

İSTANBUL TEKNİK ÜNİVERSİTESİ ★ FEN BİLİMLERİ ENSTİTÜSÜ

**TEK-SINIF DESTEK VEKTÖR MAKİNELERİ KULLANILARAK
EPİLEPTİK EEG İŞARETLERİNİN SINIFLANDIRILMASI**

**YÜKSEK LİSANS TEZİ
Ercan AVŞAR**

Anabilim Dalı : Elektronik ve Haberleşme Mühendisliği

Programı : Biyomedikal Mühendisliği

HAZİRAN 2009

İSTANBUL TEKNİK ÜNİVERSİTESİ ★ FEN BİLİMLERİ ENSTİTÜSÜ

**TEK-SINIF DESTEK VEKTÖR MAKİNELERİ KULLANILARAK
EPİLEPTİK EEG İŞARETLERİNİN SINIFLANDIRILMASI**

**YÜKSEK LİSANS TEZİ
Ercan AVŞAR
(504071403)**

**Tezin Enstitüye Verildiği Tarih : 04 Mayıs 2009
Tezin Savunulduğu Tarih : 02 Haziran 2009**

**Tez Danışmanı : Yrd. Doç. Dr. Mustafa E. KAMAŞAK (İTÜ)
Diğer Jüri Üyeleri : Prof. Dr. Bilge GÜNSEL (İTÜ)
Doç. Dr. Zehra ÇATALTEPE (İTÜ)**

HAZİRAN 2009

ÖNSÖZ

Türkçe olarak hazırlamış olduğum bu tez çalışmasının yazım aşamasında bazı terimlerin dilimizdeki karşılığını bulmakta zorluk çektiğim için ayrıca bir sözlük eklemeyi uygun gördüm. Bu sözlükteki kimi karşılıklar başkaları tarafından daha önceden kullanılmıştır kimileri ise tarafımdan ortaya atılmıştır.

Bu tez çalışması boyunca değerli yardımlarını esirgemeyen hocalarım Mustafa Kamaşak'a ve Zehra Çataltepe'ye teşekkür etmeyi bir borç bilirim.

Ayrıca yüksek lisans eğitimim boyunca bana maddi destek sağlamış olan TÜBİTAK'a teşekkür ederim.

Haziran 2009

Ercan Avşar
Elektrik – Elektronik Mühendisi

İÇİNDEKİLER

Sayfa

ÖNSÖZ	iii
İÇİNDEKİLER	v
KISALTMALAR	vii
ÇİZELGE LİSTESİ	ix
ŞEKİL LİSTESİ	xi
ÖZET	xiii
SUMMARY	xv
1. GİRİŞ	1
1.1 Epilepsi ve EEG	2
1.2 Literatür Özeti	5
2. DESTEK VEKTÖR MAKİNELERİ	9
2.1 Doğrusal Destek Vektör Makineleri	9
2.2 Doğrusal Olmayan Destek Vektör Makineleri	16
2.3 Tek – Sınıf Destek Vektör Makineleri	17
3. TEMEL BİLEŞENLER ANALİZİ	21
3.1 Ortalama	21
3.2 Standart Sapma	21
3.3 Kovaryans ve Kovaryans Matrisi	22
3.4 Özdeğer ve Özvektör	23
4. ÖZİNİTELİK SEÇİMİ	25
4.1 Asgari Gereksizlik – Azami İlişkiselik (mRMR) Öznelik Seçimi	25
5. ÇIKARILAN ÖZİNİTELİKLER	27
5.1 Spektral Entropi	27
5.2 Renyi Entropi	27
5.3 Varyans	28
5.4 Petrosian Fraktal Boyutu	28
5.5 Hjorth Parametreleri	29
5.6 Ortalama Eğri Uzunluğu	29
5.7 Ortalama Enerji	30
5.8 Ortalama Teager Enerjisi	30
5.9 Wigner-Ville Katsayıları	30
5.10 Dalgacık Katsayıları	30
6. VERİ KÜMESİ	35
7. DENEYLER	37
7.1 Öznelik Çıkarma	38
7.2 Temel Bileşenler Analizi	38
7.3 mRMR ile Öznelik Seçimi	39
7.4 Tek-Sınıf DVM	40
8. SONUÇLAR	41
9. YORUMLAR	43
KAYNAKLAR	45

EKLER..... 49

KISALTMALAR

ADD	: Ayrık Dalgacık Dönüşümü
AUC	: Eğri Altındaki Alan
BBT	: Bilgisayarlı Beyin Tomografisi
DVM	: Destek Vektör Makinesi
EEG	: Elektroansefalografi
GN	: Gerçek Negatif
GP	: Gerçek Pozitif
GPO	: Gerçek Pozitif Oranı
KKT	: Karush-Kuhn-Tucker
KZFD	: Kısa Zamanlı Fourier Dönüşümü
MRI	: Manyetik Rezonans İnceleme
mRMR	: Asgari Gereksizlik – Azami İlişkiselik
ROC	: Alıcı İşletim Karakteristiği
SDD	: Sürekli Dalgacık Dönüşümü
TBA	: Temel Bileşenler Analizi
VNS	: Vagus Sinir Uyarıcısı
YN	: Yanlış Negatif
YP	: Yanlış Pozitif
YPO	: Yanlış Pozitif Oranı

ÇİZELGE LİSTESİ

	<u>Sayfa</u>
Çizelge 7. 1 : Hata Matrisi.....	38
Çizelge 7. 2 : mRMR'a göre özniteliklerin sıralanışı.....	40
Çizelge 8. 1 : AUC Değerleri ($\nu=0.1$).....	41
Çizelge 8. 2 : AUC Değerleri ($\nu=0.5$).....	41

ŞEKİL LİSTESİ

Sayfa

Şekil 1. 1 : EEG kaydı için elektrot yerleşimi	3
Şekil 1. 2 : 10 saniyelik normal EEG işareti.....	4
Şekil 1. 3 : 10 saniyelik epileptik EEG işareti.....	4
Şekil 2. 1 : Doğrusal olarak ayrılabilen durum için hiperdüzlem.....	10
Şekil 2. 2 : Gevşek değişkenlerin gösterimi	13
Şekil 2. 3 : Taşıma fonksiyonunun temsili gösterimi.....	16
Şekil 5. 1 : 3. seviye ayrık dalgacık dönüşümü	33
Şekil 6. 1 : A, B, C, D, E kümelerinden alınmış 10'ar saniyelik örnekler	36
Şekil 7. 1 : A kümesi için eğitim ve test kümelerinin ayrılması.....	37
Şekil 7. 2 : A, B, C ve D kümesi için özdeğerler.....	39
Şekil A. 1 : Spektral entropinin tüm kümeler için ortalaması ve standart sapması ...	50
Şekil A. 2 : Renyi entropinin tüm kümeler için ortalaması ve standart sapması.....	50
Şekil A. 3 : Varyansın tüm kümeler için ortalaması ve standart sapması	51
Şekil A. 4 : Petrosian fraktal boyutunun tüm kümeler için ortalaması ve standart sapması	51
Şekil A. 5 : Hjorth hareketliliğinin tüm kümeler için ortalaması ve standart sapması	52
Şekil A. 6 : Hjorth karmaşıklığının tüm kümeler için ortalaması ve standart sapması	52
Şekil A. 7: Ortalama eğri uzunluğunun tüm kümeler için ortalaması ve standart sapması	53
Şekil A. 8 : Ortalama enerjinin tüm kümeler için ortalaması ve standart sapması....	53
Şekil A. 9 : Ortalama teager enerjisinin tüm kümeler için ortalaması ve standart sapması.....	54
Şekil A. 10 : Wigner Ville katsayıları-1'in tüm kümeler için ortalaması ve standart sapması	54
Şekil A. 11 : Wigner Ville katsayıları-2'nin tüm kümeler için ortalaması ve standart sapması	55
Şekil A. 12 : Wigner Ville katsayıları-3'ün tüm kümeler için ortalaması ve standart sapması.....	55
Şekil A. 13 : Wigner Ville katsayıları-4'ün tüm kümeler için ortalaması ve standart sapması	56
Şekil A. 14 : Dalgacık katsayıları-1'in tüm kümeler için ortalaması ve standart sapması.....	56
Şekil A. 15 : Dalgacık katsayıları-2'nin tüm kümeler için ortalaması ve standart sapması	57
Şekil A. 16 : Dalgacık katsayıları-3'ün tüm kümeler için ortalaması ve standart sapması	57
Şekil A. 17 : Dalgacık katsayıları-4'ün tüm kümeler için ortalaması ve standart sapması	58

Şekil A. 18 : Dalgacık katsayıları-5'in tüm kümeler için ortalaması ve standart sapması	58
Şekil A. 19 : Dalgacık katsayıları-6'nın tüm kümeler için ortalaması ve standart sapması	59
Şekil A. 20 : Dalgacık katsayıları-7'nin tüm kümeler için ortalaması ve standart sapması	59
Şekil A. 21 : Dalgacık katsayıları-8'in tüm kümeler için ortalaması ve standart sapması	60
Şekil A. 22 : Dalgacık katsayıları-9'un tüm kümeler için ortalaması ve standart sapması	60
Şekil A. 23 : Dalgacık katsayıları-10'un tüm kümeler için ortalaması ve standart sapması	61
Şekil A. 24 : Dalgacık katsayıları-11'in tüm kümeler için ortalaması ve standart sapması	61
Şekil A. 25 : Dalgacık katsayıları-12'nin tüm kümeler için ortalaması ve standart sapması	62
Şekil A. 26 : Dalgacık katsayıları-13'ün tüm kümeler için ortalaması ve standart sapması	62
Şekil A. 27 : Dalgacık katsayıları-14'ün tüm kümeler için ortalaması ve standart sapması	63
Şekil A. 28 : Dalgacık katsayıları-15'in tüm kümeler için ortalaması ve standart sapması	63
Şekil B. 1 : Tüm öznitelikler kullanılması durumunda elde edilen ROC eğrileri	64
Şekil B. 2 : TBA kullanılması durumunda elde edilen ROC eğrileri	64
Şekil B. 3 : 4 adet mRMR özniteliği kullanılması durumunda elde edilen ROC eğrileri	65
Şekil B. 4 : 6 adet mRMR özniteliği kullanılması durumunda elde edilen ROC eğrileri	65
Şekil B. 5 : 7 adet mRMR özniteliği kullanılması durumunda elde edilen ROC eğrileri	66
Şekil B. 6 : 15 adet mRMR özniteliği kullanılması durumunda elde edilen ROC eğrileri	66

TEK SINIF DESTEK VEKTÖR MAKİNELERİ KULLANILARAK EPİLEPTİK EEG İŞARETLERİNİN SINIFLANDIRILMASI

ÖZET

Dünya nüfusunun yaklaşık %1'inde görülebilen epilepsi hastalığı kişilerin günlük hayatlarının birçok evresini olumsuz olarak etkilemektedir. Bu yüzden epilepsinin tespiti büyük önem arz etmektedir. Epilepsi nöbetlerinin önüne geçilmesi amacıyla hastaya ilaç tedavisi uygulanabilmektedir. Bunun yanı sıra beynin sorunlu bölgesini elektriksel olarak uyararak yapılan çalışmalar da vardır.

Beynin elektriksel aktivitesi hakkında bilgi içeren bir kayıt olan EEG epilepsi nöbetinin tespiti için önemli bir araçtır çünkü epilepsi beyindeki anormal elektriksel aktivitelerden dolayı oluşan bir çeşit nörolojik rahatsızlıktır. Ayrıca epilepsi nöbetlerinin ne zaman başlayacağı daha önceden kestirilemediği için nöbet anında EEG kaydı almak da sıkıntılı bir işlem olabilir. Bu tez çalışmasında da EEG işaretleri epilepsi tespiti için kullanılmıştır.

Sınıflandırıcı olarak ise tek-sınıf destek vektör makineleri kullanılmıştır. Tek-sınıf destek vektör makinelerinin diğer sınıflandırıcılardan farkı, eğitim işlemi için sadece tek bir sınıf örneklerini kullanmasıdır. Dolayısı ile sınıflandırıcının eğitimi için sadece epilepsi nöbeti olmadığı anda alınmış EEG işaretleri kullanılmış, epilepsi nöbeti esnasında alınmış EEG işaretlerine ihtiyaç duyulmamıştır.

Bu amaçla daha önceden yapılmış olan çalışmalar incelenmiş ve epilepsi tespiti amacıyla kullanılmış olan 28 adet öznitelik çıkarılarak aynı anda kullanılmıştır. Bu özniteliklerden önemli olan boyutları elde edebilmek amacıyla temel bileşenler analizi yöntemi uygulanmıştır. Yine bu öznitelikler arasından, önemli olduğu mRMR yöntemiyle bulunan öznitelikler kullanılarak tek-sınıf DVM sınıflandırıcısı eğitilmiştir. Bu işlemler veri kümesine ayrı ayrı uygulanmış ve performans ölçütü olarak ROC eğrisi altında kalan alan, yani AUC değeri hesaplanmıştır.

Temel bileşenler analizi ile özuzaydaki enerjinin %95'i kapsanacak şekilde boyut azaltım işleminden sonra 28 boyutun 6 veya 7 boyutla da ifade edilebileceği görülmüştür. Ayrıca TBA sonrasında elde edilen sınıflandırıcının, tüm öznitelikler kullanılması durumuna göre performansı artırabildiği görülmüştür.

mRMR öznitelik seçimi ile bulunan en önemli ilk 4, 6, 7 ve 15 adet öznitelik kullanılarak farklı sınıflandırıcılar eğitilmiş ve test edilmiştir.

Sonuç olarak, bu üç durumdan (tüm öznitelikler, TBA, mRMR) mRMR öznitelik seçiminin uygun öznitelik sayısı ile tüm öznitelikler ve TBA'ya göre daha iyi sonuç verdiği görülmüştür.

EPILEPTIC EEG SIGNAL CLASSIFICATION USING ONE-CLASS SUPPORT VECTOR MACHINES

SUMMARY

Approximately 1% of world population have epilepsy which affects most parts of patients' daily lives in an unfavorable way. Therefore, detection of epilepsy is an important issue. There are efforts to control the seizures with medication. In addition, there are studies in which problematic part of the brain is electrically stimulated.

EEG, which contains information about electrical activity of the brain, is an important tool for detection of epileptic seizures because epilepsy is a kind of neurologic disorder which occurs due to abnormal electrical activities in brain. Furthermore, onset instance of epileptic seizures cannot be predicted so it may be an exhausting operation to make EEG recordings during seizures. In this thesis, EEG signals are used for epilepsy detection.

One-class support vector machines is used as classifier. Unlike other classifiers, one-class support vector machines require only one class of data for training. So only EEG recordings of non-epileptic epochs are required for training of the classifier, recordings of epileptic seizures are not needed.

For this purpose, after a literature review 28 features which were previously used for epilepsy detection are extracted and used at the same time. Principal component analysis method is applied to find out the important dimensions of these features. One-class SVM classifier is trained using important features whose importance is found by mRMR feature selection. These operations are applied separately and their effects on the classifier performance is observed by calculating AUC values as performance metric.

It is found out that 28 dimension can be expressed using only 6 or 7 dimensions after applying PCA to contain %95 of variance in eigenspace. Additionally, classifier trained by PCA features may be superior to training by all features.

mRMR is a feature selection algorithm which puts the features in order according to their importance. This importance is relevant to redundancy values which is a measure of representing target class labels and relevance values which is a measure of similarity between features. 4, 6, 7 and 15 most important features are used to train and test different classifiers.

As a result, among these three cases (all features, PCA, mRMR) mRMR feature selection is found to be superior to all features and PCA with proper number of features in terms of classification performance.

1. GİRİŞ

Epilepsi, aralıklı olarak tekrar eden kriz nöbetleriyle tanımlanan bir nörolojik rahatsızlıktır ve dünya nüfusunun yaklaşık %1'inde görülmektedir. Bu nöbetler her hastada farklı şekilde kendini gösterebilir çünkü epilepsinin çok farklı türleri vardır. Epilepsi nöbetinin tüm vücudun kasılması ve çarpınma şeklinde olabildiği gibi, sadece yüz, kol ya da bacakta kasılma, anlamsız konuşma ve davranışlar, titreme ve sabit bakma şeklinde de olabilir. (Gökçil). Epilepsinin tedavisi için farklı yöntemlerin bulunmasına karşın hastaların %25'inde bu nöbetler kontrol altına alınamamaktadır (Gardner et al., 2006).

