak günümüzde hassas elektrotlardan oluşan EEG kayıt sistemleri kullanılmaktadır. EEG işaretlerinin sayısallaştırılması ve depolanması ile birlikte çalışmalar hızlanmış ve araştırmacılar için bu işaretler üzerinde daha iyi analizlerin yapılabilmesi mümkün kılınmıştır.

EEG işaretleri, kafa derisine sistematik olarak yerleştirilen elektrotlar vasıtasıyla ölçülmektedir. EEG kayıt elektrotları ve elektrotların işlevini doğru icra etmesi, kaliteli verilerin elde edilmesi için çok önemlidir. EEG kayıt sistemlerinde farklı elektrot türleri kullanılır. Bunlardan bazıları; tek kullanımlık elektrotlar (jelsiz ve önceden jelleştirilmiş), tekrar kullanılabilir disk elektrotlar (altın, gümüş, paslanmaz çelik veya kalay), tuzlu elektrotlar ve iğne elektrotlarıdır (Sanei ve Chambers 2007). Şekil 1.2.'de örnek bir EEG ölçüm sistemi görülmektedir.



Şekil 1.2. Örnek bir EEG ölçüm sistemi

Elektrotların Bağlanma Şekilleri; Elektrotlar kafa derisine Uluslararası EEG Federasyonu Birliği (International Federation of EEG Societies) tarafından belirlenmiş olan 10-20 elektrot sistemine göre yerleştirilir. Bu sisteme göre baş; burun (nasion), başın arka kısmı (inion), sol kulak arkası ve sağ kulak arkası (preauriculars) olmak üzere dört standart noktayla işaretlenmiştir. Elektrotlar burun ve başın arka kısmı arasına % 10 - 20 - 20 - 20 - 20 - 10 olacak şekilde yerleştirilir. Şekil 1.3.'te Uluslararası 10-20 sistemine göre elektrotların bağlanma şekli farklı açılardan gösterilmiştir.



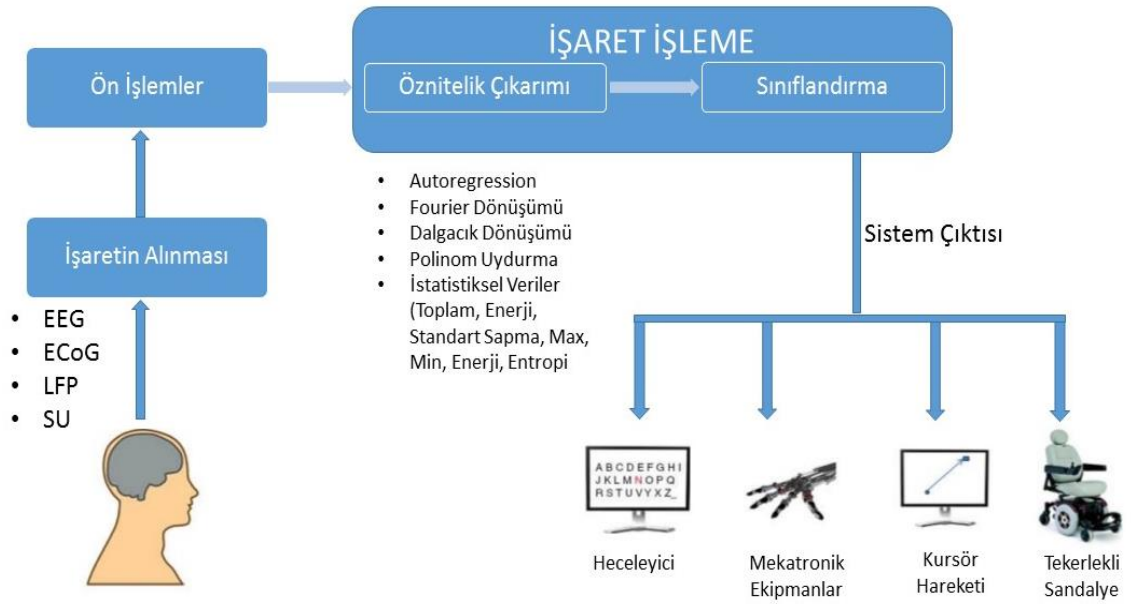
Şekil 1.3. Uluslararası 10-20 sistemine göre elektrotların bağlanma şekli a) kafanın sol yüzey görünümü b) kafanın üst yüzey görünümü c) 75 elektrot için 2 boyutlu üstten görünüm (Sanei ve Chambers 2007)

1.2 BBA & EEG ilişkisi ve BBA'nın Temel Bileşenleri

i. Beyin Bilgisayar Arayüzü (BBA) Sistemleri

İnsanlar makinalarla iletişim kurmak için klavye, fare, dokunmatik ekran, özel tasarımlı eldiven ve mikrofon gibi araçlardan faydalanır. Bu araçların kullanımı bireyin sağlıklı olması ve fiziksel aktivitelerinin bir kısmını veya tamamını kullanabilmesine bağlıdır. Ancak ALS hastalığı bulunan bireyler kas hareketlerini kullanamazken; görme, koku alma, duyma, dokunma gibi duyular ve bunun yanında hafıza, zekâ ve kişilik gibi bilişsel işlevlerini kullanabilir. Bu da beyin işlevlerinin doğru yorumlanarak uygun teknolojinin kullanılması ile insanlar ve makinalar arasında iletişim kurulabileceği fikrini doğurmuştur. (Aydemir 2008)

BBA sistemleri bireylerin kas sistemlerini başka bir ifade ile motor sinir sistemlerini kullanmadan, beyin aktivitelerinin yorumlanması ile bir bilgisayarı, elektromekanik bir kolu veya nöroprotezleri kullanmalarını sağlayan sistemlerdir (Aydemir 2008). Örnek bir BBA sisteminin yapısı ve temel bileşenleri Şekil 1.4.'te gösterilmiştir.



Şekil 1.4. Örnek bir BBA sistemi ve temel bileşenleri

ii. BBA & EEG İlişkisi

Bir BBA sistemi beyin aktivitelerinin yorumlanması temeline dayanır. Beyin aktivitelerini izlemek için kullanılan teknikler;

- Fonksiyonel Manyetik Rezonans Görüntüleme (fMRI)
- Manyetoensefalografi (MEG)
- Pozitron yayılımlı tomografi (PET)
- Tekil Foton Yayılımlı Bilgisayar Tomografi (SPECT)
- Optik Beyin Görüntüleme
- Tekil Nöron Kaydı
- Elektrokortigografi (ECoG)
- Elektroensefalografi (EEG)

Bu tekniklerden MEG, PET, fMRI ve Optik Beyin Görüntüleme yöntemleri hem finansal hem de zaman açısından maliyetlidir. Tekil Nöron Kaydı yöntemi ise kafatası içine elektrot yerleştirilmesi gerektiğinden ötürü pratik değildir.

Ağrısız, pratik ve düşük maliyetli olmasından ötürü EEG tekniği BBA sistemleri için en uygun teknik olarak değerlendirilmektedir (Şengil 2004).

iii. BBA'nın Temel Bileşenleri

Örnek bir BBA sistemi Şekil 1.4'te görüleceği üzere 4 alt sistemde incelenebilir.

EEG işaretinin ölçümü; BBA sisteminin ilk adımıdır. Ağrısız, pratik ve düşük maliyetli olmasından ötürü EEG tekniği BBA sistemleri için en uygun tekniktir. Ancak çok fazla deneme gerektiriyor olması dezavantajlarından biridir. Alınan işaretlere A/D dönüştürücü ve gürültüden arındırma işlemleri uygulanır.

Ön işlem; İşaret analizinden önce çeşitli uygulamalar bu aşamada gerçeklenir. Bu uygulamalardan en temel olanlar; filtreleme (Örneğin 0.5-50Hz bant geçiren) ve ortalamanın sıfıra indirgenmesidir.

Öznitelik çıkarımı; Analogdan Dijitale dönüştürülen işaretlerin genlik ölçümleri, spektral analizi, zaman-frekans analizleri gibi işlemlerden geçirilerek işaretlere ait benzer özelliklerin belirlenmesi işlemidir. Sınıflandırılmak istenen verinin özniteliklerinin iyi şekilde belirlenmesi, sınıflandırma sonucuna doğrudan etki eder. Öznitelik çıkarma işlemine ilişkin literatürde birçok yöntem bulunmaktadır. Kaynak özetleri bölümünde bu çalışmaların bir kısmına değinilecektir.

*Sınıflandırma***;** Bir BBA kullanıcısından alınan EEG kayıtlarında; kişinin sağlık durumu, metabolizma faaliyetleri veya BBA kullanıcısı aynı şeyleri düşünse dahi bir takım değişiklikler görülmektedir. Bundan dolayı EEG kayıtları her defasında aynı özellikleri göstermeyeceğinden, verilerin en uygun algoritma ile sınıflandırılması BBA sisteminin başarımında önemli rol oynar. Diğer bir deyişle sınıflandırma; öznitelikleri çıkarılan örüntülerin taranması ve tanınması işlemidir. Sınıflandırma işlemi için literatürde birçok yöntem bulunmaktadır. Kaynak özetleri bölümünde bu yöntemlerin bir kısmına değinilecektir. Sınıflandırma işlemi sonunda, çeşitli çevresel donanımların (tekerlekli sandalye, el/ayak protezleri, vs.) kontrolleri sağlanabilmektedir.

2. KAYNAK ÖZETLERİ

İlk olarak 1970'li yıllarda NSA (National Security Agency) ve DARPA (Defense Advanced Researh Project Agency) desteğiyle Kaliforniya Üniversitesi'nde başlayan ve böylece literatüre giren BBA sistemlerine olan ilgi son 20 yıldır artmıştır. Beyin aktivitelerinin izlenmesi için geliştirilen tekniklerden EEG yöntemi BBA sistemleri için en pratik yöntemlerin başında gelmektedir. EEG işareti tabanlı BBA sistemlerinin çok farklı alanlarda kullanıldığı literatürde görülebilmektedir. Bu bakımdan literatür özetleri iki aşamada incelenmiştir. Birinci aşamada genel amaçlı (Tat sınıflandırma, Duygu tespiti, nöroprotez uygulaması, uyku bozukluğu, heceleme, zihinsel görevler) gerçekleştirilen çalışmaların özetleri verilmiş olup, ikinci aşamada ise bu tez kapsamında çalışılan konuyla ilişkili çalışmaların özetleri verilmiştir.

i. Genel Amaçlı EEG Tabanlı BBA Sistemleri İle İlgili Çalışmalar

EEG verilerinin birçok alanda (Tıp, reklamcılık, oyun vb.) kullanıldığı görülmektedir. Bu çalışmalardan bazıları aşağıda özetlenmiştir.

Tat Sınıflandırma: Ismi Abidi ve Omar Farooq (2015), tatlı ve ekşi tatları ayırt etmek için bir EEG tabanlı BBA tasarımı üzerine çalışmışlardır. Bu amaçla, 10 sağlıklı denekten, çeşitli tatlara (küp şeker ve limon özü) ilişkin EEG kayıtları (8 kanal) alınmıştır. Çalışmada; kurtoz (kurtosis), çarpıklık (skewness), enerji ve dalgacık entropisi öznitelik olarak kullanılmıştır. Çıkarılan öznitelikler; LDA (Linear Discriminant Analysis) sınıflandırıcı ile sınıflandırılmıştır. Enerji ve dalgacık entropisinden oluşan özniteliklerin performansı %98 doğrulukta sınıflandırıldığı, diğer iki öznitelik ile %60 doğrulukta performansın elde edildiği görülmüştür. Uyarı verildikten sonra en iyi zaman aralığını değerlendirmek için yapılan analizde ise çıkarılan özniteliklere dayanan EEG işaretlerindeki en iyi ayırıcı yanıtın, uyartıdan sonra 20-30 sn arasında olduğunu tespit etmişlerdir.

Duygu Tespiti: Jiahui Pan ve ark. (2016) iki temel duygusal durumu (mutluluk ve hüzün) tespit etmek için bir EEG tabanlı BBA sistemi önermişlerdir. Araştırmada duygu tanıma için sabit frekans bantları kullanmak yerine, konuya özgü uygun frekans bantlarının seçimini önermişlerdir. İki duygusal durumu sınıflandırmak için Genel Uzaysal Örüntüler (Common Spatial Patterns, CSP) ve Destek Vektör Makinaları (DVM)

kullanılmıştır. İki sınıfta ortalama %74.17 çevrimiçi doğruluk elde edilmiştir. Dolayısıyla çalışmada önerilen yöntemin daha başarılı olduğu gösterilmiştir.

Duygu Tespiti: Süheyla Sinem Uzun (2012), duygu durumlarının kestirimi üzerine bir araştırma yapmıştır. Çalışmada, ilk aşamada duygusal olarak uyarılmış deneklerden EEG kayıtları alınmıştır. Duygu durumları SAM (Self Assesment Manikins) görselleri ile değerlendirilmiştir. Hilbert-Huang Dönüşümü ile öznitelikler çıkarılmış ve ilinti tabanlı öznitelik seçimi algoritması uygulanarak, duygu kestirimi için en uygun olan öznitelikler belirlenmiştir. Destek vektör regresyonu kullanılarak, duygu temel boyutlarının (değerlik, aktivasyon, baskınlık) kestirimi yapılmıştır.

Nöroprotez Uygulaması: Gernot R. Müller-Putz ve ark. (2004), bir EEG tabanlı BBA ile implant nöroprotez arasındaki bağlantıyı göstermek üzere bir araştırma yapmışlardır. Hasta, motor görüntü tabanlı Graz-BBA sistem eğitimini 3 günde tamamlamış, ayırt edilebilir örüntüler oluşturulmuştur. Eğitimin içeriği, hastanın felçli sol eline ilişkin motor hareket hayalidir. Hasta, BBA'nın çıkış işaretinin değerlendirildiği omuz kumanda çubuğunu genellikle taklit edebilmiştir ve tutma-bırakma testlerinin bir kısmını gerçekleştirerek, basit bir nesneyi bir yerden bir yere taşıyabilmiştir. Bu çalışmada sunulan sonuçlara göre araştırmacılar, BBA sistemlerinin, yüksek spinal kord lezyonu olan hastalarda, nöroprotezlerin kontrolü için bir seçenek olduğunu savunmuşlardır.

Uyku Bozukluğu: L. G. Doroshenkov ve ark. (2006), uyku bozuklukları konusu üzerinde bir araştırma yapmışlardır. Çalışmada 21-35 yaş arası bay ve bayanlardan elde edilen EEG işaretleri kullanılmıştır. Hidden Markov modeli ile öznitelikler çıkarılmış ve %88 doğrulukla sınıflandırma gerçekleştirilmiştir.

Zihinsel Görev: Li Zhiwei ve Shen Minfen yaptıkları çalışmada Dalgacık paket entropisi ve DVM kullanan bir yöntem önermişlerdir. İlk olarak, Daubechies ana dalgacık ailesinden "db2" ile EEG'nin her kanalına 7 seviyeli dalgacık paketi ayrıştırması uygulanmıştır. Dört spektrumlu bant (delta, teta, alfa, beta) çıkarıldıktan sonra, her bantta bir entropi algoritması gerçekleştirilmiştir. Oluşan entropi vektörleri öznitelik olarak DVM sınıflandırıcıya giriş olarak kullanılmıştır. 2 farklı denek için 5'er adet zihinsel görev uygulanmıştır. 2 sınıflı sınıflandırma doğruluğu, 1nci denek için %93,0 ve 2nci denek için %87,5 olarak bulunmuştur.

Heceleme: Hasan Balkar Erdoğan (2009), yapmış olduğu çalışmada Heceleme Paradigması uygulaması ile P300 tabanlı bir BBA sisteminin tasarımını gerçekleştirmiştir. Çalışmasında BBA problemlerine farklı işaret işleme ve örüntü sınıflandırma yöntemleri uygulayarak, problemlerdeki tahmin mekanizmalarının hızını arttırmayı amaçlamıştır. Çalışma BBA uygulamalarında kullanılmak üzere, 10 kanallı bir EEG veri toplama sistemi tasarımı ve kurulumunu içermektedir. P300 Heceleme Uygulamasına bir işaret işleme aracı olarak Wiener süzgeçleme yöntemi uygulanmıştır. Sınıflandırma işlemi DVM ve Bayes Karar Yöntemleri kullanılarak gerçekleştirilmiştir. Bu yöntem; BBA II Yarışmasında kullanılmış olup, P300 Heceleticisi veri kümesindeki test karakterleri (4 tekrar) %100 başarıyla tahmin edilmiştir.

ii. İmleç Hareketlerine İlişkin EEG Tabanlı Çalışmaların Özetleri

İmleç hareketlerine ilişkin kayda değer çalışmaların BCI 2003 yarışmasıyla başladığına inanılmaktadır. Yarışma kapsamındaki başarımlar Tablo 2.1.'de sunulmuştur. Tablodan en yüksek performansın %88.7 olduğu görülmektedir. Çalışmalara bakıldığında, Fourier katsayıları, zaman domeninde ortalamalar, sürekli dalgacık katsayıları ve frekans bantlarının güç değişimleri, öznitelik olarak kullanılmıştır. Sınıflandırıcı olarak da, LDA, parametrik olmayan Bayes sınıflandırıcılar, DVM ve yapay sinir ağları (YSA) kullanılmıştır.

Yarışmadan bugüne kadar aynı veri tabanı ile yapılan 3 çalışma ve bu çalışmada hangi yöntemlerin kullanıldığı aşağıda özetlenmiştir.

Wu Ting ve ark. (2007), işaretleri ADD ile 6ncı seviye alt bantlarına ayırmış ve 0-50 Hz. aralığındaki 25 alt bant katsayılarının ortalama ve enerjilerini öznitelik olarak kullanmışlardır. Özniteliklerin Fisher kriterlerine göre, ayrıştırılabilirlik (seperability) değerleri ele alınmıştır. Bu kriterlere göre 15 değer alt bant enerjisinden, 2 değer katsayılar ortalamasından seçilmiştir. Öznitelikler Olasılıksal Yapay Sinir Ağı (Probabilistic Neural Network, PNN) modeli ile sınıflandırılmış ve %90,8 lik bir başarım elde edilmiştir. Bu çalışmada ayrıca ALS hastalıklı kişinin veri seti de (dataset Ib) sınıflandırma işlemine tabi tutulmuş ve %59,1'lik sınıflandırma başarımı elde edilmiştir.

Aydemir ve Kayıkçıoğlu (2008) ham EEG verilerine 2. derece polinom uydurmak suretiyle polinom katsayılarını ve tepe noktalarını öznitelik olarak seçmişlerdir. Öznitelikler, k-en yakın komşu (k-NN) ve DVM ile sınıflandırılmıştır. En yüksek sınıflandırma performansı olarak %92.2 elde edilmiştir.

Tablo 2.1. BCI 2003 yarışmasında Dataset Ia veri seti için elde edilen performansların özetleri

Sıra	Katılımcı	Doğruluk (%)	Üniversite	Öznitelik	Sınıflandırıcı
1.	Brett Mensh	88.7	MIT	1. ve 2. kanalların DC Potansiyelleri. 4. ve 6. kanalların yüksek beta güç bantlarının spektrumları.	Doğrusal Ayırtaç Analizi (Linear Discriminant analysis LDA)
2.	Guido Dornhege	88.4	Fraunhofer FIRST (IDA), Berlin	Deneme başlangıcındaki Uyarılmış tepki yoğunluğu ve denemelerin ortalamaları. Çalşmada 2 günün verileri ayrı ayrı kümelenmiş. Çapraz doğrulamada sadece 2nci gün verileri kullanılmıştır.	Düzenlenmiş Ayırtaç Analizi, Doğru Programlama Makinası (regularized discriminant analysis, linear programming machine)
3.	Kai-Min Chung	88.1	National Taiwan University, Taipei	25 Hz'e indirdikten sonraki zaman serileri	Destek Vektör Makinaları
4.	Tzu-Kuo Huang	85.0	National Taiwan University, Taipei	Doğrusal DVM eğitimindan sonra, en bütük w_i ye sahip zaman serisinin öznitelik seçimi yapılmıştır.	Doğrusal olmayan Destek Vektör Makinaları
5.	David Pinto	84.3	University of Florida		10 seviyeli Hidden Markov Modeli (Hidden Markov Model with 10 states)
6.	Juma Mbwana	82.9	Yale University	Zaman serilerinin bozulması, Ayırtaç Analizi (decimation of time series, discriminant analysis)	Destek Vektör Makinaları (DVM)
7.	Vladimir Bostanov	82.6	University of Tübingen	Sürekli Dalgacık Dönüşümü, Skalaogram Tepesi Algılama	Kademeli olarak veya optimal değişken seçimi ile Doğrusal Ayırtaç Analizi (Linear Discriminant analysis LDA)
8.	Ulrich Hoffmann	82.8		Her Kanal İçin 0-7 Fourier Katsayıları (0-2 Hz)	Düzenlenmiş Doğrusal Fisher Ayırtacı
9.	Deniz Erdogmus	80.9	University of Florida		5 değişik yöntemin çoğunluk oyu
10.	Justin Sanchez	80.2	University of Florida		5 gizli İşlem elemanı içeren tamamen bağlı MLP ile tekrarlanan Çok Katmanlı Algılayıcı,
11.	Amir Saffari	76.5	Sahand University of Technology, Tabriz	Her denemenin eğitimi için A1 ve A2 kanallarına hareketli ortalama dönüşümü (moving average transform) uygulanmış. Her deneme için 25 nokta elde edilmiş. Sonra bu 25 noktanın DC bileşeni atılmış ve 25 noktanın en büyüğüne bölerek [1 -1] aralığına normalize edilmiştir.	Yapay Sinir Ağları
12.	Michael Grabner	75.4	Technical University of Graz	Zaman alanında ortalamalar alınmıştır.	Çok Katmanlı Perceptron Yapay Sinir Ağı (6 kat çapraz doğrulama uygulanmış)
13.	Yadu Rao	65.5	University of Florida		(30x8x6) 5'lik bir gömme kullanarak Zaman geciktirme sinir ağı tahmincisi
14.	Kenneth Hild	53.2	University of Florida	Temel Bileşen Analizinden en büyük üç uzunluktaki beş öz vektör ve zaman serileri üzerinde teorik özellik azaltım	Parametrik Olmayan Bayes Sınıflandırıcısı
15.	Fabien Torre	50.9	University of Lille, GRAppA	Kendilerine ait olan GloBo (anlaşılabilir ayırıcı teorileri öğrenen stokastik bir algoritma) bir algoritması kullanılmıştır.	

Qin Lin ve ark. (2015), Zaman-Frekans analizi yöntemi kullanmışlardır. Zaman domeninde işaretlere maksimum, minimum, ortalama, ilk çeyrek (upper quartile), son çeyrek (lower quartile) gibi istatistiksel işlemler uygulayarak zaman domeni öznitelik vektörünü oluşturmuşlardır. Frekans domainde ise periodogram kullanmış, 257 güç spektrum sabitinden Fisher kriterine göre en iyi 5 tanesini seçerek frekans domeni öznitelik vektörlerini oluşturmuşlardır. Bu öznitelik vektörlerini Extreme Learning Machine (ELM) ve Genetic Algorithm (GA) tekniklerini kullanarak sınıflandırmışlardır. Sadece ELM kullanarak %83.1, GA ve ELM'yi birlikte kullanarak %93.9 başarım elde ederek bugüne kadar ki en yüksek sonuçlara da ulaşmışlardır.

BCI 2003 Data set1a veri setinin dışında, farklı veri tabanları kullanılarak imleç hareketlerine ilişkin yapılan bazı çalışmalar ise aşağıda özetlenmiştir.

Zahmeeth Sakkaff ve Asiri Nanayakkara (2010), bir bilgisayar faresini modelleme amacıyla bir çalışma yapmışlardır. Bir bilgisayar ekranında kare şeklinde bir imlecin yukarı, aşağı, sağ ve sol yönlere hareket ettirilmesi için 4 zihinsel görev tanımlanmıştır. Farenin sağ ve sol tıklama işlemini modelleme amacıyla da kullanıcıdan, sağ el orta parmağını ve sol el orta parmağını hareket ettirdiğini düşünmesi istenmiştir. Araştırmada öznitelik vektörlerini elde etmek için bant güçleri, aşağı örnekleme ve Temel Bileşenler Analizi (Principal Component Analysis, PCA) metotları kullanılmıştır. Sınıflandırma işlemi için ise LDA, DVM ve k-NN sınıflandırma metotları kullanılmıştır. Veri setleri 3 sağlıklı bireyden elde edilmiştir. Çalışma sonucunda imleç hareketlerinin sınıflandırmasında, 1 numaralı bireyden %88-%98, 2 numaralı bireyden %100 ve 3 numaralı bireyden %80-%90 oranlarında performanslar elde edilmiştir. Sağ ve sol parmak hareketi sınıflandırmasında ise, 1 numaralı bireyden %75-%80, 2 numaralı bireyden %92 ve 3 numaralı bireyden %82-%98 oranlarında performanslar elde edilmiştir.

Chi-Hsuan Hsieh ve ark. (2014), EEG işaretlerini kullanarak BBA tabanlı bir göz hareketi algılama sistemi önermişlerdir. Önerilen sistemde; Bağımsız Bileşenler Analizi (Independent Component Analysis, ICA), Extended Moving Difference (EMD) ve Frekans Domeni Analizi (FDA) yöntemleri ile EEG işaretlerine ilişkin öznitelikler elde edilmiştir. Eş zamanlı olarak, göz hareketi algılama işlemini gerçekleştirmek için Hidden Markov Modeli (HMM) kullanılmıştır. Önerilen sistem, bir dizüstü bilgisayarla gerçek

zamanlı bir BBA kontrol sistemi oluşturmak üzere bir Field Programmable Gate Array (FPGA) kartı üzerinde uygulanmıştır. Kullanıcılar, gözbebeklerini sola-sağa ve yukarı-aşağı yönlerine doğru hareket ettirerek, bilgisayardaki bir oyunu kontrol edebilmişlerdir. 11 denek üzerinde çalışılmış, maksimum %100, minimum %61.1 performansı elde edilmiştir. Tüm deneklerin ortalaması olarak ise %88.6 olduğu görülmüştür.

Dong Ming ve ark. (2009), bir imleci bilgisayar ekranında hareket ettirerek EEG tabanlı fare sistemi tasarlamayı amaçlamışlardır. Bu sistemde kullanıcının el hareketini kullanmadan sadece düşünerek imleci hareket ettirmesi amaçlanmıştır. Karakteristik frekans bandını bulmak için Fisher oranı kullanılmıştır. Bu banda güç sağlayan spektrum, hayali el hareketini dinlenme durumundan ayırmak için öznitelik olarak hesaplanmıştır. Sınıflandırıcı olarak Mahalanobis mesafe ölçütü kullanılmıştır. Çalışmada %80 başarım oranına ulaşılmıştır.

Dandan Huang ve ark. (2009), imleç hareketini en az eğitimle iki boyutlu bir düzlemde kontrol etmeyi amaçlamışlardır. İki boyutlu imleç hareketinin doğruluğu bir çevrimiçi sanal bilgisayar oyunu ile kontrol edilmiştir. Öznitelik çıkarma işlemi için Genetik Algoritma tabanlı Mahalanobis Lineer Mesafe ölçütü (GA-MLD) uygulanmıştır. Özniteliklere; GA-MLD, DVM ve Karar verme ağaçları sınıflandırıcıları uygulanmış ve karşılaştırılmıştır. Performans hem çevrimdışı sınıflandırma hem de çevrimiçi iki boyutlu imleç kontrolü bakımından değerlendirilmiştir. Dört motor görevin çevrimdışı sınıflandırması için 10 tekrarlı çapraz doğrulama uygulanmış, fiziksel hareket için %88, motor imgelerinde %73 oranında başarım elde edilmiştir. Fiziksel hareketi olan deneylere katılanlar, ortalama %85.5 ± 4.65 doğrulukla çevrimiçi oyunu tamamlayabilmişlerdir. Motor imge araştırmasına katılanlar da oyunu başarılı bir şekilde tamamlamışlardır. Araştırmacılar, önerdikleri BBA'nın, uzun süreli antrenmana ihtiyaç duymayan, insanın doğal davranışları ile ilişkili, pratik ve çok boyutlu bir yöntem olduğunu savunmuşlardır.

Yuanquing Li ve ark. (2010), araştırmalarında motor imgeleri boyunca görülen Mu/Beta ritimleri ve P300 potansiyeli içeren iki beyin işaretini birleştirerek yeni bir yaklaşım önermişlerdir. Çalışma kapsamında bir motor görüntü algılama mekanizması ve bir P300 potansiyel algılama mekanizması tasarlanmıştır. Mekanizma; özel olarak hazırlanan bir grafik kullanıcı ara yüzünde, imlecin yatay ve dikey hareketlerini sırasıyla, eş zamanlı ve bağımsız olarak kontrol etmek için kullanabilecekleri şekilde tasarlanmıştır. Araştırmacılar tarafından 22-30 yaşları arasında 1 bayan ve 5 bay ile

gerçek zamanlı denemeler yapılmıştır. Sınıflandırıcı olarak DVM kullanılmıştır. Sonuç olarak %84.5-%97.5 aralığında başarım oranları elde edilmiştir. Ayrıca araştırmacılar sistemlerinin keyfi pozisyonlar arasında imlecin hareket etmesine izin vermesi bakımından önceki sistemlere göre üstün olduğunu savunmuşlardır.

Minho Kim ve ark (2013), göz izleme ve beyin işaretlerini kullanan, aynı zamanda düşük maliyetli bir hibrid ara yüzün geliştirilmesi amaçlanmıştır. Göz izleme görevleri için göz hareketinin algılanması, seçim görevi için EEG tabanlı BBA kullanılmıştır. Görev, her kullanıcının 12 olası pozisyon arasında dairesel bir hedef üzerine bir imleci hareket ettirmesi ve seçmesi işlemidir. Çalışmada Fitts yasası kullanılmıştır ve elde edilen başarım bilgisayar faresi ile karşılaştırılmıştır. Sınıflandırıcı olarak DVM sınıflandırıcı seçilmiştir. Çalışma sonunda, %78.33-%96.67 aralığında performans elde edilmiştir.

Genel olarak yapılan literatür çalışmasında, imleç hareketlerine ilişkin uygulamaların birbirine benzer yapıda olduğu görülmektedir. Diğer bir deyişle, izlenen paradigma sonunda elde edilen EEG işaretlerinin öznitelikleri elde edilir ve sınıflandırma işlemine tabii tutulur. Bu tez kapsamında, BCI-2003 dataset-Ia veri seti kullanılarak, başarım performansının artırılması hedeflenmiştir. Bu çalışma kapsamında; ayrık dalgacık dönüşümü (ADD) ile elde edilen katsayılara uygulanan istatistiksel işlemler ile öznitelikler elde edilmiştir. Bu öznitelikler, DVM ve k-NN algoritmaları ile sınıflandırılmıştır.

2. KAYNAK ÖZETLERİ

3. MATERYAL VE METOT

Bu çalışmada görsel geri besleme destekli kaydedilen aşağı-yukarı imleç hareketlerine ilişkin EEG kayıtlarının sınıflandırılması amaçlanmıştır. Bu amaç için kullanılan veri setinin ve sınıflandırma için kullanılan yöntemlerin detayları bu bölümde açıklanmıştır.

3.1 Veri Seti

Bu çalışmada kullanılan veri kümesi, "BCI Competition 2003" yarışması için sunulmuştur. Veriler; Almanya Tubingen Üniversitesinde sağlıklı bir kişiden bir bilgisayar ekranında imleci yukarı-aşağı hareket ettirmesi istenilerek, Yavaş Kortikal Potansiyeller (Slow Cortical Potentials, SCP) kayıt edilerek elde edilmiştir. Kişilere dikey göz hareketlerine bağlı olarak görsel geri besleme verilmiştir. Kortikal pozitiflik aşağı imleç hareketine (AİH) ve negatiflik ise yukarı imleç hareketine (YİH) karşılık gelmektedir. Çalışmada 10-20 elektrot sistemine göre elektrotlar bağlanmıştır. Cz referans alınarak A1, A2, FC3, CP3, FC4 ve CP4 olacak şekilde 6 elektrottan elde edilen EEG kayıtları kullanılmıştır. Kullanılan kanallar ve kanal etiketleri, Tablo 3.1.'de gösterilmiştir. Bu kanalların 10-20 sistemindeki konumları ise Şekil 3.1.'de gösterilmiştir.

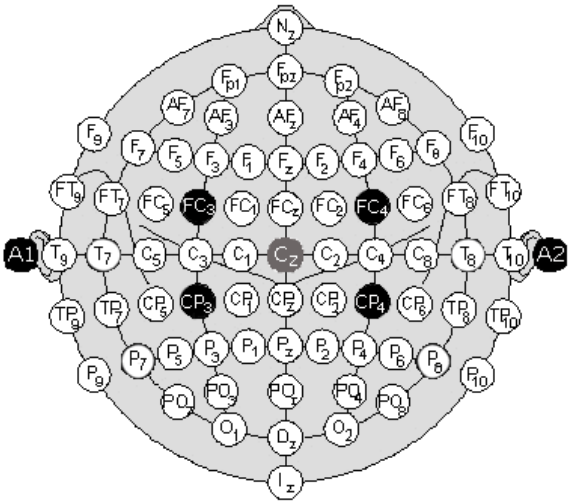
Tablo 3.1. EEG kanal numaraları ve etiketleri

Kanal No	Kanal Etiketi
1	A1
2	A2
3	FC3
4	CP3
5	FC4
6	CP4

Kayıt esnasında izlenilen paradigma adımları aşağıda açıklanmıştır.

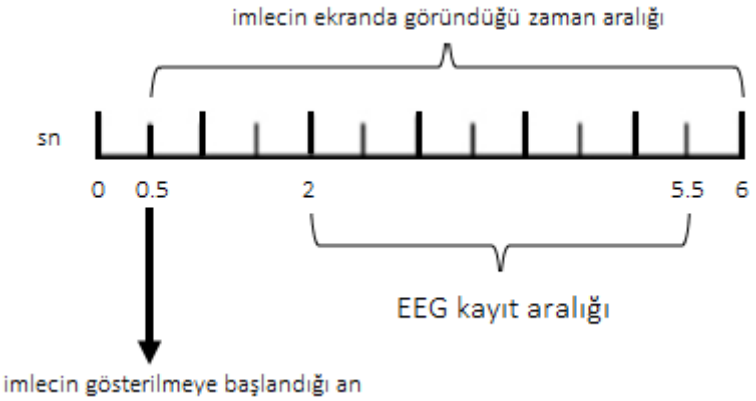
1. Kullanıcıdan ekrana bakması istenir ve süre başlatılır.
2. 0.5s - 6.0s aralığında imleç hareketi ekrana yansıtılır.
3. Görsel geri besleme 2.0s - 5.5s aralığında olduğundan, değerlendirilen veriler bu 3.5 saniyelik verilerdir.

