

**EEG SİNYALLERİNİN EPİLEPSİ DURUMUNUN MODEL-TABANLI  
SPEKTRAL ANALİZ TEKNİKLERİ İLE BELİRLENMESİ**

**SABAHAT DURAN**

**YÜKSEK LİSANS TEZİ  
ELEKTRİK VE ELEKTRONİK MÜHENDİSLİĞİ**

**TOBB EKONOMİ VE TEKNOLOJİ ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ**

**EYLÜL 2010  
ANKARA**

Fen Bilimleri Enstitü onayı

---

Prof. Dr. Ünver KAYNAK  
Müdür

Bu tezin Yüksek Lisans derecesinin tüm gereksinimlerini sağladığımı onaylarım.

---

Doç. Dr. Kahraman Güçlü KÖPRÜLÜ  
Anabilim Dalı Başkanı

Sabahat DURAN tarafından hazırlanan EEG SİNYALLERİNİN EPİLEPSİ DURUMUNUN MODEL-TABANLI SPEKTRAL ANALİZ TEKNİKLERİ İLE BELİRLENMESİ adlı bu tezin Yüksek Lisans tezi olarak uygun olduğunu onaylarım.

---

Yrd. Doç. Dr. Ali Cafer GÜRBÜZ  
Tez Danışmanı

Tez Jüri Üyeleri

Başkan : Doç. Dr. Kahraman Güçlü KÖPRÜLÜ \_\_\_\_\_

Üye : Yrd. Doç. Dr. Ali Cafer GÜRBÜZ \_\_\_\_\_

Üye : Yrd. Doç. Dr.A. Murat ÖZBAYOĞLU \_\_\_\_\_

## **TEZ BİLDİRİMİ**

Tez içindeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edilerek sunulduğunu, ayrıca tez yazım kurallarına uygun olarak hazırlanan bu çalışmada orijinal olmayan her türlü kaynağa eksiksiz atıf yapıldığını bildiririm.

Sabahat DURAN

**Üniversitesi** : TOBB Ekonomi ve Teknoloji Üniversitesi  
**Enstitüsü** : Fen Bilimleri  
**Anabilim Dalı** : Elektrik ve Elektronik Mühendisliği  
**Tez Danışmanı** : Yrd. Doç. Dr. Ali Cafer GÜRBÜZ  
**Tez Türü ve Tarihi** : Yüksek Lisans – Kasım 2010

**SABAHAHAT DURAN**

**EEG SINYALLERİNİN EPİLEPSİ DURUMUNUN MODEL-TABANLI  
SPEKTRAL ANALİZ TEKNİKLERİ İLE BELİRLENMESİ**

**ÖZET**

Elektroensefalografi (EEG), beynin elektriksel aktivitesini yansıtan önemli bir sinyaldir. Birçok beyin hastalığının teşhisinde yararlı bilgiler sağlamaktadır ve teşhisinde önemli olduğu hastalıklardan biri de epilepsi hastalığıdır. Bu tez çalışmasında, sinyallerin spektral analizinde geniş yer alan model tabanlı sinyal işleme yöntemlerinden özbağlımlı yöntem-AR kullanılmıştır. AR yöntemi özellikle dar bantlı olan sinyalleri daha iyi karakterize edebilmesi ve keskin tepelere sahip spektrumları daha iyi tahmin edebilmesi, aynı zamanda doğrusal işlemler içerdiği için kolay hesaplanabilen kestirim yöntemlerine sahip olması sebebiyle sıkça tercih edilen bir yöntemdir. Epilepsi hastası ve hastalıklı olmayan (kontrol) bireylerden alınan EEG sinyalleri AR yöntemi kullanılarak incelenmiştir. Epilepsi hastası olan ve hastalıklı olmayan (kontrol) bireylere ait EEG kayıtlarının güç yoğunluk spektrumlarının kestirimleri Yule-Walker ve Burg yöntemleri kullanılarak hesaplanmıştır. Epileptik ve Epileptik olmayan EEG verilerinin ayrımının yapılabilmesi için öznitelik çıkarmak oldukça önemlidir. Bu amaçla Epileptik ve Epileptik olmayan EEG sinyallerinin öznitelikleri güç yoğunluk spektrumlarından çıkarılmıştır ve öznitelik çıkarılması açısından Yule-Walker ve Burg yöntemlerinin başarısı incelenmiştir. Model tabanlı yöntemlerde güç yoğunluk spektrumunun doğru tahmin edilebilmesi, model derecesinin uygun bir biçimde seçilmesiyle mümkündür. Bu sebeple, kullanılan AR yönteminin model derecesini belirlemek üzere AIC (Akaike's Information Criterion), MDL (Minimum Description Length ), FPE (Akaike's Final Prediction Error), CAT (Parzen's Criterion of Autoregressive Transfer function), BIC (Bayesian Information Criterion) ve KIC (Kullback Information Criterion) yöntemleri kullanılmıştır. Model derecesi belirlemede kullanılan yöntemlerin, Yule-Walker ve Burg yöntemleri için başarısı incelenmiştir. Elde edilen sonuçlara göre model derecesi belirleme ve öznitelik çıkarma başarısının kullanılan EEG verisine bağımlı olarak değiştiği gözlenmiştir. Her EEG veri seti için her bir yöntemin başarısı yorumlanmıştır.

**Anahtar Kelimeler:** Model tabanlı yöntemler, AR yöntemi, EEG, Spektral analiz, Güç yoğunluk spektrumu.

**University** : TOBB Economics and Technology University  
**Institute** : Institute of Natural and Applied Sciences  
**Science Programme** : Electrical and Electronics Engineering  
**Supervisor** : Assistant Professor Dr. Elif Derya ÜBEYLİ  
**Degree Awarded and Date** : M.Sc. – November 2010

**SABAHAT DURAN**

**DETERMINATION OF EPILEPTIC EEG SIGNALS BY MODEL-BASED  
SPECTRAL ANALYSIS TECHNIQUES**

**ABSTRACT**

Electroencephalography (EEG) is a significant signal that represents the electrical activities of the brain. It provides useful information for the diagnosis of many diseases and the major one of these diseases is epilepsy. In this thesis, one of the parametric methods which has a wide variety of application in spectral analysis of signals and is called Autoregressive (AR) method is used. Since AR method characterizes especially narrow band spectrum successfully and it has great performance for estimation of spectrums with sharp peaks and also it has computationally efficient estimation methods, it is one of the most preferred methods for spectral estimation. EEG data of people with epilepsy and without epilepsy are analyzed with AR method. The power spectral densities of epileptic and non-epileptic EEG records are estimated with Yule-Walker and Burg methods. Feature extraction is necessary to detect the difference between epileptic and non-epileptic EEG. For this end, features of EEG data are extracted from the power spectral density estimations and in that respect the performances of Yule-walker and Burg methods are analyzed. In parametric methods, the accurate estimation of power spectral density is possible with the selection of suitable model order. For this reason, AIC (Akaike's Information Criterion), MDL (Minimum Description Length), FPE (Akaike's Final Prediction Error), CAT (Parzen's Criterion of Autoregressive Transfer function), BIC (Bayesian Information Criterion) ve KIC (Kullback Information Criterion) methods are used to determine the AR model order. The performances of these methods are analyzed for Yule-Walker and Burg methods. According to the analysis results, it is understood that the performance of the model order determination and the feature extraction differ with EEG data. The performance of every method is evaluated for every EEG data set.

**Key Words:** Model based methods, AR method, EEG, Spectral analysis, Power spectral estimation.

## TEŐEKKÜR

Çalıřmalarım boyunca deęerli bilgi ve deneyimleriyle bana yol gsteren, yardım ve katkılarıyla beni yndendiren hocam Yrd. Doç. Dr. Ali Cafer Gurbüz'e, yine kıymetli tecrübelerinden faydalandığım TOBB Ekonomi ve Teknoloji Üniversitesi Elektrik ve Elektronik Mühendisliği Bölümü öğretim üyelerine,

Destekleriyle beni hiçbir zaman yalnız bırakmayan ve her türlü zorluęa birlikte göęüs gerdiğim çalışma arkadaşlarım Merve Yasemen TÜRKOęLU, Esmâ GÜL, Ömer ÇAYIRPUNAR, Mirbek TURDUEV, Engin KARATAŐ, Abdel-Razzak MERHEB, Yunus ATAŐ, Salih Burak AKAT ve Murat İlter KÖKSAL'a

Ve bana her zaman güvenen, destekleriyle beni bugünlere getiren aileme teşekkürlerimi sunarım.

## İÇİNDEKİLER

BÖLÜM 1 .....	5
1. GİRİŞ .....	5
1.1 Tezin Konusu ve Taslağı .....	9
BÖLÜM 2 .....	10
2. EEG SİNYALİ .....	10
2.1 EEG Sinyalinin Tarihçesi .....	10
2.2 EEG Sinyalinin Oluşumu ve Ölçümü .....	11
2.3 Epileptik EEG .....	16
2.4 Kullanılan Veri Tabanı .....	18
BÖLÜM 3 .....	20
3. YÖNTEM .....	20
3.1 Model Tabanlı (Parametrik) Yöntemler .....	20
3.1.1 Zaman Serileri .....	25
3.1.2 AR Yöntemi .....	30
3.1.2.1 AR Yönteminin Otokorelasyon Yapısı .....	31
3.1.2.2 AR Parametre Kestirim Yöntemleri .....	34
3.1.2.2.1 Yule-Walker AR Yöntemi .....	34
3.1.2.2.2 Burg AR Yöntemi .....	37
3.1.2.3 AR Model Derecesi Belirleme Yöntemleri .....	41
BÖLÜM 4 .....	43
4. GÜÇ YOĞUNLUK SPEKTRUMLARININ ELDE EDİLMESİ .....	43
4.1 Yule-Walker ve Burg Yöntemi ile Elde Edilen Sonuçlar .....	44
4.1.1 Yule-Walker Yöntemi ile Elde Edilen Sonuçlar .....	45
4.1.2 Burg Yöntemi ile Elde Edilen Sonuçlar .....	56
BÖLÜM 5 .....	65
5. SONUÇ .....	65
5.1 Sonuç .....	65
6. GELECEK ÇALIŞMALAR .....	67
7. MATLAB KODLARI .....	68
KAYNAKLAR .....	79

## ÇİZELGELERİN LİSTESİ

Çizelge 4.1. Yule –Walker Yöntemi Kullanıldığında Tahmin Edilen Model Dereceleri.....	45
Çizelge 4.2. Burg Yöntemi Kullanıldığında Tahmin Edilen Model Dereceleri.....	45
Çizelge 4.3. Yule-Walker Yöntemi ile Elde Edilen Tepe/Frekans Değerleri.....	56
Çizelge 4.4. Burg Yöntemi ile Elde Edilen Tepe/Frekans Değerleri.....	65



## ŞEKİL LİSTESİ

Şekil 2.1.Sinir Hücresi [23] .....	11
Şekil 2.2.Aksiyon Potansiyeli [23] .....	12
Şekil 2.3.Standart 10-20 elektrot yerleşimi [23].....	13
Şekil 2.4.EEG sinyallerinin frekans bantları [23].....	14
Şekil 2.5.Epileptik nöbet sırasındaki EEG kaydı [28] .....	17
Şekil 2.6.Set A, B, C, D ve E'ye ait EEG sinyalleri .....	19
Şekil 3.1.ARMA modeli .....	22
Şekil 3.2.AR Modeli .....	24
Şekil 3.3.3. MA Modeli .....	24
Şekil 3.4.ARMA Yöntemi [30].....	27
Şekil 3.5.AR Yöntemi [30] .....	29
Şekil 3.6.MA metodu [30] .....	30
Şekil 4.1.Set A için Elde Edilen Güç Yoğunluk Spektrumu .....	46
Şekil 4.2. BIC Yöntemine Göre Elde Edilen Güç Yoğunluk Spektrumu.....	47
Şekil 4.3.Set B için Elde Edilen Güç Yoğunluk Spektrumu.....	48
Şekil 4.4.BIC Yöntemine Göre Elde Edilen Güç Yoğunluk Spektrumu.....	49
Şekil 4.5.Set C için Elde Edilen Güç Yoğunluk Spektrumu.....	50
Şekil 4.6. KIC Yöntemine Göre Elde Edilen Güç Yoğunluk Spektrumu.....	51
Şekil 4.7.Set D için Elde Edilen Güç Yoğunluk Spektrumu .....	52
Şekil 4.8.KIC Yöntemine Göre Elde Edilen Güç Yoğunluk Spektrumu.....	53
Şekil 4.9.Set E için Elde Edilen Güç Yoğunluk Spektrumu.....	54
Şekil 4.10.BIC Yöntemine Göre Elde Edilen Güç Yoğunluk Spektrumu.....	55
Şekil 4.11.Set A için Elde Edilen Güç Yoğunluk Spektrumu .....	56
Şekil 4.12.FPE Yöntemine Göre Elde Edilen Güç Yoğunluk Spektrumu.....	57
Şekil 4.13.Set B için Elde Edilen Güç Yoğunluk Spektrumu.....	58
Şekil 4.14.AIC Yöntemine Göre Elde Edilen Güç Yoğunluk Spektrumu.....	59
Şekil 4.15.Set C için Elde Edilen Güç Yoğunluk Spektrumu.....	60
Şekil 4.16.BIC Yöntemine Göre Elde Edilen Güç Yoğunluk Spektrumu .....	61
Şekil 4.17.Set D için Elde Edilen Güç Yoğunluk Spektrumu .....	61
Şekil 4.18.KIC Yöntemine Göre Elde Edilen Güç Yoğunluk Spektrumu.....	62
Şekil 4.19.Set E için Elde Edilen Güç Yoğunluk Spektrumu.....	63
Şekil 4.20.KIC Yöntemine Göre Elde Edilen Güç Yoğunluk Spektrumu.....	64

## KISALTMALAR

- AIC:** Akaike's Information Criterion
- ANOVA:** Analysis of Variance
- AR:** Autoregressive
- ARMA:** Autoregressive Moving Average
- BIC:** Bayes Information Criterion
- CAT:** Parzen's criterion of autoregressive transfer function
- EEG:** Elektroensefalogram
- FIC:** Finite sample Information Criterion
- FPE:** Final Prediction Error
- FSC:** Finite Sample Criterion
- LSF:** Least squares forward
- LSFB:** Least squares forward backward
- MA:** Moving Average
- MDL:** Minimum Description Length
- PAR-COR:** Partial correlation function
- RC:** Reflection coefficient
- RIS:** Rissanen's minimum description method
- SLSA:** Step-wise square estimation algorithm

## BÖLÜM 1

### 1. GİRİŞ

Elektroensefalogram (EEG) beyindeki elektriksel aktivitelerin, Elektroensefalograf adındaki bir cihaz yardımıyla ölçülerek sayısallaştırılmış biçimidir. Bazı hastalıklar beyindeki elektriksel aktivitelerde çeşitli değişikliğe sebep olarak kendini gösterir. Bu tür hastalıkların teşhisinde ve tedavisinde EEG sinyalinin analizi, önemli ve sıkça başvurulan yöntemlerden biridir.

Bu hastalıklardan yaygın olarak karşılaşılanlardan biri de epilepsi hastalığıdır. Tam olarak sebebi anlaşılamayan biçimlerde oluşan nöbetlerle kendini gösterir ve hastalığın kesin bir tedavisi mevcut değildir. Epilepsi hastalığının teşhisi ile ilgili olarak, birçok yöntem kullanılarak EEG sinyalinin analizleri gerçekleştirilmiştir. Epileptik EEG verisinde, nöbet sırasında meydana gelen değişikliklerin tespiti önemli bir bilgidir. [1] çalışmasında Epilepsi hastalarından alınan EEG verilerinin analizi ile Epileptik nöbetin tespit edilmesi üzerine çalışılmıştır. Nöbet öncesi, nöbet sırası ve nöbet sonrası EEG verileri için “Bhattacharyya uzaklık ölçümü” yöntemi kullanılmıştır. Hesaplanan uzaklık ölçüm değerleri ANOVA testi kullanılarak birbiriyle kıyaslanmıştır, sonuç olarak nöbet sırasındaki değerlerin, nöbet öncesi ve nöbet sonrası değerlerden daha yüksek çıktığı gözlenmiştir. [2]’de ise yine hastalıklı EEG verileri kullanılarak, çevrimiçi ve uyarlamalı bir yöntem uygulanmıştır. Bu yöntem ile nöbet sırasındaki anormallikler ve bu anormalliklerin oluşma zamanı tespit edilebilmiştir. Geliştirilecek bazı uygulamalarla beraber Epileptik nöbetin önlenmesinde yararlı olabilecek bir çalışma gerçekleştirmişlerdir.

Hastalıklı ve sağlıklı bireylerin EEG verileri göz ile analiz edildiğinde, hastalıklının sağlıklıdan ayrılması kolay değildir. Bu sebeple birçok çalışmada sağlıklı ve hastalıklı bireylerin EEG verileri analiz edilerek, belirgin farklar elde edilmeye çalışılmıştır. [4] çalışmasında Epileptik ve Epileptik olmayan EEG verisinin Delay Vector Variance (DVV) yöntemi kullanılarak doğrusal olmama derecesi (degree of nonlinearity) belirlenmiştir. Yaptıkları çalışma neticesinde, Epileptik verinin karakterize

edilmesinde doğrusal olmama derecesinin oldukça yararlı bir bilgi olduğu ve Epileptik verinin Epileptik olmayana göre daha yüksek doğrusal olmama derecesine sahip olduğu gözlenmiştir. Epilepsinin tespitinde Dalgacık analizi yöntemi de sıkça kullanılan yöntemlerden biridir. [3] çalışmasında, Epileptik olan ve Epileptik olmayan sivri uçlu yapıların tespitini yapabilmek için öncelikle EEG sinyalinin Dalgacık analizi gerçekleştirilmiştir. Daha sonra sinyallerin öznitelik çıkarılmıştır ve çıkarılan özniteliklere göre, epileptik ve epileptik olmayan sivri uçlu yapıların ayrımı yapay sinir ağları yöntemini kullanarak yüksek başarıyla elde edilmiştir. Yine [5] çalışmasında da sağlıklı ve Epileptik EEG sinyallerinin ayrımının yapılmasında Dalgacık analizinden yararlanılmıştır. Ayrıca Dalgacık analizi yöntemi, Fourier dönüşümü ile performans olarak kıyaslanmıştır. Sonuç olarak, EEG verisinin periyodik olmayışı sebebiyle, periyodik sinyallerin analizinde başarılı olan Fourier yönteminin, düşük frekans bileşenlerini tespit etme açısından Dalgacık dönüşümü kadar başarılı olmadığı görülmüştür.

