

**KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

**YAPAY TOPLAMSALLIK YAKLAŞIMI İLE ANNE VE KARNINDAKİ
ÇOCUĞA AİT EKG İŞARETLERİNİN AYRIŞTIRILMASI**

DOKTORA TEZİ

Elektronik Yük. Müh. Yusuf SEVİM

**AĞUSTOS 2009
TRABZON**

**KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

**YAPAY TOPLAMSALLIK YAKLAŞIMI İLE ANNE VE KARNINDAKİ ÇOCUĞA
AİT EKG İŞARETLERİNİN AYRIŞTIRILMASI**

Elektronik Yüksek Mühendisi Yusuf SEVİM

**Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsünde
“Doktor (Elektronik Mühendisliği)”
Unvanı Verilmesi İçin Kabul Edilen Tezdir.**

**Tezin Enstitüye Verildiği Tarih : 05.06.2009
Tezin Savunma Tarihi : 12.08.2009**

**Tez Danışmanı : Yrd. Doç. Dr. Ayten ATASOY
Jüri Üyesi : Prof. Dr. Tülay YILDIRIM
Jüri Üyesi : Doç. Dr. Temel KAYIKÇIOĞLU
Jüri Üyesi : Yrd. Doç. Dr. İsmail KAYA
Jüri Üyesi : Yrd. Doç. Dr. Cemal KÖSE**

Enstitü Müdürü : Prof. Dr. Salih TERZİOĞLU

Trabzon 2009

ÖNSÖZ

Karadeniz Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Elektrik-Elektronik Mühendisliği Anabilim Dalı, Doktora programı çerçevesinde gerçekleştirilmiş olan bu çalışma, anne karnında bulunan çocuğa ait elektrokardiyogram işaretinin anne işaretinden ve diğer bozucu etkilerden ayrıştırılarak elde edilmesini ele almaktadır.

Öncelikle bu çalışmam esnasında bilgi ve tecrübelerini esirgemeyen danışman hocam Sayın Yrd. Doç. Dr. Ayten ATASOY'ya vermiş olduğu destekten dolayı çok teşekkür ederim.

Tez izleme jürisinde görev alarak çalışmalarına katkıda bulunan hocalarım Doç. Dr. Temel KAYIKÇIOĞLU'na ve Yrd. Doç. Dr. Cemal KÖSE'ye çok teşekkür ederim.

Ayrıca lisans eğitimimden bu yana üzerimde emeği olan Elektrik-Elektronik Mühendisliği bölümündeki bütün hocalarıma bu vesileyle teşekkür ederim.

İhtiyaç duyduğumda benden bilgisini esirgemeyen hocalarım Yrd. Doç. Dr. İsmail KAYA, Yrd. Doç. Dr. Ali ÖZEN'e ve Öğr. Gör. Dr. Yasin OĞUZ'a, vermiş oldukları manevi destekten dolayı arkadaşlarım Ahmet GÜNER, Emre ÖZKOP, Mevlüt TOPALOĞLU ve Oğuzhan ÇAKIR'a en içten duygularıyla şükranlarımı sunarım.

Son olarak, beni bugüne kadar yalnız bırakmayan, maddi ve manevi desteklerini hiçbir zaman esirgemeyen, sevgili annem Habibe SEVİM'e, eşim Nurdan SEVİM'e ve sabrından dolayı kızım Serra SEVİM'e bu vesileyle sevgi ve saygılarımı sunarım.

Yusuf SEVİM
Trabzon 2009

İÇİNDEKİLER

	<u>Sayfa No</u>
ÖNSÖZ	II
İÇİNDEKİLER.....	III
ÖZET.....	VI
SUMMARY	VII
ŞEKİLLER DİZİNİ.....	VIII
TABLolar DİZİNİ	XII
SEMBOLLER DİZİNİ.....	XIII
KISALTMALAR DİZİNİ	XVI
1. GENEL BİLGİLER	1
1.1. Giriş.....	1
1.2. EKG İşareti	2
1.2.1. Kalp Atımı Oranı Değişimi (HRV).....	5
1.2.2. Anne Karnındaki Fetusun EKG İşareti (FEKG).....	6
1.2.3. EKG Gürültüleri.....	8
1.2.4. Tek Dipol Model	8
1.3. Dinamik Model	10
1.4. Olasılık Yoğunluk Fonksiyonu Kestirim Yöntemleri	15
1.4.1. Kernel Yoğunluk Fonksiyon Tahmin Yöntemi	17
1.5. Bilgi Teorisi	21
1.5.1. Relatif Entropi (Diverjans).....	24
1.6. Bağımsız Bileşen Analiz Algoritmaları (BBA)	24
1.6.1. İlinti ve Bağımsızlık.....	26
1.6.2. KKA Problemi ve BBA Algoritma İlişkisi	28
1.6.3. BBA Algoritmasında Kaynak İşaret Sayısı ve Sensör Sayı Bağlantısı.....	30
1.6.4. Bilgi Teorisi ve BBA Algoritma İlişkisi	31
1.6.5. BBA Algoritmalarında Ön İşlemler	34
1.7. Temel Bileşen Analiz (TBA)	34
1.8. Negentropi ve Hızlı BBA.....	37
1.9. Geometrik BBA Algoritması	41
1.9.1. Geometrik Öğrenme Algoritması.....	43
1.10. Özdeğer Matrislerinin Birleşik Köşegenselleştirilmesi (ÖMBK).....	44

1.11.	Parametrik Olmayan Olasılık Yoğunluk Tahminine Dayalı BBA Algoritması....	48
1.11.1.	Parametrik Olmayan Olasılık Yoğunluk Fonksiyonunun Bulunması.....	50
1.11.2.	Amaç Fonksiyonu Türevi.....	51
1.12.	Optimizasyon Yöntemleri	52
1.12.1.	Newton Metodu.....	54
1.12.2.	Değiştirilmiş Newton Yöntemi	56
1.12.3.	Ters Hessian Matris Yaklaşımı	57
2.	YAPILAN ÇALIŞMALAR, BULGULAR VE İRDELEME.....	60
2.1.	Giriş.....	60
2.2.	Tsallis'in Yapay Toplamsallık Özelliğini Amaç Fonksiyonu Olarak Kullanan Yeni Parametrik Olmayan BBA Algoritması	60
2.2.1.	Benzetim Ortamı	67
2.3.	Gürültüsüz EKG İşaretlerine Ait Elde Edilen Sonuçlar.....	69
2.3.1.	Tek Hamilelik Durumunda Elde Edilen Sonuçlar	69
2.3.1.1.	Boscolo'nun Parametrik Olmayan BBA Algoritma Sonuçları	74
2.3.1.2.	Önerilen Yapay Toplamsallık Özelliğini Kullanan Parametrik Olmayan BBA Algoritma Sonuçları	76
2.3.1.3.	Tek Hamilelik Durumunda BBA Algoritma Performansları	78
2.3.2.	İkiz Hamilelik Durumunda Elde Edilen Sonuçlar	82
2.3.2.1.	Boscolo'nun Parametrik Olmayan BBA Algoritma Sonuçları	83
2.3.2.2.	Önerilen Yapay Toplamsallık Özelliğini Kullanan Parametrik Olmayan BBA Algoritma Sonuçları	84
2.3.2.3.	İkiz Hamilelik Durumunda BBA Algoritma Performansları	85
2.4.	Gürültülü EKG İşaretlerine Ait Elde Edilen Sonuçlar.....	90
2.4.1.	Beyaz Gauss Gürültüye Ait Elde Edilen Sonuçlar.....	91
2.4.2.	İkiz Hamilelik Durumu İçin Beyaz Gauss Gürültüye Ait Elde Edilen Sonuçlar..	98
2.4.3.	Tek Hamilelik Durumunda Sürekli Olmayan Gürültüye Ait Elde Edilen Sonuçlar	103
2.4.4.	İkiz Hamilelik Durumunda Sürekli Olmayan Gürültüye Ait Elde Edilen Sonuçlar	111
2.4.5.	Harici Gürültüye Ait Elde Edilen Sonuçlar	116
2.5.	Elektromiyografik İşaretler ve Taban Seviye Kayması	123
2.6.	Gerçek EKG İşaretlerine Ait Sonuçlar.....	132
3.	SONUÇLAR	136
4.	ÖNERİLER	139
5.	KAYNAKLAR	140
6.	EKLER.....	146

ÖZGEÇMİŞ

ÖZET

Elektrokardiyogram sinyalleri kalbin elektriksel aktivitesi tarafından üretilirler ve cilt üzerine yerleştirilen elektrodlar kullanılarak belirlenebilirler. Bu biyolojik sinyaller, kuvvetlendiriciler ile kuvvetlendirilebilirler ve analog ve sayısal sinyal işleme teknikleri ile işlenebilirler. Bu işlenmiş sinyaller kalp hastalıklarının analizinde mükemmel bir araç olarak hizmet ederler. Cilt yüzeyinde kullanılan elektrodların en önemli özellikleri zarar vermeyen teknik oluşlarıdır, bunun anlamı vücut içerisine hiç girmeden sinyallerin ölçülebilmesidir. Bu kolaylığa rağmen zarar vermeyen metotlar diğer fizyolojik sinyaller ile ve gürültü ile karışma problemleri içermektedir.

Anne karnındaki çocuğun elektrokardiyogramı, çocuğun kalbinin elektriksel fizyolojik aktivitesini görselleştirmektedir ve bu işaret çocuğun durumu ve sağlığı hakkında önemli belirtiler içermektedir. Yetişkinlerde olduğu gibi, anne karnındaki çocuğun elektrokardiyogramı cilt üzerindeki elektrodlar ile elde edilebilir. Fakat anne karnındaki çocuğun elektrokardiyogramını elde etmede aynı problemlerin görüneceği açıktır. Bu problemlere ek olarak, annenin elektrokardiyogram sinyali, çocuğun elektrokardiyogram sinyali için problem olabilir, çünkü annenin sinyalinin genliği çocuğunkinden çok yüksektir. Geleneksel filtreleme teknikleri ile karışmış potansiyel kayıtlarından çocuğa ait istenen elektrokardiyogramın bileşenlerini elde etmek imkansızdır.

Bu tezde, amaç, kör kaynak ayrıştırma algoritmaları vasıtası ile, anne karnındaki çocuğun elektrokardiyogramının çıkarılması için uygun algoritmalara karar vermek ve yeni bir kör kaynak ayrıştırıcı algoritma bulmaktır. İlk adım olarak, yapay olarak üretilmiş elektrokardiyogram sinyalleri karıştırıldı ve uygun algoritmaları bulmak için kullanıldı. Kör kaynak ayrıştırmanın üç ana algoritması, Hızlı bağımsız bileşen analizi, özdeğer matrislerinin birleşik diyagonalizasyonu, parametrik olmayan bağımsız bileşen analizi ve yeni parametrik olmayan bağımsız bileşen analizi algoritmaları bu amaç için karşılaştırıldı.

Elde edilen sonuçlar, parametrik olmayan algoritmaların elektrokardiyogram sinyallerinde, annenin elektrokardiyogram sinyallerinin ve araya karışan sinyallerin etkilerini ayrıştırmada kullanılabileceklerini gösterdi.

Anahtar Kelimeler: Bağımsız Bileşen Analiz, Kör Kaynak Ayrıştırma, Elektrokardiyogram, Entropi, Tsallis Entropi, Shannon Entropi, Bilgi Teorisi, Relatif Entropi

SUMMARY

Fetal Electrocardiogram and Maternal Electrocardiogram Signals Separation Using Approach to Pseudo-Additivity

Electrocardiogram signals can be generated by the heart's electrical actions and can be detected using electrodes over skin. These biological signals are amplified by using amplifiers and can be processed with analog or digital signal processing techniques. These processed signals serve as an excellent tool for heart diseases analysis. Most important property of using skin electrodes is that it is a non-invasive technique, meaning that this signal can be measured without entering the body at all. Despite this facility, non-invasive methods include problems such as mixing with other physiological signals and noise.

Fetal electrocardiogram visualizes the electrical physiological activity of the fetal heart and it contains important indications about the health and condition of the fetus. Obtaining of the fetal electrocardiogram can be carried out through skin electrode like adults. But the same problems appear evidently during the obtaining of fetal electrocardiogram. In addition these problems, mother's electrocardiogram signal can be also problem for fetal electrocardiogram signal since its amplitude is much higher than that of the fetus. It is impossible to recover the wanted fetal electrocardiogram components from the mixed potential recordings by conventional filtering techniques.

In this thesis, the purpose is to determine the appropriate algorithms for fetal electrocardiogram extraction by means of blind source separation algorithms and find a new blind source separation algorithm. As the first step, artificially generated electrocardiogram signals were mixed and used to find suitable algorithms. Three main algorithms of blind source separation; FastICA, JADE, non-parametric ICA, and new non-parametric ICA algorithms compared for this purpose.

The results obtained indicate that non-parametric algorithms can be employed to preprocess electrocardiogram signals to separate the effects of maternal electrocardiogram signal and interference signals.

Key Words: Independent Component Analysis, Blind Source Separation, Electrocardiogram, Entropy, Tsallis Entropy, Shannon Entropy, Information Theory, Relative Entropy

ŞEKİLLER DİZİNİ

	<u>Sayfa No</u>
Şekil 1.1. Kalbin iletim sistemi	3
Şekil 1.2. EKG işareti.....	4
Şekil 1.3. Kalp atım süresi	5
Şekil 1.4. BBA algoritmasının Fetal EKG işareti uygulaması.....	7
Şekil 1.5. Tek dipol iz düşüm modeli.....	10
Şekil 1.6. Yapay EKG işaretinin spektral karakteristiği	13
Şekil 1.7. Yapay olarak elde edilmiş anneye ait EKG ve FEKG işaretleri	14
Şekil 1.8. Histogram.....	15
Şekil 1.9. Histogram grafiğinden elde edilmiş olasılık yoğunluk fonksiyonu	16
Şekil 1.10. Çok modlu olasılık yoğunluk fonksiyonu	17
Şekil 1.11. Kernel grafikleri a) Üçgen kernel b) Epanechnikov kernel c) İki ağırlıklı kernel d) Üç ağırlıklı kernel	18
Şekil 1.12. Bant genişliğinin (h) olasılık yoğunluk fonksiyon kestirimi üzerine etkisi	19
Şekil 1.13. Birleşik olasılık yoğunluk fonksiyonu	21
Şekil 1.14. Kokteyl parti problemi	26
Şekil 1.15. BBA ve KKA algoritmalarının blok diyagramı	29
Şekil 1.16. TBA algoritmasının çalışma prensibi	36
Şekil 1.17. BBA algoritmasının çalışma prensibi	37
Şekil 1.18. a) Kaynak sinyallerin dağınıklık grafiği b) Karıştırıcı matris ile karıştırılmış (kaydedilmiş) sinyallerin dağınıklık grafikleri	42
Şekil 2.1. Shannon ve Renyi entropi karşılaştırmaları	62
Şekil 2.2. Shannon ve Tsallis entropi karşılaştırmaları	63
Şekil 2.3. Parametrik olmayan algoritmalar için akış diyagramı	67
Şekil 2.4. Yapay olarak üretilmiş anne EKG'si ve FEKG işaretleri	70
Şekil 2.5. Yapay olarak üretilmiş anne ve fetusa ait olasılık yoğunluk fonksiyon grafikleri ve dağınıklık grafikleri	70
Şekil 2.6. Yapay olarak üretilmiş anne EKG'si ve FEKG işaretlerinden yapay karışım ile elde edilen EKG prob işaretleri.....	71
Şekil 2.7. Yapay olarak üretilmiş anne ve fetal EKG'lerin karışımının olasılık yoğunluk fonksiyon grafikleri ve dağınıklık grafikleri.....	72
Şekil 2.8. Geometrik BBA algoritması ile ayrıştırılmış yapay anne EKG'si ve FEKG işaretleri.....	73

Şekil 2.9. Geometrik BBA algoritması ile ayrıştırılmış yapay olarak üretilmiş anne ve fetal EKG'lerin olasılık yoğunluk fonksiyon grafikleri ve dağınıklık grafikleri.....	74
Şekil 2.10. Boscolo'nun parametrik olmayan BBA algoritma sonuçları.....	75
Şekil 2.11. Boscolo'nun parametrik olmayan BBA algoritma sonucunun olasılık yoğunluk fonksiyon grafikleri ve dağınıklık grafiği.....	76
Şekil 2.12. Önerilen parametrik olmayan yeni BBA algoritma sonuçları.....	77
Şekil 2.13. Önerilen parametrik olmayan yeni BBA algoritma sonuçlarının dağınıklık grafiği.....	78
Şekil 2.14. Gürültüsüz yapay EKG işaretleri için farklı BBA algoritmaları kullanılarak ayrıştırılan anneye ait EKG işaretlerinin İHO değerlerinin farklı örnek sayıları için karşılaştırılması.....	80
Şekil 2.15. Gürültüsüz yapay EKG işaretleri için farklı BBA algoritmaları kullanılarak ayrıştırılan fetusa ait EKG işaretlerinin İHO değerlerinin farklı örnek sayıları için karşılaştırılması.....	81
Şekil 2.16. Tek hamilelik durumu için parametrik olmayan iki algoritmanın adım sayılarının örnek sayılarına bağlı olarak karşılaştırılması.....	82
Şekil 2.17. Yapay olarak karıştırılmış anne EKG'si ve iki fetusa ait FEKG işaretleri (EKG prob işaretleri).....	83
Şekil 2.18. Boscolo'nun parametrik olmayan BBA algoritma sonuçları.....	84
Şekil 2.19. Önerilen parametrik olmayan yeni BBA algoritma sonuçları.....	85
Şekil 2.20. Gürültüsüz yapay EKG işaretleri (ikiz hamilelik durumunda) için farklı BBA algoritmaları kullanılarak ayrıştırılan anneye ait EKG işaretinin İHO değerlerinin farklı örnek sayılarına göre değişimi.....	87
Şekil 2.21. Gürültüsüz yapay EKG işaretleri (ikiz hamilelik durumunda) için farklı BBA algoritmaları kullanılarak ayrıştırılan birinci fetusa ait EKG işaretlerinin İHO değerlerinin farklı örnek sayılarına göre değişimi.....	88
Şekil 2.22. Gürültüsüz yapay EKG işaretleri (ikiz hamilelik durumunda) için farklı BBA algoritmaları kullanılarak ayrıştırılan birinci fetusa ait EKG işaretlerinin İHO değerlerinin farklı örnek sayılarına göre değişimi.....	89
Şekil 2.23. İkiz hamilelik durumu için parametrik olmayan iki algoritmanın adım sayılarının örnek sayılarına bağlı olarak karşılaştırılması.....	90
Şekil 2.24. Gürültü, kaynak gürültüsü iken 8 dB İKO için kaynak sinyalleri.....	91
Şekil 2.25. Gürültü, kaynak gürültüsü iken 8 dB İKO için yapay prob sinyalleri.....	92
Şekil 2.26. Gürültü, kaynak gürültüsü iken 8 dB İKO için Boscolo'nun parametrik olmayan BBA algoritma sonuçları.....	93
Şekil 2.27. Gürültü, kaynak gürültüsü iken 8 dB İKO için önerilen parametrik olmayan BBA algoritma sonuçları.....	94
Şekil 2.28. Gürültü, kaynak gürültüsü iken, farklı algoritmalar kullanılarak ayrıştırılan annenin EKG işaretlerine ait İHO değerlerinin örnek sayısı değerlerine göre değişim grafiği.....	96

Şekil 2.29. Gürültü, kaynak gürültüsü iken, farklı algoritmalar kullanılarak ayrıştırılan fetusun EKG işaretlerine ait farklı İKO değerlerinin İHO değerlerine göre değişim grafiği	97
Şekil 2.30. Gürültü, kaynak gürültüsü ve tek hamilelik durumu için parametrik olmayan iki algoritmanın adım sayılarının örnek sayılarına bağlı olarak karşılaştırılması	98
Şekil 2.31. Gürültü, kaynak gürültüsü ve ikiz hamilelik durumu için, farklı algoritmalar kullanılarak ayrıştırılan annenin EKG işaretlerine ait farklı örnek sayısı değerlerine göre değişim grafiği	100
Şekil 2.32. Gürültü, kaynak gürültüsü ve ikiz hamilelik durumu için, farklı algoritmalar kullanılarak ayrıştırılan birinci fetusun EKG işaretlerine ait farklı örnek sayısı değerlerine göre değişim grafiği	101
Şekil 2.33. Gürültü, kaynak gürültüsü ve ikiz hamilelik durumu için, farklı algoritmalar kullanılarak ayrıştırılan ikinci fetusun EKG işaretlerine ait farklı örnek sayısı değerlerine göre değişim grafiği	102
Şekil 2.34. Gürültü, kaynak gürültüsü ve ikiz hamilelik durumu için parametrik olmayan iki algoritmanın adım sayılarının örnek sayılarına bağlı olarak karşılaştırılması	103
Şekil 2.35. Sürekli olmayan gürültü için oluşturulmuş yapay kaynak sinyalleri	104
Şekil 2.36. Sürekli olmayan gürültü için yapay olarak karıştırılmış anneye ve fetusa ait prob sinyalleri	105
Şekil 2.37. Sürekli olmayan gürültü için Boscolo'nun BBA algoritma sonuçları	106
Şekil 2.38. Sürekli olmayan gürültü için önerilen parametrik olmayan BBA algoritma sonuçları	107
Şekil 2.39. Sürekli olmayan gürültü varken, farklı algoritmalar kullanılarak ayrıştırılan anneye ait EKG işaretlerinin İHO değerlerinin farklı örnek sayıları için karşılaştırılması	109
Şekil 2.40. Sürekli olmayan gürültü varken, farklı algoritmalar kullanılarak ayrıştırılan fetusa ait EKG işaretlerinin İHO değerlerinin farklı örnek sayıları için karşılaştırılması	110
Şekil 2.41. Sürekli olmayan gürültü ve tek hamilelik durumu için parametrik olmayan iki algoritmanın adım sayılarının örnek sayılarına bağlı olarak karşılaştırılması	111
Şekil 2.42. Sürekli olmayan gürültü varken ikiz hamilelik durumu için, farklı algoritmalar kullanılarak ayrıştırılan anneye ait EKG işaretlerinin İHO değerlerinin farklı örnek sayıları için karşılaştırılması	113
Şekil 2.43. Sürekli olmayan gürültü varken ikiz hamilelik durumu için, farklı algoritmalar kullanılarak ayrıştırılan birinci fetusa ait EKG işaretlerinin İHO değerlerinin farklı örnek sayıları için karşılaştırılması	114
Şekil 2.44. Sürekli olmayan gürültü varken ikiz hamilelik durumu için, farklı algoritmalar kullanılarak ayrıştırılan ikinci fetusa ait EKG işaretlerinin İHO değerlerinin farklı örnek sayıları için karşılaştırılması	115

Şekil 2.45. Sürekli olmayan gürültü ve ikiz hamilelik durumu için parametrik olmayan iki algoritmanın adım sayılarının örnek sayılarına bağlı olarak karşılaştırılması	116
Şekil 2.46. Harici gürültü eklenmiş yapay EKG prob işaretleri.....	117
Şekil 2.47. Harici gürültü için Boscolo'nun sonuçları	118
Şekil 2.48. Harici gürültü için önerilen parametrik olmayan BBA algoritma sonuçları...	119
Şekil 2.49. Anne EKG işaretinin İHO değerlerinin örnek sayısı değerlerine göre değişimi.....	121
Şekil 2.50. Fetus EKG işaretinin İHO değerlerinin örnek sayısı değerlerine göre değişimi	122
Şekil 2.51. Harici gürültü için parametrik olmayan iki algoritmanın adım sayılarının örnek sayılarına bağlı olarak karşılaştırılması	123
Şekil 2.52. Taban seviye kayması ve EMG işaretleri için kaynak işaretleri	124
Şekil 2.53. Taban seviye kayması ve EMG işaretleri için yapay olarak elde edilmiş prob işaretleri	125
Şekil 2.54. Taban seviye kayması ve EMG işaretleri için farklı BBA algoritmaları kullanılarak ayrıştırılan anneye ait EKG işaretinin İHO değerlerinin farklı örnek sayılarına göre değişimi	127
Şekil 2.55. Taban seviye kayması ve EMG işaretleri için farklı BBA algoritmaları kullanılarak ayrıştırılan fetusa ait EKG işaretinin İHO değerlerinin farklı örnek sayılarına göre değişimi	128
Şekil 2.56. Farklı entropi indeksleri için önerilen algoritmanın ve Boscolo'nun algoritmasının adım sayısı bakımından karşılaştırılması	129
Şekil 2.57. Farklı entropi indeksleri için önerilen algoritmanın ve Boscolo'nun algoritmasının işlem zamanı bakımından karşılaştırılması	130
Şekil 2.58. Anne EKG'si için önerilen algoritmanın farklı entropi indekslerinin ve Boscolo'nun algoritmasının hatalarının karelerinin toplamının ortalama değerlerinin adım sayısına göre değişimi.....	131
Şekil 2.59. Fetus EKG'si için önerilen algoritmanın farklı entropi indekslerinin ve Boscolo'nun algoritmasının hatalarının karelerinin toplamının ortalama değerlerinin adım sayısına göre değişimi.....	132
Şekil 2.60. Gerçek EKG işaretleri	133
Şekil 2.61. Boscolo'nun algoritmasının gerçek EKG işareti sonuçları.....	134
Şekil 2.62. Önerilen yeni algoritmasının gerçek EKG işareti sonuçları	135

TABLolar DİZİNİ

	<u>Sayfa No</u>
Tablo 1. EKG işareti genlik ve zaman parametreleri.....	5
Tablo 2. Yapay EKG işareti için parametre değerleri	12
Tablo 3. Yoğunluk fonksiyon tahmini için kullanılan kerneller.....	18
Tablo 4. Tek hamilelik durumunda gürültüsüz yapay EKG işaretleri için BBA algoritma sonuçlarının İHO değerlerinin farklı örnek sayılarına göre değişimi.....	79
Tablo 5. İkiz hamilelik durumunda gürültüsüz yapay EKG işaretleri için BBA algoritma sonuçlarının İHO değerlerinin farklı örnek sayılarına göre değişimi	86
Tablo 6. Tek hamilelik durumunda kaynak gürültülü yapay EKG işaretleri için BBA algoritma sonuçlarının İHO değerlerinin farklı örnek sayısı değerlerine göre değişimi	95
Tablo 7. İkiz hamilelik durumunda kaynak gürültülü yapay EKG işaretleri için BBA algoritma sonuçlarının İHO değerlerinin farklı örnek sayısı değerlerine göre değişimi	99
Tablo 8. Tek hamilelik durumunda sürekli olmayan gürültülü yapay EKG işaretleri için BBA algoritma sonuçlarının İHO değerlerinin farklı örnek sayılarına göre değişimi	108
Tablo 9. İkiz hamilelik durumunda sürekli olmayan gürültülü yapay EKG işaretleri için BBA algoritma sonuçlarının İHO değerlerinin farklı örnek sayılarına göre değişimi	112
Tablo 10. Harici gürültülü durumda, BBA algoritmaların İHO değerlerinin örnek sayısı değerleri ile değişimi	120
Tablo 11. Taban seviye kayması ve EMG işaretleri için BBA algoritma sonuçlarının İHO değerlerinin farklı örnek sayılarına göre değişimi	126

SEMBOLLER DİZİNİ

A	: Karışım matrisi
A_z	: Taban çizgisi kayma genliği
\tilde{A}	: Beyazlatılmış karışım matrisi
a_i	: P, Q, R, S, T fazlarının genlikleri
b_i	: P, Q, R, S, T fazlarının varyansları
C_x	: Kovaryans
c_i	: Mayer ve RSA dalgalarının standart sapması
D	: Kovaryans matrisin öz değer matrisi
D_o	: Ölçeklendirme matrisi
det	: Determinant
$d(t)$: Dipol model
E	: Kovaryans matrisin öz vektör matrisi
$E\{x\}$: Beklenen değer, ortalama
$EKG(t)$: EKG problemlerinde gözlenen sinyal
$E_\psi\{x\}$: Yapay ortalama
$F(M)$: Kumulant matris
f	: m tane değişkenden oluşmuş sayısal değerli fonksiyon
f_s	: Örnekleme frekansı
g	: Amaç fonksiyonunun birinci türevi
g_f	: Hızlı BBA için G fonksiyonlarının türevi
g'_f	: Hızlı BBA için g_f fonksiyonlarının türevi
$H(t)$: Amaç fonksiyonun ikinci türevine yaklaşım
$H_s(x)$: Shannon entropi ölçümü
h	: Kernel bant genişliği
$I(y_1, \dots, y_m)$: Karşılıklı bilgi miktarı
$I(x\ y)$: Relativ entropi

$I_q(x\ y)$: Tsallis relativ entropi ölçümü
$I_\alpha(x\ y)$: Renyi relativ entropi ölçümü
$J(x)$: Negentropi
$Jf(x)$: $f(x)$ fonksiyonunun Jacobien matrisi
K_k	: k. kumulant
$kum(x_i, x_j)$: Çapraz kumulant
$L(W)$: Amaç fonksiyonu
$L_{\text{ÖMBK}}$: ÖMBK algoritması için amaç fonksiyon
$L_q(W)$: Tsallis için amaç fonksiyon
M	: Veri boyu
m_x	: Ortalama değer
n_i	: Her bir probdaki gürültü işareti
P	: Permutasyon matrisi
$P_x(x)$: Olasılık yoğunluk fonksiyonu
$p(t)$: Arama yönü
pr	: Birim küre üzerine iz düşüm alınma işlemi
Q	: Amaç fonksiyonun ikinci türevi
Q_D	: Diyagonalleştirme işlemi
q	: Tsallis entropi sabiti
R_x	: İlinti matrisi
r_{ij}	: ilinti
$S(f)$: Dinamik modelin güç tayfi
$S_q(x)$: Tsallis entropi ölçümü
$S_\alpha(x)$: Renyi entropi ölçümü
$s(t)$: Kaynak işaretleri
v	: Kaydedici elektrodların konumları
$v(t)$: Gürültü işareti
W	: Ayırıştırıcı matris

w_a	: Açısal hız
w_i	: Ayrıştırıcı matrisin i. satırı
$x(t)$: Karışmış işaretler
\tilde{x}	: Beyazlatılmış karışmış sinyaller
$x^{(m)}$: Karışım matrisinin m. kolonu
Y_{im}	: Kernel merkezleri
$y(t)$: Ayrıştırılmış sinyaller
y_i^G	: y_i verisi ile aynı varyansa sahip gauss fonksiyonu
$z_o(t)$: Taban çizgisi kayması
σ	: Standart sapma
α	: Renyi entropi sabiti
$\alpha(t)$: Newton yöntemi için yakınsamayı garanti eden değişken
η	: Öğrenme sabiti
ε	: Hata tolerans değeri
θ_x	: Dinamik model için EKG işareti safhalarının açısal değerleri
$\phi(u)$: Kernel fonksiyonu
$\varphi(w)$: Karakteristik fonksiyon
$\gamma(u)$: Kumulant üretici fonksiyon
ψ	: Sürekli olan ve monoton artan veya azalan fonksiyon
$\mu(t)$: En dik azalan algoritması için adım büyüklüğü
$\langle x \rangle_w$: Yapay ortalama
Δt	: Zaman adım büyüklüğü

KISALTMALAR DİZİNİ

AV	: Atrioventriküler
BBA	: Bağımsız Bileşen Analiz
BFGS	: Broyden-Fletcher-Goldfard-Shanno
EKG	: Elektrokardiyogram
EMG	: Elektromiyografik İşaret
FEKG	: Anne Karnındaki Çocuğun Elektrokardiyogramı
FHR	: Anne Karnındaki Çocuğun Kalp Atım Oranı
HF	: Yüksek Frekans
HRV	: Kalp Atımı Oranı Değişimi
İGO	: İşaret Gürültü Oranı
İHO	: İşaret Hata Oranı
İKO	: İşaret Karışım Oranı
KKA	: Kör Kaynak Ayırıştırma
KL	: Kullback Leibler
KPP	: Kokteyl Parti Problemi
LF	: Düşük Frekans
MLT	: Merkezi Limit Teoremi
ÖMBK	: Özdeğer Matrislerinin Birleşik Köşegenselleştirilmesi
RR	: İki R Tepesi Arasındaki Mesafe
SA	: Sinoatrial
TBA	: Temel Bileşen Analiz

1. GENEL BİLGİLER

1.1. Giriş

İnsan kalbi göğüs kafesi ile ciğerler arasında bulunur ve ağırlığı 200 ila 425 gram arasında değişir. Her gün ortalama olarak 100.000 kez atmakta ve yaklaşık olarak 7600 litre kanı pompalamaktadır [1]. Pompalama işlemini kalp hücrelerindeki iyonik akımların zaman ile değişimiyle meydana gelen elektriksel faaliyetler meydana getirmektedir. Kalpte meydana gelen elektriksel faaliyetler kalp kası liflerini gerip, gevşeterek kalbin kan pompalaması işlemini gerçekleştirmektedir. Elektrokardiyogram (EKG), deri yüzeyi üzerine yerleştirilmiş olan iki elektrot ile kalpte meydana gelen bu elektriksel faaliyetlerin ölçümü ve grafiksel hale dönüştürülmesi işlemidir. EKG grafiklerinde P, Q, R, S, ve T ile adlandırılan sinyal aralıkları, iyonik akımlar ile kalbin kulakçıklar ve karıncıklarının polarizasyondan ayrılma ve tekrar polarizasyonlaşma safhalarını temsil etmektedir. Bu safhalarda meydana gelecek herhangi bir elektriksel değişim kalp ile ilgili olan hastalıkların varlığını gösterecektir ve EKG grafiklerinde gözlemlenebilecektir. Bu değişimler genellikle uyarının kaynaklandığı bölgeye (örneğin karıncık üstü, karıncık vb) ya da belirtilerin biçimine (örneğin erken atım, taşikardi, fibrilasyon vb) göre EKG grafiklerinde gözlemlenirler. EKG kayıtlarında gözlemlenecek bu değişimler ile kalp hastalıklarının erken teşhisi mümkün olacaktır ve uygun tedavi ile kalp hastalıkları fazla ilerlemeden tedavi edilebilecektir.

Yetişkinlerde olduğu gibi anne karnındaki fetusun EKG (FEKG) işaretinin ölçümü anne karnındaki fetusun kalp hastalıklarının teşhisinde güvenilir bir metot olabilir. Günümüz ölçüm aygıtları ile anneye zarar vermeden FEKG'yi ancak annenin EKG'sine karışmış şekilde elde edilebilmektedir. Bu elde edilen işaretlerde genellikle fetusun ve annenin QRS kompleksleri üst üste gelmekte veya fetusun P ve T dalgaları annenin QRS kompleksinin yakınında olmaktadır. Bu gibi durumda klasik veya adaptif filtre uygulamalarının EKG işaretlerini ayırmada başarısız olduğu görülmüştür.

Çalışmamızda bu tür durumlar için bağımsız bileşen analizi (BBA) algoritmalarının performansı yapay EKG sinyalleri üzerinde incelenecek, parametrik olmayan algoritmalar ilk kez EKG işaretleri üzerine uygulanacak ve yeni bir BBA algoritması geliştirilecektir. Ayrıca

parametrik olmayan algoritmalar gerçek EKG işaretleri üzerine uygulanarak sonuçları görsel olarak yorumlanacaktır.

BBA algoritmalarının amacı sinyalleri bağımsız sinyallere ayırtmak olup ilk olarak Jutten ve Herault [2] tarafından 1991 yılında sinirsel ağ modelleme alanı ile ilgili olarak ortaya çıkmıştır. BBA terimi ise Comon tarafından 1994 yılında lineer BBA'nın teorisi [3] adlı yayınında koyulmuştur. Geçmiş yirmi yıl boyunca BBA algoritmaları hakkında pek çok yayın yapılmış ve konferanslar düzenlenmiştir. Günümüzde pek çok çalışma grubu BBA algoritmaları ve uygulama alanları üzerine çalışmalarını sürdürmektedirler.

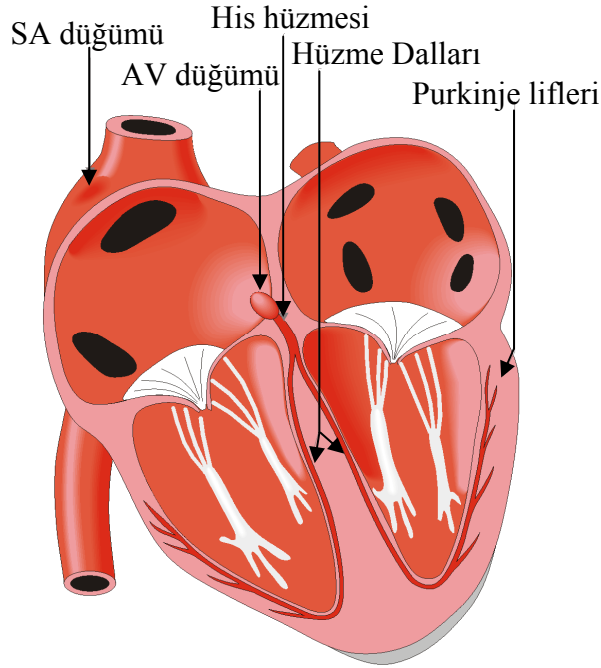
Bu çalışma FEKG işaretinin BBA algoritmaları ile ayrıştırılması ve yeni bir BBA algoritmasının oluşturulmasını içermektedir. Bu çalışmanın genel bilgiler bölümünde, yapılan çalışmalara temel teşkil edecek ön bilgiler verilmektedir. Bölüm 1.2'de, EKG işaretleri hakkında, bölüm 1.3'de, yapay EKG işaretinin oluşturulması hakkında bilgi verilmektedir. Bölüm 1.4'te, bir çok BBA algoritmasının temelini oluşturan entropi ve bilgi teorisi irdelenmiştir. Bölüm 1.5'de, BBA algoritması ile diğer tanımlar ve algoritmalar ile ilişkisi verilmektedir. Bölüm 1.6'dan 1.11'e kadar olan kısımda, yaygın olarak literatürde karşılaşılan BBA algoritmalarından bahsedilmiştir. Bölüm 1.12'de, ayrıştırıcı matris kestiriminde kullanılacak olan bazı optimizasyon algoritmaları hakkında bilgi verilecektir. Son kısımda ise yeni geliştirilmiş olan parametrik olmayan Tsallis BBA algoritması sunulmuş ve algoritmaların uygulanması ile elde edilmiş olan sonuçlar verilerek ve gelecek çalışmalar için araştırmacılara önerilerde bulunulmuştur.

1.2. EKG İşareti

Kalp kasının kasılmasına neden olan kalbin elektriksel iletim sistemi kalbin başından sonuna kadar dağılım göstermektedir. Bu iletim sistemi sinüs düğümü (SA), AV düğümü, purkinje lifleri olarak üç kısma ayrılmaktadır ve bu bölgelerdeki atım sayıları da bölgelere göre farklılık göstermektedir.

Kalbin sağ kulakçığındaki üst ana toplar damar girişinin kalbe açıldığı bölgede yer alan hilal şekline sahip SA düğümü 15 mm uzunlukta, 5 mm genişlikte olup, bütün kalp kasına yayılan uyarıların merkezidir [4]. Kalp kasını oluşturan bütün kas liflerinin özelleşmiş yapıları ve aralarındaki bağlantıları sayesinde SA düğümünden düzenli aralıklarla çıkan yaklaşık dakikada 70 uyarı kalp boyunca kolayca yayılım gösterir. Yayılan bu uyarı ilk önce yayıldığı her iki kulakçık kasının hemen kasılmasını sağlayarak kulakçıklar ile karıncıkları ayıran lifli bölmeye ulaşır. Bu bölmede ikinci bir uyarı merkezi olan AV düğümü


bulunmaktadır. AV düğümü normal olarak SA düğümünün denetimi altındadır ve kulakçıkların her kasılmasını karıncıkların kasılması izler. Fakat SA düğümünün denetimi AV düğümünde azalır ve AV düğümü kendi başına karıncıkların kasılma temposunu belirlemeye başlar ve yaklaşık dakikada 50 uyarım yapar. AV düğümünden kaynaklanan özel kas liflerinden oluşmuş bir demet (purkinje lifleri), karıncıkları ayıran bölmeyi izleyerek uyarıyı kalbin tepesine, yani karıncık liflerinin kasılmaya başlayacakları bölgeye iletir. Bu bölgedeki purkinje liflerinin uyarım sayısı dakikada 15 ila 30 arasındadır. Kalp karıncıklarının kasılması (sistol) ve bu sayede kanın aort yoluyla büyük, akciğer atardamarı yoluyla küçük dolaşıma pompalanması 0,3 saniye sürer. Karıncıkların gevşemesi (diyastol) ve bu sayede dolaşımdan gelen kanın karıncıklara dolması için geçen süre ise 0,5 saniyedir. Böylece kalp atım çevrimi dakikada yaklaşık olarak 70 kez yinelenir. Kalbin bu iletim sistemi Şekil 1.1'de görülebilmektedir.