Örnekleme frekansı 256 Hz. ve veri süresi 3.5s olduğundan örnek sayısı 896'dır (örnek sayısı/kanal).



Şekil 3.1. Uluslararası 10-20 sistemine göre ilgili veri setinde kullanılan elektrotlar (Aydemir 2008)

Bir denemede yukarı veya aşağı imleç hareketine ilişkin EEG kaydının alınma süreci, Şekil 3.2.'de gösterilmiştir.



Şekil 3.2. İmleç hareketine ilişkin EEG kaydında izlenilen zaman akışı

268 denemeden oluşan eğitim verileri 2 farklı günde (1. gün 168 deneme, 2.gün 100 deneme) kayda alınmış ve rastgele karıştırılmıştır. 135 deneme imleç yukarı ve 133 deneme imleç aşağı yönlü EEG kayıtlarıdır. Test veri kümesi ise 293 denemeden oluşmuş ve bu veriler de rastgele karıştırılmıştır. Bunların da 146 adedi imleç aşağı ve 147 adedi imleç yukarı yönlü işaretleri temsil etmektedir (Benjamin B. ve ark.). Sözü edilen veri seti ile ilgili detaylı bilgiye aşağıda belirtilen web sayfası aracılığıyla ulaşılabilir.

http://bbci.de/competition/ii/tuebingen_desc_i.html Erişim tarihi: (02.09.2016)

3.2 Dalgacık Dönüşümü (DD)

Dalgacıklar, işaretlerin matematiksel olarak bir takım kurallar dâhilinde ifade edilmesinde kullanılan fonksiyonlardır. Dalgacık Dönüşümü (DD) metodu özellikle durağan olmayan işaretlerin analizinde oldukça sık kullanılır.

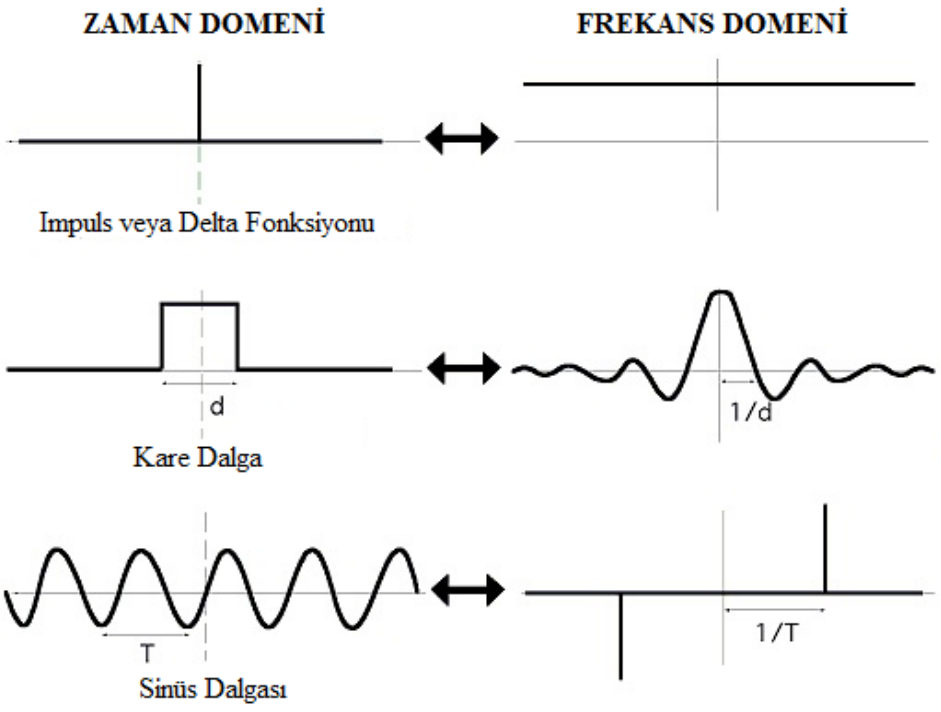
İşaret analizi yapılırken zaman alanındaki bilgilerin yeterli olmadığı durumlarda frekans analizi de yapılır. Zaman alanında kaydedilen işaretin frekans alanında incelenmesi için Fourier Dönüşümü (FD) kullanılır.

İşaret işleme, haberleşme ve biyomedikal işaret analizi gibi alanlarda faydalı bir metot olarak kullanılan DD algoritmasını anlayabilmek için durağan işaretlerin analizinde kullanılan Fourier Dönüşümüne değinmek gerekmektedir.

3.2.1 Fourier Dönüşümü (FD) ve Kısa Zamanlı Fourier Dönüşümü (KZFD)

FD; bir takım sinüsoidal fonksiyonların toplamından oluştuğu düşünülen bir f(t) fonksiyonunu bileşenlerine ayırıp her bileşenin genliğinin bulunması esasına dayanır.

FD ile zaman bölgesindeki bir işaretin frekans bölgesindeki karşılığı elde edilir. Bu ifadenin tam tersi de geçerlidir. En temel bazı fonksiyonların zaman-frekans domeni karşılıkları Şekil 3.3.'te gösterilmiştir.



Şekil 3.3. En temel bazı işaretlerin zaman ve frekans alanındaki dönüşümleri

FD çifti denklemleri (3.1) ve (3.2)'de gösterilmiştir.

$$F(jw) = \int_{-\infty}^{\infty} x(t)e^{-(j\omega t)}\mathrm{dt} \tag{3.1}$$

$$x(t) = \int_{-\infty}^{\infty} F(jw)e^{(j\omega t)}\mathrm{dw} \tag{3.2}$$

FD sırasında kullanılan taban fonksiyonların sınırsız olmasından ötürü zaman alanındaki işaret frekans alanına dönüştürülürken zaman ile ilgili bilgi kaybolur. İşaretin zaman bilgisi kaybolduğundan ötürü FD durağan olmayan işaretlerin analizinde yetersiz kalır. Zaman bilgisinin kaybolması durağan işaretler için sorun oluşturmazken durağan olmayan işaretler için aynı durum söz konusu değildir. Bu olumsuzluğu gidermek amacıyla pencereleme işlemi ile işaret bölütlere ayırılır ve pencereler içindeki kısımlar durağan kabul edilerek her bölüt için FD uygulanır. Pencere fonksiyonu zamanda ötelenerek her pencere için işlem tekrar edilir. Bu şekilde tüm zaman ekseninde işaret incelenmiş olur. İlk olarak Gabor tarafından önerilen ve pencereleme fonksiyonu Gauss olarak seçilen bu yöntem Kısa Zamanlı Fourier dönüşümü (KZFD) olarak isimlendirilir [(Altınbaş 2007), (Erişti 2010)].

Durağan olmayan bir x(t) işareti için KZFD, matematiksel olarak denklem (3.3) deki şekilde ifade edilir.

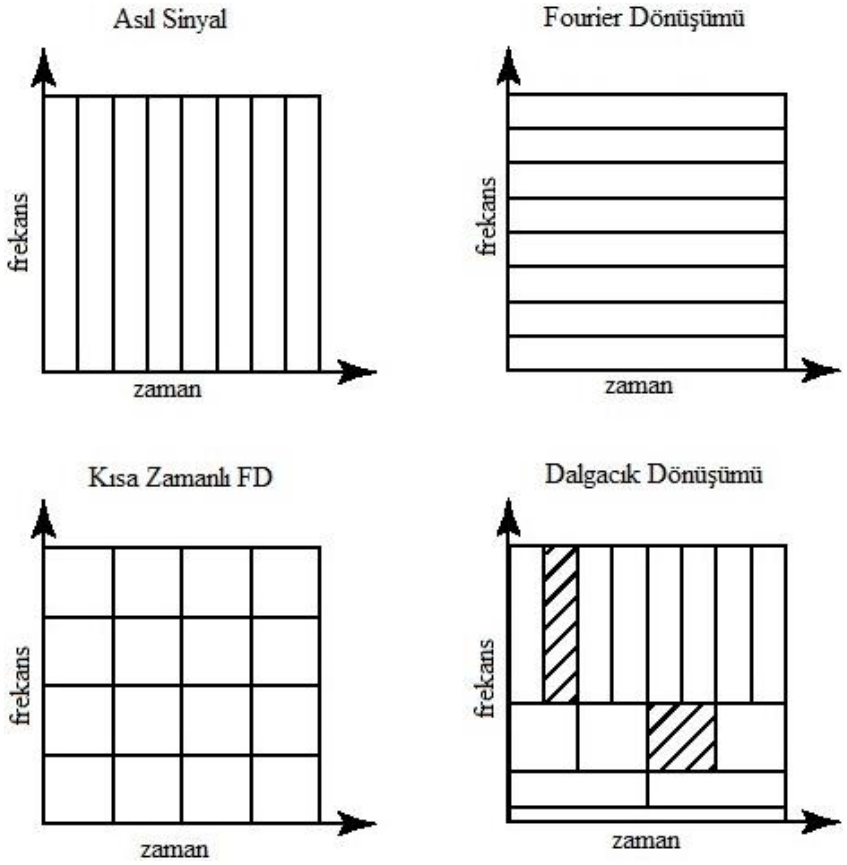
$$KZFD(t,f) = \int_{-\infty}^{\infty} x(t)w(t-\tau)e^{-(j\omega t)}\mathrm{dt} \tag{3.3}$$

Burada *w(t-τ)* zamanda kayan pencereleme fonksiyonunu ifade eder. En çok bilinen pencereleme fonksiyonları: Barlet, Blackman, Chebyshev, Hanning, Hamming, Kaiser, Dikdörtgen ve Üçgen fonksiyonlarıdır.

FD sadece frekansın bir fonksiyonudur, frekans domeninin tamamı hakkında bilgi verdiğinden frekans alanında çözünürlük problemiyle karşılaşılmazken zaman bilgisi tamamen kaybolur. KZFD hem frekansın hem de zamanın bir fonksiyonudur ve zaman alanında pencere uzunluğu sabittir. Bu da çözünürlüğün detaylı olmasına engel teşkil eder. Tersi durumda ise frekans alanında çözünürlük artarken zamanda çözünürlük azalır.

Bu sorunların giderilmesi amacıyla, zamanda değişken çözünürlük veren DD geliştirilmiştir [(Altınbaş 2007), (Erişti 2010)].

FD, KZFD, DD arasındaki Zaman-Frekans-Çözünürlük ilişkisi Şekil 3.4.'teki grafiklere bakılarak daha iyi anlaşılabilir.



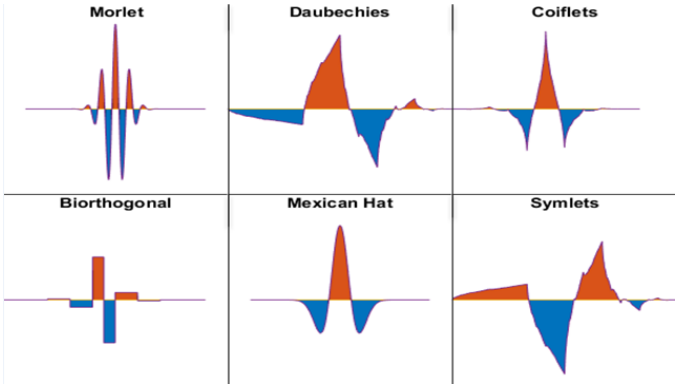
Şekil 3.4. FD, KZFD ve DD arasındaki Zaman-Frekans-Çözünürlük ilişkisi

3.2.2. Dalgacık Modeli

Adından da anlaşılacağı üzere Dalgacık küçük dalga anlamına gelir ve basit bir ifade ile işareti belirli frekans ve zaman aralığında incelemeye yarayan faydalı bir araçtır. Dalgacık analizi ile FD alt bileşenlerine ayırılması bakımından benzerlik gösterir. FD işareti farklı frekanslardaki sinüs ve kosinüs bileşenlerine ayırır. Dalgacık analizinde ise seçilen dalgacığın ölçeklenip kaydırılarak alt dalgacıkların elde edilmesi söz konusudur.

Dalgacıkların düzensiz yapısı sayesinde, süreksiz ve keskin geçişlere sahip işaretlerin analizi sağlanırken öz yapıları sayesinde de işaretlerin zamana bağlı özelliklerin belirlenmesi de kolaylaşır.

Sık kullanılan dalgacık modellerinden bazıları Şekil 3.5.'te gösterilmiştir.



Şekil 3.5. Sık kullanılan bazı dalgacık modelleri

FD de frekans bölgesindeki en ufak değişiklik tüm zaman boyunca değişikliğe neden olmaktadır. FD'nin tersine, DD ana dalgacığın kaydırılmasıyla zaman bölgesinde, ana dalgacığın ölçeklendirilmesiyle de frekans bölgesinde yerinin belirlemesine izin verir (Aygün 2006).

Bir modelin dalgacık olarak kullanılabilmesi için, denklem (3.4) ve (3.5)'te belirtilen koşulları sağlaması gerekmektedir.

$$\int_{-\infty}^{\infty} \varphi(x)dx = 0 \tag{3.4}$$

$$\int_{-\infty}^{\infty} \varphi(x)^2 dx = 1 \tag{3.5}$$

Diğer bir deyişle, bir modelin dalgacık olarak kullanılabilmesi için fonksiyonun zamanda sınırlı ve eksi sonsuz ile artı sonsuz sınırlarında integralinin sıfır olması gerekmektedir. Yine aynı sınırlarda fonksiyonun karesinin integrali bire eşit olmalıdır.

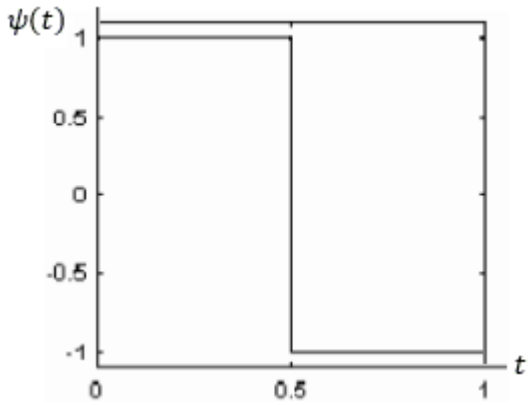
Yukarıdaki şartları sağlayan farklı dalgacık modelleri geliştirilmiştir. İncelenecek işaretin özelliklerine göre en uygun dalgacık modeli kullanılabilir. Çeşitli uygulamalar için sık kullanılan dalgacıklar aşağıda bağıntıları ile birlikte açıklanmıştır.

Haar Dalgacığı; Alfred Haar tarafından geliştirilen, kare dalga şeklinde ve bilinen en basit dalgacık modelidir. Matematiksel ifadesi (3.6) ve (3.7)'deki gibidir.

$$\Phi(t) = \begin{cases} 1 & 0 \le t \le 1; \\ 0 & diğer; \end{cases} \tag{3.6}$$

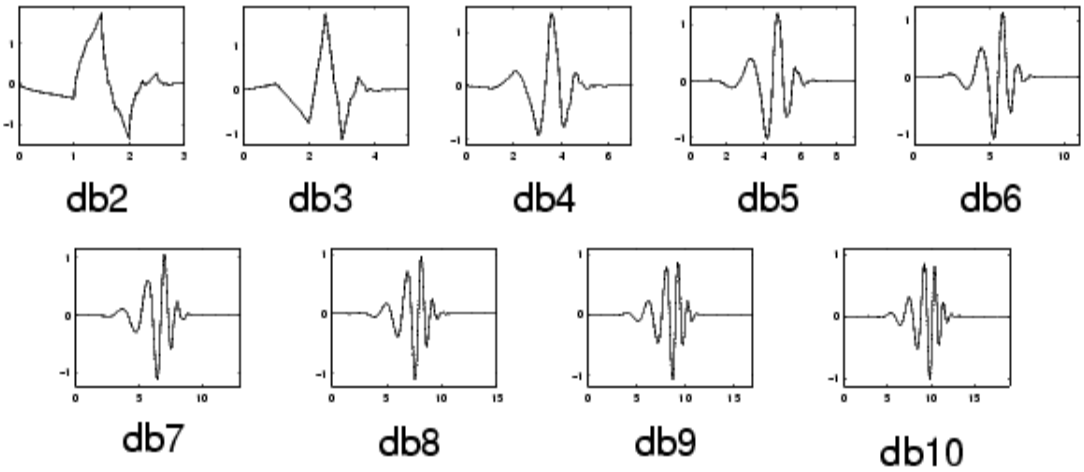
$$\Psi(t) = \begin{cases} 1 & 0 < t \le \frac{1}{2}; \\ -1 & \frac{1}{2} < t \le 1; \\ 0 & diğer; \end{cases} \tag{3.7}$$

Φ(t) Haar ölçekleme fonksiyonu ψ(t) ise Haar dalgacığıdır. Haar dalgacık modeli grafiksel olarak Şekil 3.6.'da gösterilmiştir.



Şekil 3.6 Haar Dalgacığı

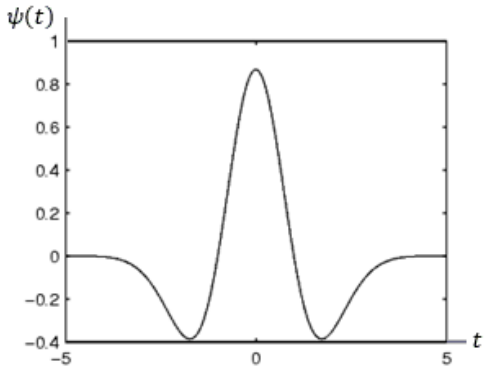
Daubechies Dalgacığı; Daubechies modeli bir dalgacık ailesi modelidir. db1 dalgacığı şekli ve matematiksel ifadesi Haar Dalgacığı ile aynıdır. Diğer dalgacıkların (db2, db3,….,db10) grafiksel gösterimi Şekil 3.7.'de ve matematiksel ifadesi (3.8)'deki gibidir. Daubechies ailesi dalgacık modeli EEG işaretlerinin incelenmesinde sıklıkla kullanılır. Bu tez çalışmasında da 'db3' dalgacık modeli kullanılmıştır.



Şekil 3.7 Daubechies Dalgacık Ailesi (x ekseni zamanı, y ekseni ise ana dalgacığın $\psi(t)$ genliğini ifade eder)

$$c_i = h_0 s_{2i} + h_1 s_{2i+1} + h_2 s_{2i+2} + h_3 s_{2i+3} \quad (3.8)$$

Meksika Şapkası Dalgacığı; Adını Meksika şapkasına benzemesinden ötürü almıştır. Matematiksel ifadesi (3.9), grafiksel gösterimi Şekil 3.8.'da gösterilmiştir.



Şekil 3.8 Meksika Şapkası Dalgacığı

$$\psi(x) = \left(\frac{2}{\sqrt{3}}\pi^{-\frac{1}{4}}\right)(1-x^2)e^{-\frac{x^2}{2}} \tag{3.9}$$

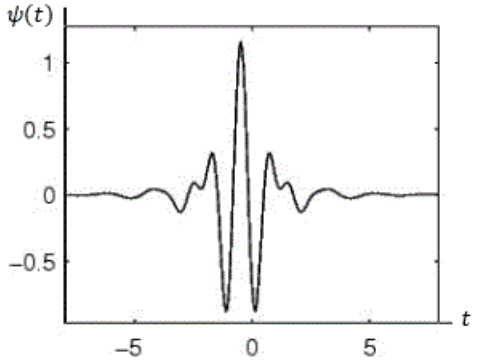
Meyer Dalgacığı; Matematiksel (3.10), (3.11), (3.12) 'deki formüllerle ifade edilebilir. Grafiksel olarak Şekil 3.9.'daki gibi gösterilebilir.

$$v(t) + v(1-t) = 1 \tag{3.10}$$

$$v(t) = \begin{cases} 0 & t \leq 0 \\ 1 & t \geq 1 \end{cases} \tag{3.11}$$

Koşulunun sağlandığı durumda;

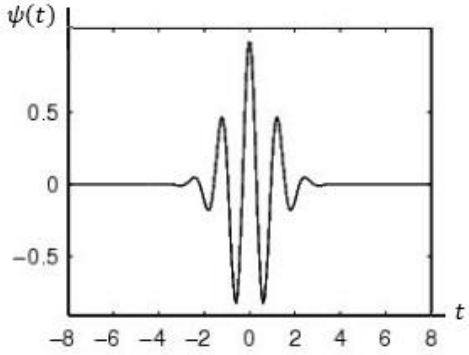
$$\Phi(\omega) = \begin{cases} 1 & |\omega| \leq \frac{2\pi}{3} \\ cos\left[\frac{\pi}{2}v(\frac{3}{4\pi}|\omega| - 1)\right] & \frac{2\pi}{3} \leq |\omega| \frac{4}{3} \\ 0 & diğer \end{cases} \tag{3.12}$$



Şekil 3.9. Meyer Dalgacığı

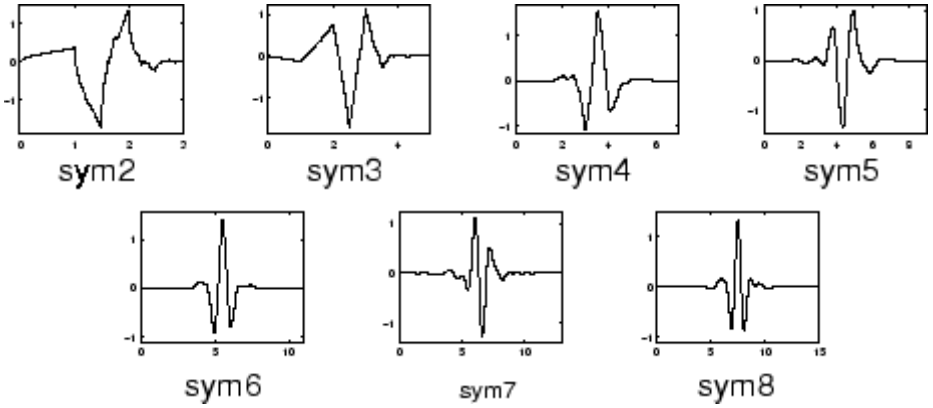
Morlet Dalgacığı; Matematiksel ifadesi (3.13) 'te, grafiksel gösterimi Şekil 3.10.'da görüldüğü gibidir.

$$\psi(x) = Ce^{-\frac{x^2}{2}}.cos5x \tag{3.13}$$



Şekil 3.10. Morlet Dalgacığı

Symlet Dalgacığı; Daubechies dalgacık ailesinin değişmiş hali olarak Daubechies ile desteklenen simetrik dalgacık yaklaşımıdır. Grafiksel gösterimi Şekil 3.11.'deki gibidir.



Şekil 3.11. Symlet Dalgacık Ailesi (x ekseni zamanı ve y ekseni ise $\psi(t)$ genliğini ifade eder)

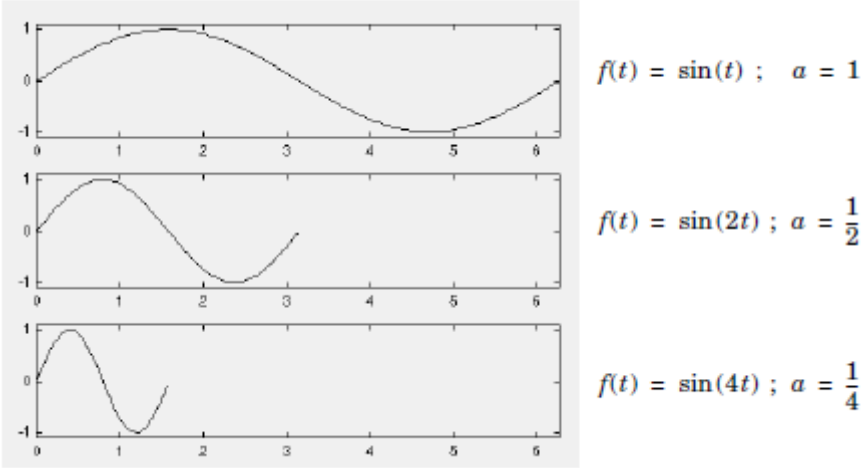
3.2.3. Sürekli Dalgacık Dönüşümü (SDD)

Sürekli dalgacık dönüşümü (SDD), seçilen dalgacığın bütün zaman aralığı boyunca ölçeklenmiş ve kaydırılmış şekliyle işaretin çarpımından oluşur. SDD sonuncunda birçok dalgacık katsayısı elde edilir. Bu katsayılar ölçek ve zamanın bir fonksiyonudur (Tepe 2009). SDD matematiksel olarak (3.14)'teki gibi ifade edilir.

$$SDD(a,u) = \frac{1}{\sqrt{|a|}} \int_{-\infty}^{+\infty} x(t)\Psi\left(\frac{t-u}{a}\right) dt \tag{3.14}$$

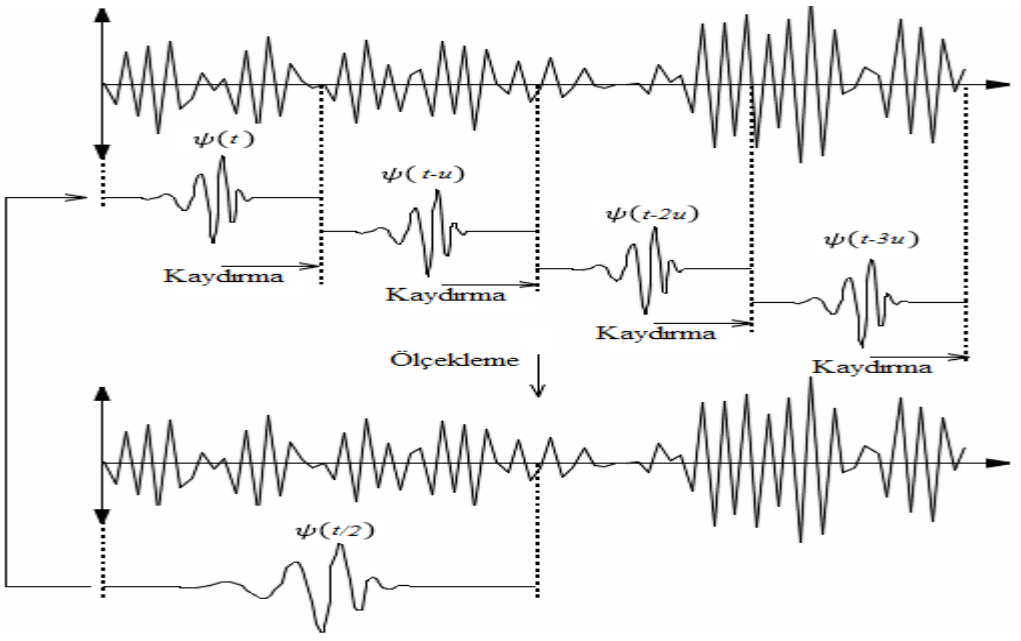
Eşitlikteki (u) öteleme parametresini ve (a) ise ölçekleme parametresini ifade eder. Ψ(t) ise seçilen dalgacığı temsil eder.

Bir dalgacığın ölçeklenmesi basit ifadeyle işaretin sıkıştırılması veya genişletilmesidir. Ölçekleme parametresi genel olarak *a* ile ifade edilir. Sinüsoidal bir işaretin farklı *a* ölçeklerine göre grafiksel gösterimi Şekil 3.12.'de gösterilmiştir.



Şekil 3.12. Sinüs fonksiyonunun ölçeklenmesi (Misiti ve ark. 1996)

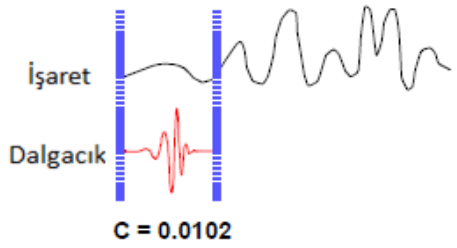
Bir dalgacığın kaydırılması, basit bir ifade ile geciktirilmesi olarak anlaşılabilir. Şekil 3.13.'te db7 dalgacık modelinin ötelenmesi ve ölçeklenmesi gösterilmiştir.



Şekil 3.13. db7 dalgacık modelinin zamanda ötelenmesi ve ölçeklenmesi (Aygün 2006)

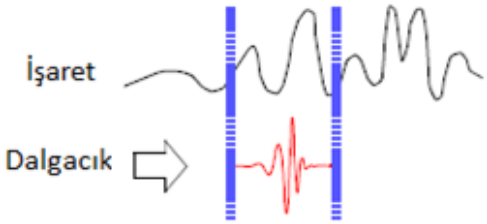
SDD işlem adımları aşağıda listelenmiştir.

1. Seçilen dalgacık işaretin başlangıcı ile karşılaştırılır.
2. Karşılaştırma sonucunda dalgacığın işaret ile benzerliğini belirten bir C katsayısı hesaplanır. C katsayısının büyüklüğü benzerlik ile doğru orantılıdır. Başka bir ifade ile işaret enerjisi ve dalgacık enerjisi 1 değerine eşit ise, C bir korelasyon katsayısı olarak yorumlanabilir. Örnek bir hesap şekil 3.14'te gösterilmiştir.



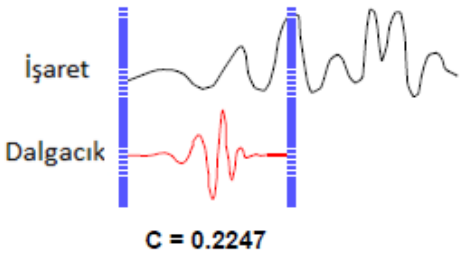
Şekil 3.14 Dalgacığın orijinal işaretin ilk kısmıyla karşılaştırılması (Misiti ve ark. 1996)

3. Dalgacık sağa kaydırılır ve ilk iki adım işaret boyunca tekrar edilir. İşaretin sağa kaydırılması işlemi, Şekil 3.15'te görülmektedir.



Şekil 3.15. Dalgacığın kaydırılarak karşılaştırılması (Misiti ve ark. 1996)

4. İşaret ölçeklenir (genişletilir veya sıkıştırılır) ve ilk üç adım tekrar edilir. Şekil 3.16.'da işaret genişletilirken elde edilen değişim görülmektedir.



Şekil 3.16. Dalgacığın yeniden ölçeklenmiş halinin işaretle karşılaştırılması (Misiti ve ark. 1996)

5. İlk dört adım tüm ölçekler için tekrarlanır.

Adımlar tamamlandığında işaretin farklı kısımlarına ait farklı ölçeklerde farklı SDD katsayıları elde edilmiş olacaktır.

Yüksek ölçek, genişletilmiş dalgacık ile elde edilir ve işaretteki yavaş değişimi saptar. Diğer bir deyişle düşük frekans bileşenlerini belirler. Düşük ölçek ise sıkıştırılmış dalgacık ile elde edilir ve işaretteki hızlı değişimleri saptar. Diğer bir deyişle yüksek frekans bileşenlerini belirler.

3.2.4. Ayrık Dalgacık Dönüşümü (ADD)

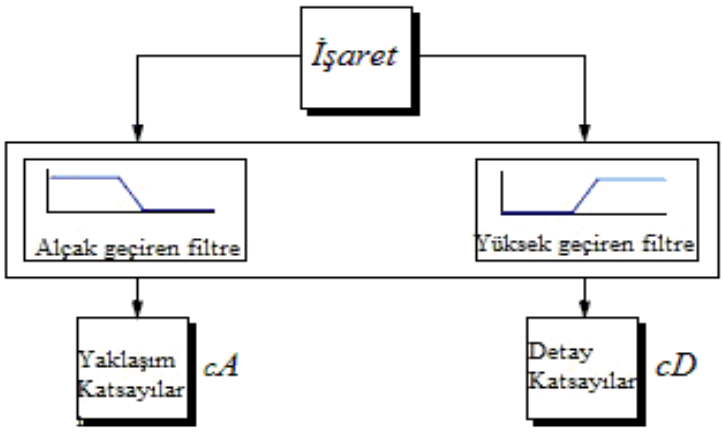
SDD'de, dalgacık katsayılarının tümünü her ölçek için hesaplamak yoğun iş yüküne ve aşırı miktarda veri yığınlarının oluşmasına neden olur. Bu olumsuzlukları gidermek amacıyla ADD geliştirilmiştir. ADD yöntemi işaretin öteleme ve ölçekleme parametreleri belli bir basamağa göre seçilerek uygulanır. Matematiksel ifadesi denklem (3.15)'te verilmiştir.

$$a = 2^j, b = k2^j \; ve \; k \in \mathrm{Z}$$

$$C_{(j,k)} = \sum x[n].\, 2^{-\frac{1}{2}} g\left(\left(2^{-j}\right)n - k\right) \qquad (3.15)$$

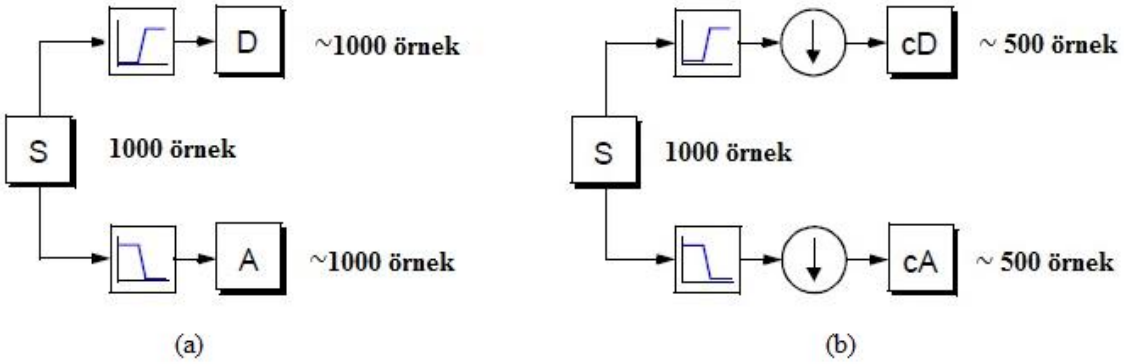
Birçok işaret için düşük frekans içeriği işaretin en önemli kısmıdır. İşaretin düşük frekans içeriği işaretin kimliğini belirler. Öte yandan yüksek frekanslarda da kayda değer belirleyici bilgiler vardır. İnsan sesini örnek vermek gerekirse; yüksek frekans bileşenlerinin silinmesi durumunda ses farklılaşır ancak hâlâ anlaşılır durumdadır. Düşük frekans bilgilerinin silinmesi durumunda ise ses anlaşılmaz hale dönüşür. Bu sebepten ötürü DD analizinde *yaklaşım* ve *detay* bileşenlerinden bahsedilir.