Epilepsi hastaları sosyal yaşamlarında da birçok sorunla karşılaşabilmektedir. Örneğin çalışma durumunda, işverenlerin önyargı ve bilgisizliği yüzünden hastaya karşı olumsuz tavırları söz konusu olabilmektedir. Bununla birlikte okul hayatı ve uzun süreli yolculuklar da hasta için problem olabilmektedir.

Farklı ilaçlar kullanılarak epilepsi nöbetlerinin önüne geçilmeye çalışılmasının yanı sıra aynı amaçla beynin sorunlu bölgesini elektriksel olarak uyaran cihazlar da geliştirilmektedir (Örneğin; Vagus Nerve Stimulator, VNS). Bu tarzdaki çalışmaların etkili bir biçimde uygulanabilmesi için de epilepsi tespiti ve tahmini büyük önem arz etmektedir.

Bu çalışmada, probleme bir anomali tespiti olarak yaklaşan tek sınıf destek vektör makinelerinden (DVM) faydalanılmıştır. Ayrıca, epilepsi tespiti amacıyla daha önceden yapılmış olan çalışmalar incelenmiş ve EEG işaretlerini temsil etmek için çıkarılan özniteliklerin büyük bir kısmı kullanılmıştır. Bununla birlikte temel bileşenler analizi (TBA) ve öznitelik seçimi uygulanarak sistemin performansını iyileştirmek amaçlanmıştır. Maddeler halinde yazarsak, bu çalışmanın daha öncekilere göre katkıları şunlardır:

- Literatürde daha önceden kullanılmış olan 28 tane öznitelik çıkarılmış ve aynı anda kullanılmıştır.

- Bu özniteliklerden önemli olan boyutların elde edilmesi amacıyla TBA yöntemi uygulanmıştır.
- Yine bu öznitelikler arasından, sınıf bilgisini daha iyi temsil eden ve diğer özniteliklerle arasında daha az karşılıklı bilgiye sahip olan özniteliklerin seçimi için mRMR yöntemi uygulanmıştır.
- Daha önceki çalışmaların çoğunda sınıflandırıcı başarımına bakılarak karar verilmiştir. Bu çalışmada ise ROC eğrisinin altında kalan alan (AUC) hesaplanmıştır.
- Epilepsi tespiti için yapılmış olan birçok çalışmada kullanılan sınıflandırıcının eğitimi için hastanın epilepsi krizi geçirmediği anda alınmış EEG kaydının (normal EEG) yanı sıra kriz anında alınmış EEG kaydına (epileptik EEG) da ihtiyaç duyulmaktadır. Bugünün yöntemleriyle, krizin ne zaman başlayacağı daha önceden kestirilemediği için, epileptik EEG işareti edinebilmek amacıyla, hastayı uzun süreli EEG kaydına tabi tutmak gerekebilir. Bu da hem hasta için rahatsızlık verici bir durumdur, hem de kayıt süresinin uzaması ile yapılan işlemin maliyeti de artmaktadır. Bu çalışmada kullanılan tek-sınıf DVM'nin eğitimi için epileptik EEG verisine ihtiyaç duyulmamaktadır. Böylelikle, hasta için diğerlerinden daha pratik bir yaklaşım oluşturmaya ümit edilmektedir.


1.1 Epilepsi ve EEG

Beyindeki sinir hücreleri (aksonlar) arasındaki iletişim elektriksel uyarılarla sistematik bir şekilde sağlanır. Halk arasında sara hastalığı olarak bilinen epilepsi, beyinde kısa süreli anormal elektriksel aktivitelere bağlı olarak ortaya çıkan bir durumdur. Bu sistematığın aniden bozulmasıyla hasta epilepsi nöbeti geçirir. Epilepsi nöbetlerinin çok farklı tipleri vardır. Genel olarak iki ana başlık altında toplanabilir; genel nöbetler ve kısmi nöbetler. Genel nöbetlerde anormal elektriksel aktivite tüm beyine yayılırken, kısmi nöbetlerde beynin sadece bir kısmında olur.

Tüm epilepsi hastaları için belirli bir sebep bulunamamasına karşın genel olarak; doğumdan önceki veya doğum sırasındaki nedenler, menenjit, beyin enfeksiyonu, zehirlenmeler ve ciddi baş yaralanmaları epilepsiye sebep olabilir (Gökçil).

Epilepsi için tedavi olarak ilaç kullanımı ve cerrahi müdahalenin yanı sıra vagnus sinir uyarılması ve hastalar için hazırlanmış özel diyetlerin uygulanması gibi yöntemler mevcuttur.


Epilepsi teşhisi için farklı tetkikler yapılmaktadır. Bunlardan en önemlisi ise elektroansefalografidir (EEG). EEG beyindeki elektriksel aktiviteyi gösteren bir işarettir ve sıkça kullanılan bir yöntemdir. EEG, saçlı deriye elektrotların uygun bir şekilde yerleştirilmesiyle kaydedilir. Bu elektrot yerleşimi şekil 1.1'de gösterilmiştir. Bunun dışında hem daha az gürültülü işaret elde edebilmek hem de beynin belli bölgeleri hakkında bilgi edinebilmek amacıyla girişimsel olarak EEG kayıtları da alınmaktadır.




Şekil 1. 1 : EEG kaydı için elektrot yerleşimi (Gökçil, izin ile).

EEG işaretleri beynin kayıt anındaki durumu hakkında bilgi verdiği için nöbet dışındaki bir zamanda alınan EEG kaydında anormallik görünmeyebilir. Bunun için tekrarlayan ya da uzun süreli EEG çekimleri yapılabilir. Şekil 1.1 ve şekil 1.2'de 10'ar saniyelik normal ve epileptik EEG işaretleri görünmektedir.

EEG dışında, bilgisayarlı beyin tomografisi (BBT) ve manyetik rezonans incelemesi (MRI) de epilepsi teşhisinde kullanılabilir (Gökçil).



Şekil 1. 2 : 10 saniyelik normal EEG işareti



Şekil 1. 3 : 10 saniyelik epileptik EEG işareti

Bir EEG iřareti ierisinde, kiřinin ruhsal durumuna ve dūřınduklerine gre, farklı frekans bandına sahip beř ayrı dalga bulunabilir. EEG iřaretlerinin analizinde morfolojik zelliklerinin yanı sıra bu dalgalardan da faydalanılır. Bu dalgalar řu Őekilde sıralanabilir:

- **Delta Dalgaları (<4 Hz):** En dūřuk frekans bandını oluřturur ve derin uyku sırasında grlr.
- **Teta Dalgaları (4-8 Hz):** Uyanıklık ve uyku arasındaki durumu yansıtır. Dūřunceli ve hayal kurma durumunda da grlr.
- **Alfa Dalgaları (8-12 Hz):** Kiři uyanıkken grlr. Rahatlık ve sakinlik durumunu belirtir.
- **Beta Dalgaları (13-30 Hz):** Gzler aıkken, dūřunme, karar verme ve problem özme gibi durumlarda aktiftir.
- **Gama Dalgaları (>30 Hz):** Ařırı zihinsel aktiviteler esnasında grlr.

1.2 Literatr zeti

Schlkopf tarafından 1999’da ortaya atılmıř bir rnt tanıma yntemi olan tek sınıf DVM (Schlkopf et al., 1999), zellikle sıradıřı ve anormal durumların tespiti amacıyla kullanılmaktadır. Quang-Anh Tran tarafından ađ trafiđindeki anormallikleri tespit etmek iin kullanılmıřtır (Tran et al., 2004). Ayrıca biyoinformatik konusunda, DNA veya RNA’nın protein sentezini dzenleyen blgesi olan cis elemanlarının tanımlanması iin (Jiang et al., 2007) ve steganografik (Steganografi: Bir eřit kodlama ve veri gizleme yntemi) grntlerde gizlenmiř olan verinin bulunması iin kullanılmıřtır (Lyu et al., 2004). Bunlarla birlikte, dokman sınıflandırma amacıyla da tek sınıf DVM’nin diđer yntemlere gre daha iyi sonu verdiđi gsterilmiřtir (Manevitz et al., 2001).

Grldđ gibi ok farklı alanlarda aktif olarak kullanılan tek sınıf DVM yntemi epileptik EEG iřaretlerinin tespiti iin ilk kez Gardner tarafından kullanılmıř ve %97.1 duyarlılık oranı ve saat bařına 1.56 adet yanlış-pozitif sınıflandırma performansı vermiřtir (Gardner et al., 2006).

Epilepsi tespiti ve EEG işaretlerinin analizi ise daha eski zamanlara kadar gitmektedir. 1982 yılında Gotman J. tarafından yapılan çalışmada EEG işareti kendisini oluşturan temel dalgalara ayrıştırılmış ve bu dalgaların genlikleri ve ritmik karakteristikleri incelenmiştir (Gotman J., 1982). 1990 yılındaki çalışmasında ise bir saatlik EEG kaydında 1 adet yanlış-pozitif oranını yakalayabilmiştir (Gotman J., 1990). 1995 yılındaki bir başka çalışmada %100'lük bir başarımlık oranına karşılık, 5 saatte bir yanlış-pozitif oranı elde edilmiştir (Qu et al., 1995).

Bu önceki çalışmaların yanı sıra son senelerde farklı özelliklere sahip öznitelikler ve farklı sınıflandırıcılar kullanılarak epilepsi tespiti çalışmaları yapılmaktadır. İnan Güler ve Elif Derya Übeyli, uyarlamalı nöro-bulanık çıkarsama sistemi (adaptive neuro-fuzzy inference system, ANFIS) sınıflandırıcısını dalgacık katsayıları ile eğiterek %98.68'lik başarımlık oranı elde etmişlerdir (Güler İ. et al., 2005). V. Srinivasan et. al. zaman ve frekans bilgisini kullanarak çıkardıkları özniteliklerle eğittikleri yapay sinir ağı (YSA) sınıflandırıcısını kullanarak %97 başarımlık, %99.6 duyarlılık, %94.4 kesinlik değeri elde etmişlerdir (Srinivasan et al., 2005). Nihal Fatma et al. yinelenen sinir ağlarıyla birlikte Lyapunov üstellerini kullanarak %96.79 değerinde bir başarımlık elde etmişlerdir (Güler N.F. et al. 2005). N. Kannathal et al., farklı entropi değerlerini epilepsi tespiti için kullanarak %90'ın üzerinde sınıflandırma doğruluğuna ulaşmışlardır (Kannathal et al., 2005). Subaşı ise ayırık dalgacık dönüşümü (ADD) katsayılarını kullanarak eğitilen uzman ağların karışımı (Mixture of Experts, ME) modelinin standart yapay sinir ağlarından daha iyi sonuç verdiğini göstermiştir (Subaşı, 2007). İnan Güler et al., birleşik sinir ağları (combined neural network, CNN), uzman ağların karışımı (mixture of experts, ME) ve değiştirilmiş uzman ağların karışımı (modified mixture of experts, MME) sınıflandırıcılarını özvektör yöntemiyle çıkardıkları özniteliklerle eğiterek karşılaştırmışlardır. Sınıflandırma doğruluğu ve eğitim süreleri temel alınarak yapılan karşılaştırmada MME'nin daha iyi sonuç verdiğini göstermişlerdir (Güler İ et al., 2006). Vairavan Srinivasan, EEG işaretinin yaklaşık entropi değerini öznitelik olarak kullanmış ve yapay sinir ağları, Elman ağları ve olasılı sinir ağları üzerinde test etmiştir. Farklı sistem değişkenleri ile %99.35-%100 sınıflandırma doğruluğuna ulaşan Elman ağlarının diğerlerine göre daha başarılı sonuç verdiğini göstermiştir (Srinivasan et al., 2007).

Kemal Polat et al., epileptik EEG işaretlerinin tespiti amacıyla, seçim ağacı sınıflandırıcısını ve hızlı Fourier dönüşümünü kullandığı melez sistemle %98,72'lik bir sınıflandırma doğruluğuna ulaşılmıştır (Polat et al., 2007). Kemal Polat et al. bir başka çalışmasında ise sınıflandırıcı olarak yapay bağışıklık tanıma sistemi ,(artificial immune recognition system, AIRS) kullanmış ve temel bileşenler analizi ile de boyut azatım işlemi yapmışlardır. Sonuç olarak %100'lük başarımlar, duyarlılık ve kesinlik değeri elde etmişlerdir (Polat et al., 2008). Forrest Sheng Bao, güç spektrumu, fraktal boyut, Hjorth değişkenleri, ortalama ve standart sapma gibi özniteliklerle eğittikleri olası sinir ağları ile %99.5'lik başarımlarına ulaşmışlardır (Bao et al, 2008). Jinfeng Fan, destek vektör makinelerini genetik algoritmalarla birlikte kullanarak %95'lik sınıflandırma doğruluğu elde etmişlerdir (Jinfeng et al., 2006). A.T. Tzallas, bir zaman-frekans dönüşümü olan Wigner-Ville katsayılarını ve yapay sinir ağlarını kullanarak %97.72 ile %100 arasında değişen başarımlarına ulaşmışlardır (Tzallas et al., 2007).

2. DESTEK VEKTÖR MAKİNELERİ

2.1 Doğrusal Destek Vektör Makineleri

DVM (Vapnik, 1999) farklı iki sınıfı temsil eden örnekler arasındaki ayrımlık mesafesini ençoklayarak bir sınıflandırıcı eğitmeyi amaçlayan bir çeşit örüntü tanıma yöntemidir.

x_i eğitim kümesindeki örnekleri ve y_i de bu örneklerin sınıf etiketlerini göstermek üzere,


$$\begin{aligned} \{x_i, y_i\}, \quad i = 1, \dots, l \\ y_i \in \{-1, +1\} \end{aligned} \quad (2.1)$$

Pozitif (+1) etiketli örnekleri negatif (-1) etiketli örneklerden ayırabilen bir hiperdüzlemimiz olsun. Bu hiperdüzlemin tam üzerine düşen x örnekleri (2.2) denklemini sağlayacaklardır:

$$x \cdot w + b = 0 \quad (2.2)$$

Burada, w hiperdüzleme normal bir vektörü temsil eder. Ayrıca $|b|/\|w\|$ değeri de hiperdüzlemin merkez noktasına olan dik uzaklığıdır.

d_+ ve d_- hiperdüzleme en yakın olan pozitif ve negatif örneklerin hiperdüzleme olan uzaklığını göstermek üzere, $d_+ + d_-$ mesafesi ayrımlık olarak tanımlanır. İşte DVM bu ayrımlık değerini en yüksek yapacak şekilde bir hiperdüzlem bulmayı amaçlar.



Şekil 2.1 : Doğrusal olarak ayrılabilen durum için hiperdüzlem

Tüm eğitim örneklerinin (2.3) ve (2.4)'teki koşulları sağladığını düşünelim.

$$x_i \cdot w + b \geq +1, \quad y_i = +1 \quad (2.3)$$

$$x_i \cdot w + b \leq -1, \quad y_i = -1 \quad (2.4)$$

Bu iki eşitsizliği tek bir eşitsizlik olarak (2.5)'teki gibi yazabiliriz.

$$y_i (x_i \cdot w + b) \geq 1 \quad \forall i \quad (2.5)$$

Şimdi (2.3) ve (2.4)'teki eşitlik durumlarını göz önüne alalım. $x_i \cdot w + b = +1$ olması durumunda, x noktaları H_1 hiperdüzlemi üzerindedir ve H_1 'in merkez noktasına olan uzaklığı $|1 - b| / \|w\|$ 'dur. $x_i \cdot w + b = -1$ olması durumunda ise, x noktaları H_2 hiperdüzlemi üzerindedir ve H_2 'nin merkez noktasına olan uzaklığı $|-1 - b| / \|w\|$ 'dur. Buradan ayrımlık değeri $2 / \|w\|$ olarak bulunur. Bu ifadede $\|w\|$ paydada bulunduğundan, esas amacımız olan ayrımlık değerini en yüksek yapmak için de, (2.5)'teki kısıtlamalar göz önünde tutularak, (2.6) ifadesini enazlamamız gerekir:

$$\frac{1}{2}\|w\|^2 \quad (2.6)$$

Burada, ifadenin başında bulunan $\frac{1}{2}$ değeri, ileriki işlemlerde matematiksel kolaylık sağlaması amacıyla eklenmiştir. Bir karesel fonksiyonu bazı doğrusal eşitsizlik kısıtlamalarına (2.5) göre enazlamaya çalıştığımız (2.6) ifadesi karesel programlama problemine bir örnektir.