Diğer birçok yöntem gibi parametrik yöntemler de Epileptik EEG'nin tespitinde geniş bir kullanım alanına sahiptir. Öz bağımlı (AR) yöntem, diğer parametrik yöntemlere göre işlem kolaylığı ve sinyallerin tepelerini belirginleştirilmesi gibi avantajları sebebiyle sıkça tercih edilen parametrik yöntemlerden biridir. Fourier tabanlı yöntemler gürültüye karşı oldukça hassastır ve pencereleme uygulanırsa sızıntılar görülür. AR yöntemi, Fourier tabanlı yöntemlere göre daha iyi frekans çözünürlüğü sağlar ve pencerelemeden kaynaklanan sorunu ortadan kaldırır. Ayrıca Dalgacık dönüşümü tekniklerine göre, gerçek zamanlı uygulamalarda AR yöntemi daha hızlıdır [7]. [7] çalışması da sağlıklı ve epileptik EEG verilerinin güç yoğunluk spektrumları FFT dönüşümü (Welch yöntemi) ve AR yöntemi (Yule-Walker ve Burg yöntemi) kullanılarak hesaplanmıştır. ANOVA testi uygulanarak, AR yönteminin, FFT tabanlı yöntemlere göre daha iyi bir performansa sahip olduğu gösterilmiştir. [6] çalışmasında, sinyalin tahmini için AR yöntemine başvurulmuştur. Hastalıklı ve sağlıklı bireylerin EEG sinyallerine ait AR katsayılarının ortalama kareköklerinin ortalaması alınarak karşılaştırılmıştır ve birbirinden ayırıcı bir biçimde farklı olduğu gözlenmiştir.

AR yönteminin başarılı bir biçimde sinyalleri modelleyebilmesi için, model derecesinin uygun bir biçimde seçilmesi çok önemlidir. Düşük model dereceleri oldukça düz bir güç yoğunluk spektrum oluşmasına sebep olur ve sinyali başarılı bir biçimde modelleyemez. Bu şekildeki güç yoğunluk spektrumundan gerekli öznitelikler çıkarılamaz. Yüksek model derecesi ise, güç yoğunluk spektrumunda aslında sinyalin orijinalinde var olmayan yanıltıcı tepelerin oluşmasına sebep olur. Böyle bir güç yoğunluk spektrumundan elde edilecek öznitelikler oldukça yanıltıcı olabilir ve doğru bilgi vermez. Bu sebeple AR yönteminin model derecesini belirleme üzerine birçok alanda çeşitli uygulamalar ve yöntemler mevcuttur [14-16]. [8] çalışmasında Doppler radarında bulunan istenmeyen karmaşık ekoların bastırılması için AR yöntemi uygulanmıştır. AR yöntemi ile tahmin edilen modelin yansıma katsayıları kullanılarak kafes tahmin hatası filtresi (ing: Lattice prediction error filter) geliştirilmiştir. Filtrenin derecesini belirlemek amacıyla FPE, AIC, CAT, ve MDL yöntemleri kullanılmıştır. Eğer filtre aynı taramada elde edilen veri için kullanılırsa, model derecesi belirleme yöntemlerinin başarısız olduğu gözlemlenmiştir. Ancak filtre bir sonraki taramada elde edilen veri için kullanıldığında AIC ve MDL yöntemleri model derecesini yüksek tahmin ederken, FPE ve CAT yöntemlerinin başarılı olduğu gözlemlenmiştir. [9] çalışmasında ise akciğer sesinin modellenmesinde LSFB ile tahmin edilen AR modeli kullanılmıştır. Model derecesini belirlemek üzere FPE, PAR-COR, AIC, MDL, BIC, FSC ve FIC yöntemleri test edilmiştir. İçlerinde FIC yöntemi en iyi model derecesini vermiştir. [10] çalışmasında ise kalp atış hızı değişkenliği (ing: Heart rate variability) AR yöntemi ile modellenmiştir ve model derecesi belirleme problemi ele alınmıştır. Bu amaçla kullanılan FPE, AIC, CAT ve RIS yöntemleri kısa ve daha uzun sinyal verisi için kıyaslanmıştır. RIS diğer yöntemlere göre daha düşük model derecesi vermiştir. Uzun sinyal verisi için FPE, CAT ve AIC iyi sonuç verirken, kısa sinyal verisi için birbiriyle aynı ve doğru model derecesinden daha düşük değerler üretmişlerdir.

Az sayıda örnekleme sahip sinyaller için, yaygın kullanıma sahip model derecesi belirleme yöntemlerinden bazılarının başarısız sonuçlar vermesi sebebiyle bu yöntemlerde bazı değişiklikler yapılarak, kısa veriler için de başarılı sonuçlar veren

model derecesi belirleme yöntemleri geliştirilmiştir. Kısa sinyal verilerinin kullanıldığı durumlara, sınırlı örnekleme durumu (ing: Finite sample case) da denmektedir. [11] çalışmasında Karimi tarafından AIC yöntemi değiştirilerek AICF yöntemi geliştirilmiştir. Bu yöntemin başarısı, sınırlı örnekleme durumu için tahmin hatasını küçültmesi açısından LSF AR yöntemi uygulanarak değerlendirilmiştir ve AIC yöntemine göre daha başarılı bulunmuştur. [12] çalışmasında ise Karimi [11]'deki uygulamanın benzerini FPE yöntemi için gerçekleştirmiştir ve FPEF yöntemini geliştirmiştir. [13] çalışmasında ise yine tahmin etme hatası açısından [11] ve [12]'de geliştirilmiş AICF ve FPEF yöntemlerinin başarısı sınırlı örnekleme durumu için incelenmiştir. Bu çalışmada ise LSF AR yerine LSF AR kullanılmıştır ve iki yöntemin de sınırlı örnekleme için başarılı sonuçlar ürettiği gözlenmiştir.

AR yönteminin model derecesinin belirlenmesi problemi çeşitli EEG uygulamalarında da ele alınmıştır. [17] çalışmasında beyin-bilgisayar ara yüzünü (ing: Brain-computer interface) kontrol etmek için EEG'den yararlanılmıştır ve EEG'nin modellendiği AR yönteminin model derecesi için  $r^2$  ve AIC yöntemlerinin başarıları analiz edilmiştir ve  $r^2$  yöntemi daha başarılı bulunmuştur. [18] çalışmasında ise [17] çalışması geliştirilerek, gürültü tarafından bastırılmış düşük frekans bileşenlerinin analizi için daha yüksek model derecelerinin gerekli olduğu belirtilmiştir. [19] çalışmasında AIC, FPE ve CAT yöntemleri EEG sinyalinin AR model derecesini belirlemedeki başarıları açısından incelenmişlerdir, genel olarak benzer fakat doğru olmayan sonuçlar verdikleri gözlenmiştir. Literatürde genelde 5-12 arasında belirtilen model derecesinin, spektral tepe değerlerinin ve onların frekanslarının belirlenmesi gereken durumlar için düşük olduğu ve daha yüksek model derecelerinin kullanılması gerektiği belirtilmiştir. [20] çalışmasında AIC, FPE ve RC yöntemleri kıyaslanmıştır ve iki zihinsel görevi yerine getiren bireylerin EEG sinyalleri yapay sinir ağlarıyla sınıflandırılmıştır. Sınıflandırma başarısına göre model derecesi belirleme yöntemlerinin başarıları değerlendirilmiştir. FPE ve AIC yöntemlerinin genelde benzer sonuç verdiği, RC yönteminin ise diğer yöntemlere göre uygun olan en düşük model derecesini verdiği belirlenmiştir. [21] çalışmasında ise [20] çalışmasındaki yöntemlere ek olarak genetik algoritma ile bulanık yöntemi

birleştiren bir model derecesi belirleme yöntemi geliştirilmiştir. Geliştirilen bu yöntemin diğer yöntemlere göre daha başarılı olduğu gözlenmiştir.

[22] çalışmasında ise Epileptik EEG ve sağlıklı EEG verileri Burg AR yöntemi ile modellenmiştir ve model derecesi belirleme problemi üzerinde durulmuştur. Bu amaçla FPE, AIC, CAT, MDL ve MATLAB'daki ARfit birimi tarafından uygulanan SLSA yöntemleri kıyaslanmıştır. Sonuç olarak SLSA yönteminin diğer yöntemlere göre model derecesini tahmin etme açısından daha başarılı olduğu belirtilmiştir.

## **1.1 Tezin Konusu ve Taslağı**

Bu tez çalışmasında [29] çalışmasındaki veri tabanından elde edilen EEG güç yoğunluk spektrumları Yule-walker ve Burg AR yöntemleri kullanılarak incelenmiştir ve AR yöntemi için çeşitli model derecesi belirleme yöntemleri uygulanmış ve başarıları değerlendirilmiştir. Bölüm 2'de EEG sinyalinin tarihçesinden, oluşumundan, genel yapısından ve epilepsi hastalığının EEG verisi üzerindeki etkisinden bahsedilmektedir. Ayrıca analizlerde kullanılan veri tabanı anlatılmaktadır. Bölüm 3'te genel olarak model tabalı yöntemler anlatılmaktadır ve AR yöntemi üzerinde durulmaktadır. Yule-Walker ve Burg yöntemleri anlatılmaktadır ve model derecesi belirleme yöntemlerinden bahsedilmektedir. Bölüm 4'te bu yöntemlere göre elde edilen güç yoğunluk spektrumları grafiklerine yorumlarına yer verilmektedir. Bölüm 5'te ise çalışmanın kısa bir özetine yer verilerek tez çalışması sonuçlandırılmıştır.

## BÖLÜM 2

### 2. EEG SİNYALİ

#### 2.1 EEG Sinyalinin Tarihçesi

Beyin aktivitesi ilk olarak Richard Caton tarafından 1875 yılında insan kafatasına yerleştirilen iki elektrot ve galvanometre yardımıyla elektriksel olarak kaydedilmiştir. Daha sonra beynin elektriksel aktivitelerini belirtmek için Elektroensefalografi (EEG) terimi kullanılmaya başlanmıştır. Bu terim, beynin elektriksel aktivitelerinin kaydını, kafatasından sinyal yayılımını ve çizme ya da yazmayı ifade eden anlamları içerisinde barındırmaktadır [23].

İnsana ait EEG sinyallerinin varlığını keşfeden kişi Hans Berger'dir. 1920 tarihinde insan EEG verisi üzerinde çalışmalarına başlamıştır. İlk defa 1929 yılında fotoğrafik bir kâğıda insan EEG verisinin kaydını raporlamıştır [23].

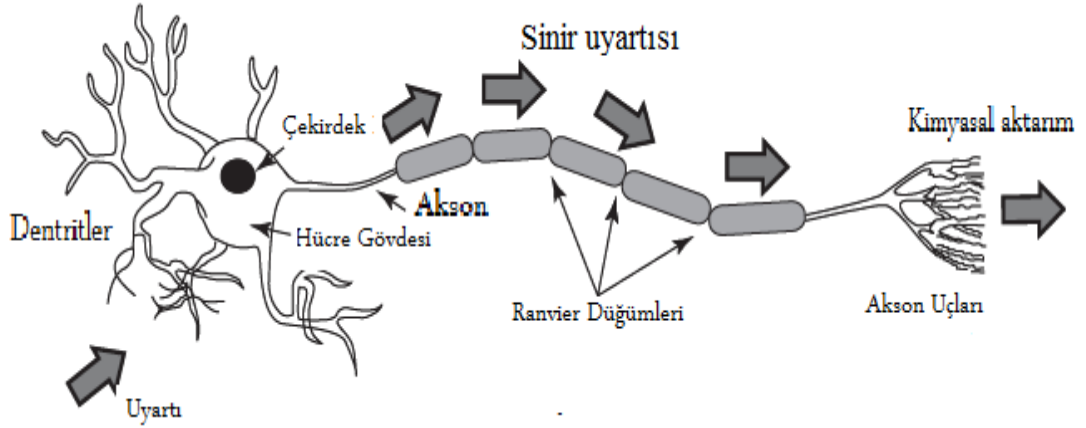
Toennies beyindeki elektriksel potansiyellerin kaydında kullanılmak üzere ilk biyolojik yükselticiyi geliştirmiştir. 1932'de ise Rockefeller tarafından diferansiyel bir yükseltici üretilmiştir [23].

Kornmüller daha geniş beyin bölgelerinin dahil edilmesi için daha fazla sayıda elektrot kullanılmasının ve çok kanallı kayıt yapılmasının ne derece önemli olduğunu ilk fark eden kişi olmuştur. Epileptik dikensi yapıların (ing: spike) gösterimi Fisher ve Löwenbach tarafından gerçekleştirilmiştir [23].




## 2.2 EEG Sinyalinin Oluşumu ve Ölçümü

Sinir hücrelerinde bilgi iletimi elektriksel potansiyeller ile sağlanır. Bu elektriksel potansiyellere aksiyon potansiyeli adı verilir. Hücre zarındaki iyon geçişleri ile aksiyon potansiyeli oluşur. İyon geçişlerinin başlaması için dışarıdan bir uyarı gelmesi gereklidir. Eğer uyarı eşik seviyesinin üstünde bir değere ulaşır, ancak o zaman hücre zarında iyon geçişlerine sebebiyet verebilir.



Şekil 2.1.Sinir Hücresi [23]

Şekil 2.1’de insandaki sinir hücrelerinin genel yapısı gösterilmiştir. Hücrede oluşan uyarı dentritlerden başlayarak, hücre gövdesi, akson, Ranvier düğümleri ve akson uçlarına doğru ilerler.




Şekil 2.2.Aksiyon Potansiyeli [23]

Şekil 2.2’de sinir hücresinin uyarıldığı durumdaki genlik değişimi zamana göre görülebilmektedir. Şekilde görüldüğü gibi hücre normalde negatif yüklüdür ve yaklaşık -70 mV genliğine sahiptir. Hücrenin dentritleri uyarıldığı zaman, yeteri kadar uyartı oluşturulduğu takdirde (eşik seviyesini aşacak kadar uyartı olduğu durumda), hücre içi iyonlarında bir geçiş söz konusu olur. Öncelikle Na kapıları açılır ve hücre negatif durumunda pozitif hale geçmeye başlar, bu sürece depolarizasyon denir. Daha sonra ise K kapıları açılır fakat Na’ya göre daha yavaş açıldığından bir süre sonra ikisi de açık olur ve bu herhangi bir başka aksiyon potansiyelinin oluşumunu engeller. Daha sonra ise hücre negatif duruma geçmeye başlar, dinlenir durumda olduğu halden daha negatif bir hale geçer (yaklaşık -90 mV’a kadar düşer), fakat kısa süre sonra dinlenme durumundaki potansiyeline yeniden kavuşur.

EEG sinyali ise, serebral korteksteki sinir hücrelerinde uyartı oluştuğunda oluşan potansiyel farktan dolayı dentritlerde oluşan akımı ifade eder. Akan bu akım kafatasında elektriksel bir alan oluşturarak, EEG cihazıyla ölçülebilir hale gelir. EEG ölçümü kafatasına yerleştirilen elektrotlar sayesinde elde edilebilir.

EEG ölçümü genelde kafatasında saçlı deriye yerleştirilen elektrotlar yardımıyla yapılır. Bu ölçüm sırasında kişi acı hissetmez ve vücuduna elektrik verilmez. Elektriksel potansiyeller, beyindeki sinir hücrelerinde gerçekleşen elektriksel aktivitelerin bir toplamı şeklinde ve yükseltilecek elektrotlar tarafından algılanır. Elektrotlar genelde 10-20 sistemine göre kafatasına yerleştirilirler. Elektrotlar beyin sağ lobuna ve sol lobuna yerleştirilirler. Sağ lobuna çift sayı ile ifade edilenler, sol lobuna ise tek sayı ile ifade edilenler yerleştirilir. Elektrot yerleşimi hemisferler arası kıyaslamının sağlıklı olması için her iki loba da simetrik olarak yerleştirilirler [24].




Şekil 2.3. Standart 10-20 elektrot yerleşimi [23]

Şekil 2.3’de standart 10-20 elektrot yerleşiminin kafatası üzerinde görsel olarak anlatımı belirtilmiştir. “Nasyon” burun kısmını simgelerken, “İnyon” ise kafatasının arkasını belirtmektedir. Burada görülmeyen ve A1 ve A2 olarak belirtilen elektrotlar

sırasıyla sol kulak ve sağ kulağa yerleştirilirler ve referans elektrotları olarak kullanılırlar. Elektrotların isimlerindeki harflerin yerleştirilen yere göre anlamları vardır. “F” ön kısım loblarını, “Fp” beynin alın lobunun önünde olan kısmı, “T” şakağa ait olan lobları, “C” merkezi lobları, “P” kafatası yan kemiği loblarını, “O” kafanın arka kısmına ait lobları belirtir [23,25].

EEG sinyalleri genelde anlaşılması zor sinyallerdir, oldukça karmaşık bir görünüme sahiptirler, bu sebeple analiz teknikleri ile incelenmeleri gerekir. Genelde EEG sinyallerinin genliği tepeden tepeye 1-100  $\mu$ V ve frekans bandı ise 0.5-100 Hz'dir [23]. Diken şeklinde görülen, durağan ve periyodik olmayan, düzensiz sinyallerdir.

EEG sinyalleri içerdikleri frekans bantlarına göre değerlendirilirler. EEG sinyalleri beş ana frekans bileşenine ayrılmıştır, bunlar: delta ( $\delta$ ), teta ( $\theta$ ), alfa ( $\alpha$ ), beta ( $\beta$ ) ve gama ( $\gamma$ ) bantlarıdır.



Şekil 2.4.EEG sinyallerinin frekans bantları [23]

Şekil 2.4'te verilen grafikte EEG sinyallerinin frekans bantlarına göre nasıl şekillendiği gözlenmektedir. Sinyallerin zaman alanındaki genlik değişimleri rahatça izlenebilmektedir.

Delta bandı: 0.5–4 Hz aralığında görülür. Genelde derin uykuda görülür, bazı durumlarda uyanma esnasında da görülebilmektedir. Genlikleri, 100 uV (p-p)'den küçüktür [23].

Teta bandı: 4–7.5 Hz aralığından gözlemlenir. Genelde bilincin uyuşukluğa doğru kaydığı durumlarda ortaya çıkar. Bilinçsiz durumlar, yaratıcı ilham ve derin meditasyonla ilgili dalgalarıdır [23].

Alfa bandı: 8–13 Hz aralığında gözlenirler. Genelde yuvarlak ya da sinüzoidal sinyaller şeklindedir. Nadir durumlarda keskin dalgalar şeklinde de görülebilir. Dikkat ya da konsantrasyon olmadan var olan sakin farkındalığı belirtir. Gözlerin açılması, yabancı bir ses duyulması, endişe, zihinsel konsantrasyon ya da dikkat durumlarında azalır [23].

Beta bandı: 14–26 Hz frekans aralığında bulunurlar Genelde aktif düşünme, konsantrasyon, odaklanma ya da somut problemler çözerken ortaya çıkan sinyallerdir [23].

Gama bandı: 30 Hz değerinin üstündeki frekansları içerir (genelde 45 Hz'e kadar) . Düşük genliklidir ve nadiren ortaya çıkarlar. Bazı beyin hastalıklarının tespitinde önemli rol oynarlar [23].