Yaklaşım bileşenleri (A); yüksek ölçekli ve düşük frekanslı bileşenlerdir.
Detay bileşenleri (D); düşük ölçekli ve yüksek frekanslı bileşenlerdir.



Şekil 3.17. ADD'de filtreleme (Misiti ve ark. 1997)

Orijinal işaret alçak ve yüksek geçiren filtrelerden geçirilerek 2 işarete dönüşür (Şekil 3.17). Bu işlem gerçek bir işarete uygulanırsa elde edilen 2 işaretin her birinin veri miktarı başlangıçtaki işaret kadar olacak ve veri 2 katına çıkmış olacaktır. Bu sorunu gidermek için "aşağı örnekleme" işlemi kullanılır. Şekil 3.18.'de aşağı örnekleme yapılmadan ve yapılarak elde edilen bileşenlerin uzunlukları gösterilmiştir.



Şekil 3.18. (a) İşaret filtrelendikten sonra elde edilen bileşenlerin uzunluğu **(b)** İşaret filtrelendikten sonra aşağı örnekleme ile oluşan bileşenlerin uzunluğu (Misiti ve ark. 1997)

Aşağı örnekleme işlemi sonrası, ölçek iki katına çıkarken çözünürlük yarıya düşer. ADD yönteminde, f[n] gerçek işaret olmak üzere;

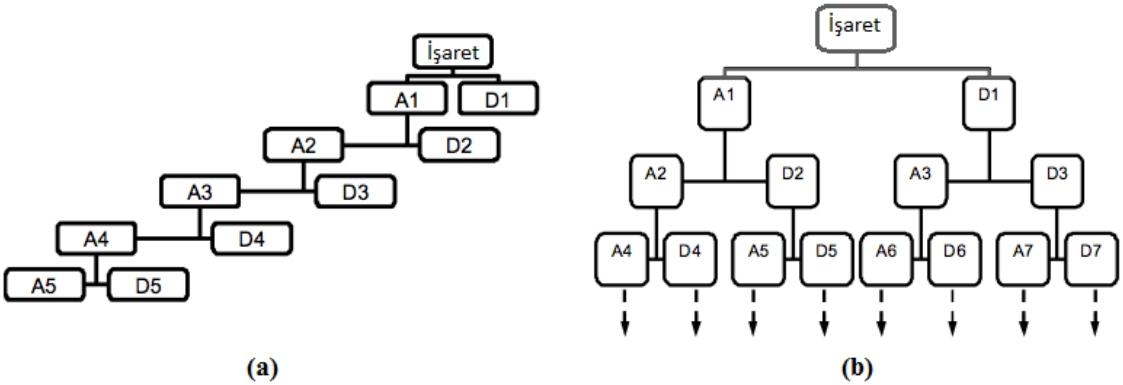
$$cD1 = \sum_{-\infty}^{+\infty} f[n].\, g[2n-k] \tag{3.16}$$

$$cA1 = \sum_{-\infty}^{+\infty} f[n].\, h[2n-k] \tag{3.17}$$

şeklinde ifade edilir. f[n] yüksek geçiren filtreden geçirilerek yaklaşım (cA1), alçak geçiren filtreden geçirilerek detay (cD1) katsayıları elde edilir.

Ayrıştırma işlemi tekrarlanarak sürdürülebilir. Böylece işaret belirli aralıklardaki düşük frekans bileşenlerine ayrıştırılabilir. Bunun sonucunda Şekil 3.19. (a)'daki "dalgacık ayrıştırma ağacı" elde edilmiş olur.

Dalgacık ayrıştırma ağacı daha geniş açıdan ele alınarak işaretin tüm ayrıştırma seviyelerindeki tüm frekans bandı analiz edilebilir. Detay bileşenlerin ikiye ayrılmasıyla uygulanan bu yöntem "dalgacık paket analizi" olarak isimlendirilir (Şekil 3.19. (b)).



Şekil 3.19. (a) Dalgacık ayrıştırma ağacı **(b)** Dalgacık paketi analizi

3.3. k-En Yakın Komşuluk (k-NN) Algoritması

Günümüzdeki veri boyutlarının fazlalığı göz önüne alındığında analistler için verilerden kısa sürede anlamlı sonuçlar çıkarmak neredeyse imkânsız hale gelmiştir. Bu nedenle, veri değerlendirme sürecini otomatikleştirmek ve rasgele ham veri setlerinin benzerliklerini keşfetmek için bir takım algoritmalar geliştirilmiştir.

k-NN parametrik olmayan ve basit bir öğrenme algoritmasıdır. Parametrik olmayan bir algoritma olmasının getirisi olarak, temel veri dağılımında herhangi bir varsayım yapmaz. Bu önemli bir avantajdır. Çünkü pratik verilerin çoğu yapılan teorik varsayımlara uymaz. Ayrıca k-NN genelleme yapmak için eğitim verilerini kullanmaz. Yani, eğitim aşaması oldukça hızlıdır. k-NN tüm eğitim verilerini korur ve eğitim veri setine dayanarak karar verir. (Anchalia 2014) k-NN bilinmeyen bir nesne ile eğitim kümesinin her bir nesnesi arasındaki mesafelerin belirlenmesine dayanır.(Berrauta 2007)

k-NN yönteminin özellikleri aşağıda listelenmiştir.

i. kNN verilerin özellik uzayında olduğunu varsayar. Dahası verileri metrik uzayında değerlendirir.

ii. Veriler, skalar veya çok boyutlu vektörler şeklindedir. Noktalar özellik uzayında olduğundan, bir mesafe kavramı vardır. Bu mesafenin hesaplanmasında Minkowski, Euclidean, Mahalanobis, Chebyshev, Cosine, Manhattan, Hamming, Canberra, Bray-Curtis, Relative Deivation, Square Chord gibi farklı yöntemler kullanılır. Bunlardan en sık kullanılanların matematiksel ifadeleri denklem (3.18), (3.19) ve (3.20)'de gösterilmiştir (Khadidja 2015).

Minkowski; genelleştirilmiş bir mesafe hesaplama yöntemidir. Matematiksel olarak (3.18)'deki denklemle ifade edilir.

$$D_{Min}(x,y) = \left(\sum_{i=1}^{n} |x_i - y_i|^p\right)^{\frac{1}{p}} \tag{3.18}$$

Eculidean; Minkowski ölçütünün özel bir hali p=2 olarak ayarlanmasıyla edilir. Matematiksel olarak (3.19)'daki denklemle ifade edilir.

$$D_{L2}(x,y) = \sqrt{\sum_{i=1}^{n} (x_i - y_i)^2} \tag{3.19}$$

Manhattan; Minkowski ölçütünün özel bir hali p=1 olarak ayarlanmasıyla edilir. Matematiksel olarak (3.20)'deki denklemle ifade edilir.

$$D_{Man}(x,y) = \sum_{i=1}^{n} (|x_i - y_i|) \tag{3.20}$$

iii. k-NN; eğitim verilerini, test verileri kümesi olarak adlandırılan yeni veri noktalarını sınıflandırmak için referans olarak kullanır.

iv. Eğitim verilerinin her biri bir vektör kümesinden ve her vektörle ilişkili sınıf etiketinden oluşur. En basit durumda + veya - (pozitif veya negatif sınıflar için) gibi 2 sınıf söz konusudur. Fakat k-NN, rasgele sayıdaki sınıflarla eşit derecede çalışabilir.

v. Son olarak kaç adet komşunun (komşulukların mesafe kavramına göre belirlendiği) olduğunu refere eden bir "k" sayısı verilir. Sınıfların sayısı 2 ise, genellikle tek sayılıdır. Eğer k = 1 ise, algoritma basitçe en yakın komşuluk algoritması olarak adlandırılır (Anchalia 2014).

3.3.1. k-NN Algoritmasının Eğitim – Test Aşamaları

k-NN algoritması, sınıflandırılacak veriler için herhangi bir eğitim aşamasına ihtiyaç duymaz. Eğitim aşamasında veri vektör koordinatlarının sınıf etiketi ile birlikte saklanması gerekir. Genelde sınıf etiketi, veri vektörünün tanımlayıcısı olarak kullanılır. Bu, test aşamasında veri vektörlerini sınıflandırmak için kullanılır (Anchalia 2014).

Test için veri noktaları göz önüne alındığında, amaç yeni nokta için sınıf etiketini bulmaktır. Algoritma, k = 1 yani 1 En Yakın Komşu kuralı için uygulanır ve sonra k = k veya k- En Yakın Komşu kuralı için genişletilir.

a) 1-En Yakın Komşu Kuralı (k=1)

Bu yaklaşım, sınıflandırma için en basit senaryodur. 'x' etiketlenecek nokta olsun.

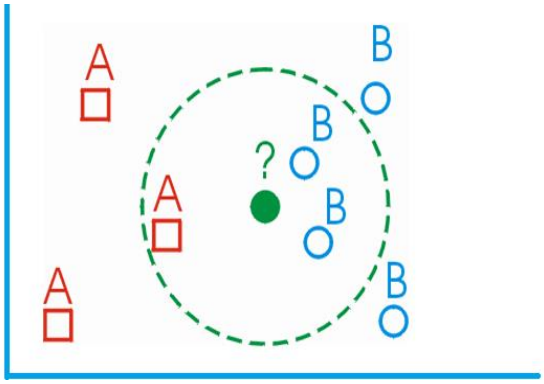
i. Eğitim verileri setinde 'x' ile en yakın nokta bulunur. Bu en yakın nokta 'y' olsun.
ii. Şimdi en yakın komşu kuralı 'y' etiketini 'x' olarak atamanızı ister.

Bu yaklaşım, veri noktalarının sayısı çok büyük olmadığı durumlarda kullanılır. Veri noktası sayısı çok büyükse, x ve y etiketlerinin aynı olma ihtimali çok yüksektir.

b) 3-En Yakın Komşu Kuralı (k=3)

Konunun anlaşılması için k=3 alınmış ve detayları aşağıda listelenmiştir.

i. İlk adımda eğitim verileri sınıflara atanır.
ii. Sınıflandırılacak yeni bir elemanın koordinatı belirlenerek tüm elemanlarla arasındaki mesafeler hesaplanır.
iii. Hesaplanan değerler sıralanır ve Şekil 3.20.'de kesik çizgilerle gösterilen daire içine giren ilk 3 komşusundaki oy çoğunluğuna göre sınıfı belirlenmiş olur.

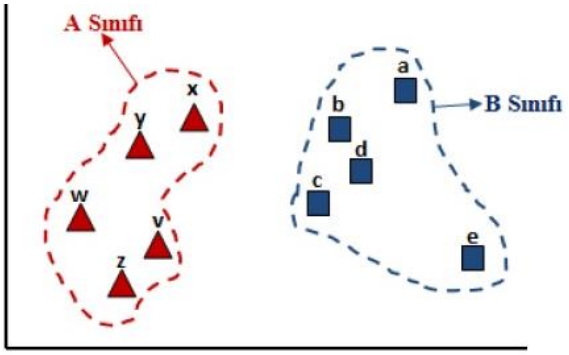


Şekil 3.20. k=3 için bilinmeyen bir nesnenin sınıflandırılması

c) k-NN Algoritmasının Genelleştirilmesi

i. Bir 'k' giriş değeri belirlenir.

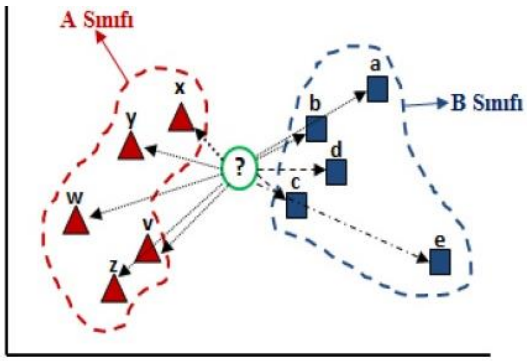
ii. Veri noktalarının koordinatları ve sınıf etiketleri depolanarak eğitim veri seti hazırlanır. Bu işlem Şekil 3.21.'de grafiksel olarak gösterilmiştir.



Şekil 3.21. Eğitim veri setinin sınıflarının belirlenmesi (Polat, H., 2016)

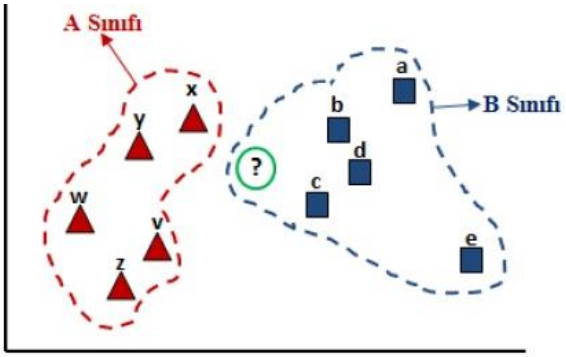
iii. Veri noktası test veri setinden yüklenir.

iv. Test verilerinin "k" en yakın komşuları arasında, bir mesafe metriğine dayalı eğitim verilerinden çoğunluk oylaması yapılır. Bu işlem Şekil 3.22.'de grafiksel olarak gösterilmiştir.



Şekil 3.22. Mesafe metriklerinin hesaplanması (Polat, H., 2016)

v. Oy çoğunluğunu elde eden sınıf etiketi test veri setinden yeni veri noktasına atanır. Bu işlem Şekil 3.23.'te grafiksel olarak gösterilmiştir.



Şekil 3.23. Bilinmeyen nesnenin atanması (Polat, H., 2016)

vi. Test aşamasındaki tüm Veri noktaları sınıflandırılana kadar bu işlem tekrarlanır.

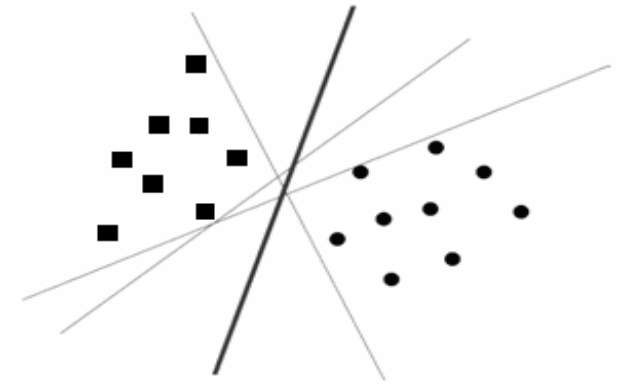
3.4. Destek Vektör Makinaları (DVM) Algoritması

DVM'ler ilk olarak Vapnik tarafından bulunan, parametrik olmayan ve bölüm 3.4.2.'de detayları verilen *yapısal risk minimizasyonu* prensibi esas alınarak uygulanan bir yöntemdir. İlk aşamada el yazısı tanıma, konuşmacı tanımlama, nesne ayırt etme, yüz tanıma ve yazı kategorizasyonu gibi örüntü tanımlama problemlerinin çözümünde kullanılmıştır. Sonradan zaman serisi tahminleri gibi regresyon analizi problemlerinde de kullanılmıştır [(Vapnik 1998), (Burges 1998)].

Gerçek dünya uygulamalarında pratik veriler çoğu zaman teorik varsayımlarla uyuşmaz. DVM parametrik olmamasından ötürü doğrusal olmayan giriş uzayı verilerini özellik uzayına dönüştürerek çözümü kolaylaştırır. Böylece karmaşık veri modellerini basitleştirir. Bu şekilde öğrenme teorisi ile pratiği için ortak bir nokta oluşturur. DVM basit fikirler üzerine kurulu bir algoritmadır ve yüksek performanslı pratik uygulamalarda kullanılabilir.

DVM, özellikle ikili sınıflandırma problemlerinde oldukça başarılıdır. Şekil 3.24.'te görüleceği üzere iki veri sınıfı arasında birçok doğrunun çizilebilme ihtimali vardır. Hata toleransını en düşük hale getirmek amacıyla çizilebilecek doğrular arasında her iki sınıfa en uzak mesafede olacak şekilde çizilen doğru bulunmalıdır. Eğitim kümesindeki verilerin her biri belirlenen iki sınıftan birine ait olacak şekilde etiketlenmiş olduğu varsayılır. DVM yöntemi kullanılırken amaç eldeki yeni verilerin bu iki sınıftan hangisine ait olduğunu ayırt edebilmektir. DVM; eğitim aşamasında, iki sınıfa ilişkin örneklerin arasındaki mesafeyi maksimum olacak şekilde, en iyi ayıran hiper düzlemi (karar fonksiyonunu) saptamaya çalışır. Bu aşamada esas olan, veri kümesini doğrusal

olmayan *çekirdek fonksiyonu* (bölüm 3.4.1) ile daha yüksek bir boyuta dönüştürmek ve sınıfları ayıracak hiper düzlemi oluşturmaktır (Yıldırım 2012).



Şekil 3.24. İki veri sınıfını ayıran optimum ayırıcı düzlemler

3.4.1. DVM'de Çekirdek Fonksiyonu

Özellik uzayındaki tüm işlemler, o uzayda skalarla ifade edilebilir. Özellik alanı dolaylı olarak, argümanlarının nokta çarpımına karşılık gelen girdi alanının iki öğesinin gerçek değerli bir fonksiyonu olan özellik uzayına eşlenmiş bir çekirdek işlevi üzerinden tanımlanır. Çekirdek işlevi genellikle çok verimli bir şekilde hesaplanabildiğinden, özellik uzayındaki tüm işlemler çekirdek kullanılarak gerçekleştirilir.

Çekirdek tabanlı algoritmalar oldukça esnektir. Bunun nedeni, algoritmanın hiper parametrelerden (öğrenme oranları ve düzenleme parametreleri gibi) bağımsız olması ve problem alanı değiştiğinde sadece çekirdek işlevinin değiştirilmesinin yeterli olmasıdır (Igel 1998).

En çok kullanılan çekirdek fonksiyonları (3.21), (3.22), (3.23), (3.24)'te matematiksel olarak ifade edilmiştir.

Polinomal çekirdek

$$K(x,y) = (x \times y + 1)^d \tag{3.21}$$

Sigmoidal çekirdek

$$K(x,y) = tanh(K(x,y) + \Phi \tag{3.22}$$

Radyal Tabanlı Fonksiyon (RBF) - çekirdek

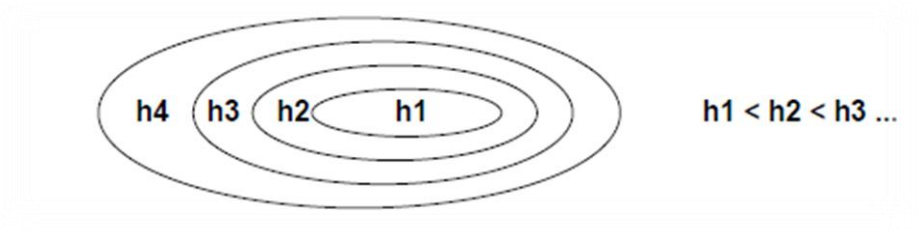
$$K(x,y) = exp(-\|x-y\|^2/2\sigma^2) \tag{3.23}$$

Lineer çekirdek

$$K(x,y) = x \times y \tag{3.24}$$

3.4.2. Yapısal Risk Minimizasyonu (YRM)

Vapnik'in Yapısal Risk Minimizasyonu (YRM) ilkesi, hesaplamalı öğrenme teorisine yeni bir ektir. Öğrenme makinesi, yaklaşım fonksiyonlarının karmaşıklıklarına göre sıralanmış Şekil 3.25.'teki gibi iç içe bir yapı oluşturur. YRM ilkesi, test hatasını en aza indirgemek için, verilen verilerin yakınlaştırma kalitesi ile yaklaşık fonksiyonun karmaşıklığı arasında bir dengelenmenin bulunması gerektiği düşüncesinden kaynaklanır. YRM ilkesi, bir dizi işlevin kapasitesini ölçmek için, Vapnik Chervonenkis Dimension (VC boyutu) kavramını kullanır. Beklenen riskin üst sınırını minimize etmek amaçlanır (Viswanathan 2004).



Şekil 3.25. VC boyutlarıyla sıralı iç içe geçmiş işlev altkümeleri

3.4.3. Doğrusal Destek Vektör Makinaları

Pratik uygulamalarda kullanılması pek kullanılmamakla birlikte DVM algoritmasının temelini inşa eder. Giriş verilerinin özellik uzayında karşılıklarının bulunmasına gerek yoktur. DVM ile sınıflandırmada amaç iki sınıfa ait örneklerin, eğitim verisi ile elde edilen bir karar fonksiyonu yardımıyla birbirinden ayrılmasıdır. Söz konusu karar fonksiyonu kullanılarak eğitim verisini en uygun şekilde ayırabilecek hiper-düzlem bulunur. Bu iki sınıfı birbirinden ayırabilen birçok hiper-düzlem çizilebilir. Ancak DVM kendisine en yakın noktalar arasındaki uzaklığı maksimuma çıkaran hiper-düzlemi bulmayı amaçlar. Bu amaç doğrultusundaki en uygun ayrımı yapan düzleme optimum hiper-düzlem ve sınır genişliğini sınırlandıran noktalara ise destek vektörleri denir (Duman 2013).

Giriş verilerini tam olarak ayırt eden hiper-düzlemin doğrusal olması durumudur. Sınıflar tüm elemanları ile birlikte hiper-düzlemin farklı taraflarındadır. DVM'nin eğitimi için n sayıda örnekten oluşan eğitim kümesi aşağıdaki şekilde olmak üzere,

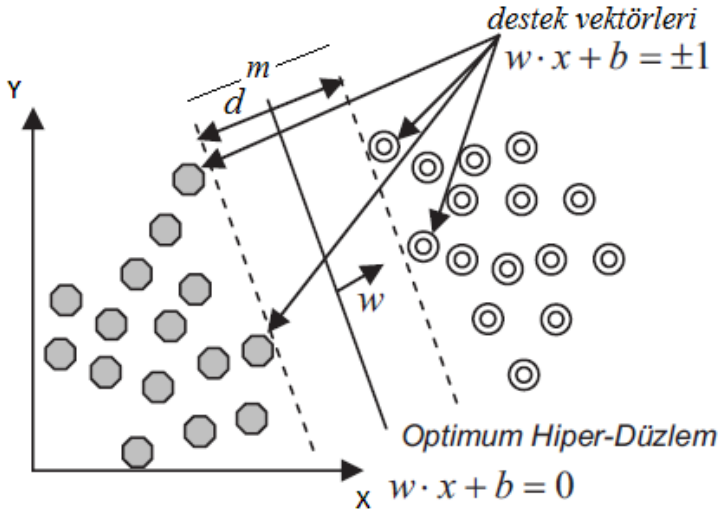
$$\{x_i, y_i\}\ i=1,..,n \text{ ve } y_i \in \{-1,+1\}$$

optimum hiper-düzleme ait eşitsizlikler (3.25) ve (3.26) da olduğu şekilde ifade edilir.

$$wx_i+b\geq+1 \quad \text{her} \quad y=+1\ için \tag{3.25}$$

$$wy_i+b\leq+1 \quad \text{her} \quad y=-1\ için \tag{3.26}$$

Burada $x \in R^N$ olup N-boyutlu bir uzayı, $y \in \{-1,+1\}$ olup sınıf etiketlerini, w ağırlık vektörünü, b eğilim değerini ifade eder. $wx + b = 0$ koşulunun sağlandığı durumdaki düzlem optimum hiperdüzlem olarak adlandırılır. Optimum hiper-düzlemin belirlenebilmesi için bu düzleme paralel ve sınırlarını oluşturacak iki hiper-düzlemin belirlenmesi gerekir. Şekil 3.26.'da gösterildiği üzere bu hiper-düzlemleri oluşturan noktalar destek vektörleri olarak adlandırılır ve bu düzlemler $wx_i + b = \pm 1$ şeklinde ifade edilirler.



Şekil 3.26. Doğrusal olarak ayrılabilen veriler için hiper düzlem ve destek vektörleri (Duman 2013)

Burada, $\boldsymbol{w}$ hiper-düzleme dik bir vektörü temsil eder. **m** ise ayrım değerini ifade eder ve $m = \frac{2}{\|w\|}$ formülü ile hesaplanır. Amaç ayrım değerini maksimize etmek olduğundan $\|\boldsymbol{w}\|$ değerini minimize etmek gerekmektedir. En uygun hiper-düzlemi belirleyebilmek için aşağıdaki sınırlı optimizasyon probleminin çözümü gerekir,

$y_i(wx_i + b) - 1 \geq 0$ ve $y_i \in \{-1,+1\}$ koşullarının sağlandığı durumda $min\left[\frac{1}{2}\|w\|^2\right]$

Bu optimizasyon problemi Lagrange denklemleri kullanılarak çözülebilir. Bu işlem sonrasında;

$$L(w,b,\alpha) = \frac{1}{2}\|w\|^2 - \sum_{i=1}^{n} \propto_i y_i(wx_i + b) + \sum_{i=1}^{n} \propto_i \tag{3.27}$$

eşitliği elde edilir. Sonuç olarak, doğrusal olarak ayrılabilen iki sınıflı bir problem için karar fonksiyonu aşağıdaki şekilde yazılabilir.

$$f(x) = sign\left[\sum_{i=1}^{n} \lambda_i y_i (x.x_i) + b\right] \quad (3.28)$$

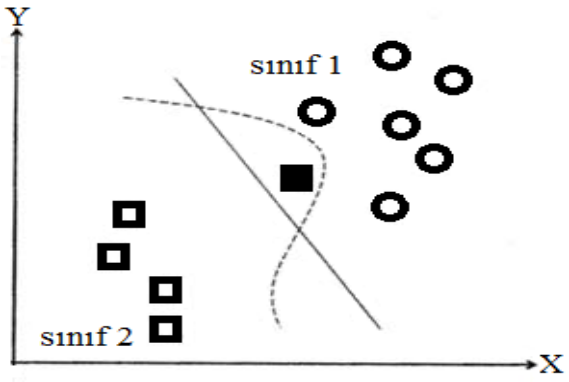
3.4.4 Doğrusal Olmayan DVM

Doğrusal olmayan DVM'ler giriş verilerini özellik uzayına düşürme fikrinden esinlenerek geliştirilmiştir. Giriş uzayında çekirdek fonksiyonları aracılığıyla doğrusal olmayan eğitim kümesinin yüksek boyutlu öznitelik uzayına dönüştürülerek, verilerin doğrusal olarak ayırt edilebileceği düşünülür. Eğitim verilerinin bir kısmının Şekil 3.27.'deki gibi optimum hiper-düzlemin diğer tarafında kalmasından kaynaklanan problem için Şekil 3.28.'de gösterildiği şekilde bir ξ değişkeni tanımlanır. Problem dönüşümden sonra çözülür. Sınırın maksimize edilmesi ve yanlış sınıflandırma hatalarının minimize edilmesi arasındaki denge, 0 - ∞ arasında pozitif değerler alan ve C ile ifade edilen bir düzenleme parametresi tanımlanmasıyla kontrol edilebilir. Burada optimizasyon problemi;

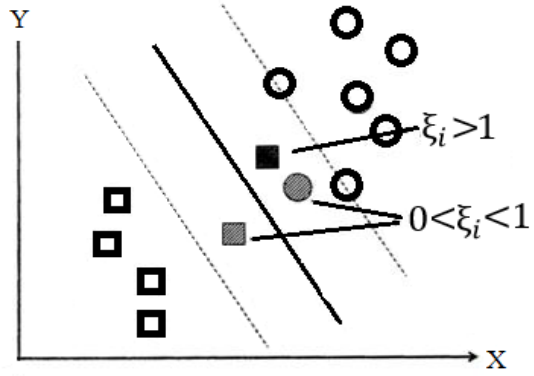
$$f(x) = min\left[\frac{\|w\|^2}{2} + C.\sum_{i=1}^{r} \xi_i\right] \quad (3.29)$$

şeklini alır. Buna bağlı sınırlamalar ise (3.30)'daki gibi ifade edilir.

$$y_i(w\varphi(x_i) + b) - 1 \geq 1 - \xi_i \; ve \; \xi_i \geq 0 \; ; \; i = 1,2,\ldots,n \quad (3.30)$$



Şekil 3.27. Doğrusal olarak ayrılamayan veriler



Şekil 3.28. Doğrusal olarak ayrılamayan veriler ve ξ değişkeni

3.4.5 Çok Sınıflı DVM

Bu bölüme kadar 2 sınıflı verilere göre DVM tasarımlarından bahsedildi. 2 den fazla sınıflı verilerin DVM ile ayrılmasında temel olarak iki yaklaşım vardır.

i. Lagrange Fonksiyonu Yaklaşımı

DVM'de optimal ayırma hiper düzleminin bulunması için kareli optimizasyon probleminin çözümünde Lagrange çarpanlarından yararlanılır. Lagrange çarpanları en küçükleme tipindeki problemi dual probleme dönüştürerek problemin daha kolay çözülmesine imkân verir. Ancak sınıf sayısı arttıkça, bir fonksiyon kullanımından dolayı hataların çok arttığı görüldüğünden bu yöntem pek tercih edilmemektedir.

ii. Sınıflar Arası Karşılaştırmalara Bağlı Yaklaşımlar

Bire karşı bir yaklaşımı; sınıf sayısındaki her örnek kümesi diğer örnekler kümeleriyle ayrı ayrı eğitilir. Yani N farklı sınıf olması durumunda N(N-1)/2 adet eğitim işlemi yapılır. Ardından test aşamasında gelen örneğin bu sınıflardan hangisine ait olduğu, bütün eğitim işlemlerinin sonucunda bulunan DV'ler ile kıyaslanarak ait olduğu sınıf bulunur.

Bire karşı hepsi yaklaşımı; her örnek kümesi, geri kalan tüm örnekler bir kümeye aitmiş gibi varsayılarak eğitilir. Yani N farklı sınıf olması durumunda N adet eğitim işlemi yapılır. Test aşamasında ise gelen örneğin ait olduğu sınıf bu eğitim verilerinde elde edilen DV'ler ile kıyaslanarak bulunur.

Döngüsel olmayan yönlü graf yaklaşımı; işleyiş bire karşı bir yönteminde olduğu gibidir. Asıl farklılık test aşamasındadır. Test yapılırken bütün eğitim işlemleri kontrol edilerek gerçekleştirilmez. Bunun yerine örneğin ait olmadığı düşünülen eğitim örnekleri elenerek ilerlenir (Demirci 2007).

3. MATERYAL VE METOT

4. İMLEÇ HAREKETLERİNİN SINIFLANDIRILMASI İÇİN ÖNERİLEN YÖNTEM

Bu çalışmada "BCI Competition 2003" yarışmasında sunulan yukarı ve aşağı imleç hareketlerine karşılık gelen 2 sınıflı EEG veri setinin öznitelikleri çıkarılarak sınıflandırılması amaçlanmıştır. Bu bölümde kanal seçimi algoritması ve özniteliklerin çıkarılması için kullanılan yöntem anlatılmıştır.

Çalışmada kullanılan veri seti 6 kanallı olup ilk olarak uygun kanal seçimi yapılmıştır. En uygun kanal seçiminden sonra, ADD ile yaklaşım katsayıları ve alt bantlardan yeniden oluşturulan işaretler elde edilmiştir. Eldeki alt bantlar ve yeniden oluşturulan işaretlere bir takım istatistiksel işlemler uygulanarak öznitelik vektörleri elde edilmiştir. Böylelikle iki farklı yaklaşımla, iki farklı öznitelik vektör kümesi üretilmiştir. Bu iki öznitelik vektör kümesi, k-NN ve DVM ile sınıflandırılmıştır. Son olarak her iki öznitelik vektör kümesi birleştirilerek, yeniden k-NN ve DVM ile sınıflandırılmıştır. Her üç sınıflandırma işleminde, veri boyutları farklı örnek aralıklarında denenerek, örnek aralıklarının performansı nasıl etkilediği gözlemlenmiştir. Başarı performansları bir sonraki bölümde tartışılmıştır.

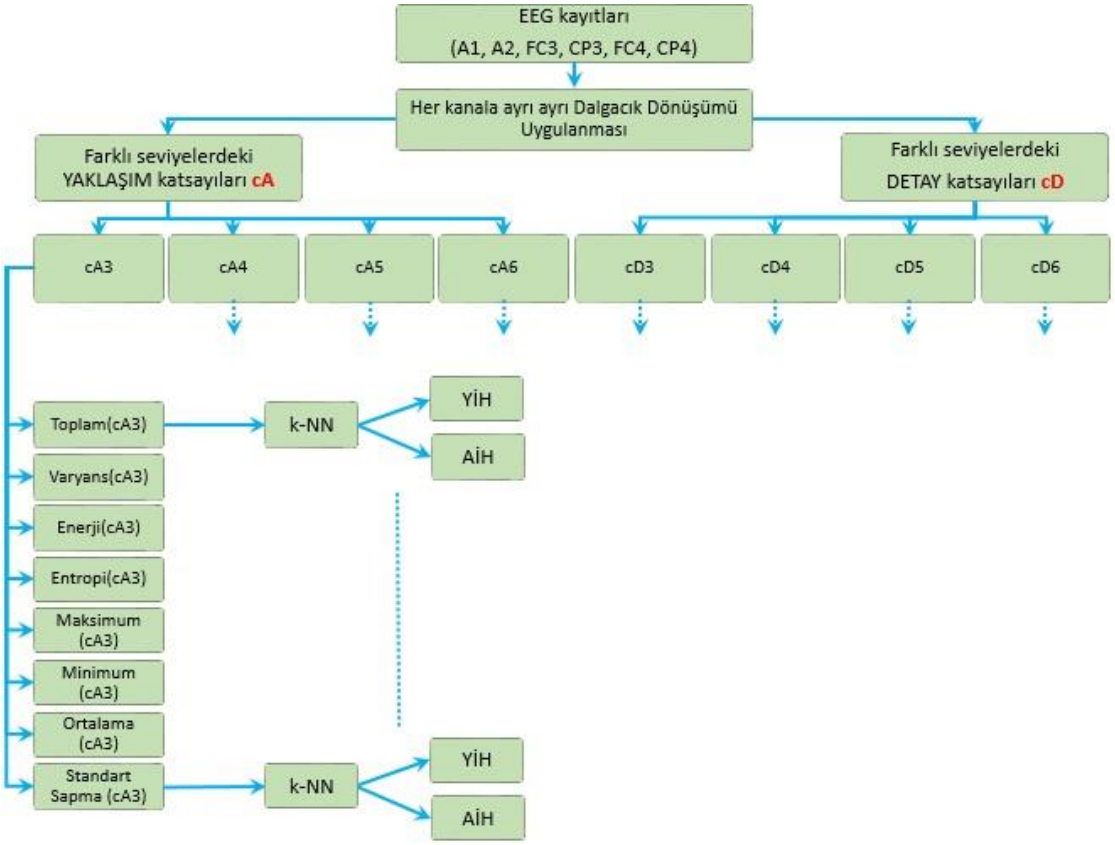
4.1. k-NN ile Kanal Seçimi

Bu aşamada ilk olarak tümleşik olarak verilen veri seti, kanallara bölünerek her bir kanal ayrı ayrı incelenmiştir. Kanallara ayrılan işaretlere ADD uygulanarak farklı seviyelerde detay (cD) ve yaklaşım (cA) katsayıları elde edilmiştir. Elde edilen bu verilerin; toplam, varyans, enerji, entropi, maksimum, minimum, ortalama ve standart sapma değerleri hesaplanmıştır. Bu işlem sonrası elde edilen veriler, öznitelik veri kümesi olarak ele alınmıştır. Bu öznitelikler k-NN ile sınıflandırılmıştır. Elde edilen sonuçlar karşılaştırıldığında, en uygun kanalın A1 kanalı olduğu görülmüştür. En yüksek performansın, cA3 katsayısına ilişkin ortalama değer ile elde edildiği ve sınıflandırma başarı oranının %77.13 olduğu görülmüştür. Çalışma sonucunda elde edilen performans değerleri yüzde (%) olarak Ek-1'de verilmiştir.