Bu problemi çözebilmek için, (2.5)'teki her bir kısıtlama için bir adet Lagrange çarpanı tanımlarız.

$$\alpha_i \geq 0, \quad i = 1, \dots, l \quad (2.7)$$

w ve b 'ye göre enazlayıp, α 'ya göre ençokladığımızdan, Lagrange fonksiyonu (2.8)'de gösterilen şekilde olacaktır.

$$L(w, b, \alpha) = \frac{1}{2}\|w\|^2 - \sum_{i=1}^l \alpha_i y_i (x_i \cdot w + b) + \sum_{i=1}^l \alpha_i \quad (2.8)$$

$L(w, b, \alpha)$ 'nın w ve b 'ye göre ayrı ayrı türevini alıp sifıra eşitleyerek (2.9) ve (2.10)'daki iki durumu elde ederiz.

$$w = \sum_i \alpha_i y_i x_i \quad (2.9)$$

$$0 = \sum_i \alpha_i y_i \quad (2.10)$$

Bu iki eşitliği (2.8)'de yerine koyarak Lagrange fonksiyonunu yeniden yazarsak, ikili gösterim şeklindeki (2.11) fonksiyonunu ençoklamamız gerekir:

$$L(\alpha) = \sum_i \alpha_i - \frac{1}{2} \sum_{i,j} \alpha_i \alpha_j y_i y_j x_i \cdot x_j \quad (2.11)$$

(2.11) için göz önünde tutulması gereken kısıtlamalar ise, (2.7) ve (2.10)'dur.

Eğitilmiş olan sınıflandırıcıyı kullanarak yeni örnekleri sınıflandırabilmek için, bu örneklerin hiperdüzlemin hangi tarafına düştüğüne bakılır. Bunu yapmak için de örnek, hiperdüzlem fonksiyonuna sokulur ve çıkışın işaretine bakılır.

$$\text{sgn}(x.w+b) \quad (2.12)$$

veya Lagrange çarpanları kullanılarak,

$$\text{sgn}\left(\sum_{i=1}^l \alpha_i y_i x_i .x + b\right) \quad (2.13)$$

Kısıtlanmış optimizasyon problemleri için Karush-Kuhn-Tucker (KKT) şartları sağlanmaktadır. Bizim problemimiz için bu şartlar:

$$\alpha_i \geq 0 \quad (2.14)$$

$$y_i (x_i .w + b) - 1 \geq 0 \quad (2.15)$$

$$\alpha_i (y_i (x_i .w + b) - 1) = 0 \quad (2.16)$$

Görüldüğü gibi her örnek için ya $\alpha_i = 0$, ya da $y_i (x_i .w + b) = 1$ 'dir. $\alpha_i = 0$ olan her örnek (2.13) denklemindeki toplama katkı sağlamayacaktır. Yani yeni örneklerin sınıf etiketlerinin kestiriminde hiç bir önemi olmayacaktır. Bunlar dışında kalan örnekler destek vektörleri olarak adlandırılır ve $y_i (x_i .w + b) = 1$ durumunu sağlamaktadır.

Verilerin doğrusal olarak ayıramadığı durumlarda, sınıfların doğrusal olmayan sınıflandırıcılar vasıtasıyla ayrılması gerektiği düşünülebilir. Fakat bu durumda da sınıflandırıcı kötü bir genelleme yetisine sahip olacaktır. Bu yüzden önceki bölümde anlattığımız DVM'yi bir miktar hataya izin verebilecek şekilde yeniden tasarlayacağız. Bunu yaparken de ilk adım olarak, (2.3) ve (2.4)'teki kısıtlamaları gevşeterek yeniden yazalım:

$$x_i .w + b \geq +1 - \xi_i, \quad y_i = +1 \quad (2.17)$$

$$x_i .w + b \leq -1 + \xi_i, \quad y_i = -1 \quad (2.18)$$

$$\xi_i \geq 0, \quad \forall i \quad (2.19)$$


Buradaki ξ ler hata terimleri olarak eklenmiştir ve gevşek değişkenler olarak adlandırılır. Bu değişkenler, örneğin uzaydaki farklı bölgelerine göre şöyle değer alacak şekilde tanımlanmıştır:

- $\xi_i = 0$, örnek ayırım sınırının üzerinde veya doğru tarafında ise.
- $\xi_i = |y_i - (x_i \cdot w + b)|$, diğer durumlar için.

Yani, eğer örnek noktası karar sınırının üzerinde ise $x_i \cdot w + b = 0$ olacak ve $\xi_i = 1$ olacaktır. Dolayısıyla $\xi_i > 1$ olan örnekler için hatalı sınıflama söz konusu olacaktır.

(1.5)'i gevşek değişkenler kullanarak (2.20)'deki şekilde yeniden yazmamız mümkündür:

$$y_i(x_i \cdot w + b) \geq 1 - \xi_i \quad \forall i \quad (2.20)$$



Şekil 2. 2 : Gevşek değişkenlerin gösterimi

Bu durumda amacımız, bir miktar örneğin hatalı sınıflandırılmasına izin vererek ayrımlığı ençoklamaktır. Dolayısıyla (2.21) ifadesini enazlamamız gerekir.

$$C \sum_{i=1}^l \xi_i + \frac{1}{2} \|w\|^2 \quad (2.21)$$

Buradaki C değişkeni hatalı sınıflandırılan örnekler için bir ceza değeri olarak düşünülebilir ($C > 0$). Hatalı sınıflandırılan her bir örnek için $\xi_i > 1$ olacağına göre, $\sum_i \xi_i$ değeri hatalı sınıflandırılmış örnek sayısı için üst sınırdır. Dolayısıyla C değişkeni sınıflandırma hatası ile model karmaşıklığı arasındaki çelişkiyi düzenleyici bir görev yapar. C değerinin yüksek seçilmesi durumunda daha fazla örnek yanlış sınıflandırılabilir ve sınıflandırıcının karmaşıklığı düşecektir. C değerinin düşük seçilmesi durumunda ise daha az örnek yanlış sınıflandırılabilir ve sınıflandırıcının karmaşıklığı artacaktır.

(2.21) için Lagrange çarpanlarını tanımlarsak,

$$\alpha_i \geq 0, \quad i = 1, \dots, l \quad (2.22)$$

$$\mu_i \geq 0, \quad i = 1, \dots, l \quad (2.23)$$

w ve b 'ye göre enazlayıp, α ve μ 'ye göre en çokladığımızdan Lagrange fonksiyonu (2.24)'deki şekilde olacaktır.

$$L(w, b, \xi, \alpha, \mu) = \frac{1}{2} \|w\|^2 + C \sum_i \xi_i - \sum_i \alpha_i \{y_i(x_i \cdot w + b) - 1 + \xi_i\} - \sum_i \mu_i \xi_i \quad (2.24)$$

(2.24) için KKT şartları şöyledir:

$$\alpha_i \geq 0 \quad (2.25)$$

$$y_i(x_i \cdot w + b) - 1 + \xi_i \geq 0 \quad (2.26)$$

$$\alpha_i \{y_i(x_i \cdot w + b) - 1 + \xi_i\} = 0 \quad (2.27)$$

$$\mu_i \geq 0 \quad (2.28)$$

$$\xi_i \geq 0 \quad (2.29)$$

$$\mu_i \xi_i = 0 \quad (2.30)$$

(2.24) fonksiyonunun w , b ve ξ_i 'ye göre ayrı ayrı kısmi türevlerini alıp sifira eşitlediğimizde (2.31), (2.32) ve (2.33) ifadelerini buluruz.

$$w = \sum_{i=1}^l \alpha_i y_i x_i \quad (2.31)$$

$$\sum_{i=1}^l \alpha_i y_i = 0 \quad (2.32)$$

$$\alpha_i = C - \mu_i \quad (2.33)$$

Bu sonuçları kullanarak Lagrange fonksiyonunu (2.34)'teki gibi ikili şekilde yazabiliriz.

$$L(\alpha) = \sum_i \alpha_i - \frac{1}{2} \sum_{i,j} \alpha_i \alpha_j y_i y_j x_i \cdot x_j \quad (2.34)$$

Aslında (2.34) fonksiyonu doğrusal olarak ayrılabilen durumdaki (2.11) fonksiyonu ile aynıdır. Sadece kısıtlamaları farklıdır:

$$0 \leq \alpha_i \leq C \quad (2.35)$$

$$\sum_i \alpha_i y_i = 0 \quad (2.36)$$

(2.28) ve (2.33)'ü aynı anda değerlendirdiğimiz zaman (2.35)'in de doğru olduğu açıkça görülmektedir.

Yeni örnekleri sınıflandırabilmek için yine (2.13) kullanılır. Sonuç olarak, $\alpha_i = 0$ olan örnekler (2.13)'teki toplama herhangi bir katkı sağlamadıklarından, yeni örneklerin sınıflandırılmasında etkisizdirler. Bunların dışında kalan ($\alpha_i > 0$) örnekler de destek vektörleri olarak adlandırılır ve (2.37)'yi sağlarlar.

$$y_i (x_i \cdot w + b) = 1 - \xi_i \quad (2.37)$$

Eğer $\alpha_i < C$ ise (2.33)'ten $\mu_i > 0$ olduğu görülür. Buradan da (2.30) kullanılarak $\xi_i = 0$ olduğu bulunur. Yani en başta söylediğimiz gibi bu noktalar ayırım sınırı üzerinde yer almaktadır.


2.2 Doğrusal Olmayan Destek Vektör Makineleri

Yukarıda anlatılanların doğrusal sınıflandırıcılar kullanılarak uygulanamaması durumunda, başka bir deyişle, karar fonksiyonunun elimizdeki verinin bir doğrusal fonksiyonu olmaması durumunda, (Aizerman et al., 1964) tarafından öne sürülen yöntemin kullanılabileceğini (Boser et al., 1992) göstermiştir (Borges, 1998).

Bunun için elimizdeki veri önce daha yüksek boyutlu bir uzaya taşınır:

$$\Phi: R^d \rightarrow H \quad (2.38)$$

Burada, Φ taşıma fonksiyonu olarak adlandırılır. R^d uzayında doğrusal olarak ayrılamayan örneklerin H uzayında doğrusal olarak ayrılabilmesi beklenmektedir.



Şekil 2.3 : Taşıma fonksiyonunun temsili gösterimi

Şimdi, (2.11), (2.13) ve (2.34)'e baktığımızda $x_i \cdot x_j$ tarzında nokta çarpımlarına (içsel çarpım) rastlamaktayız. Bu nokta çarpımları H uzayında $\Phi(x_i) \cdot \Phi(x_j)$ şeklinde tanımlanacaklardır.

Eğer ki $K(x_i, x_j) = \Phi(x_i) \cdot \Phi(x_j)$ şeklinde bir fonksiyon tanımlayabilirsek, tüm bu hesaplamaları nokta çarpımları kullanmadan daha kolay ve hızlı yapmak mümkün

olacaktır. Burada K , çekirdek fonksiyonu olarak adlandırılır. Çekirdek fonksiyonlara birkaç örnek verebiliriz:

- Doğrusal: $K(x_i, x_j) = x_i^T x_j$
- Polinom: $K(x_i, x_j) = (x_i^T x_j + 1)^p$
- Gaussian: $K(x_i, x_j) = \exp\left(-\frac{\|x_i - x_j\|^2}{2\sigma^2}\right)$
- Sigmoid: $K(x_i, x_j) = \tanh(\kappa x_i^T x_j - \delta)$

Dikkat edilirse, çekirdek fonksiyonu kullanıldığında, $\Phi(\cdot)$ fonksiyonunu hiç hesaplamaya gerek kalmadan örnekler daha yüksek boyutlu H uzayına taşınabilmektedir.

Çekirdek fonksiyonun bu özelliğini kullanarak (1.34) ve (1.13)'ü H uzayında (2.39) ve (2.40)'taki gibi ifade edebiliriz.

$$L(\alpha) = \sum_i \alpha_i - \frac{1}{2} \sum_{i,j} \alpha_i \alpha_j y_i y_j \Phi(x_i) \cdot \Phi(x_j) = \sum_i \alpha_i - \frac{1}{2} \sum_{i,j} \alpha_i \alpha_j y_i y_j K(x_i, x_j) \quad (2.39)$$

$$\text{sgn}\left(\sum_{i=1}^l \alpha_i y_i \Phi(x_i) \cdot \Phi(x) + b\right) = \text{sgn}\left(\sum_{i=1}^l \alpha_i y_i K(x_i, x) + b\right) \quad (2.40)$$

2.3 Tek – Sınıf Destek Vektör Makineleri

Tek sınıf DVM (schölkopf et al., 1999) tarafından yukarıda anlatılan DVM algoritmasının bir uzantısı olarak ortaya atılmıştır. Tek sınıf DVM'de genel olarak, giriş uzayındaki örneklerin büyük bir kısmını içeren dar bir alanda +1 değerini, geri kalan örnekler için de -1 değerini alacak bir ikili fonksiyon bulmak amaçlanmaktadır. Bunu yaparken de veriler bir çekirdek fonksiyonu kullanılarak daha yüksek boyutlu öznitelik uzayına taşınır. Burada da verileri merkez noktasından en büyük ayrımlık değeri ile ayırabilecek bir hiperdüzlem bulunur. Yeni örnekler test edilirken de bu örneklerin hiperdüzlemin hangi tarafına düştüğüne bakılır.

Tek sınıf DVM ifadesi (2.41)'de gösterilmiştir.

$$\min \left\{ \frac{1}{2} \|w\|^2 + \frac{1}{\nu l} \sum_i \xi_i - \rho \right\} \quad (2.41)$$

(2.42) ise (2.41)'e kısıtlama olarak verilmiştir.

$$(w \cdot \Phi(x_i)) \geq \rho - \xi_i, \quad \xi_i \geq 0 \quad (2.42)$$

Bu problem için karar fonksiyonu ise (2.43)'te gösterilmiştir.

$$\text{sgn}((w \cdot \Phi(x)) - \rho) \quad (2.43)$$

Buradaki dikkat çekici nokta, sınıflandırıcının eğitimi esnasında hiçbir sınıf bilgisi kullanılmamasıdır ((2.41) ve (2.42)'de sınıf bilgisini içeren değişken yoktur.). Bu yüzden tek sınıf DVM gözetimsiz öğrenmeye bir örnektir. Eğitim kümesindeki birçok örnek için (2.43)'ün sonucu pozitif olacaktır. Aynı zamanda, $\|w\|$ küçük bir değer alıyor olacaktır. Daha az öğrenin pozitif olması ile de $\|w\|$ değeri artacaktır. Bu çelişkili durum $\nu \in [0,1]$ tarafından kontrol edilir. ν , yanlış sınıflandırılan örneklerin izin verilen oranı olarak tanımlanabilir.