Şekil 1.1. Kalbin iletim sistemi [4]

Kalbin iletim sisteminden geçen elektriksel akım sinyali kalbin büzülüp gevşemesine neden olarak kalbin vücuda kan pompalamasını sağlamaktadır. Elektriksel akım bakımından kalbin büzülmesi kalbin polarizasyondan ayrılmasına, kalbin gevşemesi kalbin yeniden polarizasyonuna karşılık gelmektedir. Kalp tarafından üretilen bu elektriksel aktivite sadece kalp içinde değil aynı zamanda tüm vücut boyunca yayılım gösterir ve vücut yüzeyine

yerleştirilmiş bir dizi elektrot sayesinde ölçülüp gözlemlenebilir. Bu gözlemlenen işaret EKG olarak adlandırılır. İlk EKG işaretini 1895 yılında Einthoven elde etmiştir [5]. EKG ölçümleri ile elde edilen sinyalin genel şekli Şekil 1.2’de görülmektedir.



Şekil 1.2. EKG işareti

Şekil 1.2’den görüleceği gibi, kulakçık ve karıncık polarizasyondan ayrılma ve yeniden polarizasyon dizisini temsil eden farklı dalgalar birleşerek EKG sinyalini oluşturmaktadır. Bu dalgalar:

P dalgası: Kulakçık boyunca SA düğümünden yayılan polarizasyondan ayrılma dalgasını temsil etmektedir.

P-R aralığı: Bu aralık kulakçığın polarizasyondan ayrılmasının başlangıcı ile karıncığın polarizasyondan ayrılmasının başlangıç aralıklarının zamanını temsil eder.

QRS bileşeni: QRS bileşeni karıncığın polarizasyondan ayrılmasını temsil eder. Kulakçık oranı, QRS kompleksleri arasındaki zamanın bulunması ile hesaplanabilir. Bu zaman aralığı kulakçığın polarizasyondan ayrılmasının çok hızlı bir şekilde meydana gelmesi ile orantılıdır.

ST segmenti: Tüm kulakçığın polarizasyondan ayrılmasının bittiği süredir.

T dalgası: T dalgası kulakçığın yeniden polarizasyonunu temsil eder ve polarizasyondan ayrılmadan daha uzun sürer.

Q-T aralığı: Kulakçığın polarizasyondan ayrılması ve yeniden polarizasyonu arasındaki zaman aralığını temsil eder. Bundan dolayı ortalama kulakçık aksiyon potansiyelinin süresinin bulunmasına karşılık gelir.


Sağlıklı bir kişiye ait EKG işaretinin genlik ve zaman parametreleri Tablo 1’de görülmektedir.

Tablo 1. EKG işaretleri genlik ve zaman parametreleri

EKG Dalgası	Genliği	EKG Aralığı	Süresi
P	0.25 mV	P-R	0.12 - 0.20 sn
R	1.60 mV	Q-T	0.35 - 0.44 sn
Q	R'nin %25'i	S-T	0.05 - 0.15 sn
T	0.1-0.5 mV	Q-R-S	0.09 sn

1.2.1. Kalp Atımı Oranı Değişimi (HRV)

Kalp atımı, iki R tepesi (RR aralığı) arasındaki geçen süre olarak tanımlanmaktadır. Kalp atım oranı ise bir zaman serisi ile elde edilecek olan kalp atımlarının (RR aralığının ortalaması) analiz işlemidir. Kalp atım oranı kişiden kişiye farklılık gösterir. Bu değişimi kişinin yaşı, cinsiyeti, yaşam şekli, aldığı ilaçlar ve sağlık durumu etkilemektedir [6]. Bu etkileme sırasında sadece kalp atım oranı değil bu kalp atımının varyansı da değişir.



Şekil 1.3. Kalp atım süresi

Uygulamada pek çok kalp atım oranı ölçüm yöntemi vardır ve bunlar zaman domeni, frekans domeni ve geometrik ölçüm yöntemleri olarak üç ana başlığa ayrılabilirler.

Zaman domeni kalp atım oranı ölçüm yöntemlerinden biri, kalp atımları aralığının standart sapmasını hesaplamaktır. İkinci yöntem ise kalp atımları arasındaki farkın ortalama kareköklerinin hesaplanmasıdır.

Frekans domeni kalp atım oranı ölçüm yönteminde ise zaman serisi olan EKG işaretine ayrık Fourier dönüşümü uygulanarak güç tayfı bulunur. Bu güç tayfında genellikle alçak frekans (LF-Mayer) ve yüksek frekans (HF-RSA) olmak üzere iki pik gözlemlenir (frekans bandı). Yüksek frekans bandı 0.15 ile 0.4 Hz arasındadır ve SA düğümündeki parasempatik sinir sistemi tarafından sürüldüğü düşünülür. Ayrıca yüksek frekans bölgesinde

nefes alıp vermeden dolayı oluşan frekans ve vagal aktivitede gözlemlenebilir. Düşük frekans bandı 0.04 ile 0.15 Hz arasında olup parasempatik ve sempatik aktivite tarafından sürüldüğü düşünülmektedir. Ayrıca çok nadir olarak bu frekans bandında nefes alıp verme frekansı da gözlemlenebilmektedir. Bu iki ana frekans bandına ek olarak genellikle ihmal edilen çok düşük frekans bandı da EKG işaretinin güç tayfında gözlemlenebilir. Bu frekans aralığı 0 ve 0.0033 Hz arasında olup frekansı oluşturan temel sebeplerin fiziksel veya sadece 24 saatlik kayıtlardan elde edilebilecek gündüz gece değişimlerinden meydana geldiği düşünülmektedir.

Kalp atım oranı ölçümüne geometrik yöntem olarak Poincare çizimi gösterilebilir. Bu yöntemde kalp atımı değişim oranı lineer olmayan bir yöntem ile analiz edilmektedir. Bu konularda daha detaylı bilgi 1995 yılında Malik'in çalışmalarında bulunabilir [6,7].

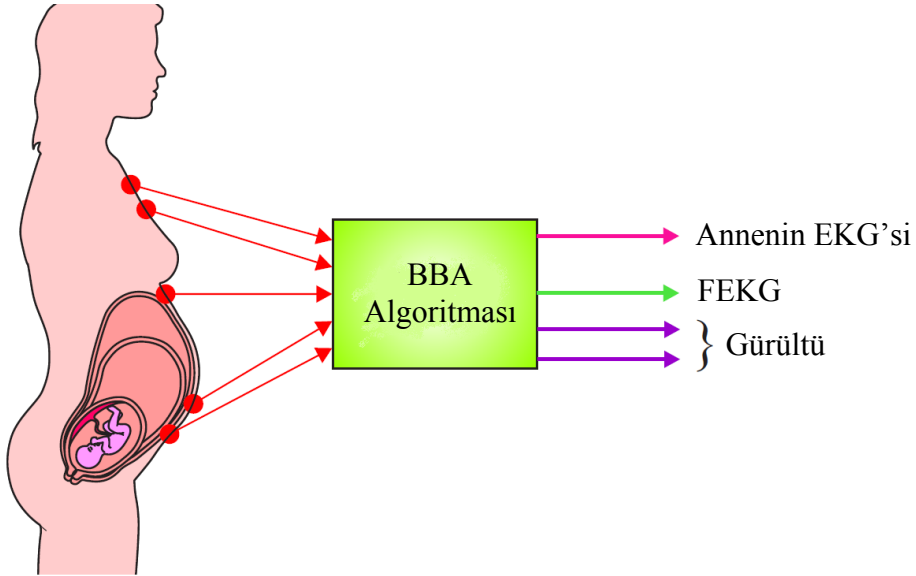
1.2.2. Anne Karnındaki Fetusun EKG İşareti (FEKG)

Tam olarak gelişmiş olan fetusun kalbinin anatomisi yetişkin kabine benzerken fonksiyonellik bakımından farklılıklar gösterir. Doğumdan sonra sol karıncık vücuda kan pompalarken sağ karıncık oksijen elde etmek için kanı ciğerlere pompalar. Fetusda ise oksijen anne plasentası tarafından sağlanır. Bundan dolayı kan ciğerlere bu amaç için pompalanmaz [8]. Kan vücudu dolaşmak için karıncıktan dışarı çıkan iki yan damar hattı ile bu işlemi yapar. Bu hatlardan biri küçük dolaşımı bypass ederek sağ kulakçığa kanın girişini sağlar. Diğer hat ise karaciğeri bypass eder. Doğumdan sonra ilk hat hemen kapanırken diğer hat 10-15 saat içinde kapanır.

Üstte belirtildiği gibi fetusun kalbinin mekanik fonksiyonları yetişkin insanınkinden farklı iken elektriksel aktiviteleri aynıdır. Kalbin kan pompalamasını sağlayan sinirsel ağ aynıdır ve kalp kası boyunca dağılım gösterir. Bu sinirsel ağ yetişkinlerde olduğu gibi kalbin büzülmesini ve gevşemesini kontrol eder [9]. Yetişkinlerde olduğu gibi FEKG işareti fetusun kalp sağlığı hakkında önemli bilgiler taşımaktadır. Günümüzde FEKG işaretinin ölçümü için kullanılan en yaygın yöntem dopler ultrasounddur ve bu yöntem ile sadece fetusun kalp atım oranı (FHR) ölçülebilmektedir [10,11]. Dopler ile ölçülen FHR değerleri araya karışan gürültüden dolayı doğru olara ölçülememekte ve ayrıca sınırlı klinik bilgi değerine sahiptir. Klasik EKG yönteminde ise anne karnı üzerine yerleştirilerek veya fetusun kafatası üzerinden ölçülecek olan FEKG işaretinin zamansal parametreleri ve morfolojik yapısı fetus hakkında ek bilgi sağlamaktadır. Bunlara ek olarak klasik EKG yönteminde, yüksek riskli hamilelik durumunda evde uzun dönem FEKG gözlemi yapılabilir. Fakat klasik yol ile elde edilen EKG ölçüm yöntemlerinin her ikisinde de problemler ile karşılaşılır. Fetusun kafatası

üzerinden ölçülecek olan FEKG işareti sadece doğum süresinde ölçülebilir iken [12] anne karnı üzerinde ölçülecek FEKG işaretinde, baskın anne EKG işareti ve diğer güçlü gürültü kaynaklarına rastlanabilmektedir [13,14]. Son yıllara kadar bu işaretler arasından FEKG'yi ayırtmak için klasik filtre ile ayırıştırma [15,16], adaptif filtre [17], çıkartım [18], ortalama alma [19,20] gibi yöntemler kullanılmaktaydı. Bu yöntemler ile ayırıştırılan anne EKG'sindeki hatalar ve diğer güçlü gürültü kaynaklarının varlığında yöntemlerin iyi sonuç vermemesi yeni yöntem arayışlarına yol açmıştır. Bunun üzerine farklı bir yöntem olan BBA algoritmaları ilk FEKG işaretlerine Choi, Cichocki, Amari, Nandi ve Zarzoso tarafından uygulanmıştır [21,22,23]. Taylor'un büyük bir veri tabanı üzerine yapmış olduğu çalışmalar [24,25] BBA algoritmaları ile doğru bir şekilde FEKG ayırıştırmanın yapılabileceğini göstermiştir. Bu çalışmalara ek olarak Zarzoso, Nandi ve Comani'nin çalışmaları [26,27] BBA algoritmalarının FEKG ayırıştırımını doğru yaptığını destekleyici çalışmalar yapmışlardır fakat henüz standart bir FEKG ayırıştırıcı BBA algoritması geliştirilememiştir.

Anne karnı üzerinden işlem yapılan FEKG ölçüm ve ayırıştırma aşamaları Şekil 1.4'de görülmektedir.



Şekil 1.4. BBA algoritmasının Fetal EKG işareti uygulaması [28]

1.2.3. EKG Gürültüleri

Genellikle ölçülen EKG işaretlerinde gürültüler ve ölçme hataları gözlemlenebilmektedir. Bu gözlemlenen hatalar ve gürültüler EKG frekans bandı içinde olabilir ve EKG işareti ile aynı morfolojik özellikleri gösterebilir. Bu gibi durumlarda uygun donanım ve sinyal işleme teknikleri ile gürültülerin tümünün üstesinden gelmek mümkün değildir. Bundan dolayı gürültünün yapısını ve nedenini bilmek ve uygun algoritma ile üstesinden gelmek önemlidir. EKG işaretinde gözlemlenen gürültüler aşağıdaki gibi tanımlanabilir.

Elektrik hattı gürültüsü: Elektrik hattından kaynaklanan gürültüdür. Frekansı 50 Hz ve harmonikleridir. Genliği EKG pikleri arasındaki genliğin %50'sinden fazla olabilir.

Elektrod bağlantı veya ayırma gürültüsü: Elektrodun deri ile bağlantısı koptuktan sonra doyuma keskin geçiş ile kendini belli eder.

Hasta-Elektrod hareket gürültüsü: Elektrodun vücuttaki bağlantı yerinin değişmesi ile meydana gelir. Elektrod ve vücut arasındaki empedansın değişmesine neden olur ve hızlı ve sürekli temel çizgi değişimi veya tam doyum ile kendini belli eder.

Elektromiyografik gürültü: Kas hücrelerindeki kasılmadan meydana gelir ve 50 ms içerisinde sona erer. Genliği EKG pikleri arasındaki genliğin %10'u kadar olabilir.

Veri toplama aygıtı gürültüsü: Sinyal işleme donanımı tarafından meydana gelen gürültüdür.

Diğer medikal donanım gürültüsü: Diğer medikal cihazlar tarafından üretilen manyetik gürültülerdir. EKG prob kabloları anten görevi görerek bu gürültüyü EKG işareti ile karıştırırlar. Bu gürültü 100 kHz ve 1MHz arasındadır ve 1 ile 10 sn içerisinde sona erer.

Kuantizasyon gürültüsü ve aliazing: EKG işaretinin analogdan dijitale dönüştürülmesi esnasında meydana gelen gürültülerdir.

Sinyal işleme hataları: Fourier dönüşümündeki kısaltmalardan meydana gelen Gibbs osilasyonu ve diğer sinyal işleme hataları.

1.2.4. Tek Dipol Model

Kalp tarafından üretilen elektriksel aktivite kalpte bulunan hücrelerin iyon kanallarının açılıp kapanması ile konum değiştiren iyon transferlerinden meydana gelmektedir. Hücre seviyesinde meydana gelen bu uyumlu işlemler bir elektriksel alan meydana getirmekte ve vücut hacim iletkeni boyunca ilerlemekte olan bu elektriksel alan vücut yüzeyinden problemler vasıtasıyla ölçülebilmektedir. Kalbin bu elektriksel aktivitesi literatürde birçok farklı yöntem

ile modellenmiştir (tek dipol model, aktivasyon eşleme) [29]. Modellemelerin amacı kalbin elektriksel aktivitesini en basit ve en fazla bilgi içerecek şekilde temsil etmektir. Bu yöntemler arasında en basit ve popüler olanı tek dipol modeldir ve vücut yüzey potansiyelinin %80-90'ını açıkladığına inanılır [1,30]. Dipol'ün matematiksel ifadesi birbirinden l uzaklığına konmuş olan iki zıt işaretli yükün birbirlerine olan etkisi ile tanımlanır. Bu etki bir vektördür ve genliği ql 'ye eşittir. Yönü ise negatif yükten pozitif yüke doğrudur.

Tek dipol modele göre kalbin elektriksel aktivitesi zaman ile dönen vektör ile temsil edilebilir. Bu vektörün kaynağı kalbin merkezi ve uzayda yarı periyodik bir bölgeyi taradığı varsayılır. Bu vektörün matematiksel tanımı kartezyen koordinat sisteminde,


$$d(t) = x(t)\hat{i} + y(t)\hat{j} + z(t)\hat{k} \quad (1.1)$$

olarak tanımlanır [31]. Burada \hat{i} , \hat{j} ve \hat{k} kartezyen koordinat sistemindeki birim vektörleri temsil etmektedir. Dipol model kalp akımını modellemenin ve vücut yüzeyindeki elektriksel kayıtları modellemenin bir yoludur. Göğüs hacim iletkenindeki kalp potansiyelinin ilerlemesini modellemek için ek bir modele daha ihtiyaç vardır. Bu hacim iletkeninin pasif dirençsel bir ortam olarak varsayılarak herhangi bir EKG sinyali, kaydedici elektrotların yönünde $d(t)$ dipol vektörünün lineer izdüşümü olduğu varsayılır. Kaydedici elektrotların koordinatları $v = a\hat{i} + b\hat{j} + c\hat{k}$ olmak üzere EKG problemlerinden birinde gözlemlenen sinyal,

$$EKG(t) = \langle d(t), v \rangle = a.x(t) + b.y(t) + c.z(t) \quad (1.2)$$

olarak tanımlanır. Vücut hacim iletkeninin lineer yayılım modeli için oluşturulan tek dipol modelli kalp işaretini doğrulamak için Dower'ın EKG için geliştirmiş olduğu dönüşüm [30] ve bu dönüşümün tersi kullanılabilir. Bu dönüşümde kalp sadece üç bağımsız boyuta sahiptir ve vücut hacim iletkeninden kaydedilen her EKG sinyali, aynı üç kaynağın lineer bir kombinasyonudur. Buna rağmen kalbin tek dipol modeli kalbin aktivitesini gösterimde yeterli değildir. Bundan dolayı kardiyologlar kalbin aktivitesini ölçmek için üç probdan fazla (6 ile 12 arası) prob kullanılarak ölçümün yapılmasını önermektedirler [1]. Tek dipolün grafiksel gösterimi Şekil 1.5'de görülebilmektedir.

EKG problemlerinde gözlemlenen işaretler çok değişkenli veri olarak yorumlanabilir. Bu çok değişkenli veri içerisinde istenmeyen işaretler ve gürültü de bulunmaktadır. Bu gürültüler



Şekil 1.5. Tek dipol izdüşüm modeli

referans çizgi kayması, kas işaretleri ve elektrotun veya vücudun konum değişirmesi gibi sinyaller olabilir. Referans çizgi kayması, solunum sırasındaki vücut hacim iletkeninin değişmesinden dolayı meydana gelmektedir. Bu gibi gürültü kaynaklarının Dipol modele eklenmesi modeli daha gerçekçi yapacaktır.

1.3. Dinamik Model

Gerçek bir EKG işaretinden yararlı klinik bilgi elde etmek için R tepe bulma [32,33], Q-T aralık bulma [34], kalp atım oranının elde edilmesi ve nefes sinyalinin EKG üzerinden elde edilmesi [35,36] gibi sinyal işleme tekniklerine ihtiyaç vardır. Bu sinyal işleme algoritmalarının çoğu Physionet gibi veri tabanlarındaki gerçek sinyaller üzerine uygulanarak

performans değerlendirmeleri yapılır. Gerçek sinyallerin farklı gürültü seviyelerini ve farklı örnekleme frekanslarını kullanarak algoritmaların doğruluğunu kontrol etmek oldukça zordur. Bu nedenden dolayı algoritmaların performans karşılaştırmaları için dinamik bir EKG modeline ihtiyaç vardır.

McSharry [37] ve Sameni'nin [38] oluşturmuş oldukları dinamik modeller ile EKG işareti, Gauss fonksiyonlar kullanılarak bilgisayar ortamında yapay olarak oluşturulmakta ve algoritmaların performans ölçümleri için kullanılabilir. Her iki model üç tane adi türevsel denklemi temel alır ve bu denklemler ile gerçeğe çok yakın EKG işareti üretilebilmektedir. Üretilen EKG işaretinin kalp atımının ortalama değeri, standart sapması, PQRST safhalarının morfolojik şekli modeller tarafından belirlenebilmektedir. McSharry'nin modeli ile Sameni'nin algoritmaları arasındaki fark; McSharry modeli kurarken kartezyen koordinat sistemini seçerken, Sameni'nin polar koordinat sistemini tercih etmiş olmalarıdır.

Modellerde kullanılan Gauss fonksiyon sayısı modellenecek işarettaki M tane simetrik, N tane simetrik olmayan dönme noktasına bağlı olarak $M+2N$ tane Gauss fonksiyon olarak belirlenir [39]. Dinamik modelde üç boyutlu durum uzayı içerisinde x , y , z koordinatları ile yapay periyoda sahip bir yörünge oluşturulmaktadır. EKG'nin yapay periyodu, x,y düzlemindeki yörüngenin hareketi ile temsil edilir. Daire üzerindeki her bir tur kalp atımına veya RR aralığına karşılık gelmektedir. z eksenindeki değişim hareketi EKG işaretindeki kalp atımının değişimi veya genlik değeri değişimini temsil etmektedir. EKG işaretindeki P, Q, R, S, T gibi safhalar z yönündeki pozitif veya negatif yaklaşım veya uzaklaşım karşılık gelmektedir. Dinamik modelde P, Q, R, S, T noktaları birim daire üzerinde θ_p , θ_q , θ_r , θ_s ve θ_t sabit açıları ile yerleştirilirler. Yörünge bu açılardan birine yaklaştığı zaman limit döngüden aşağı veya yukarı doğru itilir ve hareketten sonra limit döngüye doğru geri çekilir. Hareketin dinamik denklemleri üç tane adi türevsel denklem ile,

$$\begin{aligned} \dot{x} &= \alpha_d x - w_a y \\ \dot{y} &= \alpha_d y + w_a x \\ \dot{z} &= - \sum_{i \in \{P, Q, R, S, T\}} a_i \Delta \theta_i \exp\left(-\frac{\Delta \theta_i^2}{2b_i^2}\right) - (z - z_0) \end{aligned} \quad (1.3)$$

şeklinde elde edilir [40]. Bu denklemlerdeki,

$$\alpha_d = 1 - \sqrt{x^2 + y^2}$$

$$\Delta\theta_i = (\theta - \theta_i) \bmod 2\pi$$

$$\theta = a \tan 2(y, x) \quad (-\pi \leq a \tan 2(y, x) \leq \pi)$$

a_i safhaların genliği, b_i safhaların bant genişliği ve w_a yörünge'nin açısal hızıdır. Taban çizgisi dolanması, taban çizgisi z_0 'ın nefes alıp verme frekansı ile birleştirilmesi ile,

$$z_0(t) = A_z \sin(2\pi f_z t) \quad (1.4)$$

şeklinde tanımlanır. (1.4) denklemindeki taban çizgisi genliği A_z 'nin değeri 0.15 mV olarak seçilir. Bu hareket denklemleri, Tablo 2'deki parametre değerleri dördüncü dereceden Runge-Kutta metodu içinde kullanılarak nümerik olarak hesaplanır. Runge-Kutta metodu için zaman adımı olarak $\Delta t = 1/f_s$ (f_s örnekleme frekansı) seçilir. Bu tezde yapılan tüm dinamik modelleme çalışmalarında örnekleme frekansı f_s 256 Hz olarak alınmıştır. Bu parametre değerleri uygun seçilerek normal bir EKG işareti üretilebileceği gibi parametrelerde değişimler yapılarak normal olmayan (hastalıklı) kalp işaretleri de üretilebilir.

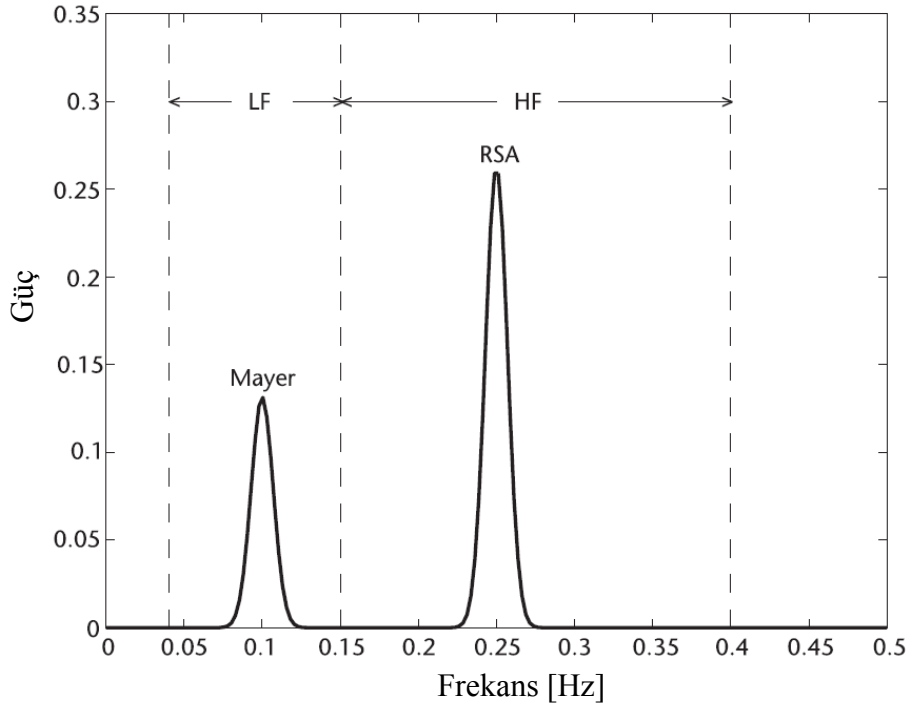
Tablo 2. Yapay EKG işareti için parametre değerleri

İndeks (i)	P	Q	R	S	T
Zaman (sn)	-0.2	-0.05	0	0.05	0.3
θ_i (radyan)	$-\frac{1}{3}\pi$	$-\frac{1}{12}\pi$	0	$\frac{1}{12}\pi$	$\frac{1}{2}\pi$
a_i	1.2	-5	30	-7.5	0.75
b_i	0.25	0.1	0.1	0.1	0.4

Tablo 2'de R tepesinin pozisyonuna bağlı olarak zaman, θ_i , a_i , b_i değerleri verilmiştir [26]. Gerçek EKG işaret döngüsü ile dinamik model karşılaştırılacak olunursa, limit döngünün bir turunu tamamlamak için gerekli zamanın gerçek EKG işaretindeki RR aralığına benzediği görülür. Ayrıca gerçek EKG işaretinin frekans domenindeki davranışına benzeşim sağlamak için, RR aralığının güç spektrumundaki RSA ve Mayer dalgalarının etkisi (RSA yüksek frekanslı bileşeni, Mayer alçak frekanslı bileşeni oluşturur), iki tane Gauss dağılımının toplamalarının dinamik modelin güç tayfına dahil edilmesi ile yapay olarak elde edilmesi,

$$S(f) = \frac{\sigma_1^2}{\sqrt{2\pi c_1^2}} \exp\left(-\frac{(f-f_1)^2}{2c_1^2}\right) + \frac{\sigma_2^2}{\sqrt{2\pi c_2^2}} \exp\left(-\frac{(f-f_2)^2}{2c_2^2}\right) \quad (1.5)$$

denklemleri ile sağlanır. Burada f_1, f_2 ortalama değerleri, Mayer ve RSA dalgalarının frekanslarının merkezlerini, c_1, c_2 bu dalgaların standart sapmalarını temsil etmektedir. Alçak frekans ve yüksek frekans bantlarındaki güç σ_1^2 ve σ_2^2 ile gösterilmektedir ve LF/HF oranı (alçak ve yüksek frekansın güç tayfı oranı) σ_1^2/σ_2^2 ile bulunmaktadır. LF/HF oranı kalp atım oranının değişimindeki parasempatik ve simpatik denge değerini temsil etmektedir. Fakat tam olarak bu konuda bir görüş birliği yoktur.



Şekil 1.6. Yapay EKG işaretinin spektral karakteristiği [31]

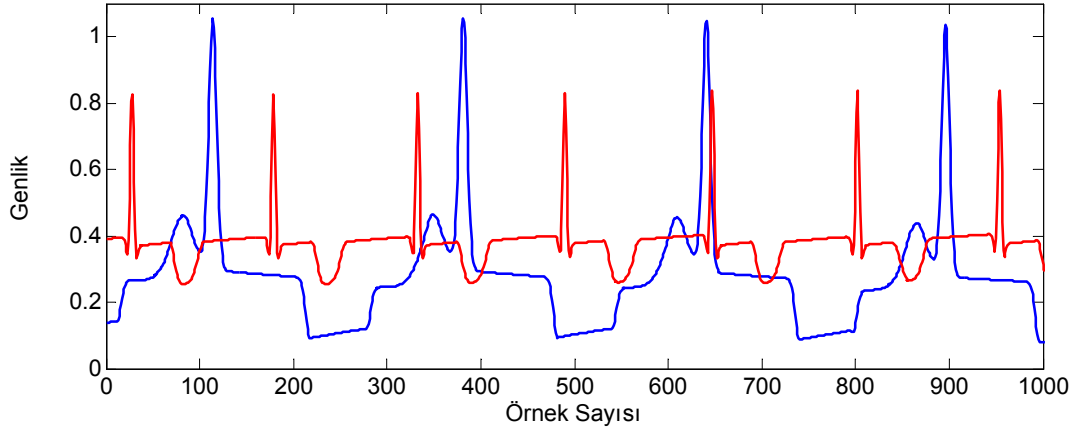
Yapılan çalışmalarda dinamik modelin güç tayfı için $f_1 = 0.1$, $f_2 = 0.25$, $c_1 = 0.01$, $c_2 = 0.01$ ve $\sigma_1^2/\sigma_2^2 = 0.5$ olarak seçilmiştir ve Şekil 1.6'da bu değerler için güç tayfı gösterilmiştir.

Güç tayfından RR zaman serisi $T(t)$ 'yi elde etmek için $\sqrt{S(f)}$ genliği bulunur, faz bilgisi $0-2\pi$ arasında rastgele şekilde oluşturulur ve ters Fourier dönüşümü alınır. Bu zaman serisi

uygun ölçekleme sabiti ve ofset değeri ile çarpılarak istenilen değerde ortalama ve standart sapmalı zaman serisi elde edilebilir. $T(t)$, RR işlemi ile $S(f)$ güç spektrumu tarafından üretilmiş zaman serisi olduğu varsayılırsa, limit döngü etrafında hareket eden zamana bağımlı açısal hız,

$$w_a(t) = \frac{2\pi}{T(t)} \quad (1.6)$$

denklemleri ile elde edilir. Bu yöntem ile, yapay EKG işaretinin $S(f)$ ye eşit güç spektrumuna sahip olması garantilenmiş olacaktır. Üstte anlatılan yöntem ile yapay olarak elde edilmiş anne ve fetusa ait EKG işaretleri Şekil 1.7’de görülmektedir. Bu şekildeki anne EKG’si dakikada altmış atım, FEKG dakikada doksan beş atım olacak şekilde parametreler düzenlenmiştir.



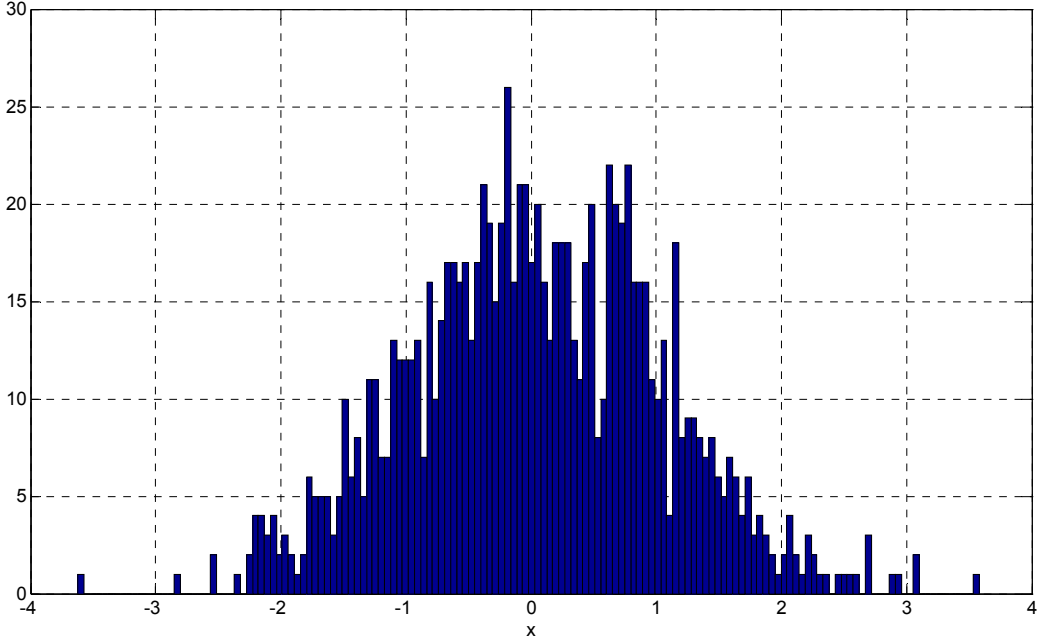
Şekil 1.7. Yapay olarak elde edilmiş anne ve fetusa ait EKG ve FEKG işaretleri

Anne EKG’si Şekil 1.7’de büyük genliğe sahip işaret iken FEKG işareti küçük genliğe sahip işaretidir. Şekilden görüleceği üzere anne EKG’sinin genliği FEKG’ye göre büyük ve dakikadaki atım sayısı daha küçüktür. Anne EKG’sinin ve FEKG’nin PQRST fazları net olarak görülebilmektedir.

1.4. Olasılık Yoğunluk Fonksiyonu Kestirim Yöntemleri

Olasılık, tüm dünyadaki verilerdeki ve olaylardaki belirsizliğin temelinin anlamamıza yardım eden bir mekanizmadır. Bu mekanizmanın işe yarayabilmesi için meydana gelen olayın sonucunun her olay tekrarlanmasından sonra değişmesi gerekmektedir. Bu sonuçtaki değişim çözümdeki hatadan veya test için farklı objelerin seçilmesinden meydana gelebilir. Bu sonuçların modellenmesi ve analizi istatistik biliminin temelinin oluşturur.

Rastgele seçilen olaylar veya yapılan deneylerde ortaya çıkan sonuçlara rastgele değişkenler adı verilir. Rastgele meydana gelen sonuçları tanımlayan en iyi ifade ise, o sonucun belli bir aralık veya değer için meydana gelme miktarını ölçen olasılık kavramıdır. Olasılık her zaman 0 ile 1 arasında değişim gösterir. Bir olayın olasılığını belirlemek için en eski ve sık kullanılan yöntem histogramdır. Histogram bir sonucun veya olayın meydana gelme sayıları f sayılarak oluşturulur. Şekil 1.8'de bir değişken için histogram örneği görülmektedir. Histogramda görünen çizgiler olayın meydana gelme sayıları f leri temsil etmektedir.




Şekil 1.8. Histogram

Histogramdan olasılık yoğunluk fonksiyonuna geçişin bir yolu, sonuçların meydana gelme sayılarının toplam sonuç sayısına bölünmesi ile Şekil 1.9. deki gibi elde edilir.


Genel olasılık yoğunluk fonksiyon ölçüm metodu olarak frekans metotları veya parametrik yaklaşım metotlarıdır. Parametrik yaklaşımlarda amaç, rastgele verinin olasılık

yoğunluk fonksiyonunu bilinen bir olasılık yoğunluk fonksiyonuna uygun hale getirmek için uygun parametreleri bulmaktır. Verilen bir rastgele x verisi için parametrik olasılık yoğunluk fonksiyonu $p(\cdot|\theta)$ ile tanımlanır. Bu ifadeye θ parametreleri temsil etmektedir ve olasılık fonksiyonu bu parametreler sayesinde bulunabilmektedir. Buradaki amaç θ parametrelerinin optimum tahminleri $\hat{\theta}$ 'ları ile tüm olasılık fonksiyonunun tahminini (\hat{p}) elde etmektir. Genellikle parametreler, rastgele verinin olabilirliği maksimize yapılarak elde edilebilir ($p(x|\hat{\theta})$ maksimize yapılır). Parametrik yaklaşıma normal dağılımdan örnek verilecek olursa; normal dağılımdaki parametreler verinin ortalaması μ ve varyansı σ^2 'dir. Normal dağılıma sahip değişken için ortalama değerin ve varyansın hesaplanması; bu değişkenin tüm olasılık yoğunluk fonksiyonunun hesaplanması anlamına gelmektedir.



Şekil 1.9. Histogram grafiğinden elde edilmiş olasılık yoğunluk fonksiyonu

Olasılık fonksiyonlarının tahmininde parametrik yaklaşım kullanılmasının ana avantajı birkaç parametre ile olasılık fonksiyonunun tahmininin tanımlanabilmesidir. Fakat bu tanımlama yapılmadan önce rastgele verinin yapısı hakkında bir ön bilgi (olasılık fonksiyonunun şekli) olması gerekmektedir. Gerçek zamanlı problemlerde ise bir çok uygulama için bu ön bilgi mümkün değildir. Özellikle Şekil 1.10'daki gibi çok modlu veri için olasılık fonksiyonu tahmini zordur.



Şekil 1.10. Çok modlu olasılık yoğunluk fonksiyonu

1.4.1. Kernel Yoğunluk Fonksiyon Tahmin Yöntemi

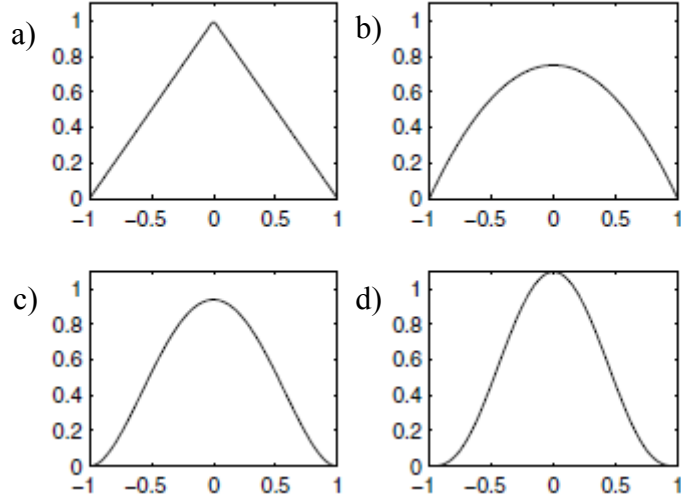
Parametrik modelin aksine, parametrik olmayan olasılık yoğunluk fonksiyonu tahmin teknikleri doğrudan rastgele veriyi kullanmaktadır. Bundan dolayı, bu yöntem ile bulunan olasılık fonksiyonu, daha çok verinin yapısına bağlıdır. En çok bilinen parametrik olasılık yoğunluk fonksiyon tahmin yöntemi histogramdır. Histogramlar 1950 yılına kadar tek parametrik olmayan yöntemdi [41].

Günümüzde en popüler parametrik olmayan olasılık yoğunluk fonksiyonu kestirim yöntemi kernel yoğunluk fonksiyonu tahmin yöntemidir. Bu yöntemin üzerinde ilk olarak 1950 ile 1960 yılları arasında çalışılmıştır. Bir boyutlu y verisi için kernel yoğunluk tahmin yöntemi,

$$P_{y_i}(y_i) = \frac{1}{Mh} \sum_{m=1}^M \phi\left(\frac{y_i - Y_{im}}{h}\right) \quad (1.7)$$

denklemini ile elde edilebilir. Burada h , kernelin bant genişliğidir ve aynı zamanda düzleştirme parametresi olarak da isimlendirilir. Tahmin edicinin performansının üzerinde en etkili olan parametre h bant genişliğidir. ϕ kernelleri temsil etmektedir ve genellikle simetrik normal olasılık yoğunluk fonksiyonu olarak seçilirler. M ise olasılık değerleri merkez noktası sayısıdır. Denklem (1.7) ifadesi, her bir noktaya yerleştirilmiş ϕ kernelinin ortalama etkisi olarak görülebilir. Kernel tahmin edici, tahmin edilecek nokta civarında bir penceredeki veri noktalarının ağırlıklı ortalamalarını hesaplar.

Literatürde bir çok kernel çeşidi vardır. Bunlardan bir kaçını matematiksel ifadesi Tablo 3’de ve dört kernelin grafiği ise Şekil 1.11’de görülmektedir.