Başarım ölçütü olarak (4.1)'deki formül kullanılmıştır.

$$B = 100 \cdot \frac{Doğru\ saptanan\ \text{örüntü}\ sayısı}{Toplam\ \text{örüntü}\ sayısı} \tag{4.1}$$

Şekil 4.1.'de kanal seçimi için kullanılan algoritma gösterilmiştir.



Şekil 4.1. Kanal seçimi için kullanılan işlem adımları

Kanal seçimi için seçilen özniteliklerin matematiksel formülleri sırasıyla (4.2)-(4.9)'da gösterilmiştir. Eşitliklerin solundaki x değerlerinin alt indisleri MATLAB program kodlarını ifade etmektedir.

n=1, 2, 3, …, N olmak üzere;

Toplam;

$$x_{sum} = \sum_{i=1}^{N} x(n) \tag{4.2}$$

Varyans;

$$x_{var} = \frac{1}{N}\sum_{i=1}^{N}(x(n) - \mu)^2 \ , \qquad \mu = x_{ort} \tag{4.3}$$

Enerji;

$$x_{enr} = \frac{1}{f_s}\sum_{i=1}^{N} x^2(n) \tag{4.4}$$

Entropi;

$$x_{wentropy} = -\sum_{i=1}^{N} x^2(n) \log x^2(n) \tag{4.5}$$

Maksimum;

$$x_{max} = \max(x(n)) \tag{4.6}$$

Minimum;

$$x_{min} = \min(x(n)) \tag{4.7}$$

Ortalama;

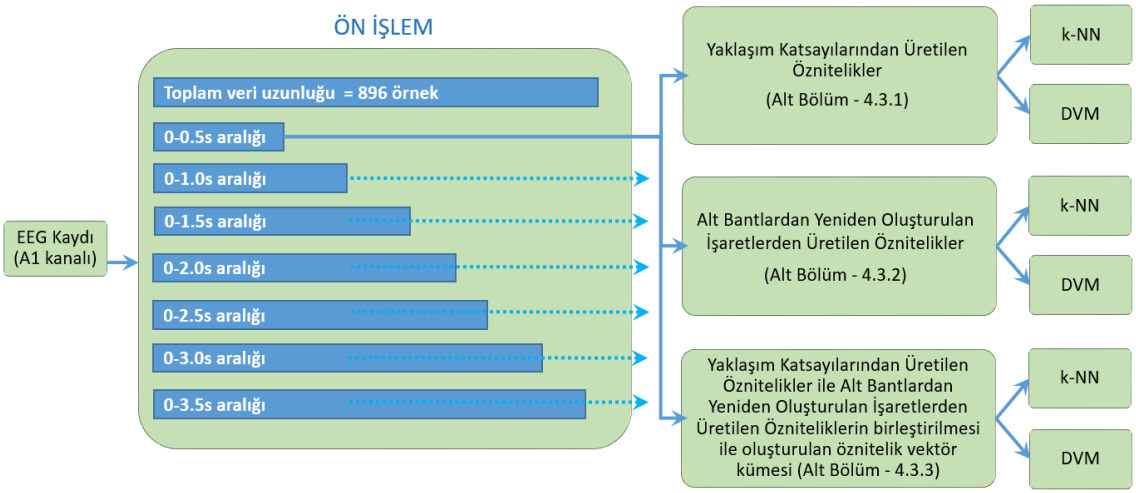
$$x_{mean} = \sum_{i=1}^{N} \frac{x(n)}{N} \tag{4.8}$$

Standart Sapma;

$$x_{std} = \sqrt{\frac{1}{N}\sum_{n=1}^{N}(x(n) - x_{ort})^2} \tag{4.9}$$

4.2. Ön İşlem

Kanal seçiminden sonra, tez kapsamında izlenilen işlem akışı şekil 4.2.'de gösterilmiştir. Şekilden görüldüğü üzere, ön işlem olarak farklı uzunluklarda [1-128 örnek aralığı (0.0s-0.5s), 1-256 örnek aralığı (0.0s-1.0s), …. 1-896 örnek aralığına (0.0s-3.5s)] bölütler değerlendirmeye alınmıştır. Farklı örnek uzunluklarındaki bölütlerin kullanılmasındaki amaç, başarımı en yüksek olan veri uzunluğunu saptamaktır.



Şekil 4.2. Tez kapsamında sınıflandırma için izlenilen işlem akışı

4.3. Özniteliklerin Elde Edilmesi

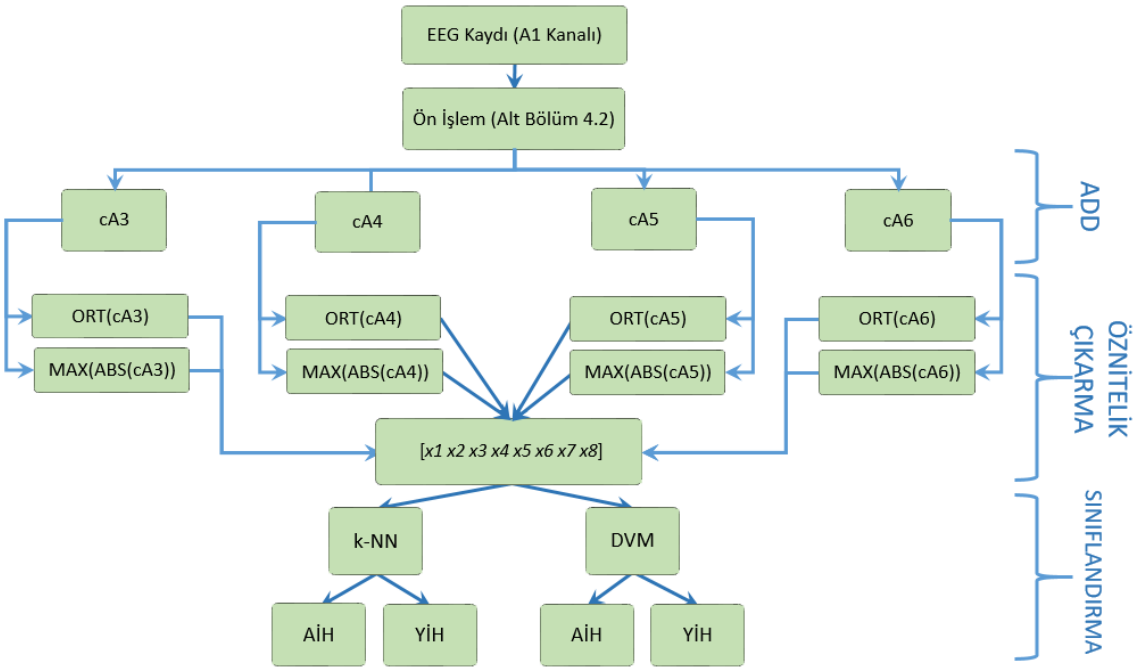
ADD, durağan olmayan EEG gibi işaretlerin incelenmesinde sık kullanılan bir yöntemdir. Bu yöntem işaretin istenilen frekans aralığının incelenebilmesine olanak tanır.

Öznitelikler üç farklı yaklaşımla elde edilmiştir. Birinci yaklaşımda, ADD uygulanan işaretlerin yaklaşım katsayılarından elde edilen öznitelikler değerlendirilmiştir. İkinci yaklaşımda, alt bantlardan yeniden oluşturulan işaretlerden öznitelikler değerlendirilmiştir. Üçüncü yaklaşımda ise bu iki öznitelik vektör kümeleri birleştirilerek değerlendirilmişlerdir.

4.3.1. Yaklaşım Katsayılarından Üretilen Öznitelikler

ADD ile elde edilen dalgacık katsayılarının işaret ile ilgili belirleyici veriler içerdiği bilinmektedir. Literatürde EEG işaretlerinin analizinde ADD ile elde edilen katsayıların kullanıldığı sıklıkla görülmektedir [(Amin 2015), (Alomari 2014), (Kharat 2012), (Ghandi 2010)]. Bu sebepten, dalgacık katsayılarının (cA ve cD) öznitelik olarak kullanılması mümkündür.

Dalgacık katsayılarından özniteliklerin elde edilip sınıflandırılmasına ilişkin akış şeması Şekil 4.3.'de gösterilmiştir.



Şekil 4.3. Dalgacık katsayılarından elde edilen özniteliklerin sınıflandırılması

Bir önceki aşamada EEG kanallarından en etkin olan A1 kanalı burada kullanılmıştır.

İşaretin özelliklerine bağlı olarak uygun ana dalgacık seçimi ve uygun ayrıştırma seviye seçimi, sistemin performansı için önemli rol oynar. Bu çalışmada Daubechies ana dalgacık ailesinden 'db3' dalgacığı kullanılmıştır. Bu tez kapsamında farklı dalgacıklar test edilmiş ve en yüksek performansın 'db3' ile elde edildiği görülmüştür. Ayrıştırma seviyesi olarak 3., 4., 5. ve 6. seviyeler kullanılmıştır. İşaretin örnekleme hızı 256Hz dir. ADD işleminde 2 ile aşağı örnekleme kullanılmasından ötürü, Nyquist kuralı gereği 128Hz olarak hesaplanmıştır (Ocak 2009). Dalgacık katsayılarının seviyelerine göre bulundukları frekans aralıkları Tablo 4.1.'de gösterilmiştir.

Tablo 4.1. Dalgacık katsayılarının seviyelerine göre bulundukları frekans aralıkları

Dalgacık Katsayıları	Frekans Aralıkları
cA1	0 – 64 Hz.
cA2	0 – 32 Hz.
cA3	0 – 16 Hz.
cA4	0 – 8 Hz.
cA5	0 – 4 Hz.
cA6	0 – 2 Hz.

Bu çalışmada ADD ile yaklaşım katsayıları için 3., 4., 5. ve 6. seviye alt bantlarda YİH ve AİH arasında bir genlik farkının olduğu gözlemlenmiştir. Bu genlik farklarını en iyi ifade edebilecek istatistiksel hesapların, ortalama değer (od) ve maksimum mutlak değer (mmd) olduğu öngörüldüğünden, bu veriler öznitelik olarak kullanılmıştır. Bu öngörüyü doğrulamak üzere, aşağıdaki çalışma gerçeklenmiştir.

Elde edilen yaklaşım (cA) katsayılarının od ve mmd değerleri alınarak her seviye için 2 şer adet öznitelik değeri üretilmiştir. Dolayısıyla, her AİH veya YİH örüntüsü için 8x1 boyutlu bir öznitelik vektörü elde edilmiştir. Özniteliklerin elde edilmesine ilişkin formüller aşağıda gösterilmiştir.

Katsayıların maksimum mutlak değerleri:

$$\begin{aligned} x1 &= \max|\mathrm{cA6(n)}| \\ x2 &= \max|\mathrm{cA5(n)}| \\ x3 &= \max|\mathrm{cA4(n)}| \\ x4 &= \max|\mathrm{cA3(n)}| \end{aligned} \tag{4.10}$$

Katsayıların ortalaması:

x(n), n = 1,2,3,…….,N için bir zaman serisi olmak üzere;

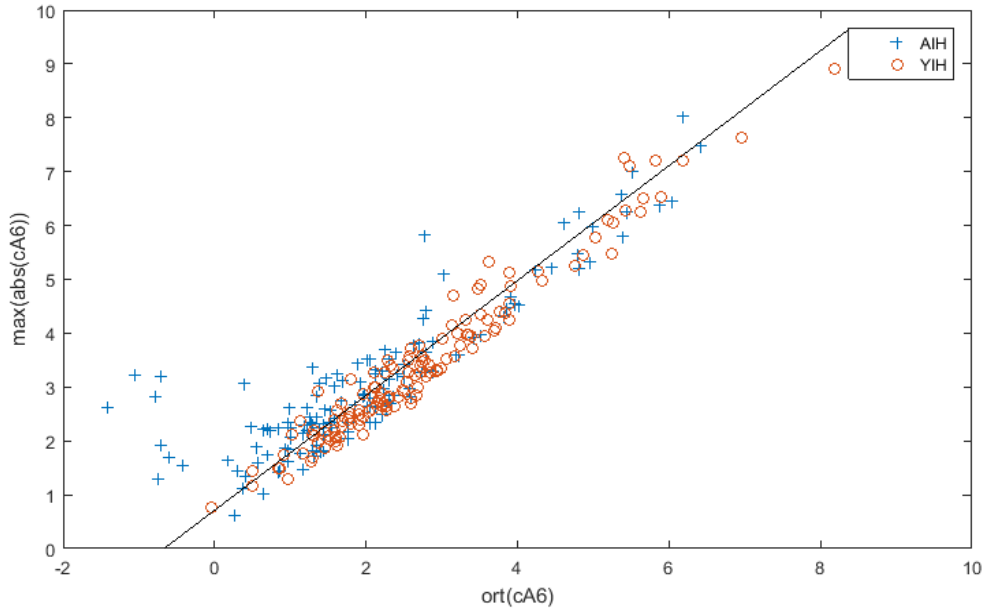
$$\begin{aligned} x5 &= \sum_{n=1}^{N} \frac{cA6(n)}{N} \\ x6 &= \sum_{n=1}^{N} \frac{cA5(n)}{N} \\ x7 &= \sum_{n=1}^{N} \frac{cA4(n)}{N} \\ x8 &= \sum_{n=1}^{N} \frac{cA3(n)}{N} \end{aligned} \tag{4.11}$$

Dolayısıyla, elde edilen bir öznitelik vektörü;

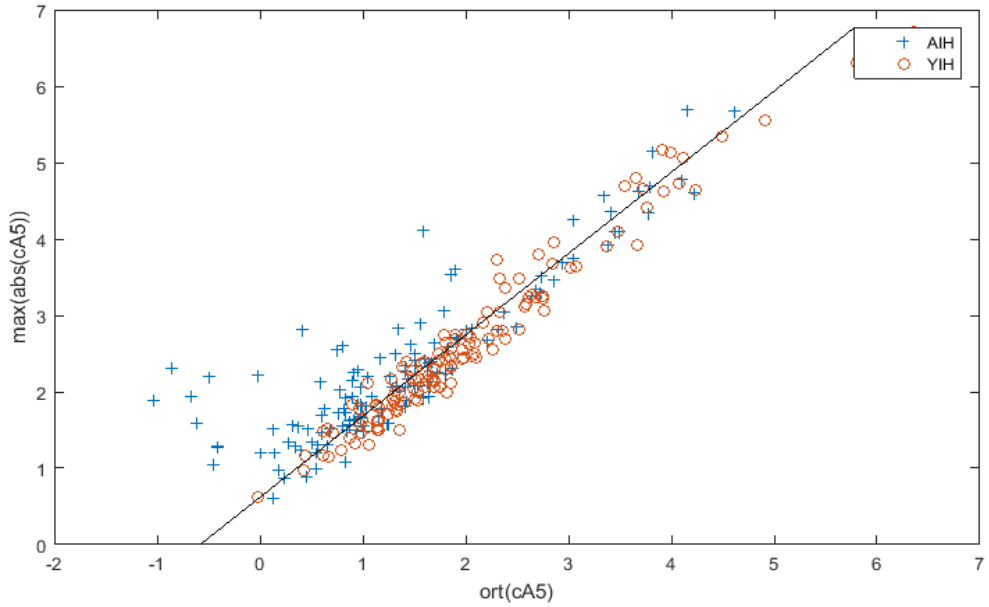
$$X = [x1\ x2\ x3\ x4\ x5\ x6\ x7\ x8]$$

şeklinde ifade edilir.

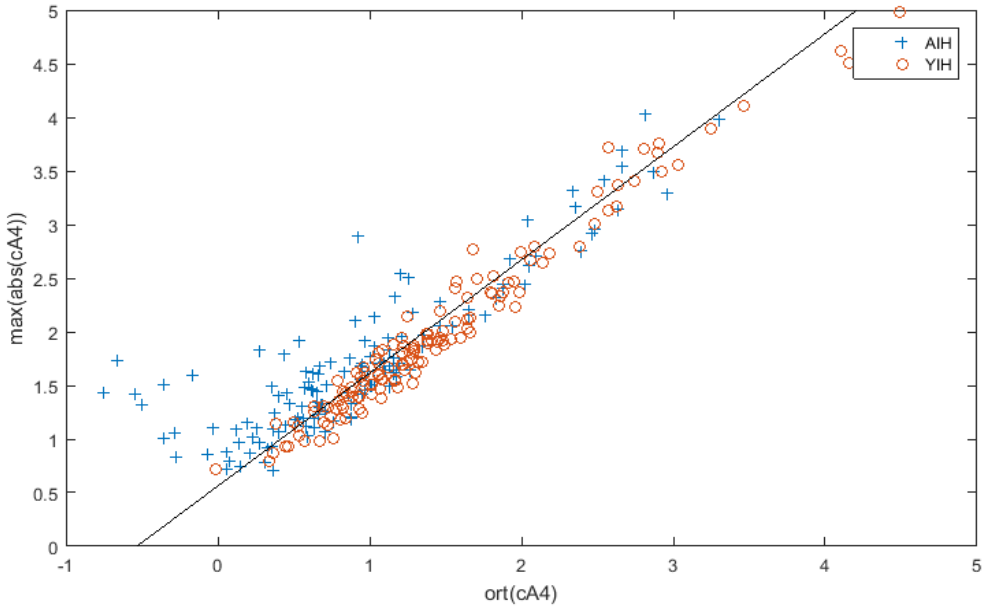
Yukarıda sözü edilen işlemler yapıldıktan sonra, şekil 4.4., Şekil 4.5., Şekil 4.6. ve Şekil 4.7'de AİH ve YİH sınıflarına ilişkin 6., 5., 4. ve 3. seviye yaklaşım katsayılarının od-mmd değişimi sırasıyla gösterilmiştir. Sınıflara ait özniteliklerin, çoğunlukla çizilen doğru parçalarının farklı bölgelerine düştüğü şekillerden görülmektedir. Dolayısıyla, seçilen özniteliklerin sınıflandırma için doğru seçimler olduğu görülmektedir.



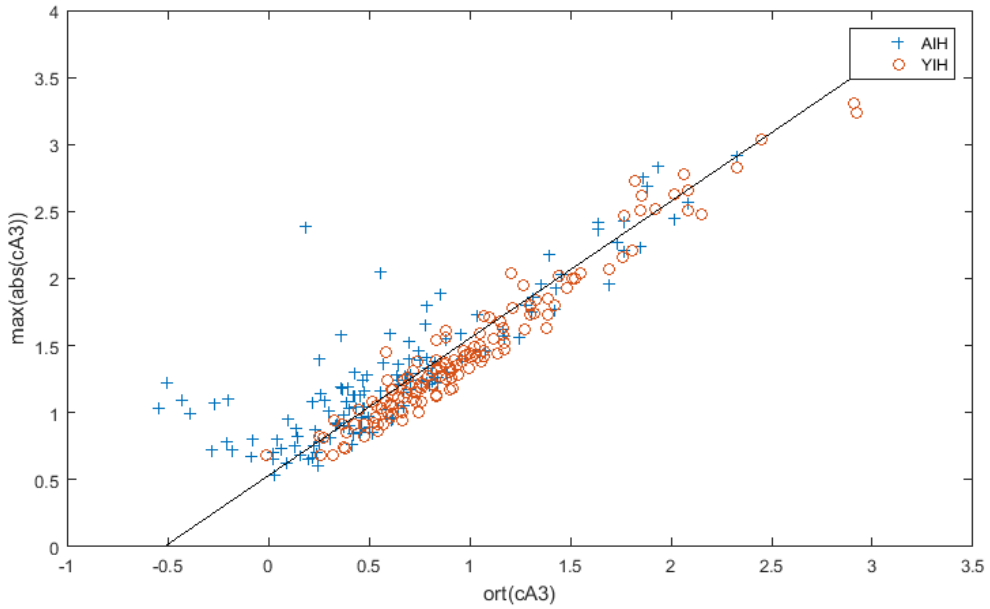
Şekil 4.4. 6. seviye yaklaşım katsayılarının od-mmd değişimi. Eksenler 100 değerine bölünerek normalize edilmiştir.



Şekil 4.5. 5. seviye yaklaşım katsayılarının od-mmd değişimi. Eksenler 100 değerine bölünerek normalize edilmiştir.



Şekil 4.6. 4. seviye yaklaşım katsayılarının od-mmd değişimi. Eksenler 100 değerine bölünerek normalize edilmiştir.

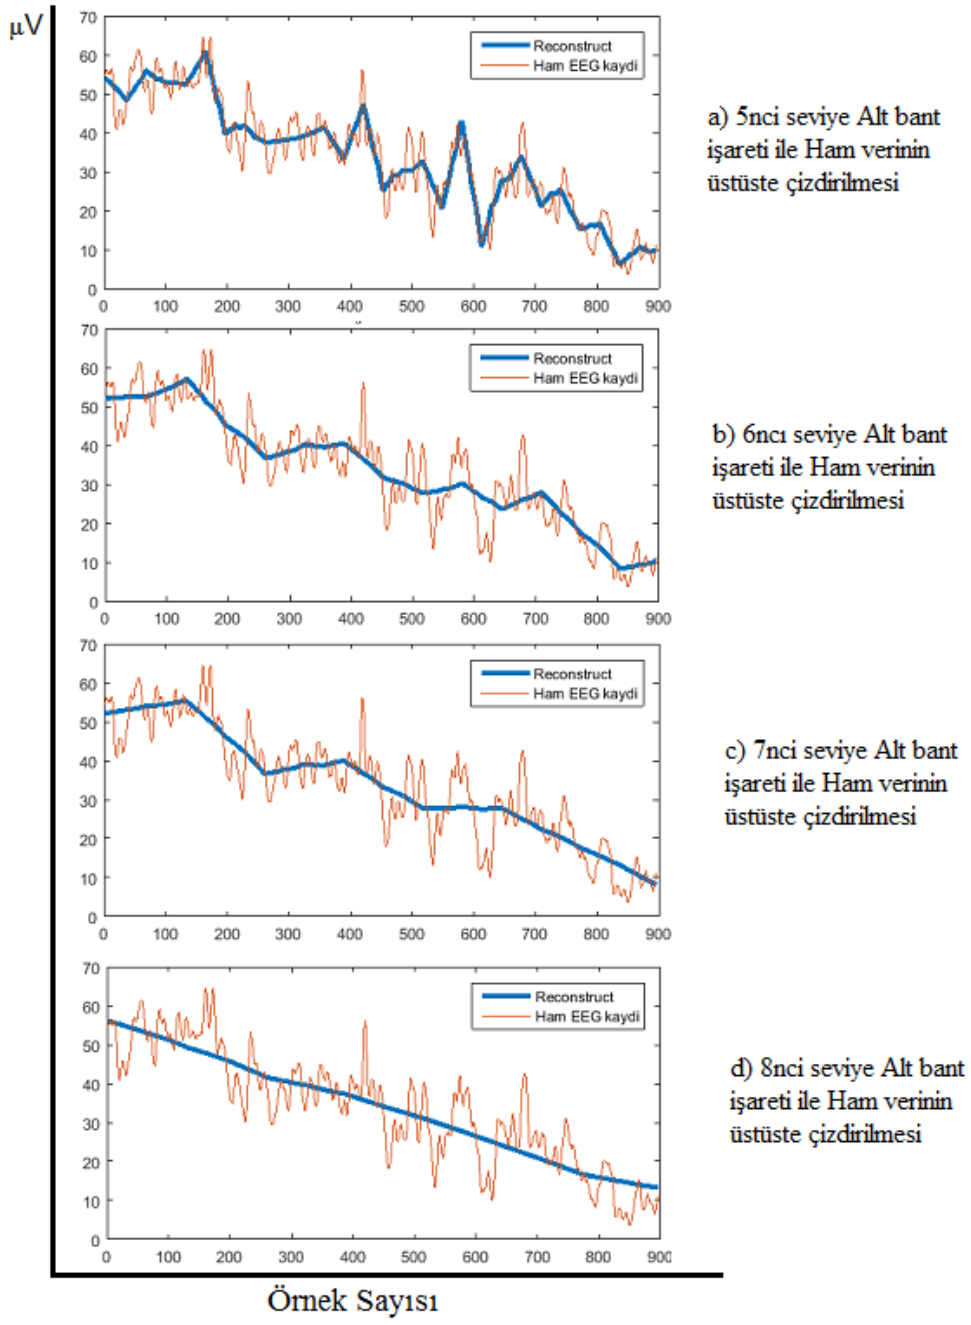


Şekil 4.7. 3. seviye yaklaşım katsayılarının od-mmd değişimi. Eksenler 100 değerine bölünerek normalize edilmiştir.

4.3.2. Alt Bantlardan Yeniden Oluşturulan İşaretlerden Üretilen Öznitelikler

ADD ile alt bantlardan yeniden oluşturulan işaretlerin de dalgacık katsayıları gibi işaret ile ilgili belirleyici veriler içerdiği bilinmektedir. Alt bantlardan yeniden oluşturulan işaretlerin elde edilmesi işleminin, ham verinin zaman alanındaki şekline eğri uydurulmasına benzer bir işlem olduğunu söylemek mümkündür. Alt bantlardan yeniden

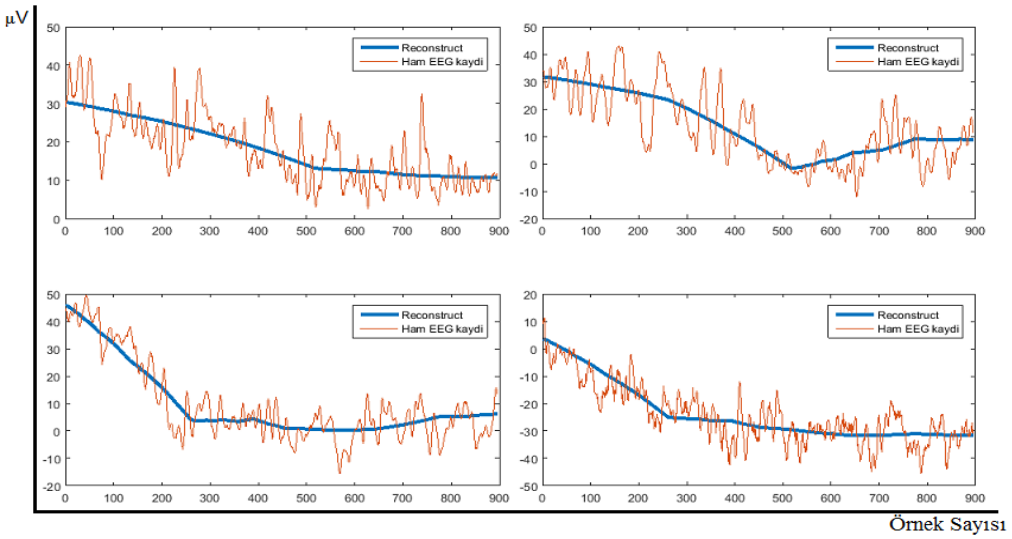
oluşturulan işaretlerin elde edilmesinde seviye arttıkça alt bant işareti yumuşamaktadır. Bu yaklaşım, bir işarete polinom uydurma işleminde derece azaltmaya benzetilebilir. Bu yumuşama durumu, Şekil 4.8.'de örnek bir AİH örüntüsü üzerinde gösterilmiştir. Şekillerde, örüntünün 5., 6., 7. ve 8. seviye alt bantlarından oluşturulan işaretin değişimi görülmektedir. Polinom uydurmada olduğu gibi, alt bantlardan yeniden oluşturulan işaret, üretildiği işaretin genel eğilimi hakkında bilgi verdiği görülmektedir.



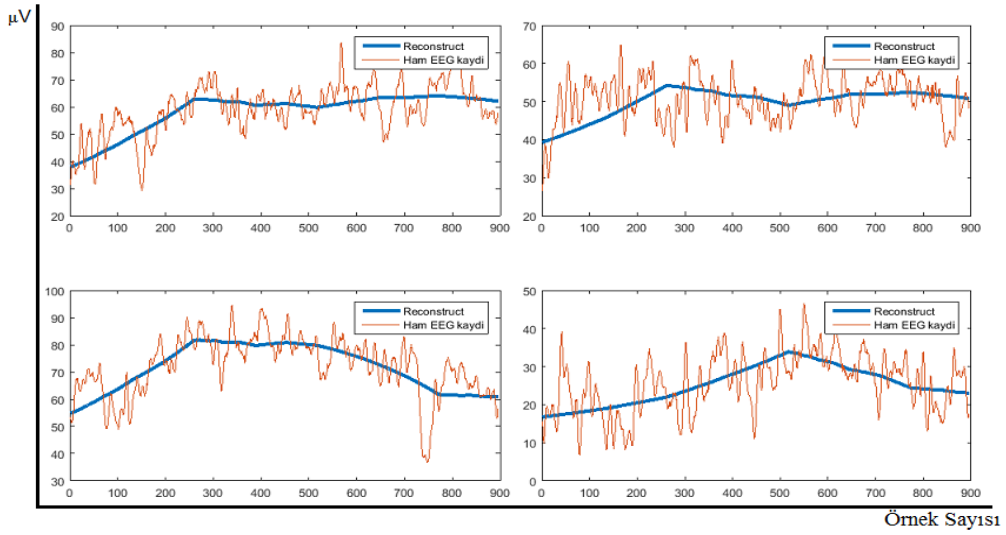
Şekil 4.8. Örnek bir AİH örüntüsüne ilişkin ham EEG kaydı ve 5.,6.,7.,8. seviye katsayılardan elde edilen işaretin değişimleri.

Yukarıda sözü edilen yaklaşım temel alınarak, eğime dayalı öznitelik çıkarma çalışması bu bölümde gerçeklenmiştir. Bu bilgiler çerçevesinde, değişime ilişkin eğimin en iyi 8. seviyede olduğu belirlenmiştir [Şekil 4.8(d)]. Bu yaklaşım temel alındığında, farklı denemelere ilişkin yapılan çalışmalar ve elde edilen eğimler aşağıda açıklanmıştır.

Şekil 4.9'da AİH sınıfına ilişkin rastgele seçilen 4 denemenin 8. seviye alt bantları, ham veri ile birlikte gösterilmiştir. Şekilden görüleceği üzere, 1-400 örnek aralığının aşağı doğru bir eğilim gösterdiği görülmektedir. Şekil 4.10'da ise YİH sınıfına ilişkin yine rastgele seçilen 4 denemenin 8. seviye alt bantları ham veri ile birlikte gösterilmiştir. Şekilden görüleceği üzere, 1-400 örnek aralığının yukarı doğru bir eğilim gösterdiği görülmektedir (Ek-2'de tüm denemelere ilişkin değişimler verilmiştir).