(2.41)'deki problemin çözümü için daha önce yaptığımız gibi Lagrange çarpanları tanımlayacağız. $\alpha_i, \mu_i \geq 0$ Lagrange çarpanları olmak üzere (2.41)'i Lagrange fonksiyonu olarak yeniden yazabiliriz:

$$L(w, \xi, \rho, \alpha, \mu) = \frac{1}{2} \|w\|^2 + \frac{1}{\nu l} \sum_i \xi_i - \rho - \sum_i \alpha_i ((w \cdot \Phi(x_i)) - \rho + \xi_i) - \sum_i \mu_i \xi_i \quad (2.44)$$

(2.44)'ün w, ξ ve ρ 'ya göre ayrı ayrı türevini alıp sıfıra eşitlediğimiz zaman ise,

$$w = \sum_i \alpha_i \Phi(x_i) \quad (2.45)$$

$$\alpha_i = \frac{1}{\nu l} - \mu_i \leq \frac{1}{\nu l}, \quad \sum_i \alpha_i = 1 \quad (2.46)$$

ifadelerini elde ederiz. (2.45) ve (2.46)'yı (2.44)'te yerlerine yazarsak, problemimiz (2.47)'de gösterilen duruma gelecektir.

$$\min \left\{ \frac{1}{2} \sum_{ij} \alpha_i \alpha_j K(x_i, x_j) \right\} \quad (2.47)$$

Bu durumda kısıtlamalarımız ise (2.48)'deki gibi olacaktır.

$$0 \leq \alpha_i \leq \frac{1}{\nu l}, \quad \sum_i \alpha_i = 1 \quad (2.48)$$

Bununla birlikte (1.43)'teki karar fonksiyonu da (2.49)'daki gibi olacaktır.

$$f(x) = \text{sgn} \left(\sum_i \alpha_i K(x_i, x) - \rho \right) \quad (2.49)$$

Dikkat edilirse, daha önceden gösterdiğimiz gibi, $\alpha_i > 0$ değerlerine sahip örnekler destek vektörleri olacaktır.

3. TEMEL BİLEŞENLER ANALİZİ

İlk olarak (Hotelling, 1933) tarafından ortaya atılmış olan temel bileşenler analizinin (TBA) esas amacı yüksek boyutlu bir veri setini daha az sayıda boyutla ifade edebilmektir. TBA değişkenler arasındaki bağımlılığı yok etmeye çalışarak veri setinin boyutunu azaltır. Bu boyut azaltım işlemi sonunda bilgi kaybı elbette ki olacaktır fakat bu kayıp, boyut azaltım işleminin getirilerine göre önemsizlenecek miktarda olabilir. TBA, boyut azaltmanın dışında, yüz tanıma, veri sıkıştırma gibi amaçlarla da sıkça kullanılmaktadır.

TBA'nın bir veri setine nasıl uygulandığını anlatmadan önce bir takım tanımlar ve açıklamalar yapmak faydalı olacaktır.

3.1 Ortalama

X , N adet örnekten oluşan bir öznitelik vektörü ise,

$$X = x_1, x_2, \dots, x_N \quad (3.1)$$

Bu örneklerin ortalaması (3.2) kullanılarak bulunur.

$$\mu_x = \frac{1}{N} \sum_{n=1}^N x_n \quad (3.2)$$

Ortalama değeri ayrıca X 'in beklenen değeri olarak ifade edilir ve (3.3)'teki şekilde gösterilir.

$$\mu_x = E\{X\} \quad (3.3)$$

3.2 Standart Sapma

Standart sapma, vektörü oluşturan örneklerin dağılımının ölçüsü olarak tanımlanır. σ sembolü ile gösterilir ve (3.4) ile hesaplanır.

$$\sigma = \sqrt{\frac{1}{N} \sum_{n=1}^N (x_n - \mu_x)^2} \quad (3.4)$$

Beklenen değer kullanılarak da (3.5)'teki gibi ifade edilebilir.

$$\sigma = \sqrt{E\{(X - \mu_x)^2\}} \quad (3.5)$$

Standart sapma, örneklerin ortalamaya göre nasıl bir dağılım gösterdiğini anlatır. Ayrıca, standart sapmanın karesi varyans olarak adlandırılır ve σ^2 ile gösterilir.

3.3 Kovaryans ve Kovaryans Matrisi

Kovaryans iki değişkenin birlikte ne kadar değişim gösterdiğinin bir ölçütü olarak tanımlanabilir.

Y, başka bir öznitelik vektörü olmak üzere,

$$Y = y_1, y_2, \dots, y_N \quad (3.6)$$

X ve Y vektörleri arasındaki kovaryans değeri (3.7) ile hesaplanır.

$$\text{cov}(X, Y) = \frac{1}{N} \sum_{n=1}^N (x_n - \mu_x)(y_n - \mu_y) \quad (3.7)$$

Beklenen değer kullanarak da (3.8)'deki gibi ifade edilebilir:

$$\text{cov}(X, Y) = E\{(X - \mu_x)(Y - \mu_y)\} \quad (3.8)$$

Kovaryans her zaman iki boyutta hesaplanır. Bir vektörün kendisiyle olan kovaryansı ise vektörün varyansına eşit olacaktır. Kovaryansın pozitif olması iki değişkenin birlikte arttığı, negatif olması ise birinin artarken diğerinin azaldığı anlamına gelir.

TBA daha yüksek boyutlu veri kümeleri üzerinde uygulanır. Dolayısı ile her iki boyut arasında hesaplanan kovaryans değerleri kovaryans matrisinde tutulur.

$$\Sigma = \begin{bmatrix} \text{cov}(X, X) & \text{cov}(X, Y) & \text{cov}(X, Z) \\ \text{cov}(Y, X) & \text{cov}(Y, Y) & \text{cov}(Y, Z) \\ \text{cov}(Z, X) & \text{cov}(Z, Y) & \text{cov}(Z, Z) \end{bmatrix} \quad (3.9)$$

Kovaryans matrisi her zaman simetrik bir kare matristir ($\text{cov}(X, Y) = \text{cov}(Y, X)$) ve köşegen değerleri her bir vektörün varyansına eşittir.

3.4 Özdeğer ve Özvektör

Bir A matrisi için, x bir vektör ($x \neq 0$) ve λ skaler bir büyüklük olacak şekilde (3.10) eşitliği sağlanabiliyorsa, x, A matrisinin özvektörü, λ ise bu özvektöre karşılık gelen özdeğer olarak adlandırılır.

$$Ax = \lambda x \quad (3.10)$$

Bir matris için bulunan özvektörlerin hepsi birbirine diktir. TBA da bu diklik özelliğini kullanarak veriyi özvektörlerle ifade edilen özuzaya taşır.

Burada, veri kümesinin boyutu kadar özdeğer ve özvektör bulunacaktır. Özdeğerlerin büyüklüğü karşı düştüğü özvektörün önemi olarak düşünülebilir. Yani düşük özdeğerli özvektörler daha az öneme sahipken yüksek özdeğerli özvektörler daha fazla öneme sahiptir. Dolayısı ile düşük özdeğerli özvektörleri kullanmadan daha az boyutlu bir izdüşüm matrisi oluşturulabilir. İzdüşüm matrisinin boyut sayısı ise özdeğerlerin özuzayda kapladığı enerji oranıyla belirlenir. Bu enerji oranı (3.11)'de gösterilen şekilde hesaplanır.

$$\frac{\lambda_1 + \lambda_2 + \dots + \lambda_d}{\lambda_1 + \lambda_2 + \dots + \lambda_d + \dots + \lambda_n} \quad (3.11)$$

Burada, $d < n$ olmak üzere, d izdüşüm matrisinin boyut sayısını, n ise veri kümesinin boyut sayısını ifade etmektedir. Ayrıca özdeğerlerin büyükten küçüğe doğru sıralanmış olduğu düşünülmelidir. Yani λ_1 en büyük özdeğeri gösterirken, λ_n ise en küçük özdeğeri göstermektedir.

Temel bileşenler analizine başlamadan önce elimizdeki öznitelik vektörlerinin hepsinin aynı birimde olduklarından emin olmamız gereklidir. Bununla birlikte öznitelik vektörlerinin varyansları arasında çok fazla fark varsa vektörler ölçeklendikten sonra TBA işlemine sokulmalıdır. Aksi takdirde kovaryans matrisinin özdeğerlerinin biri veya birkaçı diğer özdeğerleri bastırarak kadar büyük çıkacaktır.

Temel bileşenler analizi algoritmasını adım adım şu şekilde yazabiliriz:

1. Eğitim kümesi özniteliklerinin ortalaması eğitim ve test kümesi özniteliklerinden çıkarılır. Böylelikle eğitim kümesindeki her öznitelik için ortalama sıfır olur.
2. Birinci adım sonucunda elde edilen eğitim kümesinin kovaryans matrisi hesaplanır.
3. Kovaryans matrisinin özvektörleri ve bunlara karşılık gelen özdeğerleri bulunur.
4. Seçilen enerji eşik değerini içerecek en büyük özdeğerlere denk gelen özvektörler alınarak izdüşüm matrisi oluşturulur.
5. Birinci adım sonucunda elde edilen eğitim ve test kümelerini ifade eden matrisler, dördüncü adımda elde edilen izdüşüm matrisiyle çarpılarak boyut düşürülür.

4. ÖZİNİTELİK SEÇİMİ

Örüntü tanıma uygulamalarında, kullanılacak olan örüntü tanıma yöntemine girdi olarak genellikle veri setinden çıkarılmış olan öznitelikler kullanılır. Bazı uygulamalarda öznitelik sayısı birkaç tane ile sınırlı kalırken, bazılarında da çok fazla miktarda olabilir. Her nesne için çıkarılan öznitelikler bir öznitelik matrisinde saklanır. Dolayısı ile hem nesne sayısı hem de öznitelik sayısı matrisin boyutunu yani işlem süresini etkileyecektir. Bununla birlikte, etkili bir sınıflandırıcının eğitilebilmesi için, kullanılan nesne sayısı öznitelik sayısının en az 10 katı olmalıdır.

Çıkarılmış olan özniteliklerin nesnelere karşılık gelen sınıfları ne kadar iyi temsil ettiği önemlidir. Sınıflar arasında daha iyi ayırım yapabilen öznitelikler, yüksek seviyeli öznitelikler olarak adlandırılır ve sınıflandırıcının performansı açısından daha önemlidir. Tüm öznitelikleri kullanmak yerine sadece bazı yüksek seviyeli özniteliklerin kullanılması performansta çok büyük farklılıklara neden olmayacakken, yapılan işlem sayısını azaltacaktır. Bununla birlikte, öznitelik sayısını azaltmak performansı arttırabilir çünkü gürültülü öznitelikler bu sayede süzölmüş olur. Ayrıca nesne sayısının öznitelik miktarına göre düşük olduğu durumlarda da öznitelik seçimi yaparak daha güçlü bir sınıflandırıcı eğitilebilir.

4.1 Asgari Gereksizlik – Azami İlişkisellik (mRMR) Öznitelik Seçimi

mRMR öznitelik seçim yöntemi Hanchuan Peng tarafından geliştirilmiştir (Peng et al., 2005). Bu yöntemde özniteliklerin hedef sınıfı temsil edebilme miktarını gösteren ilişkisellik değeri azami seviyede tutulmaya çalışılırken özniteliklerin birbirleri arasındaki bağımlılık miktarını gösteren gereksizlik değeri asgari seviyede tutulması amaçlanır.

x ve y ayrık rastgele değişkenler olmak üzere ve $p(.)$ olasılık kütle fonksiyonunu göstermek üzere, I ile gösterilen olan karşılıklı bilgi fonksiyonu (4.1) ile hesaplanır. Bu karşılıklı bilgi değeri ilişkisellik ve gereksizlik değerlerinin hesaplanmasında kullanılacaktır.

$$I(x, y) = \sum_{i,j} p(x_i, y_j) \log \frac{p(x_i, y_j)}{p(x_i)p(y_j)} \quad (4.1)$$

Ω tüm öznitelikleri, S de seçilecek öznitelik altkümesini göstermek üzere, azami ilişkisellik değeri (4.2) kullanılarak bulunur.

$$\max_{S \subset \Omega} D(S, c), \quad D = \frac{1}{|S|} \sum_{x_i \in S} I(x_i, c) \quad (4.2)$$

Bu denklemdaki I, her bir özneliğin sınıf etiketiyle olan karşılıklı bilgisini, |S| ise S öznitelik altkümesindeki öznitelik sayısını göstermektedir.

Sadece ilişkisellik değerine göre seçilen özniteliklerin birbirlerine bağımlılık miktarı fazla olabilir. Bağımlılık miktarı fazla olan bu özniteliklerden birinin seçilip diğerinin dışarıda bırakılması ile ayırt edicilik açısından önemli bir sorun teşkil etmeyecektir. Dolayısı ile öznitelikler arasındaki gereksizlik değeri hesaplanır. Asgari gereksizlik değeri ise (4.3) kullanılarak bulunur.

$$\min_{S \subset \Omega} R(S), \quad R = \frac{1}{|S|^2} \sum_{x_i, x_j \in S} I(x_i, x_j) \quad (4.3)$$

mRMR sonucunda elde edilen öznitelik kümesi ise (4.2) ve (4.3)ün aynı anda optimize edilmesi ile elde edilir. Bu optimizasyon işlemi de eşit öneme sahip iki durumdan biri ile yapılır (Ding et al., 2003):

$$\max \phi(D, R), \quad \phi = D - R \quad (4.4)$$

$$\max \phi(D, R), \quad \phi = D / R \quad (4.5)$$

Başka bir çalışmada da mRMR algoritmasında kategorilere ayrılmış veriler kullanılmasının sürekli veriler kullanılmasından daha iyi sonuç verdiği gösterilmiştir (Ding et al., 2005). Bu yüzden bu çalışmada da öznitelik seçimi işleminden önce öznitelikler kategorilere ayrılmıştır.

5. ÇIKARILAN ÖZNİTELİKLER

5.1 Spektral Entropi

Entropi bir sistemdeki düzensizliğin ölçütü olarak tanımlanabilir. Entropi ilk kez Shannon tarafından ortaya atılmıştır ve hesabında verinin olasılık dağımı kullanılır. Düzgün bir olasılık dağılımına sahip olan verinin entropisi yüksek olacaktır. Bununla birlikte düzensiz bir olasılık dağılımına sahip olan verinin entropisi ise düşük olacaktır. EEG işaretinin entropisi kullanılarak yapılmış olan bazı çalışmalar mevcuttur (Srinivasan et al. 2005 & Kannathal et al., 2005).

Spektral entropi, normal entropi hesabından farklı olarak işaretin güç spektrumu bileşenlerinin olasılıkları kullanılarak hesaplanır.

$$S = \sum_f P_f \log \left(\frac{1}{P_f} \right) \quad (5.1)$$

Öncelikle, işaretin güç spektral yoğunluğunu bulabilmek amacıyla işaretin Fourier dönüşümü hesaplanır. Buradaki her bir frekans değeri işaretin toplam güç miktarına bölünerek bir olasılık yoğunluk fonksiyonu elde edilir. (5.1)'deki P_f , bu fonksiyonu göstermektedir.

5.2 Renyi Entropi

Renyi Entropi, spektral entropinin özel bir durumudur (Kannathal et al., 2005). (5.2)'de gösterilen şekilde hesaplanır.

$$\text{REN}(\alpha) = -\frac{\alpha}{1-\alpha} \sum \log P_k^\alpha \quad (\alpha \neq 1) \quad (5.2)$$

Bu çalışmada Renyi Entropi $\alpha = 2$ için hesaplanmıştır.

$$\text{REN}(2) = -\log\left(\sum_f P_f^2\right) \quad (5.3)$$

5.3 Varyans

Varyans basit bir istatistiksel değerdir ve ayrık durumlar için (5.4)'teki gibi hesaplanır.

$$\sigma^2 = \frac{1}{N} \sum_{n=1}^N (x_n - \mu_x)^2 \quad (5.4)$$

Burada, x işaretin kendisini, μ ise işaretin ortalamasını göstermektedir.

Epileptik EEG işaretinde daha hızlı ve rastgele değişimler olduğundan varyansın normal EEG işaretlerine göre artması beklenir. Varyans değeri (Mohseni et al., 2006)'da öznitelik olarak kullanılmıştır.

5.4 Petrosian Fraktal Boyutu

Fraktal boyut işaretin fraktal özellikleri hakkında bilgi verir. Petrosian fraktal boyutu (Bao et al, 2008)'de EEG işaretlerinin sınıflandırılması için kullanılmış olan bir özniteliktir.

Petrosian fraktal boyutu (Petrosian, 1995)'e göre (5.5)'te gösterilen şekilde hesaplanmaktadır.

$$PFD = \frac{\log_{10} N}{\log_{10} N + \log_{10} \left(\frac{N}{N + 0.4N_\delta} \right)} \quad (5.5)$$

Burada, N işarettaki örnek sayısını, N_δ işaretin türevindeki \pm işaret değişimini göstermektedir.