### 2.3 Epileptik EEG


EEG sinyali çeşitli sinirsel hastalıkların ya da sinirsel anormalliklerin anlaşılmasında oldukça yararlı bilgiler sunmaktadır. Bunama hastalığının etkilerini gözlemlemek için EEG verisinden yararlanılabilir. Bunama hastalıklarından sıkça karşılaşılanlardan biri de Alzheimer hastalığıdır. Alzheimer hastalığında ya da psikolojik bozukluklardan “bilinç bozukluğu ile beraber olan depresyon” gibi hastalıklarda ortaya çıkan anormalliklerin tespit edilmesinde EEG yararlı bir kaynaktır [23]. Koma, beyin ölümü ve ensofalopati durumlarının teşhisinde kullanılmaktadır. Karotis (şah damarına ait) endarterektomide (Bir atardamarda bulunan aterom plağının cerrahi yöntemle çıkarılması) serebral perfüzyonun (bir çözeltinin damar yoluyla kana akıtılması) direkt olmayan bir göstergesi olabilir. Wada testi (hangi serebral fonksiyonun hangi beyin yarı küresinde bulunduğunu anlamak için yapılan test) sırasında amobarbital (bir çeşit yatıştırıcı ve uyuşturucu) etkiyi izlemeye yarayabilir [26].

EEG'nin, tanısı, izlenmesi ve tedavisinde sıkça kullanıldığı sinirsel rahatsızlıklardan biri de halk arasında “Sara” olarak da bilinen “Epilepsi” hastalığıdır. Sinir hücrelerinde sebepsiz ve anormal elektriksel deşarj durumu oluşur ve bu sırada hastanın bilinci kaybolur. Bu elektriksel bozukluk epileptik nöbetin oluşumuna sebep olur. Nöbet sırasında hasta boğulma, trafik kazası geçirme gibi tehlikelerle karşı karşıyadır, bu sebeple epilepsinin tedavisi oldukça önemlidir. Epilepsi genelde çocuk yaşta ortaya çıkar ya da 65 yaş üstü bireylerde görülür, nadir de olsa farklı durumlarda da ortaya çıktığı bilinmektedir. Bazen çocuk yaşta oluşan epilepsi belirli bir yaşa gelindiğinde kendiliğinden ortadan kaybolabilir. Hastalığın tedavisi ilaçlarla kontrol edilmesi şeklinde gerçekleştirilir, tamamen yok edilmesi henüz mümkün değildir [27]. Epilepsi hastalığının neredeyse 40'tan fazla çeşidi vardır [26]. Epileptik sinyalin morfolojisi çeşidine ve yaşa göre değişmektedir.

Epileptik nöbetler, senkronize osilasyonların nöbetsel oluşumu ile karakterize edilebilirler. Bu çeşit nöbetler beyindeki bölgeleri kapsama alanına göre iki çeşittir. Bunlardan bir tanesi genellenmiş nöbettir, bu nöbetler beyindeki çoğu alanı kapsar.

Diğer nöbet çeşidi ise fokal nöbetlerdir ve sınırlandırılmış bir alanda meydana gelirler. Genellenmiş nöbetler çıplak gözle teşhis edilebilirken, fokal nöbetlerin teşhisi daha karmaşıktır [23].

Epileptik nöbetler genelde belirgin diken şeklinde ve ritmik sinyallerdir, epileptik olmayan nöbetler ise genelde gürültü şeklindeki sinyaller olarak kendini göstermektedir. Genelde nöbet sırasında, sinyalin diken şeklinde ve daha yüksek genlikli olduğu görülmüştür.



Şekil 2.5.Epileptik nöbet sırasındaki EEG kaydı [28]


Şekil 2.5'te EEG sinyalinde nöbet sırasındaki değişiklikler zaman alanında görülebilmektedir. 3 Hz frekansında diken şeklindeki bir sinyal aniden ortaya çıkmaktadır ve birkaç saniye sonra ortadan kaybolmaktadır. [28]

## 2.4 Kullanılan Veri Tabanı

Bu tez çalışmasında yapılan spektral analizler [29] çalışmasındaki EEG veri tabanı kullanılarak gerçekleştirilmiştir. Kullanılan veri tabanı A, B, C, D ve E olmak üzere 5 veri setinden oluşmaktadır. Her bir set 23.6 saniyelik, 100 tek-kanallı ölçümlerle kaydedilmiş EEG parçalarını içerir. Her bir EEG parçası durağanlık kriterini taşımaktadır. Her bir sette 5 kişiye ait EEG verisi vardır ve her bir kişiden 20 adet ölçüm alınmıştır. Set A ve Set B, standart 10-20 sistemine göre yerleştirilen yüzeysel elektrotlar yardımıyla ölçülen EEG sinyallerini içerirler. Set A, sağlıklı kişilerden uyanık durumda gözleri açıkken ve Set B yine aynı kişilerden uyanık durumda gözleri kapalıyken alınan EEG verisini içerir. Set C ve Set D ise derin elektrotlar kullanılarak kontrol altındaki epilepsi hastalarından alınan ve nöbet olmayan durumda kaydedilen EEG verisine sahiptir. Set D verisi epileptik bölgeden alınarak kaydedilmiştir ve Set C ise beynin diğer lobunun hippocampusla ilgili dizilim (ing: hippocampal formation) kısmından alınan ölçümlerle kaydedilmiştir. Set E ise epilepsi hastalarından alınan ve nöbet sırasında kaydedilen EEG verisini içerir. Set E verisi kaydedilirken strip elektrotlar kullanılmıştır. Tüm EEG kayıtları için aynı 128-kanallı yükseltici sistem ve ortalama ortak bir referans kullanılarak gerçekleştirilmiştir. Daha sonra ölçülen veri, 12 bitlik analog-dijital çeviriciden geçirilerek, 173.61 Hz frekansında örneklenecek veri toplama bilgisayarına kaydedilmiştir. Bant geçiren filtre ise 0.53-40 Hz ayarındadır.

Zaman serilerinin başlangıç ve bitişi arasındaki süreksizlik, aldatıcı frekans bileşenlerinin oluşumuna sebep olduğu için öncelikle kayıtlardan 4396 adet örneklem seçilmiştir. Daha sonra bu uzun veri içerisinde, seçilen örneklemelerin başlangıç ve bitişinde bulunan veri noktalarının genlikleri arasındaki fark, ardışık veri noktalarının genlik farkı aralığında olacak şekilde  $N=4096$  örneklem seçilmiştir. Aynı zamanda örnekler seçilirken, zaman serilerinin başlangıç ve bitişindeki eğimlerin aynı işaretlere sahip olmasına dikkat edilmiştir. Bu yöntemle, güç yoğunluk spektrumunun hesaplanması sırasında pencere fonksiyonunun kullanımı önlenmektedir.





Şekil 2.6.Set A, B, C, D ve E'ye ait EEG sinyalleri

Şekil 2.6'da [29] çalışmasındaki veri tabanından alınan EEG verilerinin zaman alanındaki grafikleri görülebilmektedir. Grafikteki ilk satır, Set A ve diğer satırlar sırasıyla, Set B, Set C, Set D ve Set E verilerinin zamanla değişimini göstermektedir. Grafikten de görülebileceği gibi, Set E'deki EEG (epileptik nöbet sırasındaki EEG) verisinin genliği, diğer EEG verilerine göre oldukça yüksektir ve dikensi bir yapıdadır.

## BÖLÜM 3

### 3. YÖNTEM

#### 3.1 Model Tabanlı (Parametrik) Yöntemler

Sinyallerin periyodikliğini belirlemek için sinyalin güç yoğunluk spektrumundan faydalanılabilir. Güç yoğunluk spektrumu, sinyalin frekans alanındaki içeriğini karakterize eder. Elimizde sonsuz uzunlukta veri olmadığı için, yalnızca veriden alınan sınırlı sayıdaki örneklem kullanılarak güç yoğunluk spektrumu hesaplanamaz. Bu sebeple, güç yoğunluk spektrumunun kestirimi (tahmini) yapılmalıdır.

Sinyalin spektral kestirimini elde etmek için kullanılan yöntemleri “Parametrik” ve “Parametrik olmayan” yöntemler olarak iki gruba ayırabiliriz. Parametrik olmayan yöntemler, Fourier tabanlı yöntemlerdir. Bu yöntemlerin frekans çözünürlüğü kullanılan verinin uzunluğuna bağlıdır. İyi bir frekans çözünürlüğü ancak yeteri kadar uzun veri kullanıldığı zaman elde edilebilir. Aynı zamanda Fourier tabanlı yöntemlerin karşılaştığı başka bir sorun ise, pencerelemeden kaynaklanan spektral sızıntılardır [30,31]. Parametrik yöntemler kısa veriler için parametrik olmayan yöntemlere göre daha yüksek frekans çözünürlüğü sağlamaktadır. Aynı zamanda, parametrik olmayan yöntemlerde pencerelemeden kaynaklanan spektral sızıntılar, parametrik yöntemlerin kullanımıyla giderilmiş olur [30]. Hiçbir yöntem için, en iyi yöntem ifadesi kullanılamaz, kullanılan uygulamaya göre, istenen performans ve özelliklere göre kullanılacak yöntem değişebilir.

Parametrik yöntemler, model tabanlı yöntemler olarak da adlandırılmaktadır. Model tabanlı olarak adlandırılmalarının sebebi, sinyalin belirli bir model oluşturularak ifade edilmesidir. Veri, rasyonel transfer fonksiyonuna sahip bir filtrenin çıkışı olarak modellenir. Böylece veri ve verinin güç yoğunluk spektrumu da rasyonel bir şekilde ifade edilmiş olur. Sinyalin güç yoğunluk spektrumunun kestirimi 3 adımdan oluşur:

- Model Seçimi
- Model Parametrelerinin Kestirimi
- Güç Yoğunluk Spektrumunun Kestirimi

Model tabanlı yöntemler, AR (Öz-bağlı), MA(yürüyen ortalama), ARMA(Öz-bağlı yürüyen ortalama) modelleri olmak üzere, üç farklı modele sahiptir. AR modeli keskin tepeleri olan fakat derin çukurları olmayan spektrumlar için, MA modeli derin çukurları olan fakat keskin tepeleri olmayan spektrumlar için, ARMA modeli ise, keskin tepeleri ve derin çukurları olan spektrumlar için uygundur. Bir model belirlerken, optimum çözümü veren en düşük sayıda parametreye sahip model tercih edilmelidir. Model parametresinin az olması işlem kolaylığı sağlar. [30]

Spektral kestirimin yapılabilmesi için, elimizdeki verinin durağan olması gereklidir. Verinin durağan olması,  $x[n]$ ,  $n = 0,1,2...N$  zaman serisi verisinin istatistiksel özelliklerinin  $n$ 'e bağlı olarak değişmediğini ifade eder. [32]

Model tabanlı yöntemlerde veri, girişi beyaz Gauss gürültüsü ( $w(n)$ ) olan nedensel, sıfır-kutup, ayrık filtrenin çıkışı olarak modellenir. Filtrenin nedensel olabilmesi için,  $z$ - alanında transfer fonksiyonunun kutupları birim çember içerisinde yer almalıdır.


Beyaz Gauss gürültüsü düz bir güç yoğunluk spektrumuna sahip rastgele bir sinyaldir. Beyaz Gauss gürültüsünün ortalaması sıfırdır ve varyans değeri ise  $\sigma^2$  'ye eşittir. Modelin çıkışı olan veri, rastgele bir sinyal olarak modellenir ve bu rastgelelik, girişteki beyaz Gauss gürültüsü ile sağlanır. [33]

Parametrik yöntemlerde filtrenin transfer fonksiyonu rasyoneldir ve bu sebeple sürekli güç yoğunluk spektrumları rasyonel olarak yazılabilir [34]:

$$P(f) = \frac{\sum_{k=-m}^m \gamma_k e^{-j2\pi f k}}{\sum_{k=-p}^p \rho_k e^{-j2\pi f k}} \quad (3.1)$$

burada  $P(f)$  güç yoğunluk spektrumu,  $\gamma_{-k} = \gamma_k^*$  ( $\gamma_k$  'nın kompleks eşleniği) ve  $\rho_{-k} = \rho_k^*$  ( $\rho_k$  'nın kompleks eşleniği) katsayılarıdır.  $m$  ve  $p$  değerleri modelin derecesini belirtir. Spektral kestirim yapılırken denklem (3.1)'deki model kullanılarak işlem yapılmaktadır. Weierstrass teoremine göre, güç yoğunluk spektrumunun rasyonel bir biçimde ifade edilebilmesi için, denklem (3.1)'deki  $m$  ve  $p$  dereceleri yeterli büyüklükte seçilmelidir. [34]

$P(f)$  , varyansı  $\sigma^2$  olan beyaz Gauss gürültüsünün transfer fonksiyonu  $H(f) = B(f)/A(f)$  olan rasyonel filtreden geçirilmesi ile elde edilen işaretin güç yoğunluk spektrumu olarak ifade edilebilir.



Şekil 3.1.ARMA modeli

Şekil 3.1'de ARMA yönteminde kullanılan model gösterilmektedir. Burada filtrenin girişi olan  $w[n]$ ,  $\sigma^2$  varyansına sahip beyaz Gauss gürültüsüdür.  $x[n]$  filtrenin çıktısı olarak modellenen ve spektral kestirimi yapılacak olan veridir.  $H(f) = B(f)/A(f)$  ise filtrenin transfer fonksiyonudur.

Spektral faktörlerine ayırma teoremine göre denklem (3.1)'deki rasyonel güç yoğunluk spektrumu şu şekilde yazılabilir:

$$P(f) = \left| \frac{B(f)}{A(f)} \right|^2 \sigma^2, \quad (3.2)$$

$A(f)$  ve  $B(f)$  polinomlarının ifadeleri aşağıdaki denklem (3.3) ve (3.4)'te belirtilmiştir.


$$A(f) = 1 + a_1 e^{-j2\pi f} + \dots + a_p e^{-j2\pi fp}, \quad (3.3)$$

$$B(f) = 1 + b_1 e^{-j2\pi f} + \dots + b_m e^{-j2\pi fm}, \quad (3.4)$$

$a_1, a_2, \dots, a_p$  ve  $b_1, b_2, \dots, b_m$  modelin katsayılarını belirtir. Rasyonel güç yoğunluk spektrumunun spektral faktörlerine ayrılmış şeklinin çözümlerinden biri ARMA metodudur. Hem  $a$  hem de  $b$  katsayıları sıfırdan farklı olan (sıfır-kutup) filtrenin kullanıldığı modellere ARMA modeli denir. ARMA modeli, AR ve MA modellerinin bir birleşimi olarak düşünülebilir. AR modelinde  $b$  katsayıları sıfır olan ve  $a$  katsayılarından oluşan (tüm-kutup) filtre kullanılırken, MA modelinde  $a$  katsayıları sıfır olan ve  $b$  katsayılarından oluşan (tüm-sıfır) filtre kullanılır.

AR yöntemi için güç yoğunluk spektrumu şu şekilde ifade edilir:

$$P(f) = \left| \frac{1}{A(f)} \right|^2 \sigma^2, \quad (3.5)$$




Şekil 3.2.AR Modeli

Şekil 3.2’de AR yönteminde kullanılan model gösterilmektedir. Burada filtrenin girişi olan  $w[n]$ ,  $\sigma^2$  varyansına sahip beyaz Gauss gürültüsüdür.  $x[n]$  filtrenin çıktısı olarak modellenen ve spektral kestirimi yapılacak olan veridir.  $H(f) = 1/A(f)$  ise filtrenin transfer fonksiyonudur.

MA yöntemi için güç yoğunluk spektrumu şu şekilde ifade edilir:

$$P(f) = |B(f)|^2 \sigma^2, \quad (3.6)$$



Şekil 3.3.3. MA Modeli

Şekil 3.3’te MA yönteminde kullanılan model gösterilmektedir. Burada filtrenin girişi olan  $w[n]$ ,  $\sigma^2$  varyansına sahip beyaz Gauss gürültüsüdür.  $x[n]$  filtrenin çıktısı olarak modellenen ve spektral kestirimi yapılacak olan veridir.  $H(f) = B(f)$  ise filtrenin transfer fonksiyonudur.

### 3.1.1 Zaman Serileri

ARMA modelindeki filtrenin z-dönüşümü uygulanmış rasyonel halini şu şekilde ifade edebiliriz:

$$H(z) = \frac{B(z)}{A(z)}, \quad (3.7)$$

Şekil 3.1'deki ARMA modeli, zaman alanında şu şekilde ifade edilebilir:

$$x[n] = \frac{B(z)}{A(z)} w[n], \quad (3.8)$$

$$A(z)x[n] = B(z)w[n], \quad (3.9)$$

burada  $x[n]$  filtrenin çıkışı,  $z^{-1}$  birim gecikme işlemi ( $z^{-k}x[n] = x[n-k]$ ),  $w[n]$  varyansı  $\sigma^2$  olan beyaz Gauss gürültüsüdür [34].

Denklem (3.8)'i sağlayan  $x[n]$  işareti, ARMA  $(p, m)$  olarak adlandırılır ve  $(p, m)$  model derecesini belirtir.  $m = 0$  olması durumunda  $x[n]$ , AR  $(p)$  işareti olur ve  $p = 0$  olması durumunda  $x[n]$ , MA  $(m)$  işareti olarak belirtilir. Burada,  $p$  ve  $m$  sırası ile AR ve MA modellerinin derecesini gösterir. Bu durumda,

$$\text{ARMA: } A(z)x[n] = B(z)w[n], \quad (3.9)$$

$$\text{AR: } A(z)x[n] = w[n], \quad (3.10)$$

$$\text{MA: } x[n] = B(z)w[n], \quad (3.11)$$

$A(z)$ , ARMA modelindeki filtrenin AR bölümünü gösterir, matematiksel ifadesi ise şu şekildedir:

$$A(z) = \sum_{k=0}^p a[k]z^{-k}, \quad (3.12)$$

$B(z)$ , ARMA modelindeki filtrenin MA bölümünü gösterir, matematiksel ifadesi ise şu şekildedir:

$$B(z) = \sum_{k=0}^m b[k]z^{-k}, \quad (3.13)$$


ARMA metodunda, data girişi beyaz Gauss gürültüsü ( $w[n]$  varyansı  $\sigma^2$ ) olan nedensel, sıfır-kutup, ayrık filtrenin çıkışı olarak modellenir. ARMA modelinin fark denklemi şu şekilde ifade edilir [34]:

$$x[n] = -\sum_{k=1}^p a_k x[n-k] + \sum_{k=0}^m b_k w[n-k], \quad (3.14)$$

Denklem (3.14) için,  $a[0] = 1$  ve  $b[0] = 1$  dir.



ARMA( $p, m$ ) metodu ( $(p, m)$ 'inci dereceden ARMA metodu) ARMA parametreleri  $\{a[1], a[2], \dots, a[p], b[1], b[2], \dots, b[m], \sigma^2\}$  ile karakterize edilebilir. ARMA metodunda, verilen data dizisi  $x[n]$ ,  $0 \leq n \leq N-1$ , kullanılarak  $\{a_k\}_{k=1}^p$ ,  $\{b_k\}_{k=1}^m$ ,  $\sigma^2$  parametrelerinin kestirimi yapılır. Bu kestirilen parametreler denklem (3.2)'deki güç yoğunluk spektrumu ifadesinde yerine konur ve güç yoğunluk spektrum kestirimi bulunur. ARMA metodu, sıfır-kutup modeli olarak da adlandırılır. [34].