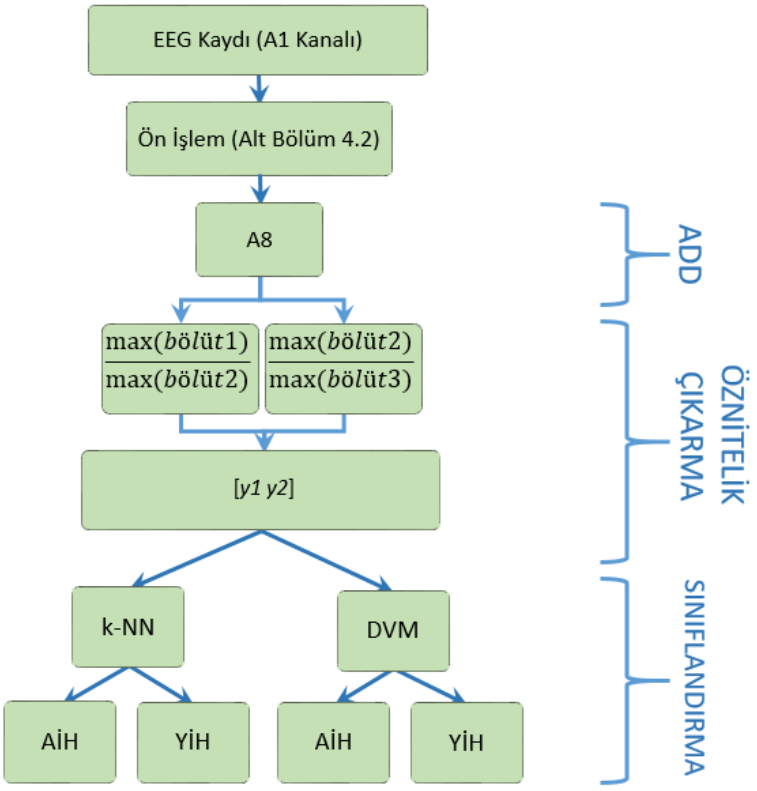


Şekil 4.9. AİH sınıfına ilişkin rastgele seçilen 4 denemenin Ham EEG kaydı ve 8. seviye yeniden oluşturulan alt bant işaretlerinin üst üste çizimleri



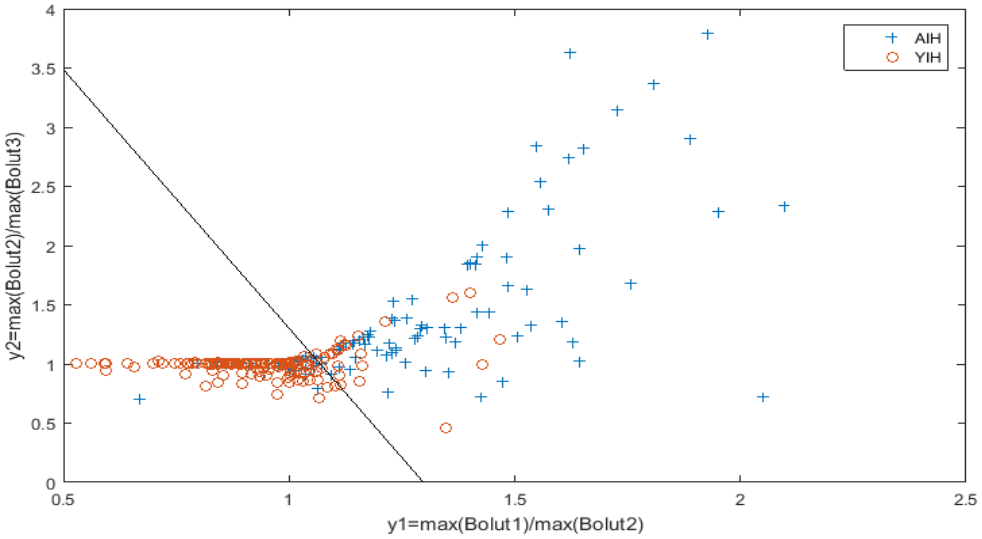
Şekil 4.10. YİH sınıfına ilişkin rastgele seçilen 4 denemenin Ham EEG kaydı ve 8. seviye yeniden oluşturulan alt bant işaretlerinin üst üste çizimleri

Bu bilgiler çerçevesinde, 8. seviye ile elde edilen eğim bilgisinin öznitelik olarak kullanılabileceği görülmüştür. 8. seviye bandı elde edildikten sonra, işaretin genel eğilimini en iyi ifade edebilecek istatistiksel işlemin, işareti bölütlere ayırarak maksimumlarının oranlarını almak olacağı öngörülmüştür. Buna göre, bir örüntü 3 eşit bölüte ayrılmıştır. Bu bölütlerden; *y1=max(Bölüt1)/max(Bölüt2)* ve *y2=max(Bölüt2)/max(Bölüt3)* değerleri öznitelik olarak kullanılmıştır. Özniteliklerin elde edilip sınıflandırılmasına ilişkin akış şeması Şekil 4.11'de gösterilmiştir. Bir önceki aşamada EEG kanallarından en etkin olan A1 kanalı burada da kullanılmıştır. Bir önceki uygulamada olduğu gibi burada da Daubechies ana dalgacık ailesinden 'db3' dalgacığı kullanılmıştır. Akış şemasından görüleceği üzere, her bir örüntüye ilişkin oluşturulan öznitelik vektörü $Y = [y1\ y2]$ dir.



Şekil 4.11. 8. seviye alt bandına ait özniteliklerin elde edilip sınıflandırılmasına ilişkin akış şeması

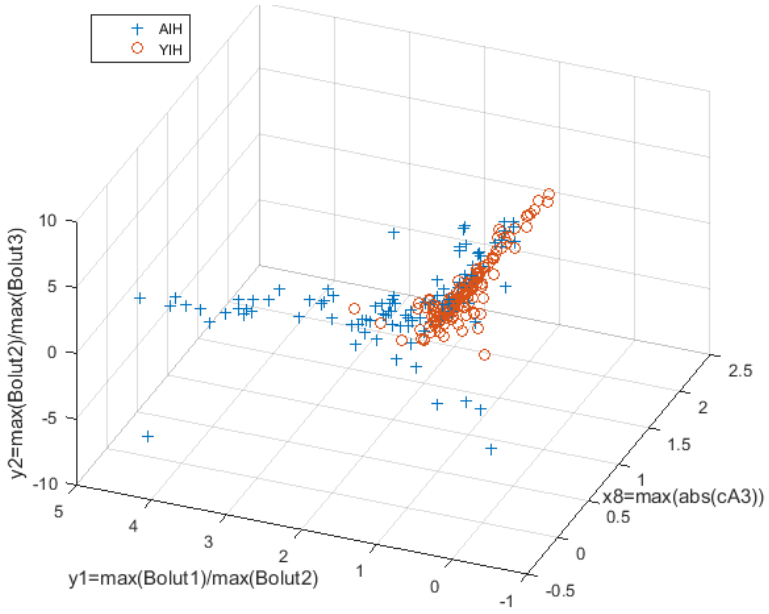
Şekil 4.12'de iki farklı sınıfa (AİH ve YİH) ilişkin örüntülerin *y1-y2* değişimleri gösterilmiştir. Özniteliklerin çoğunlukla çizilen doğru parçalarının farklı bölgelerine düştüğü şekilden görülmektedir. Dolayısıyla, seçilen özniteliklerin sınıflandırma için doğru seçimler olduğu görülmektedir.



Şekil 4.12. İki farklı sınıfa (AİH ve YİH) ilişkin örüntülerin *y1-y2* değişimleri

4.3.3. Hibrid yaklaşım (Dalgacık Katsayıları ve Yeniden Oluşturulan İşaretlerden Üretilen Özniteliklerin Birlikte Kullanılması)

ADD ile dalgacık katsayılarından ve yeniden oluşturulan işaretlerden üretilen özniteliklerin oldukça iyi öznitelikler olduğu şekil 4.3-4.6 ve şekil 4.10'dan görülmüştür. Bu alt bölümde; hibrid yaklaşımın sonuca nasıl etki ettiği incelenmiştir. *y1=max(Bölüt1)/max(Bölüt2), y2=max(Bölüt2)/max(Bölüt3)* ve denklem (4.11)'den *x8* (3. seviye katsayılarının ortalaması) özniteliklerinin değişimi, şekil 4.13'te görülmektedir. Farklı iki sınıfa (AİH/YİH) ait özniteliklerin gözle görülür şekilde ayrık olduğu açıktır. Araştırma bulguları bölümünde verilen sonuç değerleri de bu durumu desteklemektedir.



Şekil 4.13. *x8*'in *y1* ve *y2* ye göre değişimi

5. ARAŞTIRMA BULGULARI

Bir önceki bölümde elde edilen öznitelik vektör kümeleri k-NN ve DVM ile sınıflandırılmıştır. k-NN için uzaklık ölçütü olarak literatürde sık kullanılan Öklid (Euclidean) seçilmiştir. Komşuluk değeri olan k, 1:100 arası için hesaplanmıştır. DVM için ise çekirdek olarak RBF kullanılmış, sigma ($\boldsymbol{\sigma}$) değeri 0.1:0.1:3 için hesaplanmıştır.

İşaret bir önceki bölümde açıklandığı üzere, farklı örnek uzunluklarına göre incelenmiştir. İşaretin örnek uzunlukları; 1-128 örnek aralığı (0.0s-0.5s), 1-256 örnek aralığı (0.0s-1.0s), …. 1-896 örnek aralığı (0.0s-3.5s) olacak şekilde alınmıştır. Yaklaşım katsayıları ile üretilen özniteliklerin sınıflandırılmasına ilişkin elde edilen başarımlar Tablo 5.1'de verilmiştir. Tablodan görüldüğü üzere, en yüksek başarımın %84.98 olarak DVM ile elde edilmiştir. İşaretin tamamının yerine 0-1.5s aralığının kullanılması ile daha yüksek başarımın elde edilebileceği görülmüştür.

Tablo 5.1. Yaklaşım Katsayılarından üretilen öznitelik vektörlerinin sınıflandırılması ile elde edilen başarım değerleri

Kullanılan bölüt aralığı		**k-NN**		**DVM**	
Örnek Sayısı	**Süre (sn)**	Başarım (%)	k Komşu sayısı	Başarım (%)	RBF ($\boldsymbol{\sigma}$) değeri
1-128	0-0,5	70.65	1	72.70	1.0
1-256	0-1	77.47	12	80.20	0.7
1-384	0-1,5	77.82	30	**84.98**	0.5
1-512	0-2	82.94	11	83.28	1.3
1-640	0-2,5	**83.62**	7	83.96	0.7
1-768	0-3	**83.62**	8	**84.98**	0.3
1-896	0-3,5	80.55	5	80.55	0.9

Yeniden oluşturulmuş İşaretlerden üretilen öznitelik vektörlerinin sınıflandırılmasına ilişkin elde edilen başarımlar Tablo 5.2'de verilmiştir. Tablodan görüldüğü üzere, en yüksek başarım %88.40 olarak DVM ile elde edilmiştir. İşaretin tamamının yerine 0-2.5s aralığının kullanılması ile yüksek başarımın elde edilebileceği görülmüştür. Bir önceki başarım ile kıyaslandığında, yaklaşım katsayıları ile elde edilen başarımın (0-1.5s için %84.98) burada da yaklaşık olarak (0-1.5s için %84.30) elde edildiği görülmektedir.

Tablo 5.2. Yeniden oluşturulmuş İşaretlerden üretilen öznitelik vektörlerinin sınıflandırılması ile elde edilen başarım değerleri

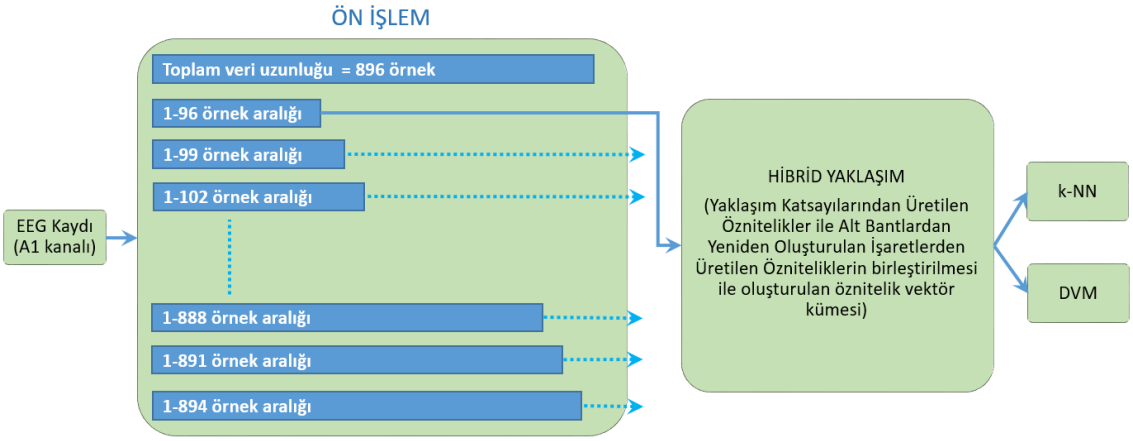
Kullanılan bölüt aralığı		**k-NN**		**DVM**	
Örnek Sayısı	**Süre (sn)**	Başarım (%)	k Komşu sayısı	Başarım (%)	RBF (σ) değeri
1-128	0-0,5	66.55	77	69.28	0.1
1-256	0-1	70.65	7	75.43	0.6
1-384	0-1,5	**82.59**	4	84.30	0.1
1-512	0-2	79.86	13	83.62	0.4
1-640	0-2,5	81.57	4	**88.40**	0.2
1-768	0-3	82.49	3	87.37	0.2
1-896	0-3,5	79.52	4	83.62	0.2

Hibrid yaklaşım ile elde edilen başarımlar Tablo 5.3'te verilmiştir. Yaklaşım katsayılarından ve yeniden oluşturulmuş işaretlerden üretilen hibrid özniteliklerin sınıflandırma başarımları incelendiğinde, en yüksek başarımın %94.19 olarak DVM ile elde edildiği görülmüştür. Tablodan görüldüğü üzere, Hibrid yapı ile yine aynı sürede (0-1.5s) başarımın arttığı gözlemlenmiştir.

Tablo 5.3. Hibrid yaklaşım ile elde edilen başarımlar

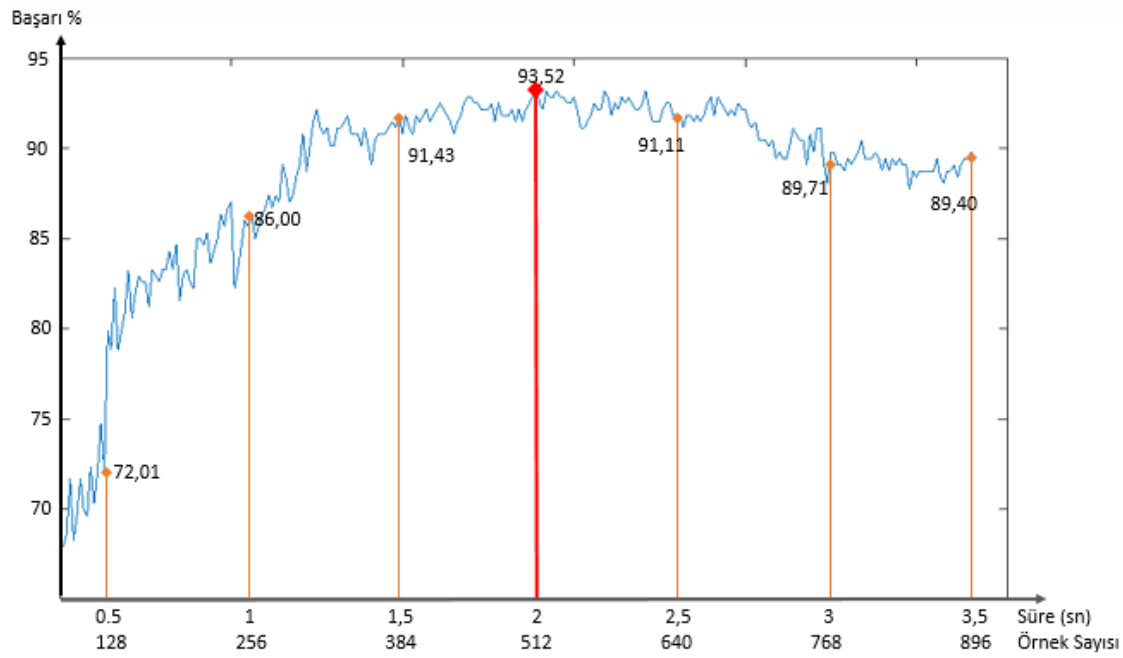
Kullanılan bölüt aralığı		**k-NN**		**DVM**	
Örnek Sayısı	**Süre (sn)**	Başarım (%)	k Komşu sayısı	Başarım (%)	RBF (σ) değeri
1-128	0-0,5	72.01	1	78.49	1.3
1-256	0-1	86.01	12	87.03	2.2
1-384	0-1,5	91.43	22	**94.19**	1.6
1-512	0-2	**93.52**	20	93.17	0.9
1-640	0-2,5	91.11	5	92.83	0.9
1-768	0-3	89.71	20	88.73	2.5
1-896	0-3,5	89.40	20	89.41	2.5

Ayrıca Hibrid yaklaşımda tüm örnek aralıkları çalışılmış ve başarımın nasıl değiştiği araştırılmıştır. Tüm örnek aralığını tanımlayan yaklaşım şekil 5.1'de gösterilmiştir.



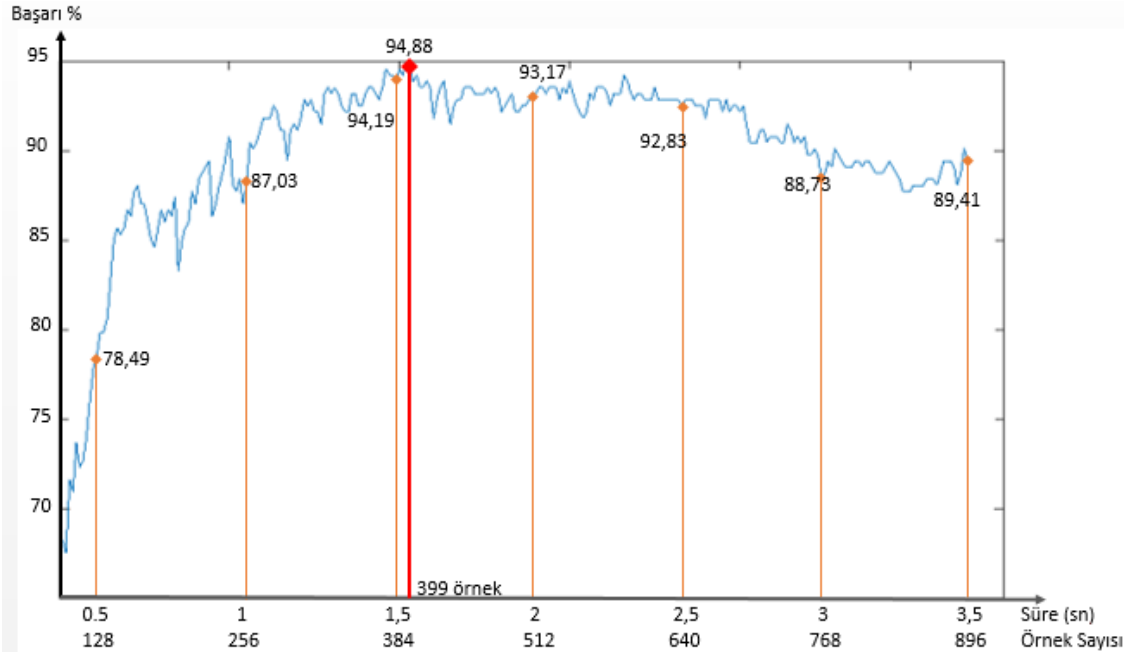
Şekil 5.1. Hibrid yaklaşım ile sınıflandırma için izlenilen işlem akışı

Tüm örnek aralığının k-NN ile analizi sonucu oluşan başarım grafiği Şekil 5.2'de gösterilmiştir. Şekilden görüldüğü üzere, 2. saniyede [0-512 örnek aralığı] en yüksek başarımın (%93.52) elde edildiği görülmüştür.



Şekil 5.2. k-NN'de performansın değerlendirmeye alınan veri uzunluğuna göre değişimi

Tüm örnek aralığının DVM ile analizi sonucu oluşan başarım grafiği Şekil 5.3'de gösterilmiştir. Şekilden görüldüğü üzere, 1.55. saniyede [0-399 örnek aralığı] en yüksek başarımın (%94.88) elde edildiği görülmüştür.



Şekil 5.3. DVM'de performansın değerlendirmeye alınan veri uzunluğuna göre değişimi

6. SONUÇLAR VE TARTIŞMA

Bu çalışmada, Yukarı-Aşağı imleç hareketlerine ilişkin EEG verilerinin sınıflandırılması amaçlanmıştır. 2003 yılındaki BCI Competition II yarışmasında sunulan Data set Ia veri kümesi kullanılmıştır.

Bu tez çalışmasında öncelikle en etkin olan kanal belirlenmiştir. En etkin kanal belirleme sürecinde, işaret bütün olarak alınmış ve ADD ile farklı (3., 4., 5. ve 6.) seviyeler için dalgacık katsayıları elde edilmiştir. Her seviyenin ayrı ayrı istatistiksel parametreleri (toplam, varyans, enerji, entropi, max, min, ort ve std sapma) hesaplanmıştır. Her parametre ayrı ayrı k-NN ile sınıflandırılmıştır. En iyi başarımın 3. seviyede toplam ve ortalama parametreleri ile elde edildiği görülmüştür. Buna göre en etkin kanalın A1 olduğu belirlenmiştir.

İkinci aşamada ise belirlenen kanal üzerinden, yukarı-aşağı imleç hareketine ilişkin öznitelik çıkarma ve sınıflandırma işlemi yapılmıştır. EEG işaretinden üç farklı yaklaşımla öznitelikler elde edilmiştir. Bu yaklaşımlar aşağıda özetlenmiştir.

Birinci yaklaşımda, farklı (3., 4., 5. ve 6.) seviyeler için yaklaşım katsayıları elde edilmiştir. Her seviyenin ayrı ayrı ortalama ve maksimum mutlak değerleri hesaplanmış ve bu değerler bir vektörde birleştirilerek öznitelik vektörü olarak kullanılmıştır. Bu vektörler k-NN ve DVM ile sınıflandırılmıştır. Bu sınıflandırma işlemi, farklı örnek aralıkları için denenmiş ve en yüksek başarımın (0-1.5s için %84.98) DVM ile elde edildiği görülmüştür.

İkinci yaklaşımda, alt bantlardan yeniden oluşturulan YİH ve AİH işaretlerinin eğim bilgisinin (1-400 örnek aralığı) öznitelik olarak kullanılabileceği görülmüştür. Bu eğim en iyi 8. seviyede gözlemlenmiştir. Yeniden oluşturulan işaret 3 eşit bölüte ayrılmıştır. Bu bölütlerden; *max(Bölüt1)/max(Bölüt2)* ve *max(Bölüt2)/max(Bölüt3)* değerleri birleştirilerek öznitelik olarak kullanılmıştır. Bu vektörler k-NN ve DVM ile sınıflandırılmıştır. Bu sınıflandırma işlemi, farklı örnek aralıkları için denenmiş ve en yüksek başarımın (0-2.5s için %88.40) DVM ile elde edildiği görülmüştür.

Üçüncü yaklaşımda, yukarıda sözü edilen birinci ve ikinci öznitelikler birleştirilerek (Hibrid yaklaşım) öznitelik vektörü olarak kullanılmıştır. Bu vektörler k-NN ve DVM ile sınıflandırılmıştır. Bu sınıflandırma işlemi, farklı örnek aralıkları için

denenmiş ve en yüksek başarımın (0-1.5s için %94.19) DVM ile elde edildiği görülmüştür.

Ayrıca Hibrid yaklaşımda tüm örnek aralıkları çalışılmış ve başarımın nasıl değiştiği araştırılmıştır. Tüm örnek aralığının k-NN ile analizi yapıldığında, en yüksek başarımın %93.52 ile 2. saniyede elde edildiği görülmüştür. Tüm örnek aralığının DVM ile analizi yapıldığında ise, en yüksek başarımın %94.88 ile 1.55. saniyede elde edildiği görülmüştür.

Yukarıda açıklanan bulgulara göre önem arz eden noktalar aşağıda listelenmiştir.

1) Yukarı-aşağı imleç hareketinin sınıflandırılmasında en etkin kanalın A1 olduğu belirlenmiştir.

2) Sonuçlar *sınıflandırıcı* açısından değerlendirildiğinde, DVM sınıflandırıcısının k-NN sınıflandırıcısına göre çalışılan veri için daha üstün olduğu görülmüştür. Her üç yaklaşımda da (yaklaşım katsayılarından üretilen özniteliklerin sınıflandırılması, alt bantlardan yeniden oluşturulmuş işaretlerden üretilen özniteliklerin sınıflandırılması ve Hibrid yaklaşım ile elde edilen özniteliklerin sınıflandırılması) DVM yönteminin k-NN yöntemine göre daha başarılı sonuçlar ürettiği gözlemlenmiştir.

3) *Örnek aralıklarına* göre sonuçlar değerlendirildiğinde; yaklaşım katsayıları ile üretilen özniteliklerin sınıflandırılmasında 0-1.5 saniye aralığında en yüksek başarımın (DVM ile %84.98) elde edildiği görülmüştür. Alt batlardan yeniden oluşturulmuş işaretlerden üretilen özniteliklerin sınıflandırılmasında 0-2.5 saniye aralığında en yüksek başarımın (DVM ile %88.40) elde edildiği görülmüştür. Hibrid yaklaşım ile elde edilen özniteliklerin sınıflandırılmasında 0-1.5 saniye aralığında en yüksek başarımın (DVM ile %94.19) elde edildiği görülmüştür. Böylelikle işaretin tamamının yerine başlangıçtan itibaren belirli bir aralığının kullanılması ile daha yüksek başarımın elde edilebileceği görülmüştür. Bu durum, işlenecek veri yığınının ve dolayısıyla işlem hacminin azalmasını sağlamıştır.

4) *Öznitelikler* bakımından incelendiğinde ise farklı öznitelikler ile yüksek başarımların elde edildiği görülmüştür. Yaklaşım katsayılarının ortalama değeri ve maksimum mutlak değeri öznitelik olarak değerlendirilmiş ve en yüksek başarımın %84.98 olduğu gözlenmiştir. Alt bantlardan yeniden oluşturulmuş

işaretlerin 3 eşit parçaya bölünerek maksimumlarının oranları öznitelik olarak kullanılmış ve en yüksek başarımın %88.40 olduğu gözlemlenmiştir. Bu sonuçlar seçilen özniteliklerin doğru seçimler olduğunu gösterir. Bu özniteliklerin birleştirilmesi ile başarımın artacağı öngörülerek yapılan sınıflandırmada ise başarımın %94.19 değerine yükseldiği görülmüştür.

Bu tez kapsamında kullanılan veri seti ilk olarak BCI-2003 yarışmasında kullanılmış ve en yüksek başarım %88.70 olarak elde edilmiştir. Yarışmacıların farklı öznitelikler (DC potansiyeller, skalaogram tepesi algılama, Fourier katsayıları, zaman alanında ortalamalar, vb.) ve sınıflandırıcılar (LDA, DVM, YSA, Bayes, vb.) kullanarak çalışmalarını gerçeklemişlerdir. Aynı veri tabanı ile sonradan üç farklı çalışma yapılmıştır. 2007 yılında Wu Ting ve ark. tarafından çalışılmış ve %90.80 başarımı elde edilmiştir. Çalışmada öznitelik olarak ADD ile 6. seviye katsayılarının ortalama ve enerji değerleri PNN ile sınıflandırılmıştır. 2008 yılında Aydemir ve ark. tarafından çalışılmış ve %92.20 başarımı elde edilmiştir. Çalışmada öznitelik olarak 2. derece polinom katsayıları ve tepe noktaları, k-NN ve DVM ile sınıflandırılmıştır. 2015 yılında Qin Lin ve ark. tarafından çalışılmış ve %93.90 başarımı elde edilmiştir. Çalışmada öznitelik olarak zaman ve frekans domeninde farklı öznitelikler elde edilmiştir. Bu öznitelikler GA-ELM ile sınıflandırılmıştır. Bu tez kapsamında yapılan çalışma ile elde edilen başarımın (%94.88), yukarıda sözü edilen çalışmalara ilişkin başarımların üzerinde olduğu görülmüştür. Çalışmalarda başarımı etkileyen en önemli faktörün öznitelikler olduğu görülmektedir.

Genel olarak yapılan çalışmalar incelendiğinde, farklı paradigmalar kapsamında elde edilen EEG işaretleri farklı bilim dalları tarafından değerlendirilmektedir. Temelde bu çalışmaların amacı, beyin dinamiğinin anlaşılabilmesi üzerinedir. Bu tez çalışmasında kullanılan EEG işaretleri de aynı amaç için kullanılmış ve önerilen yöntemin başarıyla uygulanabilir olduğu görülmüştür.

7. KAYNAKLAR

7. KAYNAKLAR

Abidi I., Farooq O., 2015, Sweet And Sour Taste Classification Using EEG Based Brain Computer İnterface, Annual IEEE India Conference (INDICON), 1-5.

Adeli, H., Zhou, Z., Dadmehr, N. 2003. Analysis of EEG records in an epileptic patient using wavelet transform. ***Journal of Neuroscience Methods*** 123, 69-87.

Altınbaş, A. 2007. EMG Sinyallerinin Kısa Zamanlı Fourier Dönüşümü Ve Dalgacık Dönüşümü Kullanarak Analiz Edilmesi. Yüksek Lisans Tezi, Gazi Üniversitesi Fen Bilimleri Enstitüsü, Ankara, 39.

Amin, H.U. 2015, Feature Extraction And Classification For EEG Signals Using Wavelet Transform And Machine Learning Techniques, Australasian College of Physical Scientists and Engineers in Medicine 38, 139–149.

Anchalia, P., Roy, K. The k-Nearest Neighbor Algorithm Using MapReduce Paradigm. 2014 Fifth International Conference on Intelligent Systems, Modelling and Simulation, 513-518.

Aydemir, Ö. 2008. Beyin Bilgisayar Arayüzü Uygulamalarına Yönelik EEG İşaretleri İçin Öznitelik Çıkarma. Yüksek Lisans Tezi, KTÜ Fen Bilimleri Enstitüsü, Trabzon, 7-8,40.

Aygün, O. 2006. Konuşmacı Tanıma Sistemlerinde Dalgacık Dönüşümü. Yüksek Lisans Tezi, Selçuk Üniversitesi Fen Bilimleri Enstitüsü, Konya, 57.

Başçıl, M.S. 2015 Beyinde Üretilen Yöne Bağlı EEG Sinyallerinin Öznitelik Çıkarımı Yardımıyla Sınıflandırılması. Doktora Tezi, Sakarya Üniversitesi Fen Bilimleri Enstitüsü, Sakarya, 1-2.

Batar, H. 2005. EEG işaretlerinin Dalgacık Analiz Yöntemleri Kullanılarak Yapay Sinir Ağları İle Sınıflandırılması. Yüksek Lisans Tezi, KSÜ Fen Bilimleri Enstitüsü, Kahramanmaraş, 6.

Blankertz, B., Mueller, K. R., Curio, G., Vaughan, T. M., Schalk, G., Wolpaw, J. R., Schloegl, A., Neuper, C., Pfurtscheller, G., Hinterberger, T., Schroeder, M. ve Birbaumer, N., The BCI Competition 2003, IEEE Trans. Biomed. Eng. XX(1044–1051).

Burges, J.C.,1998 A Tutorial on Support Vector Machines for Pattern Recognition, Data Mining and Knowledge Discovery, 2(121-167).

Chi-Hsuan Hsieh, Hao-Ping Chu, Yuan-Hao Huang. An HMM-based Eye Movement Detection System Using EEG Brain-Computer İnterface, 2014 IEEE International Symposium on Circuits and Systems (ISCAS), 662 – 665.

Dandan Huang, Peter Lin, Ding-Yu Fei, Xuedong Chen, Ou Bai. EEG-Based Online Two-Dimensional Cursor Control, 2009 Annual International Conference of the IEEE Engineering in Medicine and Biology Society, 4547 – 4550.

Demirci, D.A. 2007, Destek Vektör Makinaları İle Karakter Tanıma, Yüksek Lisans Tezi, Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü, İstanbul, 9.

7. KAYNAKLAR

Dong Ming, Yuhuan Zhu, Hongzhi Qi, Baikun Wan, Yong Hu, 2009. Study On EEG-Based Mouse System By Using Brain-Computer İnterface, IEEE International Conference on Virtual Environments, Human-Computer Interfaces and Measurements Systems, 236-239.

Doroshenkov, L. G., Konyshev, V. A. ve Selishchev, S. V., 2007, Classification of Human Sleep Stages Based on EEG Processing Using Hidden Markov Models, Biomedical Engineering, 41, 25-28.

Duman, Fırat. 2013. Destek Vektör Makineleri Yardımıyla İnvaziv EEG Verilerinden Epileptik Nöbet Tahmini. Yüksek Lisans Tezi, Mustafa Kemal Üniversitesi Fen Bilimleri Enstitüsü, Hatay, 25-27.

Erdoğan H. B., 2009, A Design And Implementation Of P300 Based Brain-Computer Interface, Middle East Technical University, Master of Science in Electrical and Electronics Engineering, Ankara, Türkiye.

Erişti, H. 2010. Güç Kalitesi İçin Dalgacık Dönüşümü Ve Destek Vektör Makine Tabanlı Bir Olay Tanıma Tekniğinin Geliştirilmesi. Doktora Tezi, Fırat Üniversitesi Fen Bilimleri Enstitüsü, Elazığ, 13.

Gernot R., Müller-Putz, Scherer, R., Pfurtscheller, G. ve Rupp, R., 2005, EEG-Based Neuroprosthesis Control: A Step Towards Clinical Practice, Neuroscience Letters, 382, 169–174.

Igel.C., Machine Learning: Kernel-based Methods., Department of Computer Science University of Copenhagen, 2(27).

Karadağ, K. 2013. ECoG Tabanlı Parmak Hareketlerinin k-NN Ve DVM Yöntemleri İle Sınıflandırılması, Yüksek Lisans Tezi, Dicle Üniversitesi Fen Bilimleri Enstitüsü, Diyarbakır, 32.

Khadidja Belattar; Sihem Mostefai, Similarity Measures for Content-Based Dermoscopic Image Retrieval: A comparative study. 2015 First International Conference on New Technologies of Information and Communication (NTIC), 3.

Luis A. Berrueta, Rosa M. Alonso-Salces, K´aroly H´eberger, 2007. Supervised Pattern Recognition in Food Analysis. ***Journal of Chromatography*** A, 1158, 196–214.

Minho Kim, Yongwook Chae, Sungho Jo, 2013. Hybrid EEG and Eye Movement Interface to Multi-Directional Target Selection. 35th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC), 763-766.

Misiti, M., Misiti, Y., Oppenheim, G., Poggi, J.M. 1997-2002. Wavelet Toolbox For Use with Matlab. The MathWorks Inc., United States. 1(10-14).

Mohammad H. Alomari. 2014, Wavelet Based Feature Extraction for the Analysis of EEG Signals Associated with Imagined Fists and Feet Movements, Computer and Information Science, 7(2).

Ocak H. 2009. Automatic Detection Of Epileptic Seizures in EEG Using Discrete Wavelet Transform and Approximate Entropy, Expert Systems with Applications 36, 2027–2036.

Ochoa J. B., Molina G. G., Ebrahimi T., 2002. EEG Signal Classification for Brain Computer Interface Applications, Ecole Polytechnique Federale De Lausanne, 11.

Pan J., Li Y., Wang J., 2016, An EEG Based Brain Computer Interface For Emotion Recognition, International Joint Conference on Neural Networks (IJCNN), 2063 – 2067.

Polat, H. 2016. Görsel-İşitsel Kaynaklı Uyaranlar Kaynaklı Oluşan Duyguların EEG İşaretleri ile Sınıflandırılması. Yüksek Lisans Tezi, Dicle Üniversitesi Fen Bilimleri Enstitisü, Diyarbakır, 42-43.

Pravın A. Kharat. 2012, Daubechies Wavelet Neural Network Classifier for the Diagnosis of Epilepsy, Wseas Transactıons On Bıology and Biomedicine, Issue 4, 9(103-113).

Sakkaff Z., Nanayakkara A. 2010, New set of cognitive tasks in EEG based Brain Computer Interface, 2010 Fifth International Conference on Information and Automation for Sustainability. 70-74.