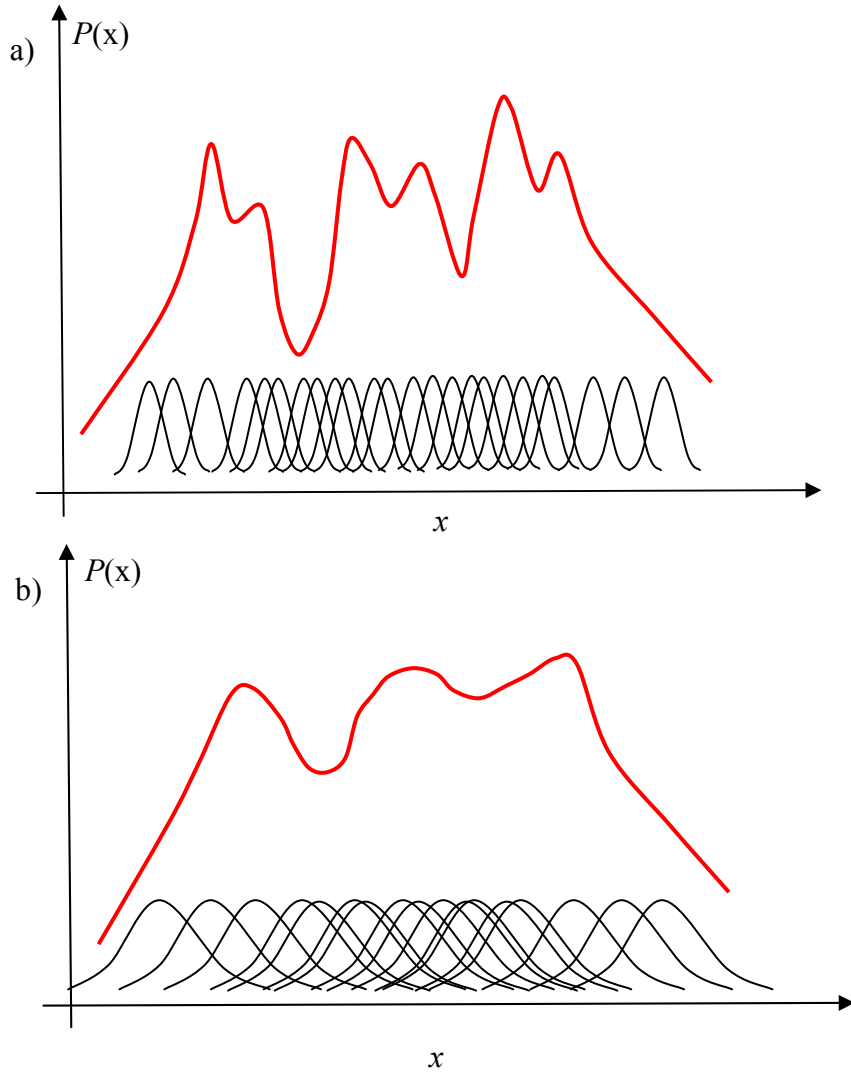


Şekil 1.11. Kernel grafikleri a) Üçgen kernel b) Epanechnikov kernel
c) İki ağırlıklı kernel d) Üç ağırlıklı kernel

Tablo 3. Yoğunluk fonksiyon tahmini için kullanılan kerneller

Kernel Adı	Denklem	Sınırlar
Üçgen	$\phi(t) = (1 - t)$	$-1 \leq t \leq 1$
Epanechnikov	$\phi(t) = \frac{3}{4}(1 - t^2)$	$-1 \leq t \leq 1$
İki Ağırlıklı	$\phi(t) = \frac{15}{16}(1 - t^2)^2$	$-1 \leq t \leq 1$
Üç Ağırlıklı	$\phi(t) = \frac{35}{32}(1 - t^2)^3$	$-1 \leq t \leq 1$
Normal	$\phi(t) = \frac{1}{\sqrt{2\pi}} e^{-t^2/2}$	$-\infty \leq t \leq \infty$

Tablo 3’deki denklemlerin birer olasılık yoğunluk fonksiyon kestirimi olabilmeleri için $\int \phi(t)dt = 1$ eşitliğini sağlamalı ve $\phi(t) \geq 0$ olmalıdır. Kernel kestirimi için diğer bir önemli özellikte h bant genişliğinin seçimidir. Uygun bir bant genişliği ile olasılık yoğunluk fonksiyonunun tüm özellikleri Şekil 1.12.a’daki gibi elde edilebilir. h büyük seçilecek olursa



Şekil 1.12. Bant genişliğinin (h) olasılık yoğunluk fonksiyon kestirimi üzerine etkisi

olasılık yoğunluk fonksiyonundaki detaylar Şekil 1.12.b'deki gibi düzleşecek ve kaybolacaktır.

Uygun h seçimi ile kernel tahmin ediciler histogramlardan daha hızlı yakınsama hızına sahip olurlar. Bu da h 'ın seçiminin ϕ 'nin seçiminden daha önemli olduğunu gösterir. h 'ın optimal değerini bulmanın bir yolu çapraz doğrulama yöntemidir. Bu algoritmanın temelinde örnekten tekil değeri ortadan kaldırma (x_i) ve sonra geri kalan $n-1$ örnek için uygun yoğunluk tahminini hesaplamaya dayanır. Bu işlemin matematiksel ifadesi,

$$P_{y_l}(y_l) = \frac{1}{(M-1)h} \sum_{m \neq l} \phi\left(\frac{y_l - y_m}{h}\right) \quad (1.8)$$

şeklindedir. Bu denklemde $P_{y_l}(y_l)$ 'nin tüm değerleri için uygun kritere göre h değeri seçilir.

Yapılan bir diğer çalışma da h 'in optimum değerinin veri uzunluğuna göre,

$$h = 1.06M^{-1/5} \quad (1.9)$$


denklemini ile belirlenebileceğini göstermiştir [42]. Bu çalışmaya göre az örnek sayısına sahip veriler için büyük bant genişliği değeri ile, çok fazla örnek sayısına sahip veriler için daha küçük bant genişliği değeri ile olasılık yoğunluk fonksiyonunun tahmini yapılmalıdır.

Çok boyutlu verinin birleşik olasılık yoğunluk fonksiyonunun parametrik olmayan yöntem ile tahmini, kernellerin çarpımı yöntemi ile,

$$P_x(x) = \frac{1}{(Mh)^d} \sum_{m=1}^M \prod_{j=1}^d \phi_j\left(\frac{x - x_m}{h}\right) \quad (1.10)$$

denklemindeki gibi elde edilir. Bu denklem ile elde edilmiş iki boyutlu birleşik olasılık yoğunluk fonksiyonu Şekil 1.13'te görülmektedir.

BBA algoritmaları içinde kullanılacak olan olasılık yoğunluk fonksiyon kestirimlerindeki en önemli özellik; kestirimi yapılmış olan olasılık yoğunluk fonksiyonunun türevinin alınabiliyor olmasıdır. Histogram teknikleri ile bulunan olasılık yoğunluk fonksiyonlarında ise en önemli dezavantaj türevlerinin alınamayışıdır. Parametrik yaklaşımlarda da çok modlu sinyalleri modelleme problemleri meydana gelmektedir. Bu olumsuzluklardan dolayı kernel yoğunluk fonksiyonu tahmini yöntemleri, olasılık yoğunluk kestirimi için diğer yöntemlere göre daha uygundur. Fakat işlem yükleri diğer algoritmalara göre çok fazladır.



Şekil 1.13. Birleşik olasılık yoğunluk fonksiyonu

1.5. Bilgi Teorisi

Bir maddesel sistemin durumu kesin olarak biliniyorsa, bunun hakkında aktarılan bilgi çok değerli değildir. Buna göre, gelişigüzel olarak herhangi bir durumda bulunan bir sisteme ilişkin alınan bir bilginin ne kadar değerli olduğunu ölçmeye yarayan bir ölçüt olmalıdır. Buna sistemin kararsızlık derecesi veya bilgi ölçümü denir. Bir sistemin kararsızlık derecesi sadece mümkün olan durum sayısı ile değil; o durumda bulunma olasılıkları ile bağlantılıdır. Rastgelelik içeren bir sistemin (X) bulunabileceği durumlar x_1, x_2, \dots, x_n olsun. Her bir durumun olasılığı $p_i = P(X = x_i)$ olmak üzere, sistem,

$$X \equiv \begin{pmatrix} x_1, x_2, \dots, x_n \\ p_1, p_2, \dots, p_n \end{pmatrix} \quad (1.11)$$

ifadesi ile temsil edilebilir. Sistemin kararsızlık derecesini veren ifadelerden biri olasılıkların logaritmasını almaktır. Olasılıkların logaritmalarının alınması işlemi Hartley'e [43] kadar gitmektedir. Hartley tarafından bulunan bilgi ölçümü,

$$Hartley = -\log(P(X = x_i)) = -\log(p_i) \quad (1.12)$$

denklemleri ile ifade edildi. 1948’de Shannon ve Wiener [44] birbirlerinden bağımsız olarak sınırlı olasılık dağılımları için bilgi miktarının ölçümünü Hartley bilgi ölçümünün ortalamasını alarak elde ettiler ve bu ölçüm entropi olarak adlandırıldı. Ayrık durumlarda bulunan bir X sisteminin entropisi,

$$H_s = E\{Hartley\} = E\{-\log P(X = x_i)\} = -\sum_{k=1}^n p_k \log p_k \quad (1.13)$$

şeklinde tanımlanmaktadır. Shannon bu entropi ölçümünü bilgi ölçümü olarak adlandırıp çalışmalarında pek çok önemli özelliklerini ispatlamıştır. İspatlamış olduğu özelliklerden en önemlisi bağımsız bileşenler için geçerli olan toplamsallık özelliğidir. İşaretler bağımsız ise birleşik olasılık yoğunluk fonksiyonu,

$$p_{x,y}(x, y) = p_x(x)p_y(y) \quad (1.14)$$

şeklinde ayrı ayrı bileşenlerinin olasılık yoğunluk fonksiyonlarının çarpımı şeklinde yazılabilir. Denklem (1.14)’den yararlanılarak bağımsız işaretlerin birleşik olasılık yoğunluk fonksiyonlarının Entropi’si toplamsallık özelliğine göre,

$$H_s(X, Y) = H_s(X) + H_s(Y) \quad (1.15)$$

denklemindeki gibi bağımsız bileşenlerin entropilerinin toplamı şeklinde ifade edilebilir. Üstteki denklemde $H_s(X, Y)$ birleşik olasılık yoğunluk fonksiyonunun entropisini temsil ederken $H_s(X)$ ve $H_s(Y)$ bağımsız bileşenlerin entropilerini temsil etmektedir. Bu özellikten dolayı (1.11) denklemi BBA algoritması için amaç fonksiyonu olarak kullanılabilir [45].

Shannon’un entropi ölçümü literatürdeki tek entropi ölçüm yöntemi olmayıp 1960 yılında matematikçi Albert Renyi Shannon entropisine alternatif olarak Renyi entropisini öne sürmüştür [46]. Renyi’nin entropi ölçümünü oluşturan temel fikir, entropide kullanılan lineer ortalamanın, ortalama almak için kullanılan tek yol olmayışıdır. Herhangi bir rastgele fonksiyon kullanılarak da ortalama değer bulunabilir. Bunu yaparken fonksiyonun sürekli ve monoton fonksiyon olarak seçilme zorunluluğunu Hardy, Littlewood ve Polya göstermiştir [47]. Renyi tanımlamış olduğu entropi ölçümünü,

$$S_\alpha(p) = \frac{1}{1-\alpha} \ln \sum_{k=1}^n p_k^\alpha \quad (1.16)$$

denklemini ile ifade etmiştir. Burada, α ($\alpha \neq 1, \alpha > 0$) eksponansiyel fonksiyona karşılık gelen parametredir ve genelleştirilmiş ortalamayı tanımlamakta olup, entropi indeksi olarak da bilinmektedir. Shannon'un entropi ölçümü tüm entropi ölçümleri için referans kabul edilmiştir ve Renyi entropi ölçümü $\alpha \rightarrow 1$ limit sınırlarında Shannon'un entropi ölçümüne eşit olmaktadır. Bu çalışmadan sonra bilgi ölçümü pek çok bilim adamının ilgi alanı olmaya devam etmiştir ve 1988 yılında fizikçi Tsallis bilgi ölçüm için yeni bir yöntem öne sürmüştür [48]. Bu yöntemde entropi ölçümü,

$$S_q(p) = \frac{1 - \sum_k p_k^q}{q-1} \quad (1.17)$$

denklemini ile ifade edilmiştir. Bu bilgi ölçümü Renyi'nin ölçümüne çok benzemektedir ve $q \rightarrow 1$ 'e yakınsar iken (1.17) ifadesi Shannon'un entropi ölçümüne eşit olmaktadır. Tsallis entropi ölçümünün önemli ve henüz anlaşılamayan özelliği bağımsız bileşenler için (1.15) denkleminde ifade edilen toplanabilirlik özelliğinin sağlanmıyor olmasıdır. Bundan dolayı Tsallis entropi yaygın olmayan istatistik olarak da adlandırılır. Tsallis entropi ölçümünde toplamsallığın yerini,

$$S_q(X, Y) = S_q(X) + S_q(Y) + (1-q)S_q(X)S_q(Y) \quad (1.18)$$

denklemini ile ifade edilen yapay toplamsallık almıştır. Bu ifade sadece X ve Y değişkenleri birbirlerinden bağımsız ise geçerlidir. Shannon'un toplamsallık özelliğinde olduğu gibi $S_q(X, Y)$ değişkenlerin birleşik olasılık yoğunluk fonksiyonlarının Tsallis entropisini temsil ederken $S_q(X)$ ve $S_q(Y)$ ayrı ayrı değişkenlerin olasılık yoğunluk fonksiyonlarının Tsallis entropilerini temsil etmektedir.

1.5.1. Relatif Entropi (Diverjans)

Diğer bilgi teorisi ölçümleri özel durum olarak relatif entropi türünden formülize edilebildiklerinden dolayı relatif entropi bilgi teorisinde önemli bir kavramdır. Relatif entropi, iki değişkenin birbiri ile olan ilişkisini gösteren bir ölçümdür. Relatif entropi veya bilgi diverjansı formülünü 1951’de Kullback ve Leibler bulmuştur [49]. Bu ölçüm aynı zamanda KL-entropi, çapraz entropi, I-diverjans ve yöneltmiş diverjans olarak da adlandırılır. Relatif entropinin matematiksel ifadesi,

$$I(p_x(x)||p_y(y)) = I(X||Y) = \sum_{k=1}^n p_x(x(k)) \ln \frac{p_x(x(k))}{p_y(y(k))} \quad (1.19)$$

denklemleri ile tanımlanır. Burada X, Y değişkenleri, $p_x(x), p_y(y)$ ise bu değişkenlerin olasılık dağılımlarını temsil etmektedir. Eşitlik sadece $p_x(x)$ ve $p_y(y)$ birbirine eşit olduğu zaman sıfır olmaktadır. $p_x(x)$ ve $p_y(y)$ birbirinden farklı ise diverjans ölçümü farklılık derecesine bağlı olarak değer üretecektir.

1.6. Bağımsız Bileşen Analiz Algoritmaları (BBA)

Kaynakların kör ayrıştırım (KKA) çerçevesinden bakıldığında, sinyalleri bağımsız sinyallere ayrıştırma fikri ilk Jutten ve Herault [2] tarafından 1991 yılında ortaya atılmıştır. BBA terimi ise Comon tarafından 1994 yılında “lineer BBA’nın teorisi” [3] adlı yayınında koyulmuştur.

Bu alan Bell ve Sejnowski nin 1995 yılında Infomax prensibini [50] incelemesi ile çok hızlı bir şekilde popüler olmuştur. Daha sonra Amari 1998 yılında Infomax kuralını basitleştirerek doğal gradyant kavramını [51] bulmuştur. 1999 yılında Hyvarinen diğer algoritmalar arasında en etkin algoritma olan Hızlı BBA algoritmasını [52], negentropi ve basıklığı amaç fonksiyon kullanarak geliştirmiştir. Sinirsel öğrenme kümeleme algoritmalarını temel alan Geometrik BBA algoritması [53] ise ilk olarak Puntonen tarafından 1995 yılında bulunmuş ve Fabian Theis [54] tarafından geliştirilmiştir. Geometrik BBA algoritmasını diğer algoritmalarla göre çekici kılan yön, uygulanmasının ve anlaşılmasının kolay oluşudur. Günümüzde ise BBA algoritmaları akustik, biyoloji, kimya, bilgisayar

mühendisliği, finans, tıp, fizik, istatistik, işaret işleme ve telekomünikasyon gibi pek çok alanda uygulama alanı bulabilmektedir [55-58].

Çok kipli zaman serisi analiz tekniği olan BBA algoritmalarının amacı verilen bir veri dizisi içerisinde istatistiksel olarak bağımsız sinyalleri bulmaktır. Fakat bulunan sinyaller denklem (1.10)'da ifade edildiği gibi hiçbir zaman birbirlerinden tamamen bağımsız olmayabilirler. Bu tanımlamalara bağlı olarak BBA algoritmalarındaki bağımsız kaynak işaretlerinin karışımının matematiksel ifadesi,

$$\begin{bmatrix} X_1 \\ X_2 \end{bmatrix} = \begin{bmatrix} a_{11} & a_{12} \\ a_{21} & a_{22} \end{bmatrix} \begin{bmatrix} S_1 \\ S_2 \end{bmatrix} \quad (1.20)$$

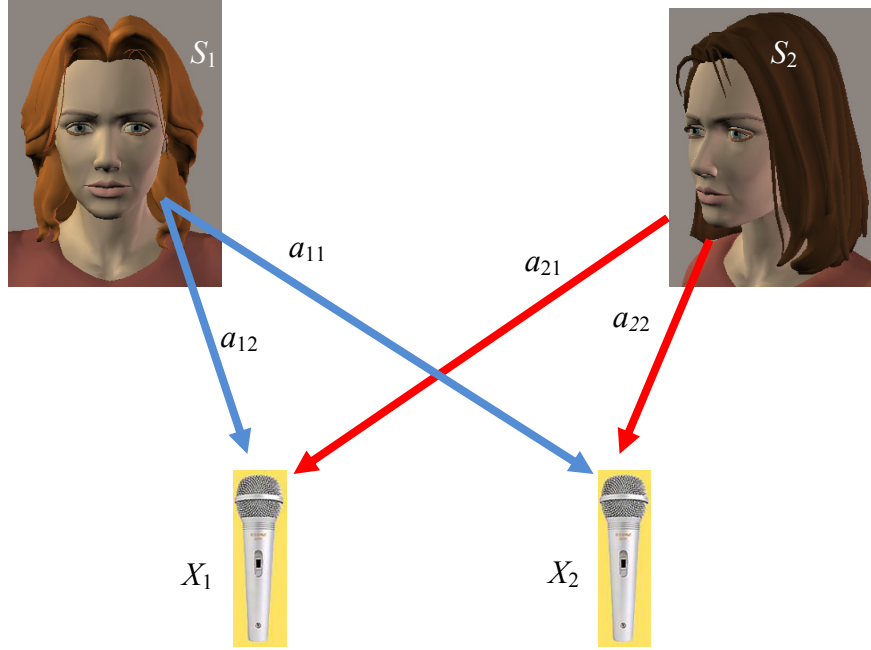
$$x(t) = As(t) \quad (1.21)$$

denklemleri ile tanımlanabilir. Denklem (1.20)'yi açıklayabilecek en iyi örnek kokteyl parti problemi (KPP) [59]. Bu problem aynı zamanda KKA problemi olarak da isimlendirilir. KPP'de, iki konuşmacının aynı ortamda rastgele olarak birbirleri ile konuştuğu ve bu konuşmaların en az iki mikrofon ile kayıt edildiği düşünülür. Buradaki amaç, S_1 ve S_2 kaynaklarını (konuşmacıların sesleri) ve a_{ij} karışım işlemini (ortamın özelliğini) bilmeden, sadece kaydedilmiş X_1 , X_2 konuşma sinyalleri kullanılarak kaynak sinyallerinin yeniden oluşturulmasıdır. Bu işlem Şekil 1.14'de görülebilmektedir. Bu işlemin gerçekleştirilebilmesi için kaynakların denklem (1.14)'deki gibi istatistiksel olarak birbirinden bağımsız olduğu varsayılır.

BBA algoritmaları sadece, kokteyl parti problemi için doğru çözümü bulmaz, aynı zamanda çoğu uygulamada verinin temel yapısını, gizli değişkenleri ortaya çıkarır. Sinyallerin bağımsızlık varsayımı çok kuvvetli bir özelliktir ve ayrıca çok kipli veri serilerinin analizi için çok yararlıdır. Denklem (1.10)'da iki bağımsız değişken için tanımlanan ifade n kipli istatistiksel olarak bağımsız kaynak sinyali $s(t) \in R^n$ serisi için,

$$p_s(s) = \prod_{i=1}^n p_s(s_i) \quad (1.22)$$

denklemindeki gibi genelleştirilebilir. Bu denklemde s , n boyutlu rastgele değişken, s_i ise s 'nin i . bileşenidir. Karışım ortamının $m \times n$ boyutunda olduğu varsayılır ise $A \in R^{m \times n}$, karışım sinyalleri $x(t) \in R^m$, m boyutlu olarak modellenebilir.



Şekil 1.14. Kokteyl parti problemi (KPP)

1.6.1. İlinti ve Bağımsızlık

İlinti, verilen iki veri arasında ilişki olup olmadığını gösteren istatistiksel işlemdir. r_{ij} , rastgele vektör x 'in i . ve j . bileşenleri arasındaki ilinti,

$$r_{ij} = E\{x_i x_j\} = \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} x_i x_j p_{x_i, x_j}(x_i, x_j) dx_i dx_j \quad (1.23)$$

denklemleri ile tanımlanır. Bu denklem ile hesaplanan ilinti sıfır, pozitif veya negatif olabilir. Eğer ilinti sıfıra eşitse, rastgele değişkenler ilintisiz olarak isimlendirilir. Rastgele vektör x 'in tüm elemanları arasındaki ilintinin hesaplanması için ilinti matrisi,

$$R_x = E\{xx^T\} \quad (1.24)$$

şeklinde tanımlanır. Merkez momentleri kullanarak da bir tür ilinti ölçümü olan kovaryans matris tanımlanabilir. Kovaryans işleminin ilinti işleminden farkı, vektörlerin ortalama değerlerinin işlem yapılmadan önce çıkarılmış olmalarıdır. x vektörünün ortalaması $m_x = E\{x\}$ olmak üzere kovaryans işlemi,

$$C_x = E\{(x - m_x)(x - m_x)^T\} \quad (1.25)$$

şeklinde tanımlanır. Ortalama (m_x) değeri sıfır ise ilinti ve kovaryans matrisleri birbirlerine eşittir. x ve y gibi iki farklı vektörün karşılıklı ilinti ve karşılıklı kovaryans matrisleri,

$$R_{xy} = E\{xy^T\} \quad (1.26)$$

$$C_{xy} = E\{(x - m_x)(y - m_y)^T\} \quad (1.27)$$

denklemleri ile hesaplanabilir. Eğer bu iki vektörün karşılıklı kovaryans matrisi sıfıra eşit ise x ve y vektörlerinin ilintisiz olduğu söylenebilir ($C_{xy}=0$). Denklem (1.14)'ü sağlayan bağımsız değişkenler (1.27) denklemini de sağlar. Bu bağımsız olan değişken aynı zamanda ilintisizdir anlamına gelmektedir. Fakat bunun tersi doğru değildir. Bağımsız ve ilintisiz değişkenler arasındaki bir diğer fark ise bağımsız değişkenler,

$$E\{g(x)h(y)\} = E\{g(x)\}E\{h(y)\} \quad (1.28)$$

eşitliğini sağlar iken, ilintisiz işaretler bu eşitliği sağlamazlar. Burada, $g(x)$ ve $h(y)$, x ve y 'nin lineer olmayan denklemler içine konularak dönüşüme tabi tutulduklarını ifade eder. Bu denklem bağımsızlık ifadesinin ilintisizlik ifadesinden daha kuvvetli bir özellik olduğunu gösterir.

Gauss dağılımına sahip ilintisiz rastgele değişkenler aynı zamanda bağımsızdırlar. Bu yukarıda ifade edilenlere ters düşer. Fakat Gauss dağılımına sahip değişkenler için özel bir durumdur, diğer dağılımlar bu özelliği sağlamazlar. x 'in n boyutlu Gauss olasılık yoğunluk fonksiyonu,

$$P_x(x) = \frac{1}{(2\pi)^{n/2} \sqrt{\det C_x}} e^{-\frac{1}{2}(x-m_x)^T C_x^{-1}(x-m_x)} \quad (1.29)$$

şeklinde yazılacak olursa ve eğer x verisinin ilintisiz olduğu varsayılırsa, C_x matrisinin köşegenel matris olduğu görülür. Buna bağlı olarak C_x in tersi de köşegendir. Bu, üstel fonksiyon üzerindeki x verisinin ayrıştırılabileceğini ve toplam olasılık yoğunluk fonksiyonu $P_x(x)$ 'in x verisini oluşturan değişkenlerin olasılık yoğunluk fonksiyonlarının çarpımı şeklinde yazılabileceğini gösterir. Ayrıştırma bağımsızlığın kriteri olduğundan dolayı; ilintisiz Gauss rastgele vektörler, aynı zamanda bağımsızdırlar denilebilir.

BBA algoritma uygulamalarında ikiden fazla Gauss değişken varsa, bu Gauss değişkenler bağımsız olsa bile, BBA algoritması bu değişkenleri ayrıştırmada yetersiz kalacaktır. Bunun açıklaması: eğer x , sıfır ortalamalı bağımsız Gauss dağılıma sahip ve olasılık yoğunluğu üstteki denklemdeki gibi ise, bir ortogonal matris O 'nun her transformasyonu altında ($y=Ox$) y 'nin olasılık yoğunluğu değişmez ($P_y(y) = P_x(x)$). Bundan dolayı BBA sadece Gauss dağılımlı rastgele değişkenlerin karışımının ayrıştırıcı matrisini ortogonal matrise bağlı olarak bulur.

1.6.2. KKA Problemi ve BBA Algoritma İlişkisi

KKA problemlerinde; bilinmeyen kaynak işaretlerinin karışım ve filtreleme işlemi uygulama alanına bağlı olarak, farklı matematiksel ve fiziksel modellere sahip olabilir. En basit durumda, m karışmış sensör sinyali $x_i(t)$ ($i=1,2,\dots,m$) n tane sıfır ortalamalı, gürültülü ve birbirinden bağımsız sinyalin lineer karışımı olarak tanımlanabilir. Bunun matematiksel modellenmesi,

$$x_i(t) = \sum_{j=1}^n a_{ij} s_j(t) + v_i(t) \quad (i=1,2,\dots,m) \quad (1.30)$$

denklemi ile ifade edilebilir. Bu ifadenin (1.21) denkleminde olan farkı gürültü eklenmiş olmasıdır. Denklem (1.30)'un matris vektör notasyonu ve kümesel işlem formunda,

$$x(t) = As(t) + v(t) \quad (1.31)$$


$$X = AS + V \quad (1.32)$$

şeklinde yazılabilir. (1.31) denklemindeki

$$x(t) = [x_1(t), x_2(t), \dots, x_m(t)]^T$$

$$s(t) = [s_1(t), s_2(t), \dots, s_n(t)]^T$$

birer vektördürler. (1.32) denklemindeki kümesel işlem formunda ise $X = [x(1), x(2), \dots, x(N)]^T \in R^{m \times N}$ ve $S = [s(1), s(2), \dots, s(N)]^T \in R^{n \times N}$ boyutundadır. A ise $m \times n$ boyutlu tam ranka sahip karıştırıcı matristir. Üstteki her iki denklem fiziksel olarak ifade edilecek olursa bir dizi sensör (mikrofon, anten, dönüştürücü) vasıtası ile kaydedilen sinyaller, kaynakların lineer karışımı olarak elde edilmektedir. Uygulamada bu kaynaklar sıfır ortalamalı, zamanla değişen, birbirlerine göre bağımsız veya tam olarak bağımsız oldukları ve sayılarının bilinmediği varsayılır. KKA ve BBA algoritmaları sadece sensör işaretleri $x(t)$ yardımı ile ve uygun bir algoritma ile kaynak sinyallerinin bulunmasını amaç edinmişlerdir. Bu gibi bir sistemin blok diyagramı aşağıdaki şekilde görülebilir.



Şekil 1.15. BBA ve KKA algoritmalarının blok diyagramı

Üstteki blok diyagramdan görülebileceği gibi BBA ve KKA algoritmaları rastgele bir değişken olan $s(t)$ işaretlerinin tahmini olan $y(t)$ işaretlerini,

$$s_j(t) = y_j(t) = \sum_{i=1}^m w_{ji} x_i(t) \quad (j=1, 2, \dots, n)$$

$$y(t) = Wx(t) \quad (1.33)$$

modelindeki gibi bir W matrisi kullanarak lineer bir dönüşüm ile bulmaya çalışır. Dönüşüm ile bulunan işaretlerin mümkün olduğunca birbirlerinden bağımsız oldukları varsayılır. Bağımsızlığın ölçüsü ise, bilgi teorisine dayalı amaç fonksiyonu olan KL diverjans ölçümü, seyreklik, yüksek dereceden istatistik içeren amaç fonksiyonları ile ölçülebilir.

KKA ve BBA algoritmaları birbirlerine benzeyen veya aynı modeller için benzer algoritmalar ile kaynak sinyallerini bulmaya çalıştıklarından dolayı genelde karıştırılırlar. Gerçek dünya problemleri göz önüne alındığında BBA ve KKA algoritmalarının amacı biraz farklıdır. KKA algoritmalarının amacı gerçek kaynak sinyallerini aslında bağımsız olmasalar bile bulmaya çalışmaktır. Bu işlemi yaparken sadece ikinci dereceden istatistik kullanırlar. BBA algoritmalarının amacı ise belirlemiş oldukları dönüşüm ile mümkün olduğu kadar birbirlerinden bağımsız sinyalleri bulmaya çalışmaktır. BBA algoritmaları çoğu problemin çözümü için yüksek dereceden istatistik kullanır. İkinci ve yüksek dereceden istatistik arasındaki temel fark, ikinci dereceden istatistik kaynakların ilintisiz olduklarını varsayarken yüksek dereceden istatistik kaynakların bağımsız olduklarını varsaymaktır. Diğer bir farklılık ise yüksek dereceden istatistik Gauss sinyallere uygulanamaz iken ikinci dereceden istatistik birden fazla Gauss sinyal üzerine uygulanabilir. Buna bağlı olarak şu görülür ki, aslında KKA metotları BBA metotlarının yerini alamazlar. Çünkü her bir yaklaşım farklı varsayım ve farklı amaçları temel alır.

1.6.3. BBA Algoritmasında Kaynak ve Sensör Sayı Bağlantısı

Genelde BBA algoritmalarında gözlenen sinyallerin sayısının kaynakların sayısına eşit olduğu varsayılır ($m=n$) ve bu karesel durum olarak adlandırılır. Karesel durumda ek bir bilgiye gerek kalmadan kaynak işaretleri bulunabilir. $m>n$, kaynaklarının sayısının kaydedicilerin sayısından az olduğu durumda, problem çok kolay bir şekilde, temel bileşen analiz (TBA) algoritmasının kullanılması ile karesel duruma dönüştürülebilir, çözüme devam edilebilir ve kaynak işaretleri bulunabilir. $n>m$ durumunda kaynak sayısı kaydedici sayısından büyüktür ve bu durum tam olmayan durum olarak isimlendirilir. Bu problemin çözümü çok zordur ve ek bilgi olmadan eşsiz bir çözüm bulunamaz. İlk tam olmayan durumlu BBA probleminin çözümüne yönelik yaklaşım Lewicki ve Sejnowski [60] tarafından 1998 yılında yapılmıştır. Daha sonra Theis 2003 yılında geometrik BBA yaklaşımını [61] kullanarak bu problemi çözümlenmiştir fakat sonuçlar çokda iyi değildir.

Karesel durum göz önünde bulundurulursa, elde edilmiş karıştırıcı matris W 'nin A matrisinin tersine benzer olduğu söylenebilir, fakat aynı değildir. Bundan dolayı yeniden

oluşturulmuş kaynakların, orijinal kaynak sinyallerinden sadece ölçeklendirme ve permutasyon ile farklı olduğu söylenebilir. Permutasyon ve ölçeklendirme ifadelerinden yararlanarak bulunan kaynak işaret yaklaşımları,

$$\begin{aligned} y(t) &= Wx(t) \\ y(t) &= WAs(t) \\ y(t) &= D_oPs(t) \end{aligned} \tag{1.34}$$

denklemleri ile ifade edilebilir. Burada, D_o , ölçeklendirme matrisidir ve sadece köşe ekseninde katsayılar vardır. P ise permutasyon matrisidir. Sonuç olarak elde edilen $y(t)$ işaretleri $s(t)$ işaretlerinin yaklaşımlarıdır.

1.6.4. Bilgi Teorisi ve BBA Algoritma İlişkisi

Rastgele değişkenleri karakterize etmenin alternatif bir yolu (momentleri kullanma yerine) bilgi teorisidir. Bilgi teorisinin temel kavramı entropidir ve matematiksel olarak denklem (1.13) ile ifade edilir. Entropi, rastgele değişkenin rastgeleliği veya kesinsizliğinin ölçüsü olarak görülebilir ve sürekli değişken x için entropi, diferansiyel entropi olarak adlandırılır. Diferansiyel entropinin matematiksel ifadesi,

$$H_s(x) = -\int P_x(x) \log P_x(x) dx \tag{1.35}$$

şeklinde tanımlanır. Bu ifade tersi alınabilir lineer ve lineer olmayan bir dönüşüm $y=f(x)$ ile dönüşümü alınır ise dönüşüme uğramış değişkenin entropisi dönüşümden önceki değişkenin entropisine bağlı olarak,

$$H_s(y) = H_s(x) + E\{\log |\det Jf(x)|\} \tag{1.36}$$

denklemleri ile tanımlanabilir. Burada $Jf(x)$, f fonksiyonun Jakobien matrisini ifade eder ki bunun matematiksel anlamı f 'nin x noktasındaki kısmi türevinin matrisidir. Lineer dönüşümler için ($y=Wx$) üstteki Jacobian matrisin sonucu $\log |\det W|$ şeklinde elde edilir. Bu

gösteriyor ki diferansiyel entropi, ölçek değişmeyen değildir (dönüşümden sonra entropi değeri değişmektedir).

Bir diğer ölçüm olan karşılıklı bilgi miktarı ise, entropiden türetilmiştir ve iki rastgele değişken arasındaki ortak bilginin ölçümü olarak tanımlanır. Karşılıklı bilgi miktarının matematiksel ifadesi,

$$I(y_1, y_2, \dots, y_m) = \sum_{i=1}^m H_s(y_i) - H_s(y) \quad (1.37)$$

denklemi ile tanımlanır. Aslında bu ifade bağımsız bileşenler için tanımlı olan olasılık fonksiyonlarının entropilerinin $H_s(y_i)$, bu bağımsız bileşenlerin birleşik olasılık yoğunluk fonksiyonunun entropisinden $H_s(y)$ farkıdır.

Entropi bakımından, karşılıklı bilgi miktarı, her bir rastgele değişken için minimum kod uzunluğunun toplamları arasındaki farklılık veya tüm rastgele vektörler için kod uzunluğu olarak yorumlanabilir. Eğer rastgele değişkenlerin her biri birbirinden bağımsız ise, tüm rastgele vektörün bir kodlaması kod uzunluğunu düşürmeyecektir, çünkü uzunluğu düşürmek için ortak bir bilgi yoktur. Bu varsayım ile, karşılıklı bilgi miktarının negatif olmadığı ve sadece bağımsız değişkenler için sıfır olduğu görülebilir.

KL diverjans ölçümü de aynı zamanda BBA algoritmalarında amaç fonksiyonu olarak kullanılabilir. Bunun için (1.22) denkleminin diverjans ölçümü içerisinde,

$$I(P_x(x) \parallel \prod_i P_x(x_i)) = \int P_x(x) \log \frac{P_x(x)}{\prod_i P_x(x_i)} dx \quad (1.38)$$

denklemindeki gibi kullanılması gerekir. Bu yeni ifade karşılıklı bilgi miktarının diverjans ölçümü yöntemi ile ifade edilmesidir. Bu ifadenin matematiksel anlamı, iki farklı olasılık yoğunluk fonksiyonu arasındaki $(P_x(x)$ ve $\prod_i P_x(x_i)$) uzaklığın ölçülmesidir. (1.38) denklemi ayrık formda iki değişken için,

$$I(p_{x,y}(x, y) \parallel p(x)_x, p(y)_y) = \sum_{k=1}^n p_k(x, y) \ln \frac{p_k(x, y)}{p_k(x)p_k(y)} \quad (1.39)$$

denklemindeki gibi yazılabilir. Bu işlemin sonucu ancak işaretler bağımsız ise birleşik olasılık yoğunluk fonksiyonu ayrıştırılabileceğinden dolayı sifıra eşit olacaktır.

Farklı diverjans ölçümleri için amaç fonksiyonları aşağıdaki denklemlerdeki gibi bulunabilir. Olasılık yoğunluk fonksiyonları için Renyi'nin relatif entropi ölçümü,

$$I_{\alpha}(p_x(x)||p_y(y)) = I_{\alpha}(X||Y) = \frac{1}{1-\alpha} \ln \int \frac{p_x(x)^{\alpha}}{p_y(y)^{\alpha-1}} dx \quad (1.40)$$

$$I_{\alpha}(p_x(x)||p_y(y)) = \frac{1}{1-\alpha} \ln \sum_{k=1}^n p_x(x) \frac{p_x(x)^{\alpha-1}}{p_y(y)^{\alpha-1}} \quad (1.41)$$

denklemlerindeki gibi ifade edilir. Burada $p_x(x)$, X değişkenin olasılık yoğunluk fonksiyonunu, $p_y(y)$ ise Y değişkeninin olasılık yoğunluk fonksiyonunu ifade etmektedir. İki bağımsız değişken için Renyi'nin relatif entropi ölçümü BBA algoritması için amaç fonksiyonu olarak,

$$I_{\alpha}(p_{x,y}(x,y)||p_x(x),p_y(y)) = \frac{1}{1-\alpha} \ln \frac{\sum_{k=1}^n p_k(x,y)^{\alpha}}{\sum_{m=1}^n (p_m(x)p_m(y))^{\alpha-1}} \quad (1.42)$$

denklemindeki gibi elde edilebilir. Denklem (1.42)'de olduğu gibi Tsallis'in relatif entropi ölçümü,

$$I_q(p_x(x)||p_y(y)) = I_q(X||Y) = \frac{\int \frac{p_x(x)^q}{p_y(y)^{q-1}} dx - 1}{q-1} \quad (1.43)$$

$$I_q(p_x(x)||p_y(y)) = \sum_{k=1}^n p_x(x) \frac{\left[\frac{p_x(x)}{p_y(y)} \right]^{q-1} - 1}{q-1}$$

denklemlerindeki gibi elde edilir. İki değişken için Tsallis'in relatif entropi ölçümü BBA için amaç fonksiyonu olarak,

$$I_q(p_{x,y}(x,y) \| p_x(x)p_y(y)) = \sum_{k=1}^n p_k(x,y) \frac{\left[\frac{p_k(x,y)}{p_k(x)p_k(y)} \right]^{q-1} - 1}{q-1} \quad (1.44)$$

denklemindeki gibi elde edilir. KL-diverjans ölçümünde olduğu gibi Renyi ve Tsallis diverjans ölçümlerinde de relatif entropi sadece (1.22) denklemi sağlandığında yani işaretler bağımsız ise sifıra eşit olacaktır. Bu da diverjans ölçümlerinin BBA algoritmalarında bağımsızlık ölçümü için amaç fonksiyon olarak kullanılabileceğini göstermektedir.

1.6.5. BBA Algoritmalarında Ön İşlemler

Kaydedilmiş veriye BBA algoritması uygulamadan önce bazı ön işlemler yapmak çok yararlı olabilir. BBA algoritması öncesi yapılabilecek ilk ön işlem merkezileştirme işlemidir. Merkezileştirme değişkenin ortalama değerinin sifıra eşitlenmesi demektir. Bu işlemin işaretin morfolojisi üzerinde hiçbir etkisi yoktur. Merkezileştirmenin matematiksel ifadesi,

$$x = x - E\{x\} \quad (1.45)$$

denklemini ile tanımlanır.

Diğer bir faydalı ön işlem, işaretin beyazlaştırılmasıdır. Beyazlaştırma, TBA algoritması ile işaretlerin ilintisiz hale getirilmeleridir. İlintisiz hale getirilen işaretin ilinti matrisinin matematiksel ifadesi,

$$E\{xx^T\} = I \quad (1.46)$$

denklemini ile tanımlanır. Beyazlaştırmadan sonra ayrıştırıcı matris arayışı ortogonal ayrıştırıcı matris arayışına dönüşmüş olur.

1.7. Temel Bileşen Analizi (TBA)

TBA ilk olarak 1901 yılında Karl Pearson tanımlamasına karşın ilk bilinen algoritmayı 1930 yılında Hotelling oluşturmuştur [62,63]. TBA en yüksek varyansa sahip olan alt uzayı

kullanmak için optimal doğrusal dönüşüm olma özelliğine sahip olmasına rağmen diğer dönüşüm tekniklerine göre daha fazla hesapsal işlem gerektirmektedir.

TBA uygulamada farklı amaçlar için kullanılabilir. Literatürde en fazla karşılaşılan TBA uygulama türleri veri boyutu indirgeme [64] ve aralarında ilişki olan değişkenlerden oluşan bir verinin ilintisizleştirilmesi amacıyla kullanmasıdır [62-64]. İlintisiz hale getirilen bileşenler temel bileşenler olarak adlandırılırlar.