Şekil 3.4. ARMA Yöntemi [30]


Şekil 3.4'te ARMA modelinde zaman alanında yapılan filtreleme işlemi grafiksel olarak anlatılmaktadır.

AR metodunda, veri girişi beyaz Gauss gürültüsü ( $w[n]$  varyansı  $\sigma^2$ ) olan nedensel, tüm-kutup, ayrık filtrenin çıkışı olarak modellenir (Şekil 3.1). AR modelinin fark denklemi şu şekilde ifade edilir:

$$x[n] = -\sum_{k=1}^p a_k x[n-k] + w[n], \quad (3.15)$$

Denklem (3.15)'de,  $a[0] = 1$ ,  $b[0] = 1$  ve diğer  $b_k$  parametreleri sıfırdır.

AR ( $p$ ) metodu ( $p$ 'inci dereceden AR metodu) AR parametreleri  $\{a[1], a[2], \dots, a[p], \sigma^2\}$  ile karakterize edilebilir. AR metodunda, verilen data dizisi  $x(n)$ ,  $0 \leq n \leq N-1$ , kullanılarak  $\{a_k\}_{k=1}^p$ ,  $\sigma^2$  parametrelerinin kestirimi yapılır. Bu kestirilen parametreler denklem (3.5)'deki güç yoğunluk spektrumu ifadesinde yerine konur ve güç yoğunluk spektrum kestirimi elde edilir. AR metodu, tüm-kutup modeli olarak da adlandırılır [34].



Şekil 3.5.AR Yöntemi [30]

Şekil 3.5'te AR modelinde zaman alanında yapılan filtreleme işlemi grafiksel olarak anlatılmaktadır.


MA metodunda veri, girişi beyaz Gauss gürültüsü ( $w(n)$  varyansı  $\sigma^2$ ) olan nedensel, tüm-sıfır, ayrık filtrenin çıkışı olarak modellenir. MA metodunun fark denklemi şu şekilde ifade edilir:

$$x[n] = \sum_{k=0}^m b_k w[n-k], \quad (3.16)$$

Denklem (3.15)'de  $b[0]=1$ ,  $a[0]=1$  ve diğer  $a_k$  parametreleri sıfırdır.

MA ( $m$ ) metodu ( $m$ 'inci dereceden MA metodu) MA parametreleri  $\{b[1], b[2], \dots, b[m], \sigma^2\}$  ile karakterize edilebilir. MA metodunda, verilen data dizisi  $x(n)$ ,  $0 \leq n \leq N-1$ , kullanılarak  $\{b_k\}_{k=1}^m$ ,  $\sigma^2$  parametrelerinin kestirimi yapılır. Bu kestirilen parametreler denklem (3.6)'daki güç yoğunluk spektrumu ifadesinde yerine

konur ve güç yoğunluk spektrum kestirimi elde edilir. MA metodu, tüm-sıfır modeli olarak da adlandırılır. [34].



Şekil 3.6.MA metodu [30]

Şekil 3.6’da MA modelinde zaman alanında yapılan filtreleme işlemi grafiksel olarak anlatılmaktadır.

### 3.1.2 AR Yöntemi

AR yöntemi zaman serilerini modelleme yaklaşımlarında en sık kullanılan yöntemlerden biridir. Uygulamalarda dar bantlı spektrumlar ile daha çok karşılaşılmaktadır. AR yönteminde, denklem (3.5) ifadesindeki A polinomunun sıfırları birim çembere yakın bir biçimde yerleştirilerek, dar bantlı spektrumların kestirimi yapılabilir [34]. ARMA ve MA yöntemlerinde parametrelerin kestirimini yapabilmek için yüksek derecede doğrusal olmayan denklemlerin çözülmesi gerekirken, AR yönteminde parametrelerin kestirimi doğrusal denklemlerin çözülmesi ile elde edilir. Ayrıca AR yönteminde, Fourier tabanlı spektral kestirim yöntemlerinde olduğu gibi pencereleme yapılmadığı için, spektral sızıntılar

oluşmamaktadır. Frekans çözünürlüğü Fourier tabanlı yöntemlere göre çok daha yüksektir. [30]. Tüm bu avantajları sebebiyle, bu tez çalışmasında EEG sinyallerinin modellenmesinde AR yöntemi kullanılmıştır.

### 3.1.2.1 AR Yönteminin Otokorelasyon Yapısı

Otokorelasyon, bir sinyalin kendisi ile zaman gecikmesine uğrayan biçimi arasındaki benzerlik ölçüsüdür ve genelde tekrar eden sinyallerin tespitini yapabilmek için kullanılmaktadır. Sinyalin güç yoğunluk spektrumunun kestirimini yapabilmek için otokorelasyon fonksiyonlarının hesaplanabilmesi gerekmektedir. Elimizdeki sinyal verisi sonlu sayıda örneklem içerdiği için, otokorelasyon fonksiyonu hesaplanamaz ancak tahmin edilebilir. Otokorelasyon fonksiyonunun ifadesi şu şekildedir:

$$r[k] = E(x[n]x^*[n-k]), \quad (3.17)$$

Burada  $r[k]$  otokorelasyon fonksiyonu,  $x^*[n-k]$  ise  $x[n]$  işaretinin  $[n-k]$  'daki kompleks eşleniğidir ve  $E$  ise beklenen değer operatörüdür.

AR yönteminde otokorelasyon fonksiyonlarını elde edebilmek için  $\{a_i\}_{i=1}^p$ , ve  $\sigma^2$  parametreleri kullanılır. Öncelikle ARMA yönteminden harekete geçerseniz, denklem (3.9)'da verilen  $A[z]x[n] = B[z]w[n]$  ifadesi şu şekilde yazılabilir,

$$x[n] + \sum_{i=1}^p a_i x[n-i] = \sum_{j=0}^m b_j w[n-j], \quad (3.18)$$

burada  $a_0 = 1$  ve  $b_0 = 1$  'dir [34].

Denklem (3.18)'deki ifadeden otokorelasyon fonksiyonu ifadesine geçiş yapabilmek için, denklemdeki ifade  $x^*[n-k]$  ile çarpılır daha sonra ise beklenen değerleri alınır, ifade aşağıdaki biçime dönüşür [34]:

$$r[k] + \sum_{i=1}^p a_i r[k-i] = \sum_{j=0}^m b_j E\{w[n-j]x^*[n-k]\}, \quad (3.19)$$

$H(z) = B(z)/A(z)$  filtresi asimptotik olarak kararlı ve nedensel olduğu için şu şekilde yazılabilir,

$$H(z) = \sum_{k=0}^{\infty} h_k z^{-k}, \quad (h_0 = 1), \quad (3.20)$$

burada  $h$  filtrenin dürtü tepkisidir.

Denklem (3.20)'den yola çıkarak,  $x[n]$  sinyali aşağıdaki şekilde ifade edilebilir:

$$x[n] = H[q]w[n] = \sum_{k=0}^{\infty} h_k w[n-k], \quad (3.21)$$

Denklem (3.21)'deki ifadeyi kullanarak, denklem (3.19)'daki  $E\{w[n-j]x^*[n-k]\}$  ifadesi aşağıdaki gibi hesaplanır:

$$E\{w[n-j]x^*[n-k]\} = E\left\{w[n-j] \sum_{s=0}^{\infty} h_s^* w^*[n-k-s]\right\} = \sigma^2 \sum_{s=0}^{\infty} h_s^* \delta_{j,k+s} = \sigma^2 h_{j-k}^* \quad (3.22)$$

burada,  $\delta$  dürtü fonksiyonudur.

Denklem (3.22) ile elde edilen ifade, denklem (3.19)'da yerine konursa aşağıdaki ifade elde edilir:

$$r[k] + \sum_{i=1}^p a_i r[k-i] = \sigma^2 \sum_{j=0}^m b_j h_{j-k}^* , \quad (3.23)$$

ARMA yöntemi temel alınarak yapılan işlemlerin ardından, AR yöntemi için otokorelasyon ifadelerini elde edebiliriz. AR yönteminde  $m = 0$  ve  $B[z] = 1$ 'dir. AR yöntemi için denklem (3.23)'deki ifade aşağıdaki gibi elde edilir:

$$r[k] + \sum_{i=1}^p a_i r[k-i] = \sigma^2 \sum_{j=0}^0 b_j h_{j-k}^* = \sigma^2 b_0 h_{-k}^* , \quad (3.24)$$

Sistemin nedensel olmasından dolayı  $k < 0$  için  $h(k) = 0$ 'dır ve aşağıdaki ifade elde edilir [34]:

$$r[0] + \sum_{i=1}^p a_i r[-i] = \sigma^2 , \quad k = 0 \quad (3.25)$$

$$r[k] + \sum_{i=1}^p a_i r[k-i] = 0 , \quad k > 0 \quad (k = 1, 2, \dots, p) . \quad (3.26)$$

Böylece denklem (3.25) ve denklem (3.26)'daki ifadelerle AR yönteminin otokorelasyon yapısı elde edilmiş olur. Denklem (3.25) ve denklem (3.26)'daki ifadelerin ikisi birlikte “Yule-Walker denklemleri” veya “normal denklemler” olarak adlandırılır [34].

AR yönteminde parametrelerin kestirimini yapabilmek için çeşitli kestirim yöntemleri kullanılır. Bu kestirim yöntemler genel olarak dört çeşittir, bunlar, Yule-Walker, Burg, Kovaryan (Least-Squares-Forward), Modifiye edilmiş kovaryans (Least-Squares-Forward-Backward) yöntemleridir [13]. Bu tez çalışmasında analizlerler Yule-Walker ve Burg yöntemleri kullanılarak elde edilmiştir.

### 3.1.2.2 AR Parametre Kestirim Yöntemleri

#### 3.1.2.2.1 Yule-Walker AR Yöntemi

Yule-Walker denklemleri (Denklem (3.25) ve denklem (3.26)'daki ifadeler) AR parametrelerinin kestiriminde kullanılan yöntemlerin temelini oluşturmaktadır. . Yule-Walker denklemlerindeki  $a[k]$  ( $k = 1, 2, \dots, p$ ) parametrelerinin ve  $\sigma^2$ 'nin kestirimi yapılır, buradan da anlaşılacağı gibi modellediğimiz sinyal verisine ait  $p + 1$  adet bilinmeyen parametre vardır. Yule-Walker denklemlerinden denklem (3.26)'daki ifadeyi matris biçiminde ifade edersek:

$$\begin{bmatrix} r[1] \\ \vdots \\ r[p] \end{bmatrix} + \begin{bmatrix} r[0] & \cdots & r[-p+1] \\ \vdots & \ddots & \vdots \\ r[p-1] & \cdots & r[0] \end{bmatrix} \begin{bmatrix} a_1 \\ \vdots \\ a_p \end{bmatrix} = \begin{bmatrix} 0 \\ \vdots \\ 0 \end{bmatrix}, \quad (3.27)$$

Denklem (3.27)'deki matrisleri aşağıdaki gibi ifade edebiliriz:

$$r_p = \begin{bmatrix} r[1] \\ \vdots \\ r[p] \end{bmatrix}, \quad (3.28)$$



$$R_p = \begin{bmatrix} r[0] & \cdots & r[-p+1] \\ \vdots & \ddots & \vdots \\ r[p-1] & \cdots & r[0] \end{bmatrix}, \quad (3.29)$$

$$a = \begin{bmatrix} a_1 \\ \vdots \\ a_p \end{bmatrix}, \quad (3.30)$$

Böylece denklem (3.27)'deki ifadenin bir diğer eşdeğer biçimi aşağıdaki gibi yazılabilir:

$$r_p + R_p a = 0, \quad (3.31)$$

Denklem (3.31)'de  $k > 0$  için  $r[-k] = r^*[k]$ 'dir.  $R_p$  otokorelasyon matrisidir ve bu matris Hermitian, Toeplitz ve tekil olmayan bir matristir. Tekil olmayan bir matris olduğu için tersi alınabilir. Denklem (3.31)'deki ifadeyi  $R_p^{-1}$  ile çarparsak ve  $a$  ifadesini denklemden çekersek [34]:

$$a = -R_p^{-1} r_p, \quad (3.32)$$

Denklem (3.32)'deki ifade ile  $a = [a_1 \cdots a_p]^T$  parametreleri otokorelasyon fonksiyonları  $\{r[k]\}_{k=0}^p$  kullanılarak hesaplanır. AR katsayıları olarak adlandırılan  $a = [a_1 \cdots a_p]^T$  parametrelerinin hesaplanmasının ardından, hesaplanması gereken bir diğer parametre ve son parametre ise beyaz Gauss gürültüsünün varyansıdır ( $\sigma^2$ ).

Bulunan AR katsayıları, denklem (3.25)'de yerine konur ve böylece  $\sigma^2$  hesaplanır. [34]

Daha önce de bahsedildiği gibi, otokorelasyon fonksiyonlarının hesaplanması direk yapılamaz çünkü eldeki  $\{x[n]\}_{n=1}^N$  sinyali verisi sonsuz uzunlukta değildir, sonlu sayıdaki örneklemden oluşur. Bu sebeple otokorelasyon fonksiyonlarının kestirimi yapılır. Yöntemin kararlı olabilmesi için,  $\hat{R}_p$ 'nin pozitif olması ve tek bir çözüm elde edilmesi gerekir, bu sebeple otokorelasyon fonksiyonlarının kutuplu kestirimleri kullanılır. [34]

$\{x[n]\}_{n=1}^N$  verisine ait otokorelasyon fonksiyonlarının kutuplu kestirimleri aşağıdaki ifade ile elde edilir:

$$\hat{r}[k] = \frac{1}{N} \sum_{n=k+1}^N x[n]x^*[n-k], 0 \leq k \leq N-1, \quad (3.33)$$

Denklem (3.25) ve denklem (3.26)'daki Yule-Walker denklemlerinde otokorelasyon fonksiyonları  $\{r[k]\}_{k=0}^p$  yerine, otokorelasyon fonksiyonlarının kutuplu kestirimleri  $\{\hat{r}[k]\}_{k=0}^p$  konur,

$$\hat{a} = -\hat{R}_p^{-1}\hat{r}_p, \quad (3.34)$$

$$\hat{\sigma}^2 = \hat{r}[0] + \sum_{i=1}^p \hat{a}_i \hat{r}[-i] \quad (3.35)$$

Güç yoğunluk spektrumunun kestirimi için ihtiyaç duyduğumuz AR parametreleri olan  $a = [a_1 \ \dots \ a_p]^T$  ve  $\sigma^2$  parametrelerinin kestirimleri denklem (3.34) ve (3.35) kullanılarak Yule-Walker metoduna göre hesaplanmış olur [16-20]. Son adım olarak, hesaplanan AR parametreleri, aşağıdaki denklem (3.36) ile verilen güç yoğunluk spektrumunun ifadesinde yerine yerleştirilerek, güç yoğunluk spektrumunun kestirimi hesaplanmış olur [34].

$$\hat{P}_{YW}(f) = \frac{\hat{\sigma}^2}{\left| 1 + \sum_{k=1}^p \hat{a}_p(k) e^{-j2\pi fk} \right|^2}, \quad (3.36)$$

### 3.1.2.2.2 Burg AR Yöntemi

Burg yöntemi doğrusal kestiricilerdeki (ing: linear predictors) ileri-geri yöndeki tahmin hataların (ing: forward and backward errors) küçültülmesi temeline dayanan derece-özyinelemeli en küçük kareler örgü yöntemi (ing: order-recursive least squares lattice method) olarak ifade edilebilir. Hesaplamalarda AR parametrelerinin Levinson-Durbin özyinelemesini sağladığı öngörülmektedir. [35].

$p$  model derecesine sahip  $\{x[n]\}_{n=0}^{N-1}$  verisi için ileri ve geri doğrusal kestirim aşağıdaki şekilde ifade edilebilir:

$$\hat{x}[n] = -\sum_{k=1}^p a_p[k] x[n-k], \quad (3.45)$$

$$\hat{x}[n-p] = -\sum_{k=1}^p a_p^*[k] x[n+k-p], \quad (3.46)$$

Denklem (3.45) ve denklem (3.46)'daki  $a_p[k], 0 \leq k \leq p-1, p = 1, 2, \dots, q$  tahmin katsayılarını belirtir.

İleri yöndeki tahmin hatası aşağıdaki şekilde ifade edilebilir:

$$f_p[n] = x[n] - \hat{x}[n], \quad (3.47)$$

Geri yöndeki tahmin hatası ise aşağıdaki denklem ile gösterilebilir:

$$g_p[n] = x[n-p] - \hat{x}[n-p], \quad (3.48)$$

En küçük kareler hatası ise aşağıdaki gibi hesaplanır:

$$\varepsilon_p = \sum_{n=p}^{N-1} \left[ |f_p[n]|^2 + |g_p[n]|^2 \right], \quad (3.49)$$

Denklem (3.49)'daki hata, Levinson-Durbin özyinelemesini sağlayan tahmin katsayılarını seçerek küçültülür. Tahmin katsayılarının aşağıdaki ifadeyi sağladığı öngörülmüştür [35]:

$$a_p[k] = a_{p-1}[k] + K_p a_{p-1}^*[p-k], \quad 1 \leq k \leq p-1, \quad 1 \leq p \leq q-1 \quad (3.50)$$

Denklem (3.50)'de  $K_p = a_p[p]$ , AR modelindeki filtrenin  $p$ 'inci yansıma katsayısını ifade eder. Bu yansıma katsayısının kestirimi ise aşağıdaki denklem ile hesaplanır [35]:

$$\hat{K}_p = \frac{-\sum_{n=p}^{N-1} f_{p-1}[n] g_{p-1}^*[n-1]}{\frac{1}{2} \sum_{n=p}^{N-1} \left[ |f_{p-1}[n]|^2 + |g_{p-1}[n-1]|^2 \right]}, \quad p = 1, 2, \dots, q, \quad (3.51)$$

Denklem (3.51)'deki ifadenin pay kısmı, ileri ve geri yöndeki tahmin hataları arasındaki çapraz korelasyonun (ing: crosscorrelation) kestirimini ifade eder. Denklem payda kısmındaki ifadenin büyüklüğü, pay kısmındaki ifadeye göre daha büyük olacağı için,  $|K_p| < 1$  olacağı açıktır, bu sebeple Burg yöntemindeki model kararlıdır. [35] .