Sanei, S., Chambers, J. A. 2007. EEG Signal Processing. Center of Digital signal processing, United Kingdom, 1(13-17).

Şengil, E. 2004. Beyin Bilgisayar Ara yüzü (BCI). Yüksek Lisans Tezi, İTÜ Fen Bilimleri Enstitüsü, İstanbul, 7.

Tapan Gandhi. 2010. A Comparative Study of Wavelet Families for EEG Signal Classification, Neurocomputing 74, 17(3051-3057).

Tepe, C. 2009. EKG Sinyalinde Gürültü Gidermede Dalgacık Dönüşümü Kullanılması. Yüksek Lisans Tezi, 19 Mayıs Üniversitesi Fen Bilimleri Enstitüsü, Samsun, 26.

Teplan, M. 2002. Fundamentals of EEG Measurement, ***Measurement Science Review***, 2(1-11).

Vapnik , V., Statistical Learning Theory, Wiley, 1998.

Viswanathan, M., Kotagiri, R., 2004. Comparing the Performance of Support Vector Machines to Regression With Structural Risk Minimization, Proceedings of International Conference on Intelligent Sensing and Information Processing, 445 -449.

Vladimir N. Vapnik,.1999. An Overview of Statistical Learning Theory IEEE Transactıons On Neural Networks, 10(5).

Yıldırım, M. 2012. Kandaki Glikoz Ve HbA1c Değerlerinin Avuç İçi Nem Parametreleri Kullanılarak Destek Vektör Makinesi İle Sınıflandırılması. Yüksek Lisans Tezi, Dumlupınar Üniversitesi Fen Bilimleri Enstitüsü, Kütahya, 18.
http://bbci.de/competition/ii/tuebingen_desc_i.html Erişim tarihi: (02.09.2016)

EK-1

Kanal seçimi için kullanılan algoritmada kanal performansları ve k-NN komşuluk değeri (k).

A1 KANALI		
cA6	Performans %	k
TOPLAM	69,62	7
VARYANS	62,45	8
ENERJI	63,48	9
ENTROPI	62,11	9
MAX	68,6	5
MIN	65,87	10
ORTALAM	69,62	5
STD SAPMA	62,11	8

A2 KANALI		
cA6	Performans %	k
TOPLAM	68,94	9
VARYANS	54,26	3
ENERJI	44,71	1
ENTROPI	47,44	1
MAX	57,33	10
MIN	69,28	8
ORTALAM	68,94	9
STD SAPMA	54,94	3

FC3 KANALI		
cA6	Performans %	k
TOPLAM	53,24	1
VARYANS	65,18	10
ENERJI	51,19	9
ENTROPI	49,82	1
MAX	49,14	6
MIN	55,29	1
ORTALAM	53,24	1
STD SAPMA	65,18	9

cA5	Performans %	k
TOPLAM	72,69	6
VARYANS	58,36	5
ENERJI	63,82	7
ENTROPI	65,87	5
MAX	66,55	5
MIN	68,94	7
ORTALAM	72,69	6
STD SAPMA	58,36	5

cA5	Performans %	k
TOPLAM	69,28	10
VARYANS	57,67	10
ENERJI	47,09	3
ENTROPI	47,09	1
MAX	59,38	10
MIN	64,84	6
ORTALAM	69,28	10
STD SAPMA	58,02	10

cA5	Performans %	k
TOPLAM	48,12	4
VARYANS	65,18	8
ENERJI	49,82	3
ENTROPI	50,85	3
MAX	51,53	8
MIN	54,6	1
ORTALAM	48,12	4
STD SAPMA	65,18	8

cA4	Performans %	k
TOPLAM	76,45	5
VARYANS	56,31	9
ENERJI	65,52	7
ENTROPI	66,89	8
MAX	68,6	10
MIN	66,21	9
ORTALAM	76,45	5
STD SAPMA	56,31	9

cA4	Performans %	k
TOPLAM	66,89	5
VARYANS	63,48	9
ENERJI	43,68	1
ENTROPI	43,68	8
MAX	62,11	9
MIN	69,28	7
ORTALAM	66,89	5
STD SAPMA	63,48	8

cA4	Performans %	k
TOPLAM	49,14	1
VARYANS	62,79	8
ENERJI	49,82	3
ENTROPI	51,19	1
MAX	50,85	1
MIN	50,17	9
ORTALAM	49,14	1
STD SAPMA	62,79	8

cA3	Performans %	k
TOPLAM	77,13	7
VARYANS	54,94	5
ENERJI	62,79	9
ENTROPI	63,82	7
MAX	68,94	7
MIN	67,23	7
ORTALAM	**77,13**	7
STD SAPMA	54,94	5

cA3	Performans %	k
TOPLAM	64,84	9
VARYANS	59,04	5
ENERJI	44,36	9
ENTROPI	44,36	10
MAX	57,33	10
MIN	67,91	7
ORTALAM	64,84	9
STD SAPMA	59,38	9

cA3	Performans %	k
TOPLAM	53,58	3
VARYANS	59,72	9
ENERJI	47,78	1
ENTROPI	48,12	7
MAX	50,85	6
MIN	50,17	3
ORTALAM	53,58	3
STD SAPMA	59,72	9

CP3 KANALI		
cA6	Performans %	k
TOPLAM	53,24	6
VARYANS	61,09	7
ENERJI	49,48	10
ENTROPI	48,46	7
MAX	54,26	9
MIN	50,51	3
ORTALAM	53,24	6
STD SAPMA	65,18	9

FC4 KANALI		
cA6	Performans %	k
TOPLAM	57,67	7
VARYANS	51,53	5
ENERJI	57,33	7
ENTROPI	56,65	7
MAX	54,6	1
MIN	55,97	4
ORTALAM	57,67	7
STD SAPMA	52,9	6

CP4 KANALI		
cA6	Performans %	k
TOPLAM	49,82	1
VARYANS	54,6	3
ENERJI	51,19	10
ENTROPI	51,87	4
MAX	51,87	4
MIN	53,58	1
ORTALAM	49,82	1
STD SAPMA	54,26	3

cA5	Performans %	k
TOPLAM	1,53	4
VARYANS	64,16	3
ENERJI	48,8	5
ENTROPI	48,8	9
MAX	53,24	6
MIN	50,85	10
ORTALAM	51,53	4
STD SAPMA	63,82	3

cA5	Performans %	k
TOPLAM	55,63	7
VARYANS	58,7	4
ENERJI	53,92	7
ENTROPI	52,9	7
MAX	53,58	8
MIN	53,58	9
ORTALAM	55,63	7
STD SAPMA	58,7	4

cA5	Performans %	k
TOPLAM	49,82	1
VARYANS	55,29	7
ENERJI	52,55	1
ENTROPI	54,94	5
MAX	51,19	3
MIN	52,21	3
ORTALAM	48,8	10
STD SAPMA	54,6	7

cA4	Performans %	k
TOPLAM	53,24	5
VARYANS	59,72	3
ENERJI	50,51	7
ENTROPI	50,17	10
MAX	56,99	5
MIN	49,82	7
ORTALAM	53,24	5
STD SAPMA	59,72	3

cA4	Performans %	k
TOPLAM	52,21	9
VARYANS	55,97	10
ENERJI	53,92	10
ENTROPI	52,55	7
MAX	53,24	3
MIN	52,9	7
ORTALAM	52,21	9
STD SAPMA	56,31	10

cA4	Performans %	k
TOPLAM	50,51	1
VARYANS	56,65	4
ENERJI	53,58	7
ENTROPI	52,55	8
MAX	52,55	1
MIN	53,58	1
ORTALAM	49,82	1
STD SAPMA	56,65	4

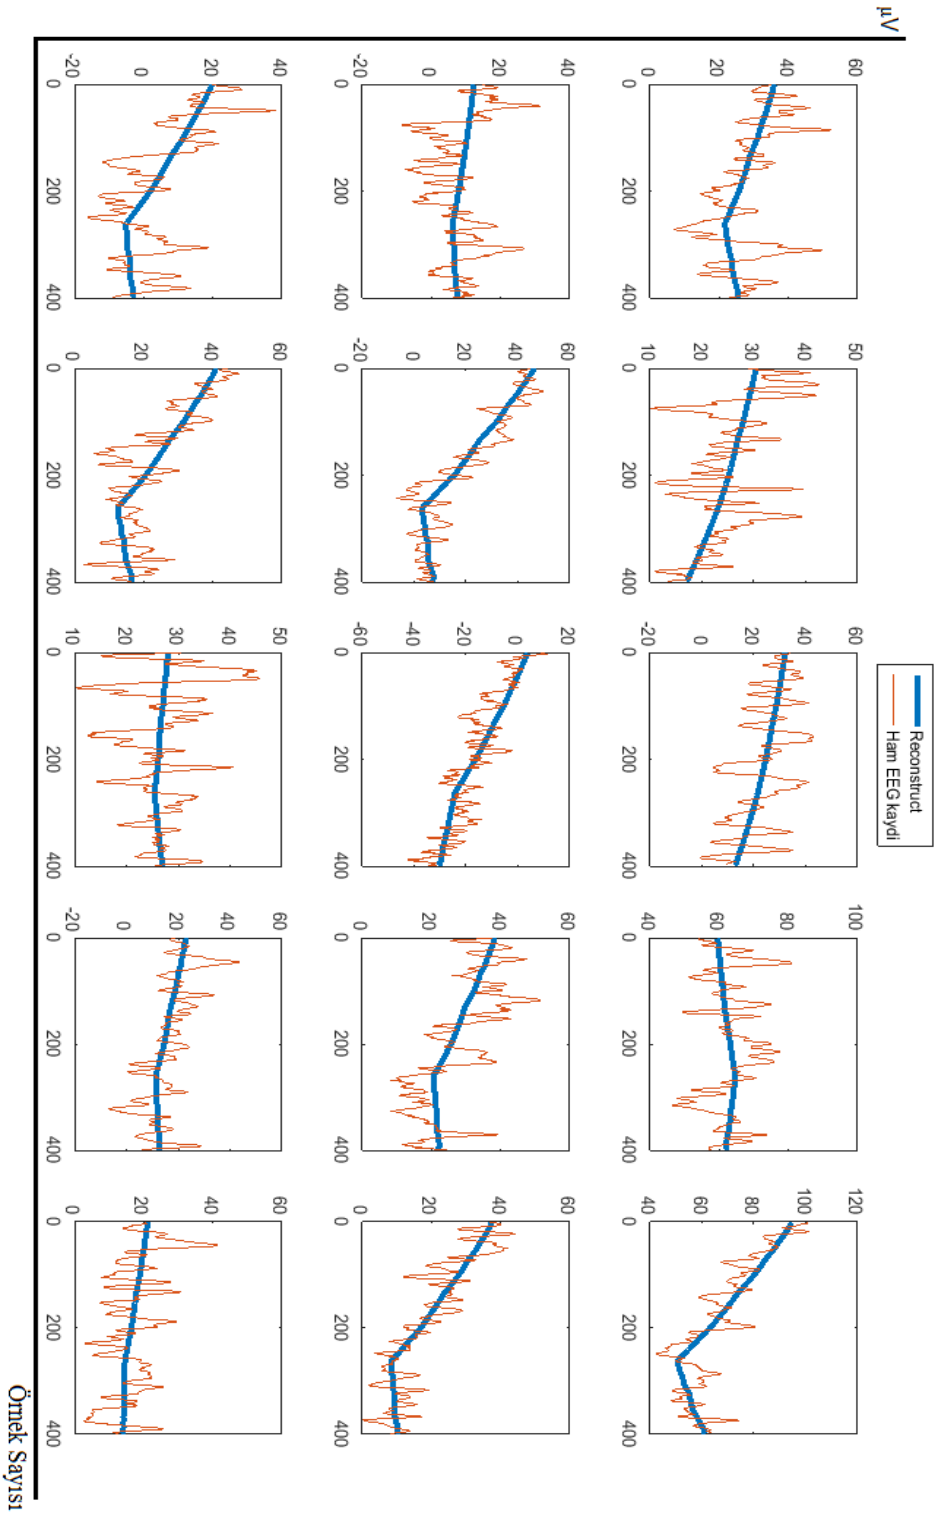
cA3	Performans %	k
TOPLAM	52,9	6
VARYANS	61,43	5
ENERJI	49,48	10
ENTROPI	50,51	9
MAX	52,55	5
MIN	47,78	3
ORTALAM	52,9	6
STD SAPMA	61,43	5

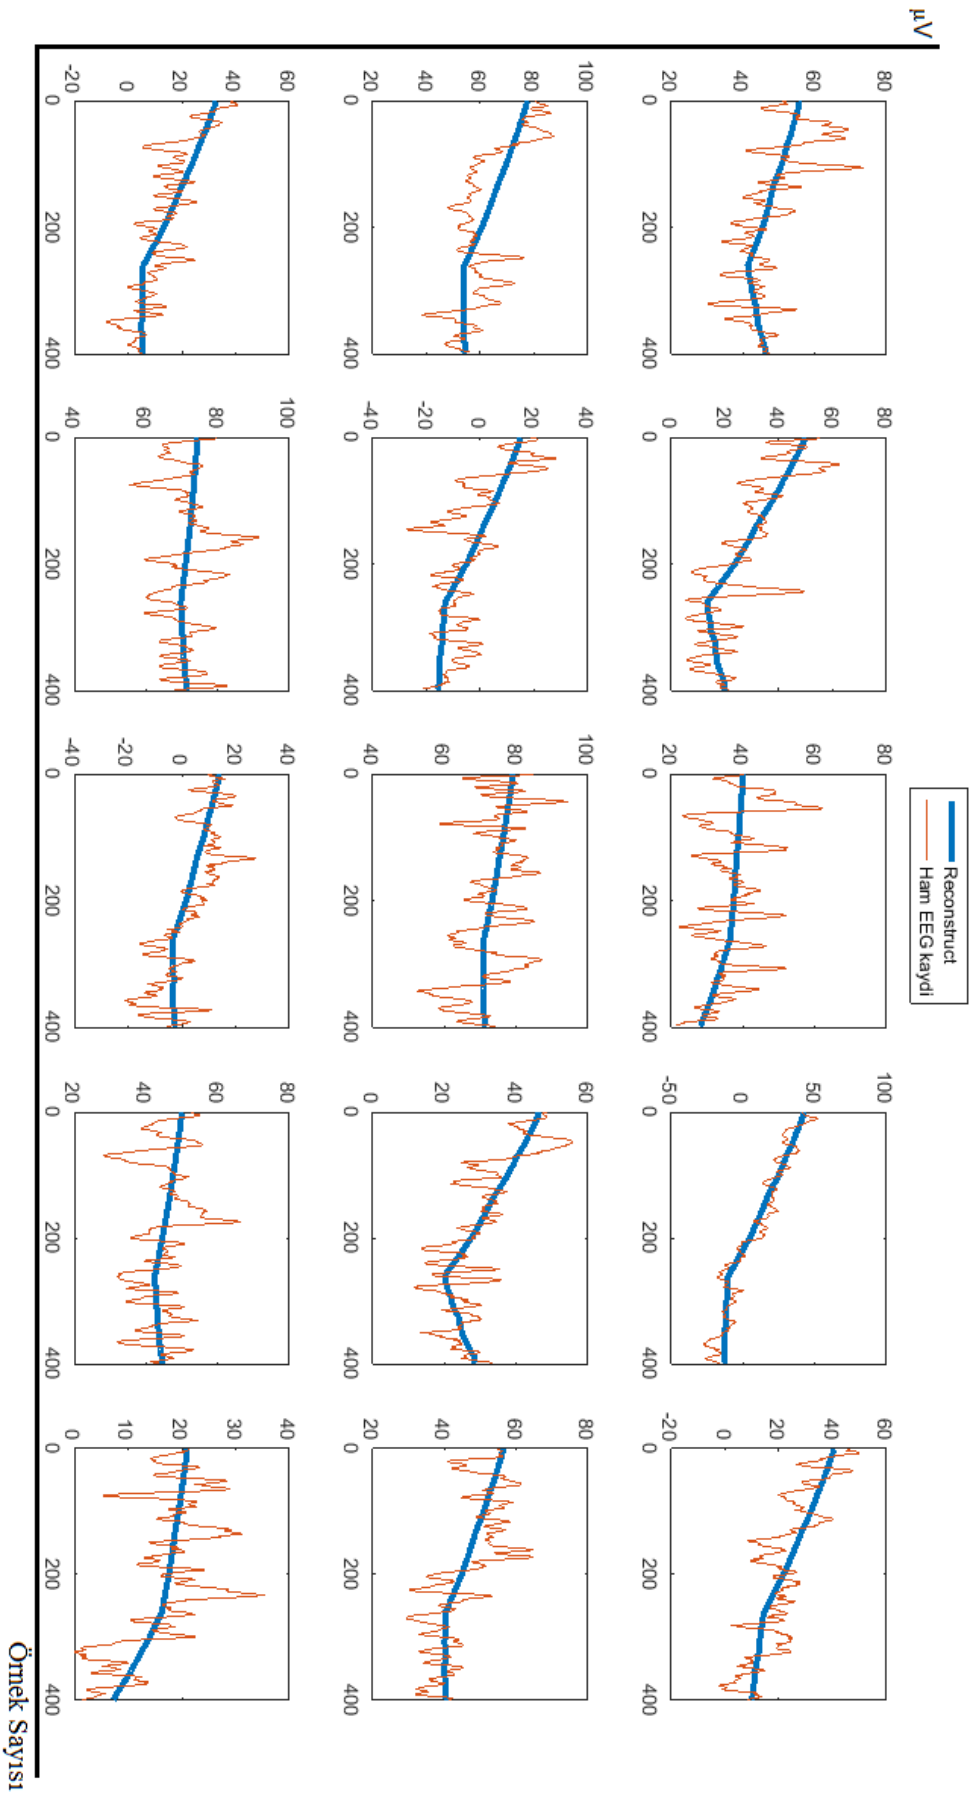
cA3	Performans %	k
TOPLAM	52,21	3
VARYANS	51,19	7
ENERJI	52,21	9
ENTROPI	52,55	9
MAX	55,63	8
MIN	55,29	9
ORTALAM	52,21	3
STD SAPMA	51,19	6

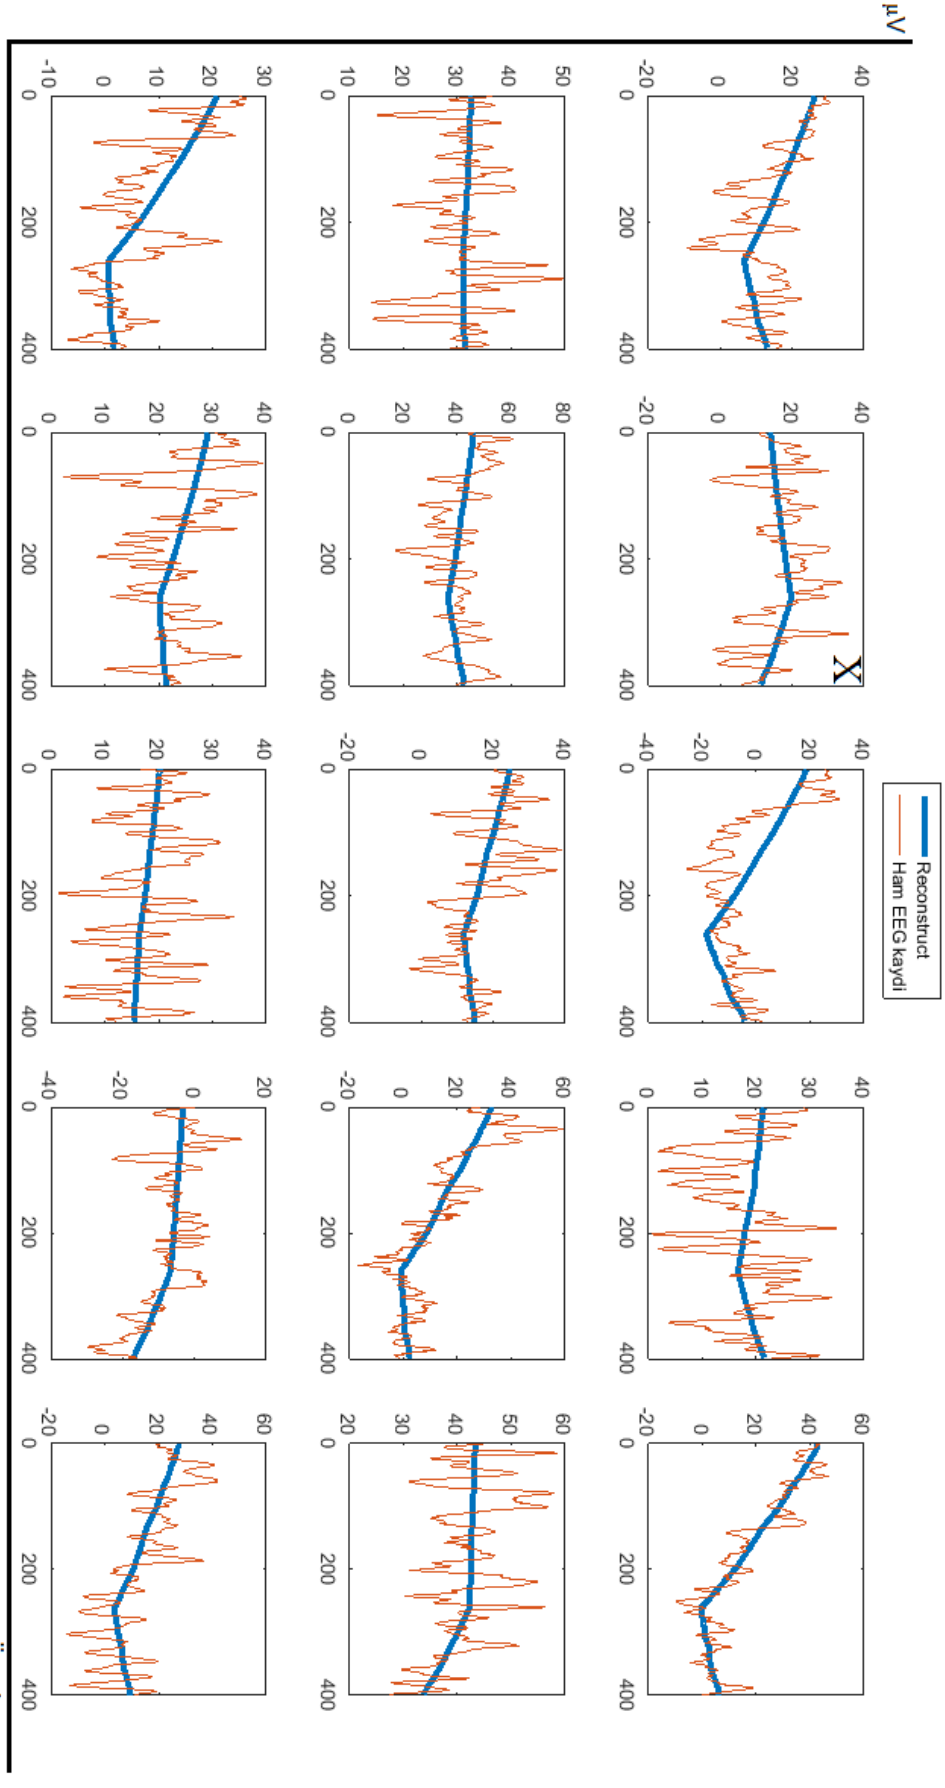
cA3	Performans %	k
TOPLAM	50,51	1
VARYANS	54,26	9
ENERJI	53,24	1
ENTROPI	50,51	1
MAX	57,33	4
MIN	51,53	3
ORTALAM	50,51	1
STD SAPMA	54,6	10

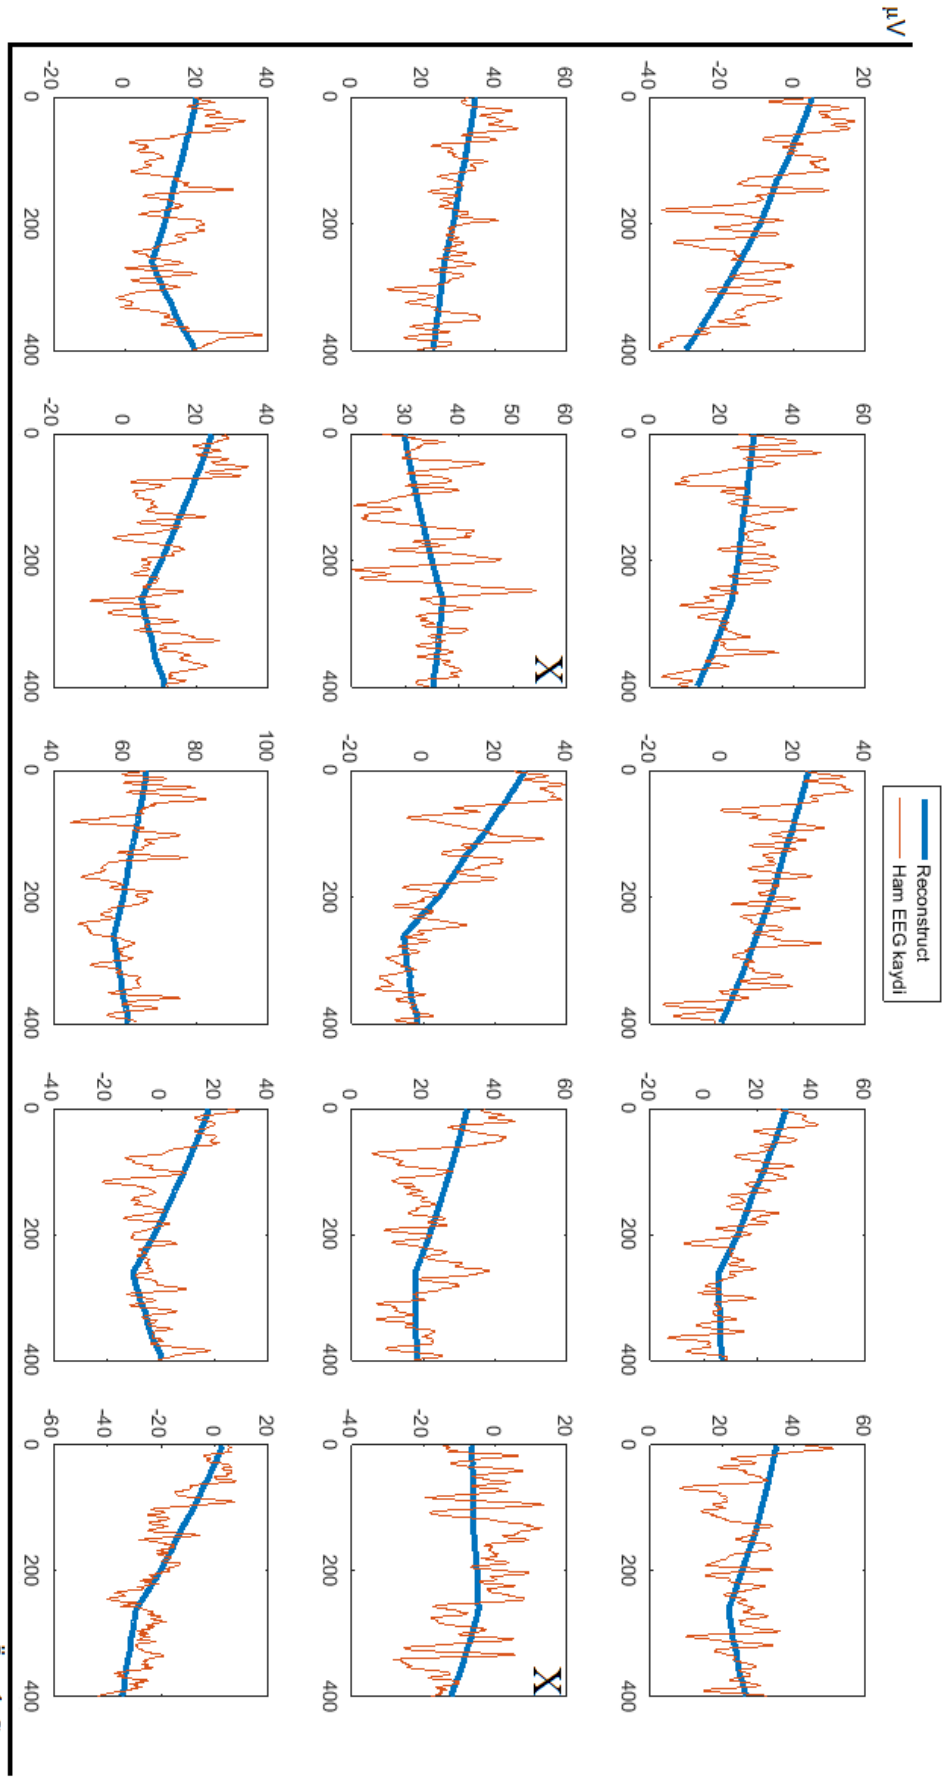
EK-2

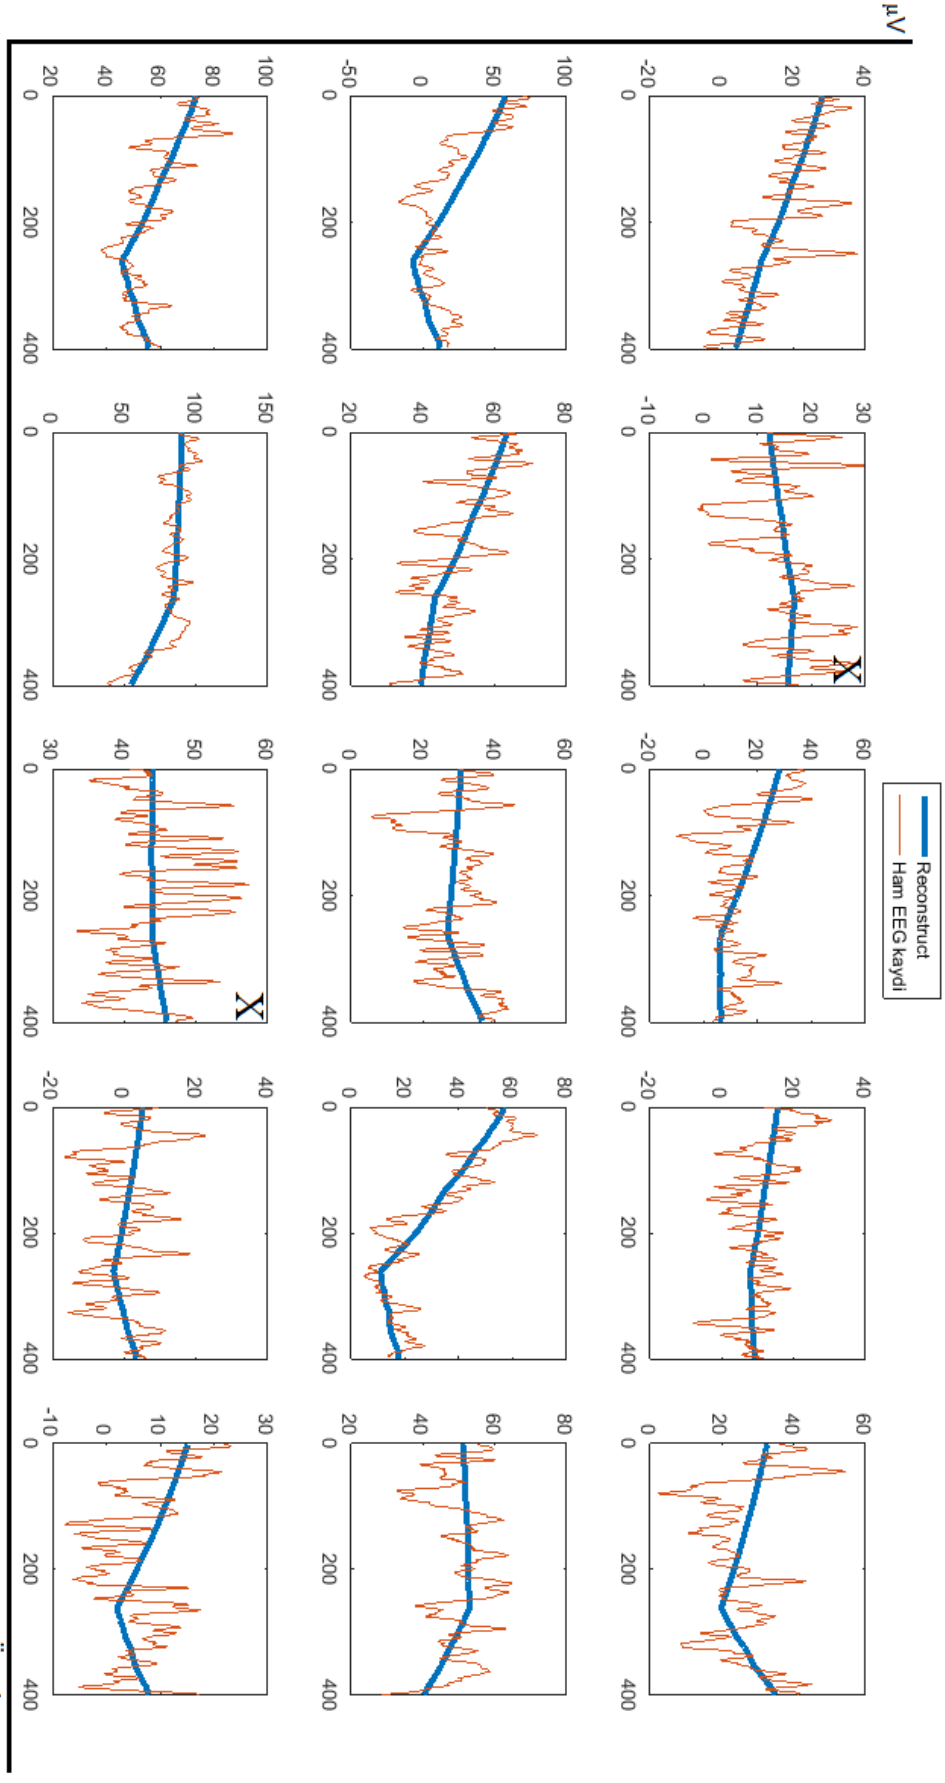
Aşağı imleç hareketlerine ilişkin 133 denemenin 0-399 arası örneklerin 8nci seviye yeniden oluşturulmuş formu ile Ham verinin üst üste çizimleri bu ekte mevcuttur. Şekillerde gözle görülür bir aşağı eğim fark edilmektedir. Bu eğimin olmadığı denemeler 'X' ile işaretlenmiştir.