Veri boyutu indirgeme çalışmaları istatistiksel veri analiz uygulamalarında iyi bilinen fakat zor olan bir konudur. Çok değişkenli verinin boyut tahmini ve boyutunu düşürmek için bir çok istatistiksel ve geometriksel yaklaşım geliştirilmiştir. Boyut bulmak için bilinen en popüler yöntem TBA ve onun lineer olmayan varyantlarıdır. Boyut tahminindeki en önemli sıkıntı tüm veri kayıtlarının gürültülü olmasıdır ve yüksek boyutlu bileşenler muhtemelen sinyalden çok gürültü bileşenlerine karşılık gelebilir. Bu nedenle yüksek boyutlu gürültü bileşeninin sinyalden ayrıştırılması doğru olmayabilir.

İşaretlerin temel bileşenlerinin bulunma işlemi pek çok farklı yöntem ile yapılabilir. Bu yöntemler adaptif olabileceği gibi kümesel beyazlatma işlemi olarak da yapılabilir. Adaptif beyazlatma algoritma sonucu kümesel beyazlatma işlemine göre iyi olmamasına karşılık veri boyutu çok büyük ise ve hızlı işlem yapılması gerekiyorsa adaptif beyazlatma işlemi daha uygun olacaktır. Kümesel beyazlatma yöntemlerinden biri kovaryans matrisin,

$$R_x = E\{xx^T\} = EDE^T \quad (1.47)$$

denklemindeki gibi öz değerlerine ve öz vektörlerine ayrıştırılmasıdır. Denklem (1.47)'deki E , kovaryans matrisin öz vektörlerinin ortogonal matrisini ve D 'de öz değerlerinin köşegenel matrisini temsil etmektedir. Bu öz değerler ve öz vektörler elde edildikten sonra beyazlaştırma işlemi,

$$\tilde{x} = ED^{-1/2}E^T x \quad (1.48)$$

denklemindeki gibi elde edilebilir. Burada,


$$D^{-1/2} = \text{diag}(d_1^{-1/2}, \dots, d_n^{-1/2})$$

işlemi ile bulunur. Beyazlatma işleminin karıştırıcı A matrisi üzerine etkisi,

$$\tilde{x} = ED^{-1/2}E^T As = \tilde{A}s \quad (1.49)$$


ifadesinde görülebileceği gibi \tilde{A} matrisi artık ortogonal bir matristir.

Çoğu BBA algoritmasında TBA algoritması ön işlem olarak kullanıldığından BBA algoritmasının TBA algoritmasından daha iyi sonuç üreteceği kesindir. Fakat bu grafiksel olarak açıklanacak olursa: Şekil 1.16'da görüleceği üzere TBA algoritması ilk adım olarak varyansı en büyük olan bileşenin yönünü bulacaktır (1 numaralı çizgi), ikinci adım olarak ilk varyansa dik olan ikinci en büyük varyansa sahip bileşeni bulacaktır (2 numaralı çizgi). Bulunan bu ikinci yön Şekil 1.16'da görüleceği üzere ikinci en büyük varyansa sahip bileşenin yönünü göstermemektedir.



Şekil 1.16. TBA algoritmasının çalışma prensibi

BBA algoritması TBA algoritmasının aksine Şekil 1.17'de görüleceği üzere doğrudan ikinci bileşenin yönünü bulacaktır. Çünkü BBA algoritmasının amacı bulunan bileşenlerin istatistiksel olarak bağımsız olmasıdır, TBA gibi birbirlerine dik (ilintisiz) olması değildir.



Şekil 1.17. BBA algoritmasının çalışma prensibi

1.8. Negentropi ve Hızlı BBA

BBA algoritmalarında ana amaç karışmış sinyaller arasından bağımsız bileşenleri ayırtmaktır. Bağımsız olan bileşenlerden en fazla bir tanesi Gauss dağılıma sahip olabileceği için BBA algoritmalarına Gauss olmayan dağılım arayan algoritmalar gözü ile bakılabilir. Bundan dolayı işaretin Gauss dağılıma mı yoksa Gauss olmayan dağılıma mı sahip olduğunu ölçebilen her fonksiyon BBA algoritmalarında amaç fonksiyonu olarak kullanılabilir.

Gauss değişkenlerin önemli bir özelliği, aynı varyansa sahip değişkenler arasında entropisi en büyük olan değişken olmalarıdır. Diğer her bir olasılık dağılımı Gauss dağılımından düşük entropiye sahiptir. Bu özellik, entropinin Gauss olmayan dağılım ölçümü için negentropi ifadesi olarak ölçümde kullanılabileceğini göstermektedir. Negentropinin matematiksel ifadesi,

$$J(x) = H_s(x^G) - H_s(x) \quad (1.50)$$

denklemi ile tanımlanır. Burada, x rastgele değişken iken, x^G , x ile aynı kovaryans matrisine sahip Gauss dağılımlı rastgele vektördür. Eğer rastgele değişken Gauss dağılıma sahip ise negentropi ölçümü sıfır olur. Rastgele değişken Gauss olmayan dağılıma sahip olursa

negentropi ölçümü negatif olmayan değere sahip olacaktır. Negentropinin diğer bir önemli özelliği, tersi alınabilir lineer değişimler için değişken olmayışıdır. Bu tanımın matematiksel ifadesi,

$$J(y) = J(Mx) = \dots = J(x) \quad (1.51)$$

denklemleri ile tanımlanır. Bu özelliğe ek olarak, $E\{x\} = 0$ ve y 'nin varyansı 1 ise $E\{yy^T\} = I$ birim matristir ve bu eşitliklere göre karşılıklı bilgi miktarı negentropi bakımından ifadesi,

$$I(y) = \sum_i H_s(y_i) - H_s(y) \quad (1.52)$$

ifadesi ile bulunur. Bu denkleme lineer dönüşüm,

$$I(y) = \sum_i H_s(y_i) - H_s(x) - \log|\det W| \quad (1.53)$$

şeklinde uygulanır ise ve $\sum_i H_s(y_i^G)$ 'yi y_i^G ile beraber ekler ve çıkarılır ise,

$$I(y) = -\sum_i H_s(y_i^G) + \sum_i H_s(y_i) + \sum_i H_s(y_i^G) - H_s(x) - \log|\det W| \quad (1.54)$$

Karşılıklı bilgi miktarı negentropi bakımından (1.54) denklemindeki gibi elde edilir. Burada, $\sum_i H_s(y_i^G)$ ve $H_s(x)$, W 'den bağımsızdırlar ve her ikisi de denkleme sadece sabit değer olarak katkıda bulunurlar. Aynı zamanda son terim $\log|\det W|$ sabittir. Çünkü, y 'nin kovaryans matrisi,

$$E\{yy^T\} = E\{Wxx^TW^T\} = WE\{xx^T\}W^T = I \quad (1.55)$$

birim matristir. Bundan dolayı kovaryans matrisin determinanı,

$$\det I = \det(WE\{xx^T\}W^T) = \det W \det E\{xx^T\} \det W^T = I \quad (1.56)$$

denklemindeki gibi birim matristir. Bu ifade $\det W = \text{sabit}$ olmasına yol açar. Çünkü $\det W = \det W^T$ ve W 'dan bağımsızdır. Bundan dolayı karşılıklı bilgi miktarı negentropi bakımından,

$$I(y) = \sum_i J(y_i) + \text{sabit } I(y) \quad (1.57)$$

denklemini olarak yazılabilir. Denklem (1.57)'de entropinin hesaplanmasında büyük sayıda gözlemin tahminine gerek vardır. Bundan dolayı gerekli gözlem sayısını düşürmek için yaklaşımlara başvurulabilir. Negentropi için, x rasgele değişkenlerinin olasılık yoğunluk fonksiyonlarının standart Gauss yoğunluğu etrafındaki açılımı alınabilir. Bu Taylor açılımına benzemeyen Gram-Charlier açılımdır [65]. Bir boyutlu rastgele değişken için elde edilen açılım,

$$J(x) \approx \frac{1}{12} E\{x^3\}^2 + \frac{1}{48} (E\{x^4\} - 3)^2 \quad (1.58)$$

denklemini olarak bulunur. (1.58) denklemindeki $E\{x^3\}$ eğrilik, $E\{x^4\}$ basıklığa karşılık gelir. Bu işlemlerde varyansın 1'e eşit olduğu varsayılır ($E\{x^2\} = 1$). Böyle bir yaklaşımın dezavantajı aşırı büyük değerlere karşı hassas olmasıdır. x terimi ortalama değerden uzak değişkenlere çok hassastır ve doğru bir tahminin yapılmasını engeller.

Maksimum entropi metodu yaklaşımını temel alan entropi yaklaşımları, bu gibi problemlerin üstesinden gelir. Bu çözüme bir alternatifte x^3 ve x^4 kullanmak yerine iki yeni fonksiyon G^1 (tek) ve G^2 (çift) fonksiyonlarının tanımlanıp kullanılmasıdır. Bu fonksiyonların seçimi yapılırken, çok hızlı büyümeyen fonksiyonlar olarak seçilmeleri gerekmektedir. Bunun sonucu olarak da, ölçüm metodu aşırı büyük değerlere karşı daha doğru sonuçlar verir. Bu fonksiyonlara göre negentropinin yeni yaklaşımı,

$$J(x) \approx k_1 E\{G^1(x)\}^2 + k_2 (E\{G^2(x)\} - E\{G^2(v)\})^2 \quad (1.59)$$

denklemleri ile tanımlanabilir. Denklem (1.59)'daki k_1 ve k_2 pozitif sabitlerdir ve v , sıfır ortalamalı birim varyansa sahip Gauss değişkendir. Bu denklem, (1.58)'ün genelleştirilmiş halidir. Çünkü $G^1(x) = x^3$ ve $G^2(x) = x^4$ alındığında, Gram-Charlier açılımı ile aynı sonuç elde edilir.

Denklem (1.59)'dan Hızlı BBA algoritmasının amaç fonksiyonunu elde etmek için (1.59) denklemi,

$$J(y) \approx [E\{G(y)\} - E\{G(v)\}]^2 \quad (1.60)$$

şeklinde sadeleştirilir. Denklem (1.60)'daki G ifadeleri yerine,

$$G(y) = \frac{1}{a_1} \log(\cosh(a_1 y)) \quad (1.61)$$

$$G(v) = -e^{-v^2/2} \quad (1.62)$$

karesel olmayan fonksiyonları yerleştirilebilir. Denklem (1.61)'de a_1 'in değeri $1 \leq a_1 \leq 2$ arasında seçilmelidir. Denklem (1.61) ile (1.62), (1.60) denkleminin içine yerleştirilerek elde edilen denklemin lineer olmayan optimizasyon algoritmaları kullanılarak optimizasyonu ile Hızlı BBA algoritması,

$$w \leftarrow E\{x g_f(w^T x)\} - E\{g'_f(w^T x)\} w \quad (1.63)$$

ifadesindeki gibi elde edilir. Bu denklemdeki g_f ve g'_f ifadeleri G 'lerin birinci ve ikinci türevleri olup,

$$g_{f1}(y) = \tanh(a_1 y) \quad (1.64)$$

$$g_{f2}(y) = -y e^{-y^2/2} \quad (1.65)$$

$$g'_{f1}(y) = a_1 (1 - \tanh^2(a_1 y)) \quad (1.66)$$

$$g'_{f2}(y) = (1 - y^2) e^{-y^2/2} \quad (1.67)$$

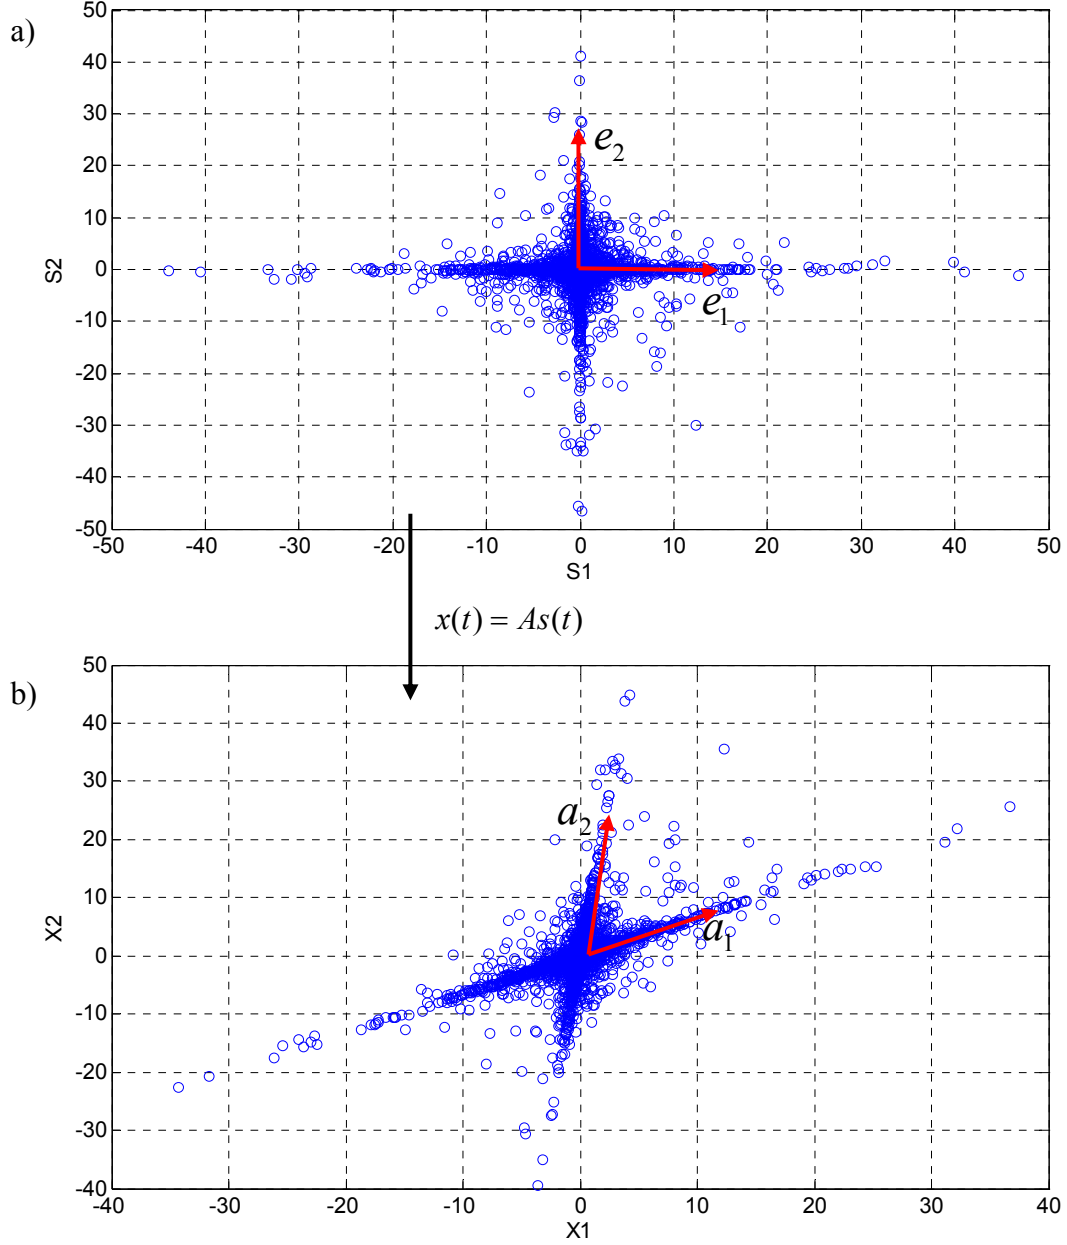
şeklinde bulunurlar. Denklem (1.63)'e yapılan bir dizi sadeleştirme sonucu erişilebilir.

1.9. Geometrik BBA Algoritması

Lineer BBA için tasarlanan geometrik algoritmalar, BBA algoritmalarına benzerdir. Bu algoritmaların anlaşılması ve uygulanması çok kolay olduğundan büyük ilgi çekmektedirler. BBA'ya geometrik yaklaşım, ilk 1995 yılında Puntonent [53] tarafından öne sürülmüştür. Bu yaklaşımda Puntonent, lineer karışımları, bir tür sinir ağı algoritması kullanarak ayırmaya çalışmıştır.

Geometrik BBA algoritmasının esası, ilk olarak dağınıklık grafiklerinden yararlanarak karıştırıcı matrisin bulunmasını ve daha sonra bu elde edilmiş karıştırıcı matrisin tersi alınarak kaynak sinyallerinin yeniden oluşturulmasını temel alan iki safhalı algoritmadan oluşur. Dağınıklık grafikleri, eksenlerin her biri kaynak işaretlerinin veya kaydedilmiş işaretlerin biri olarak atanması ile elde edilen grafiklerdir. Dağınıklık grafiklerinin boyutu kaydedilmiş sinyallerin boyutuyla aynıdır. Bundan dolayı doğal olarak üçten fazla değişken içeren sistemlerin dağınıklık grafikleri bilgisayar ortamında çizilemez. Fakat, bu yine de dağınıklık grafikleri üzerinden geometrik BBA algoritmasının işlem yapmasını engellemez. İki veya üç boyutlu dağınıklık grafiğine uygulanan algoritma aynı şekilde üç boyuttan büyük dağınıklık grafiklerine de uygulanabilir. Örnek olarak Şekil 1.18.a'da birbirinden bağımsız iki tane kaynak işaretinin (iki boyutlu) dağınıklık grafiği görülmektedir. Şekil 1.18.b de ise karıştırıcı matrisin kaynak sinyali üzerindeki etkisi ile dağınıklık grafiğinin nasıl bir dönüşüme uğradığı görülmektedir.

Şekillerden görüleceği gibi işaretlerin iki boyutlu sıfır ortalamalı, tepeli olasılık yoğunluk fonksiyonuna (basıklık >0) sahip rastgele vektörler olduğu görülmektedir. Şekil 1.18.a'daki kaynak işaretlerinin bağımsız oldukları, rastgele değişkenlerin birbirlerine göre dik olarak konumlanmalarından da belli olmaktadır. Şekil 1.18.b'de ise karıştırıcı matrisin $x(t) = As(t)$ modelindeki gibi kaynakların dağınıklık grafikleri üzerindeki dağılımların yönlerini nasıl değiştirdiği görülebilmektedir. Bu grafiklerin her ikisinde, büyük olasılık yoğunluğuna sahip alanlar düşük olasılık yoğunluğuna sahip olan alanlardan daha fazla örnek yoğunluğuna sahiptir. Bundan dolayı dağınıklık grafikleri aynı zamanda işaretlerin birleşik olasılık yoğunluklarının gözlenebilmesi için kullanılabilir.



Şekil 1.18. a) Kaynak sinyallerin dağılım grafikleri b) Karıştırıcı matris ile karıştırılmış (kaydedilmiş) sinyallerin dağılım grafikleri

Şekilden de görüleceği üzere birinci ve ikinci kaynak değişkenlerin yönlerindeki birim vektörler $e_{1/2}$, karıştırıcı matrisin etkisi ile $a_{1/2}=A.e_{1/2}$ olarak dönüşüme uğramıştır. Bu dönüşümdeki yönlendirmeler tam olarak A matrisinin sütunlarına karşılık gelir. A matrisini bulabilmek için, karışım uzayında a_1 ve a_2 ile belirlenen verinin ana eksenlerin bulunması yeterli olmaktadır. Aslında burada noktaların değil şekildeki çizgilerin yönünün bulunmasına ihtiyaç vardır.

a_1 ve a_2 'yi bulabilmek için x 'in örneklerinin birim küre üzerine izdüşümünün alınması ve Kohonen benzeri kümeleme algoritmaları [66] ile kümelerin yönünün bulunması gerekiyor. Bu algoritma, seçilen örnek yönünde birim daire üzerinde nöronları (w_1, w_1', w_2, w_2') yinelemeli bir şekilde hareket ettirme yöntemi ile çözüm aramaktadır. Bir başka deyişle geometrik ayırma metodunun temeli, karışım matrisi ile çarpılmış olan ve yönleri değişmiş olan veri vektörlerinin yönünü bulmaya dayanmaktadır. Bu n tane eksenin yönünün bulunması ile karışım matrisi A oluşturulur ve ayrıştırıcı matris W bu matrisin tersi alınarak bulunur.

Bu çizgilerin yönleri, (nöral) geometrik algoritmalar kullanılarak elde edilebileceği gibi histogram temelli algoritmalar ile de bulunabilir.

1.9.1. Geometrik Öğrenme Algoritması

S kaynak işaretlerinin bağımsız iki boyutlu rastgele vektör kaynak dağılımına sahip olduğu, birleşik yoğunluk fonksiyonları P olarak tanımlandığı varsayılır ise kaynaklar bağımsız ise, P (1.18) denklemi gibi ayrıştırılabilir ve P_i karşılık gelen marjinal kaynak yoğunluk fonksiyonu olarak tanımlanır. Daha sonra kolaylık sağlamak için, kaynak değişkenlerinin sıfır ortalamalı $E\{s\} = 0$ ve simetrik dağılıma sahip olduğu $P_i(x) = P_i(-x)$ varsayılmaktadır. Geometrik algoritmada kararlılığın sağlanması için kaynak dağılımının Gauss dağılıma sahip olmadığı ve tek kipli olduğu varsayılır.

Nöral geometrik algoritmada ilk önce dört tane başlangıç nöronu seçilir w_1, w_1', w_2, w_2' . w_i ve w_i' 'lerin her biri birbirinin tersidir $(w_i = -w_i')$. w_1 ve w_2 lineer olarak bağımsız vektörlerdir. Genellikle $w_1 = e_1$ ve $w_2 = e_2$ birim vektörleri seçilir ve η öğrenme oranı sabit olarak seçilir. η için genel varsayım,

$$\eta(t) > 0 \quad \sum_{n \in N} \eta(n) = \infty \quad \sum_{n \in N} \eta(n)^2 < \infty \quad (1.68)$$

şeklinde tanımlanır. Daha sonra aşağıdaki adım, uygun kesme şartları sağlanana kadar döngü şeklinde devam ettirilir. İlk önce $x(t) \in R^2$ 'de bir örnek x 'in dağılımına göre seçilir. Eğer $x(t) = 0$ ise yeni bir tane $x(t)$ seçimi yapılır. Bu durum olasılığın sıfır olduğu durumda

meydana gelir. Çünkü olasılık yoğunluk fonksiyonunun sürekli olduğu varsayılır. $x(t)$ 'nin birim daire üzerinde iz düşümü,

$$y(t) = \frac{x(t)}{|x(t)|} \quad (1.69)$$

denklemleri ile elde edilir. i 'nin 1 ve 2 olmasını w_i veya w_i' 'nin y 'ye öklit metrik bakımından en yakın olanı seçilerek elde edilir. Daha sonra $w_i(t)$,

$$w_i(t+1) = pr \left(w_i(t) + \eta(t) \frac{y(t) - w_i(t)}{|y(t) - w_i(t)|} \right) \quad (1.70)$$

güncelleme kuralına göre güncellenir. Burada, pr , birim küre üzerine iz düşüm alınmasını temsil eder ve $w_i'(t+1) = -w_i(t+1)$ olarak atanır. Diğer nöronlar bu iterasyon içinde hesaplanmazlar, her bir nöron kendi döngüsü içerisinde güncellenir. Bu güncelleme kuralı mutlak kazanan tümünü alır öğrenme algoritması olarak adlandırılır [67]. Tüm nöronlar doğru bir şekilde işaretlerin yönünü bulana kadar bu işleme devam edilir ve bulunan w_1, \dots, w_n nöronları kullanılarak karışım matrisi $A = (w_1 | \dots | w_n)$ ifadesinde olduğu gibi oluşturulur. Bundan sonraki adımda kaynakları ayrıştırma işlemi gelmektedir. Eğer kaynaklar karesel ise ($m=n$), KKA problemi bulunmuş olan A karıştırıcı matrisinin tersi alınarak kolay bir şekilde çözüme ulaşılabilir. Fakat kaynak sayısının kaydedici sayısından büyük olduğu durum ($n>m$) tam olmayan durum olarak isimlendirilir ve çözüme karışım matrisinin tersini alma yöntemi ile ulaşılamaz. Kaynakları ayrıştırabilmek için ek varsayımların yapılması gerekmektedir. Bu ek varsayım genelde en büyük olabilirlik kestirimi kullanılarak elde edilir.

1.10. Özdeğer Matrislerinin Birleşik Köşegenselleştirmesi (ÖMBK)

ÖMBK algoritması ilk olarak 1993 yılında Cardoso ve Souloumiac [68] tarafından geliştirilmiştir ve bu konu üzerine pek çok çalışma yapılmıştır [3,68-72]. ÖMBK algoritması verinin yüksek dereceden kumulat tensörlerini (dördüncü dereceden) temel olarak bağımsız işaretleri bulmaya çalışmaktadır. Tensörler lineer operatörlerin ve matrislerin genelleştirilmiş

hali olarak düşünülebilir. Eğer veri sıfır ortalamaya sahip ise kumulant tensör, kovaryans matrisin genelleştirilmiş halidir.

Rastgele değişkenin kumulantları, değişkenin olasılık yoğunluk fonksiyonundan elde edilen karakteristik fonksiyonunun doğal logaritmasının Taylor serisine açılımı ile elde edilir. Bir değişken için karakteristik fonksiyon o değişkenin olasılık yoğunluk fonksiyonunun Fourier dönüşümü ile,

$$\varphi(w) = E\{e^{jwx}\} = \int_{-\infty}^{\infty} p_x(x)e^{jwx} dx \quad (1.71)$$

şeklindeki gibi ifade edilir. Denklem (1.71)'deki karakteristik fonksiyon Taylor serisine açılarak moment üretici fonksiyon,

$$\varphi(w) = \int_{-\infty}^{\infty} \left(\sum_{k=0}^{\infty} \frac{x^k (jw)^k}{k!} \right) p_x(x) dx = \sum_{k=0}^{\infty} E\{x^k\} \frac{(jw)^k}{k!} \quad (1.72)$$

şeklinde elde edilir [73,74]. Bu açılımın katsayılarından x rastgele değişkeninin momentleri $E\{x^k\}$ 'lar elde edilebilir. Aynı şekilde rastgele değişkenin kumulantlarını bulmak için karakteristik fonksiyonun logaritması alınarak kumulant üretici fonksiyon,

$$\gamma(w) = \ln(\varphi(w)) = \ln\left(E\{e^{jwx}\}\right) \quad (1.73)$$

denklemindeki gibi elde edilir. Denklem (1.73) Taylor serisine açılarak elde edilen denklemin katsayılarından kumulantlar,

$$\gamma(w) = \sum_{k=0}^{\infty} K_k \frac{(jw)^k}{k!} \quad (1.74)$$

şeklinde elde edilir. Denklem (1.74)'den k.kumulant,

$$K_k = (-j)^k \left. \frac{d^k \gamma(w)}{dw^k} \right|_{w=0} \quad (1.75)$$

şeklinde türev ile elde edilebilir. Sıfır ortalamalı bir rastgele değişken için ilk dört kumulant,

$$K_1 = 0 \quad (1.76)$$

$$K_2 = E\{x^2\} \quad (1.77)$$

$$K_3 = E\{x^3\} \quad (1.78)$$

$$K_4 = E\{x^4\} - 3[E\{x^2\}]^2 \quad (1.79)$$

denklemlerindeki gibi elde edilir. Denklem (1.76), (1.77) ve (1.78) ile tanımlanan ilk üç kumulant ilk üç merkezi momente eşittir. Eğer rastgele değişken sıfır ortalamaya sahip değilse rastgele değişkenin kumulantları,

$$K_1 = E\{x\} \quad (1.80)$$

$$K_2 = E\{x^2\} - [E\{x\}]^2 \quad (1.81)$$

$$K_3 = E\{x^3\} - 3E\{x^2\}E\{x\} + 2[E\{x\}]^3 \quad (1.82)$$

$$K_4 = E\{x^4\} - 3[E\{x^2\}]^2 - 4E\{x^3\}E\{x\} + 12E\{x^2\}[E\{x\}]^2 - 6[E\{x\}]^4 \quad (1.83)$$

denklemlerindeki gibi elde edilir. Rastgele değişken birden çok ise kumulantlar çapraz kumulant olarak isimlendirilir ve matematiksel ifadeleri,

$$kum(x_i, x_j) = E\{x_i x_j\} \quad (1.84)$$

$$kum(x_i, x_j, x_k) = E\{x_i x_j x_k\} \quad (1.85)$$

$$kum(x_i, x_j, x_k, x_l) = E\{x_i x_j x_k x_l\} - E\{x_i x_j\}E\{x_k x_l\} - E\{x_i x_k\}E\{x_j x_l\} - E\{x_i x_l\}E\{x_j x_k\} \quad (1.86)$$

denklemleri ile tanımlanır. Denklem (1.84)'den görüleceği üzere ikinci dereceden kumulant ikinci dereceden momente eşitken üçüncü dereceden kumulantta üçüncü dereceden momente eşittir. Fakat dördüncü dereceden kumulant dördüncü dereceden momente eşit değildir. Kumulantlar momentlerin çarpımlarının toplamı cinsinden ifade edilebilecekleri için momentler ile aynı istatistiksel bilgiye sahiptirler. Fakat genellikle momentler yerine

kumulantlar ile çalışmak tercih edilir. Çünkü yüksek dereceden istatistiğin sağlamış olduğu ek bilgiyi taşırlar.

TBA algoritmasında veriyi beyazlaştırmak için özdeğer ayrıştırması kullanılmıştır. Bu işlemde veri bir matris ile çarpılır ve sonuçta elde edilen verinin ikinci dereceden ilintisi (karşılıklı ilintisi, karşılıklı kovaryansı) sıfırdır veya birim kovaryans matris elde edilir. Aynı şekilde dördüncü dereceden kumulant tensör içinde dördüncü dereceden kumulantı sıfır yapmak için uygun bir matris, özdeğer ayrıştırması ile bulunabilir. Bu tip bir yüksek dereceden ilintisizleştirme ÖMBK algoritması olarak isimlendirilir.

Kumulant tensör, dördüncü dereceden kumulant için (1.87) denklemindeki lineer T operatörü ile tanımlanmıştır.

$$F(M) \leftrightarrow T(K)_{i,j} = \sum_{k,l} \text{kum}(x_i, x_j, x_k, x_l) K_{kl} \quad (1.87)$$

Denklem (1.83)'deki $F(M)$ kumulant matris olarak isimlendirilir. Kumulant matris, paralel kumulant dilimlerinin lineer bir kombinasyonu olarak görülebilir. d boyutlu rastgele bir x vektörü için dördüncü dereceden kumulantının öz değerleri d^2 boyutundadır ve $\lambda_1, \lambda_2, \dots, \lambda_{d^2}$ ile temsil edilirler. Ayrıca dördüncü dereceden kumulant d^2 boyutunda öz matrise sahiptir ve M_1, M_2, \dots, M_{d^2} ile temsil edilirler [45,68,75]. $F(M)$ kumulant matrisi öz değerler ve öz matrislerin çarpımı cinsinden,

$$F(M_r) = \lambda_r M_r \quad (r=1,2,\dots,d^2) \quad (1.88)$$

denklemini ifade edilir.

ÖMBK algoritmalarında (1.88) denklemindeki dördüncü dereceden kumulanta iki türlü yaklaşım yapılarak ayrıştırıcı matris bulunmaya çalışılır. Bu yaklaşımlardan ilki kumulant tensörün köşegenel elemanlarını maksimize yapacak ayrıştırıcı matrisi bulmaktır. İkinci yaklaşım ise kumulant tensörün köşegenel olmayan elemanlarını minimize yapacak ayrıştırıcı matrisi bulmaktır. Her iki durumda da öz değer ayrıştırması, kumulant tensörü köşegenel hale getirmek için veya köşegenel olmayan elemanları sıfır yapmak için kullanılır. Bunun için her öz matris için W matrisini kullanarak $F(M)$ mümkün oldukça köşegenel hale getirilmeye çalışılır. Köşegenleştirme işlemi,

$$Q_D = WF(M)W^T \quad (1.89)$$

denklemleri ile tanımlanır. Q_D 'nin köşegenliği, köşegenel olmayan elemanların karelerinin toplamı $\sum_{k=l} q_{kl}^2$ ile kontrol edilebilir. Çünkü ortogonal W matrisi, toplam matrisin karelerinin toplamını değiştirmez. Aynı zamanda köşegenel olmayan elemanların karelerinin toplamının minimizasyonu köşegenel elemanların karelerinin toplamının maksimizasyonuna eşittir. Üstteki tanımlamalara bağlı olarak ÖMBK algoritmaları için amaç fonksiyon,

$$L_{\text{ÖMBK}} = \sum_i \left\| \text{diag} \left(WF(M_i)W^T \right) \right\|^2 \quad (1.90)$$

şeklinde yazılabilir. Bu denklemdeki köşegenel olmayan elemanların minimizasyonunun bir yöntemi Jacobi metodudur [76].

1.11. Parametrik Olmayan Olasılık Yoğunluk Tahminine Dayalı BBA Algoritması

Çoğu BBA algoritması kaynak istatistiğini temel alan basit varsayımlara dayanır. Varsayılan kaynak istatistiği doğru değilse, bu algoritmalar optimum çözümün altında çalışır veya arzu edilen kaynak ayırma işleminde başarısız olurlar. Bu konuyla ilgili olan Hızlı BBA algoritmasında [52] kullanıcının kaynakların varsayılan olasılık yoğunluk fonksiyonlarına göre yeniden oluşturulabilmesi için bir amaç fonksiyonunun seçilmesi gerekir. Bu gibi bir durum moment tabanlı KKA algoritmalarında görülmez (Cardoso'nun ÖMBK algoritması [68]). Bu gibi yaklaşımlar bağımsızlık ölçümlerinde ve karşılıklı bilgi miktarı minimizasyon prensibine yaklaşım için [77] aşırı derecede üçüncü veya dördüncü dereceden çapraz kumulanta bağlıdır. Bu gibi yaklaşımlar gerçek sinyallere uygulandığı zaman iyi sonuçlar vermeyebilir bu da istenmeyen bir durumdur.

Bu yöntemlere alternatif olarak kaynak sinyallerinin olasılık yoğunluk fonksiyonları için daha esnek modeller de vardır [78,79]. Bu gibi metotlar parametrik yoğunluk fonksiyonu tahmin tekniklerinden oluşmaktadır ve amaç fonksiyonlu optimizasyon adımını değiştirmektedir. Bu gibi algoritmaların özel durumlarda (kaynakların olasılık yoğ. fonk. simetrik değilse) standart algoritmalara göre üstünlük göstermelerine rağmen yakınsama özellikleri ve rastgele dağılımlı kaynakları modelleme kapasiteleri tam olarak değerlendirilmemiştir.

Kaynak istatistiğinin tam temsili, parametrik olmayan olasılık yoğunluk fonksiyon tahmini algoritmaları ile elde edilebilir ve bu konuda yapılan çalışmalardan biri Boscolo'ya aittir [80,81]. Parametrik olmayan yoğunluk tahminine dayalı BBA algoritmasının iki önemli özelliğinden biri, kaynak sinyallerinin bilinmeyen olasılık yoğunluk fonksiyonu ile karışmış sinyallerin ayrıştırılmasını sağlayan ayrıştırıcı matrisin eşzamanlı olarak bulunmasıdır. İkinci özellik ise, parametrik olmayan algoritma veri ile işlem görür ve yoğunluk fonksiyonları için özel bir model gerektirmez.

Bilindiği üzere geleneksel BBA modelinde n tane bağımsız kaynak sinyali S , bir tam ranklı bilinmeyen karıştırıcı A matrisi ile karıştırılmıştır $X=AS$. Orijinal sinyallerin bulunması işlemi $Y=WX$ şeklinde lineer projeksiyon yolu ile yapılır. Bu işlemin yapılabilmesi için kaynakların en fazla birinin Gauss dağılıma sahip olması gerektiği daha önce vurgulanmıştı. Çoğu BBA algoritmasının ana prensibi yeniden oluşturulmuş sinyaller arasındaki karşılıklı bilgi miktarının minimizasyonuna dayanmaktadır. Minimizasyonun matematiksel ifadesi,

$$W_{opt} = \min_W I(y_1, \dots, y_n) \quad (1.91)$$

denklemindeki gibi yazılabilir. Bu prensip, minimum asimptotik varyansa sahip olmak ile karakterize edilir ve ayrıca Donoho'nun [82] gösterdiği üzere dağılımlar biliniyorsa en büyük olabilirlik kestirimi prensibine eşdeğerdir. Denklem (1.91)'de değişkenlerin marjinal entropi ve birleşik olasılık yoğunluk fonksiyonlarının entropi değerleri yerine konulması ile minimizasyon denklemi,

$$\min_W \left\{ \sum_{i=1}^N H_s(y_i) - \log |\det W| - H_s(x) \right\} \quad (1.92)$$

şeklini alır. Bu denklemdeki $H_s(x)$, W değişkenine göre sabit olduğundan amaç fonksiyonunun sadeleşmiş hali,

$$L(W) = \sum_{i=1}^N H_s(y_i) - \log |\det W| \quad (1.93)$$

$$= - \sum_{i=1}^N E \left[\log p_{y_i}(w_i, x) \right] - \log |\det W| \quad (1.94)$$

şeklinde olur. Denklem (1.94)'deki w_i , W matrisinin i . satırındır.

1.11.1. Parametrik Olmayan Olasılık Yoğunluk Fonksiyonunun Bulunması

Denklem (1.88)'deki marjinal entropi $H_s(y_i)$ 'yi bulmak için, bilinmeyen sinyallerin dağılımlarının modellerine ihtiyaç vardır. Cardoso [83] bu dağılımlar üzerinde yapılacak olan yanlış varsayımların kaynak sinyallerini elde etmede bazen başarısızlığa neden olabileceğini göstermiştir. Bu durumun üstesinden gelmek için kernel tahmini teknikleri kullanılarak p_{y_i} olasılık yoğunluk fonksiyonunu doğrudan veriden tahmin etme yöntemi geliştirilmiştir [84,85]. Yeni yaklaşım doğrudan amaç fonksiyonunun ve türevinin değerlendirilmesine izin vermektedir. Bu yöntem ile optimizasyon adımını amaç fonksiyonun tekrar tahmini adımından ayırma gereksinimi ortadan kalkmıştır [78,79]. Verilen M boyutlu veri kümesi için, yeniden oluşturulmuş sinyalin marjinal dağılımları,

$$P_{y_i}(y_i) = \frac{1}{Mh} \sum_{m=1}^M \phi\left(\frac{y_i - Y_{im}}{h}\right), \quad i=1, \dots, N \quad (1.95)$$

denklemleri ile bulunabilir. Burada ϕ , kerneli ve h , kernelin bant genişliğini temsil etmektedir. ϕ kerneli genellikle,

$$\phi(u) = \frac{1}{\sqrt{2\pi}} e^{-u^2/2} \quad (1.96)$$

şeklinde Gauss fonksiyonu olarak seçilirler. Denklem (1.95)'deki kernel merkezleri Y_{im} 'ler,

$$Y_{im} = w_i x^{(m)} = \sum_{n=1}^N w_{in} X_{nm} \quad (1.97)$$

şeklinde elde edilebilir. Bu denklemdeki $x^{(m)}$ karışım matrisi X 'in m . kolonudur. İşlem sonucu değerlendirildiğinde parametrik olmayan olasılık yoğunluk fonksiyon tahmininin gerçek olasılık yoğunluk fonksiyonuna yakınsadığı görülebilir. Buna ek olarak bu yoğunluk fonksiyonu süreklidir ve ayrıştırıcı matris W 'nin bileşenlerine göre türevi,

$$\frac{\partial p(y_i)}{\partial w_i} = \sum_{m=1}^M x^{(m)} (y_i - w_i x^{(m)}) \phi\left(\frac{y_i - w_i x^{(m)}}{h}\right) \quad (1.98)$$

şeklinde elde edilebilir. Kaynak dağılımının kernel açılımını kullanarak, veri noktasında değerlendirilen bir boyutlu oluşturulmuş olasılık yoğunluk fonksiyonu tahmininin kapalı form ifadesi,

$$p(w_i x^{(k)}) = \frac{1}{Mh} \sum_{m=1}^M \phi\left(\frac{w_i (x^{(k)} - x^{(m)})}{h}\right) \quad (1.99)$$

şeklinde tanımlanabilir.