5.5 Hjorth Parametreleri

Hjorth tarafından (Hjorth, 1970), EEG işaretlerini zaman uzayında tanımlayabilmek için üç adet değişken hesaplanmıştır. Bunlar genel olarak Hjorth parametreleri olarak bilinir ve isimleri ise aktivite, hareketlilik ve karmaşıklık. Hjorth parametreleri aynı zamanda normalize edilmiş eğim açıklayıcıları olarak da adlandırılır çünkü bu parametreleri hesaplarırken işaretin birinci ve ikinci türevlerinden faydalanılır.

İlk parametre olan aktivite değeri işaretin ortalama enerjisine eşittir. Ortalama enerji başka bir öznelik olarak hesaplandığından burada ayrıca kullanılmamıştır. İkinci parametre olan hareketlilik değeri ortalama frekansın kestirimidir. Son parametre olan karmaşıklık ise işaretin bant genişliğinin kestirimidir (Vourkas et al., 2000).

(Bao et al, 2008)'de öznelik olarak kullanılmış olan bu değerlerin nasıl hesaplandığı (5.6) ve (5.7)'de gösterilmiştir.

$$MOB = \sqrt{\frac{M2}{TP}} \quad (5.6)$$

$$COM = \sqrt{\frac{M4.TP}{M2.M2}} \quad (5.7)$$

Burada, N işaretteki örnek sayısını göstermek üzere, $TP = \sum x_i / N$,

$M2 = \sum d_i / N$, $M4 = \sum (d_i - d_{i-1})^2 / N$ ve $d_i = x_i - x_{i-1}$ olarak tanımlanmıştır.

5.6 Ortalama Eğri Uzunluğu

Epileptik EEG tespiti için daha önceden (Esteller et al., 2001) ve (Gardner et al., 2006)'da kullanılmış olan ortalama eğri uzunluğu esas olarak fraktal boyuttan türetilmiştir. İşlemsel olarak daha kolay olmasının yanı sıra fraktal boyuttan daha iyi sonuçlar verdiği de (Esteller et al., 2001)'de gözlemlenmiştir. (5.8)'de gösterilen şekilde hesaplanır.

$$CL = \frac{1}{N} \sum_{t=2}^N |x[t] - x[t-1]| \quad (5.8)$$

5.7 Ortalama Enerji

Bu öznitelik, (Gardner et al., 2006)'da kullanılmıştır ve işaretteki tüm örneklerin karelerinin ortalaması alınarak hesaplanır (5.9).

$$E = \frac{1}{N} \sum_{t=1}^N x[t]^2 \quad (5.9)$$

5.8 Ortalama Teager Enerjisi

Burada hesaplanan değer ilk kez (Kaiser, 1990)'da ortaya atılmıştır, (Gardner et al., 2006)'da da epilepsi tespiti için öznitelik olarak kullanılmıştır. (5.10)'da gösterilen şekilde hesaplanır.

$$TE = \frac{1}{N} \sum_{t=3}^N (x[t-1]^2 - x[t]x[t-2]) \quad (5.10)$$

5.9 Wigner-Ville Katsayıları

Wigner-Ville dağılımı, zaman ve frekans bilgisini aynı düzlem üzerinde gösteren bir dağılımdır. (5.11)'de gösterilen şekilde hesaplanır.

$$WV(n, \theta) = 2 \sum_{t=-\infty}^{\infty} x(n+t)x^*(n-t)e^{-j2t\theta} \quad (5.11)$$

İşarete Wigner-Ville dönüşümü uygulandıktan sonra elde edilen zaman-frekans düzleminden öznitelikler çıkarabilmek amacıyla bu düzlemdeki her zaman noktası için en büyük olan frekans değerleri kullanılmıştır. Bu frekans değerlerinin oluşturduğu tek boyutlu fonksiyon 3. dereceden bir polinomla modellenmiş ve bu polinomun katsayıları öznitelik olarak kullanılmıştır (Mohseni et al., 2006).

5.10 Dalgacık Katsayıları

Dalgacık dönüşümü, işaretin frekans bilgisinin yanında zaman bilgisini de içerdiğinden, durağan olmayan işaretlerin analizinde Fourier dönüşümünden daha faydalı olması beklenir. Fourier dönüşümü (5.12) denklemiyle ifade edilir.

$$X(f) = \int_{-\infty}^{+\infty} x(t)e^{-2\pi ft} dt \quad (5.12)$$

Görüldüğü gibi dönüşüm sonucunda elde edilen $X(f)$ fonksiyonu sadece frekansa bağlıdır yani zamana ait tüm bilgiler kaybedilmiştir. EEG gibi zaman içinde farklı frekans bileşenlerine sahip olan (durağan olmayan) işaretlerin analizinde ise bu istenmeyen bir durumdur. Fourier dönüşümünün bu kusurunun önüne geçmek için kısa zamanlı Fourier dönüşümü (KZFD) öne sürülmüştür. KZFD’de işaret önce zamanda durağan kabul edilebilecek parçalara ayrılır, bu işleme pencereleme denir. Daha sonra da her bir pencere içersinde kalan işaret için Fourier dönüşümü hesaplanır. Bu işlem (5.13)’te gösterilmiştir.

$$KZFD(\tau, f) = \int_{-\infty}^{+\infty} x(t)g(t-\tau)e^{-j2\pi ft} dt \quad (5.13)$$

Burada $g(t)$ pencere fonksiyonunu göstermektedir.

Seçilen pencerenin boyutu dönüşümün beklenen performansında etkili olacaktır. İşarete sonlu uzunlukta pencerelerden bakıldığı için frekans bilgisinde kayıp olacaktır yani frekans çözünürlüğü azalacak fakat buna karşılık olarak da zaman çözünürlüğü artacaktır. KZFD, tüm dönüşümü sabit boyutlu bir pencere üzerinden yaptığından, KZFD ile hem zamanda hem de frekansta iyi bir çözünürlük sağlanmasında sıkıntı yaşanacaktır. Bu çözünürlükle ilgili problemi gidermek üzere işareti zaman boyunca farklı ölçeklerde analiz edebilen Dalgacık Dönüşümü geliştirilmiştir.

Sürekli Dalgacık Dönüşümünde (SDD) işaret bir dalgacık fonksiyonu ile çarpılarak analiz edilir. Bu dalgacık fonksiyu KZFD’deki pencere fonksiyonu gibi düşünülebilir. Dalgacık dönüşümünün KZFD’den farkı ise bu dalgacık fonksiyonunun ölçeğinin değiştirilmesidir. SDD’nin hesaplanması için kullanılan eşitlik (5.14)’te gösterilmiştir.

$$SDD(s, \tau) = \frac{1}{\sqrt{s}} \int s(t)\psi\left(\frac{t-\tau}{s}\right) dt \quad (5.14)$$

SDD'nin işlem karmaşıklığının çok fazla olması ve dönüşüm sonucunda elde edilen katsayıların bir kısmının sentez için gereksiz olmasından dolayı, bir düzlem üzerindeki SDD katsayılarından ikili olarak örnekler seçilebilir. Böylelikle Ayrık Dalgacık Dönüşümü (ADD) elde edilir:

$$ADD(m, n) = 2^{-\frac{m}{2}} \sum_k s(k) \psi(2^{-m}k - n) \quad (5.15)$$

ADD katsayılarını elde etmek için farklı kesim frekanslarına sahip süzgeçler kullanılır. Analiz edilecek olan işaret öncelikle yarım bantlı alçak ve yüksek geçiren süzgeçlerden geçirilir. Bu süzgeçler birbirinden bağımsız olmayıp, aralarında (5.16)'daki gibi bir ilişki bulunur.

$$g(L-1-n) = (-1)^n h(n) \quad (5.16)$$

Burada, $g(\cdot)$ yüksek geçiren süzgeçi, $h(\cdot)$ alçak geçiren süzgeçi, L ise süzgeç uzunluğunu göstermektedir.


Süzgeçleme işleminden sonra işaret içindeki sıklık bilgisi yarılandığından dolayı, süzgeç çıkışları 2 ile alt-örneklenebilir.

Buradaki süzgeçleme işlemi ile işaretin zaman çözünürlüğü yarıya inerken, alt-örnekleme işlemiyle ölçek iki katına çıkar. Bu işlem matematiksel olarak (5.17) ve (5.18)'deki gibi ifade edilebilir:

$$y_{yüksek}(n) = \sum_k x(k) g(2n - k) \quad (5.17)$$

$$y_{alçak}(n) = \sum_k x(k) h(2n - k) \quad (5.18)$$

Bu işlem alçak geçiren süzgeç çıkışlarına arka arkaya uygulanarak dalgacık katsayıları elde edilir. Alçak geçiren süzgeç çıkışlarının alt-örneklemeinden sonra elde edilen işaret yaklaşıklık katsayıları, yüksek geçiren süzgeç çıkışlarının alt-örneklemeinden sonra elde edilen işaret ise ayrıntı katsayıları olarak isimlendirilir.



Şekil 5. 1 : 3. seviye ayrık dalgacık dönüşümü

Bu çalışmada, Abdülhamit Subaşı'nın çalışmasında (Subaşı, 2007) yaptığı gibi, EEG işaretleri db-4 dalgacığı kullanılarak 5. seviyeye kadar ayrıştırılmıştır. Bu işlem sonucunda, 5 adet ayrıntı katsayıları işareti (A1-A5) ve 1 adet yaklaşıklık katsayıları işareti (Y5) elde edilmiştir. Bu işaretlerden sadece A3,A4,A5 ve Y5 kullanılarak aşağıda açıklanan öznelikler çıkarılmıştır:

- Her alt-banttaki katsayıların mutlak değerinin ortalaması
- Her alt banttaki katsayıların ortalama gücü
- Her alt-banttaki katsayıların standart sapması
- Ardışık her iki alt-bandın mutlak değerlerinin ortalamasının oranı.


Böylelikle 15 boyutlu bir öznelik vektörü elde edilmiştir.

6. VERİ KÜMESİ

Bu çalışmada kullanılan EEG işaretleri (EEG Time Series Download Page) den alınmıştır ve bu işaretlerin özellikleri (Andrzejak et al., 2001) de ayrıntılı bir biçimde açıklanmıştır. Bu veri tabanında, A, B, C, D, E olmak üzere, 5 farklı EEG veri kümesi bulunmaktadır. Bu kümeler, her biri 23.6 saniyelik süreye sahip 100 parçalık tek kanallı EEG kaydından oluşmaktadır. Çok kanallı EEG kaydındaki, kas kasılması veya göz hareketinden dolayı oluşan bozulmaların görsel denetim sonunda çıkarılması ile bu parçalar elde edilmiştir.

A kümesi, sağlıklı kişilerden, gözler açık biçimde, yüzey elektrotları ile kaydedilmiş EEG verisini içerir. B kümesi, sağlıklı kişilerden, gözler kapalı biçimde, yüzey elektrotları ile kaydedilmiş EEG verisini içerir. D kümesi, epilepsi hastalarının beynindeki epileptik bölgeden, ameliyat öncesinde girişimsel olarak kaydedilmiş EEG verisini içerir. Bu kümedeki veriler epileptik bölgeden alınmış olmasına rağmen epilepsi nöbeti olmadığı anda kaydedildiğinden epilepsi bilgisi içermemektedir. C kümesi, D kümesindeki kayıtların alındığı bölgeye simetrik olan beynin diğer yarısındaki kısımdan alınmıştır. E kümesi ise hastalıklı kişilerden, epilepsi krizi anında, girişimsel olarak kaydedilmiş EEG verisini içerir.


Bu EEG işaretleri 12 bitlik çözünürlükte, 173.61 Hz'lik örnekleme frekansı ile sayısallaştırılmıştır ve her bir küme 39.33 dakikalık kayıt içermektedir. Ayrıca süzgeç olarak 40Hz.'lik kesim frekansına sahip alçak geçiren süzgeç kullanılmıştır. Her bir küme için örnek işaretler şekil 6.1'de gösterilmiştir.



Şekil 6. 1 : A, B, C, D, E kümlelerinden alınmış 10'ar saniyelik örnekler

7. DENEYLER

Eđitim için kullanılan EEG verileri epilepsi krizinin olmadığı anda kaydedildiđinden, bu kümelerin her biri için farklı sınıflandırıcılar eğitilmiştir. Eğitim işlemi için ilgili kümenin %90'ı kullanılmış olup geriye kalan %10'luk kısmı test kümesine dahil edilmiştir. Yani test işlemi epileptik veriyi içeren E kümesinin yanında bu bahsedilen %10'luk kısım üzerinde yapılmıştır.



Şekil 7. 1 : A kümesi için eğitim ve test kümelerinin ayrılması

Eđitim ve test işlemleri için 3 farklı durum için yapılmıştır:

- Tüm 28 öznitelik birden kullanılarak
- TBA ile özniteliklerin özuzaydaki enerjisinin %95'i kapsanacak şekilde boyut azaltım işleminden sonra
- mRMR ile öznitelik seçimi yapıldıktan sonra

Her bir durum için performansın karşılaştırılabilmesi amacıyla da ölçüt olarak ROC eğrisi çıkarılmış ve AUC değerleri hesaplanmıştır. ROC eğrisi ikili sınıflandırma sistemlerinde farklı eşik değerleri için gerçek pozitif oranının (GPO) yanlış pozitif oranına (YPO) göre değişimini gösterir. Bu eğri altında kalan alan ise bize AUC değerini vermektedir. Dolayısı ile AUC değeri 1'e ne kadar yakın ise sonuç o kadar iyi demektir.

$$GPO = \frac{GP}{GP + YN} \quad (7.1)$$

$$YPO = \frac{YP}{YP + GN} \quad (7.2)$$

(7.1) ve (7.2)'de GP: gerçek pozitif, YP: yanlış pozitif, GN: gerçek negatif, YN: yanlış negatif olarak kısaltılmıştır. Bu değerler çizelge 7.1'deki hata matrisinde gösterildiği şekilde hesaplanmıştır.

Çizelge 7. 1 : Hata Matrisi.

		Kestirilmiş	
		+1	-1
Gerçek	+1	GP	YN
	-1	YP	GN

Bu çalışmada normal EEG örnekleri +1 ile etiketlenmiş, epileptik EEG örnekleri ise -1 ile etiketlenmiştir.


7.1 Öznitelik Çıkarma

Öznitelik çıkarma işlemi için 1 saniyelik pencere 0.5 saniyelik adımlarla EEG işareti üzerinde kaydırılmış ve her adımda pencere içinde kalan EEG işareti için öznitelikler bölümünde anlatılmış olan öznitelikler hesaplanmıştır. Böylelikle her adım için 28 boyutlu bir öznitelik vektörü oluşturulmuştur.

Her bir özniteliğin A, B, C, D, E kümelerinin her biri için ortalaması standart sapmaları ile birlikte EK A'daki şekillerde gösterilmiştir. Özniteliğin düşük standart sapmaya sahip olması ve epileptik veriden farklı bölgede dağılım göstermesi o özniteliğin daha ayırt edici olduğunu göstermektedir.

7.2 Temel Bileşenler Analizi

TBA işlemi, epileptik EEG işaretini içeren E kümesi test için kullanılırken geriye kalan dört küme ayrı ayrı eğitim kümesi olarak alınarak yapılmıştır. Bu işlem sonucunda elimizdeki 28 boyutlu öznitelik uzayının boyutu, eğitim için A kümesi kullanılması durumunda 7'ye, B,C ve D kümesi kullanılması durumunda ise 6'ya düşmüştür. Bu dört durum için elde edilen özdeğerler küçükten büyüğe doğru sıralanarak şekil 7.2'de gösterilmiştir. Özdeğerlerin çoğunun düşük olması, enerjinin yüksek özdeğerlerle ifade edilen az miktardaki özvektörlerde yoğunlaştığını, dolayısıyla TBA ile boyut azaltılsa da performansta düşme olmayabileceğine işaret etmektedir.