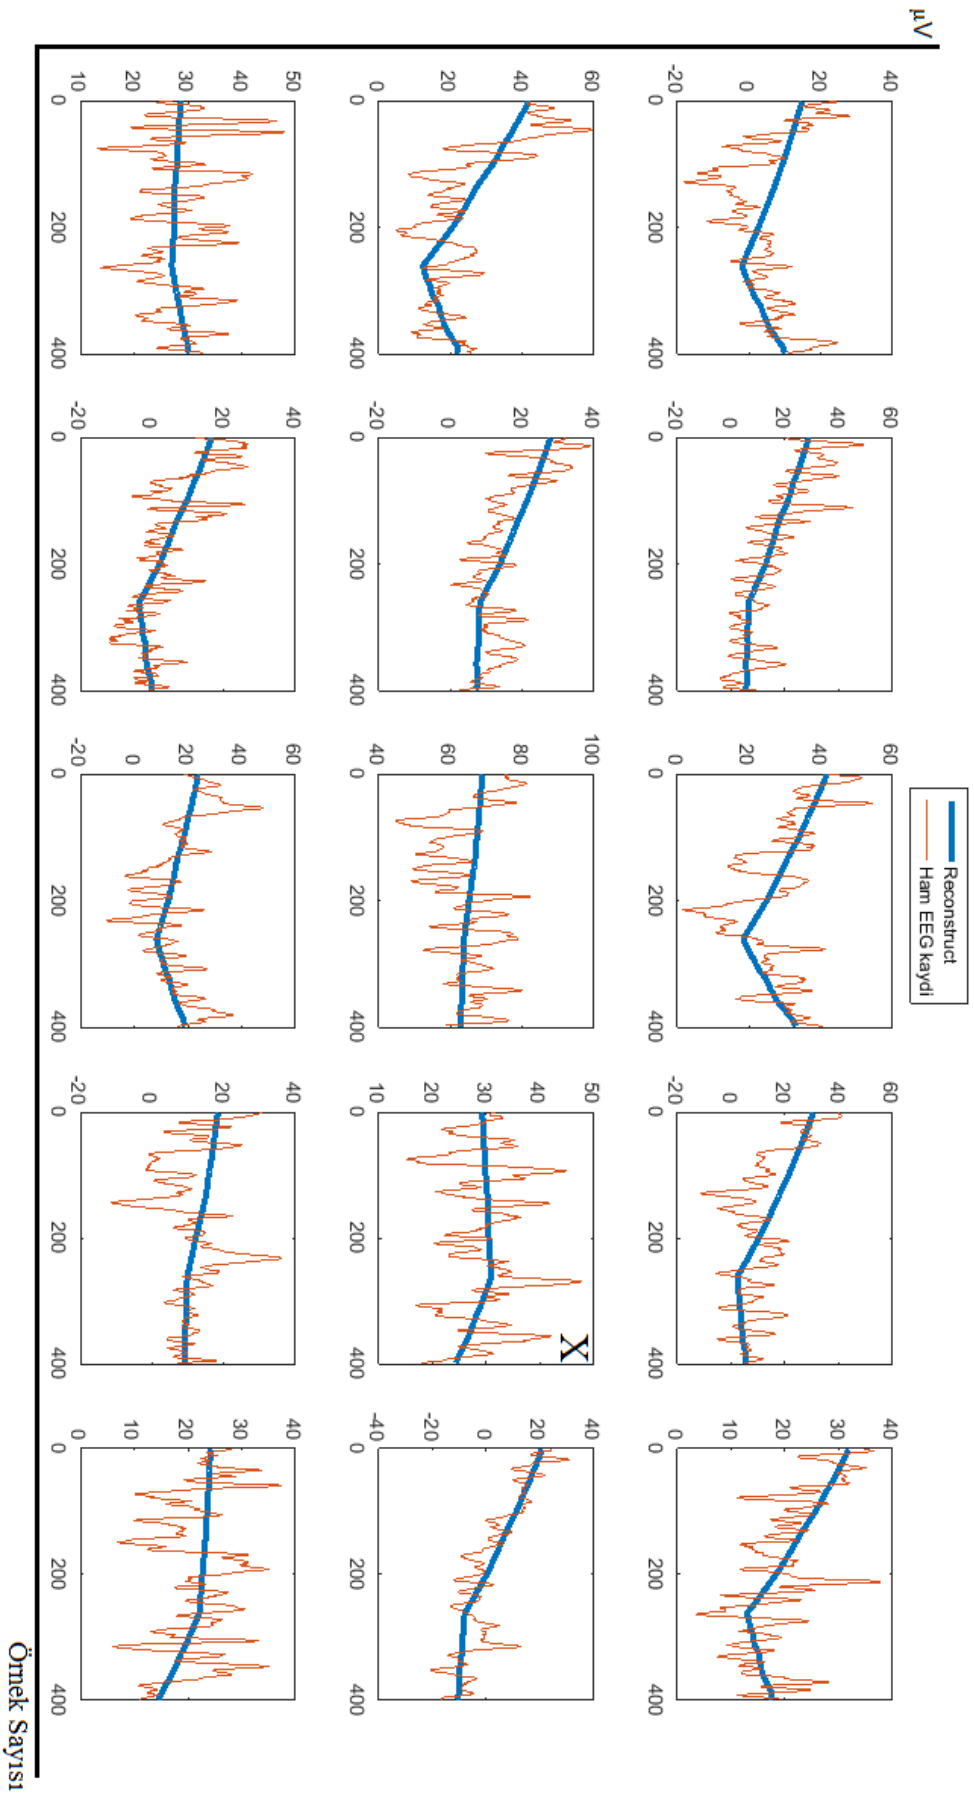


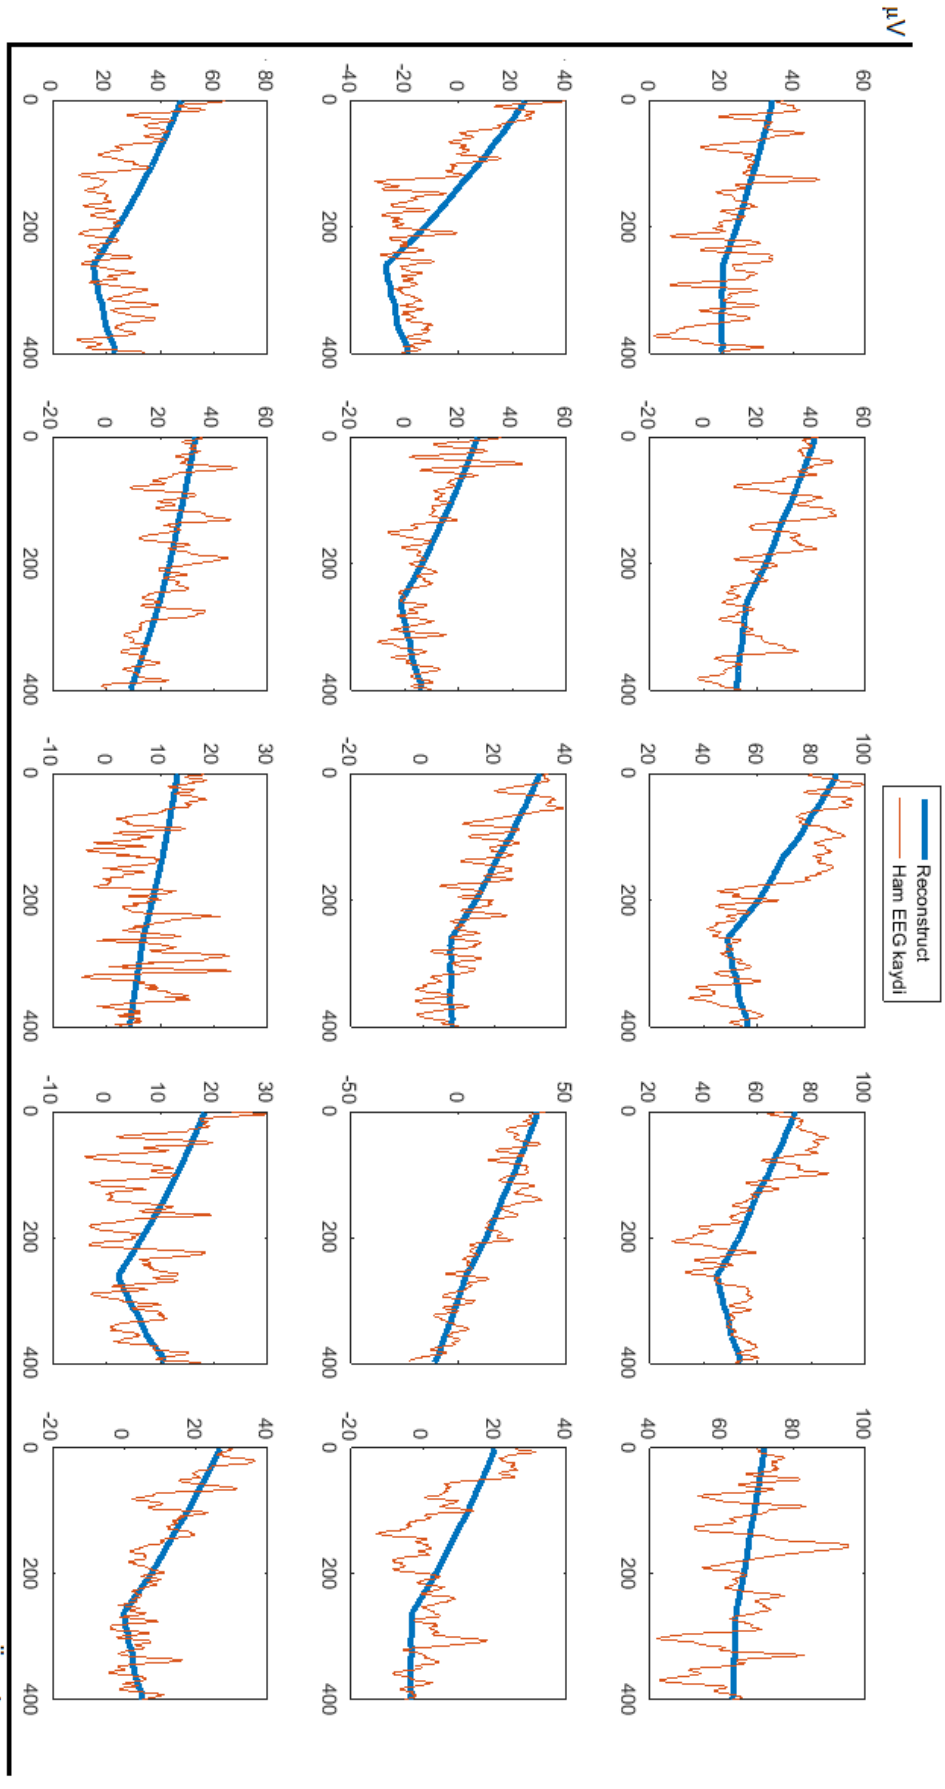

µV
Reconstruct
Ham EEG kaydı
Örnek Sayısı

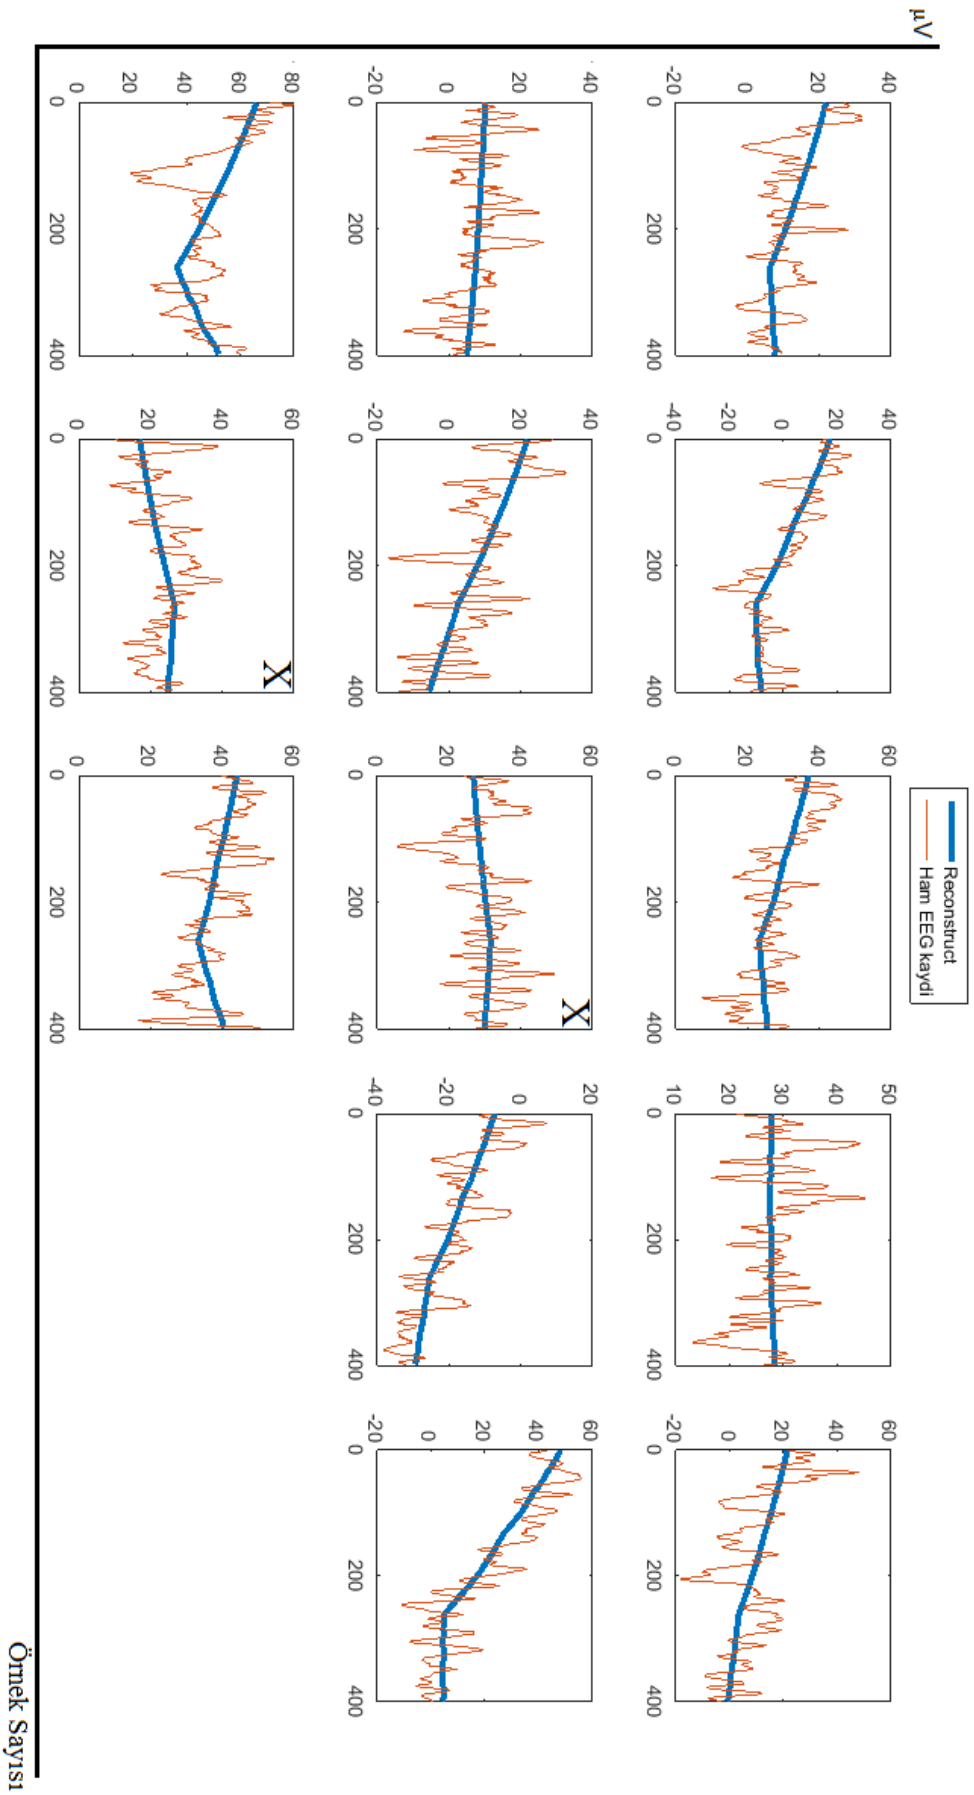

μV
Reconstruct
Ham EEG kaydı
X
Örnek Sayısı


µV
Reconstruct
Ham EEG kaydi
X
X
Örnek Sayısı

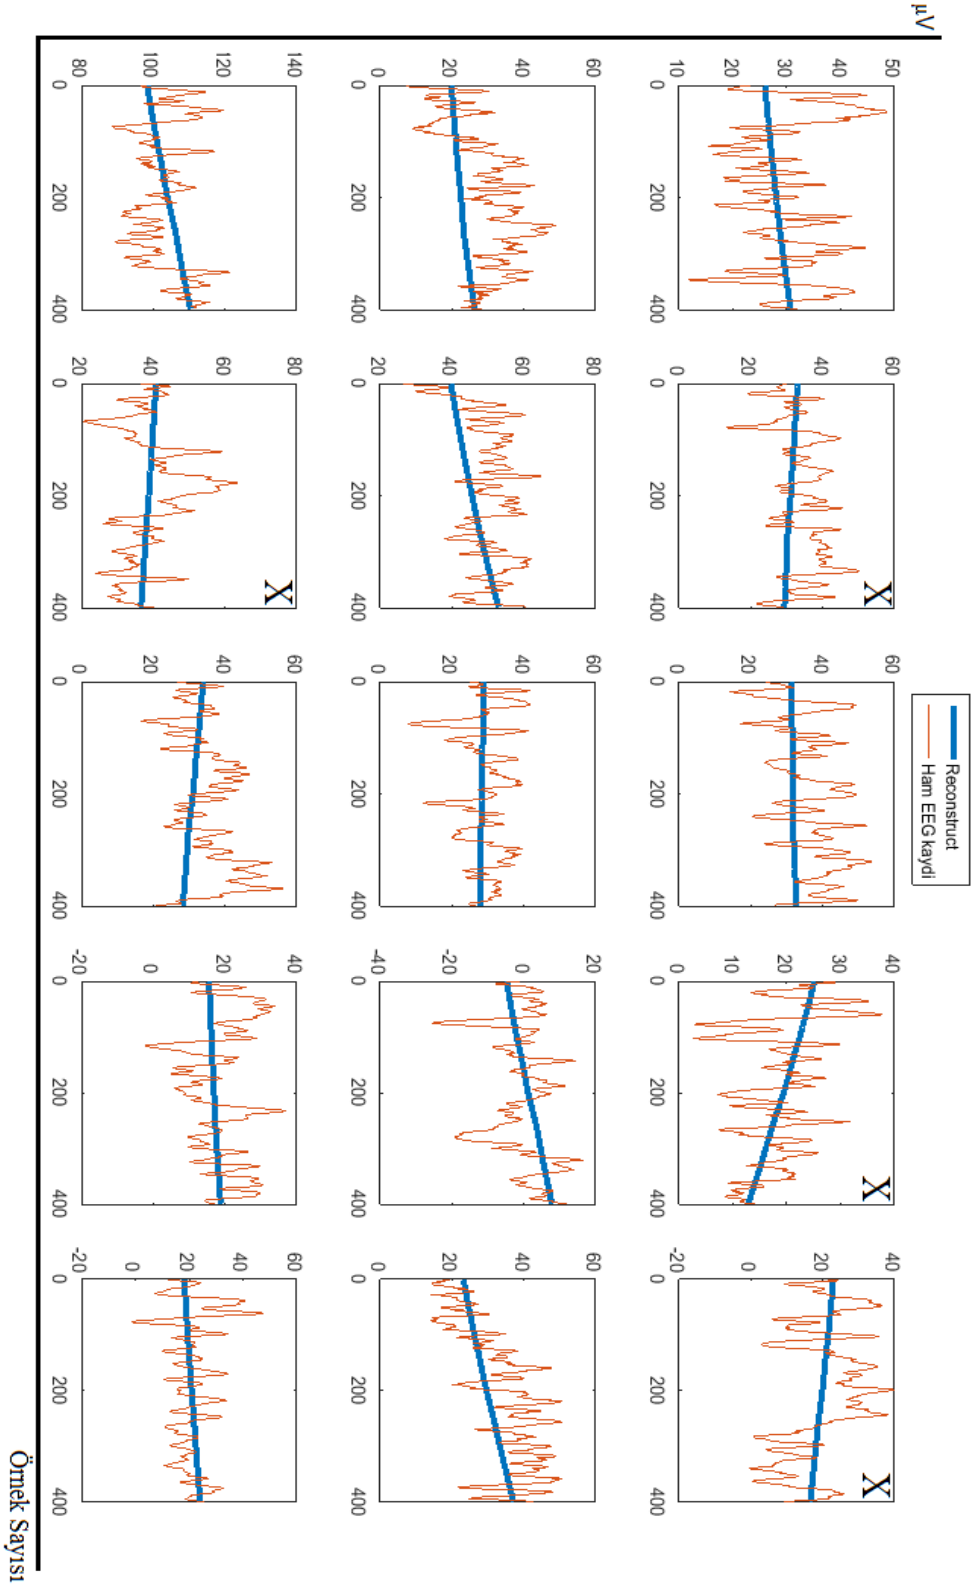

µV
Reconstruct
Ham EEG kaydı
Örnek Sayısı

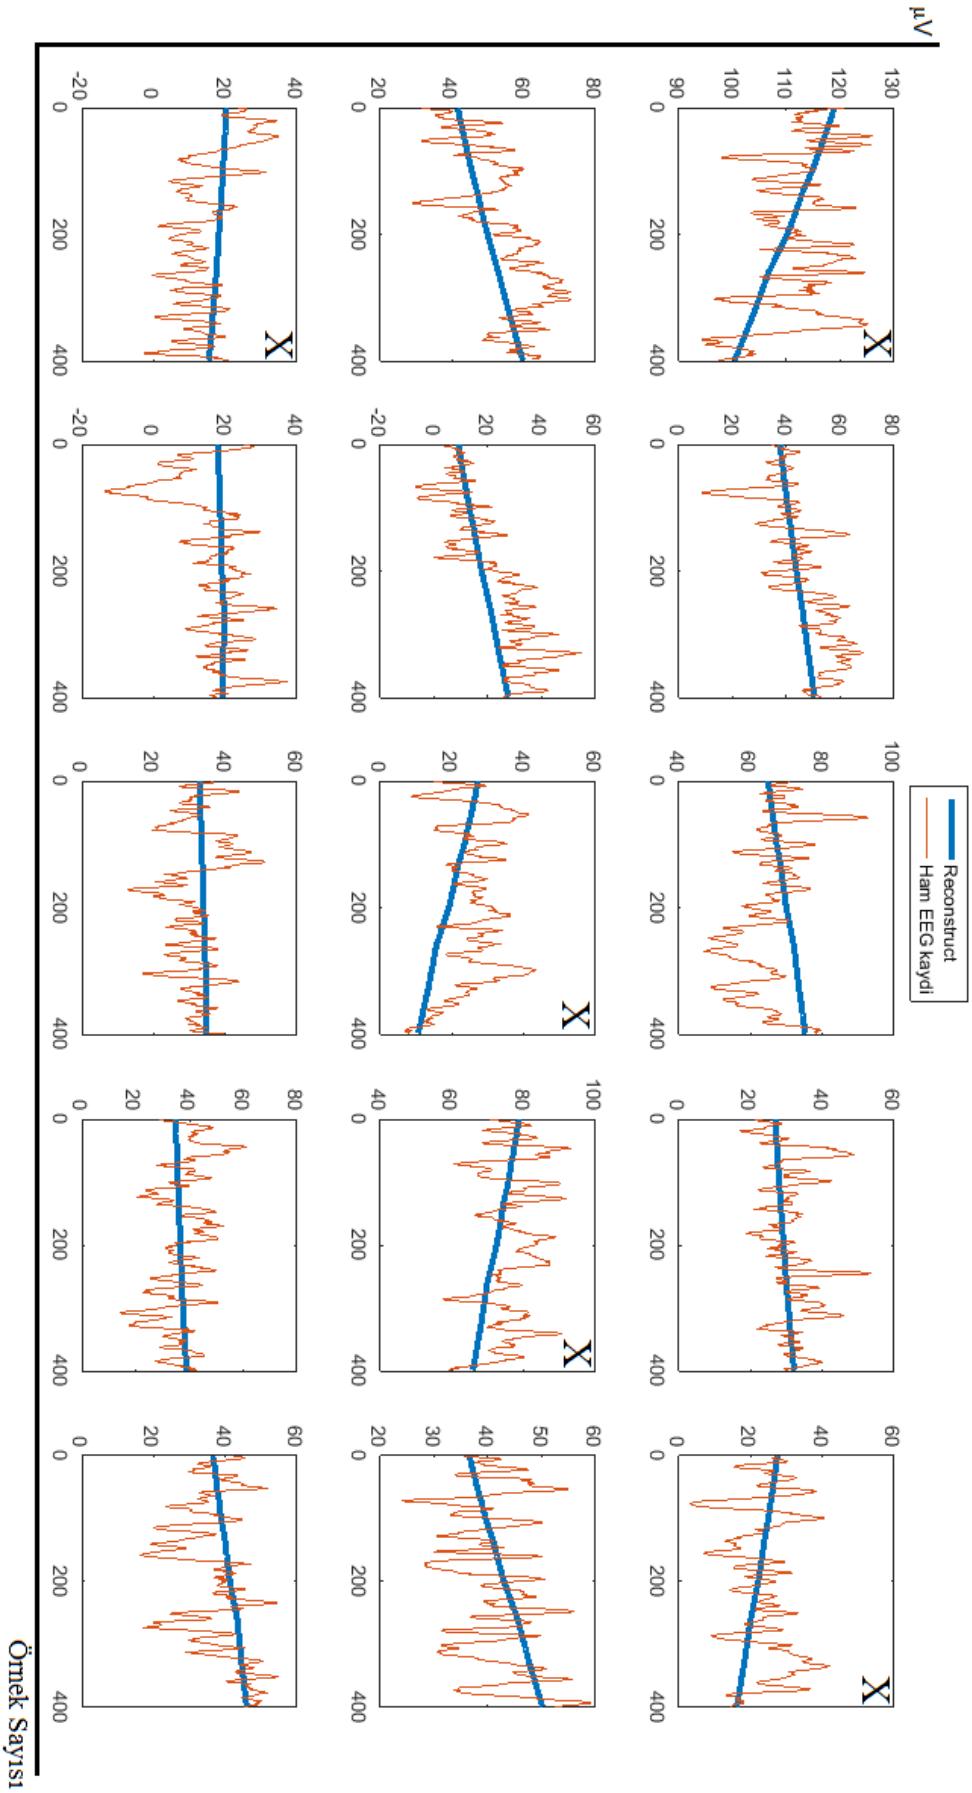

μV
Reconstruct
Ham EEG kaydi
X
Örnek Sayısı

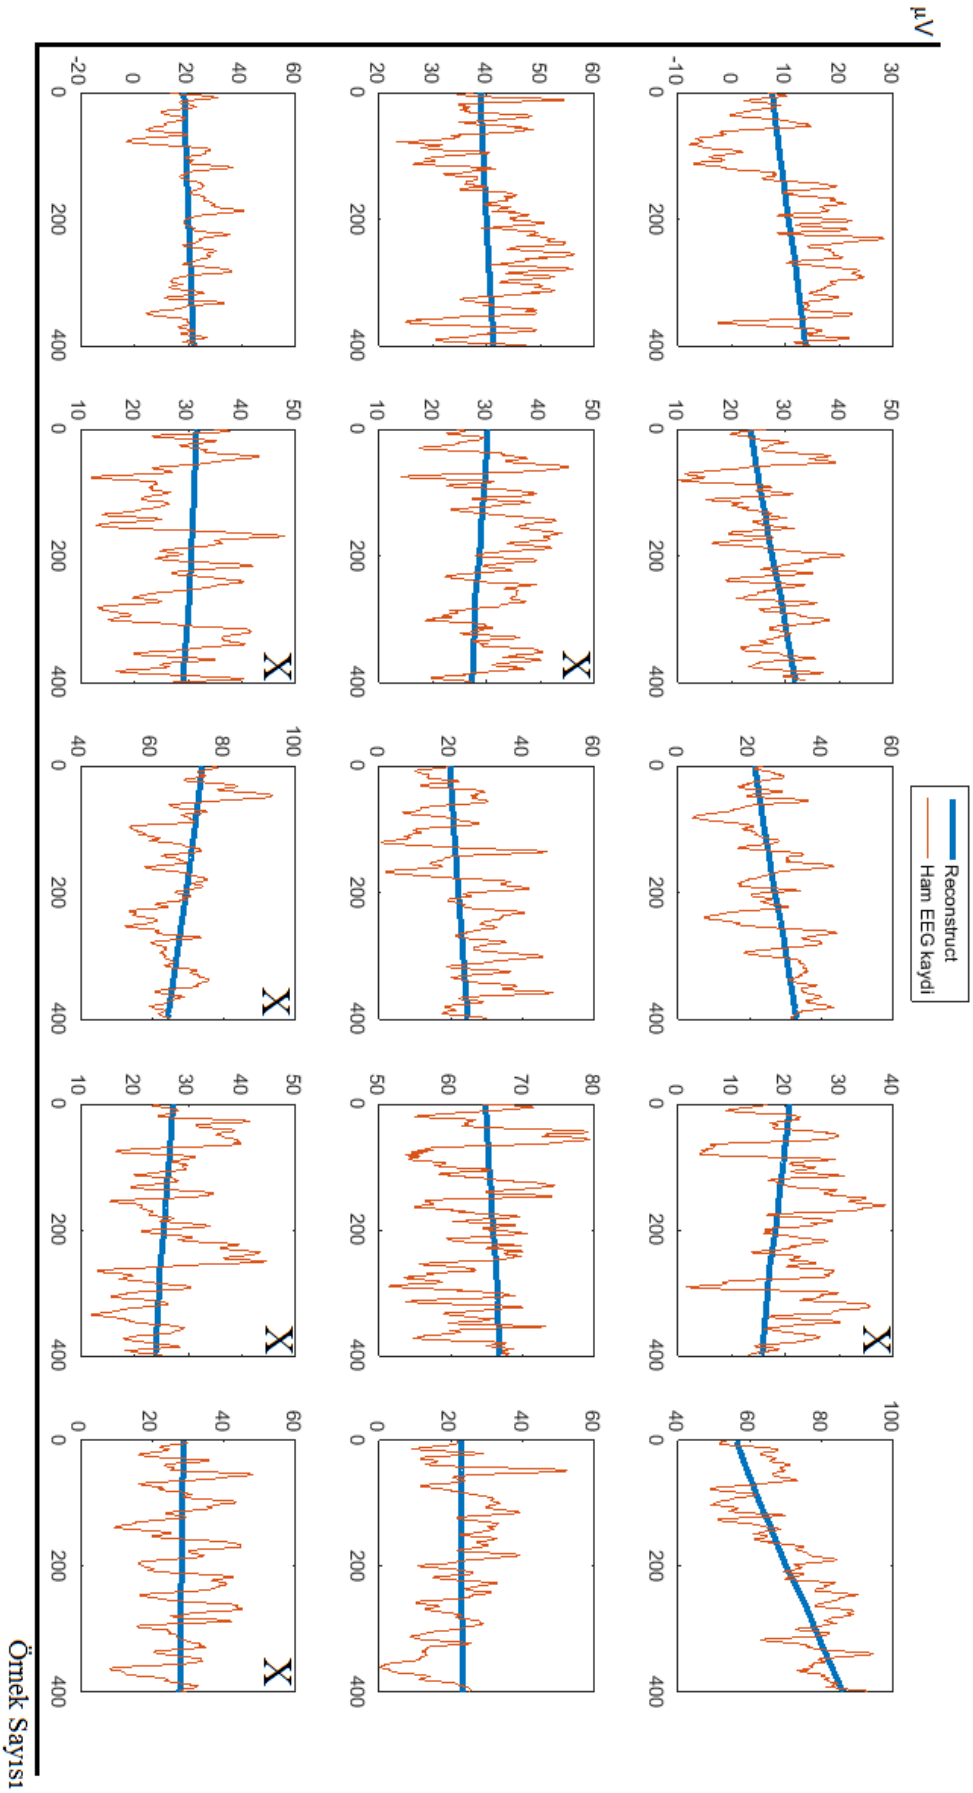

µV
Reconstruct
Ham EEG kaydı
Örnek Sayısı

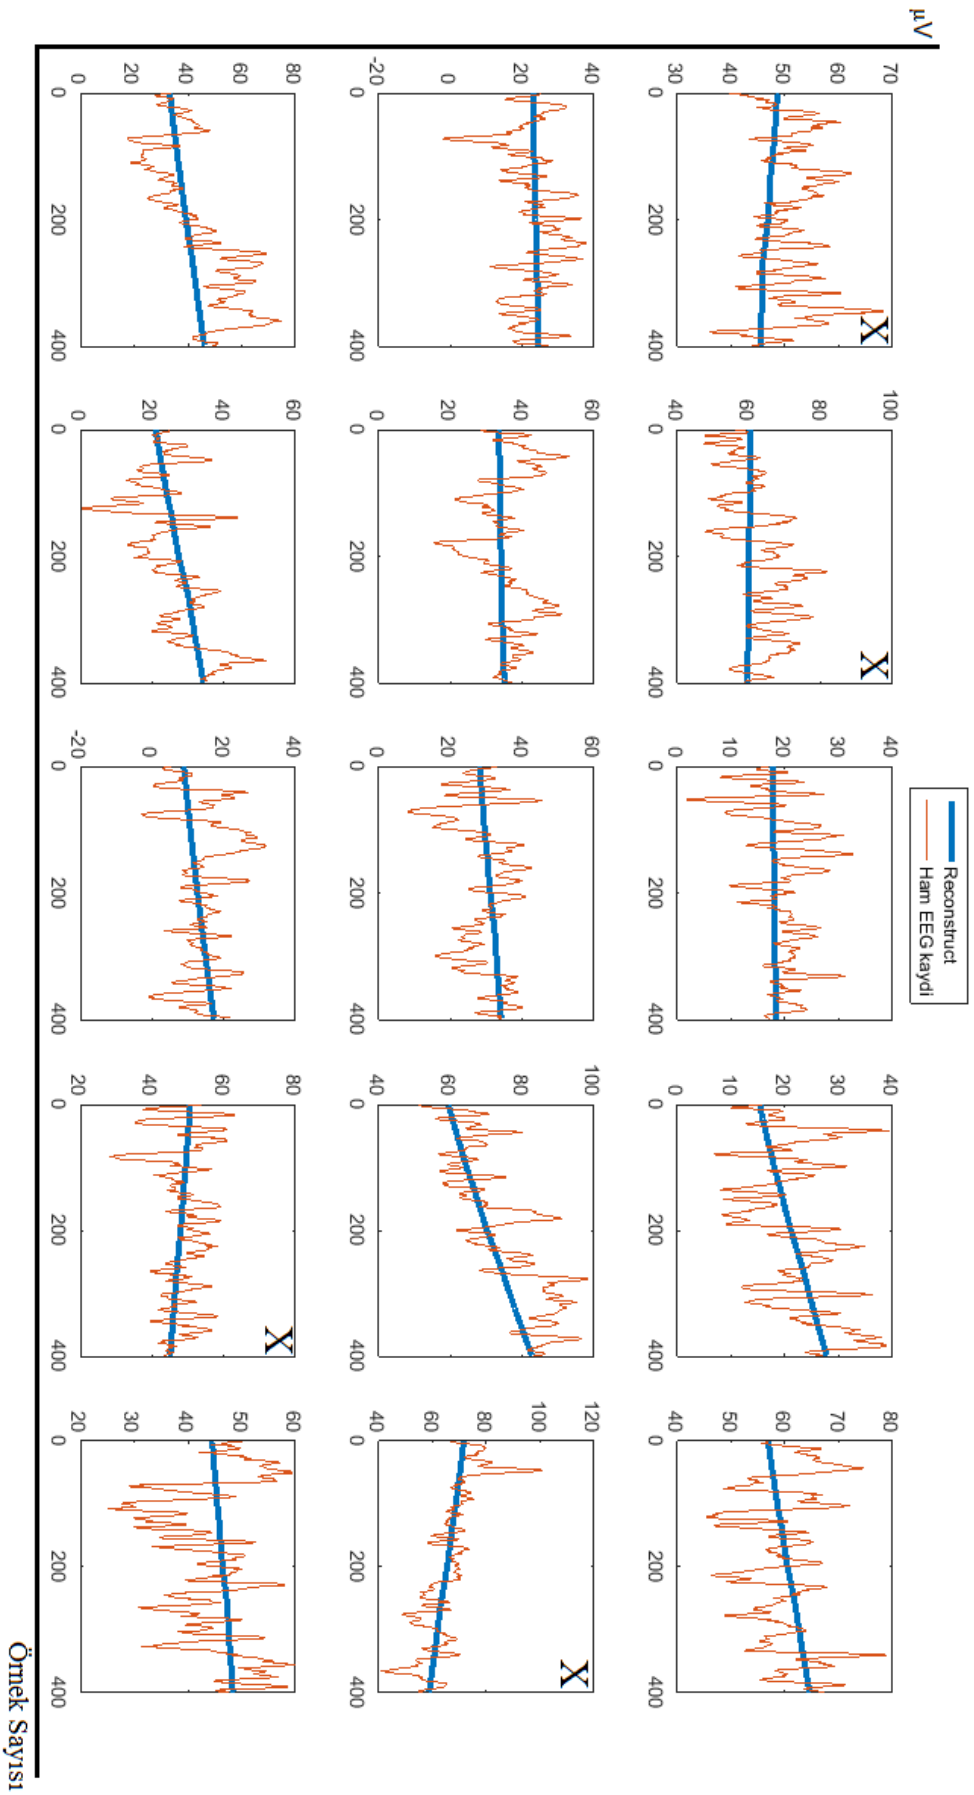

μV
Reconstruct
Ham EEG kaydı
X
X
Örnek Sayısı

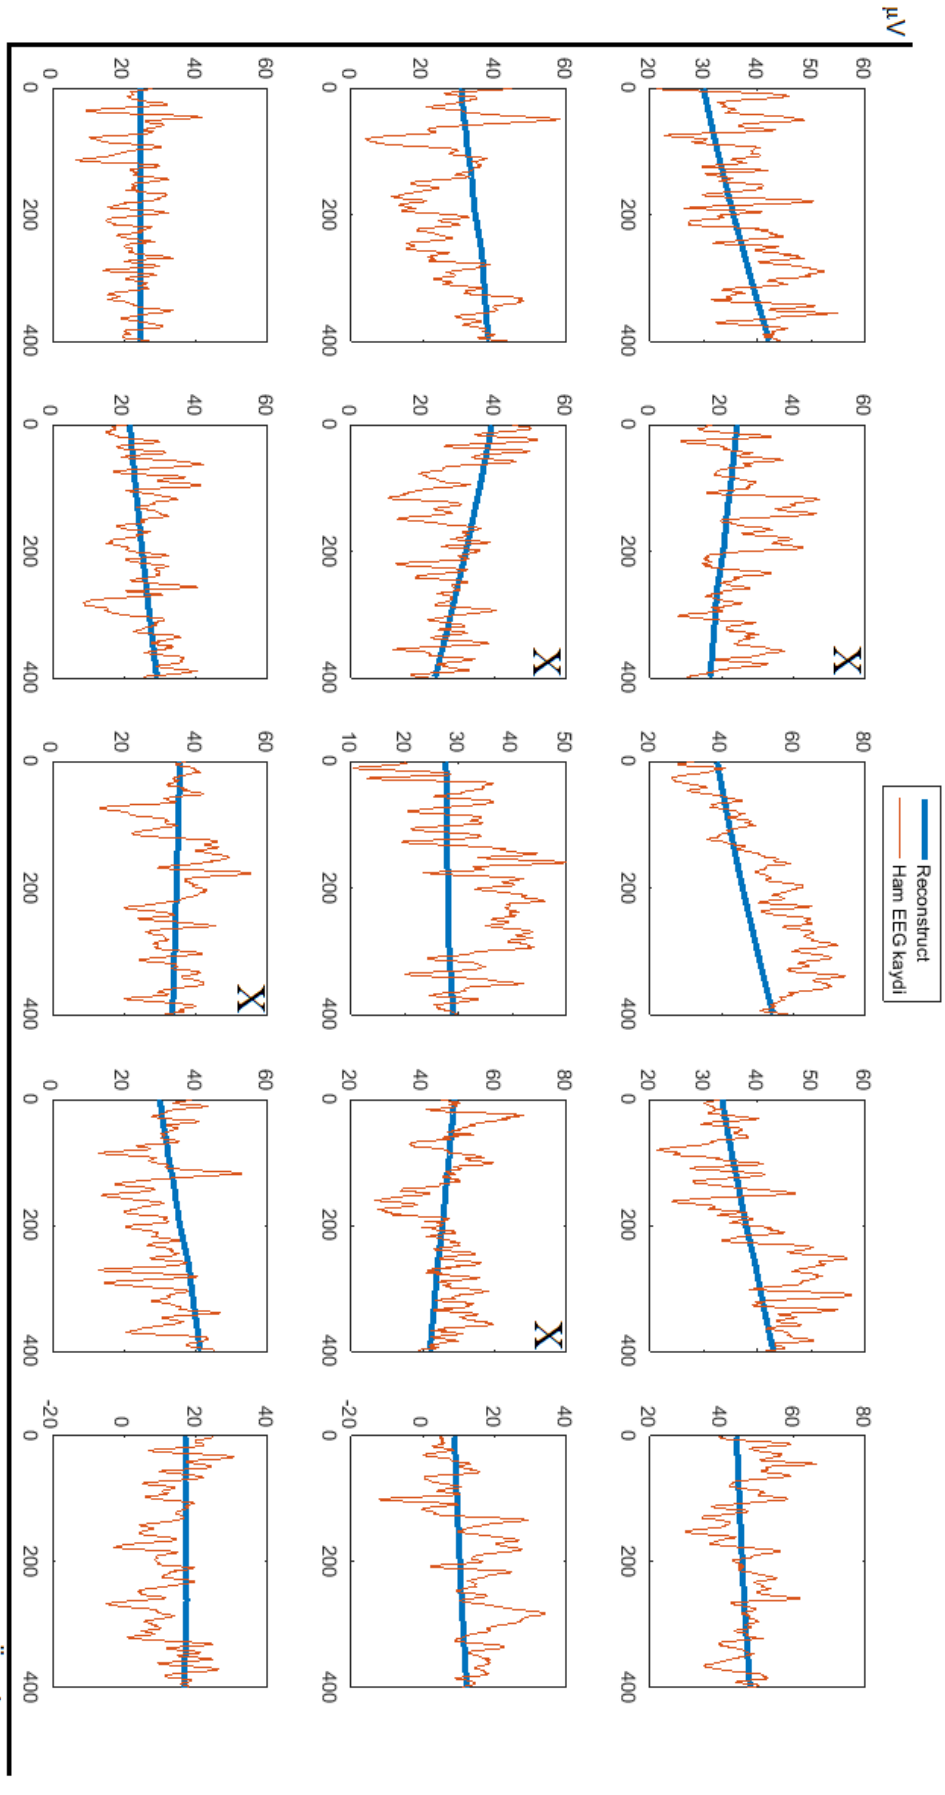
Yukarı imleç hareketlerine ilişkin 135 denemenin 0-399 arası örneklerin 8nci seviye yeniden oluşturulmuş formu ile Ham verinin üst üste çizimleri bu ekte mevcuttur. Şekillerde gözle görülür bir yukarı eğim fark edilmektedir. Bu eğimin olmadığı denemeler 'X' ile işaretlenmiştir.

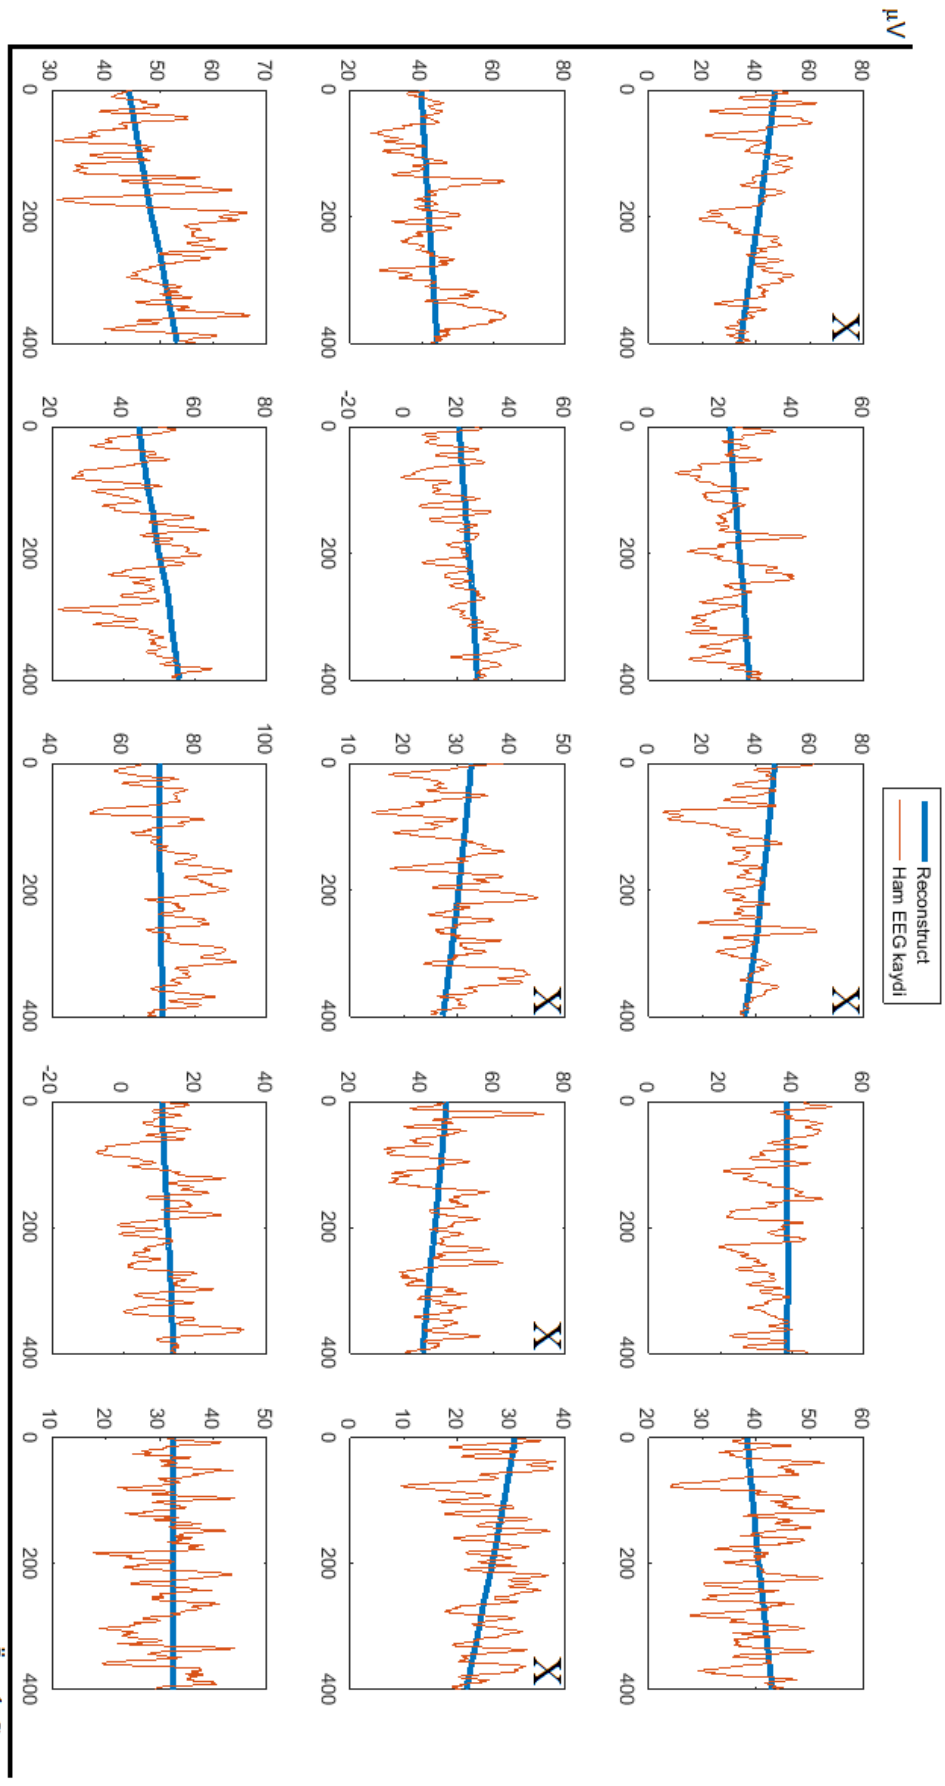


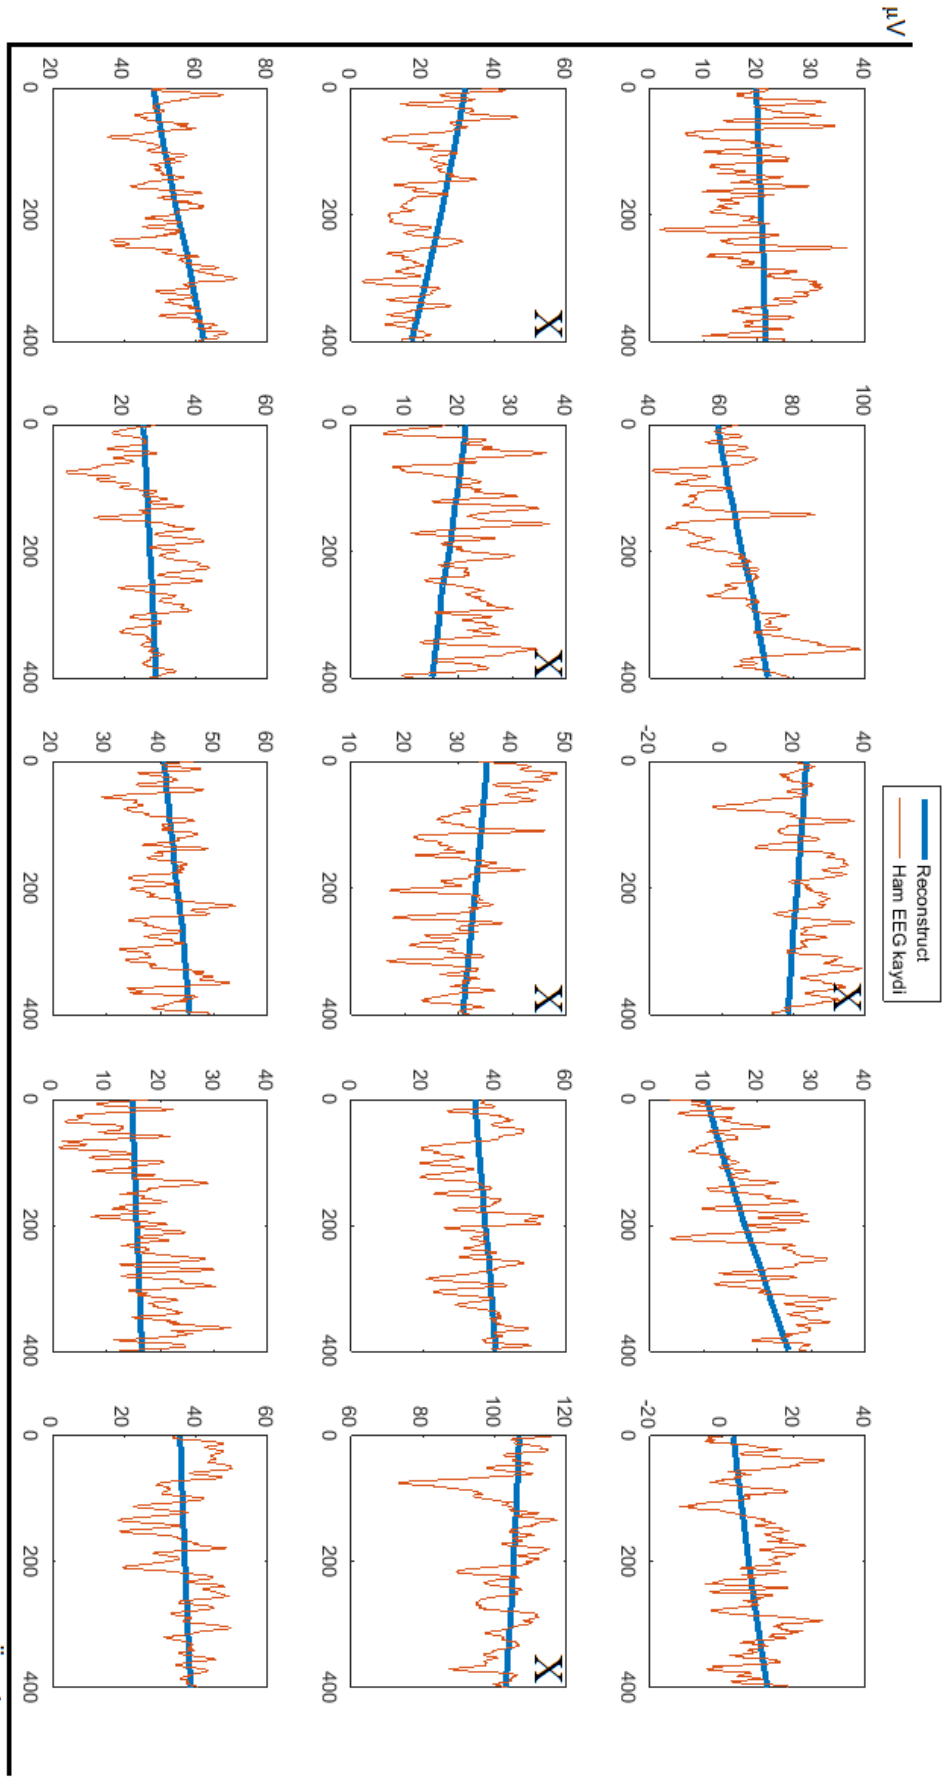

µV
Reconstruct
Ham EEG kaydı
X
Örnek Sayısı

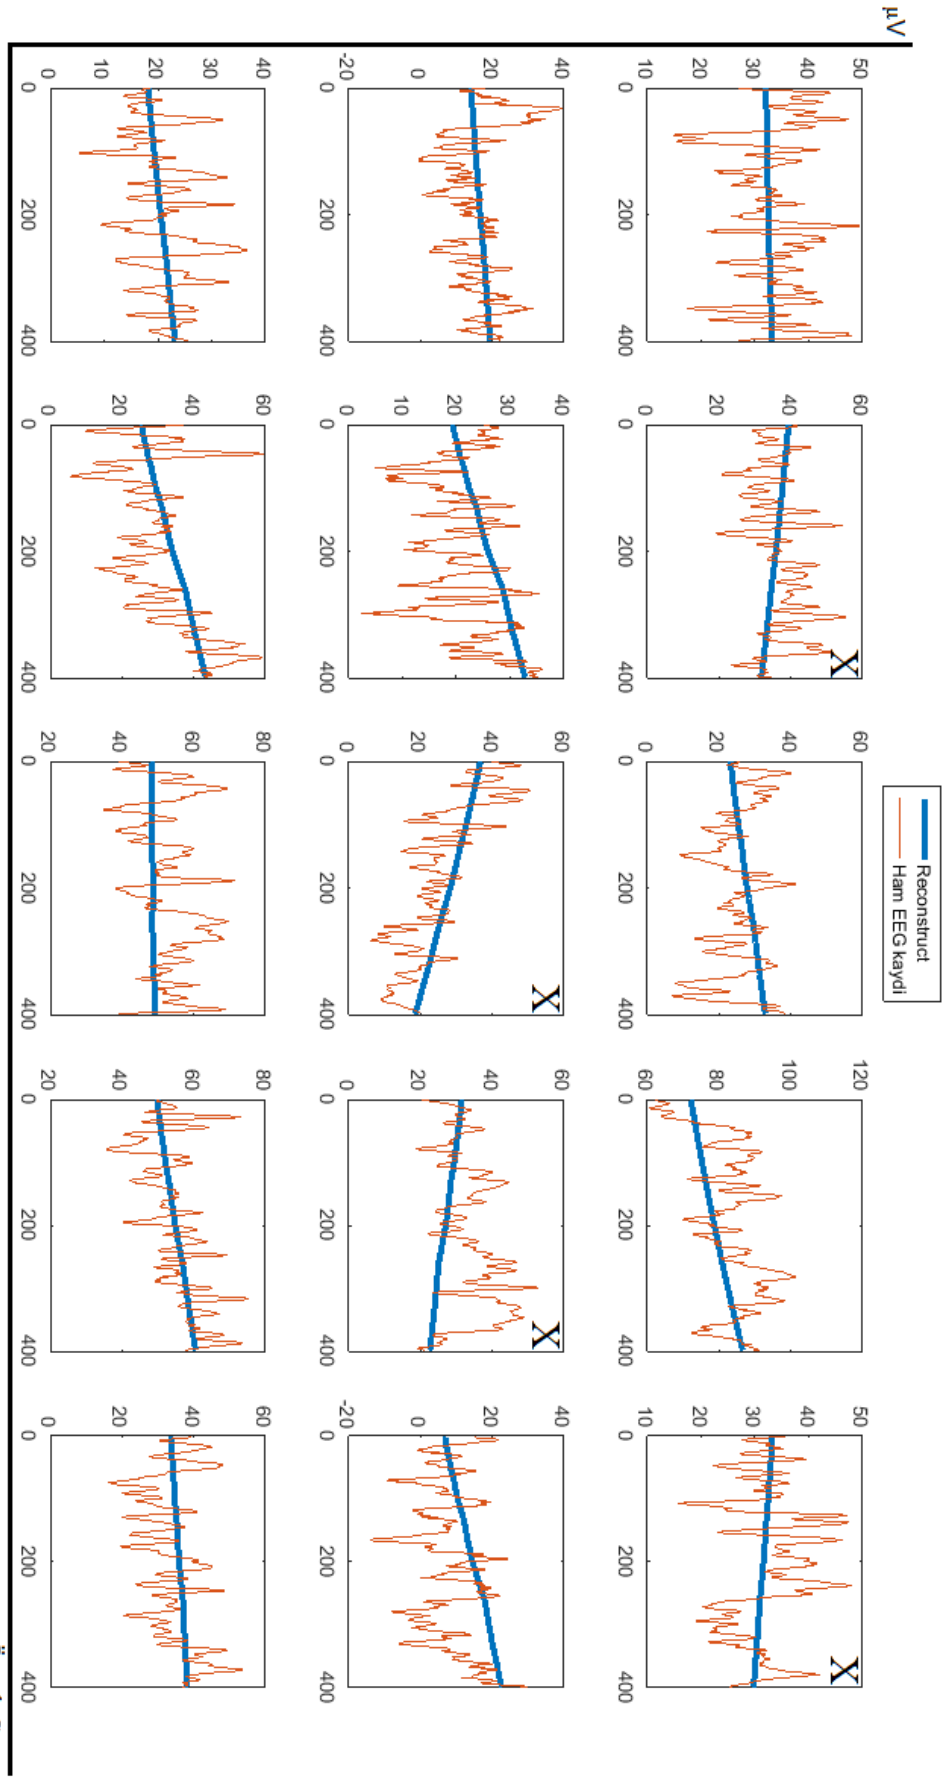

µV
Reconstruct
Ham EEG kaydı
Örnek Sayısı

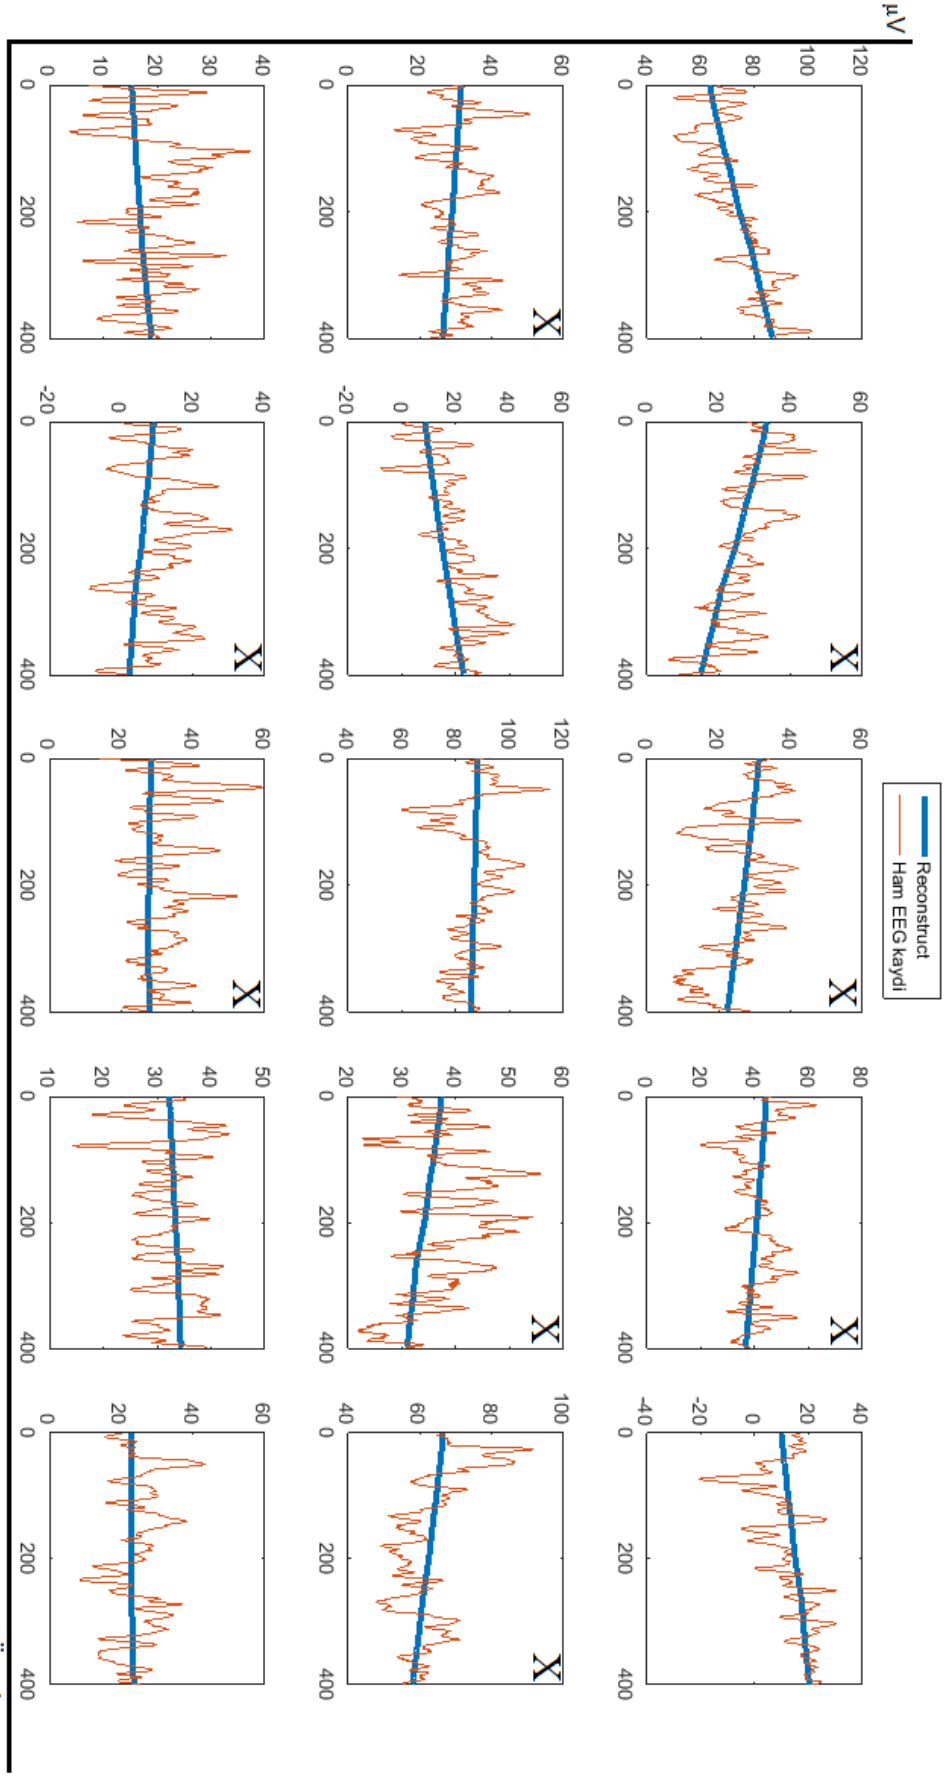

µV
Reconstruct
Ham EEG kaydı
Örnek Sayısı


µV
Reconstruct
Ham EEG kaydı
X
X
X
X
Örnek Sayısı


µV
Reconstruct
Ham EEG kaydi
X
Örnek Sayısı


µV
Reconstruct
Ham EEG kaydi
Örnek Sayısı


µV
Reconstruct
Ham EEG kaydı
X
Örnek Sayısı


µV
Reconstruct
Ham EEG kaydı
X
Örnek Sayısı

ÖZGEÇMİŞ



Adı Soyadı **:** Ömer EMHAN

Doğum Yeri **:** Diyarbakır

Doğum Tarihi **:** 20.10.1982

Medeni Hali **:** Evli

Yabancı Dil **:** İngilizce

Eğitim Durumu;

Lisans : İstanbul Üniversitesi Elektrik Elektronik Mühendisliği / İstanbul, 2005

Çalıştığı Kurum / Kurumlar ve Yıl:

2006-2007 : Ertunç Mühendislik