1.11.2. Amaç Fonksiyonu Türevi

Parametrik olmayan yaklaşıma dayalı olasılık yoğunluk fonksiyonundan BBA algoritması elde etmek için (1.94) denkleminde bazı değişiklikler yapılması gerekmektedir. İlk olarak denklemdeki beklenen değere,

$$L(W) \approx -\frac{1}{M} \sum_{i=1}^N \sum_{k=1}^M \log p_{y_i}(w_i x^{(k)}) - \log |\det W| \quad (1.100)$$

şeklinde yaklaşım yapılır. Bu amaç fonksiyonunun bir değişik ifadesi,

$$L(W) = -L_0(W) - \log |\det W| \quad (1.101)$$

şeklinde yazılabilir. Buradaki, $L_0(W)$, $p(y_i)$ marjinal olasılık yoğunluk fonksiyonu kendi yoğunluk kestirimleri ile yer değiştirilerek elde edilir. Bu parametrik olmayan yoğunluk kestirimleri denklemde yerine konulacak olursa,

$$L_0(W) = \sum_{i=1}^N E \left\{ \log \left[\frac{1}{Mh} \sum_{m=1}^M \phi\left(\frac{y_i - Y_{im}}{h}\right) \right] \right\} \quad (1.102)$$

$$\approx \frac{1}{M} \sum_{i=1}^N \sum_{k=1}^M \log \left[\frac{1}{Mh} \sum_{m=1}^M \phi \left(\frac{w_i (x^{(k)} - x^{(m)})}{h} \right) \right] \quad (1.103)$$

denklemini elde edilir. Denklem (1.103)'ün uygun optimizasyon algoritması ile optimizasyonu,

$$\min_W - \frac{1}{M} \sum_{i=1}^N \sum_{k=1}^M \log \left[\frac{1}{Mh} \sum_{m=1}^M \phi \left(\frac{w_i (x^{(k)} - x^{(m)})}{h} \right) \right] - \log |\det W| \quad (1.104)$$

$$\|w_i\| = 1, i=1, \dots, N \quad (1.105)$$

şeklinde elde edilebilir. Denklem (1.104)'de $x^{(k)}$, verilen veri örnekleridir $k=1, \dots, M$. (1.104) denkleminde minimizasyon işlemi uygulanan amaç fonksiyonu, W ayrıştırıcı matrisin bileşenlerinin lineer olmayan bir fonksiyonudur. Denklem (1.105)'deki ek sınırlandırma, problemin çözüm uzayını sınırlamak için kullanılmıştır. Bu sınırlandırma ile aynı zamanda optimizasyon algoritmasının kararlılığı garantilenmiş olur.

Başlangıçta karışmış işaretin merkezleştirildiği ve küresel hale getirildiği varsayılmaktadır. Bu işlemlerden sonra problem sadece ortogonal bir ayrıştırıcı matrisin bulunması işlemine düşürülmüş olur. Karışmış veri üzerinde yapılan bu ön işlemler kernel yoğunluk tahminini oldukça basitleştirir. Çünkü yeniden oluşturulmuş sinyallerin sıfır ortalamaya ve birim varyansa sahip rastgele değişkenler olduğu varsayılabilir. Bir başka dikkat edilecek husus, h parametresidir. h parametresi fonksiyonun düzlüğünü kontrol etmeyi sağlar [42].

1.12. Optimizasyon Yöntemleri

BBA algoritmalarında ana amaç bağımsız bileşenleri verecek olan ayrıştırıcı bir W matrisi bulmaktır. Açıklaması yapılan algoritmalarından görüldüğü gibi W matrisine kapalı formda bulmak mümkün değildir. W matrisini bulmak için bir amaç fonksiyon belirlenmesi ve amaç fonksiyonun uygun bir optimizasyon algoritması ile işlenmesi gerekmektedir. W matrisi bu amaç fonksiyonlarını minimum veya maksimum yapan değerlerdir.

Çoğunlukla optimizasyon algoritmaları amaç fonksiyonunun birinci türevini temel alır. Bundan dolayı vektör ve matrisin, bulunacak parametreye göre türevlerinin tanımlanması gerekmektedir. m tane değişkenden oluşmuş sayısal değerli fonksiyon,

$$f = f(w_1, \dots, w_m) = f(\mathbf{w}) \quad (1.110)$$

şeklinde tanımlanabilir. Burada,

$$\mathbf{w} = (w_1, \dots, w_m)^T$$

olarak tanımlanmıştır. f fonksiyonunun w 'ya göre türevi sütun vektör olup,

$$\frac{\partial f}{\partial \mathbf{w}} = \begin{pmatrix} \frac{\partial f}{\partial w_1} \\ \cdot \\ \cdot \\ \cdot \\ \frac{\partial f}{\partial w_m} \end{pmatrix} \quad (1.111)$$

şeklinde ifade edilir. f fonksiyonunun ikinci türevi ise,

$$\frac{\partial^2 f}{\partial \mathbf{w}^2} = \begin{pmatrix} \frac{\partial^2 f}{\partial w_1^2} & \cdot & \cdot & \cdot & \frac{\partial^2 f}{\partial w_1 \partial w_m} \\ \cdot & & & & \cdot \\ \cdot & & & & \cdot \\ \cdot & & & & \cdot \\ \frac{\partial^2 f}{\partial w_m \partial w_1} & \cdot & \cdot & \cdot & \frac{\partial^2 f}{\partial w_m^2} \end{pmatrix} \quad (1.112)$$

denklemleri ile ifade edilir. Denklem (1.112) $m \times m$ boyutunda bir matristir ve Hessian matrisi olarak isimlendirilir.

Matrislerin türevleri vektörlere benzerdir ve türevleri her bir satırı vektör varsayılarak yerine getirilebilir. f matrisinin $m \times n$ boyutunda olduğu varsayılırsa ,

$$f = f(W) = f(w_{11}, \dots, w_{ij}, \dots, w_{mn}) \quad (1.113)$$

denklemindeki gibi yazılabilir. Denklem (1.108)'deki matrisin aynı boyutta W matrisine göre türevi,

$$\frac{\partial f}{\partial W} = \begin{pmatrix} \frac{\partial f}{\partial w_{11}} & \cdot & \cdot & \cdot & \frac{\partial f}{\partial w_{1n}} \\ \cdot & & & & \cdot \\ \cdot & & & & \cdot \\ \cdot & & & & \cdot \\ \frac{\partial f}{\partial w_{m1}} & \cdot & \cdot & \cdot & \frac{\partial f}{\partial w_{mn}} \end{pmatrix} \quad (1.114)$$

şeklinde bulunur.

BBA algoritması için amaç fonksiyonu $L(W)$ olarak tanımlanabilir. Amaç fonksiyon seçimi yapıldıktan sonra temel optimizasyon yöntemi olan en dik azalan algoritması için amaç fonksiyonun birinci türevi alınarak w ayrıştırıcı matrisi,

$$W(t) = W(t-1) - \mu(t) \left. \frac{\partial L(W)}{\partial W} \right|_{W=W(t-1)} \quad (1.115)$$

şeklinde bulunabilir. Burada, $\mu(t)$, negatif türev yönündeki adım büyüklüğünü belirler. Bu adım büyüklüğü uygun seçilerek algoritmanın optimum değere hızlı veya yavaş bir şekilde yakınsaması sağlanabilir. Algoritmanın optimum değere yakınsaması,

$$\|W(t) - W(t-1)\| < \gamma \quad (1.116)$$

arasındaki öklid uzaklığı γ değerinin altına düşmesi ile sonlandırılır, eğer bu değerden büyük çıkar ise optimum değer bulunana kadar algoritma çalıştırılmaya devam edilir.

1.12.1. Newton Metodu

En dik azalan algoritmasının en önemli problemi global minimum yerine en yakın yerel minimum noktasına yönelebmesidir. Bu gibi bir durumda en dik azalan algoritmasının

başlangıç noktasının optimum çözüme yakın seçilmesi çok önemlidir. Bir diğer önemli problem ise en dik azalan algoritmasının optimum çözüme yakınsama hızının çok yavaş olmasıdır. Bunun için bir alternatif yöntem ikinci dereceden öğrenme algoritmaları kullanmaktır. Bu algoritmalar optimum çözüme daha kısa zamanda ulaşırken işlem sayıları en dik azalan algoritmasına göre oldukça fazla olacaktır. Ayrıca ikinci dereceden türev bilgisi kullandıkları için lokal minimuma yönelme durumları en dik azalan algoritmasına göre çok daha iyidir.

İkinci dereceden öğrenme algoritmalarının temelini oluşturan fikir, amaç fonksiyonu yerine karesel yaklaşım fonksiyonu kullanılmasıdır. Bu yaklaşım birinci ve ikinci türevlere karşılık gelir. Burada orijinal amaç fonksiyonu değil, yaklaşık (karesel) fonksiyon minimize edilir. Bir sonraki adım olarak yaklaşım fonksiyonunun minimum değerine karşılık gelen parametre başlangıç değeri olarak kullanılır ve işlem optimum değeri bulana kadar tekrarlanır. Eğer amaç fonksiyonu karesel ise optimum değere yaklaşım meydana gelir ve metot çok kısa adım sayısında sonuçlanır. Eğer amaç fonksiyonu karesel değilse yaklaşım sadece optimum değere yakın bir tahmin olur.

Verilen amaç fonksiyonuna karesel yaklaşım Taylor serisi ile elde edilir. Bunun için Taylor serisinde, üçüncü ve dördüncü dereceden yüksek terimler göz ardı edilir ise amaç fonksiyonunun $w(t)$ noktasındaki Taylor serisi,

$$L(w) = L(w(t)) + (w - w(t)) \frac{\partial L(w(t))}{\partial w(t)} + \frac{1}{2} (w - w(t)) \frac{\partial^2 L(w(t))}{\partial w(t)^2} (w - w(t)) \quad (1.117)$$

şeklinde elde edilir. Bu denklemden düzenleme yapmak için,

$$\frac{\partial L(w)}{\partial w} = \frac{L(w) - L(w(t))}{w - w(t)} = 0 \quad (1.118)$$

şeklinde türev tanımı yapılır ve (1.117) denkleminde yerine konursa amaç fonksiyonu,

$$\frac{\partial L(w)}{\partial w} = \frac{\partial L(w(t))}{\partial w(t)} + \frac{\partial^2 L(w(t))}{\partial w(t)^2} (w - w(t)) = 0 \quad (1.119)$$

şeklini alır. Eğer $\frac{\partial^2 L(w(t))}{\partial w(t)^2} > 0$ ise minimum noktaya,

$$w(t+1) = w(t) - \left(\frac{\partial^2 L(w(t))}{\partial w(t)^2} \right)^{-1} \frac{\partial L(w(t))}{\partial w(t)} \quad (1.120)$$

denklemini kullanılarak ulaşılır. Bu iteratif yöntem *Newton metodu* olarak isimlendirilir.

1.12.2. Değiştirilmiş Newton Yöntemi

Optimizasyon için Newton metodu en başarılı algoritmalarından biridir. Fakat lineer olmayan amaç fonksiyonları için rastgele bir başlangıç noktası $w(0)$ 'dan optimum çözüme yakınsama garanti edilemez. Eğer $w(0)$ başlangıç noktası optimum çözüme yeteri kadar yakın değilse algoritma azalan özelliğe sahip olmayabilir ($L(w(t+1)) > L(w(t))$). Newton metodunun azalan özelliğe sahip olabilmesi için Newton algoritmasında,

$$w(t+1) = w(t) - \alpha(t) \left(\frac{\partial^2 L(w(t))}{\partial w(t)^2} \right)^{-1} \frac{\partial L(w(t))}{\partial w(t)} \quad (1.121)$$

şeklinde değişiklik yapılabilir. Burada $\alpha(t)$,

$$\left(\frac{\partial^2 L(w(t))}{\partial w(t)^2} \right)^{-1} < \frac{\partial L(w(t))}{\partial w(t)}$$

olacak şekilde seçilir. İkinci türev birinci türevden küçük seçilerek algoritmanın optimum çözüme yakınsaması garanti edilmiş olur. $\alpha(t)$ 'nin seçim işlemi,

$$\alpha(t) = \arg \min_{\alpha \geq 0} L \left(w(t) - \left(\alpha \frac{\partial^2 L(w(t))}{\partial w(t)^2} \right)^{-1} \frac{\partial L(w(t))}{\partial w(t)} \right) \quad (1.122)$$

denkleminin minimizasyonu ile elde edilir.

1.12.3. Ters Hessian Matris Yaklaşımı

Newton metodunda en fazla işlem tutan kısım ikinci dereceden türevin hesaplanması ve tersinin alınmasıdır. Bu hesaplamadan kaçmak için ters alma yerine bunun yaklaşımı kullanılabilir. Yaklaşım işleminin ikinci türevin tersine eşit olabilmesi için, algoritmanın her döngüsünde yaklaşım işlemi güncellenir. İkinci dereceden türevin tersine yaklaşım,

$$w(t+1) = w(t) - \alpha(t) H(t) \frac{\partial L(w(t))}{\partial w(t)} \quad (1.123)$$

denklemindeki gibi $H(t)$ ifadesi ile yapılabilir. Burada $H(0), H(1), H(2), \dots$ her bir adımda elde edilen ardışık Hessian matris yaklaşımlarını temsil etmektedir. Hessian matris ve Hessian matrisin tersi simetrik olduğundan dolayı, yaklaşımlar da simetrik seçilir. Bu yaklaşımlar aşağıdaki denklemlerde ifade edildiği gibi elde edilir. Amaç fonksiyonunun birinci ve ikinci türevleri g ve Q olmak üzere,

$$g = \frac{\partial L(w)}{\partial w} \quad (1.124)$$

$$Q = \frac{\partial^2 L(w)}{\partial w^2} \quad (1.125)$$

şeklinde tanımlanabilirler. Birinci türevinin ikinci türeğe bağlı olarak ifadesi,

$$g(t+1) - g(t) = Q(w(t+1) - w(t)) \quad (1.126)$$

şeklinde tanımlanabilir. Denklem (1.126) içindeki fark ifadeleri yeniden,

$$\Delta g(t) = g(t+1) - g(t) \quad (1.127)$$

$$\Delta w(t) = w(t+1) - w(t) \quad (1.128)$$

denklemlerindeki gibi tanımlanabilir. Denklem (1.126) yeniden,

$$\Delta g(t) = Q \Delta w(t) \quad (1.129)$$

şeklinde tanımlanabilir. İkinci türevin tersini bulma işlemine reel simetrik pozitif tanımlı $H(0)$ ile başlanılacak olursa: verilen k adım için,

$$Q^{-1}\Delta g(t) = \Delta w(t) \quad (1.130)$$

denklemini $0 \leq t \leq k$ adımları için sağlanır. Bir diğer adım olarak $H(k+1)$,

$$H(k+1)\Delta g(t) = \Delta w(t) \quad (1.131)$$

denklemini de $0 \leq t \leq k$ adımları için yazılabilir. Üstteki denklem n adım için yazılırsa:

$$\begin{aligned} H(n)\Delta g(0) &= \Delta w(0) \\ H(n)\Delta g(1) &= \Delta w(1) \\ &\cdot \\ &\cdot \\ &\cdot \\ H(n)\Delta g(n-1) &= \Delta w(n-1) \end{aligned} \quad (1.132)$$

denklemleri elde edilir. Denklem (1.132)'ler düzenlenirse,

$$H(n)[\Delta g(0) \quad \Delta g(1) \quad \dots \quad \Delta g(n-1)] = [\Delta w(0) \quad \Delta w(1) \quad \dots \quad \Delta w(n-1)] \quad (1.133)$$

denklemini ile temsil edilebilir. n adımdan sonra Q^{-1} ,

$$Q^{-1} = H(n) = [\Delta w(0) \quad \Delta w(1) \quad \dots \quad \Delta w(n-1)][\Delta g(0) \quad \Delta g(1) \quad \dots \quad \Delta g(n-1)]^{-1} \quad (1.134)$$

şeklinde bulunur. Sonuç olarak eğer $H(n)$, $H(n)\Delta g(t) = \Delta w(t)$ 'i $0 \leq t \leq n-1$ için sağlıyorsa, (1.122) ve (1.123) denklemini $n+1$ adımda karesel amaç fonksiyonunun çözümünü garanti eder. Bunun nedeni (1.123) denkleminin güncellenmesi Newton metoduna eşittir.

Hessian matrisin tersine yaklaşım için pek çok yöntem geliştirilmiştir [86]. Bu çalışmada Hessian matris yaklaşım için BFGS algoritması (Broyden-Fletcher-Goldfard-Shanno) kullanılmıştır. BFGS algoritması ilk defa 1970 yılında Broyden, Fletcher, Goldfard ve Shanno tarafından birbirlerinden bağımsız olarak geliştirilmiştir. BFGS algoritması,

$$H(t+1) = H(t) + \left(1 + \frac{\Delta g(t)^T H(t) \Delta g(t)}{\Delta g(t)^T \Delta w(t)} \right) \frac{\Delta w(t) \Delta w(t)^T}{\Delta w(t)^T \Delta g(t)} - \frac{H(t) \Delta g(t) \Delta w(t)^T + (H(t) \Delta g(t) \Delta w(t)^T)^T}{\Delta g(t)^T \Delta w(t)} \quad (1.135)$$

ifadesini kullanarak Hessian matrisin tersine yaklaşım yapmaktadır.

Aşağıda BFGS algoritmasının optimizasyon işlemi için programlama adımları gösterilmiştir.

1. adım : $w(0)$, ε ve $H(0)$ için başlangıç değerlerini ata.

2. adım : $t \leftarrow 0$

while $\|\nabla w(k)\| > \varepsilon$

 arama yönünü araştır

$$p(t) = -H(t) \nabla w(t)$$

$$w(t+1) = w(t) + \alpha(t) p(t)$$

$$\nabla w(t) = w(t+1) - w(t) \text{ ve } \nabla g(t) = g(t+1) - g(t) \text{ tanımla.}$$

(1.129) denklemine göre $H(t+1)$ 'i hesapla.

$$t = t + 1$$

end (while)

2. YAPILAN ÇALIŞMALAR, BULGULAR VE İRDELEME

2.1. Giriş

FEKG işaretinin doğru bir şekilde değerlendirilebilmesi için karın üzerinden elde edilen işaretlere bir dizi işlem yapılması gerekmektedir. İlk önce EKG problemleri düzgün bir şekilde anne karnı üzerine yerleştirilmelidirler. Sonra şebeke frekansından kaynaklanan 50 Hz'lik girişimi elemek için klasik filtreleme teknikleri uygulanmalıdır. Klasik filtreleme yöntemi kullanmadan da BBA algoritması ile 50 Hz'lik girişim işareti ayrıştırılabilir. Bir sonraki adım olarak, karışım ortamının kestirilmesi, anneye ve fetusa ait EKG işaretlerinin ayrıştırılması gerekmektedir. Ayrıştırma gerçekleştirildikten sonra, sistem başarımını artırmak ve ayrıştırılan işaretleri gürültüden arındırmak için çeşitli yöntemler kullanılabilir.

Bu tezde, klasik prob yöntemi ile kaydedildiği varsayılan FEKG işaretini diğer işaretlerden ayırtmak için BBA algoritmaları kullanılmıştır ve yapılan çalışmalar aşağıdaki şekilde gruplandırılabilir.

- Gürültüsüz yapay EKG işaretleri üzerinde yapılan ayırıştırma çalışmaları,
- Gürültülü yapay EKG işaretleri üzerinde yapılan ayırıştırma çalışmaları,
- Gerçek EKG işaretleri üzerinde yapılan ayırıştırma çalışmaları,
- Ayrıca, bu çalışmalara ek olarak tezde, Tsallis'in yapay toplamsallık özelliğini amaç fonksiyonu olarak kullanan yeni geliştirilen bir BBA algoritması da önerilmektedir.

2.2. Tsallis'in Yapay Toplamsallık Özelliğini Amaç Fonksiyonu Olarak Kullanan Yeni Parametrik Olmayan BBA Algoritması

Entropi'de kullanılan lineer ortalama yerine herhangi bir rastgele fonksiyon kullanılarak da ortalama değer bulunabileceğini Renyi 1960 yılında göstermiştir [22]. Bunun için ortalama da kullanılacak fonksiyon sürekli ve monoton fonksiyon olarak seçilmelidir [23]. Bu konuda ilk yapılan çalışma 1930 yılında Kolmogorov ve Naguma'ya [87] ait olup verilen bir vektör (x_1, \dots, x_M) için yapay ortalama,

$$\langle x \rangle_\psi = \psi^{-1} \left(\sum_{k=1}^M \frac{1}{M} \psi(x_k) \right) \quad (2.1)$$

denklemi ile ifade etmişlerdir. Üstteki (2.1) denklemdeki ψ , sürekli olan ve monoton olarak artan veya azalan bir fonksiyonu temsil etmektedir. Ortalamanın genel tanımına göre X rastgele değişkeni için yapay ortalama aşağıdaki gibi tanımlanır.

$$E_{\psi} \{X\} = \langle x \rangle_{\psi} = \psi^{-1} \left(\sum_{k=1}^M p_k \psi(x_k) \right) \quad (2.2)$$

Eğer ψ lineer bir fonksiyon ise (2.1) denklemdeki lineer ortalamaya eşit olur.

$$E_{\psi} \{X\} = \langle x \rangle = \sum_{k=1}^M p_k x_k \quad (2.3)$$

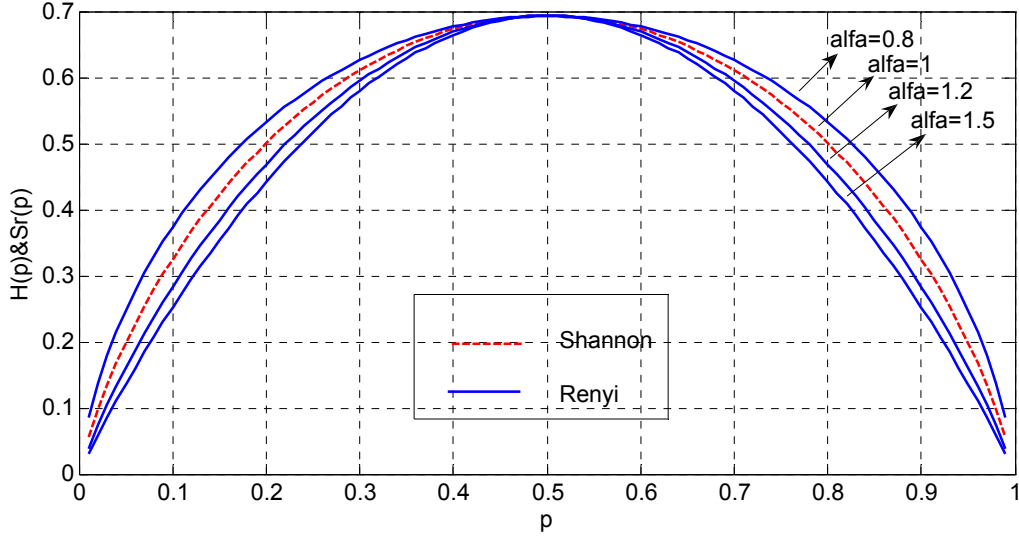
Renyi ψ fonksiyonu yerine $\psi(x) = e^{(1-\alpha)x}$ ifadesini kullanarak Renyi entropiyi aşağıdaki gibi elde etmiştir.

$$S_{\alpha}(X) = \frac{1}{1-\alpha} \ln \left(\sum_{k=1}^M p_k^{\alpha} \right) \quad (2.4)$$

Bu denklemde $\alpha \neq 1$ ve $\alpha > 1$ olmalıdır. Eğer α negatif ise p 'nin küçük değerleri için ölçüm sonsuza gidecektir. $\alpha \rightarrow 1$ yaklaşırken Renyi entropi ölçümü Shannon entropi ölçümüne yaklaşacaktır. Renyi entropi, Shannon entropide olduğu gibi bağımsız sinyaller için toplamsallık özelliğini sağlamaktadır.

$$S_{\alpha}(X, Y) = S_{\alpha}(X) + S_{\alpha}(Y) \quad (2.5)$$

Aşağıdaki şekilde farklı α değerleri için Shannon entropi fonksiyonunun Renyi entropi fonksiyonu ile karşılaştırılması görülmektedir.



Şekil 2.1. Shannon ve Renyi entropi karşılaştırmaları

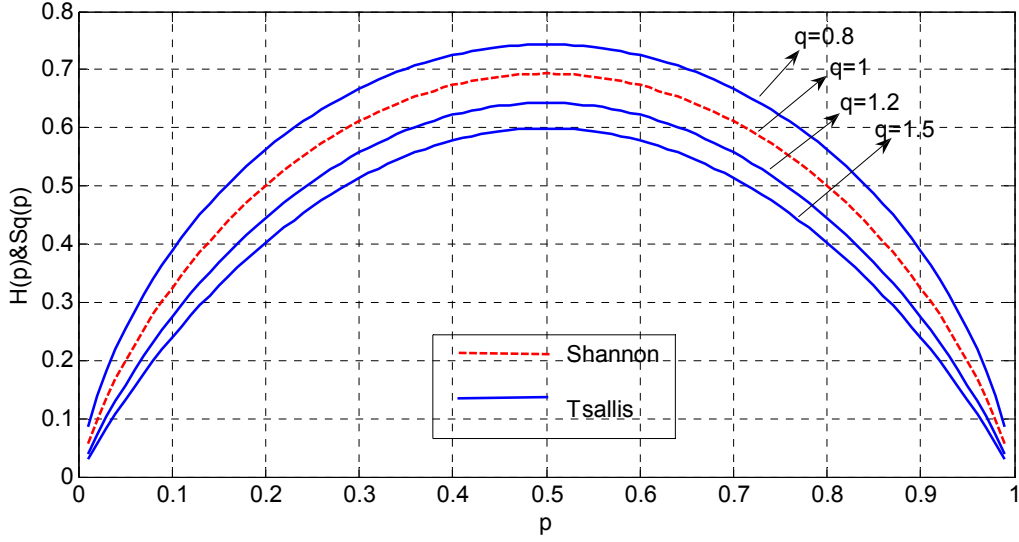
Bu çalışmadan sonra bilgi ölçümü pek çok bilim adamının ilgi alanı olmaya devam etti ve 1988 yılında fizikçi Tsallis bilgi ölçüm için yeni bir yöntem [24] buldu. Tsallis entropi ölçümünü aşağıdaki denklem ile ifade etmiştir.

$$S_q(X) = \frac{1 - \sum_{k=1}^M p_k^q}{q-1} \quad (2.6)$$

Bu denklemdeki $q > 0$ genel olmayan indeks olarak ifade edilir. Tsallis entropi ölçümü (Renyi entropi ölçümünde olduğu gibi) $q \rightarrow 1$ yaklaşır iken Shannon entropi ölçümüne yaklaşmaktadır. Tsallis entropi ölçümü, Shannon entropi ölçümü ile toplamsallık hariç, pek çok özelliği paylaşmaktadır. Tsallis entropi için geçerli olan yapay toplamsallığın derecesini entropi indeksi q belirlemektedir. Bağımsız iki değişkenin birleşik olasılık yoğunluk fonksiyonunun Tsallis entropisi yapay toplamsallık türünden, ayrı ayrı değişkenlerin Tsallis entropileri ile,

$$S_q(X, Y) = S_q(X) \oplus S_q(Y) = S_q(X) + S_q(Y) + (1-q)S_q(X)S_q(Y) \quad (2.7)$$

denklemindeki gibi ifade edilir. Şekil 2.2'de farklı q değerleri için Shannon entropi fonksiyonu Tsallis entropi fonksiyonu ile karşılaştırılmıştır.



Şekil 2.2. Shannon ve Tsallis entropi karşılaştırmaları

Shannon entropi ölçümünde olduğu gibi iki değişken için Tsallis yapay toplamsallık özelliğini BBA algoritmasında amaç fonksiyon olarak kullanmak için yapay toplamsallık açılımı birleşik olasılık yoğunluk fonksiyonundan,

$$L(W) = S_q(y_1) + S_q(y_2) + (1-q)S_q(y_1)S_q(y_2) - S_q(y_1, y_2) \quad (2.8)$$

denklemindeki gibi çıkarılır. Önerilen algoritmada amaç fonksiyon olarak denklem (2.8) kullanılmaktadır. Denklem (2.8)'de olasılık yoğunluk fonksiyonları yerine konursa,

$$L_q(W) = \frac{\sum_{k=1}^M p_1^{1-q} - 1}{q-1} + \frac{\sum_{k=1}^M p_2^{1-q} - 1}{q-1} + (1-q) \frac{\sum_{k=1}^M p_1^{1-q} - 1}{q-1} \frac{\sum_{k=1}^M p_2^{1-q} - 1}{q-1} - \frac{\sum_{k=1}^M p_{1,2}^{1-q} - 1}{q-1} \quad (2.9)$$

denklemini elde edilir. Denklem (2.9)'da (1.90) denklemindeki olasılık yoğunluk fonksiyon tahminleri yerine konursa,

$$\begin{aligned}
L_q(W) = & \frac{\sum_{k=1}^M \left(\frac{1}{Mh} \sum_{m=1}^M \phi \left(\frac{y_1 - Y_{1m}}{h} \right) \right)^{1-q} - 1}{q-1} + \frac{\sum_{k=1}^M \left(\frac{1}{Mh} \sum_{m=1}^M \phi \left(\frac{y_2 - Y_{2m}}{h} \right) \right)^{1-q} - 1}{q-1} \\
& + (1-q) \frac{\sum_{k=1}^M \left(\frac{1}{Mh} \sum_{m=1}^M \phi \left(\frac{y_1 - Y_{1m}}{h} \right) \right)^{1-q} - 1}{q-1} \frac{\sum_{k=1}^M \left(\frac{1}{Mh} \sum_{m=1}^M \phi \left(\frac{y_2 - Y_{2m}}{h} \right) \right)^{1-q} - 1}{q-1} \\
& - \frac{\sum_{k=1}^{M^2} \left(\frac{1}{(Mh)^2} \sum_{m=1}^{M^2} \phi \left(\frac{y_{1,2} - Y_{1,2m}}{h} \right) \right)^{1-q} - 1}{q-1}
\end{aligned} \tag{2.10}$$

denklemini elde edilir. Denklem (2.10)'daki kernel merkezleri Y_{im} 'ler, denklem (1.90)'daki gibi ifade edilir. Y_{ijm} ise, birleşik olasılık yoğunluk fonksiyon kestirimlerinin kernel merkezlerini temsil etmektedir. Optimizasyonun her adımında (2.10) denklemindeki birleşik olasılık yoğunluk fonksiyonunun Tsallis entropisinin hesaplanmasından kurtulmak için denklem (1.87)'deki gibi birleşik olasılık yoğunluk fonksiyonunun lineer dönüşümü alınarak optimizasyon işleminde yerine konur. Elde edilen amaç fonksiyonu uygun bir optimizasyon algoritması ile optimize edilerek ayrıştırıcı matris elde edilir. Denklem (2.8)'in minimizasyon işlemi,

$$\min_W \left\{ S_q(y_1) + S_q(y_2) + (1-q)S_q(y_1)S_q(y_2) - S_q(y_1, y_2) \right\} \tag{2.11}$$

denklemini ile ifade edilir. Bu denklem (2.10) denklemini için düzenlenir ise,

$$\min_w \left\{ \frac{\sum_{k=1}^M \left(\frac{1}{Mh} \sum_{m=1}^M \phi \left(\frac{y_1 - Y_{1m}}{h} \right) \right)^{1-q}}{q-1} + \frac{\sum_{k=1}^M \left(\frac{1}{Mh} \sum_{m=1}^M \phi \left(\frac{y_2 - Y_{2m}}{h} \right) \right)^{1-q}}{q-1} \right. \\
+ (1-q) \frac{\sum_{k=1}^M \left(\frac{1}{Mh} \sum_{m=1}^M \phi \left(\frac{y_1 - Y_{1m}}{h} \right) \right)^{1-q} - 1}{q-1} \frac{\sum_{k=1}^M \left(\frac{1}{Mh} \sum_{m=1}^M \phi \left(\frac{y_2 - Y_{2m}}{h} \right) \right)^{1-q} - 1}{q-1} \\
\left. - \frac{\sum_{k=1}^{M^2} \left(\frac{1}{(Mh)^2} \sum_{m=1}^{M^2} \phi \left(\frac{y_{1,2} - Y_{1,2m}}{h} \right) \right)^{1-q} - 1}{q-1} \right\} \quad (2.12)$$

denklemini elde edilir. Denklem (2.12) iki deęişken için tanımlanmış olan önerilen algoritmanın amaç fonksiyonudur. Önerilen algoritmanın amaç fonksiyonu üç deęişkene göre yazılacak olur ise, ilk önce yapay toplamsallık üç deęişken için,

$$S_q(X, Y, Z) = S_q(X) \oplus S_q(Y, Z) = S_q(X) + S_q(Y, Z) + (1-q)S_q(X)S_q(Y, Z) \quad (2.13)$$

denklemini ile ifade edilir. Denklem (2.13)'de tanımlanan $S_q(Y, Z)$, denklem (2.7)'de iki deęişken için tanımlanmış olan yapay toplamsallıktır. Bu yöntem ile dört deęişken için önerilen algoritmanın amaç fonksiyonu, üç deęişken için tanımlanan yapay toplamsallık denkleminde faydalanarak,

$$S_q(X, W, Y, Z) = S_q(X) \oplus S_q(W, Y, Z) \\
S_q(X, W, Y, Z) = S_q(X) + S_q(W, Y, Z) + (1-q)S_q(X)S_q(W, Y, Z) \quad (2.14)$$

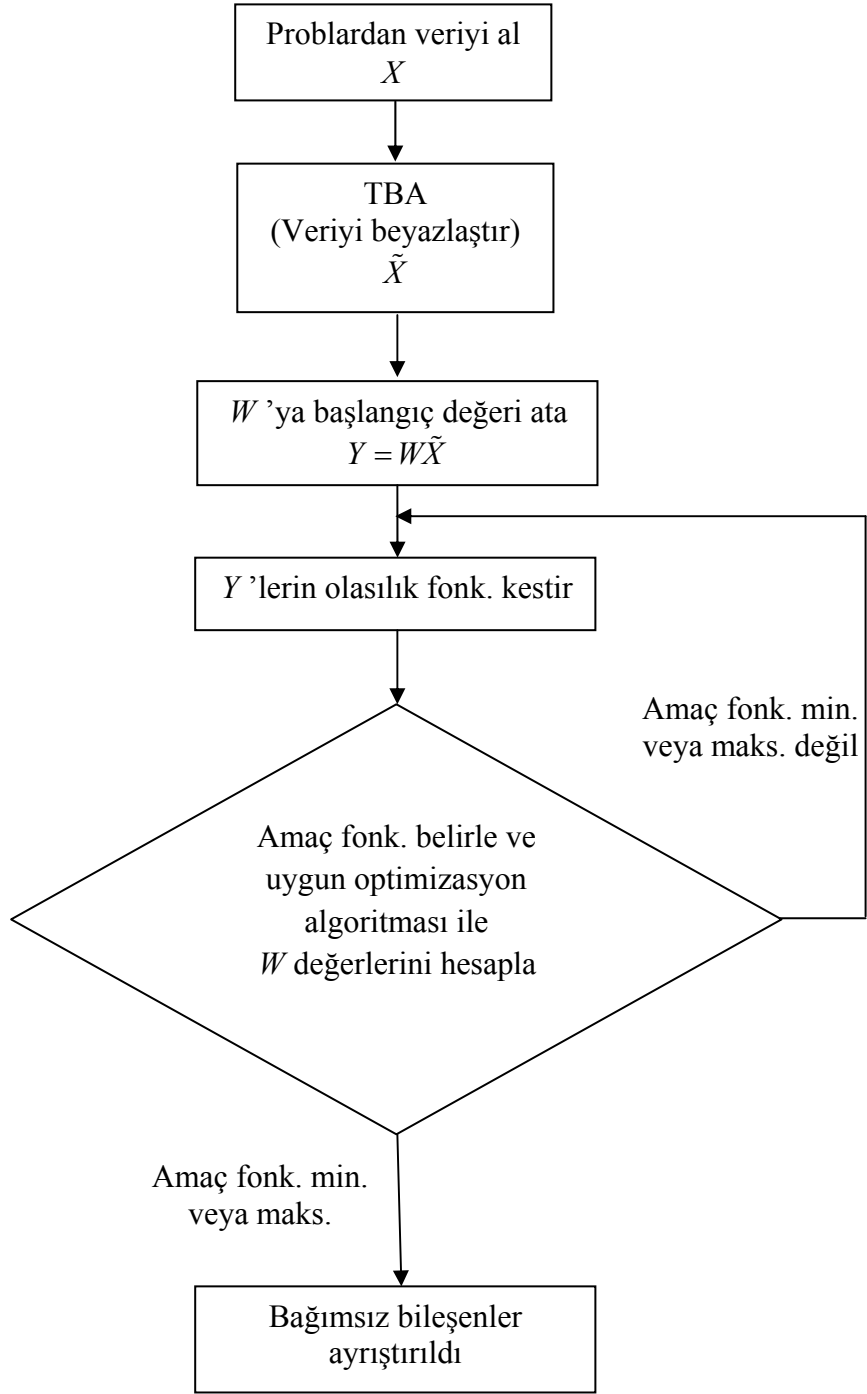
denklemleri ile ifade edilir. Yapılacak olan bu tür genellemeler ile istenilen boyuttaki yapay toplamsallık, bir boyut düşük yapay toplamsallık cinsinden elde edilebilir ve birleşik olasılık yoğunluk fonksiyonunun Tsallis entropi ifadesinden çıkartılarak, amaç fonksiyon elde edilir.

Denklem (2.13) içersinde parametrik olmayan olasılık yoğunluk fonksiyon tahmini kullanılarak önerilen algoritmanın amaç fonksiyonunun elde edilmesi işlemi,

$$\begin{aligned}
L_q(W) = & \frac{\sum_{k=1}^M \left(\frac{1}{Mh} \sum_{m=1}^M \phi \left(\frac{y_1 - Y_{1m}}{h} \right) \right)^{1-q} - 1}{q-1} + \frac{\sum_{k=1}^M \left(\frac{1}{Mh} \sum_{m=1}^M \phi \left(\frac{y_2 - Y_{2m}}{h} \right) \right)^{1-q} - 1}{q-1} \\
& + \frac{\sum_{k=1}^M \left(\frac{1}{Mh} \sum_{m=1}^M \phi \left(\frac{y_3 - Y_{3m}}{h} \right) \right)^{1-q} - 1}{q-1} + (1-q) \frac{\sum_{k=1}^M \left(\frac{1}{Mh} \sum_{m=1}^M \phi \left(\frac{y_1 - Y_{1m}}{h} \right) \right)^{1-q} - 1}{q-1} \frac{\sum_{k=1}^M \left(\frac{1}{Mh} \sum_{m=1}^M \phi \left(\frac{y_2 - Y_{2m}}{h} \right) \right)^{1-q} - 1}{q-1} \\
& + (1-q) \frac{\sum_{k=1}^M \left(\frac{1}{Mh} \sum_{m=1}^M \phi \left(\frac{y_1 - Y_{1m}}{h} \right) \right)^{1-q} - 1}{q-1} \frac{\sum_{k=1}^M \left(\frac{1}{Mh} \sum_{m=1}^M \phi \left(\frac{y_3 - Y_{3m}}{h} \right) \right)^{1-q} - 1}{q-1} \\
& + (1-q) \frac{\sum_{k=1}^M \left(\frac{1}{Mh} \sum_{m=1}^M \phi \left(\frac{y_3 - Y_{3m}}{h} \right) \right)^{1-q} - 1}{q-1} \frac{\sum_{k=1}^M \left(\frac{1}{Mh} \sum_{m=1}^M \phi \left(\frac{y_2 - Y_{2m}}{h} \right) \right)^{1-q} - 1}{q-1} \\
& + (1-q)^2 \frac{\sum_{k=1}^M \left(\frac{1}{Mh} \sum_{m=1}^M \phi \left(\frac{y_1 - Y_{1m}}{h} \right) \right)^{1-q} - 1}{q-1} \frac{\sum_{k=1}^M \left(\frac{1}{Mh} \sum_{m=1}^M \phi \left(\frac{y_2 - Y_{2m}}{h} \right) \right)^{1-q} - 1}{q-1} \frac{\sum_{k=1}^M \left(\frac{1}{Mh} \sum_{m=1}^M \phi \left(\frac{y_3 - Y_{3m}}{h} \right) \right)^{1-q} - 1}{q-1} \\
& \frac{\sum_{k=1}^M \left(\frac{1}{(Mh)^3} \sum_{m=1}^3 \phi \left(\frac{y_{1,2,3} - Y_{1,2,3m}}{h} \right) \right)^{1-q} - 1}{q-1}
\end{aligned} \tag{2.15}$$

denklemindeki gibi ifade edilir. Denklem (2.15)'in her hangi bir optimizasyon algoritması ile optimizasyonu denklem (2.12)'ye benzer şekilde yapılır.