Denklem (3.51)'deki ifadenin payda kısmındaki ifade ileri ve geri yöndeki tahmin hatalarının en küçük kareler kestirimlerini içerir. İleri yöndeki tahmin hatasının en küçük kareler kestirimi  $\hat{E}_{p-1}^f$  ve geri yöndeki tahmin hatasının en küçük kareler kestirimi  $\hat{E}_{p-1}^b$ , denklem (3.51)'de yerine yerleştirilirse, ifade aşağıdaki şekli alır:

$$\hat{K}_p = \frac{-\sum_{n=p}^{N-1} f_{p-1}[n]g_{p-1}^*[n-1]}{\frac{1}{2}[\hat{E}_{p-1}^f + \hat{E}_{p-1}^b]}, p = 1, 2, \dots, q, \quad (3.52)$$

Toplam en küçük karesel hatanın kestirimi, ileri ve geri yöndeki hataların en küçük kareler kestirimlerinin toplamı şeklinde ifade edilebilir:

$$\hat{E}_p = \hat{E}_p^f + \hat{E}_p^b, \quad (3.53)$$

Burg algoritması kullanılarak, yansıma katsayılarının kestirimi hesaplanır ve Levinson-Durbin algoritması kullanılarak da AR parametrelerinin kestirimi gerçekleştirilir. Burg yöntemine göre, güç yoğunluk spektrumunun kestirimi aşağıdaki ifade ile hesaplanır [35]:

$$\hat{P}_{BU}(f) = \frac{\hat{E}_p}{\left| 1 + \sum_{k=1}^p \hat{a}_p(k)e^{-j2\pi fk} \right|^2}, \quad (3.54)$$

### 3.1.2.2.2.1 Levinson-Durbin Algoritması

Levinson-Durbin algoritması, AR parametrelerinin kestirimini yapabilmek için kullanılan özyinelemeli bir hesaplama yöntemidir. Öncelikle model derecesini 1 olarak alır ve hesaplama yapar, daha sonra model derecelerini birer arttırarak onlar için de daha önceki model derecesine ait sonuçları kullanarak hesaplama yapar. Böylece model derecesi  $q$  olan bir model için, 1'den  $q$  ya kadar model derecesini arttırarak kestirim yapar [36].

Denklem (3.25) ve denklem (3.26)'daki Yule-Walker denklemleri, denklem (3.29) kullanılarak aşağıdaki şekilde ifade edilebilir:

$$R_{p+1} \begin{bmatrix} 1 \\ a_p \end{bmatrix} = \begin{bmatrix} \sigma_p^2 \\ 0 \end{bmatrix}, \quad (3.37)$$

$R$  matrisinin iç içe geçmiş yapısını ve denklem (3.37)'deki ifadeyi kullanarak, aşağıdaki denklem elde edilebilir:

$$R_{p+2} \begin{bmatrix} 1 \\ a_p \\ - \\ 0 \end{bmatrix} = \begin{bmatrix} R_{p+1} & - & r^*[p+1] \\ & - & \hat{r}_p \\ & - & - \\ r[p-1] & \hat{r}_p^* & r[0] \end{bmatrix} \begin{bmatrix} 1 \\ a_p \\ - \\ 0 \end{bmatrix} = \begin{bmatrix} \sigma_p^2 \\ 0 \\ - \\ \alpha_p \end{bmatrix}, \quad (3.38)$$

$r_p$  'nin ifadesi denklem (3.28)'de bulunmaktadır,

$$\alpha_p = r[p+1] + \hat{r}_p^* a_p, \quad (3.39)$$

Yansıma katsayısı olarak adlandırılan  $k$  değerleri aşağıdaki şekilde ifade edilebilir:

$$k_{.p+1} = -\alpha_p / \sigma_p^2, \quad (3.40)$$

$R$  matrisinin Hermitian, Toeplitz matris olma özelliğinden ve denklem (3.38)'deki ifadeden yararlanılarak, aşağıdaki ifade elde edilebilir [36]:

$$R_{p+2} \left\{ \begin{bmatrix} 1 \\ a_p \\ 0 \end{bmatrix} + k_{p+1} \begin{bmatrix} 0 \\ \hat{a}_p \\ 1 \end{bmatrix} \right\} = \begin{bmatrix} \sigma_p^2 \\ 0 \\ \alpha_p \end{bmatrix} + k_{p+1} \begin{bmatrix} \alpha_p^* \\ 0 \\ \sigma_p^2 \end{bmatrix} = \begin{bmatrix} \sigma_p^2 + k_{p+1} \alpha_p^* \\ 0 \end{bmatrix}, \quad (3.41)$$

$$R_{p+2} \begin{bmatrix} 1 \\ a_{p+1} \end{bmatrix} = \begin{bmatrix} \sigma_{p+1}^2 \\ 0 \end{bmatrix}, \quad (3.42)$$

Denklem (3.41), denklem (3.42)'yle aynı yapıdadır. İki denklem kıyaslandığında parametrelerin kestirimi aşağıdaki ifadelerle elde edilebilir [36]:

$$a_{p+1} = \begin{bmatrix} a_p \\ 0 \end{bmatrix} + k_{p+1} \begin{bmatrix} \hat{a}_p \\ 1 \end{bmatrix}, \quad p = 1, 2, \dots, q \quad (3.43)$$

$$\sigma_{p+1}^2 = \sigma_p^2 (1 - |k_{p+1}|^2), \quad p = 1, 2, \dots, q \quad (3.44)$$

### 3.1.2.3 AR Model Derecesi Belirleme Yöntemleri

AR yönteminde karşılaşılan en büyük sorunlardan biri model derecesini belirleme problemidir. Güç yoğunluk spektrum kestirimlerinin doğru bir şekilde yapılabilmesi, ancak oluşturulan modelin model derecesinin uygun bir biçimde seçilmesi ile mümkündür. Bu problemin çözümü için çok çeşitli yöntemler geliştirilmiştir. Bu tez çalışmasında, eldeki veri tabanından elde edilen EEG kayıtlarının model derecesini belirlemek üzere AIC, MDL, FPE, CAT, BIC ve KIC yöntemlerine başvurulmuştur.

$\hat{\sigma}^2$  beyaz Gauss gürültüsünün varyansının kestirimi,  $N$  eldeki verinin örneklem sayısını ve  $p$  model derecesini belirtir. Uygun model derecesini belirlemek için,

çeşitli model derecesi değerleri yöntemlere ait denklemlerdeki ifadelerde yerine yerleştirilir ve denklemdaki ifadenin minimum değerine ulaştığı model derecesi, uygun model derecesi olarak belirlenir.

AIC (Akaike's Information Criterion) yönteminin ifadesi aşağıdaki gibidir [35]:

$$AIC(p) = \ln(\hat{\sigma}^2) + \frac{2p}{N}, \quad (3.45)$$

MDL (Minimum Description Length ) yönteminin ifadesi [35] :

$$MDL(p) = N \ln(\hat{\sigma}^2) + p \ln(N), \quad (3.46)$$

FPE (Akaike's Final Prediction Error) yönteminin ifadesi [35] :

$$FPE(p) = \hat{\sigma}^2 \frac{(N + p + 1)}{(N - p - 1)}, \quad (3.47)$$

CAT (Parzen's Criterion of Autoregressive Transfer function) yönteminin ifadesi [22] :

$$CAT(p) = \left( \frac{1}{N^2} \sum_{k=1}^p \frac{N-k}{\hat{\sigma}_k^2} \right) - \frac{N-p}{N \hat{\sigma}_p^2}, \quad (3.48)$$

BIC (Bayesian Information Criterion) yönteminin ifadesi [37]:

$$BIC(p) = \ln(\hat{\sigma}_p^2) + \frac{p \ln(N)}{N}, \quad (3.49)$$



KIC (Kullback Information Criterion) yönteminin ifadesi [11]:

$$KIC(p) = \ln(\hat{\sigma}_p^2) + \frac{3p}{N}, \quad (3.50)$$

## BÖLÜM 4

### 4. GÜÇ YOĞUNLUK SPEKTRUMLARININ ELDE EDİLMESİ

Bölüm 2.4'te anlatılan veri tabanından elde edilen EEG verileri kullanılarak her bir set için model dereceleri model derecesi belirleme yöntemlerine göre hesaplanarak, güç yoğunluk spektrumlarının kestirimleri yapılmıştır. Benzer bir çalışma Serap Aydın tarafından [22] çalışmasında gerçekleştirilmiştir. [22] çalışmasından farklı olarak, bu tez çalışmasında SLSA yöntemi yerine model derecesi belirleme yöntemlerinden KIC yöntemi kullanılmaktadır. Ayrıca parametre kestirimleri için Burg yönteminin yanında Yule–Walker yöntemi de kullanılmaktadır. [29] çalışmasında Set A, Set D ve Set E verileri üzerinden hesaplamalar yapılırken, bu çalışmada ek olarak Set B, Set C için de spektral analizler gerçekleştirilmektedir. Bir diğer fark ise, model derecesi belirlenirken, öncelikle her bir setteki 5 kişiye ait 20'şer verinin her biri için model derecesi hesaplanmıştır, daha sonra her bir kişiye ait 20 model derecesi elde edildikten sonra onların ortalaması alınarak her bir kişiye ait tek bir model derecesi elde edilmiştir. Bu tez çalışmasında ise her bir kişiye ait 20 verinin öncelikle model derecesini bulmak yerine, her bir kişiye ait bu 20 EEG sinyali verisinin ortalaması alınarak her bir kişi için ortalama bir EEG verisi elde edilmiştir. Daha sonra ise her bir kişi için elde edilen EEG verisine ait model derecesi hesaplanmıştır.

Bu çalışmada yapılan model derecesi belirleme işlemlerini aşağıdaki şekilde sıralarsak:

1. Öncelikle her bir kişi için tek bir EEG verisi elde etmek için, her bir kişiye ait 20 EEG verisinin ortalaması alınmıştır
2. Daha sonra her bir kişiye ait hesaplanan ortalama EEG verisi için model derecesi hesaplanmıştır.
3. Her setteki 5 kişi için hesaplanan model derecelerinin ortalaması alınarak, her bir set için tek bir model derecesi belirlenmiştir.

#### 4.1 Yule-Walker ve Burg Yöntemi ile Elde Edilen Sonuçlar

Öncelikle Yule-Walker yöntemi ile kestirilen model parametreleri kullanılarak, her bir model derecesi belirleme yöntemi ile her bir set için model derecesi belirlenmiştir. Belirlenen model derecelerine göre her bir set için güç yoğunluk spektrumları çizdirilmiştir. Her model derecesi belirleme yöntemine göre, Yule-Walker ve Burg kestirim yöntemiyle hesaplanan parametreler kullanılarak her bir set için hesaplanan model dereceleri sırasıyla Çizelge 4.1 ve Çizelge 4.2’de görülmektedir:

Çizelge 4.1. Yule –Walker Yöntemi Kullanıldığında Tahmin Edilen Model Dereceleri

	AIC	FPE	BIC	KIC	MDL	CAT
Set A	77	77	36	64	36	21
Set B	107	107	32	61	32	24
Set C	78	78	21	57	21	13
Set D	76	76	9	50	9	9
Set E	21	21	12	19	12	11


Çizelge 4.2. Burg Yöntemi Kullanıldığında Tahmin Edilen Model Dereceleri

	AIC	FPE	BIC	KIC	MDL	CAT
Set A	91	86	41	74	41	25
Set B	121	121	33	61	33	24
Set C	133	133	32	73	32	15
Set D	100	100	22	61	22	9
Set E	25	25	14	20	14	11

Çizelge 4.1 ve Çizelge 4.2'deki sonuçlar incelendiğinde, Burg yöntemi kullanıldığında tüm set ve tüm yöntemler için elde edilen model dereceleri, Yule-Walker yöntemi kullanıldığında elde edilenlere göre daha yüksek değerlere sahiptir. Her iki durum için de, AIC ve FPE yaklaşık aynı sonuçları verirken, BIC ve MDL yöntemleri de birbirleriyle aynı model derecesi değerlerini üretmişlerdir. Ayrıca her iki durum için, tüm model derecesi belirleme yöntemleri en düşük model derecesi değerlerini Set E'deki EEG verisi için elde etmişlerdir. Her iki durumda da her set için en yüksek değerler AIC ve FPE, en düşük değerler ise CAT yöntemleri ile elde edilmiştir. Genel olarak her bir yöntem, her bir set için farklı sonuçlar vermiştir, elde edilen model derecesi elde edilen sinyalin karakteristiğine bağlı olarak değişmektedir.

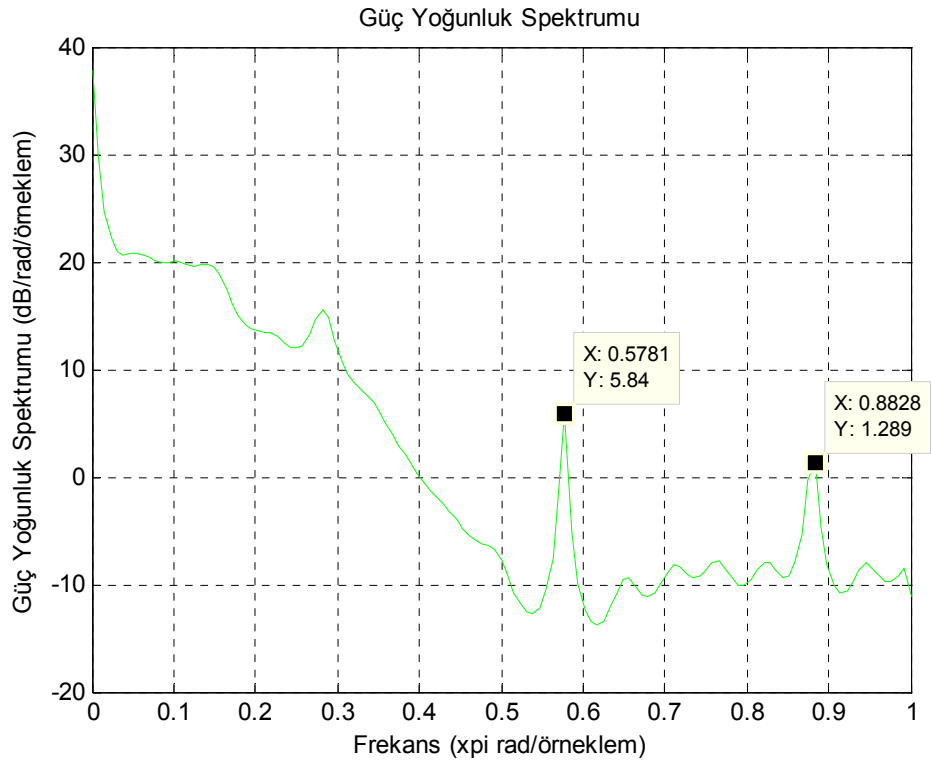
#### 4.1.1 Yule-Walker Yöntemi ile Elde Edilen Sonuçlar

Yule-Walker yöntemi kullanılarak, model derecesi belirleme yöntemleriyle belirlenen model derecelerine göre güç yoğunluk spektrumlarının grafikleri Şekil 4.1, 4.2, 4.3, 4.4 ve 4.5 de görülmektedir. Elde edilen grafiklerde AIC ve FPE, aynı zamanda BIC ve MDL aynı sonuçları verdiği için, sadece bir yöntemin bulunduğu model derecesine göre güç yoğunluk spektrumları çizdirilmiştir. Sonuçlarda AIC ve BIC yöntemlerinin performans değerlendirmesi sırasıyla FPE ve MDL yöntemleri ile yaklaşık olarak aynıdır.




Şekil 4.1. Set A için Elde Edilen Güç Yoğunluk Spektrumu

Şekil 4.1’de, Set A’daki EEG verisi için, model belirleme yöntemleri kullanılarak elde edilen model derecelerine göre, güç yoğunluk spektrumları Yule-Walker yöntemi ile hesaplanarak çizdirilmiştir. Elde edilen grafikte BIC yöntemi ile elde edilen model derecesinin daha iyi bir spektrum kestirimi sağladığı görülmüştür. KIC ve AIC yöntemleriyle elde edilen model derecesinin oldukça yüksek olduğu için yanıltıcı tepeler oluşturduğu görülmektedir. BIC yöntemi ile elde edilen model derecesine göre çizdirilmiş güç yoğunluk spektrumu ve seçilen tepe değerleri Şekil 4.2’de görülmektedir.




Şekil 4.2. BIC Yöntemine Göre Elde Edilen Güç Yoğunluk Spektrumu




Şekil 4.3.Set B için Elde Edilen Güç Yoğunluk Spektrumu

Şekil 4.3’de, Set B’deki EEG verisi için, model belirleme yöntemleri kullanılarak elde edilen model derecelerine göre, güç yoğunluk spektrumları Yule-Walker yöntemi ile hesaplanarak çizdirilmiştir. Elde edilen grafikte CAT yöntemi ile elde edilen model derecesinin daha iyi bir spektrum kestirimi sağladığı görülmüştür. Diğer yöntemlerle elde edilen model derecelerinin oldukça yüksek olduğu için yanıltıcı tepeler oluşturduğu görülmektedir. CAT yöntemi ile elde edilen model derecesine göre çizdirilmiş güç yoğunluk spektrumu ve seçilen tepe değerleri Şekil 4.4’te görülmektedir.




Şekil 4.4.CAT Yöntemine Göre Elde Edilen Güç Yoğunluk Spektrumu




Şekil 4.5.Set C için Elde Edilen Güç Yoğunluk Spektrumu

Şekil 4.5’de, Set C’deki EEG verisi için, model belirleme yöntemleri kullanılarak elde edilen model derecelerine göre, güç yoğunluk spektrumları Yule-Walker yöntemi ile hesaplanarak çizdirilmiştir. Elde edilen grafikte KIC ve AIC yöntemlerinin her ikisinin de diğer yöntemlere göre daha iyi bir spektrum kestirimi sağladığı, ancak KIC ile bulunan model derecesinin en düzgün spektrumu ürettiği görülmüştür. Diğer yöntemler oldukça düşük model derecesi değerleri ürettikleri için, sinyal düzgün modellenememiştir ve oldukça düz bir spektrum oluşmuştur. KIC yöntemi ile elde edilen model derecesine göre çizdirilmiş güç yoğunluk spektrumu ve seçilen tepe değerleri Şekil 4.6’da görülmektedir.