Şekil 7. 2 : A, B, C ve D kümesi için özdeğerler

7.3 mRMR ile Öznitelik Seçimi

Dördüncü bölümde optimizasyon işleminin iki şekilde yapılabileceği belirtilmişti. Bu çalışmada ilişkisellik ve gereksizlik değerlerinin farkını alan (4.3) kullanılmıştır.

mRMR işleminin uygulanması esnasında (Peng, mRMR Feature Selection Site)'deki araçtan faydalanılmıştır. Bu işlem tüm EEG kümeleri için sınıf etiketleri ile birlikte aynı anda uygulanmıştır. Sonuç olarak öznitelikler önem sırasına göre çizelge 7.2'de gösterilen şekilde sıralanmıştır.

Çizelge 7.2'ye göre en önemli ilk 4, 6, 7 ve 15 öznitelik kullanılarak sınıflandırıcı eğitilmiş ve bu sınıflandırıcının test kümesi üzerindeki performansına bakılmıştır. Bu öznitelik sayılarından 6 ve 7'nin seçilme nedeni TBA sonucunda da 6 ve 7 boyutlu öznitelik vektörleri elde edilmiş olmasıdır. 4 ve 15'in seçilme nedeni ise kullanılan öznitelik sayısının artması veya azalması durumunda performansın nasıl değişim gösterdiği hakkında fikir sahibi olabilmektir.

Çizelge 7. 2 : mRMR'a göre özneliklerin sıralanışı

Sıra no	Öznitelik	Sıra no	Öznitelik
1	Dalgacık - 10	15	Dalgacık – 13
2	Petrosian Fraktal Boy.	16	Wigner Ville – 3
3	Dalgacık - 11	17	Dalgacık – 6
4	Dalgacık - 9	18	Hjorth Mobilitesi
5	Dalgacık - 4	19	Varyans
6	Wigner Ville - 2	20	Wigner Ville – 1
7	Dalgacık - 2	21	Dalgacık – 7
8	Dalgacık - 3	22	Ort. Teager Enerjisi
9	Dalgacık – 14	23	Ort. Enerji
10	Ort. Eğri Uzunluğu	24	Hjorth Kompleksitesi
11	Dalgacık - 12	25	Dalgacık – 8
12	Dalgacık – 15	26	Dalgacık – 5
13	Dalgacık – 1	27	Spektral Entropi
14	Wigner Ville – 4	28	Renyi Entropi

7.4 Tek-Sınıf DVM

Elimizdeki örnekler tek-sınıf DVM'de kullanılmadan önce (7.3)'te gösterilen şekilde ölçeklenmiştir.

$$z = \frac{x - \mu}{\sigma} \quad (7.3)$$

Burada μ öznelik ortalaması, σ öznelik standart sapması ve x de öznelik vektörünü göstermektedir.

Uygulama MATLAB ortamında gerçekleştirilmiş ve ücretsiz bir yazılım olan LIBSVM'den (Chang et al., 2001) faydalanılmıştır. Çekirdek fonksiyonu olarak, $\gamma = 1$ olan Gauss fonksiyonu kullanılmıştır. Ayrıca tek-sınıf DVM'nin, yanlış sınıflandırmaların izin verilen en fazla oranını kontrol eden değişkeni ν 'nün sınıflandırıcı performansı üzerindeki etkisini inceleyebilmek amacıyla, bu değişkenin 2 farklı değeri için ($\nu = 0.1$ ve $\nu = 0.5$) eğitim ve test işlemleri tekrar edilmiştir.

8. SONUÇLAR

Tüm öznitelikler, TBA ve 4, 6, 7, 15 mRMR özniteliği kullanılarak yapılmış olan sınıflandırmalar sonucunda elde edilen ROC eğrilerini görmek için EK B'deki şekillere bakınız. Bu ROC eğrileri için AUC değerleri de çizelge 8.1 ve çizelge 8.2'de gösterilmiştir.

Çizelge 8. 1 : AUC Değerleri ($\nu=0.1$)

	Tüm Öznitelikler	tba 95%	mrmr 4	mrmr 6	mrmr 7	mrmr 15
A	0.9935	0.9978	0.9994	0.9999	0.9999	0.9978
B	0.9925	0.9928	0.9919	0.9940	0.9937	0.9931
C	0.9823	0.9940	0.9950	0.9950	0.9952	0.9914
D	0.9858	0.9589	0.9868	0.9846	0.9856	0.9834

Çizelge 8. 2 : AUC Değerleri ($\nu=0.5$)

	Tüm Öznitelikler	tba 95%	mrmr 4	mrmr 6	mrmr 7	mrmr 15
A	0.9935	0.9978	0.9996	0.9999	0.9999	0.9978
B	0.9925	0.9933	0.9943	0.9939	0.9935	0.9931
C	0.9823	0.9942	0.9951	0.9954	0.9954	0.9914
D	0.9864	0.9840	0.9926	0.9950	0.9952	0.9864

Çizelgelerdeki AUC değerlerinin çok yüksek olması, bahsedilen sınıflandırıcıların iyi sonuçlar verdiğini göstermektedir. C ve D kümelerinde performans daha düşüktür çünkü bu kümelerdeki veriler de E kümesindeki veriler gibi girişimsel olarak kaydedilmiştir. A, B ve C kümelerinde TBA kullanılması, tüm özniteliklere göre daha iyi sonuç vermiştir. D kümesinde de TBA sonucunda sonuçta kötüleşme olmuştur. mRMR sonuçlarına baktığımızda ise performansın öznitelik sayısı ile orantılı olarak arttığı gözlemlenmemektedir. Ama yine de mRMR-4 ile TBA'yı karşılaştırdığımızda, çizelge 8.1'deki B kümesi haricinde, öznitelik seçimi ile daha yüksek AUC değerleri elde etmenin mümkün olduğu görülmektedir. Ayrıca, TBA sonucundaki öznitelik sayısı olan 6 ve 7 adet öznitelik kullanılarak yapılan testlerin sonucu TBA ile alınan sonuçlardan daha iyidir. 15 adet öznitelik kullanılması

durumunda ise kimi AUC deęerlerinde genel olarak kçük artıř veya azalma olurken kimi AUC deęerleri ise deęiřiklik gstermemiřtir.

9. YORUMLAR

Bu çalışmada tek-sınıf DVM'den yararlanılarak epileptik EEG işaretleri tespit edilmiştir. Şimdiye kadar bu yönde yapılmış olan birçok çalışmada sınıflandırıcının eğitimi için edinilmesi bir hayli güç olan epileptik veriye de ihtiyaç duyulmuştur. Fakat tek-sınıf DVM'nin bu diğer çalışmalarda kullanılmış olan yöntemlerden farkı eğitim için sadece normal veriye ihtiyaç duymasıdır. Bu şekilde eğitilmiş olan bir sınıflandırıcı doğru sınıflandırılan örnekleri hastaliksız veri olarak etiketlerken, yanlış sınıflandırılan örnekleri ise epileptik veri olarak etiketler.

Bu amaçla literatürde daha önceden kullanılmış olan 28 adet öznitelik çıkarılmıştır. Öznitelik uzayının boyutunu azaltmak amacıyla da öznitelikler arasındaki bağımlılığı ortadan kaldırarak birbirinden ilişkisiz yeni öznitelikler elde eden TBA yöntemi ve özniteliklerin birbirleri ve sınıf etiketleri arasındaki karşılıklı bilgilerini kullanan mRMR öznitelik seçimi yöntemi uygulanmıştır.

TBA işleminde kovaryans matrisinin bazı özdeğerlerinin diğerlerine göre daha baskın olduğu görülmüştür. Buradan da TBA kullanılarak boyutun büyük ölçüde azaltılabileceği anlaşılmaktadır. mRMR yönteminde de öznitelikler karşılıklı ilişkisellik ve gereksizlik değerleri göz önünde bulundurularak önem sırasına göre dizilmişlerdir. Sınıflandırıcının eğitimi için de tüm öznitelikler yerine diğerlerine göre daha önemli olduğu anlaşılan öznitelikler kullanılarak boyut azaltılmıştır.

Boyut azaltım işlemi ile hem sınıflandırıcının karmaşıklığı azaltılmıştır hem de eğitim ve test sürelerinde düşme olmuştur çünkü daha düşük boyutlu bir öznitelik uzayında örnekler ve sınıflandırıcı daha az veri ile ifade edilebilmektedir.

Çizelge 8.1 ve çizelge 8.2'deki sonuçlara baktığımızda ise TBA uygulanması durumunda sistem performansının tüm öznitelikler kullanılması durumuna göre artma eğiliminde olduğu gözlemlenmiştir. Bununla birlikte en iyi sonuçlar mRMR ile seçilen özniteliklerden 4, 6 ve 7 tanesinin kullanılması ile elde edilmiştir. Bu 4 öznitelik sırasıyla dalgacık-10, petrosian fraktal boyutu, dalgacık-11 ve dalgacık-9'dur. Bunlardan dalgacık katsayıları (Subaşı, 2007)'de, petrosian fraktal boyutu da

(Bao et al, 2008)'de kullanılmıştır. Kullanılan öznitelik sayısı 15'e çıkarıldığında ise performansta düşme görülmektedir. Yani mRMR özniteliklerinden uygun sayıda kullanılması gereklidir. Son olarak, tek-sınıf DVM'nin ν parametresinin farklı 2 değeri için de en iyi sonuçlar yine mRMR öznitelikleri ile alınmıştır.

En iyi sonuçların elde edildiği mRMR'da özniteliklerin uygun sayıda olması gerektiğini söylemiştik. Bu çalışmayı daha da ilerletmek amacıyla, bahsedilen bu uygun öznitelik sayısına otomatik olarak karar verilebilecek şekilde sistemin geliştirilmesi düşünülebilir. Ayrıca, mRMR'dan sonra daha başka öznitelik seçim yöntemleri de uygulanıp sonuçlar toplu olarak karşılaştırılabilir.

KAYNAKLAR

- Aizerman, M.A., Braverman, E.M. & Rozoner, L.I.**, 1964. Theoretical Foundations of the Potential Function Method in Pattern Recognition Learning. *Automation and Remote Control*. 25:821-837.
- Andrzejak, R. G., Lehnertz, K., Mormann, F., Rieke, C., David, P., & Elger, C. E.**, 2001. Indications of Nonlinear Deterministic and Finite-Dimensional Structures in Time Series of Brain Electrical Activity: Dependence on Recording Region and Brain State. *Physical Review E*. vol. 64, Nov.
- Bao, F. S., Lie, D. Y., & Zhang, Y.**, 2008. A New Approach to Automated Epileptic Diagnosis Using EEG and Probabilistic Neural Network. *20th IEEE International Conference on Tools with Artificial Intelligence*. vol:2, pp: 482-486.
- Boser, B. E., Guyon, I. M., & Vapnik V.** 1992. A training Algorithm for Optimal Margin Classifiers. *5th Annual Workshop on Computational Learning Theory*. Pittsburg. ACM.
- Burges, C. J. C.**, 1998. A Tutorial on Support Vector Machines for Pattern Recognition. *Data Mining and Knowledge Discovery*. vol. 2, pp: 121–167.
- Chang, C. C., & Lin, C. J.**, 2001. LIBSVM: A Library for Support Vector Machines. Alındığı Tarih: 01.09.2008 Alındığı Adres: <http://www.csie.ntu.edu.tw/~cjlin/libsvm>
- Ding, C., & Peng, H.**, 2003. Minimum Redundancy Feature Selection from Microarray Gene Expression Data. *Proceedings of the IEEE Bioinformatics Conference*. pp: 523-528.
- Ding, C., & Peng, H.**, 2005. Minimum Redundancy Feature Selection from Microarray Gene Expression Data. *Journal of Bioinformatics and Computational Biology*, vol:3, no:2, pp: 185-205.
- EEG Time Series Download Page.** *Klinik für Epileptologie, Universitat Bonn*. Alındığı Tarih: 01.09.2008. Alındığı Adres: http://www.meb.uni-bonn.de/epileptologie/cms/front_content.php?idcat=193&lang=3&channelang=3
- Esteller, R., Echauz, J., Tcheng, T., Litt, B., & Pless, B.**, 2001. Line Length: An Efficient Feature for Seizure Onset Detection. *Proceedings of the 23rd Annual EMBS International Conference*. pp: 1707-1710.
- Gardner, A. B., Krieger, A. E., Vachtsevanos, G., & Litt, B.**, 2006. One-Class Novelty Detection for Seizure Analysis from Intracranial EEG. *Journal of Machine Learning Research*. vol:7, pp:1025-1044.

- Gotman, J.**, 1982. Automatic recognition of epileptic seizures in the EEG. *Electroencephalography and Clinical Neurophysiology*. 54(5):530-40.
- Gotman, J.**, 1990. Automatic seizure detection: improvements and evaluation. *Electroencephalography and Clinical Neurophysiology*. 76(4):317-24.
- Gökçil, Z.**, Epilepsi. Alındığı tarih 15.04.2009, alındığı adres <http://www.gata.edu.tr/dahilibilimler/noroloji/epilepsi.htm>
- Güler, İ., & Übeyli, E. D.**, 2005. Adaptive neuro-fuzzy inference system for classification of EEG signals using wavelet coefficients. *Journal of Neuroscience Methods*. 148: 113-121.
- Güler, N. F., Übeyli, E. D., & Güler, İ.**, 2005. Recurrent neural networks employing Lyapunov exponents for EEG signals classification. *Expert systems with applications*. 29: 506-514.
- Güler, İ., & Übeyli, E. D.**, 2006. Expert systems for time-varying biomedical signals using eigenvector methods. *Expert Systems with Applications*. vol: 32, pp: 1045-1058.
- Hjorth, B.**, 1970. EEG Analysis Based on Time Domain Properties. *Electroencephalography and Clinical Neurophysiology*. vol:29, pp: 306-310.
- Hotelling, H.**, 1933. Analysis of a complex of statistical variable into principal components. *The Journal of Educational Psychology*. vol. 24, pp: 417-441.
- Jiang, B., Zhang, M. Q., & Zhang, X.**, 2007. OSCAR: One-Class SVM for Accurate Recognition of cis-elements. *Bioinformatics*, Oxford, England, vol:23, no:21, pp:2823-2828.
- Jinfeng, F., Chenxi, S., Ouyang, Y., Jian, W., Shaobin, L., & Zicai, W.**, 2006. Automatic seizure detection based on support vector machines with genetic algorithms. *Springer*. 4247, pp: 845-852.
- Kaiser, J. F.**, 1990. On a Simple Algorithm to Calculate the ‘energy’ of a Signal. *International Conference on Acoustics, Speech, and Signal Processing*. vol:1, pp:381-384.
- Kannathala, N., Choo, M. L., Acharyab, U. R., & Sadasivana, P. K.**, 2005. Entropies for detection of epilepsy in EEG. *Computer Methods and Programs in Biomedicine*. 80: 187-194.
- Lyu, S., & Farid, H.**, 2004. Steganalysis Using Color Wavelet Statistics and One-Class Support Vector Machines. *SPIE Symposium on Electronic Imaging*. vol. 5306, pp: 35–45.
- Manevitz, L. M., & Yousef, M.**, 2001. One-Class SVMs for Document Classification. *Journal of Machine Learning Research*. vol:2, pp:139-154.
- Mohseni, H. R., Maghsoudi, A., & Shamsollahi, M. B.**, 2006. Seizure Detection in EEG Signals: A Comparison of Different Approaches. *28th Annual International Conference of the IEEE EMBS*. pp: 6724-6727.