Uygulamada pek çok BBA algoritması vardır. Her BBA algoritması farklı amaç fonksiyonu kullanarak bağımsız bileşenleri ayırtırmaya çalışmaktadır. Parametrik olmayan BBA algoritmaları da bağımsız bileşenler için geçerli olan toplamsallık (Boscolo'nun algoritması) ve yapay toplamsallık (önerilen algoritma) özelliklerinden faydalanarak amaç fonksiyonu oluşturmaktadırlar. Seçilen amaç fonksiyonuna bağlı olarak parametrik olmayan algoritma uygulamalarının genel akış diyagramı Şekil 2.3'de gösterilmektedir.



Şekil 2.3. Parametrik olmayan algoritmalar için akış diyagramı

2.2.1. Benzetim Ortamı

Bu tezde, yapay olarak oluşturulmuş EKG işaretleri için iki türlü karışım işlemi gerçekleştirilmiştir. İlk karışım işleminde algoritmaların aynı karışım işlemi için sonuçlarının görsel olarak karşılaştırılabilmesi için karışım matrisleri sabit alınmıştır ve elde edilen

parametrik olmayan algoritma sonuçları şekiller ile temsil edilmiştir. Şekiller ile temsil edilen algoritma sonuçlarındaki iki problu karışım işlemi için,

$$A = \begin{bmatrix} -0,51 & 0,93 \\ 0,72 & -0,4 \end{bmatrix} \quad (2.16)$$

üç problu karışım işlemi için,

$$A = \begin{bmatrix} 0,8 & 0,6 & 0,8 \\ 0,3 & 0,5 & -0,7 \\ 0,3 & 0,4 & 0,9 \end{bmatrix} \quad (2.17)$$

dört problu karışım işlemi için,

$$A = \begin{bmatrix} 0,8 & 0,6 & 0,5 & 0,2 \\ 0,3 & 0,5 & -0,7 & 0,7 \\ 0,7 & 0,4 & 0,9 & 0,6 \\ -0,3 & 0,4 & 0,8 & 0,3 \end{bmatrix} \quad (2.18)$$

karışım matrisleri kullanılmıştır. Bu karıştırma matrislerinin seçilme amacı tüm algoritmaların aynı karışım ortamı için sonuçlarının karşılaştırılabilmesidir. İkinci karışım işlemindeyse algoritmaların farklı karışım matrisleri ile performanslarının karşılaştırılması amaç edinilmiştir. Bunun için karışım matrisi her bir algoritma döngüsünde rastgele olarak üretilmiş ve karıştırılmıştır. Rastgele üretilen karışım matrislerinin satırları birim varyansa eşitlenmiştir. Her bir algoritma için 100 döngü uygulanmış ve elde edilen sonuçların işaret hata oranı (İHO) değerlerinin ortalaması alınarak tablolar oluşturulmuştur.

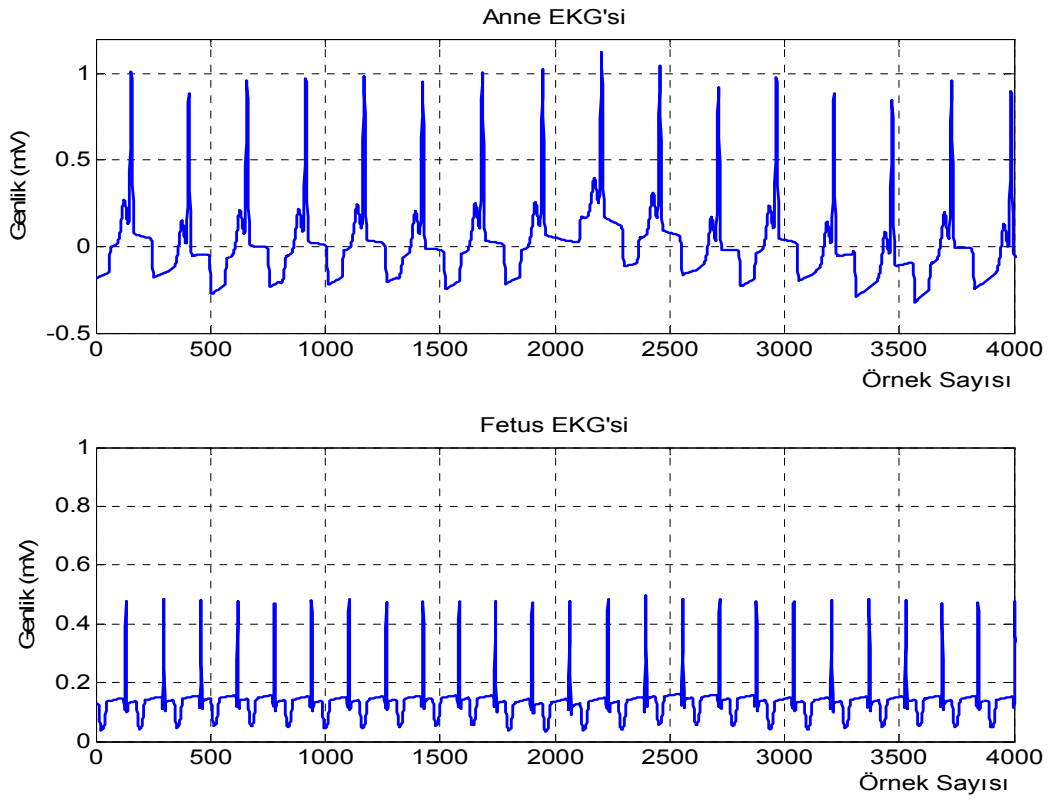
Algoritma performanslarının karşılaştırılması amacı ile, algoritma sonuçlarının İHO değerlerinin örnek sayısına göre karşılaştırılması yapılmıştır. EKG işaretlerine kaynak işareti olarak ve harici gürültü işareti olarak eklenen Gauss dağılımlı gürültü her bir döngüde rastgele olarak değişmektedir. İHO değerlerinin hesaplama formülleri Ek 1'de verilmektedir. Sistemin bilgisayar benzetimi Matlab ortamında gerçekleştirilmiştir ve optimizasyon algoritmasının $\|\nabla w(k)\| > \varepsilon$ hata tolerans değeri olarak 10^{-10} seçilmiştir.

2.3. Gürültüsüz EKG İşaretlerine Ait Elde Edilen Sonuçlar

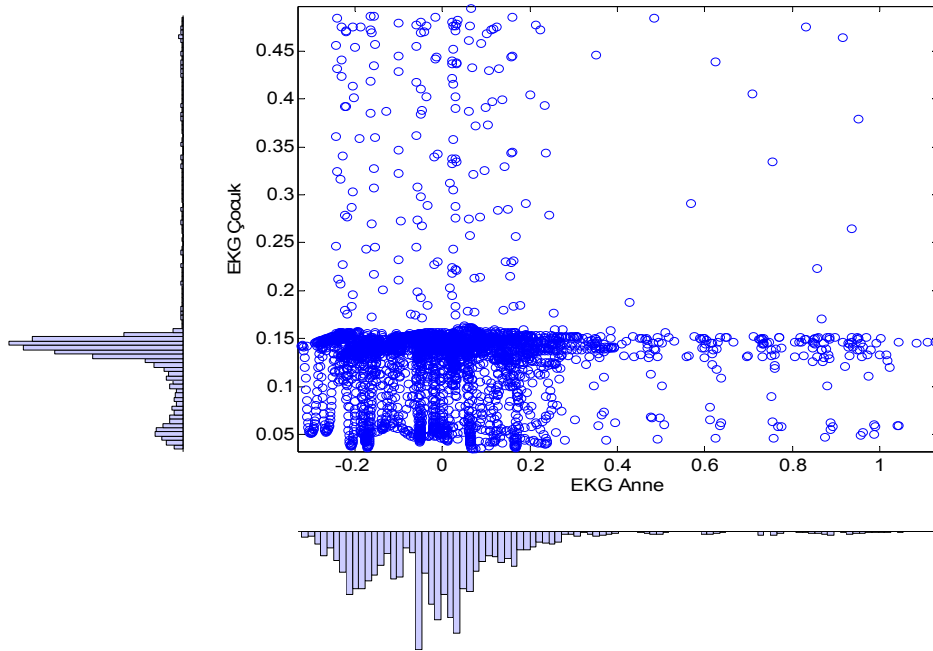
2.3.1. Tek Hamilelik Durumunda Elde Edilen Sonuçlar

Yapılan çalışmalarda performans ölçümü yapabilmek için kaynak sinyallerinin (Anne ve fetusun EKG sinyallerinin) önceden bilinmesi gerekmektedir ve bilinen bu işaretler ile ayrıştırılan işaretler karşılaştırılarak İHO değerleri hesaplanmakta ve bu hesaplanan İHO değerlerine göre algoritmaların performansı hakkında karar verilmektedir. Bu tezde yapay EKG işaretleri ile yapılan tüm çalışmalarda, Şekil 2.4'deki yapay EKG işaretleri kullanılmıştır.

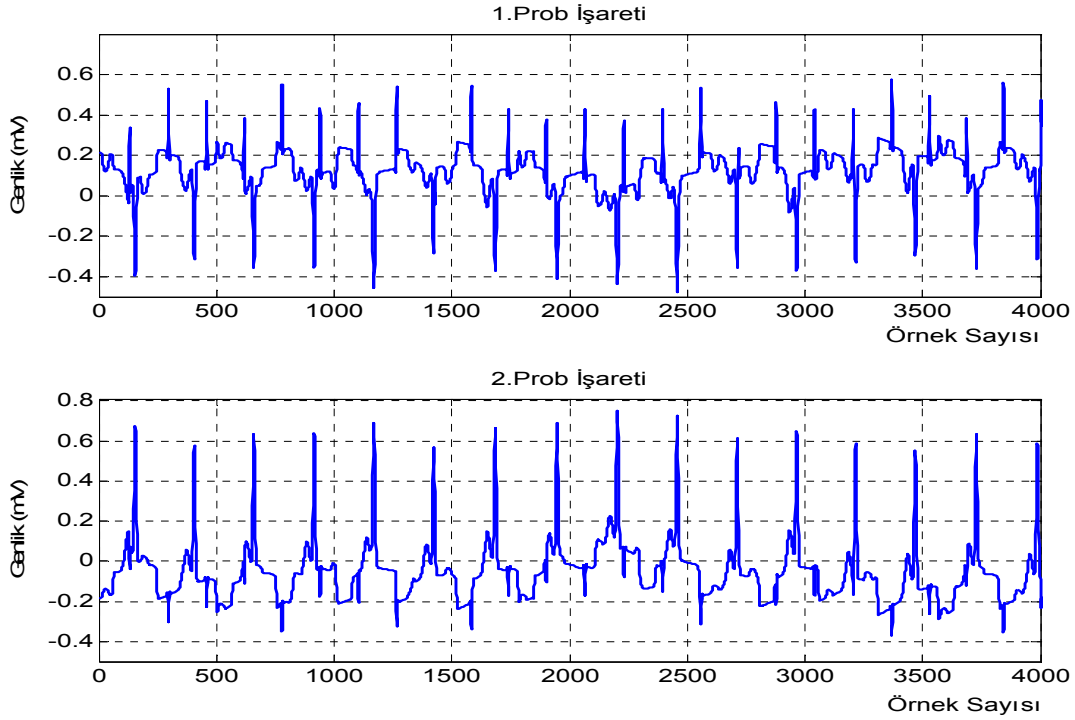
Şekil 2.4'den görüleceği üzere anneye ve fetusa ait EKG işaretleri gerçeğe uygun olacak şekilde Sameni'nin [38] çalışması ile, genlikleri ve atım sayıları farklı olacak şekilde üretilmiştir. Bu yapay EKG işaretlerinden annenin EKG işareti dakikada 60 atım yapacak şekilde ayarlanmış iken FEKG işareti dakikada 90 atım yapacak şekilde ayarlanmıştır. Yapay olarak oluşturulmuş olan bu EKG işaretlerinin dağınıklık grafikleri ve her bir işaretin olasılık yoğunluk dağılımı Şekil 2.5'de görülmektedir. Bu grafiklerden de görüleceği üzere işaretlerin olasılık dağılımları çok modlu olup Gauss dağılımdan farklıdır. Bu da işaretlerin olasılık dağılımlarının parametrik olarak modellenmesini güçleştirmektedir. Ayrıca dağınıklık grafiğinde işaretlerin birbirlerine dik oldukları görülmektedir. Bu işaretlerin bağımsız olduklarının bir göstergesidir ve BBA algoritmaları için kullanılabilirler. Dağınıklık grafiklerinin bir diğer önemli özelliği de işaretlerin birleşik olasılık dağılımlarının iki boyutlu yüzey üzerine iz düşümünü temsil etmesidir. Bu grafiğe bakılarak EKG işaretlerinin birleşik olasılık dağılımlarının nasıl olması gerektiği hakkında bir yorum yapılabilir.



Şekil 2.4. Yapay olarak üretilmiş anne EKG'si ve FEKG işaretleri



Şekil 2.5. Yapay olarak üretilmiş anne ve fetusa ait olasılık yoğunluk fonksiyon grafikleri ve dağınıklık grafikleri




Şekil 2.6. Yapay olarak üretilmiş anne EKG'si ve FEKG işaretlerinden yapay karışım ile elde edilen EKG prob işaretleri

Yapay EKG işaretlerinin karışım işlemi için rastgele bir karışım matrisi (2.16) ifadesindeki gibi seçilmiştir. Karışım işlemi gerçekleştirildikten sonra elde edilen yapay EKG prob işaretleri Şekil 2.6'daki gibi elde edilmiştir.

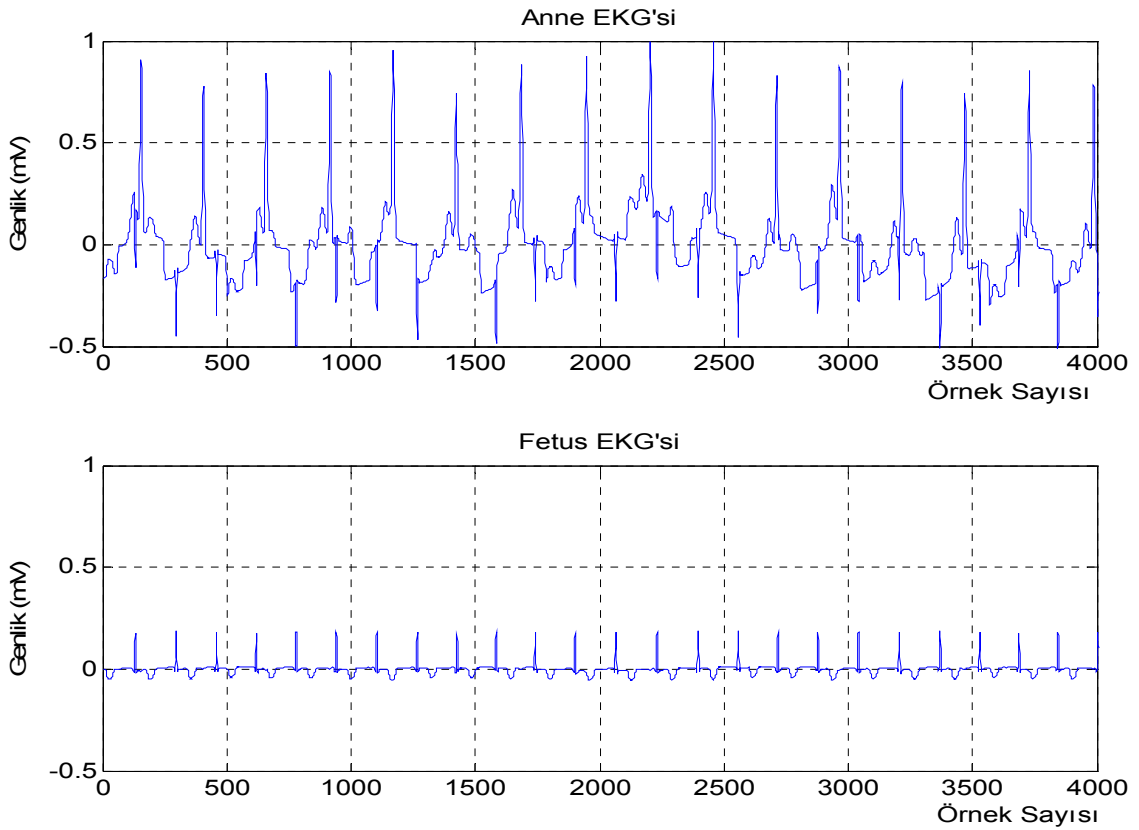
Yapay olarak karıştırılmış olan prob işaretlerinin dağınıklık grafiği ve problardaki karışmış işaretlerin olasılık dağılımları Şekil 2.7'de görülmektedir. Bu grafiğe dikkat edilecek olursa prob işaretlerinin olasılık dağılımlarının kaynak işaretlerine göre Gauss dağılıma daha yakın bir dağılıma sahip oldukları görülmektedir. Bunun nedeni merkezi limit teoremi (MLT) ile açıklanabilir. MLT'e göre iki değişkenin karışımının olasılık yoğunluk fonksiyonu, her bir değişkenin olasılık yoğunluk fonksiyonundan daha Gauss dağılıma sahiptir, yani Gauss şekline daha yakındır.

Şekil 2.7'deki dağınıklık grafiğinde, karışmış işaretlerin yönlendirme şekillerine bakılacak olursa, işaretler karışım matrisine bağlı olarak yönlendirilmişlerdir. Bu yönlendirmeler grafikte açık bir şekilde görülebildiğinden dolayı en basit BBA algoritmalarından olan Geometrik BBA algoritması uygulanacak olursa bulunacak olan karışım matrisi yaklaşımı aynı grafikteki çizgiler ile temsil edilmiştir. Çizgilerden biri dağınıklık grafiğindeki bir sinyalin yönlendirilmesini tam olarak bulmuş iken diğer çizginin diğer işaretin yönlendirilmesini bulamadığı görülmektedir.




Şekil 2.7. Yapay olarak üretilmiş anne ve fetal EKG'lerin karışımının olasılık yoğunluk fonksiyon grafikleri ve dağılıklık grafikleri

Bulunan bu yönlendirmeler kullanılarak işaretler ayrıştırılacak olur ise, Şekil 2.8'deki ayrıştırılmış işaretler elde edilir. Bu ayrıştırılmış işaretlerden anneye ait olan EKG işareti yönlendirme yönü yanlış bulunduğundan dolayı tam olarak ayrıştırılamamıştır. Fakat fetusa ait EKG işaretinin yönlendirme yönü tam olarak bulunabildiğinden dolayı fetusa ait EKG işaretinin Geometrik BBA algoritması ile ayrıştırılması mümkün olmuştur ve Şekil 2.8'de alt grafikte açık bir şekilde görülebilmektedir. Elde edilen fetusa ait EKG işaretinin İHO 22,99 dB iken anneye ait EKG işaretinin İHO 11,42 dB olarak hesaplanmıştır.



Şekil 2.8. Geometrik BBA algoritması ile ayrıştırılmış yapay anne EKG'si ve FEKG işaretleri


Geometrik BBA algoritması ile ayrıştırılmış olan Şekil 2.8'deki işaretlerin dağınıklık grafikleri ve olasılık dağılımları Şekil 2.9'da görülebilmektedir. Ayrıştırılmış işaretlerin olasılık dağılımları ile kaynak işaretlerinin olasılık dağılımları karşılaştırılacak olursa fetusun EKG işaretinin olasılık dağılımı gerçeğine yakın bir şekilde elde edilebildiği görülmekte iken anneye ait EKG işaretinin olasılık dağılımı gerçek işaretin dağılımına benzememektedir. Benzer şekilde dağınıklık grafiği de kaynakların dağınıklık grafiklerinden farklı olarak birbirlerine göre tam olarak dik olmadıkları görülebilmektedir. Ayrıştırılmış işaretlerin az da olsa birbirlerine bağlı oldukları grafikteki yönelmeden de görülebilmektedir.



Şekil 2.9. Geometrik BBA algoritması ile ayrıştırılmış yapay olarak üretilmiş anne ve fetal EKG'lerin olasılık yoğunluk fonksiyon grafikleri ve dağınıklık grafikleri


2.3.1.1. Boscolo'nun Parametrik Olmayan BBA Algoritma Sonuçları

Şekil 2.6'da yapay olarak karışmış işaretlere, birinci bölümde Boscolo'ya ait parametrik olmayan olasılık yoğunluk tahminine dayalı BBA algoritması 3000 örnek sayısı için uygulandı ve elde edilen sonuçlar Şekil 2.10'da görülmektedir. Şekildeki sonuçlardan da görüleceği üzere parametrik olmayan yaklaşımı kullanan Boscolo'nun BBA algoritması EKG işaretlerini çok doğru bir şekilde ayrıştırmıştır. Bu ayrıştırma sonucunda işaretlerde hesaplanan İHO değerleri, annenin EKG işareti için 49,16 dB iken fetusun EKG işareti için 41,54 dB olarak bulunmuştur. Boscolo'nun algoritması ile elde edilen İHO değerleri Geometrik BBA algoritma sonucu ile karşılaştırılacak olur ise aralarında çok büyük bir farkın olduğu görülecektir.



Şekil 2.10. Boscolo'nun parametrik olmayan BBA algoritma sonuçları

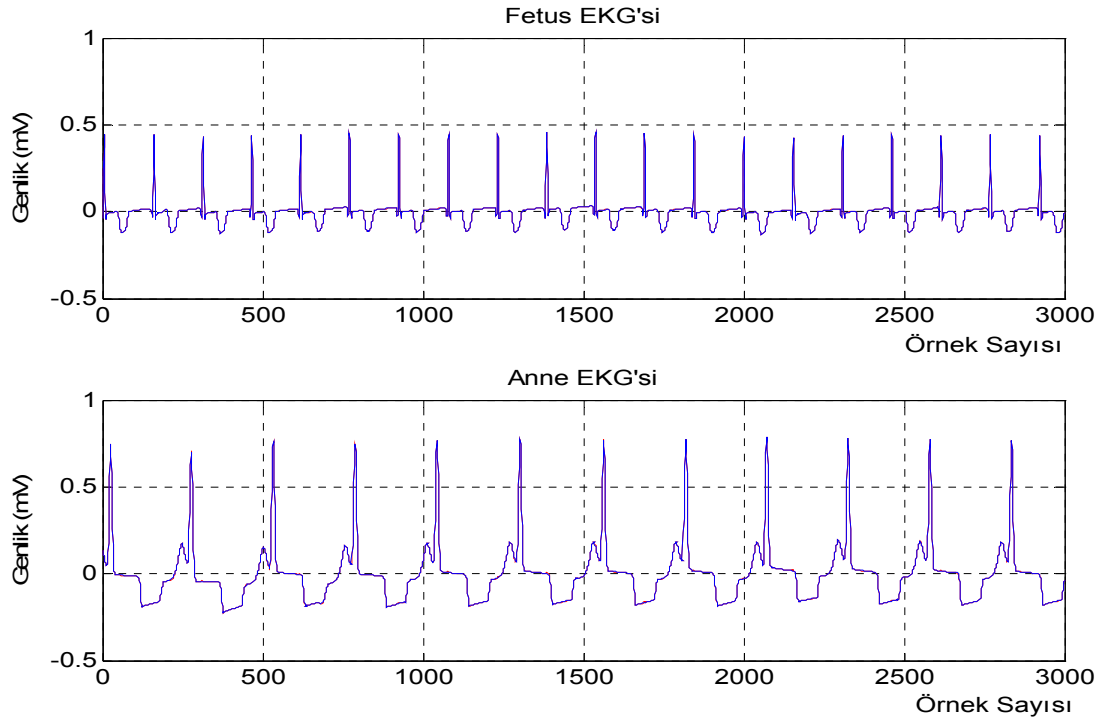
Üstteki şekilde ayrıştırılmış olan EKG işaretlerinin dağınıklık grafikleri ve olasılık dağılımları Şekil 2.11'de görülmektedir. Olasılık dağılımları Şekil 2.5'deki kaynak olasılık dağılımları ile karşılaştırıldıklarında aynı forma sahip oldukları görünmektedir. Dağınıklık grafiğindeki yönelme yönü ise Şekil 2.5'deki ile aynıdır, aralarındaki tek fark eksenlerin farklı işaretleri temsil etmeleridir.



Şekil 2.11. Boscolo'nun parametrik olmayan BBA algoritma sonucunun olasılık yoğunluk fonksiyon grafikleri ve dağınıklık grafiği


2.3.1.2. Önerilen Yapay Toplamsallık Özelliğini Kullanan Parametrik Olmayan BBA Algoritma Sonuçları

İkinci bölümde önermiş olduğumuz Tsallis'in yapay toplamsallık özelliğini amaç fonksiyon olarak kullanan parametrik olmayan BBA algoritması, Boscolo'nun metodunda olduğu gibi Şekil 2.6'daki yapay olarak karışmış 3000 örneklilik işaretler üzerine uygulanır ise elde edilen sonuçlar Şekil 2.12'de görülmektedir. Şekildeki sonuçlardan da görüleceği üzere parametrik olmayan yaklaşımı kullanan önerilen yeni BBA algoritması EKG işaretlerini çok iyi bir şekilde ayırtmıştır. Bu ayırıştırma sonucunda işaretlerde hesaplanan İHO değerleri, annenin EKG işareti için 48,66 dB iken fetusun EKG işareti için 50,43 dB olarak bulunmuştur. Bu İHO değerleri Boscolo'nun algoritması ile elde edilen İHO değerleri ile karşılaştırılacak olur ise aralarında çok büyük bir farkın olmadığı görülecektir. Fakat önerilen yeni algoritmanın fetusun EKG işaretini ayırıştırır iken yapmış olduğu hatanın daha az olduğu görülmektedir.



Şekil 2.12. Önerilen parametrik olmayan yeni BBA algoritma sonuçları

Şekil 2.12’de önerilen parametrik olmayan yeni BBA algoritması kullanılarak ayrıştırılmış olan EKG işaretlerinin dağınıklık grafikleri ve olasılık dağılımları Şekil 2.13’de görülmektedir. Olasılık dağılımları Şekil 2.5 ve Şekil 2.11’deki kaynak olasılık dağılımları ile karşılaştırıldıklarında aynı forma sahip oldukları gözlenmektedir. Dağınıklık grafiğindeki yönelme yönü ise Şekil 2.5’deki ile aynıdır, aralarındaki tek fark Boscolo’nun algoritma sonuçlarında olduğu gibi eksenlerin farklı işaretleri temsil etmeleridir.



Şekil 2.13 . Önerilen parametrik olmayan yeni BBA algoritma sonuçlarının dağılıklık grafiği


2.3.1.3. Tek Hamilelik Durumunda BBA Algoritma Performansları

Önerilen yeni BBA algoritmasının performansı hakkında daha iyi bilgi sahibi olmak için, günümüzde en çok bilinen iki BBA algoritması (Hızlı BBA, ÖMBK) ve kendisi gibi parametrik olmayan yaklaşım kullanan Boscolo'nun algoritması ile farklı örnek sayılarına göre İHO değerleri karşılaştırılmış ve sonuçlar Tablo 4'de görülmektedir. Bu sonuçları elde etmek için örnek sayısı olarak 512 adım artımı kullanılmıştır. Karışım matrisi olarak 100 tane rastgele üretilmiş matris kullanılmış ve tablodaki İHO değerlerini elde etmek için algoritmaların uygulanması sonucunda ayrıştırılan işaretlerin İHO değerlerinin ortalaması alınmıştır.

Tablo 4. Tek hamilelik durumunda gürültüsüz yapay EKG işaretleri için BBA algoritma sonuçlarının İHO değerlerinin farklı örnek sayılarına göre değişimi


Örnek Sayısı	Hızlı BBA İHO (dB)		ÖMBK İHO (dB)		Boscolo'nun Par. Olmayan BBA İHO (dB)		Önerilen Par. Olmayan BBA İHO (dB)	
	Anne	Fetus	Anne	Fetus	Anne	Fetus	Anne	Fetus
512	28,20	34,63	29,67	35,70	39,39	38,46	39,38	50,85
1024	39,02	35,18	37,06	35,05	45,36	45,74	48,59	48,59
1536	42,36	41,63	36,25	44,74	32,94	38,61	34,01	37,33
2048	29,03	34,82	28,12	40,58	26,21	37,40	28,39	38,44
2560	51,34	32,54	35,25	45,15	33,22	35,11	31,63	35,04
3072	34,34	30,60	31,72	42,38	32,16	37,34	29,85	37,38
3584	37,27	34,26	32,46	45,01	34,68	36,30	33,80	36,18
4096	39,60	31,54	33,23	67,45	36,46	36,95	33,57	36,68
4608	40,94	36,61	34,70	40,95	38,60	36,54	37,71	36,68

Tablo 4’de elde edilen anneye ait İHO değerlerinin örnek sayısına göre değişim grafiği Şekil 2.14’de görülmektedir. Şekilden görüleceği üzere iki kaynaklı durum için önerilen yeni algoritmanın İHO değerleri küçük örnek sayısı için diğer algoritmalara göre daha iyi sonuç verir iken örnek sayısı büyüdükçe algoritmalar birbirlerine yakın İHO değerlerine sahip olmaktadır. Ayrıştırılmış anneye ait EKG işaretinde, Hızlı BBA algoritmasının İHO değerlerinin 1536 örnekten sonra diğer algoritmalara göre daha iyi olmaktadır.




Şekil 2.14. Gürültüsüz yapay EKG işaretleri için farklı BBA algoritmaları kullanılarak ayrıştırılan anneye ait EKG işaretlerinin İHO değerlerinin farklı örnek sayıları için karşılaştırılması

Tablo 4’de elde edilen fetusa ait İHO değerlerinin örnek sayısına göre değişim grafiği Şekil 2.15’de görülmektedir. Şekilden görüleceği üzere iki kaynaklı durum için önerilen yeni algoritmanın İHO değerleri, annenin İHO değerlerindeki gibi küçük örnek sayısı için yüksek iken örnek sayısı büyüdükçe sabit kalmaktadır ve Boscolo’nun algoritma sonuçlarına eşit olmaktadır. Fetusa ait ayrıştırılmış EKG işaretlerinde en iyi sonucu 1536 örnek sayısından sonra ÖMBK algoritması vermektedir. Hızlı BBA algoritması ise genel olarak düşük İHO değerlerine sahip olmasına rağmen yaklaşık olarak parametrik olmayan algoritma sonuçlarına eşittir.



Şekil 2.15. Gürültüsüz yapay EKG işaretleri için farklı BBA algoritmaları kullanılarak ayrıştırılan fetusa ait EKG işaretlerinin İHO değerlerinin farklı örnek sayıları için karşılaştırılması


Örnek sayısına göre, parametrik olmayan yeni algoritma ile Boscolo'nun parametrik olmayan algoritmasının performansları adım sayı değerleri cinsinden karşılaştırılması Şekil 2.16'de görülmektedir. Önerilen yeni algoritma sonuca daha az adım sayısında ulaşıyor iken Boscolo'nun algoritması sonuca daha çok adım sayısında ulaşmaktadır. Fakat işlem hacmi olarak önerilen yeni algoritma Boscolo'nun algoritmasından daha fazla işlem yapmaktadır.



Şekil 2.16. Tek hamilelik durumu için parametrik olmayan iki algoritmanın adım sayılarının örnek sayılarına bağlı olarak karşılaştırılması

2.3.2. İkiz Hamilelik Durumunda Elde Edilen Sonuçlar

İkiz hamilelik durumunda, EKG işaretlerinin ayrıştırılması; nadir olarak karşılaşılan, fakat fetusların kalp atım oranları birbirine yakın olduğundan dolayı çözümü zor olan bir problemdir. BBA algoritmalarının performanslarının kaynak sayısına göre karşılaştırılması için ikiz hamilelik durumu göz önüne alınarak ikinci bir fetusun EKG işareti Şekil 2.4'teki işaretlere eklenerek ikiz hamilelik için kaynak işaretleri elde edilir. Bu yeni eklenen işaretin dakikadaki atım sayısı 95 olarak seçilmiştir. Bu yapay kaynak işaretlerini kullanarak yapay prob işaretlerini üretmek için (2.17) denklemini kullanılmış ve sonuçlar Şekil 2.17'deki gibi elde edilmiştir. Karışım için 3000 örneklilik işaret dizisi kullanılmıştır.




Şekil 2.17. Yapay olarak karıştırılmış anne EKG'si ve iki fetusa ait FEKG işaretleri (EKG prob işaretleri)

Şekilden de görüleceği üzere annenin ve fetal EKG işaretlerinin hangi işaretler olduğuna karar verilmesi üçüncü prob işareti hariç çok zordur.

2.3.2.1. Boscolo'nun Parametrik Olmayan BBA Algoritma Sonuçları


Şekil 2.17'de yapay olarak karışmış işaretlere, Boscolo'ya ait parametrik olmayan olasılık yoğunluk tahminine dayalı BBA algoritması 3000 örnek sayısı için uygulanır ise elde edilen sonuçlar Şekil 2.18'de görülmektedir. Şekilde 2.18'deki sonuçlardan da görüleceği üzere parametrik olmayan yaklaşımı kullanan Boscolo'nun BBA algoritması ile EKG işaretleri oldukça doğru bir şekilde ayrıştırılmıştır. Ayrıştırılan işaretlerde hesaplanan İHO değerleri, annenin EKG işareti için 36,92 dB, birinci fetus için 53,39 dB ve ikinci fetus için 32,11 dB olarak bulunmuştur.



Şekil 2.18. Boscolo'nun parametrik olmayan BBA algoritma sonuçları

2.3.2.2. Önerilen Yapay Toplamsallık Özelliğini Kullanan Parametrik Olmayan BBA Algoritma Sonuçları

Tsallis'in yapay toplamsallık özelliğini kullanan önerilen yeni parametrik olmayan BBA algoritması, Boscolo'nun metodunda olduğu gibi Şekil 2.17'deki yapay olarak karışmış 3000 örneklilik işaretler üzerine uygulanır ise elde edilen sonuçlar Şekil 2.19'da gösterilmiştir. Şekildeki sonuçlardan da görüleceği üzere önerilen parametrik olmayan BBA algoritması EKG işaretlerini oldukça doğru bir şekilde ayırtmıştır. Bu ayırıştırma sonucunda işaretlerde hesaplanan İHO değerleri, annenin EKG işareti için 64,61 dB, birinci fetusun EKG işareti için 54,54 dB ve ikinci fetus için 35,44 dB olarak bulunmuştur. Önerilen algoritma ile elde edilen İHO değerleri, Boscolo'nun algoritması ile elde edilen İHO değerleri ile karşılaştırılacak olursa, annenin EKG işareti ve ikinci fetusun EKG işaretleri arasında fark var iken birinci fetusun EKG işaretleri arasında çok büyük bir farkın olmadığı görülecektir.



Şekil 2.19. Önerilen parametrik olmayan yeni BBA algoritma sonuçları


Önerilen yeni parametrik olmayan algoritmanın sonuçları her bir işaret için farklı birleşik olasılık yoğunluk fonksiyon tahminleri kullanılarak elde edilmiştir. Birleşik olasılık yoğunluk fonksiyonu tahminlerinden biri annenin EKG işaretinin İHO değerini artırır iken fetusun EKG işaretinin İHO değerini azaltmaktadır. Diğer tahmin ise fetusun EKG işaretinin İHO değerini artırır iken annenin EKG işaretinin İHO değerini azaltmaktadır. Bu Boscolo'nun algoritmasında elde edilemeyen bir sonuçtur.

2.3.2.3. İkiz Hamilelik Durumunda BBA Algoritma Performansları

İkiz hamilelik durumu için önerilen yeni BBA algoritmasının performansı hakkında bilgi sahibi olmak için; bu algoritma, Hızlı BBA, ÖMBK ve parametrik olmayan yaklaşım kullanan Boscolo'nun algoritması ile farklı örnek sayılarına göre hesaplanan İHO değerleri karşılaştırılmış ve sonuçlar Tablo 5'de verilmiştir.

Tablo5 . İkiz hamilelik durumunda gürültüsüz yapay EKG işaretleri için BBA algoritma sonuçlarının İHO değerlerinin farklı örnek sayılarına göre değişimi


Örnek Sayısı	Hızlı BBA İHO (dB)			ÖMBK İHO (dB)		
	Anne	1.Fetus	2. Fetus	Anne	1. Fetus	2. Fetus
512	33,31	19,73	21,36	30,64	26,01	15,90
1024	29,39	22,28	21,34	34,05	29,69	32,77
1536	32,88	35,91	29,47	40,17	31,14	31,49
2048	31,62	27,78	31,24	36,78	26,66	39,99
2560	30,04	33,20	33,13	36,78	34,86	32,16
3072	28,80	37,14	42,48	38,32	31,64	37,49
3584	30,10	31,82	30,68	37,01	30,95	38,72
4096	29,27	29,98	30,60	39,53	32,79	40,20
4608	32,26	34,28	36,41	37,10	34,39	43,52
Örnek Sayısı	Boscolo'nun Par. Olmayan BBA İHO (dB)			Önerilen Par.Olmayan BBA İHO (dB)		
	Anne	1.Fetus	2. Fetus	Anne	1. Fetus	2. Fetus
512	34,89	20,69	27,20	41,82	18,72	28,57
1024	40,67	33,41	31,35	38,15	34,14	41,34
1536	38,64	32,49	39,02	36,64	27,30	30,87
2048	37,22	24,02	37,34	37,48	25,66	37,01
2560	35,12	33,24	35,68	33,81	24,61	43,23
3072	36,92	32,11	53,39	35,89	27,14	47,34
3584	36,34	32,77	41,13	35,71	33,24	51,11
4096	36,99	36,23	43,20	36,58	31,87	49,30
4608	36,56	36,86	47,50	35,85	36,21	43,10



Şekil 2.20. Gürültüsüz yapay EKG işaretleri (ikiz hamilelik durumunda) için farklı BBA algoritmaları kullanılarak ayrıştırılan anneye ait EKG işaretinin İHO değerlerinin farklı örnek sayılarına göre değişimi


Tablo 5’de elde edilen anneye ait İHO değerlerinin örnek sayısına göre değişim grafiği Şekil 2.20’de gösterilmiştir. Şekilden görüleceği üzere üç kaynaklı durum için önerilen yeni algoritmanın İHO değeri 512 örnek sayısı için diğer algoritmalara göre daha iyi sonuç verirken örnek sayısı arttıkça yaklaşık olarak diğer algoritmalar ile aynı İHO değerlerine sahip olmaktadır. Hızlı BBA algoritması ise tek hamilelik durumundan farklı olarak İHO değerleri diğer algoritmalara göre daha düşük değer vermektedir.

Tablo 5’de elde edilen birinci fetusa ait İHO değerlerinin örnek sayısına göre değişim grafiği Şekil 2.21’de gösterilmiştir. 1536, 2560 ve 3072 örnek sayısı hariç önerilen yeni algoritma diğer algoritmalar ile birbirlerine yakın İHO değerlerini vermektedir.




Şekil 2.21. Gürültüsüz yapay EKG işaretleri (ikiz hamilelik durumunda) için farklı BBA algoritmaları kullanılarak ayrıştırılan birinci fetusa ait EKG işaretlerinin İHO değerlerinin farklı örnek sayılarına göre değişimi

Tablo 5'deki ikinci fetusa ait EKG işaretinin, örnek sayısına göre İHO değişimi Şekil 2.22'de gösterilmiştir. Kaynak işaretlerine en yakın sonuçları, önerilen yeni algoritma üretmektedir. Önerilen yeni algoritmanın İHO değerleri 512 ve 1024 örnek sayıları için diğer algoritmalara göre oldukça yüksektir. Boscolo'nun algoritması ise 2048 örnek sayısı hariç önerilen algoritmadan sonra en iyi İHO değerlerini vermektedir. 3072 örnek sayısında en iyi İHO değerini vermektedir. Hızlı BBA algoritmasıysa en kötü İHO değerlerini vermektedir.



Şekil 2.22. Gürültüsüz yapay EKG işaretleri (ikiz hamilelik durumunda) için farklı BBA algoritmaları kullanılarak ayrıştırılan ikinci fetusa ait EKG işaretlerinin İHO değerlerinin farklı örnek sayılarına göre değişimi

Adım sayısına göre, parametrik olmayan önerilen yeni algoritma ile Boscolo'nun parametrik olmayan algoritmasının performanslarının İHO cinsinden karşılaştırılması Şekil 2.23'de gösterilmiştir. Tüm örnek sayıları için önerilen yeni algoritma Boscolo'nun algoritmasından daha düşük adım sayısında sonuç vermektedir. Her iki algoritmada da örnek sayısı arttıkça adım sayısı da buna bağlı olarak artış göstermektedir.