Şekil 4.6. KIC Yöntemine Göre Elde Edilen Güç Yoğunluk Spektrumu

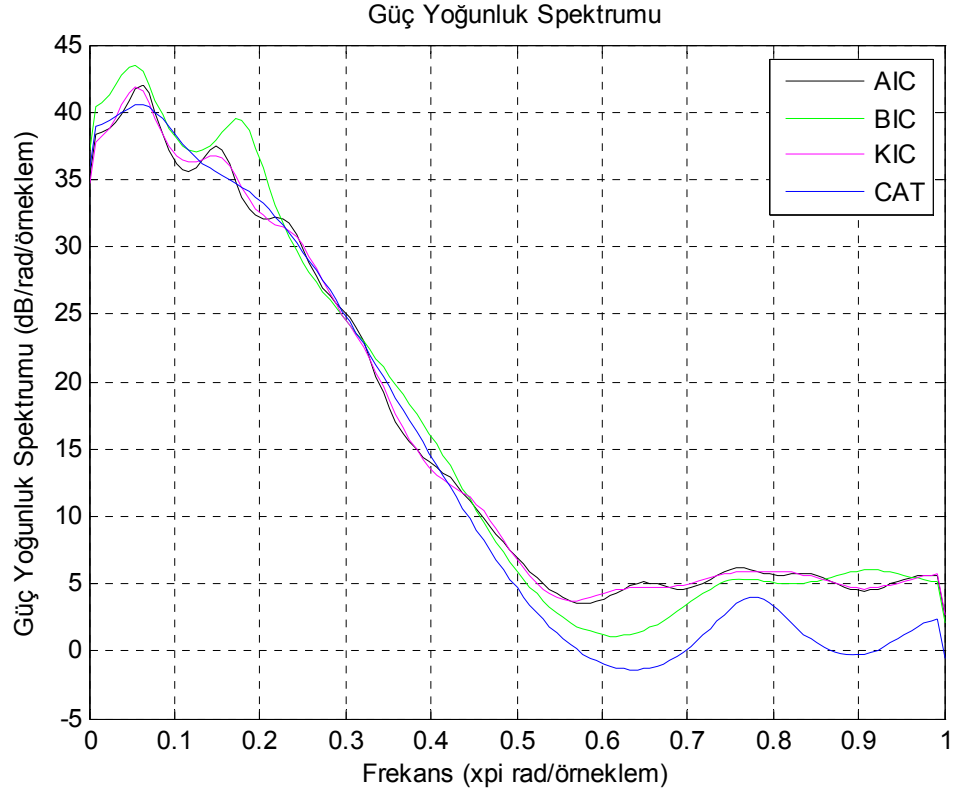


Şekil 4.7.Set D için Elde Edilen Güç Yoğunluk Spektrumu

Şekil 4.7’de, Set D’deki EEG verisi için, model belirleme yöntemleri kullanılarak elde edilen model derecelerine göre, güç yoğunluk spektrumları Yule-Walker yöntemi ile hesaplanarak çizdirilmiştir. Elde edilen grafikte KIC ile bulunan model derecesinin en düzgün spektrumu ürettiği görülmektedir. AIC ile üretilen model derecesinin oldukça yüksek model derecesi ürettiği ve spektrumda gerçekçi olmayan tepe değerlerine sebep olduğu görülmektedir. BIC ve CAT yöntemleri oldukça düşük model derecesi değerleri ürettikleri için, sinyal düzgün modellenememiştir ve oldukça düz bir spektrum oluşmuştur. KIC yöntemi ile elde edilen model derecesine göre çizdirilmiş güç yoğunluk spektrumu ve seçilen tepe değerleri Şekil 4.8’de görülmektedir.

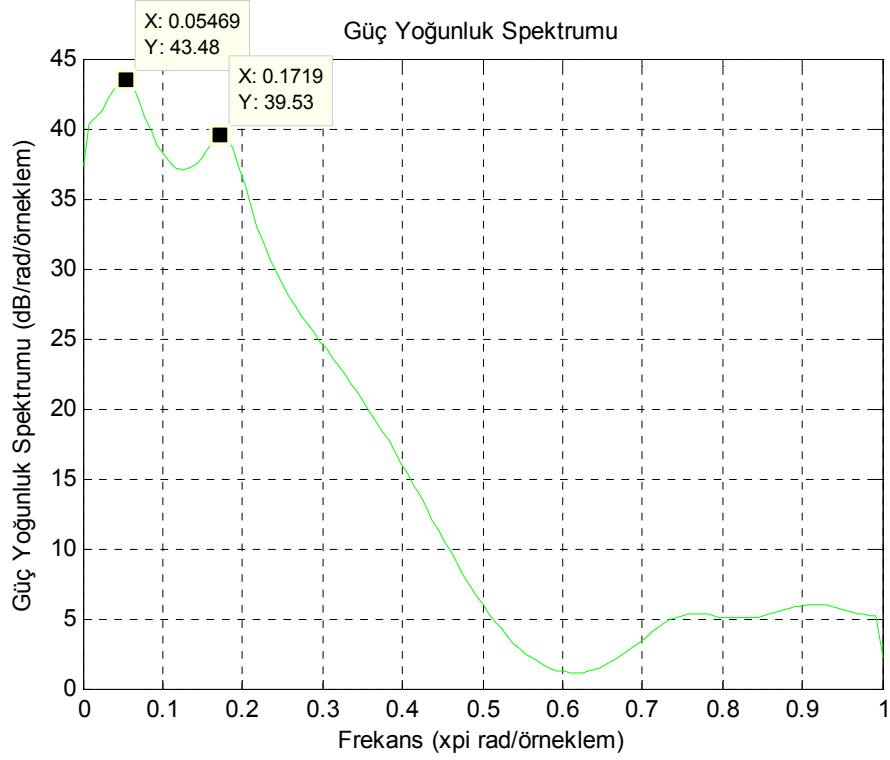


Şekil 4.8.KIC Yöntemine Göre Elde Edilen Güç Yoğunluk Spektrumu



Şekil 4.9.Set E için Elde Edilen Güç Yoğunluk Spektrumu

Şekil 4.9’da, Set E’deki EEG verisi için, model belirleme yöntemleri kullanılarak elde edilen model derecelerine göre, güç yoğunluk spektrumları Yule-Walker yöntemi ile hesaplanarak çizdirilmiştir. Elde edilen grafikte BIC ile bulunan model derecesinin en düzgün spektrumu ürettiği görülmektedir. AIC ile üretilen model derecesinin oldukça yüksek model derecesi ürettiği ve spektrumda gerçekçi olmayan tepe değerlerine sebep olduğu görülmektedir. CAT yöntemi oldukça düşük model derecesi değerleri ürettiği için, sinyal düzgün modellenememiştir ve oldukça düz bir spektrum oluşmuştur. BIC yöntemi ile elde edilen model derecesine göre çizdirilmiş güç yoğunluk spektrumu ve seçilen tepe değerleri Şekil 4.10’de görülmektedir.



Şekil 4.10.BIC Yöntemine Göre Elde Edilen Güç Yoğunluk Spektrumu

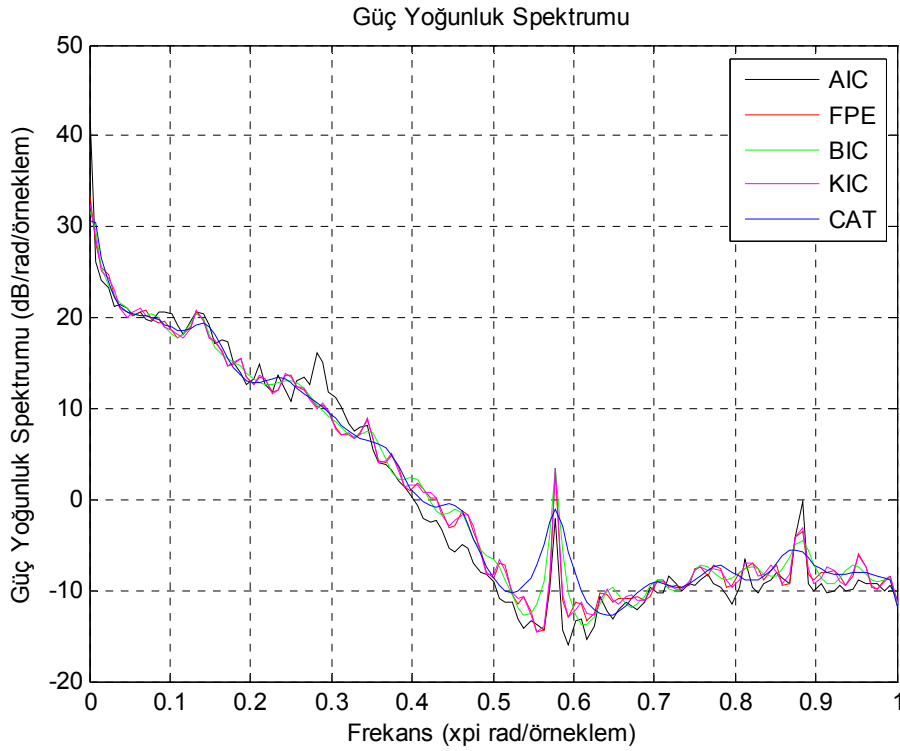
Çizelge 4.3’de her set için, uygun görülen model derecesi ile elde edilen güç yoğunluk spektrumlarındaki tepe/frekans değerleri gösterilmektedir.

Çizelge 4.3.Yule-Walker Yöntemi ile Elde Edilen Tepe/Frekans Değerleri

(dB/rad/örneklem)/ ( $x\pi$ rad/örneklem)	Tepe1/frekans	Tepe2/frekans	Tepe3/frekans
Set A	5.84/0.5781	1.289/0.8828	
Set B	34.53/0.125	1.573/0.5781	-2.792/0.875
Set C	-0.02484/0.5781		
Set D	-1.941/0.5781		
Set E	43.48/0.05469	39.53/0.1719	

#### 4.1.2 Burg Yöntemi ile Elde Edilen Sonuçlar


Burg yöntemi kullanılarak, model derecesi belirleme yöntemleriyle belirlenen model derecelerine göre güç yoğunluk spektrumlarının grafikleri Şekil 4.11, 4.12, 4.13, 4.14 ve 4.15 de görülmektedir. Elde edilen grafiklerde AIC ve FPE, aynı zamanda BIC ve MDL aynı sonuçları verdiği için, sadece bir yöntemin bulduğu model derecesine göre güç yoğunluk spektrumları çizdirilmiştir. Sonuçlarda AIC ve BIC yöntemlerinin performans değerlendirmesi sırasıyla FPE ve MDL yöntemleri için de benzerdir. Yalnızca Set A için, AIC ve FPE farklı değerler vermektedir ve Set A için çizdirilen güç yoğunluk spektrumu grafiğinde FPE ile elde edilen spektrum çizimine de yer verilmektedir.




Şekil 4.11. Set A için Elde Edilen Güç Yoğunluk Spektrumu

Şekil 4.11’de, Set A’daki EEG verisi için, model belirleme yöntemleri kullanılarak elde edilen model derecelerine göre, güç yoğunluk spektrumları Burg yöntemi ile

hesaplanarak çizdirilmiştir. CAT ve AIC yöntemleri hariç, FPE, BIC ve KIC yöntemlerinin çok büyük farklara sahip olmadığı görülmektedir. AIC yöntemi daha fazla yanıltıcı tepeler oluşmasına sebep olurken, CAT yöntemiyle elde edilen güç yoğunluk spektrumunda elde edilen tepe değeri diğer yöntemlerle elde edilenler kadar belirgin değildir. Elde edilen grafikte FPE yöntemi ile elde edilen model derecesinin diğer yöntemlere göre daha iyi bir spektrum kestirimi sağladığı görülmektedir. FPE yöntemi ile elde edilen model derecesine göre çizdirilmiş güç yoğunluk spektrumu ve seçilen tepe değerleri Şekil 4.12’de görülmektedir.




Şekil 4.12.FPE Yöntemine Göre Elde Edilen Güç Yoğunluk Spektrumu




Şekil 4.13.Set B için Elde Edilen Güç Yoğunluk Spektrumu

Şekil 4.13’de, Set B’deki EEG verisi için, model belirleme yöntemleri kullanılarak elde edilen model derecelerine göre, güç yoğunluk spektrumları Burg yöntemi ile hesaplanarak çizdirilmiştir. Elde edilen grafikte CAT yöntemi ile elde edilen model derecesinin daha iyi bir spektrum kestirimi sağladığı görülmektedir. En kötü güç yoğunluk spektrumu ise AIC yöntemiyle elde edilen model derecesinin kullanıldığı durumda elde edilmektedir. CAT yöntemi ile elde edilen model derecesine göre çizdirilmiş güç yoğunluk spektrumu ve seçilen tepe değerleri Şekil 4.14’te görülmektedir.






Şekil 4.14.CAT Yöntemine Göre Elde Edilen Güç Yoğunluk Spektrumu




Şekil 4.15.Set C için Elde Edilen Güç Yoğunluk Spektrumu

Şekil 4.15’de, Set C’deki EEG verisi için, model belirleme yöntemleri kullanılarak elde edilen model derecelerine göre, güç yoğunluk spektrumları Burg yöntemi ile hesaplanarak çizdirilmiştir. Elde edilen grafikte BIC yöntemi ile elde edilen model derecesinin daha iyi bir spektrum kestirimi sağladığı görülmektedir. CAT yönteminin model derecesini olması gerekenden çok düşük olarak seçtiği ve bu sebeple çok düz bir spektrum ortaya çıktığı gözlenmektedir. KIC ve AIC yöntemleriyle elde edilen model derecesinin oldukça yüksek olduğu için yanıltıcı tepeler oluşturduğu görülmektedir. BIC yöntemi ile elde edilen model derecesine göre çizdirilmiş güç yoğunluk spektrumu ve seçilen tepe değerleri Şekil 4.16’da görülmektedir.




Şekil 4.16.BIC Yöntemine Göre Elde Edilen Güç Yoğunluk Spektrumu




Şekil 4.17.Set D için Elde Edilen Güç Yoğunluk Spektrumu

Şekil 4.17’de, Set D’deki EEG verisi için, model belirleme yöntemleri kullanılarak elde edilen model derecelerine göre, güç yoğunluk spektrumları Burg yöntemi ile hesaplanarak çizdirilmiştir. Elde edilen grafikte KIC yöntemi ile elde edilen model derecesinin daha iyi bir spektrum kestirimi sağladığı görülmektedir. BIC ve CAT yöntemleriyle elde edilen model derecelerinin oldukça düşük olması sebebiyle oldukça düz bir spektrum oluştuğu görülmektedir. KIC yöntemi ile elde edilen model derecesine göre çizdirilmiş güç yoğunluk spektrumu ve seçilen tepe değerleri Şekil 4.18’de görülmektedir.

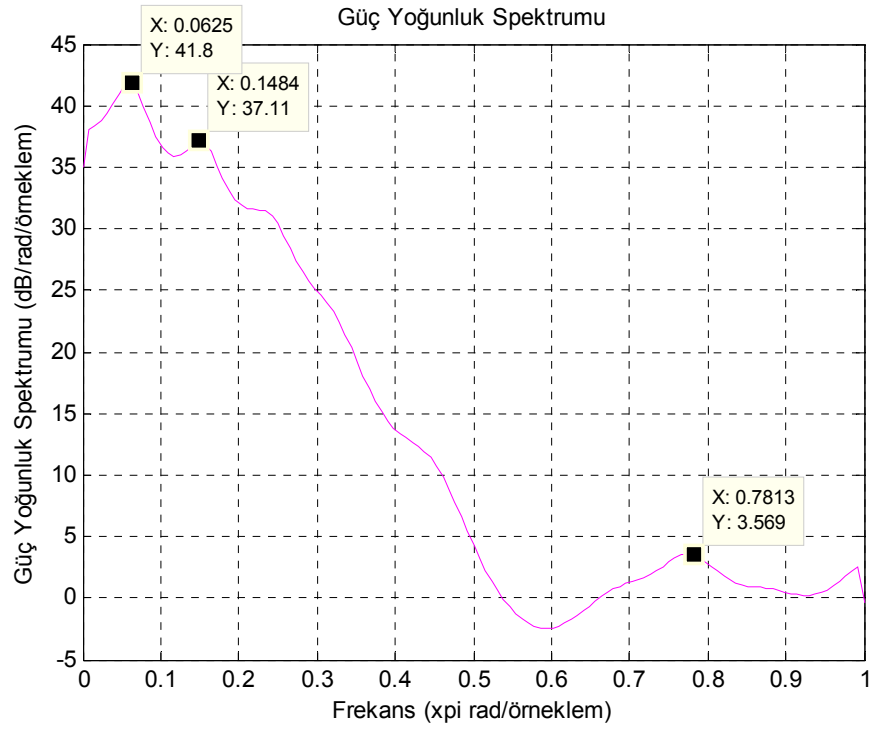


Şekil 4.18.KIC Yöntemine Göre Elde Edilen Güç Yoğunluk Spektrumu



Şekil 4.19.Set E için Elde Edilen Güç Yoğunluk Spektrumu

Şekil 4.19’da, Set E’deki EEG verisi için, model belirleme yöntemleri kullanılarak elde edilen model derecelerine göre, güç yoğunluk spektrumları Burg yöntemi ile hesaplanarak çizdirilmiştir. Elde edilen grafikte KIC yöntemi ile elde edilen model derecesinin daha iyi bir spektrum kestirimi sağladığı görülmektedir. CAT yöntemiyle elde edilen model derecesinin oldukça düşük olduğu için çok düz bir spektrum oluşturduğu görülmektedir. KIC yöntemi ile elde edilen model derecesine göre çizdirilmiş güç yoğunluk spektrumu ve seçilen tepe değerleri Şekil 4.20’de görülmektedir.



Şekil 4.20.KIC Yöntemine Göre Elde Edilen Güç Yoğunluk Spektrumu

Çizelge 4.4'te her set için, uygun görülen model derecesi ile elde edilen güç yoğunluk spektrumlarındaki tepe/frekans değerleri gösterilmektedir.

Çizelge 4.4.Burg Yöntemi ile Elde Edilen Tepe/Frekans Değerleri

(dB/rad/örneklem)/ ( $x\pi$ rad/örneklem)	Tepe1/frekans	Tepe2/frekans	Tepe3/frekans
Set A	2.964/0.5781	-3.499/0.8828	
Set B	34.47/0.125	1.898/0.5781	-2.845/0.875
Set C	-3.645/0.5781		
Set D	39.24/0.007813	1.881/0.5781	
Set E	41.8/0.0625	37.11/0.1484	3.569/0.7813

## BÖLÜM 5

### 5. SONUÇ

#### 5.1 Sonuç

Bu tez çalışmasında [29] çalışmasındaki veri tabanı kullanılarak EEG sinyallerinin güç yoğunluk spektrumu kestirimleri hesaplanmıştır. Eldeki veri tabanındaki EEG verileri 5 setten oluşmaktadır, her bir sette 5 kişiye ait EEG verileri vardır ve ayrıca bu her 5 kişiden 20 kayıt alınmıştır. Kullanılan veri tabanında, Set A, sağlıklı kişilerden uyanık durumda gözleri açıkken ve Set B yine aynı kişilerden uyanık durumda gözleri kapalıyken alınan EEG verisini içerir. Set C ve Set D ise derin elektrotlar kullanılarak kontrol altındaki epilepsi hastalarından alınan ve nöbet olmayan durumda kaydedilen EEG verisine sahiptir. Set D verisi epileptik bölgeden alınarak kaydedilmiştir ve Set C ise beynin diğer lobunun hippocampusla ilgili dizilim (ing: hippocampal formation) kısmından alınan ölçümlerle kaydedilmiştir. Set E ise epilepsi hastalarından alınan ve nöbet sırasında kaydedilen EEG verisini içerir.

Her setteki EEG verisi için AR yöntemi kullanılarak güç yoğunluk spektrumu kestirimi yapılmıştır. AR modelinde kestirim yöntemi olarak Yule-Walker ve Burg yöntemleri kullanılmıştır. AR yönteminde iyi bir spektral analiz yapabilmek için, model derecesini belirlemek çok önemli bir faktördür. Çok yüksek model dereceleri güç yoğunluk spektrumunda gerçekte var olmayan tepe değerleri oluştururken, çok düşük değerler çok düz bir spektrum oluşturarak spektrumdan öznelik çıkarılmasını engellemektedir. Model derecesi belirlenirken, AIC, MDL, FPE, CAT, BIC ve KIC yöntemleri kullanılmıştır.