- Peng, H., Long, & F., Ding, C.,** 2005. Feature Selection Based on Mutual Information: Criteria of Max-Dependency, Max-Relevance, and Min-Redundancy. *IEEE Transactions on Pattern Analysis and Machine Intelligence*. vol:27, no: 8, pp:1226-1238, August.
- Peng, H.,** mRMR Feature Selection Site, Alındığı Tarih: 01.03.2009, Alındığı Adres: <http://research.janelia.org/peng/proj/mRMR/>
- Petrosian, A.,** 1995. Kolmogorov complexity of finite sequences and recognition of different preictal EEG patterns. *Proc. of the 8th IEEE Symposium on Computer-Based Medical Systems*.
- Polat, K., & Güneş, S.,** 2007. Classification of epileptiform EEG using a hybrid system based on decision tree classifier and fast Fourier transform. *Applied Mathematics and Computation*. vol: 187, pp: 1017-1026.
- Polat, K., & Güneş, S.,** 2008. Artificial immune recognition system with fuzzy resource allocation mechanism classifier, principal component analysis and FFT method based new hybrid automated identification system for classification of EEG signals. *Expert Systems with Applications*, vol: 34, pp: 2039-2048.
- Qu, H., & Gotman, J.,** 1995. A seizure warning system for long-term epilepsy monitoring. *American Academy of Neurology, Neurology*. 45: 2250-2254.
- Schölkopf, B., Platt, J. C., Taylor, J. S., Smola, A. J., & Williamson, R. C. ,** 1999. Estimating the support of a high-dimensional distribution. *Microsoft Research*, Redmond, WA, USA, MSR-TR-99-87
- Srinivasan, V., Eswaran, C., & Sriraam, N.,** 2005. Artificial Neural Network Based Epileptic Detection Using Time-Domain and Frequency-Domain Features. *Journal of Medical Systems*. 29: 647-660.
- Srinivasan, V., Eswaran, C., & Sriraam, N.,** 2007. Approximate Entropy based Epileptic EEG detection using Artificial Neural Networks. *IEEE Transactions on Information Technology in Biomedicine*. vol: 11, no:3, May.
- Subaşı, A.,** 2007. EEG signal classification using wavelet feature extraction and a mixture of expert model. *Expert Systems with Applications*. 32, pp:1084-1093.
- Tran, Q. A., Duan, H., & Li, X.,** 2004. One-class Support Vector Machine for Anomaly Network Traffic Detection. *The 2nd Network Research Workshop of the 18th APAN*, Cairns, Australia
- Tzallas, A. T., Tsipouras, M. G., & Fotiadis, D. I.,** 2007. Automatic Seizure Detection Based on Time-Frequency Analysis and Artificial Neural Networks. *Computational Intelligence and Neuroscience*. vol:7, issue 3.
- Vapnik, V.,** 1999. The Nature of Statistical Learning Theory. *Springer-Verlag*. New York.

Vourkas, M., Papadourakis, G., & Micheloyannis, S., 2000. Use of ANN and Hjorth Parameters in Mental-Task Discrimination. *1st International Conference on Advances in Medical Signal and Information Processing*. pp:327-332.


EKLER

EK A : Özniteliklerin Ortalama ve Standart Sapmaları

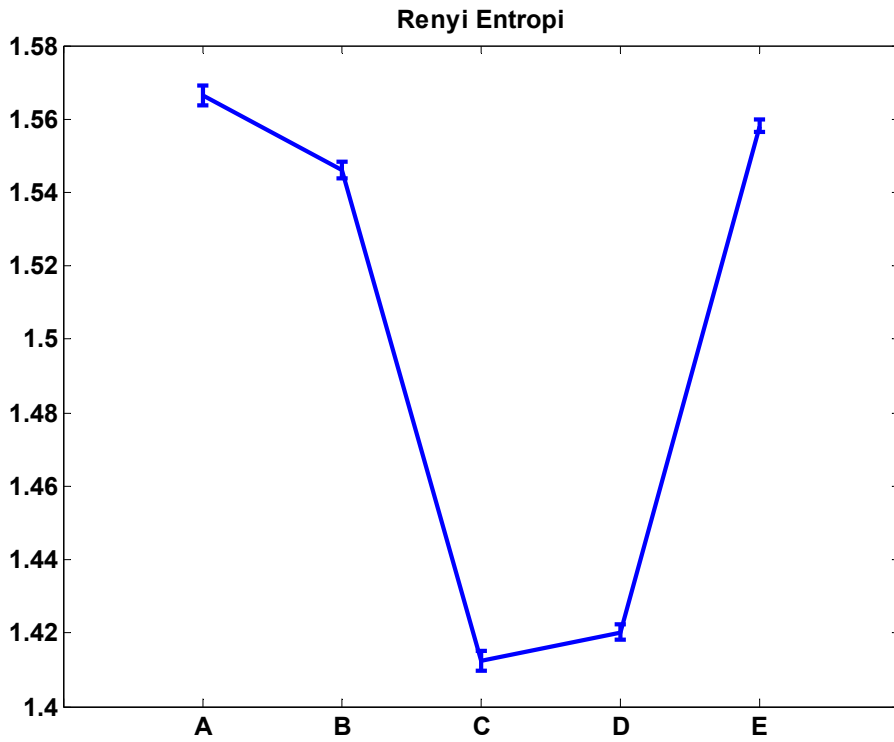
EK B : ROC Eğrileri

EK C : Sözlük

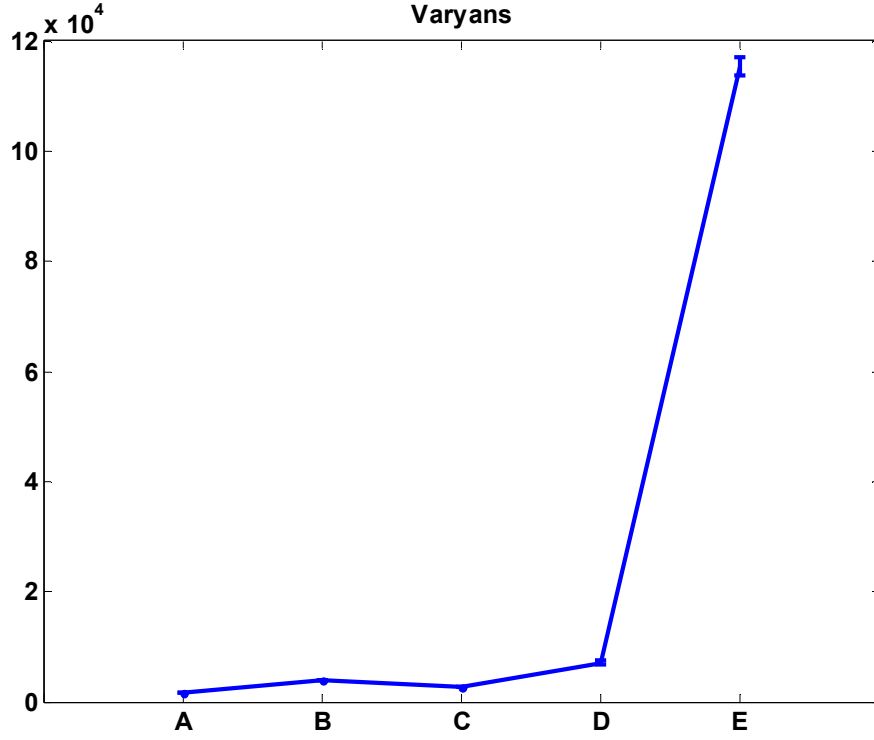
EK A: Özniteliklerin Ortalama ve Standart Sapmaları




Şekil A. 1 : Spektral entropinin tüm kümeler için ortalaması ve standart sapması




Şekil A. 2 : Renyi entropinin tüm kümeler için ortalaması ve standart sapması



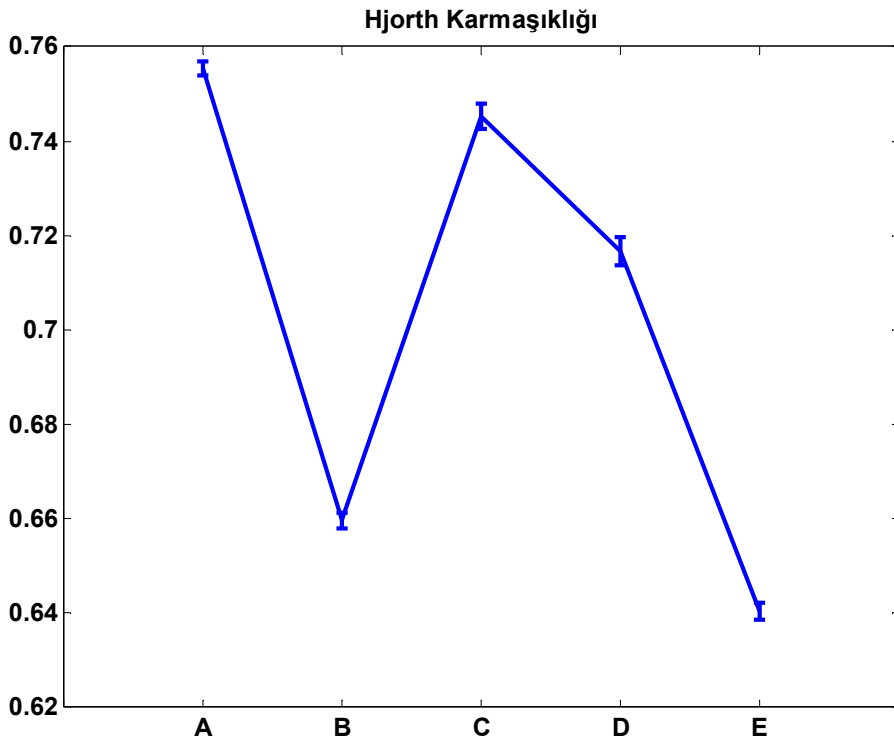
Şekil A. 3 : Varyansın tüm kümeler için ortalaması ve standart sapması




Şekil A. 4 : Petrosian fraktal boyutunun tüm kümeler için ortalaması ve standart sapması



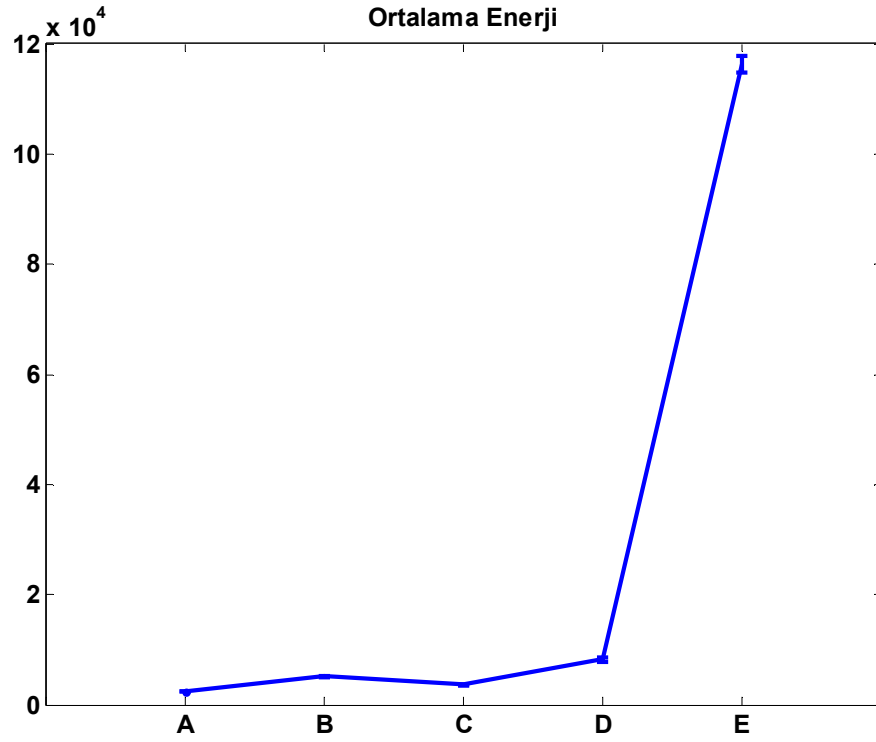
Şekil A. 5 : Hjorth hareketliliğinin tüm kümeler için ortalaması ve standart sapması



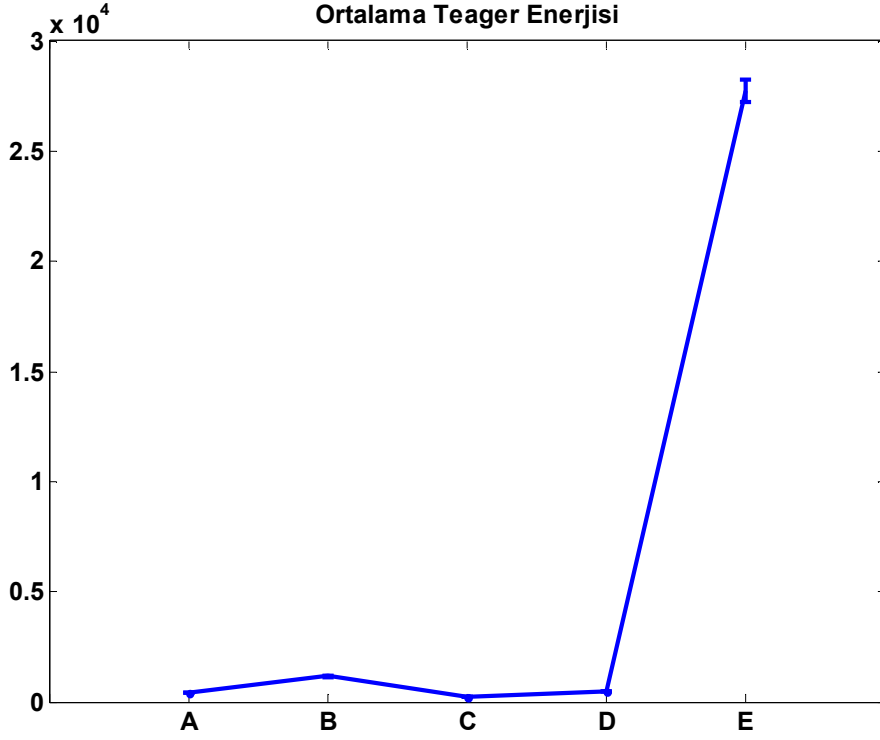
Şekil A. 6 : Hjorth karmaşıklığının tüm kümeler için ortalaması ve standart sapması




Şekil A. 7: Ortalama eğri uzunluğunun tüm kümeler için ortalaması ve standart sapması



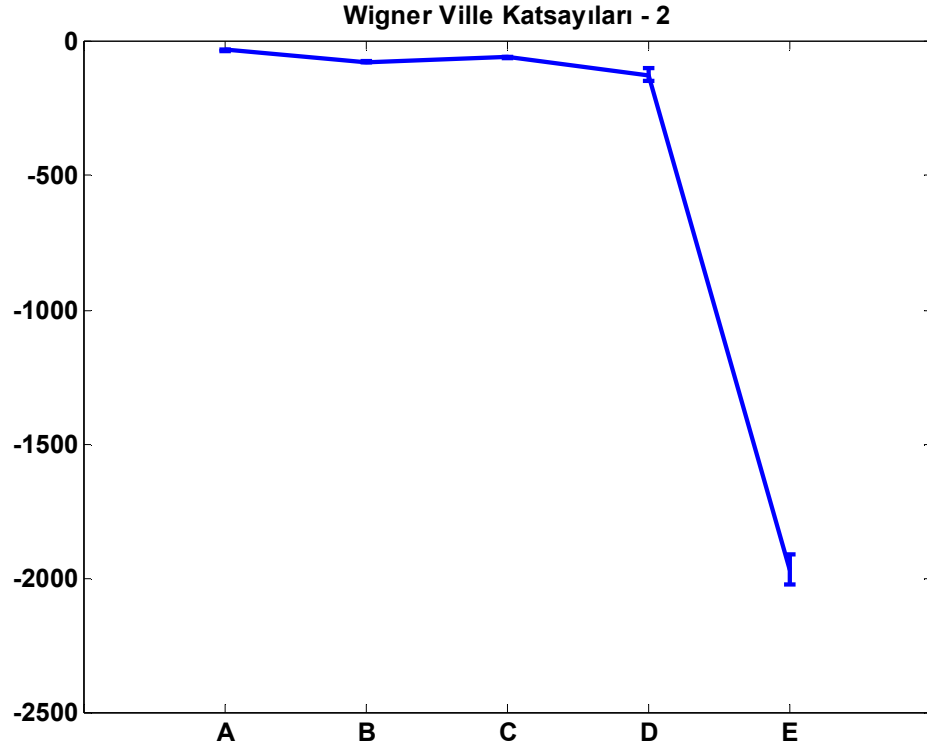
Şekil A. 8 : Ortalama enerjinin tüm kümeler için ortalaması ve standart sapması




Şekil A. 9 : Ortalama teager enerjisinin tüm kümeler için ortalaması ve standart sapması