Şekil 2.23. İkiz hamilelik durumu için parametrik olmayan iki algoritmanın adım sayılarının örnek sayılarına bağlı olarak karşılaştırılması


2.4. Gürültülü EKG İşaretlerine Ait Elde Edilen Sonuçlar

Bu bölüme kadar yapılan çalışmalarda, algoritmaların performansları gürültü yokken incelenmeye çalışıldı. Bu bölümde ise, algoritmaların performansları gürültü var iken test edilecektir. İlk olarak gürültü kaynak işareti, beyaz Gauss gürültü olarak ele alınacaktır. İkinci olarak sürekli olmayan gürültü kaynak işareti olarak ele alınacak ve işaretler ayrıştırılmaya çalışılacaktır. Her iki durum için gürültü kaynak işareti olarak seçildiğinden dolayı işaretlerin işaret karışım oran (İKO) değerleri yaklaşık olarak sabit değer almasına çalışılmıştır. Son olarak gürültü işareti harici gürültü olarak ele alınacak ve karışım işlemi gerçekleştirildikten sonra gürültü karışımış işaretlere eklenecektir. Bu durumda da işaretlerin işaret gürültü oran (İGO) değerleri yaklaşık olarak sabit değer almasına çalışılmıştır. Tüm gürültülü EKG

uygulamalarında, algoritmaların performans ölçütü olarak örnek sayısı değişimine bağlı olarak ayrıştırılan işaretlerin İHO değerleri karşılaştırılacaktır.


2.4.1. Beyaz Gauss Gürültüye Ait Elde Edilen Sonuçlar

İlk uygulanan kaynak gürültüsü beyaz Gauss gürültüsüdür. 2560 örnek sayısı ve 8 dB'lik İKO değeri için kaynak sinyalleri Şekil 2.24'de verilmiştir. Şekilden de görüleceği üzere anne ve fetusun EKG işaretleri gerçek EKG işaretlerine benzerlik göstermektedir.




Şekil 2.24. Gürültü, kaynak gürültüsü iken 8 dB İKO için kaynak sinyalleri

Şekil 2.24'deki kaynak işaretleri (2.17) denklemindeki karışım matrisi kullanılarak karıştırılmış ve elde edilen yapay prob işaretleri Şekil 2.25'de görülmektedir. Şekil 2.25'den de görüleceği üzere annenin ve fetusun EKG işaretleri beyaz Gauss kaynak gürültüsü tarafından görülemeyecek derecede bastırılmıştır. Annenin EKG işaretinin genliği yüksek olduğundan ve karışım matrisindeki ilk değer büyük olduğundan dolayı ilk probdaki kayıtlarda annenin EKG işaretinin R tepeleri fark edilebilmektedir.




Şekil 2.25. Gürültü, kaynak gürültüsü iken 8 dB İKO için yapay prob sinyalleri

Şekil 2.25’de yapay olarak karışmış işaretlere, Boscolo’ya ait parametrik olmayan olasılık yoğunluk tahminine dayalı BBA algoritması 2560 örnek sayısı için uygulandı ve elde edilen sonuçlar Şekil 2.26’da gösterildi. Şekildeki sonuçlardan görüleceği üzere Boscolo’nun BBA algoritması EKG işaretlerini ayrıştırabilmiştir. Ayrıştırılan işaretler BBA algoritmalarındaki belirsizlikten biri olan bulunan işaretlerin sıralamasının belirlenemeyişinden dolayı farklı sıralamalar ile bulunmuşlardır.



Şekil 2.26. Gürültü, kaynak gürültüsü iken 8 dB İKO için Boscolo'nun parametrik olmayan BBA algoritma sonuçları

Önerilen yeni algoritmanın aynı karışım işaretleri üzerine uygulanması ile elde edilen sonuçlar Şekil 2.27'de gösterilmiştir. Önerilen yeni algoritma da Boscolo'nun algoritmasında olduğu gibi, sıralamaları farklı olacak şekilde işaretleri ayırtmada başarılı olmuştur. Şekil 2.26 ve Şekil 2.27 karşılaştırıldıklarında görsel açıdan aralarında pek fark olmadığı ve sonuçların uzman kişiler için yeterli olabileceği görülmektedir.




Şekil 2.27. Gürültü, kaynak gürültüsü iken 8 dB İKO için önerilen parametrik olmayan BBA algoritma sonuçları

Parametrik olmayan özelliğe sahip, önerilen yeni algoritmanın, Boscolo'nun algoritmasının ve en çok bilinen iki BBA algoritmasının farklı örnek sayı değerlerine karşılık elde edilen İHO değerleri Tablo 6'da verilmiştir. Gürültüsüz EKG uygulamasında olduğu gibi karışım matrisi algoritmaların her çalıştırılmasında rastgele olarak üretilmiş ve buna ek olarak kaynak işareti olan gürültü de algoritmaların her çalıştırılışında rastgele olarak üretilmektedir. İHO değerleri ise algoritmaların 100 kez çalıştırılmasından sonra elde edilen İHO değerlerinin ortalaması alınarak elde edilmiştir.

Tablo 6. Tek hamilelik durumunda kaynak gürültülü yapay EKG işaretleri için BBA algoritma sonuçlarının İHO değerlerinin farklı örnek sayısı değerlerine göre değişimi


Örnek Sayısı	Hızlı BBA İHO (dB)		ÖMBK İHO (dB)		Boscolo'nun Par. Olmayan BBA İHO (dB)		Önerilen Par. Olmayan BBA İHO (dB)	
	Anne	Fetus	Anne	Fetus	Anne	Fetus	Anne	Fetus
512	29,68	30,08	26,15	27,22	37,31	41,96	40,16	39,28
1024	27,72	33,97	29,13	32,27	38,28	41,30	34,77	40,29
1536	29,54	33,83	33,36	32,69	50,03	40,25	41,89	40,34
2048	31,05	39,76	32,64	36,86	51,82	43,85	45,29	43,98
2560	30,43	33,50	32,18	34,26	45,55	41,49	40,53	41,53
3072	29,88	37,54	34,66	35,45	43,90	54,29	39,71	48,53
3584	30,60	37,91	34,07	36,59	46,84	48,25	41,85	45,76
4096	31,98	37,52	35,27	39,20	48,69	46,65	43,57	45,21
4608	32,85	41,15	35,26	40,88	48,70	49,21	44,49	48,88

Tablo 6'da elde edilmiş olan anneye ait İHO değerlerinin örnek sayılarına göre değişim grafiği Şekil 2.28'de görülmektedir. Şekil 2.28'den görüleceği üzere parametrik olmayan algoritmalar hemen hemen aynı İHO değerlerine sahiptirler. Boscolo'nun algoritması önerilen yeni algoritmaya göre daha iyi sonuç verirken, önerilen yeni algoritma sonuçları ikinci en iyi sonuçları vermektedir. ÖMBK ve Hızlı BBA algoritmaları ise yaklaşık olarak aynı İHO değerlerine sahiptirler ve parametrik olmayan algoritmalarından düşük İHO değerleri vermektedirler.




Şekil 2.28. Gürültü, kaynak gürültüsü iken, farklı algoritmalar kullanılarak ayrıştırılan annenin EKG işaretlerine ait İHO değerlerinin örnek sayısı değerlerine göre değişim grafiği

Benzer şekilde fetusa ait EKG işaretinin İHO değerlerinin örnek sayılarına göre değişimi Şekil 2.29’da görülmektedir. Parametrik olmayan Boscolo’nun algoritması ve önerilen yeni algoritma en iyi İHO değeri veren algoritmalarıdır ve 3072 örnek sayısı hariç yaklaşık olarak aynı İHO değerlerini vermektedirler. Hızlı BBA ve ÖMBK algoritmaları ise annenin EKG işaretinde olduğu gibi yaklaşık olarak aynı İHO değerleri sahiptirler ve örnek sayısı arttıkça İHO değerleri artış göstermektedir.



Şekil 2.29. Gürültü, kaynak gürültüsü iken, farklı algoritmalar kullanılarak ayrıştırılan fetusun EKG işaretlerine ait farklı İKO değerlerinin İHO değerlerine göre değişim grafiği

Önerilen yeni algoritmanın ve Boscolo'nun algoritmasının örnek sayısına göre adım sayısı değerlerinin değişimlerinin karşılaştırılması Şekil 2.30'da gösterilmiştir. Tüm örnek sayı değerleri için önerilen yeni algoritma Boscolo'nun algoritmasına göre daha düşük adım sayısına sahip olduğu şekilden de görülmektedir.



Şekil 2.30. Gürültü, kaynak gürültüsü ve tek hamilelik durumu için parametrik olmayan iki algoritmanın adım sayılarının örnek sayılarına bağlı olarak karşılaştırılması


2.4.2. İkiz Hamilelik Durumu İçin Beyaz Gauss Gürültüye Ait Elde Edilen Sonuçlar

Tek hamilelik durumunda olduğu gibi ikiz hamilelik durumunda algoritmaların performanslarını ölçmek için her algoritma rastgele değişen karışım matrisi ile 100 kez karıştırılmış ve ayrıştırılan EKG işaretlerinin İHO değerlerinin örnek sayısına göre değişimlerinin ortalaması Tablo 7’de görünmektedir.


Tablo 7. İkiz hamilelik durumunda kaynak gürültülü yapay EKG işaretleri için BBA algoritma sonuçlarının İHO değerlerinin farklı örnek sayısı değerlerine göre değişimi

Örnek Sayısı	Hızlı BBA İHO (dB)			ÖMBK İHO (dB)		
	Anne	1. Fetus	2. Fetus	Anne	1. Fetus	2. Fetus
512	31,88	22,01	19,30	28,85	15,74	25,57
1024	28,10	22,57	21,35	29,63	28,11	29,90
1536	29,74	31,80	28,70	32,67	29,74	29,80
2048	29,75	26,97	30,99	32,22	26,08	34,74
2560	28,24	31,45	30,72	32,94	32,99	31,01
3072	27,70	33,92	36,91	34,07	30,58	34,70
3584	28,55	29,98	30,18	33,90	30,23	35,84
4096	28,52	29,26	30,70	35,05	32,04	36,31
4608	29,31	31,32	35,50	34,43	33,11	38,88
Örnek Sayısı	Boscolo'nun Par. Olmayan BBA İHO (dB)			Önerilen Par. Olmayan BBA İHO (dB)		
	Anne	1.Fetus	2. Fetus	Anne	1. Fetus	2. Fetus
512	34,13	20,59	27,13	36,53	18,84	29,87
1024	39,36	32,19	31,16	36,25	32,14	38,74
1536	38,16	31,75	38,39	35,86	26,66	29,87
2048	36,90	23,91	37,03	37,15	26,71	38,15
2560	34,93	32,66	35,48	34,18	24,96	40,96
3072	36,73	31,75	49,01	35,71	26,87	44,78
3584	36,17	32,36	40,74	35,84	32,58	46,94
4096	36,87	35,58	42,73	36,74	31,55	45,70
4608	36,43	36,21	46,32	36,58	35,56	43,12

Tablo 7’deki anneye ait İHO değerlerinin örnek sayısı değerlerine göre değişimi Şekil 2.31’de görülmektedir. Şekil 2.31’de görüleceği üzere parametrik olmayan her iki algoritma diğer algoritmalara göre daha yüksek İHO değerlerine sahiptir ve örnek sayısı değişiminden bağımsız olarak sabit İHO değerleri vermektedir. Hızlı BBA algoritması en kötü İHO değerlerine sahip algoritmadır. Bu sonuçlar gürültüsüz ikiz hamilelik durumundaki annenin EKG işareti sonuçları ile karşılaştırılacak olursa; ÖMBK algoritması hariç diğer algoritmaların İHO değerleri yaklaşık olarak sabit kalırken ÖMBK algoritmasının İHO değerlerinin düştüğü görülmektedir.



Şekil 2.31. Gürültü, kaynak gürültüsü ve ikiz hamilelik durumu için, farklı algoritmalar kullanılarak ayrıştırılan annenin EKG işaretlerine ait farklı örnek sayısı değerlerine göre değişim grafiği




Şekil 2.32. Gürültü, kaynak gürültüsü ve ikiz hamilelik durumu için, farklı algoritmalar kullanılarak ayrıştırılan birinci fetusun EKG işaretlerine ait farklı örnek sayısı değerlerine göre değişim grafiği

Tablo 7’de elde edilen birinci fetusa ait İHO değerlerinin örnek sayısı değerlerine göre değişiminin grafiği Şekil 2.32’de görülmektedir. Önerilen yeni algoritmanın birinci fetusa ait sonuçları 2560 ve 3072 örnek sayıları hariç yaklaşık olarak aynı İHO değerlerini vermektedir. Bu sonuçlar gürültüsüz ikiz hamilelik durumundaki birinci fetusa ait EKG işareti sonuçları ile karşılaştırılacak olursa; İHO değerlerinde çok küçük bir azalma olduğu görülmektedir.


Tablo 7’de elde edilen ikinci fetusa ait İHO değerlerinin örnek sayısı değerlerine göre değişiminin grafiği Şekil 2.33’de görülmektedir. Önerilen yeni algoritmanın ikinci fetusa ait sonuçları genel olarak diğer algoritmalarla karşılaştırıldığında 1536 ve 3072 örnek sayıları hariç daha yüksek İHO değerleri sağlamaktadır. ÖMBK ve Hızlı BBA algoritmaları parametrik olmayan

algoritmalarla göre daha düşük İHO deęerleri vermektedir. Bu sonular gürültüsüz ikiz hamilelik durumundaki ikinci fetusa ait EKG iřareti sonuları ile karřılařtırılacak olursa; anne ve birinci fetusa ait İHO deęerlerinde olduęu gibi ikinci fetusa ait İHO deęerlerinde ok küçük bir azalma olduęu gürölmektedir.

İkiz hamilelik durumu için parametrik olmayan algoritmaların adım sayı deęerlerinin örnek sayı deęerlerine göre deęiřimi Őekil 2.34’de gürölmektedir. Őekilden de güröleceęi üzere, kaynak gürültülü ikiz hamilelik durumu için önerilen yeni algoritma adım sayısı olarak Boscolo’nun algoritmasından daha az adım sayısında iřaretleri ayırřtırabilmektedir.




Őekil 2.33. Gürültü, kaynak gürültüsü ve ikiz hamilelik durumu için, farklı algoritmalar kullanılarak ayırřtırılan ikinci fetusun EKG iřaretlerine ait farklı örnek sayı deęerlerine göre deęiřim grafięi



Şekil 2.34. Gürültü, kaynak gürültüsü ve ikiz hamilelik durumu için parametrik olmayan iki algoritmanın adım sayılarının örnek sayılarına bağlı olarak karşılaştırılması


2.4.3. Tek Hamilelik Durumunda Sürekli Olmayan Gürültüye Ait Elde Edilen Sonuçlar

Sürekli olmayan gürültü diğer gürültüden farklı olarak EKG kayıtlarında süreklilik göstermezler ve kişinin kalp problemi olmadığı halde kalbinde problem varmış gibi görünmesine neden olabilirler. Sürekli olmayan gürültü ve modellenmesi Şekil 2.35’de 3.kaynak işareti olarak gösterilmiştir. Bu şekilde sürekli olmayan gürültü, EKG kayıt anında iki defa meydana geldiği varsayılarak modellenmiştir. Anneye ve fetusa ait EKG işaretleri ise Şekil 2.4’deki EKG işaretleri olarak seçilmiştir.




Şekil 2.35. Sürekli olmayan gürültü için oluşturulmuş yapay kaynak sinyalleri

Şekil 2.35'deki kaynak işaretleri (2.17) denklemindeki karışım matrisi kullanılarak yapay prob işaretleri Şekil 2.36'daki gibi elde edilmiştir. Karışım matrisinin katsayılarına bağlı olarak sürekli olmayan gürültü tüm yapay prob işaretlerinde daireler ile gösterilen bölgelerde gözlemlenir.




Şekil 2.36. Sürekli olmayan gürültü için yapay olarak karıştırılmış anneye ve fetusa ait prob sinyalleri

Şekil 2.36’da yapay olarak karışmış işaretlere, Boscolo’ya ait parametrik olmayan olasılık yoğunluk tahminine dayalı BBA algoritması 3072 örnek sayısı için uygulandığında elde edilen sonuçlar Şekil 2.37’de verilmiştir. Boscolo’nun BBA algoritmasının uygulanması ile elde edilen anneye ait EKG işaretinin İHO değeri 35,56 dB olarak hesaplanmıştır. Fetusa ait EKG işaretinin İHO değeri 38,68 dB olarak hesaplanırken, sürekli olmayan gürültüye ait İHO değeri 10,64 dB olarak hesaplanmıştır.



Şekil 2.37. Sürekli olmayan gürültü için Boscolo'nun BBA algoritma sonuçları

Şekil 2.36'deki yapay prob işaretlerine yeni algoritmanın uygulanması ile elde edilen sonuçlar Şekil 2.38'de gösterilmiştir. Önerilen yeni algoritma ile elde edilen anneye ait EKG işaretinin İHO değeri 43,28 dB olarak hesaplanmıştır. Fetusa ait EKG işaretinin İHO değeri 48,17 dB iken, sürekli olmayan gürültüye ait İHO değeri 10,64 dB olarak hesaplanmıştır. 3072 örnek sayısı için elde edilen sonuçlar karşılaştırılacak olursa önerilen yeni algoritmanın her iki EKG işareti için daha yüksek İHO değerlerine sahip olduğu görülmektedir.




Şekil 2.38. Sürekli olmayan gürültü için önerilen parametrik olmayan BBA algoritma sonuçları

Tek hamilelik durumunda sürekli olmayan gürültü işaretleri için parametrik olmayan BBA algoritmalarının ve güncel olan Hızlı BBA ile ÖMBK algoritmalarının İHO değerlerinin örnek sayısına göre değişim sonuçları Tablo 8’de görülmektedir. Karışım matrisi olarak, 100 tane rastgele üretilmiş matris kullanılmış ve tablodaki İHO değerleri algoritmaların bu karışmış işaretlere uygulanması sonucu elde edilen işaretlerin İHO değerlerinin ortalaması alınarak elde edilmiştir.

Tablo 8. Tek hamilelik durumunda sürekli olmayan gürültülü yapay EKG işaretleri için BBA algoritma sonuçlarının İHO değerlerinin farklı örnek sayılarına göre değişimi

Örnek Sayısı	Hızlı BBA İHO (dB)			ÖMBK İHO (dB)		
	Anne	Fetus	Sür. Olma. Gürültü	Anne	Fetus	Sür. Olma. Gürültü
512	10,42	29,49	6,03	10,94	24,99	6,03
1024	12,69	35,25	5,41	12,99	28,93	5,40
1536	12,73	26,24	7,41	14,12	25,42	7,33
2048	13,29	27,01	8,75	14,44	27,29	8,70
2560	13,70	28,99	9,77	14,48	29,44	9,76
3072	14,56	29,68	10,58	14,83	29,51	10,60
3584	15,12	29,47	11,27	15,33	30,33	11,30
4096	15,61	30,71	11,87	15,75	31,19	11,90
4608	16,02	29,71	12,40	16,07	31,21	12,42
Örnek Sayısı	Boscolo'nun Par. Olmayan BBA İHO (dB)			Önerilen Par. Olmayan BBA İHO (dB)		
	Anne	Fetus	Sür. Olma. Gürültü	Anne	Fetus	Sür. Olma. Gürültü
512	8,99	33,64	6,41	7,78	32,03	6,41
1024	14,22	42,52	5,66	10,79	40,63	5,65
1536	18,97	31,98	7,53	13,81	31,54	7,52
2048	19,43	33,79	8,83	9,87	34,78	8,83
2560	18,49	36,83	9,83	15,70	36,37	9,82
3072	20,11	40,54	10,65	16,90	39,17	10,63
3584	20,66	40,44	11,32	17,13	39,02	11,31
4096	21,51	39,50	11,91	17,60	37,72	11,90
4608	28,48	39,29	12,43	18,16	38,29	12,42



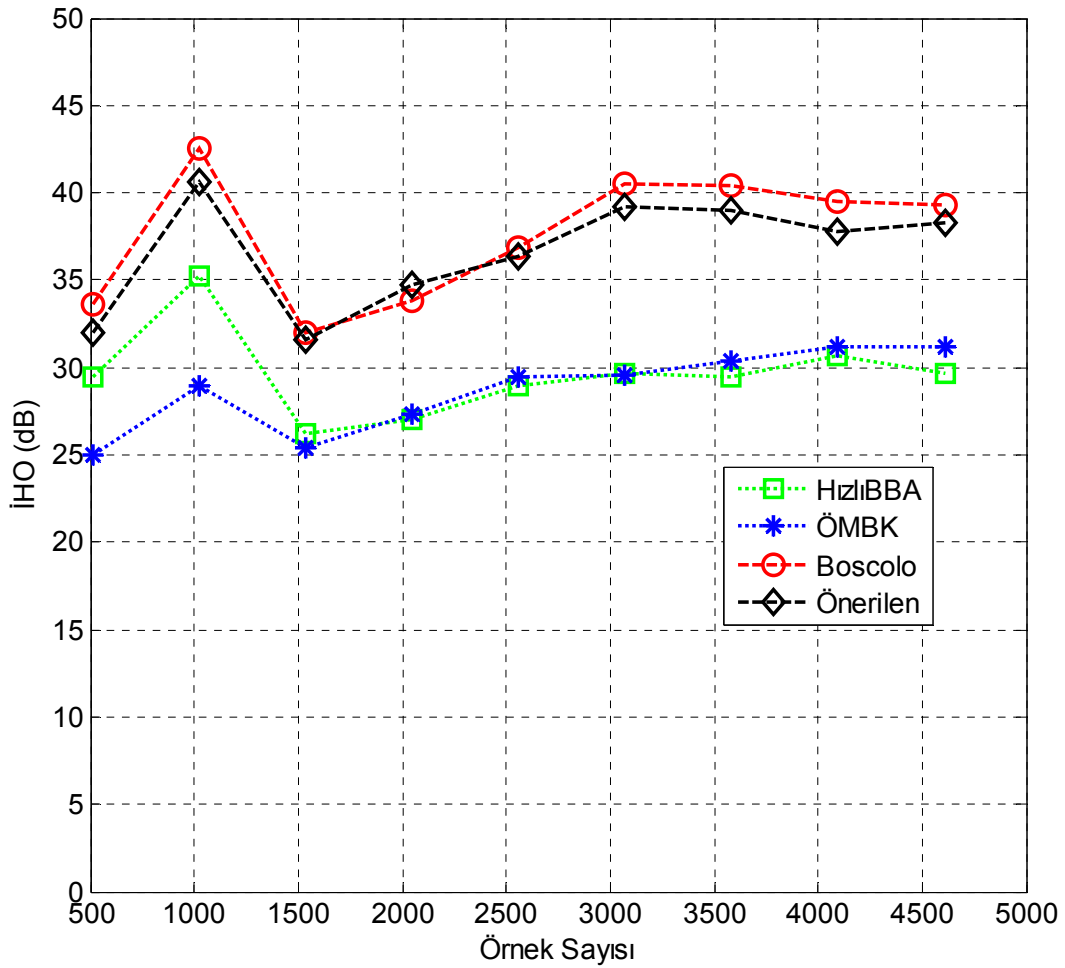
Şekil 2.39. Sürekli olmayan gürültü varken, farklı algoritmalar kullanılarak ayrıştırılan anneye ait EKG işaretlerinin İHO değerlerinin farklı örnek sayıları için karşılaştırılması

Tablo 8’de elde edilen anneye ait EKG işaretlerinin İHO değerlerinin örnek sayısına göre değişiminin grafiği Şekil 2.39’da görülmektedir. En iyi sonuçları parametrik olmayan Boscolo’nun algoritması verirken önerilen yeni algoritma 512, 1024 ve 2048 örnek sayıları hariç en iyi ikinci İHO değerlerini vermektedir. ÖMBK ve Hızlı BBA algoritmaları yaklaşık olarak aynı İHO değerlerine sahiptirler. Sürekli olmayan gürültü Gauss dağılıma sahip gürültüye göre İHO değerleri üzerinde daha etkili olduğu görülmektedir ve ayrıştırılan işaretlerin İHO değerlerini oldukça düşürmektedir.


Benzer şekilde Tablo 8’deki fetusa ait EKG işaretlerinin İHO değerlerinin örnek sayısına göre değişim grafiği Şekil 2.40’da verilmiştir. Sürekli olmayan gürültülü durumda; parametrik olmayan algoritmalar yaklaşık olarak aynı İHO değerlerini verirken önerilen yeni

algoritma az da olsa Boscolo'nun algoritmasından düşük İHO değerleri vermektedir. ÖMBK ve Hızlı BBA algoritmaları düşük İHO değerleri vermektedirler.

Her iki parametrik olmayan algortmadan elde edilen sonuçların adım sayılarının örnek sayısına göre karşılaştırılması Şekil 2.41'de görülmektedir. Önerilen yeni algoritma Boscolo'nun algoritmasına göre daha düşük adım sayısında sonuca ulaşmaktadır.



Şekil 2.40. Sürekli olmayan gürültü varken, farklı algoritmalar kullanılarak ayrıştırılan fetusa ait EKG işaretlerinin İHO değerlerinin farklı örnek sayıları için karşılaştırılması



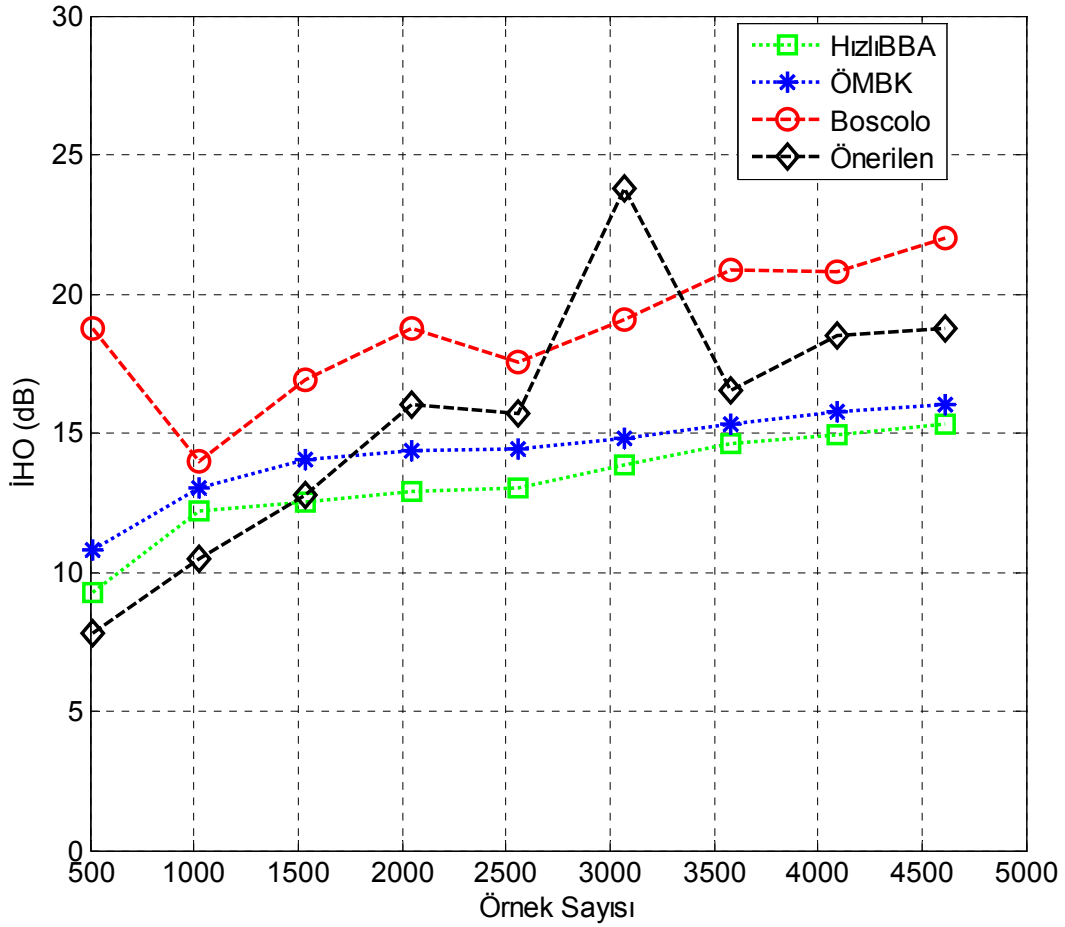
Şekil 2.41. Sürekli olmayan gürültü ve tek hamilelik durumu için parametrik olmayan iki algoritmanın adım sayılarının örnek sayılarına bağlı olarak karşılaştırılması

2.4.4. İkiz Hamilelik Durumunda Sürekli Olmayan Gürültüye Ait Elde Edilen Sonuçlar

Sürekli olmayan gürültülü işaret varlığında algoritmaların performanslarının karşılaştırılması için; anne ve ikiz fetuslarının EKG işaretlerine sürekli olmayan gürültü kaynak işareti olarak eklenmiştir. Kaynak işaretlerinden yapay prob işaretleri elde etmek için 100 tane rastgele üretilmiş karıştırıcı matris kullanılır. Elde edilen yapay prob işaretleri üzerine algoritmaların uygulanması ile elde edilen işaretlerin İHO değerlerinin ortalaması alınarak Tablo 9’da ki İHO değerleri elde edilir.

Tablo 9. İkiz hamilelik durumunda sürekli olmayan gürültülü yapay EKG işaretleri için BBA algoritma sonuçlarının İHO değerlerinin farklı örnek sayılarına göre değişimi


Örnek Sayısı	Hızlı BBA İHO (dB)				ÖMBK İHO (dB)			
	Anne	1.Fetus	2.Fetus	Sür. Olma. Gürültü	Anne	1.Fetus	2.Fetus	Sür. Olma. Gürültü
512	9,27	16,51	19,73	6,03	10,78	15,09	23,21	6,02
1024	12,20	20,19	21,49	5,42	13,01	25,85	29,15	5,39
1536	12,54	21,05	25,42	7,40	14,04	22,93	24,52	7,33
2048	12,89	20,16	27,01	8,75	14,34	21,77	27,08	8,70
2560	13,01	22,24	27,31	9,79	14,42	25,34	28,26	9,74
3072	13,86	23,56	29,74	10,60	14,78	26,30	29,52	10,58
3584	14,62	25,32	28,44	11,28	15,29	28,85	30,20	11,28
4096	14,92	26,20	28,28	11,89	15,73	31,82	31,04	11,88
4608	15,29	28,97	29,42	12,41	16,02	33,04	31,03	12,41
Örnek Sayısı	Boscolo Par. Olmayan BBA İHO (dB)				Önerilen Par. Olmayan BBA İHO (dB)			
	Anne	1.Fetus	2.Fetus	Sür. Olma. Gürültü	Anne	1.Fetus	2.Fetus	Sür. Olma. Gürültü
512	18,77	18,78	26,58	6,40	7,77	17,10	29,52	6,40
1024	13,95	27,28	31,39	5,66	10,47	21,84	37,52	5,65
1536	16,90	22,51	31,10	7,53	12,79	20,16	28,09	7,52
2048	18,74	21,52	33,14	8,83	16,03	20,88	30,99	8,73
2560	17,52	25,08	34,35	9,83	15,72	21,74	35,75	9,66
3072	19,04	26,72	40,48	10,64	23,80	15,29	37,37	10,63
3584	20,87	31,77	38,32	11,32	16,52	27,39	38,14	11,12
4096	20,80	33,02	38,58	11,91	18,52	30,21	37,37	11,69
4608	22,01	34,03	38,82	12,43	18,75	34,14	37,04	12,32



Şekil 2.42. Sürekli olmayan gürültü varken ikiz hamilelik durumu için, farklı algoritmalar kullanılarak ayrıştırılan anneye ait EKG işaretlerinin İHO değerlerinin farklı örnek sayıları için karşılaştırılması


Tablo 9’da anne EKG işaretlerine ait bulunan İHO değerlerinin örnek sayısına göre değişimi grafiksel olarak Şekil 2.42’de görünmektedir. Önerilen yeni algoritma 512-1536 örnek sayı aralığı hariç en iyi ikinci İHO değerlerini verir iken Boscolo’nun algoritması tüm örnek sayıları için en iyi İHO değerlerini vermektedir. Hızlı BBA ve ÖMBD algoritmaları ise yaklaşık olarak aynı İHO değerlerini vermekte ve örnek sayı değerleri arttıkça İHO değerleri artmaktadır.

Tablo 9’daki birinci fetusa ait EKG işaretlerinin İHO değerlerinin örnek sayısına göre değişim grafiği Şekil 2.43’de görülmektedir. Birinci fetusun EKG’si için, 3584 örnek sayısından sonra önerilen yeni algoritmanın İHO değerleri yaklaşık olarak diğer algoritmalara eşit olmaktadır. 2560 örnek sayısından küçük örnek sayılarında önerilen yeni algoritma ve Hızlı BBA algoritmaları yaklaşık olarak aynı ve en kötü İHO değerlerini vermektedir.




Şekil 2.43. Sürekli olmayan gürültü varken ikiz hamilelik durumu için, farklı algoritmalar kullanılarak ayrıştırılan birinci fetusa ait EKG işaretlerinin İHO değerlerinin farklı örnek sayıları için karşılaştırılması

Tablo 9'daki ikinci fetusa ait EKG işaretlerinin örnek sayısına göre İHO değerlerinin değişimlerinin grafiği Şekil 2.44'de verilmiştir. Önerilen yeni algoritma 512 ve 1024 örnek sayı değerleri için en yüksek İHO değerlerini verirken 1536 örnek sayısından büyük örnek sayı değerleri için Boscolo'nun algoritmasından küçük fakat yaklaşık olarak eşit İHO değerleri vermektedir. ÖMBK ve Hızlı BBA algoritmaları en kötü İHO değerlerini verirken İHO değerleri bir birine çok yakındır.



Şekil 2.44. Sürekli olmayan gürültü varken ikiz hamilelik durumu için, farklı algoritmalar kullanılarak ayrıştırılan ikinci fetusa ait EKG işaretlerinin İHO değerlerinin farklı örnek sayıları için karşılaştırılması

Her iki parametrik olmayan algoritmadan elde edilen sonuçların adım sayılarının örnek sayısına göre karşılaştırılması Şekil 2.45’de görülmektedir. Önerilen yeni algoritma Boscolo’nun algoritmasına göre daha düşük adım sayısında sonuca ulaşmaktadır.




Şekil 2.45. Sürekli olmayan gürültü ve ikiz hamilelik durumu için parametrik olmayan iki algoritmanın adım sayılarının örnek sayılarına bağlı olarak karşılaştırılması

2.4.5. Harici Gürültüye Ait Elde Edilen Sonuçlar


Harici gürültü, kaynak gürültüsünden farklı olarak her bir prob kaydında gözlemlenen birbirlerinden bağımsız gürültü işaretleri olarak modellenmiştir. Ayrıca bu gürültüye işaretin analogdan dijitale dönüşüm esnasında meydana gelen gürültü de eklenir. Harici gürültünün Gauss dağılıma sahip olduğu varsayılır ve her bir prob için farklıdır. Bir probda gözlemlenen gürültü diğer probda gözlemlenmemektedir. Günümüzde 16 bitlik elektronik kayıt sistemlerinde işaret gürültü oranı (İGO) yaklaşık 95 dB'dir. Bu İGO oldukça yüksek bir orandır ve bu gürültü yok varsayılabilir fakat bu tür gürültü var iken BBA algoritmaları ile işaretleri gürültüden ayırtmak mümkün değildir. Bunun ana nedeni bir işaretin BBA

algoritması ile ayrıştırılabilmesi için o işaretin farklı genliklerde tüm prob kayıtlarında gözlemlenebilmesi gerekmektedir. Harici gürültüler ise her bir probda farklı morfolojide ve birbirlerinden bağımsız olarak meydana gelirler. Fakat bu tür işaretlerin varlığında BBA algoritmalarının performansı test edilebilir. Şekil 2.46'da 30 dB İGO değeri için yapay prob işaretleri görülmektedir. Yapay prob işaretlerindeki gürültü birbirinden bağımsız olarak gözlemlenebilmektedir.

Şekil 2.46'daki yapay prob işaretlerine Boscolo'nun parametrik olmayan BBA algoritması uygulanarak elde edilen sonuçlar Şekil 2.47'de verilmiştir. Şekillerden de görüleceği üzere her iki EKG işareti başarıyla ayrıştırılmıştır fakat problemlerdeki harici gürültü ayrıştırılamamıştır. Boscolo'nun algoritması sonucu elde edilen anneye ait EKG işaretinin İHO değeri 27,34 dB iken fetusa ait EKG işaretinin İHO değeri 16,41 dB olarak hesaplanmıştır.




Şekil 2.46. Harici gürültü eklenmiş yapay EKG prob işaretleri



Şekil 2.47. Harici gürültü için Boscolo'nun sonuçları

Benzer şekilde önerilen yeni algoritmanın Şekil 2.46'deki yapay prob işaretlerine uygulanması ile ayrıştırılan EKG işaretleri Şekil 2.48'de gösterilmiştir. Boscolo'nun algoritmasında olduğu gibi önerilen yeni algoritma EKG işaretlerini ayrıştırmada başarılı olmuştur fakat harici gürültüleri ayrıştırmada başarılı olamamıştır. Önerilen yeni algoritma sonucu elde edilen anneye ait EKG işareti İHO değeri 28,19 dB iken , fetusa ait İHO değeri 17,17 dB olarak hesaplanmıştır.




Şekil 2.48. Harici gürültü için önerilen parametrik olmayan BBA algoritma sonuçları

Parametrik olmayan algoritmaların ve iki güncel algoritmanın İHO değerlerinin örnek sayı değerleri ile değişimi Tablo 10'da verilmiştir. Her bir algoritma, 100 defa rastgele karıştırılmış ve karıştırıldıktan sonra her bir karışım sinyaline harici rastgele Gauss dağılıma sahip gürültü eklenmiş sinyal üzerine uygulanmıştır ve kaynak sinyaller ayrıştırılmıştır. Ayrıştırılan işaretlerin İHO değerlerinin ortalaması alınarak Tablo 10'daki değerler elde edilmiştir.

Tablo 10. Harici gürültülü durumda, BBA algoritmaların İHO değerlerinin örnek sayısı değerleri ile değişimi


Örnek Sayısı	Hızlı BBA İHO (dB)		ÖMBK İHO (dB)		Boscolo'nun Par. Olmayan BBA İHO (dB)		Önerilen Par. Olmayan BBA İHO (dB)	
	Anne	Fetus	Anne	Fetus	Anne	Fetus	Anne	Fetus
512	9,70	4,44	16,11	5,54	9,70	-1,57	11,25	6,10
1024	12,10	6,41	14,57	9,06	12,28	5,79	10,34	7,08
1536	12,49	6,97	12,10	6,16	12,59	6,72	11,93	6,23
2048	11,83	6,22	12,58	6,31	12,57	5,85	12,49	6,86
2560	12,59	6,39	11,89	6,14	12,15	6,62	11,25	6,47
3072	12,38	6,54	12,34	6,44	12,63	6,22	11,64	6,58
3584	12,83	6,50	12,80	5,16	12,83	6,46	11,22	6,78
4096	12,44	6,29	12,40	6,18	12,45	6,13	12,08	6,90
4608	12,11	7,13	12,47	6,24	13,16	6,08	11,12	6,20

Tablo 10'da uygulanan algoritmalar sonucu ayrıştırılan anneye ait EKG işaretinin, İHO değerlerinin örnek sayı değerleri ile değişimi Şekil 2.49'da verilmiştir. Şekilden görüleceği üzere tüm algoritmalar yaklaşık olarak aynı İHO değerlerini vermektedir. Sadece 512 ve 1024 örnek sayıları için ÖMBK algoritması diğer algoritmalara göre daha yüksek İHO değerleri vermektedir.




Şekil 2.49. Anne EKG işaretinin İHO değerlerinin örnek sayısı değerlerine göre değişimi

Tablo 10’da ki fetusa ait EKG işaretlerinin İHO değerlerinin, örnek sayısı değerlerine göre değişimi Şekil 2.50’de gösterilmiştir. Anneye ait İHO değerlerinde olduğu gibi fetusun EKG işaretinin İHO değerleride yaklaşık olarak eşittirler. Boscolo’nun algoritması ilk 512 örnek sayısı için diğer algoritmalarından düşük İHO değeri vermiştir.



Şekil 2.50. Fetus EKG işaretinin İHO değerlerinin örnek sayısı değerlerine göre değişimi


Algoritmaların performanslarının adım sayısı bakımından karşılaştırılması Şekil 2.51’de gösterilmiştir. Diğer sonuçlarda olduğu gibi önerilen yeni algoritma adım sayısı bakımından Boscolo’nun algoritmasına göre daha düşük adım sayısında işaretleri ayırtmaktadır.



Şekil 2.51. Harici gürültü için parametrik olmayan iki algoritmanın adım sayılarının örnek sayılarına bağlı olarak karşılaştırılması


2.5. Elektromiyografik İşaretler ve Taban Seviye Kayması

EKG işaretlerinde elektromiyografik işaretler (kas işaretleri, EMG) ve nefes alıp vermeden dolayı meydana gelen taban seviye kayması en fazla görünen gürültü kaynaklarıdır. Bu bölümde BBA algoritmalarının performanslarını taban seviye kayması ve EMG işaretleri varlığında test edilecektir. Bunun için ilk olarak EMG işareti gerçek kas işaretlerinden elde edilmiş ve EKG işareti için uygun genlik seviyesine getirilmiştir. İkinci olarak taban seviye kayması düşük frekanslı sinüs işareti ile modellenmiştir. Modelleme sonucu elde edilen kaynak işaretleri Şekil 2.52'deki gibi elde edilmiştir.