2007-2010 : Turkcell İletişim Hiz. A.Ş. Diyarbakır Bölge Teknik Operasyonlar Saha Operasyonları Birimi / Uzman Mühendis

2010-Halen : Dicle Üniversitesi Bilgi İşlem Daire Başkanlığı Ağ Hizmetleri Planlama ve Destek Birim Sorumlusu

T.C.
DİCLE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
YÜKSEK LİSANS TEZ ÇALIŞMASI İNTİHAL RAPORU FORMU

ÖĞRENCİ BİLGİLERİ	
ADI VE SOYADI	Ömer EMHAN
ÖĞRENCİ NO	18805025
EĞİTİM – ÖĞRETİM YILI	2016-2017
YARIYIL	☒ Güz ☐ Bahar
ANABİLİM DALI	Elektrik-Elektronik Mühendisliği
PROGRAM	Yüksek Lisans
TEZ KONUSU	Yukarı – Aşağı İmleç Hareketine İlişkin EEG Kayıtlarının Ayrık Dalgacık, k-NN Ve DVM İle Sınıflandırılması
İNTİHAL RAPORU BİLGİLERİ	
RAPOR TÜRÜ	Tez Savunma Sınavı Sonrası
SAYFA SAYISI	93
BENZERLİK ORANI	% 14
RAPORLAMA TARİHİ	12 / 04 / 2017

Yukarıda başlığı/konusu gösterilen tez çalışmamın kapak sayfası, giriş, ana bölümler, sonuç ve tartışma kısımlarından oluşan toplam ***93*** sayfalık kısmına ilişkin, 12/04/2017 tarihinde şahsım/tez danışmanım tarafından ***"Turnitin"*** adlı intihal tespit programından aşağıda belirtilen filtrelemeler uygulanarak alınmış olan intihal raporuna göre, tezimin benzerlik oranı ***% 14*** 'tür.
Uygulanan filtrelemeler:

☐ Kabul/Onay sayfaları hariç,
☐ Kaynakça hariç
☐ Alıntılar ~~hariç~~/dâhil
☐ Diğer

Dicle Üniversitesi Fen Bilimleri Enstitüsü Lisansüstü Programlarda Tez Çalışması İntihal Raporu Uygulama Esasları'nı inceledim ve bu Uygulama Esasları'nda belirtilen azami benzerlik oranlarına göre tez çalışmamın herhangi bir intihal içermediğini; aksinin tespit edilmesi durumunda doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi ve vermiş olduğum bilgilerin doğru olduğunu beyan ederim.

Gereğini saygılarımla arz ederim.

Ömer EMHAN

12 / 04 / 2017
Doç. Dr. Mehmet Siraç ÖZERDEM
Tez Danışmanı

12 / 04 / 2017
Prof. Dr. İbrahim KAYA
Anabilim Dalı Başkanı