Yule-Walker yöntemi kullanıldığında tüm set ve tüm yöntemler için elde edilen model dereceleri, Burg yöntemi kullanıldığında elde edilenlere göre daha düşük değerlere sahiptir. Yule-Walker yöntemi ile hesaplanan güç yoğunluk spektrumları için, AIC ve FPE aynı sonuçları verirken, BIC ve MDL yöntemleri de birbirleriyle

aynı model derecesi değerlerini üretmişlerdir. Burg yöntemi ile hesaplanan güç yoğunluk spektrumları için, BIC ve MDL yöntemleri birbirleriyle aynı model derecesi değerlerini verirken, AIC ve FPE birbirlerine yakım model derecesi değerleri üretmişlerdir.

Burg ve Yule –Walker yöntemlerinin kullanıldığı her iki durum için, tüm model derecesi belirleme yöntemleri en düşük model derecesi değerlerini Set E'deki EEG verisi için elde etmişlerdir. Her set için en yüksek değerler AIC ve FPE, en düşük değerler ise CAT yöntemleri ile elde edilmiştir. Her bir yöntem, her bir set için farklı sonuçlar vermiştir, elde edilen model derecesinin eldeki sinyal verisinin karakteristiğine bağlı olarak değiştiği gözlenmiştir.

Yule-Walker yönteminin kullanıldığı durumda, Set A için BIC Set B için CAT, Set C için KIC, Set D için KIC ve Set E için BIC yöntemleri en uygun model derecelerini üretmişlerdir. Burg yönteminin kullanıldığı durumda ise, Set A için FPE, Set B için CAT, Set C için BIC, Set D için KIC ve Set E için KIC yöntemleri en uygun model derecelerini üretmişleridir.

Yule-Walker ve Burg yöntemleri için, epileptik nöbet sırasında kaydedilen EEG kaydı (Set E) dışındaki tüm setlerde  $0.5781\pi$  radyan/örneklem frekansında belirgin tepeler oluştuğu gözlenmiştir. Yule-Walker için, Set E'deki tepeler daha düşük frekanslarda görülmektedir. Hastalıklı ve epileptik nöbet olmayan durumda kaydedilen EEG verilerinin (Set C ve D)  $0.5781\pi$  radyan/örneklem frekansındaki genliği, sağlıklı EEG kayıtlarındakilere (Set A ve B) göre daha düşüktür.



## **6. GELECEK ÇALIŞMALAR**

MA, ARMA ve diğler AR yöntemler (En küçük kareler, Kovaryans, Modifiye Kovaryans, Maksimum olabilirlik) kullanılarak epileptik EEG verileri incelenebilir. Tepe deęerleri, güç yoğunluk spektrumlarındaki tüm deęerler ya da AR kat sayıları kullanılarak yapay sinir aęları eğitilebilir ve EEG kayıtlarının sınıflandırma işlemi gerçekleştirilebilir.

## 7. MATLAB KODLARI

### Ana Program

```
clear all
close all
load S001.txt;load S002.txt;load S003.txt;load S004.txt;load
S005.txt; load S006.txt; load S007.txt;load S008.txt;load
S009.txt;load S010.txt; load S011.txt;load S012.txt;load S013.txt;
load S014.txt;load S015.txt; load S016.txt;load S017.txt;load
S018.txt;load S019.txt;load S020.txt;load S021.txt;load
S022.txt;load S023.txt;load S024.txt;load S025.txt;
load S026.txt;load S027.txt;load S028.txt;load S029.txt;load
S030.txt;load S031.txt;load S032.txt;load S033.txt;load
S034.txt;load S035.txt;load S036.txt;load S037.txt;load
S038.txt;load S039.txt;load S040.txt;load S041.txt;load
S042.txt;load S043.txt;load S044.txt;load S045.txt;load
S046.txt;load S047.txt;load S048.txt;load S049.txt;load S050.txt;
load S051.txt;load S052.txt;load S053.txt;load S054.txt;load
S055.txt;load S056.txt;load S057.txt;load S058.txt;load
S059.txt;load S060.txt;load S061.txt;load S062.txt;load
S063.txt;load S064.txt;load S065.txt;load S066.txt;load
S067.txt;load S068.txt;load S069.txt;load S070.txt;load
S071.txt;load S072.txt;load S073.txt;load S074.txt;load S075.txt;
load S076.txt; load S077.txt; load S078.txt; load S079.txt;load
S080.txt;load S081.txt;load S082.txt;load S083.txt;load
S084.txt;load S085.txt;load S086.txt;load S087.txt;load
S088.txt;load S089.txt;load S090.txt;load S091.txt;load
S092.txt;load S093.txt;load S094.txt;load S095.txt;load
S096.txt;load S097.txt;load S098.txt;load S099.txt;load S100.txt;

load Z001.txt;load Z002.txt; load Z003.txt;load Z004.txt;load
Z005.txt;load Z006.txt;load Z007.txt;load Z008.txt;load
Z009.txt;load Z010.txt;load Z011.txt;load Z012.txt;load
Z013.txt;load Z014.txt;load Z015.txt; load Z016.txt;load
Z017.txt;load Z018.txt;load Z019.txt;load Z020.txt;load
Z021.txt;load Z022.txt;load Z023.txt;load Z024.txt;load Z025.txt;
load Z026.txt;load Z027.txt;load Z028.txt;load Z029.txt;load
Z030.txt;load Z031.txt;load Z032.txt;load Z033.txt;load
Z034.txt;load Z035.txt;load Z036.txt;load Z037.txt;load
Z038.txt;load Z039.txt;load Z040.txt;load Z041.txt;load
Z042.txt;load Z043.txt;load Z044.txt;load Z045.txt;load
Z046.txt;load Z047.txt;load Z048.txt;load Z049.txt;load Z050.txt;
load Z051.txt;load Z052.txt;load Z053.txt;load Z054.txt;load
Z055.txt; load Z056.txt;load Z057.txt;load Z058.txt;load
Z059.txt;load Z060.txt;load Z061.txt;load Z062.txt;load
Z063.txt;load Z064.txt;load Z065.txt;load Z066.txt;load
Z067.txt;load Z068.txt;load Z069.txt;load Z070.txt;load
Z071.txt;load Z072.txt;load Z073.txt;load Z074.txt;load Z075.txt;
load Z076.txt; load Z077.txt; load Z078.txt;load Z079.txt;load
Z080.txt;load Z081.txt;load Z082.txt;load Z083.txt;load
Z084.txt;load Z085.txt;load Z086.txt;load Z087.txt;load
Z088.txt;load Z089.txt;load Z090.txt;load Z091.txt;load
```

Z092.txt;load Z093.txt;load Z094.txt;load Z095.txt;load  
Z096.txt;load Z097.txt;load Z098.txt;load Z099.txt;load Z100.txt;

load F001.txt;load F002.txt;load F003.txt;load F004.txt;load  
F005.txt;load F006.txt;load F007.txt;load F008.txt;load  
F009.txt;load F010.txt;load F011.txt;load F012.txt;load  
F013.txt;load F014.txt;load F015.txt;load F016.txt;load  
F017.txt;load F018.txt;load F019.txt;load F020.txt;load  
F021.txt;load F022.txt;load F023.txt;load F024.txt;load F025.txt;  
load F026.txt;load F027.txt;load F028.txt;load F029.txt; load  
F030.txt; load F031.txt; load F032.txt; load F033.txt; load  
F034.txt;load F035.txt; load F036.txt; load F037.txt; load F038.txt;  
load F039.txt; load F040.txt; load F041.txt;load F042.txt;load  
F043.txt;load F044.txt;load F045.txt;load F046.txt;load  
F047.txt;load F048.txt;load F049.txt;load F050.txt;  
load F051.txt;load F052.txt;load F053.txt;load F054.txt;load  
F055.txt;load F056.txt;load F057.txt;load F058.txt; load  
F059.txt;load F060.txt;load F061.txt;load F062.txt;load  
F063.txt;load F064.txt;load F065.txt;load F066.txt;load  
F067.txt;load F068.txt;load F069.txt;load F070.txt;load  
F071.txt;load F072.txt;load F073.txt;load F074.txt;load F075.txt;  
load F076.txt;load F077.txt;load F078.txt;load F079.txt;load  
F080.txt;load F081.txt;load F082.txt;load F083.txt;load  
F084.txt;load F085.txt;load F086.txt;load F087.txt;load  
F088.txt;load F089.txt;load F090.txt;load F091.txt;load  
F092.txt;load F093.txt;load F094.txt;load F095.txt;load  
F096.txt;load F097.txt;load F098.txt;load F099.txt;load F100.txt;

load N001.txt;load N002.txt;load N003.txt;load N004.txt;load  
N005.txt;load N006.txt;load N007.txt;load N008.txt;load  
N009.txt;load N010.txt;load N011.txt;load N012.txt;load  
N013.txt;load N014.txt;load N015.txt;load N016.txt;load  
N017.txt;load N018.txt;load N019.txt;load N020.txt;load  
N021.txt;load N022.txt;load N023.txt;load N024.txt;load N025.txt;  
load N026.txt;load N027.txt;load N028.txt;load N029.txt;load  
N030.txt;load N031.txt;load N032.txt;load N033.txt;load  
N034.txt;load N035.txt;load N036.txt;load N037.txt;load  
N038.txt;load N039.txt;load N040.txt;load N041.txt;load  
N042.txt;load N043.txt;load N044.txt;load N045.txt;load  
N046.txt;load N047.txt;load N048.txt;load N049.txt;load N050.txt;  
load N051.txt;load N052.txt;load N053.txt;load N054.txt;load  
N055.txt;load N056.txt;load N057.txt;load N058.txt;load  
N059.txt;load N060.txt;load N061.txt;load N062.txt;load  
N063.txt;load N064.txt;load N065.txt;load N066.txt;load  
N067.txt;load N068.txt;load N069.txt;load N070.txt;load  
N071.txt;load N072.txt;load N073.txt;load N074.txt;load N075.txt;  
load N076.txt;load N077.txt;load N078.txt;load N079.txt;load  
N080.txt;load N081.txt;load N082.txt;load N083.txt; load  
N084.txt;load N085.txt;load N086.txt;load N087.txt;load  
N088.txt;load N089.txt;load N090.txt;load N091.txt;load  
N092.txt;load N093.txt;load N094.txt;load N095.txt;load  
N096.txt;load N097.txt;load N098.txt;load N099.txt;load N100.txt;

load O001.txt;load O002.txt;load O003.txt;load O004.txt;load  
O005.txt;load O006.txt;load O007.txt;load O008.txt;load  
O009.txt;load O010.txt;load O011.txt;load O012.txt;load  
O013.txt;load O014.txt;load O015.txt;load O016.txt;load

```

0017.txt;load 0018.txt;load 0019.txt;load 0020.txt;load
0021.txt;load 0022.txt;load 0023.txt;load 0024.txt;load 0025.txt;
load 0026.txt;load 0027.txt;load 0028.txt;load 0029.txt;load
0030.txt;load 0031.txt;load 0032.txt;load 0033.txt;load
0034.txt;load 0035.txt;load 0036.txt;load 0037.txt;load
0038.txt;load 0039.txt;load 0040.txt;load 0041.txt;load
0042.txt;load 0043.txt;load 0044.txt;load 0045.txt;load
0046.txt;load 0047.txt;load 0048.txt;load 0049.txt;load 0050.txt;
load 0051.txt;load 0052.txt;load 0053.txt;load 0054.txt;load
0055.txt;load 0056.txt;load 0057.txt;load 0058.txt;load
0059.txt;load 0060.txt;load 0061.txt;load 0062.txt;load
0063.txt;load 0064.txt;load 0065.txt;load 0066.txt;load
0067.txt;load 0068.txt;load 0069.txt;load 0070.txt;load
0071.txt;load 0072.txt;load 0073.txt;load 0074.txt;load 0075.txt;
load 0076.txt;load 0077.txt;load 0078.txt;load 0079.txt;load
0080.txt;load 0081.txt;load 0082.txt;load 0083.txt;load
0084.txt;load 0085.txt;load 0086.txt;load 0087.txt;load
0088.txt;load 0089.txt;load 0090.txt;load 0091.txt;load
0092.txt;load 0093.txt;load 0094.txt;load 0095.txt;load 0096.txt;
load 0097.txt;load 0098.txt;load 0099.txt;load 0100.txt;

```

```
% SET A
```

```

A1=(Z001+Z002+Z003+Z004+Z005+Z006+Z007+Z008+Z009+Z010+
Z011+Z012+Z013+Z014+Z015+Z016+Z017+Z018+Z019+Z020)/20;
A2=(Z021+Z022+Z023+ Z024+ Z025+Z026+Z027+ Z028+ Z029+Z030+
Z031+Z032+ Z033+Z034+Z035+ Z036+Z037+Z038+Z039+Z040)/20;
A3=(Z041+Z042+Z043+Z044+Z045+Z046+Z047+Z048+Z049+Z050+Z051+Z052+Z053
+Z054+Z055+Z056+Z057+Z058+Z059+Z060)/20;
A4=(Z061+Z062+ Z063+ Z064+ Z065+Z066+Z067+ Z068+ Z069+ Z070+ Z071+
Z072+Z073+Z074+ Z075+Z076+Z077+ Z078+ Z079+ Z080)/20;
A5=(Z081+ Z082+ Z083+ Z084+ Z085+ Z086+ Z087+ Z088+ Z089+ Z090+
Z091+ Z092+ Z093+ Z094+ Z095+ Z096+ Z097+ Z098+ Z099+ Z100)/20;

```

```
% SET B
```

```

B1=(O001+O002+O003+O004+O005+O006+O007+O008+O009+O010+
O011+O012+O013+O014+O015+O016+O017+O018+O019+O020)/20;
B2=(O021+O022+O023+ O024+ O025+O026+O027+ O028+ O029+O030+
O031+O032+ O033+O034+O035+ O036+O037+O038+O039+O040)/20;
B3=(O041+O042+O043+O044+Z045+O046+O047+O048+O049+O050+O051+O052+O053
+O054+O055+O056+O057+O058+O059+O060)/20;
B4=(O061+O062+ O063+ O064+ O065+O066+O067+ O068+ O069+ O070+ O071+
O072+O073+O074+ O075+O076+O077+ O078+ O079+ O080)/20;
B5=(O081+ O082+ O083+ O084+ O085+ O086+ O087+ O088+ O089+ O090+
O091+ O092+ O093+ O094+ O095+ O096+ O097+ O098+ O099+ O100)/20;

```

```
% SET C
```

```

C1=(N001+N002+N003+N004+N005+N006+N007+N008+N009+N010+
N011+N012+N013+N014+N015+N016+N017+N018+N019+N020)/20;

```

```

C2=(N021+N022+N023+ N024+ N025+N026+N027+ N028+ N029+N030+
N031+N032+ N033+N034+N035+ N036+N037+N038+N039+N040)/20;
C3=(N041+N042+N043+N044+N045+N046+N047+N048+N049+N050+N051+N052+N053
+N054+N055+N056+N057+N058+N059+N060)/20;
C4=(N061+N062+ N063+ N064+ N065+N066+N067+ N068+ N069+ N070+ N071+
N072+N073+N074+ N075+N076+N077+ N078+ N079+ N080)/20;
C5=(N081+ N082+ N083+ N084+ N085+ N086+ N087+ N088+ N089+ N090+
N091+ N092+ N093+ N094+ N095+ N096+ N097+ N098+ N099+ N100)/20;

% SET D

D1=(F001+F002+F003+F004+F005+F006+F007+F008+F009+F010+
F011+F012+F013+F014+F015+F016+F017+F018+F019+F020)/20;
D2=(F021+F022+F023+ F024+ F025+F026+F027+ F028+ F029+F030+
F031+F032+ F033+F034+F035+ F036+F037+F038+F039+F040)/20;
D3=(F041+F042+F043+F044+F045+F046+F047+F048+F049+F050+F051+F052+F053
+F054+F055+F056+F057+F058+F059+F060)/20;
D4=(F061+F062+ F063+ F064+ F065+F066+F067+ F068+ F069+ F070+ F071+
F072+F073+F074+ F075+F076+F077+ F078+ F079+ F080)/20;
D5=(F081+ F082+ F083+ F084+ F085+ F086+ F087+ F088+ F089+ F090+
F091+ F092+ F093+ F094+ F095+ F096+ F097+ F098+ F099+ F100)/20;

% SET E

E1=(S001+S002+S003+S004+S005+S006+S007+S008+S009+S010+
S011+S012+S013+S014+S015+S016+S017+S018+S019+S020)/20;
E2=(S021+S022+S023+ S024+ S025+S026+S027+ S028+ S029+S030+
S031+S032+ S033+S034+S035+ S036+S037+S038+S039+S040)/20;
E3=(S041+S042+S043+S044+S045+S046+S047+S048+S049+S050+S051+S052+S053
+S054+S055+S056+S057+S058+S059+S060)/20;
E4=(S061+S062+ S063+ S064+ S065+S066+S067+ S068+ S069+ S070+ S071+
S072+S073+S074+ S075+S076+S077+ S078+ S079+ S080)/20;
E5=(S081+ S082+ S083+ S084+ S085+ S086+ S087+ S088+ S089+ S090+
S091+ S092+ S093+ S094+ S095+ S096+ S097+ S098+ S099+ S100)/20;

global N fic
N=length(Z001);
%% Yule-Walker
%A1
or_A1=FPE(A1);
[psd_A1,f_A1]=pburg(A1,or_A1);%PSD
[a_A1,var_A1]=arburg(A1,or_A1);% AR COEFFICIENTS
Alpsd = dspdata.psd(psd_A1,f_A1);
% figure
% plot(Alpsd)

%A2
or_A2=FPE(A2);
[psd_A2,f_A2]=pburg(A2,or_A2);%PSD
[a_A2,var_A2]=arburg(A2,or_A2);% AR COEFFICIENTS
A2psd = dspdata.psd(psd_A2,f_A2);
% figure
% plot(A2psd)

%A3
or_A3=FPE(A3);

```

```

[psd_A3,f_A3]=pburg(A3,or_A3);%PSD
[a_A3,var_A3]=arburg(A3,or_A3);% AR COEFFICIENTS
A3psd = dspdata.psd(psd_A3,f_A3);
% figure
% plot(A3psd)

%A4
or_A4=FPE(A4);
[psd_A4,f_A4]=pburg(A4,or_A4);%PSD
[a_A4,var_A4]=arburg(A4,or_A4);% AR COEFFICIENTS
A4psd = dspdata.psd(psd_A4,f_A4);
% figure
% plot(A4psd)

%A5
or_A5=FPE(A5);
[psd_A5,f_A5]=pburg(A5,or_A5); %PSD
[a_A5,var_A5]=arburg(A5,or_A5);% AR COEFFICIENTS
A5psd = dspdata.psd(psd_A5,f_A5);
% figure
% plot(A5psd)

or_A=(or_A1+or_A2+or_A3+or_A4+or_A5)/5;

%B1
or_B1=FPE(B1);
[psd_B1,f_B1]=pburg(B1,or_B1);%PSD
[a_B1,var_B1]=arburg(B1,or_B1);% AR COEFFICIENTS
B1psd = dspdata.psd(psd_B1,f_B1);
% figure
% plot(B1psd)

%B2
or_B2=FPE(B2);
[psd_B2,f_B2]=pburg(B2,or_B2);%PSD
[a_B2,var_B2]=arburg(B2,or_B2);% AR COEFFICIENTS
B2psd = dspdata.psd(psd_B2,f_B2);
% figure
% plot(B2psd)

%B3
or_B3=FPE(B3);
[psd_B3,f_B3]=pburg(B3,or_B3);%PSD
[a_B3,var_B3]=arburg(B3,or_B3);% AR COEFFICIENTS
B3psd = dspdata.psd(psd_B3,f_B3);
% figure
% plot(B3psd)

%B4
or_B4=FPE(B4);
[psd_B4,f_B4]=pburg(B4,or_B4);%PSD
[a_B4,var_B4]=arburg(B4,or_B4);% AR COEFFICIENTS
B4psd = dspdata.psd(psd_B4,f_B4);
% figure
% plot(B4psd)