Şekil 2.52. Taban seviye kayması ve EMG işaretleri için kaynak işaretleri

Şekil 2.52'deki kaynak işaretlerin (2.18) denklemi ile karıştırılmasıyla elde edilen yapay prob işaretleri Şekil 2.53'deki gibi elde edilmiştir. Şekil 2.53'de her bir probda kaynak işaretleri farklı genlikte gözlemlenebilmektedir. Tüm prob kayıtlarında anne EKG işareti gözlemlenebilirken fetal EKG işareti birinci prob kayıtlarında tam olarak gözlemlenebilmektedir. EMG işareti ise tüm prob kayıtlarında gözlemlenebilirken taban seviye kayması birinci ve dördüncü prob kayıtlarında daha fark edilebilir bir şekilde gözlemlenebilmektedir.




Şekil 2.53. Taban seviye kayması ve EMG işaretleri için yapay olarak elde edilmiş prob işaretleri

Şekil 2.53 karışım matrisine bağlı olarak farklı şekillerde elde edilebilir. Algoritmaların performanslarını karşılaştırmak için kaynak işaretleri 100 farklı karışım matrisiyle karıştırılmış ve algoritmalar bu karışmış yapay prob sinyalleri üzerine uygulanmıştır. Ayrıca bu işlem örnek sayıları değiştirilerek tekrarlanmıştır ve algoritma sonuçları İHO değerleri olarak Tablo 11’de verilmiştir. Yapılan çalışmalarda tüm algoritmalar EMG işaretlerini, taban seviye kaymasını anne ve fetusun EKG işaretlerinden başarıyla ayırtmışlardır.

Tablo 11. Taban seviye kayması ve EMG işaretleri için BBA algoritma sonuçlarının İHO değerlerinin farklı örnek sayılarına göre değişimi


Örnek Sayısı	Hızlı BBA İHO (dB)		ÖMBK İHO (dB)		Boscolo'nun Par. Olmayan BBA İHO (dB)		Önerilen Par. Olmayan BBA İHO (dB)	
	Anne	Fetus	Anne	Fetus	Anne	Fetus	Anne	Fetus
512	21,69	27,23	15,97	21,73	18,68	32,47	18,89	28,51
1024	27,57	31,03	26,63	30,03	29,52	33,87	30,97	31,01
1536	25,89	24,91	24,99	26,41	24,23	26,19	24,26	26,28
2048	21,48	26,02	22,15	28,30	26,18	27,04	26,15	26,74
2560	30,61	23,42	29,98	25,21	34,67	25,66	33,47	24,95
3072	29,70	26,55	32,68	28,97	33,38	28,07	32,63	27,60
3584	26,61	27,06	27,89	28,89	32,62	29,36	31,81	28,86
4096	28,62	29,22	31,81	31,32	34,01	31,70	33,20	31,73
4608	28,73	29,28	27,97	30,58	32,60	32,65	31,82	31,28

Tablo 11'de elde edilen anneye ait İHO değerlerinin örnek sayısına göre değişim grafiği Şekil 2.54'de gösterilmiştir. Şekilden görüleceği üzere parametrik olmayan algoritmalar yaklaşık aynı İHO değerlerini sahipken diğer algoritmalar daha düşük İHO değerlerine sahiptirler ve parametrik olmayan algoritmaların İHO değerleri örnek sayısı arttıkça artış göstermektedir. Tüm algoritma sonuçları 512, 1536 ve 2048 örnek sayıları için İHO değerlerinde düşüş göstermektedir.




Şekil 2.54. Taban seviye kayması ve EMG işaretleri için farklı BBA algoritmaları kullanılarak ayrıştırılan anneye ait EKG işaretinin İHO değerlerinin farklı örnek sayılarına göre değişimi

Fetusa ait İHO değerlerinin örnek sayısına göre değişim grafiği Şekil 2.55’de gösterilmiştir. İlk 512 ve 1024 örnek sayıları için en iyi sonucu Boscolo’nun algoritması vermektedir. Fetus için en düşük İHO değerlerine Hızlı BBA algoritması sahiptir. Diğer algoritmalar 1536-2560 örnek sayısı arası hariç birbirlerine yakın İHO değerlerini almaktadırlar. Tüm algoritmaların İHO değerleri 3072 örnek sayısından sonra artış göstermektedir.




Şekil 2.55. Taban seviye kayması ve EMG işaretleri için farklı BBA algoritmaları kullanılarak ayrıştırılan fetusa ait EKG işaretinin İHO değerlerinin farklı örnek sayılarına göre değişimi

Boscolo'nun algoritmasının 2560 örnek sayısı için önerilen algoritmanın farklı entropi indeksleri (q) ile adım sayısı bakımından karşılaştırılması Şekil 2.56'da gösterilmiştir. Şekil 2.56 adım sayılarının kutu grafiği olarak adlandırılmaktadır. Kutu grafiklerinde kırmızı çizgi ortalamayı (0,5 quartili), kırmızı çizgiye kadar olan ilk kutu 0,25'inci quartili, kırmızı çizginin üstündeki kutu ise 0,75'inci quartili temsil etmektedir. Kutuların üstündeki ve altındaki siyah düz çizgiler komşu değerleri kırmızı artı işaretleri ise aşırı büyük değerleri temsil etmektedir. Kutu grafikleri incelenecek olursa, önerilen algoritmanın entropi indeksi arttıkça ortalama adım sayısı olarak daha küçük adım sayısında sonuca ulaştığı görülmektedir. Ayrıca önerilen algoritma tüm entropi indeksleri için Boscolo'nun algoritmasından küçük adım sayısında sonuca ulaşmaktadır.




Şekil 2.56. Farklı entropi indeksleri için önerilen algoritmanın ve Boscolo'nun algoritmasının adım sayısı bakımından karşılaştırılması

Şekil 2.57'de parametrik olmayan algoritmaların 2560 örnek sayısı için ortalama işlem zamanları saniye cinsinden gösterilmektedir. Boscolo'nun algoritmasının önerilen algoritmaya göre daha az zamanda işaretleri ayrıştırdığı görülmektedir. Entropi indeksi arttıkça önerilen algoritmanın daha az zamanda işaretleri ayrıştırdığı görülmektedir. Fakat aradaki zaman farkı saliseler ile ifade edilmektedir.




Şekil 2.57. Farklı entropi indeksleri için önerilen algoritmanın ve Boscolo'nun algoritmasının işlem zamanı bakımından karşılaştırılması

Anne EKG işareti için, 2560 örnek sayısında önerilen algoritmanın farklı entropi indekslerinde yapılan hatanın karelerinin ortalama değerlerinin adım sayısının göre değişim grafiği Şekil 2.58'de gösterilmiştir. Şekil 2.58, 100 karışmış sinyal üzerine algoritmaların 100 kez uygulanması ile elde edilen hataların karelerinin toplamının ortalaması alınarak elde edilmiştir. Hataların karelerinin toplamı $E\{(y-s)^2\}$ formülü ile hesaplanmaktadır. Boscolo'nun algoritmasının hataların kareleri toplamının ortalama değeri önerilen algoritmanın tüm entropi indeks değerlerine göre daha az adım sayısında minimum değere erişmektedir. Önerilen algoritma ise entropi indeks değeri arttıkça hatanın minimum değere erişmesi daha fazla adım sayısında olmaktadır.



Şekil 2.58. Anne EKG'si için önerilen algoritmanın farklı entropi indekslerinin ve Boscolo'nun algoritmasının hatalarının karelerinin toplamının ortalama değerlerinin adım sayısına göre değişimi


Fetus EKG işareti için, 2560 örnek sayısında önerilen algoritmanın farklı entropi indekslerinde yapılan hatanın karelerinin ortalama değerlerinin adım sayısının göre değişim grafiği Şekil 2.59'da gösterilmiştir. Anne EKG'sinde olduğu gibi fetus EKG'side entropi indeksi arttıkça hatanın karelerinin toplamının ortalama değeri minimum değere daha fazla adım sayısında ulaşmaktadır. Boscolo'nun algoritması ise daha az adım sayısında minimum değere erişmektedir.



Şekil 2.59. Fetus EKG'si için önerilen algoritmanın farklı entropi indekslerinin ve Boscolo'nun algoritmasının hatalarının karelerinin toplamının ortalama değerlerinin adım sayısına göre değişimi


2.5. Gerçek EKG İşaretlerine Ait Sonuçlar

Bu bölümde parametrik olmayan iki algoritmanın gerçek EKG kayıtları üzerine uygulanması ve sonuçları incelenecektir. Bunun için gerçek EKG işaretleri L. De Lathauwer'ın web sitesinden temin edilmiş ve onun izniyle kullanılmıştır. Uygulama için 2516 tane örnek alınmış ve sadece anne ve fetusun EKG işaretlerinin her ikisini içeren dört EKG kayıtları seçilmiştir. Seçilen dört gerçek EKG prob kayıtları Şekil 2.60'da gösterilmiştir.




Şekil 2.60. Gerçek EKG işaretleri

Şekil 2.60'daki gerçek EKG işaretlerine Boscolo'nun algoritması uygulandığında, elde edilen sonuçlar Şekil 2.61'de gösterilmiştir. Şekil 2.61'de ilk grafikte annenin ve fetusun EKG işaretleri aynı anda görünmekle beraber annenin EKG işaretinin genliği fetusa göre çok yüksektir. İkinci grafikte ise taban çizgisi kayması ve fetusun EKG işareti aynı anda gözlemlenebilmektedir. Üçüncü grafikte ise fetusun EKG işareti ve taban çizgi dolanması gözlemlenmektedir. Dördüncü grafikte ise annenin EKG işareti gözlemlenmektedir. Sonuç olarak Boscolo'nun algoritması anne ve fetusa ait EKG işaretlerini başarı ile ayırtmıştır.



Şekil 2.61. Boscolo'nun algoritmasının gerçek EKG işareti sonuçları

Şekil 2.60'daki gerçek EKG işaretlerine önerilen yeni parametrik olmayan algoritmanın uygulanması ile elde edilen sonuçlar Şekil 2.62'de verilmiştir. Şekil 2.62'de ilk grafikte ayrıştırılmış fetusa ait gerçek işaretleri görünmekte iken ikinci grafikte anneye ait EKG işareti gözlemlenmektedir. Üçüncü grafikte, annenin EKG işareti, gürültülü gözlemlenmektedir. Dördüncü grafikte ise fetusa ait EKG işareti ile temel çizgi dolanması birlikte gözlemlenmektedir. Önerilen yeni algoritma da gerçek EKG işaretlerini başarılı bir şekilde ayrıştırmayı başarmıştır. Fakat iki parametrik olmayan algoritma arasında gözle görülür bir fark olmadığı için gerçek EKG işaretleri üzerinde performans karşılaştırması yapılamamaktadır.



Şekil 2.62. Önerilen yeni algoritmanın gerçek EKG işareti sonuçları

3. SONUÇLAR

Bu çalışmada; BBA algoritmalarının, anne EKG'si ve FEKG işaretlerini ayırtmadaki performansları incelenmiştir. Yapılan performans analiz işlemlerinde, gürültü yok ve var iken tek ve ikiz hamilelik durumu için ayırtılan işaretlerin ortalama İHO değerlerinin ve algoritmaların ortalama adım sayılarının örnek sayısına göre değişimleri incelenmiştir.

İlk yapılan çalışma Geometrik BBA algoritması üzerinde yapılmıştır. Geometrik BBA algoritması görsel açıdan bir karışım işleminin nasıl meydana geldiği, ayırtma sonucunda elde edilen işaretlerin birbirlerine göre durumunu ve algoritma sonucunun doğru olup olmadığını gösteren en iyi yöntemlerden biridir. Şekil 2.8 ve 2.9'da görüldüğü üzere Geometrik BBA algoritması anneye ait EKG işaretini tam olarak diğer işaretlerden ayırtamamış iken fetusa ait EKG işaretini başarıyla ayırtabilmiştir. Geometrik BBA algoritmasının sonuçları diğer algoritmalara göre kötü olduğundan dolayı diğer algoritmalar ile ayırtma performansı karşılaştırılmamıştır.

Gürültü yok iken, tek hamilelik durumu için yapılan çalışmada en iyi sonuçları 512 ve 1024 örnek sayıları için parametrik olmayan algoritmalar vermektedir (Şekil 2.14, Şekil 2.15). Anneye ait EKG işareti için 1536 ve 2560 örnek sayıları hariç algoritma sonuçları birbirlerine yakın İHO değerlerine sahip olmaktadır. Fetusa ait EKG işareti için ise 1536 örnek sayısından sonra en iyi İHO değerlerini ÖMBK algoritması almaktadır. Diğer algoritmalar ise birbirlerine yakın İHO değerlerini almaktadır.

Gürültü yok iken ikiz hamilelik durumu için yapılan çalışmada anneye ve 2. fetusa ait EKG işaretlerinde en iyi sonuçları parametrik olmayan algoritma vermektedir (Şekil 2.20, Şekil 2.22). 1. fetusa ait EKG işareti için ise diğer algoritmalar birbirlerine yakın İHO değerlerini alırken önerilen yeni algoritma 1536-3584 örnek sayıları arası düşük İHO değerleri almaktadır. Gürültüsüz tek hamilelik durumunda olduğu gibi 512 ve 1024 örnek sayıları için en iyi İHO değerini önerilen yeni algoritma almaktadır.

Bir sonraki adım olarak çalışmalarımızda işaretlere gürültü eklenmiştir. İlk eklenen gürültü kaynak gürültüsü olduğu varsayımı yapıp Gauss dağılıma sahip gürültü eklenmiştir. Gauss gürültü var iken, tek hamilelik durumunda fetusa ait EKG işaretlerinin İHO değerleri için önerilen yeni algoritma ve Boscolo'nun algoritması en iyi sonuçları vermektedir (Şekil 2.28, Şekil 2.29). Anneye ait EKG işareti için Boscolo'nun algoritması önerilen algoritmaya göre daha yüksek İHO değerleri alırken fetusa ait EKG işareti için birkaç örnek sayısı hariç

birbirlerine yakın İHO değerleri almaktadır. ÖMBK ve Hızlı BBA algoritmaları ise daha düşük olmasına karşılık yakın İHO değerleri almaktadır.

Gauss kaynak gürültüsü varken, ikiz hamilelik durumu için elde edilen sonuçla bakılacak olur ise elde edilen İHO değerleri gürültüsüz duruma göre daha düşük olmasına rağmen gürültüsüz ikiz hamilelik durumu ile yaklaşık aynı sonuçları vermektedir (Şekil 2.31, Şekil 2.32 ve Şekil 2.33).

Gürültü kaynağı olarak sürekli olmayan gürültü var iken, tek hamilelik durumu için yapılan çalışmalarda anneye ait EKG işaretinde örnek sayısına göre en iyi İHO değerlerine parametrik olmayan algoritmalar sahiptir (Şekil 2.39). ÖMBK ve Hızlı BBA algoritmaları en kötü olmasına rağmen birbirlerine yakın İHO değerleri alırlar. Fetusa ait EKG işaretinde en iyi İHO değerlerini Boscolo'nun algoritması almaktadır. İkinci en iyi sonuçları 2560 örnekten sonra önerilen yeni algoritma almaktadır (Şekil 2.40).

Sürekli olmayan gürültü kaynağı var iken, ikiz hamilelik durumu için yapılan çalışmalarda algoritma sonuçlarına bakıldığında, 1. fetusa ve 2. fetusa ait EKG işaretleri için örnek sayısına göre en iyi İHO değerlerine parametrik olmayan algoritmalar sahiptir (Şekil 2.43, Şekil 2.44), Anneye ait EKG işaretindeyse 2048 örnek sayısından sonra önerilen yeni algoritma en iyi ikinci İHO değerlerine sahiptir (Şekil 2.42). ÖMBK ve Hızlı BBA algoritmaları en kötü İHO değerlerini almaktadır.

Her prob için harici gürültü kaynağı varsayılarak, örnek sayısına göre İHO değerlerinin değişimine bakıldığında, tüm algoritmalar birbirlerine yakın İHO değerlerini almaktadır.

EKG kayıtlarına, EMG işaretleri ve taban seviye kayması karışması durumunda tüm algoritmaların karışım işaretlerini ayrıştırabildiği fakat anne EKG'si için en iyi İHO değerlerine parametrik olmayan algoritmaların sahip olduğu (Şekil 2.54), fetus EKG'si için Hızlı BBA algoritması hariç diğer algoritmaların birbirlerine yakın İHO değerlerine sahip oldukları gözlemlenmiştir (Şekil 2.55). Ek olarak EMG işaretleri ve taban seviye kayması karışması için parametrik olmayan Boscolo'nun algoritması ve önerilen yeni algoritma farklı entropi indeksleri için adım sayıları bakımından karşılaştırılmış (Şekil 2.56) ve önerilen yeni algoritmanın entropi indeks değeri büyüdükçe algoritmaların ortalama adım sayı değerlerinin azaldığı görülmektedir. Buna ek olarak algoritmaların işlem zamanlarına saniye olarak bakıldığında (Şekil 2.57), Boscolo'nun algoritmasının daha kısa zamanda işlemleri sonlandırırken önerilen algoritmanın entropi indeksi arttıkça işlem zamanının azaldığı fakat bu azalmanın salise değerlerinde olduğu görülmektedir. Entropi indeks değeri arttıkça algoritmaların çalışma zamanı azaldığından dolayı ve büyük entropi indeks değerleri için

sonuçların Boscolo'nun algoritması sonuçları ile farkının karşılaştırılabilmesi için bu tezde entropi indeks değeri olarak 1,5 seçilmiştir. Bu işaretler üzerine yapılan bir diğer çalışmada ise adım sayısına bağlı olarak ortalama hata değişimi gözlemlenmiştir (Şekil 2.58, Şekil 2.59). Anne ve fetusa ait EKG işareti sonuçlarından, Boscolo'nun algoritmasının ortalama hatasının daha küçük adım sayısında minimum değere ulaşırken önerilen algorithmada entropi indeksi arttıkça ortalama hatanın daha büyük adım sayısında minimum değere ulaştığı görülmektedir.

Son olarak sadece parametrik olmayan algoritmalar, gerçek EKG işaretlerine uygulandığında; her iki algoritma da anne ve fetusa ait EKG işaretlerini ayırtılabildiği görülmektedir (Şekil 2.61, Şekil 2.62).

Bu çalışmaların sonucunda, gürültü karışımı durumunda klasik algoritmalar olan Hızlı BBA ve ÖMBK yerine parametrik olmayan algoritmaların FEKG işaretlerini ayırtırmada kullanılabileceği gösterilmiştir. İki den fazla hamilelik durumu için algoritmalar fetuslara ait EKG işaretlerini ayırtırmaya iken, ayırtılan işaretlerin İHO değerlerinde düşmeler olduğu gözlemlenmiştir. EKG işaretlerine karışım yapan uzun süreli gürültülerin daha iyi ayırtılırken, kısa süreli gürültülerin ayırtılmasının daha zor yapıldığı gözlemlenmiştir. Diğer önemli bir problem, örnek sayısının değişiminin algoritma performanslarını etkiliyor olmasıdır. Bunun nedeni, amaç fonksiyonu olarak entropi yaklaşımı kullanan algoritmalarda örnek sayısına bağlı olarak işaretlerin entropi değerlerinin değişmesi ve algoritmanın gerçek değere yakınsamasını etkilemesidir. Amaç fonksiyon olarak öz değer matrisleri kullanan algoritmalarda ise öz değer matrislerinin örnek boyuna bağlı olarak öz değerlerinin değişmesidir.

Sonuçlara genel olarak bakıldığında, parametrik olmayan algoritmalar işaretlerin olasılık yoğunluk fonksiyonlarını doğru olarak kestirdiklerinden dolayı BBA algoritmalarında daha doğru sonuç vermektedirler. Önerilen yeni algoritma bir çok durum için Boscolo'nun algoritmasından ortalama İHO değeri olarak düşük sonuç vermekte fakat yapılan tüm çalışmalarda adım sayısı olarak önerilen yeni algoritma daha az adım sayısına ihtiyaç duymaktadır. Buna rağmen birleşik olasılık yoğunluk fonksiyonunun Tsallis entropisini hesaplarken karşılaşılan güçlük algoritmanın genel bir EKG ayırtıcı algoritma olarak kullanılabilesini güçleştirmektedir. Bundan dolayı içerisinde birleşik olasılık yoğunluk fonksiyonu hesaplanması adımı bulunan amaç fonksiyonları tercih edilmemeli veya Boscolo'nun algoritmasında olduğu gibi lineer dönüşüm ile bu hesaplama işleminden kaçınılmalıdır.

4. ÖNERİLER

Bu tezde, FEKG işaretini daha doğru bir şekilde ayrıştırabilmek için Tsallis'in yapay toplamsallık özelliğini amaç fonksiyon olarak kullanan yeni bir parametrik olmayan algoritma önerilmiştir ve Boscolo'nun parametrik olmayan algoritması ilk kez EKG işaretleri üzerinde kullanılmıştır. Ek olarak parametrik olmayan algoritmaların performansları bilinen BBA algoritma performansları ile karşılaştırılmıştır.

Bununla birlikte, elde edilen başarımlar için yapılan çalışmalar gerçek zaman uygulaması üzerinde çalışılmadı. Yapılan çalışmalar kaydedilmiş EKG işaretleri üzerine uygulanabilir ve elde edilen sonuçlar farklı örnek sayıları için tekrarlanır ise daha iyi sonuçlar elde edilebilir.

Önerilen yeni algoritmanın performansını etkileyen en önemli problem birleşik olasılık yoğunluk fonksiyonunun Tsallis entropisinin hesaplanmasıdır. Bu parametre algoritma performansını önemli ölçüde etkilemektedir. Eğer uygun seçilmez ise algoritma bir EKG işaretini yüksek İHO değeri ile ayrıştırır iken diğer EKG işaretinin İHO değerini düşük olarak ayırtmaktadır. Bunun çözümü için, adaptif algoritmalarda olduğu gibi değişen bir unutmama faktörü ile sonuçlar iyileştirilebilir.

Tezde geometrik BBA algoritmasının sonuçları kötü çıktığından dolayı diğer algoritmalar ile karşılaştırılması yapılmamıştır fakat Geometrik BBA algoritması BBA algoritmaları üzerine çalışmaya başlayanların öğrenebileceği anlaşılması ve uygulanması en kolay algoritmadır.

5. KAYNAKLAR

1. Khawaja, A., Automatic ECG Analysis Using Principal Component Analysis and Wavelet Transformation, 2004.
2. Jutten, C. ve Herault, J., Blind Separation of Sources, Part I: An Adaptive Algorithm Based on Neuromimetic Architecture, Signal Processing, 24, (1991) 1-10.
3. Common, P., Independent Component Analysis, A New Concept?, Signal Processing, 36, 3 (1994) 287-314.
4. Malmivuo, J. ve Plonsey, R., Bioelectromagnetism, Oxford University Press, 1995.
5. Hurst, J. W., Naming of The Waves in the ECG, with A Brief Account of Their Genesis, Circulation, 98, 18 (1998) 1937-1942.
6. Malik, M., Heart Rate Variability: Standarts of Measurements, Physiological Interpretation, and Clinical Use, Circulation, 93, (1996) 1043-1065.
7. Malik, M., Camm, A. J., Heart Rate Variability, Armonk, NY: Futura Publishing, 1995.
8. Stinstra, J., Reliability of the fetal magnetocardiogram, Ph.D. dissertation, University of Twente, Enschede, The Netherlands, 2001.
9. Physiology, Cardiovascular Consultants, <http://www.cardioconsult.com/Physiology/>. 15 Şubat 2009.
10. Van Gaijn ve H. P., Copray, F. J. A., A Critical Appraisal of Fetal Surveillance, Amsterdam: Excerpta Medica, 1994.
11. Lewis, M. J., Review of Electromagnetic Source Investigations of The Fetal Heart, Med. Eng. Phys., 25, (2003) 801-810.
12. Crowe, J. A., Antenatal Assesment Using the FECG Obtained via Abdominal Electrodes, J. Perinat. Med., 24, (1996) 43-53.
13. Lathauwer, L. De., Moor, B. De. ve Vandewalle, J., Independent Component Analysis Based on Higher-Order Statistics Only, In Proc. IEEE SP Workshop on Stat Signal Array Processing, (1996) 356-359.
14. Friesen, G. M., Jannett, T. C., Jadallah, M., A., Yates, S. L., Quint, S. R. ve Nagle, H. T., A Comparison of The Noise Sensitivity of Nine QRS Detection Algorithms, IEEE Trans. Biomed. Eng., 37, (1990) 85-98.

15. Widrow, B. ve Walach, E., *Adaptive Inverse Control*, Prentice Hall, 1996.
16. Bommel, J. H. V. ve Van Der Weide, H., Detection Procedure to Represent The Foetal Heart Rate and Electrocardiogram, IEEE Trans. Biomed. Eng., 13, (1966) 175-182.
17. Widrow, B., Glover, J. R., McCool, J., Kaunitz, J., Williams, C. S., Hearn, R. H., Zeidler, J. R., Dong, E. ve Goodlin, R., Adaptive Noise Cancelling: Principles and Applications Proc., IEEE, 62, (1975) 1692-1716.
18. Meijer, P. B. W. J., A New Technique for The Suppression of The MECG, IEEE Trans., Biomed. Eng., 28, (1981) 248-353.
19. Abboud, S. ve Sadeh, D., Spectral Analysis of The Fetal Electrocardiogram, Comput. Biol. Med., 19, (1989) 409-415.
20. Cerutti, S., Baselli, G., Civardi, S., Ferrazzi, E., Marconi, A. M., Pagani, M. ve Pardi, G., Variability Analysis of Fetal Heart Rate Signals as Obtained From Abdoinal Electrocardiographic Recordings, J. Perinat. Med., 14, (1986) 445-452.
21. Nandi, A. K. ve Zarzoso, V., Fourth-Order Cumulant Based Blind Source Separation, IEEE Signal Processing Letters, 3, 12 (1996) 312-314.
22. Choi, S., Chichocki, A. ve Amari, S., Fetal Electrocardiogram Data Anaylsis via Flexible Independent Component Analysis, In The 4th Asia Pacific Conference on Medical&Biological Engineering, 1999, Korea.
23. Choi, S., Chichocki, A. ve Amari, S., Flexible Independent Component Analysis, Journal of VLSISignal Processing, 26, 1 (2000) 25-38.
24. Taylor, M. J., Smith, M. J., Thomas, M., Green, A. R., Cheng, F., Oseku-Afful, S., Wee, L. Y., Fisk, N. M. ve Gardiner, H. M., Non-Invasive Fetal Electrocardiography in Singleton and Multiple Pregnancies, Br. J. Obstet. Gynaecol., 110, (2003) 668-678.
25. Taylor, M. J., Thomas, M., Smith, M. J., Oseku-Afful, S., Fisk, N. M., Green, A. R., Paterson-Brown S. ve Gardiner, H. M., Non-Invasive Intrapartum Fetal ECG: Preliminary Report, Br. J. Obstet. Gynaecol., 112, (2005) 1016-21.
26. Zarzoso, V. ve Nandi, A. K., Noninvasive Fetal Electrocardiogram Extraction: Blind Separation Versus Adaptive Noise Cancellation, IEEE Trans. Biomed. Eng., 48, (2001) 12-18.
27. Comani, S., Mantini, D., Lagatta, A., Esposito, F., Luzio, S. D. ve Romani, G., Time Course Reconstruction of Fetal Cardiac Signals From fMCG: Independent Component Analysis Versus Adaptive Maternal Beat Substraction, Phsiol. Meas. 25, (2004) 1305-1321.

28. Cichocki, A. ve Amari, S., Adaptive Blind Signal and Image Processing, John Wiley-Sons Ltd., 2002.
29. Dössel, O., Inverse Problem of Electro- and Magnetocardiography: Review and Recent Progress, International Journal of Bioelectromagnetism, 2, 2 (2000).
30. Van Oosterom, A., Beyond The Dipole; Modeling The Genesis of The Electrocardiogram, in 100 Years Einthoven, The Einthoven Foundation, Leiden, The Netherlands, 2002, 7-15.
31. Clifford, G. D. ve Azuaje, F. ve McSharry, P. E., Advanced Methods and Tools for ECG Data Analysis, Artech House, 2006.
32. Pan, J. ve Tompkins, W. J., A Real Time QRS Detection Algorithm, IEEE Trans. Biomed. Eng., 32, 3 (1985) 220-236.
33. Kaplan, D. T., Simultaneous QRS Detection and Feature Extraction Using Simple Matched Filter Basis Functions, IEEE Computer Society Press, (1991) 113-116.
34. Davey, P., A New Physiological method for Heart Rate Correction of the QT Interval, Heart, 82, (1999) 183-186.
35. Moody, G. B., Mark, R., G., Zoccola, A. ve Mantero, S., Derivation of Respiratory Signals From Multi-Lead ECGs, Computers in Cardiology, 12, (1985) 113-116.
36. Moody, G. B., Mark, R. G., Bump, M. A., Weimstein, J. S., Berman, A. D., Mietus, J. E. ve Goldberger, A. L., Clinical Validation of The ECG Derived Respiration (edr) Technique, Computers in Cardiology, 13, (1986) 507-510.
37. McSharry, P. E., Clifford, G., Tarassenko, L. ve Smith, L. A., A Dynamical model for Generating Synthetic Electrocardiogram Signals, IEEE Trans. Biomed. Eng., 50, 3 (2003) 289-294.
38. Sameni, R., Noninvasive Extraction and Processing of Fetal Cardiac Signals from an Array of Maternal Abdominal Recordings, PhD Thesis, Sharif University of Technology, Tehran, 2008.
39. Clifford, G. D., A Novel Framework for Signal Representation and Source separation; Applications to Filtering and Segmentation of Biosignals, Journal of Biological Systems, 14, 2 (2006) 169-183.
40. Sameni, R., Clifford, G. D., Jutten, C., ve Shamsollahi, M. B., Multichannel ECG and Noise Modeling: Application to Maternal and Fetal ECG Signals, EURASIP Journal on Applied Signal Processing, (2007) 94-94.
41. Scott, D. W., Multivariate Density Estimation, Wiley-Interscience, 1992.
42. Martinez, W. L. ve Martinez, A. R., Computational Statistics Handbook with Matlab, Chapman&Hall/CRC, 2000.

43. Hartley, R. V. L., Transmission of Information, Bell System Technical Journal, 7, (1928) 335.
44. Shannon, C. E., A Mathematical Theory of Communication, Bell System Technical Journal, 27, (1948) 339.
45. Hyvarinen, A., Karhunen, J. ve Oja , E., Independent Component Analysis, John Wiley & Sons, Inc., 2001.
46. Renyi, A., Some Fundamental Questions of Information Theory, MTA III. Oszt. Közl., 10, (1960) 251-282.
47. Hardy, G. H. ve Littlewood, J. E., Inequalities. Cambridge, 1934.
48. Tsallis, C., Genealized Entropy-Based Criterion for Consistent Testing, Physical Review E, 58, (1998) 1442-1445.
49. Kullback , S. ve Leibler, R. A., On Information and Sufficiency, Ann. Math. Stat., 22, (1951) 79-86.
50. Bell, A. J. ve Sejnowski, T. J., An Information Maximization Approach to Blind Separation and Blind Deconvolution, Neural Computation, 7, (1995) 1129-1159.
51. Amari, S., Natural Gradient Works Efficiently in Learning, Neural Computation, 10, 2 (1998) 251–276.
52. Hyvarinen, A., Fast and Robust Fixed-Point Algorithms for Independent Components Analysis, IEEE Trans on Neural Networks, 10, (1999) 626-634.
53. Puntonet, C. G. ve Prieto, A., An Adaptive Geometrical Procedure for Blind Separation of Sources, Neural Processing Letters, 2, (1995).
54. Theis, F. J., Jung, A., Lang, E. W. ve Puntonet, C.G., A Theoretic Model for Geometric ICA, Proc. of ICA 2001, December 2001, San Diego, 349-354.
55. Douglas, S. C., Blind Source Separation and Independent Component Analysis: A Crossroads of Tools and Ideas, 4th Int. Semp. On ICA and BSS, April 2003, Nara, 1-10.
56. Amari, S. ve Cichocki, A., Adaptive blind Signal Processing-Neural Network Approaches, Proceedings IEEE, 86, (1998) 1186-1187.
57. Amari, S., Douglas, S. C., Cichocki, A. ve Yang, H. H., Novel on-line Adaptive Learning Algorithms for Blind Deconvolution Using The Natural Gradient Approach, In Proc. 11th IFAC Symposium on System Identification , 3, 1997 1057-1062.

58. Gardner, W. A., A New Method of Channel Identification , IEEE Trans. Communications, 39, 6 (1991) 813-817.
59. Hyvarinen, A., Independent Component Analysis: Algorithms and Applications, Neural Networks, 13, 4 (2000) 411-430.
60. Lewicki, M. S. ve Sejnowski, T. J., Learning Nonlinear Overcomplete Representations for Efficient Coding, Advances in Neural Information Processing Systems, 1998, Denver, The MIT Press, 556-562.
61. Theis, F. J., Lang, E. W. ve Puntonet, C.G., A Geometric Algorithm for Overcomplete Linear ICA, Neurocomputing, 56, (2003) 381-398.
62. Bokman, L., Syungkwon, R. ve Park, F., C., Movement Primitives, Principal Component Analysis, and the Efficient Generation of Natural Motions, Proceedings of the 2005 IEEE International Conference on Robotics and Automation, April 2005, Barcelona, 4630-4635.
63. Manly, B. F. J., Multivariate Statistical Methods A premier, Chapman & Hall, USA, 1992.
64. Jackson, J. E., A User Guide to Principle Component, John Wily & Sons Inc, 1991.
65. McDonough, R. N. ve Whalen, A. D., Detection of Signals in Noise, Academic Press, 1995.
66. Brugger, D., Bogdan, M. ve Rosenstiel , W., Automatic Cluster Detection in Kohonen's SOM, Neural Networks IEEE Transactions on, 19, 3 (2008), 442-459.
67. Haykin, S., Neural Networks, Macmillan College Publishing Company, 1994.
68. Cardoso, J. F. ve Souloumiac, A., Blind Beamforming for Non Gaussian Signals, IEEE Proc.-F, 140, 6 (1993) 362-370.
69. Cardoso, J. F., Eigen-Structure of The Fourth-Order Cumulant Tensor with Application to The Blind Source Separation Problem, In Proc. ICASSP90, April 1990, USA, 2655-2658.
70. Cardoso, J. F., Super-Symmetric Decomposition of The Fourth-Order Cumulant Tensor, In Proc. ICASSP91, May 1991, Toronto, 3109-3112.
71. Cardoso, J. F., Iterative Techniques for Blind Source Separation Using Only Fourth-Order Cumulants, In Proc. EUSIPCO, 1992, Brussels, 739-742.
72. Cardoso, J. F. ve Comon, P., Independent Component Analysis, A Survey of Some Algebraic Methods, In Proc. ISCAS96, May 1996, Atlanta, 2, 93-96.

73. Papoulis, A., Probability, Random Variables, and Stochastic Processes, McGraw-Hill, 1991.
74. Girolami, M., Self-Organising Neural Networks-Independent Component Analysis and Blind Source Separation, Springer-Verlag, 1999.
75. Cardoso, J. F. ve Comon, P., Tensor Based Independent Component Analysis, In Proc. EUSIPCO, 1990.
76. Golub, G. H. ve Van Loan, C. F., Matrix Computations, The Johns Hopkins University Press, 1996.
77. Cardoso, J. F., High-order Constants for Independent Component Analysis, Neural Computat., 11, 1 (1999) 157-192.
78. Karvanen, J., Eriksson, J. ve Koivunen, V., Pearson System Based Method for Blind Separation, in Proce. Second Int. Workshop on Independent Component Analysis and Blind Signal Separation, June 2000, Helsinki, 585-590.
79. Vlasis, N. ve Motomura, Y., Efficient Source Adaptivity in Independent Component Analysis, IEEE Trans. Neural Networks, 12, (2001) 559-566.
80. Boscolo, R., Pan, H. Ve Roychowdhury, V. P., Non-Parametric ICA, in Proc. ICA2001, December 2001, San Diego, 13-18.
81. Boscolo, R., Pan, H. Ve Roychowdhury, V. P., Independent Component Analysis Based on Non-Parametric Density Estimation, IEEE Transactions on Neural Networks, 15, 1 (2004), 55-65.
82. Donoho, D., On Minimum Entropy Deconvolution, in Proc. Second Applied Time Series Symp., 1981, New York, 565-609.
83. Cardoso, J. F, Blind Signal Separation:Statical Principles, Proc. IEEE. Special Issue on Blind Identification and Estimation, 9, (1998) 2009-2025.
84. Silverman, B. W., Density Estimation for Statistics and Data Analysis., Chapman and Hall, New York, 1985.
85. Jones, M. C., The Projection Pursuit Algorithm for Exploratory Data Analysis, PhD Thesis, University of Bath, Bath, 1983.
86. Chong, E. K. P. ve Zak, S. H., An Introduction to Optimization, Wiley-Interscience, 2001.
87. Dukkupati, A., On Generalized Measures of Information with Maximum and Minimum Entropy Prescriptions, PhD Thesis, Indian Institute of Science, Bangalore, 2006.

6. EKLER

EK 1

İşaret Hata Oranı (İHO)

İHO değeri, kaynak işareti ile ayrıştırılmış işaret arasındaki işaret hata oranı değerini göstermekte olup, her bir ayrıştırılmış işaret için İHO değerleri,

$$IHO = 10 \log_{10} \left(\frac{E \{s^2\}}{E \{(y-s)^2\}} \right)$$

denklemini ile hesaplanır. Burada s , kaynak işaretini, y ise, ayrıştırılmış kaynak yaklaşımını temsil etmektedir.

İşaret Karışım Oranı (İKO)

İKO değeri, çok boyutlu sinyal ayrıştırma işleminde istenen işaretler ile istenmeyen işaretlerin kaynak işareti olarak aralarındaki toplam karışım oranlarını göstermekte olup,

$$IKO = 10 \log_{10} \left(\frac{E_i \{s_i^2\}}{E_i \{k_i^2\}} \right)$$

denklemini ile hesaplanır. Burada s_i , tüm problemlerdeki istenen kaynak işaretlerini, k_i ise, tüm problemlerdeki istenmeyen karışım işaretlerini temsil etmektedir.

İşaret Gürültü Oranı (İGO)

İGO değeri, çok boyutlu sinyal ayrıştırma işleminde kaynak işaretleri ile gürültü işaretleri arasındaki toplam işaret gürültü oranını göstermekte olup,

$$IGO = 10 \log_{10} \left(\frac{E_i \{s_i^2\}}{E_i \{n_i^2\}} \right)$$

denklemini ile hesaplanır. Burada s_i , tüm problemlerdeki kaynak işaretlerini, n_i ise, tüm problemlerdeki gürültü işaretlerini temsil etmektedir.

ÖZGEÇMİŞ

Yusuf SEVİM, 01.06.1975 tarihinde Trabzon'un Akçaabat ilçesinde doğdu. İlköğrenimini Trabzon'da Atatürk İlköğretim Okulu'nda, ortaöğrenimini Cumhuriyet Orta Okulu'nda, lise öğrenimini Trabzon Lisesi'nde tamamladı. 1993 yılında Trabzon Meslek Yüksek Okulu Elektronik bölümünü kazandı ve 1995 yılında bu bölümden mezun oldu. 1996 yılında girdiği Karadeniz Teknik Üniversitesi, Mühendislik – Mimarlık Fakültesi, Elektrik – Elektronik Mühendisliği Bölümünü 1999–2000 öğretim döneminde bitirerek Elektronik Mühendisi ünvanı ile mezun oldu. 2000 yılında Karadeniz Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Elektrik-Elektronik Mühendisliği Anabilimdalı'nda yüksek lisans eğitimi almaya hak kazandı. 2000–2001 öğretim döneminde Karadeniz Teknik Üniversitesi, Yabancı Diller Bölümü, İngilizce Hazırlık Sınıfını başarıyla bitirdi. 2001-2002 öğretim döneminde yüksek lisans eğitimine başladı. 2003 yılında yüksek lisans eğitimini tamamladı. Aynı yıl Karadeniz Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Elektrik-Elektronik Mühendisliği Anabilimdalı'nda doktora eğitimine başladı. Aynı zamanda 2001-2005 yılları arasında Elektrik–Elektronik Mühendisliği bölümünde araştırma görevlisi olarak görev yaptı ve 2005 yılından itibaren Elektrik-Elektronik Mühendisliği bölümünde uzman olarak görev yapmaktadır. İyi derecede İngilizce bilmektedir.