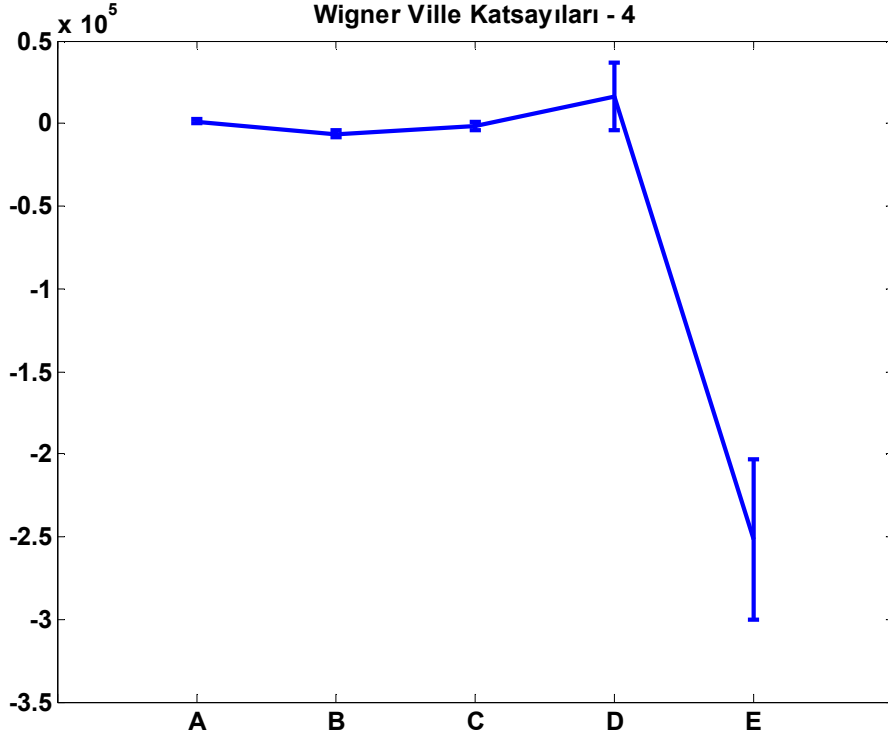
Şekil A. 10 : Wigner Ville katsayıları-1'in tüm kümeler için ortalaması ve standart sapması




Şekil A. 11 : Wigner Ville katsayıları-2'nin tüm kümeler için ortalaması ve standart sapması




Şekil A. 12 : Wigner Ville katsayıları-3'ün tüm kümeler için ortalaması ve standart sapması




Şekil A. 13 : Wigner Ville katsayıları-4'ün tüm kümeler için ortalaması ve standart sapması




Şekil A. 14 : Dalgacık katsayıları-1'in tüm kümeler için ortalaması ve standart sapması



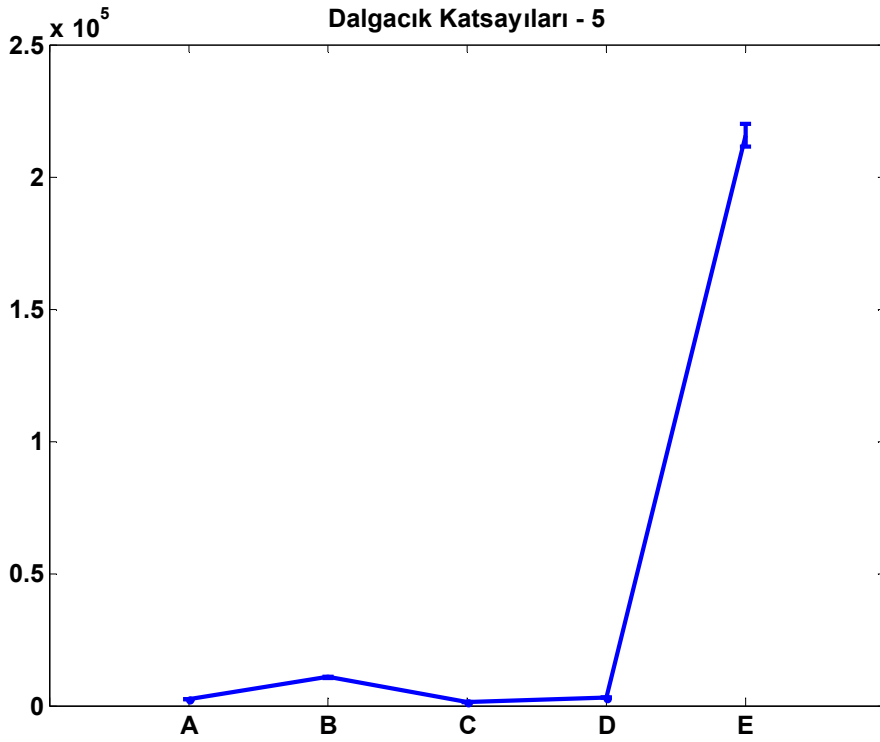
Şekil A. 15 : Dalgacık katsayıları-2'nin tüm kümeler için ortalaması ve standart sapması



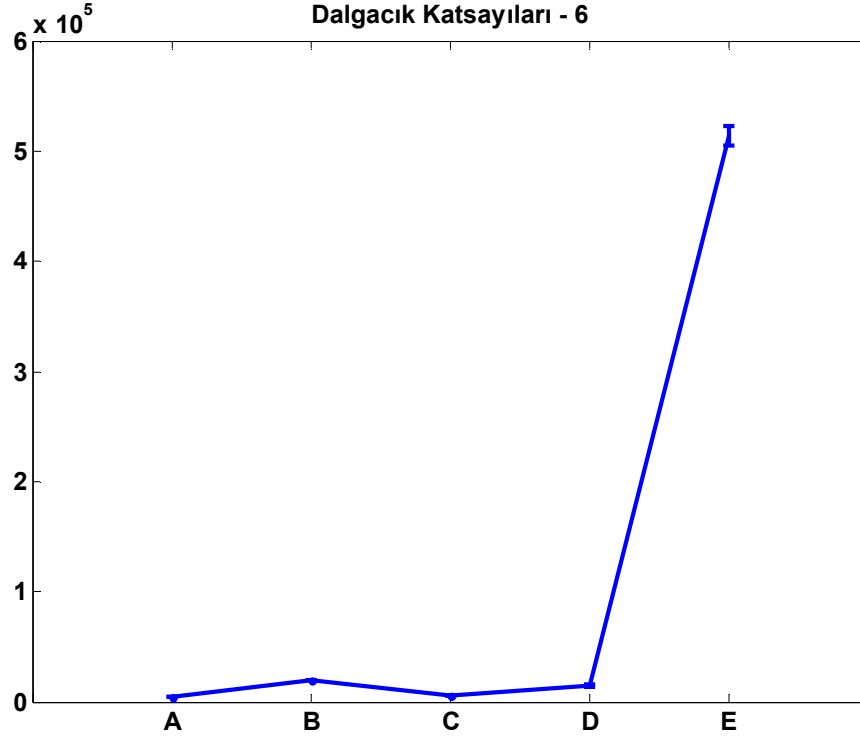
Şekil A. 16 : Dalgacık katsayıları-3'ün tüm kümeler için ortalaması ve standart sapması




Şekil A. 17 : Dalgacık katsayıları-4'ün tüm kümeler için ortalaması ve standart sapması




Şekil A. 18 : Dalgacık katsayıları-5'in tüm kümeler için ortalaması ve standart sapması




Şekil A. 19 : Dalgacık katsayıları-6'nın tüm kümeler için ortalaması ve standart sapması




Şekil A. 20 : Dalgacık katsayıları-7'nin tüm kümeler için ortalaması ve standart sapması




Şekil A. 21 : Dalgacık katsayıları-8'in tüm kümeler için ortalaması ve standart sapması




Şekil A. 22 : Dalgacık katsayıları-9'un tüm kümeler için ortalaması ve standart sapması




Şekil A. 23 : Dalgacık katsayıları-10'un tüm kümeler için ortalaması ve standart sapması



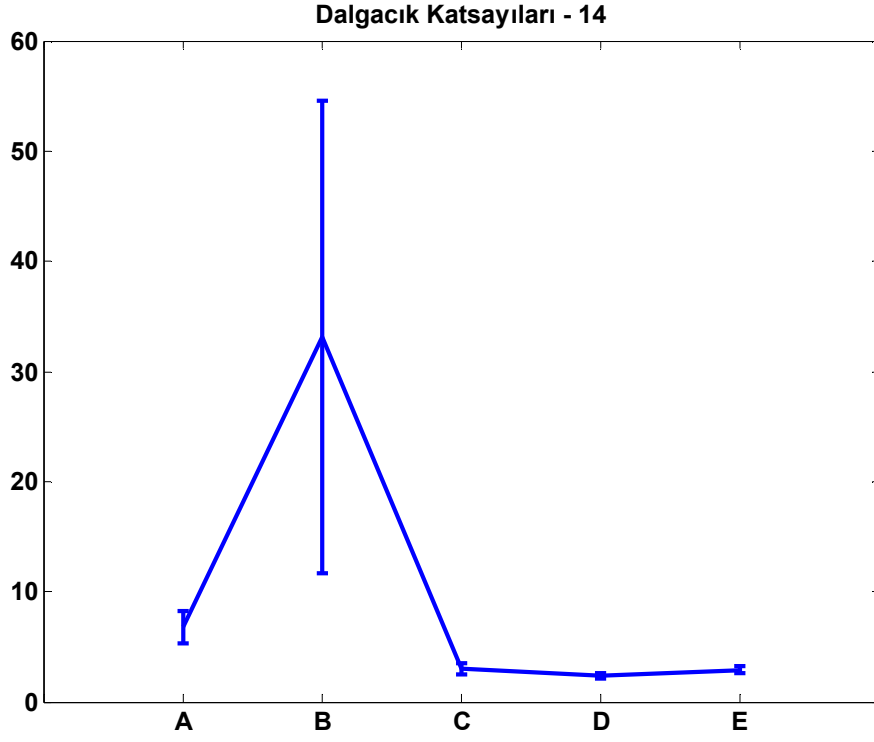
Şekil A. 24 : Dalgacık katsayıları-11'in tüm kümeler için ortalaması ve standart sapması




Şekil A. 25 : Dalgacık katsayıları-12'nin tüm kümeler için ortalaması ve standart sapması



Şekil A. 26 : Dalgacık katsayıları-13'ün tüm kümeler için ortalaması ve standart sapması




Şekil A. 27 : Dalgacık katsayıları-14'ün tüm kümeler için ortalaması ve standart sapması

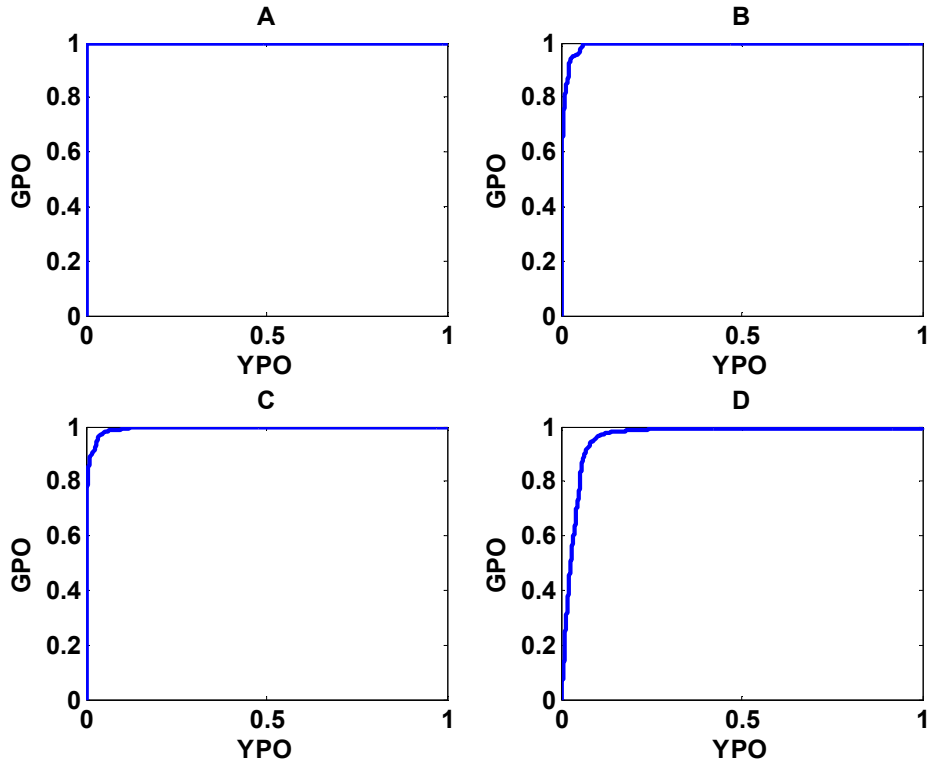


Şekil A. 28 : Dalgacık katsayıları-15'in tüm kümeler için ortalaması ve standart sapması


EK B: ROC Eğrileri




Şekil B. 1 : Tüm öznelıklar kullanılması durumunda elde edilen ROC eğrileri




Şekil B. 2 : TBA kullanılması durumunda elde edilen ROC eğrileri




Şekil B. 3 : 4 adet mRMR öz niteliği kullanılması durumunda elde edilen ROC eğrileri



Şekil B. 4 : 6 adet mRMR öz niteliği kullanılması durumunda elde edilen ROC eğrileri



Şekil B. 5 : 7 adet mRMR özneliği kullanılması durumunda elde edilen ROC eğrileri



Şekil B. 6 : 15 adet mRMR özneliği kullanılması durumunda elde edilen ROC eğrileri

EK C: Sözlük

Alt örnekleme	:	Sub-sampling
Ayırım sınırı	:	Margin boundary
Ayrımlık	:	Margin
Ayrıntı katsayıları	:	Detail coefficients
Başarım	:	Accuracy
Boyut azaltımı	:	Dimension reduction
Çekirdek fonksiyonu	:	Kernel function
Doğrusal olarak ayrılabilen	:	Linearly separable
Durağan	:	Stationary
Durağan olmayan	:	Non-stationary
Duyarlılık	:	Sensitivity
Eğri uzunluğu	:	Curve length
Enazlamak	:	Minimize
Ençoklamak	:	Maximize
Fraktal boyut	:	Fractal dimension
Genelleme yetisi	:	Generalization
Gereksizlik	:	Redundancy
Gevşek değişken	:	Slack variable
Giriş uzayı	:	Input space
Gözetimsiz öğrenme	:	Unsupervised learning
Hareketlilik	:	Mobility
Hata matrisi	:	Confusion matrix
Hiperdüzlem	:	Hyperplane
İkili	:	Dyadic
İkili fonksiyon	:	Binary function
İkili gösterim	:	Dual representation
İlişkiselik	:	Relevance
Karar fonksiyonu	:	Decision function
Karar sınırı	:	Decision boundary
Karesel	:	Quadratic
Karesel programlama problemi	:	Quadratic programming problem
Karmaşıklık	:	Complexity
Karşılıklı bilgi	:	Mutual information
Kategorilere ayrılmış	:	Discretized
Kesinlik	:	Specificity
Kısıtlanmış optimizasyon	:	Constrained optimization
Merkez noktası	:	Origin
Olasılı sinir ağları	:	Probabilistic neural network

Öznitelik seçimi	:	Feature selection
Seçim ağacı	:	Decision tree
Spektral entropi	:	Spectral entropy
Taşıma fonksiyonu	:	Mapping function
Uzay	:	Domain
Yaklaşık entropi	:	Approximate entropy
Yaklaşıklık katsayıları	:	Approximation coefficients
Yanlış sınıflandırılan örnek	:	Outlier
Yinelenen sinir ağları	:	Recurrent neural network

ÖZGEÇMİŞ

Ad Soyad: Ercan Avşar

Doğum Yeri ve Tarihi: Adana – 10 Şubat 1985

Lisans Üniversitesi: Çukurova Üniversitesi – Elektrik Elektronik Mühendisliği

Yayın Listesi:

- Avşar, E., Kamaşak, M. E., & Çataltepe, Z., 2009: Tek-Sınıf Destek Vektör Makineleri Kullanılarak EEG İşaretlerinin Sınıflandırılması. *14. Biyomedikal Mühendisliği Ulusal Toplantısı*, 20-24 Mayıs 2009, İzmir, Türkiye