```

```

%B5
or_B5=FPE(B5);
[psd_B5,f_B5]=pburg(B5,or_B5); %PSD
[a_B5,var_B5]=arburg(B5,or_B5);% AR COEFFICIENTS
B5psd = dspdata.psd(psd_B5,f_B5);
% figure
% plot(B5psd)

or_B=(or_B1+or_B2+or_B3+or_B4+or_B5)/5;

%C1
or_C1=FPE(C1);
[psd_C1,f_C1]=pburg(C1,or_C1);%PSD
[a_C1,var_C1]=arburg(C1,or_C1);% AR COEFFICIENTS
C1psd = dspdata.psd(psd_C1,f_C1);
% figure
% plot(C1psd)

%C2
or_C2=FPE(C2);
[psd_C2,f_C2]=pburg(C2,or_C2);%PSD
[a_C2,var_C2]=arburg(C2,or_C2);% AR COEFFICIENTS
C2psd = dspdata.psd(psd_C2,f_C2);
% figure
% plot(C2psd)

%C3
or_C3=FPE(C3);
[psd_C3,f_C3]=pburg(C3,or_C3);%PSD
[a_C3,var_C3]=arburg(C3,or_C3);% AR COEFFICIENTS
C3psd = dspdata.psd(psd_C3,f_C3);
% figure
% plot(C3psd)

%C4
or_C4=FPE(C4);
[psd_C4,f_C4]=pburg(C4,or_C4);%PSD
[a_C4,var_C4]=arburg(C4,or_C4);% AR COEFFICIENTS
C4psd = dspdata.psd(psd_C4,f_C4);
% figure
% plot(C4psd)

%C5
or_C5=FPE(C5);
[psd_C5,f_C5]=pburg(C5,or_C5); %PSD
[a_C5,var_C5]=arburg(C5,or_C5);% AR COEFFICIENTS
C5psd = dspdata.psd(psd_C5,f_C5);
% figure
% plot(C5psd)

or_C=(or_C1+or_C2+or_C3+or_C4+or_C5)/5;

```

```

%D1
or_D1=FPE(D1);
[psd_D1,f_D1]=pburg(D1,or_D1);%PSD
[a_D1,var_D1]=arburg(D1,or_D1);% AR COEFFICIENTS
D1psd = dspdata.psd(psd_D1,f_D1);
% figure
% plot(D1psd)

%D2
or_D2=FPE(D2);
[psd_D2,f_D2]=pburg(D2,or_D2);%PSD
[a_D2,var_D2]=arburg(D2,or_D2);% AR COEFFICIENTS
D2psd = dspdata.psd(psd_D2,f_D2);
% figure
% plot(D2psd)

%D3
or_D3=FPE(D3);
[psd_D3,f_D3]=pburg(D3,or_D3);%PSD
[a_D3,var_D3]=arburg(D3,or_D3);% AR COEFFICIENTS
D3psd = dspdata.psd(psd_D3,f_D3);
% figure
% plot(D3psd)

%D4
or_D4=FPE(D4);
[psd_D4,f_D4]=pburg(D4,or_D4);%PSD
[a_D4,var_D4]=arburg(D4,or_D4);% AR COEFFICIENTS
D4psd = dspdata.psd(psd_D4,f_D4);
% figure
% plot(D4psd)

%D5
or_D5=FPE(D5);
[psd_D5,f_D5]=pburg(D5,or_D5); %PSD
[a_D5,var_D5]=arburg(D5,or_D5);% AR COEFFICIENTS
D5psd = dspdata.psd(psd_D5,f_D5);
% figure
% plot(D5psd)

or_D=(or_D1+or_D2+or_D3+or_D4+or_D5)/5;

%E1
or_E1=FPE(E1);
[psd_E1,f_E1]=pburg(E1,or_E1);%PSD
[a_E1,var_E1]=arburg(E1,or_E1);% AR COEFFICIENTS

```



```

Elpsd = dspdata.psd(psd_E1,f_E1);
% figure
% plot(E1psd)

%E2
or_E2=FPE(E2);
[psd_E2,f_E2]=pburg(E2,or_E2);%PSD
[a_E2,var_E2]=arburg(E2,or_E2);% AR COEFFICIENTS
E2psd = dspdata.psd(psd_E2,f_E2);
% figure
% plot(E2psd)

%E3
or_E3=FPE(E3);
[psd_E3,f_E3]=pburg(E3,or_E3);%PSD
[a_E3,var_E3]=arburg(E3,or_E3);% AR COEFFICIENTS
E3psd = dspdata.psd(psd_E3,f_E3);
% figure
% plot(E3psd)

%E4
or_E4=FPE(E4);
[psd_E4,f_E4]=pburg(E4,or_E4);%PSD
[a_E4,var_E4]=arburg(E4,or_E4);% AR COEFFICIENTS
E4psd = dspdata.psd(psd_E4,f_E4);
% figure
% plot(E4psd)

%E5
or_E5=FPE(E5);
[psd_E5,f_E5]=pburg(E5,or_E5); %PSD
[a_E5,var_E5]=arburg(E5,or_E5);% AR COEFFICIENTS
E5psd = dspdata.psd(psd_E5,f_E5);
% figure
% plot(E5psd)

or_E=(or_E1+or_E2+or_E3+or_E4+or_E5)/5;

or_A=round(or_A);
or_B=round(or_B);
or_C=round(or_C);
or_D=round(or_D);
or_E=round(or_E);

```

## AIC fonksiyonu

```
function order = aAIC(data)
global N
[a1,var1] = arburg(data,1);
aic=zeros(1,200);
min=log(var1)+2*1/N;
for or=1:1:200
[a,var] = arburg(data,or);
aic(or)=log(var)+2*or/N;

    if aic(or)<min
min=aic(or);
end
end

for or=1:200
    if aic(or)==min
        order=or;
    end
end
end
```

## MDL Fonksiyonu

```
function order = MDL(data)
global N
[a1,var1] = arburg(data,1);
min=N*log(var1)+1*log(N);
mdl=zeros(1,200);

for or=1:1:200
[a,var] = arburg(data,or);
mdl(or)=N*log(var)+or*log(N);
%mdl=-log(var)+0.5*or*(log(N));
    if mdl(or)<min
min=mdl(or);
end
end

for or=1:200
    if mdl(or)==min
        order=or;
    end
end
end
```

## FPE Fonksiyonu

```
function order = FPE(data)
global N
[a1,var1] = arburg(data,1);
fpe=zeros(1,200);
min=var1*(N+1+1)/(N-1-1);

for or=1:1:200
    [a,var] = arburg(data,or);
    fpe(or)=var*(N+or+1)/(N-or-1);
    if fpe(or)<min
        min=fpe(or);
    end
end

for or=1:200
    if fpe(or)==min
        order=or;
    end
end
```

## CAT Fonksiyonu

```
function order = CAT(data)
global N
[a1,var1] = arburg(data,1);
min=( ( (N-1)/(N*var1) )/N ) - ((N-1)/(N*var1));
cat=zeros(1,200);
suum=0;
for or=1:1:200
    [a,var] = arburg(data,or);
    for i=1:or
        [ai,vari] = arburg(data,i);
        suum=suum+(N-i)/(N*vari);
    end
    cat(or)=(suum/N) - ( (N-or)/(N*var) );

    if cat(or)<min
        min=cat(or);
    end
end
for or=1:200
    if cat(or)==min
        order=or;
    end
end
```

```
end  
end
```

### BIC Fonksiyonu

```
function order = BIC(data)  
global N  
[a1,var1] = arburg(data,1);  
min=log(var1)+log(N)/N;  
bic=zeros(1,200);  
for or=1:1:200  
    [a,var] = arburg(data,or);  
    bic(or)=log(var)+((or*log(N))/N);  
    if bic(or)<min  
        min=bic(or);  
    end  
end  
  
for or=1:200  
    if bic(or)==min  
        order=or;  
    end  
end
```

### KIC Fonksiyonu

```
function order = KIC(data)  
global N  
[a1,var1] = arburg(data,1);  
    min=log(var1)+(3)/N;  
    kic=zeros(1,200);  
for or=1:1:200  
    [a,var] = arburg(data,or);  
    kic(or)=log(var)+((3*or)/N);  
  
    if kic(or)<min  
        min=kic(or);  
    end  
end  
  
for or=1:200  
    if kic(or)==min  
        order=or;  
    end  
end
```

## KAYNAKLAR

- [1] Niknazar, M., Mousavi, S.R., Vosoughi Vahdat, B., Shamsollahi, M.B., Sayyah, M., A New Dissimilarity Index of EEG Signals for Epileptic Seizure Detection, Proceedings of the 4th International Symposium on Communications, Control and Signal Processing, ISCCSP 2010, 1 – 5, Limassol, cyprus, Mart 2010
- [2] Dahanayake, B.W., Upton, A.R.M., A Novel Approach for Epileptic Seizure Detection, Proceedings 1994 IEEE Seventh Symposium on Computer-Based Medical Systems, 188 – 193, Winston-Salem, NC , USA, Haziran 1994
- [3] Ganesan, M., Sathidevi, P.S., Indiradevi, K.P., A novel approach for the analysis of epileptic spikes in EEG, International Conference on Computational Intelligence and Multimedia Applications, 297 – 312, Sivakasi, Tamil Nadu, Aralık 2007
- [4] Yuan, Y., Li, Y., Yu, L., Guo, H., Analysis of Nonlinearity in Normal and Epileptic EEG Signals, 9th International Conference on Signal Processing (ICSP 2008), 2162 – 2165, Beijing, Ekim 2008
- [5] Yamaguchi, C., Fourier and Wavelet Analyses of Normal and Epileptic Electroencephalogram (EEG), Proc. First International IEEE EMBS Conference on Neural Engineering, 406 – 409, Capri Island, Italy, Mart 2003
- [6] Padmasai, Y., SubbaRao, K., Malini, V., Rao, C.R., Linear Prediction Modelling for the Analysis of the Epileptic EEG, International Conference on Advances in Computer Engineering (ACE), 6 – 9, Bangalore, Haziran 2010
- [7] Faust, O., Acharya, R.U., Allen, A.R., Lin, C.M., Analysis of EEG signals during epileptic and alcoholic states using AR modeling techniques, Innovations and Technology in Biology and Medicine (ITBM-RBM), 29(1), 44-52, 2008.
- [8] Aklin, O., Study of Model-Order Selection Algorithms and Their Applicability to Adaptive Clutter Suppression, Southeastcon '88., IEEE Conference Proceedings , 55 - 60 , Knoxville, TN , USA, Nisan 1988
- [9] Vanderschoot, J., Kappeyne, N.G.J., Schreur, H.J.W., AR Model Orders of Lung Sounds, Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society, 2531 – 2532, Kasım 1992
- [10] Boardman, A., Schindwein, F.S., Rocha, A.P., Leite, A., A study on the optimum order of autoregressive models for heart rate variability, Physiological Measurement, 23 (2), 325-336, 2002
- [11] Karimi, M., Finite Sample AIC for Autoregressive Model Order Selection, Proc. IEEE International Conference on Signal Processing and Communications, 24-27, Dubai, United Arab Emirates, Kasım 2007.

- [12] Karimi, M., A Corrected FPE Criterion for Autoregressive Processes, 15th European Signal Processing Conference, 803-806, Poznan, Poland, Eylül 2007
- [13] Khorshidi, S., Karimi, M., Modified AIC and FPE Criteria for Autoregressive (AR) Model Order Selection by Using LSFB Estimation Method, International Conference on Advances in Computational Tools for Engineering Applications, ACTEA, 374 - 379, Zouk Mosbeh, Temmuz 2009
- [14] Xiao-dan, D., Yu-Ming, D., Tao, Y., Rong, L., Evaluation of AR Model Order Selection Approaches, International Forum on Information Technology and Applications, IFITA, 704 – 707, Chengdu, Mayıs 2009
- [15] Burshtein, D., Weinstein, E., Some Relations Between the Various Criteria for Autoregressive Model Order Determination, IEEE Transactions on Acoustics, Speech and Signal Processing, 33(4), 1017 – 1019, Ağustos 1985
- [16] Lichun, L., An Empirical Formula for Selection of AR model Order, IEEE Antennas and Propagation Society International Symposium, 97 – 100, Haziran 2003
- [17] Krusienski, D.J., McFarland, D.J., Wolpaw, J.R., An Evaluation of Autoregressive Spectral Estimation Model Order for Brain-Computer Interface Applications, 1323–1326, New York, USA, Ağustos-Eylül 2006
- [18] McFarland, D.J., Wolpaw, J.R., Sensorimotor rhythm-based brain-computer interface (BCI): model order selection for autoregressive spectral analysis, Journal of Neural Engineering , 5(2), 155–162, Haziran 2008
- [19] Simpson, D.M., Infantosi, A.F.C., Junior, J.F.C., Peixoto, A.J., Abrantes, L.M.deS., On the selection of autoregressive order for electroencephalographic (EEG) signals, Proceedings of the 38th Midwest Symposium on Circuits and Systems, 1353 – 1356, Rio de Janeiro, Ağustos 1995
- [20] Palaniappan, R., Raveendran, P., Nishida, S., Saiwaki, N., Autoregressive Spectral Analysis and Model Order Selection Criteria for EEG Signals, TENCON 2000. Proceedings, 126 – 129, Kuala Lumpur , Malaysia, Eylül 2000
- [21] Palaniappan, R., Raveendran, P., Nishida, S., Saiwaki, N., Evolutionary fuzzy ARTMAP for autoregressive model order selection and classification of EEG signals, 2000 IEEE International Conference on Systems, Man, and Cybernetics, 3682 – 3686, Nashville, TN , USA, Ekim 2000
- [22] Aydın, S., Determination of autoregressive model orders for seizure detection, Turk J Elec Eng & Comp Sci, 18 (1), 23-30, 2010
- [23] Sanei S., Chambers, J.A., EEG Signal Processing, *Wiley*, England, 2007

[24] “EEG”, erişim adresi: <http://www.baskent.edu.tr/~bmeweb/20494316.htm>, erişim tarihi: 12 Şubat 2010

[25] “Elektrofizyolojik Sensörler”, erişim adresi: <http://www.monomermedikal.com/webdoc/sensors/sensorler.htm> erişim tarihi: 12 Şubat 2010.

[26] “Epilepsy”, erişim adresi: <http://en.wikipedia.org/wiki/Epilepsy> , erişim tarihi: 15 Şubat 2010.

[27] “Epilepsi”, erişim adresi: <http://tr.wikipedia.org/wiki/Epilepsi>, erişim tarihi: 15 Şubat 2010.

[28] “Dynamical mechanisms of epileptic transitions”, erişim adresi: [http://brain.fuw.edu.pl/~suffa/Modeling\\_SW.html](http://brain.fuw.edu.pl/~suffa/Modeling_SW.html), erişim tarihi: 16.Şubat 2010.

[29] Andrzejak R.G., Lehnertz K., Mormann F., Rieke C., David P., Elger C.E., 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*, 64, 1-8, 2001.

[30] Kay, S.M., *Modern Spectral Estimation: Theory and Application*, Prentice Hall, Upper Saddle River, New Jersey, 1988

[31] “Spectral Density Estimation”, erişim adresi: [http://en.wikipedia.org/wiki/Spectral\\_density\\_estimation](http://en.wikipedia.org/wiki/Spectral_density_estimation), erişim tarihi: 5 Mart 2010

[32] “Stationary Time Series ”, erişim adresi: <http://www.statistics.com/resources/glossary/s/sttser.php>, erişim tarihi: 10 Nisan 2010

[33] “Time Series”, erişim adresi: [http://en.wikipedia.org/wiki/Time\\_series](http://en.wikipedia.org/wiki/Time_series), erişim tarihi: 15 Nisan 2010

[34] Übeyli, E.D., İnan, G., Cramer-Rao Alt Sınırı ile AR Metodunda Parametre Kestirim Performansının Analizi, *Pliteknik Degisi*, 5 (1), 1-11, 2002

[35] Proakis, J.G., Manolakis, D.G., *Digital Signal Processing: Principles, Algorithms, and Applications*, 4th Ed., *Prentice Hall*, Upper Saddle River, New Jersey, 2007.

[36] Stoica, P., Mose, R., *Introduction to Spectral Analysis*, *Prentice Hall*, Upper Saddle River, New Jersey, 1997.

[37] Mousavi, S.R., Niknazar, M., Vahdat, B.V., Epileptic Seizure Detection using AR Model on EEG Signals, Cairo International Biomedical Engineering Conference, CIBEC , 1 – 4, Cairo, Aralık 2008



## ÖZGEÇMİŞ

### Kişisel Bilgiler

Soyadı, adı : DURAN, Sabahat  
Uyruğu : T.C.  
Doğum tarihi ve yeri : 30.06.1986 İzmit  
Medeni hali : Bekar  
e-mail : [sduran@etu.edu.tr](mailto:sduran@etu.edu.tr)

### Eğitim

Derece	Eğitim Birimi	Mezuniyet tarihi
Lisans	TOBB Ekonomi ve Teknoloji Üniversitesi /Elektrik ve Elektronik Müh.	2008

### İş Deneyimi

Yıl	Yer	Görev
2010-	Türk Havacılık ve Uzay Sanayii A. S.	Asistan Tasarım Mühendisi
2008-2010	TOBB Ekonomi ve Teknoloji Üniversitesi	Araştırma Görevlisi

### Yabancı Dil

İngilizce, Almanca

### Yayımlar

S. Duran, V. Gazi, "Adaptive Formation Control and Target Tracking in a Class of Multi-Agent Systems", American Control Conference (ACC'10), 30 Haziran-2 Temmuz 2010, Baltimore, Maryland, USA

S.Duran, "Implementation of PID, Fuzzy, and Fuzzy-PID Control Strategies on a 2-Dof Manipulator", 1st International Fuzzy Systems Symposium, 1-2 Ekim 2009, Ankara, Türkiye

E. Gül, S. Duran, M. İ. Köksal, A.T.Şamilođlu, V. Gazi, "Sürü Robot Sistemleri Üzerine Bazı Deneysel Çalışmalar", Türk Otomatik Kontrol Konferansı, 13-15 Kasım 2008, İstanbul, Türkiye