

**T.C.
ERCIYES ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI**

**ÇOK AMAÇLI OPTİMİZASYON YÖNTEMLERİ İLE
İŞARET AYRIŞTIRMA**

**Hazırlayan
Hüsamettin ÇELİK**

**Danışman
Prof. Dr. Nurhan KARABOĞA**

Doktora Tezi

**Nisan 2024
KAYSERİ**

**T.C.
ERCIYES ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI**

**ÇOK AMAÇLI OPTİMİZASYON YÖNTEMLERİ İLE
İŞARET AYRIŞTIRMA
(Doktora Tezi)**

**Hazırlayan
Hüsamettin ÇELİK**

**Danışman
Prof. Dr. Nurhan KARABOĞA**

**Bu çalışma, Erciyes Üniversitesi Bilimsel Araştırma Projeleri Birimi
tarafından FDK-2022- 11706 kodlu proje ile desteklenmiştir.**

**Nisan 2024
KAYSERİ**

BİLİMSEL ETİĞE UYGUNLUK

Bu çalışmadaki tüm bilgilerin, akademik ve etik kurallara uygun bir şekilde elde edildiğini beyan ederim. Aynı zamanda bu kural ve davranışların gerektirdiği gibi, bu çalışmanın özünde olmayan tüm materyal ve sonuçları tam olarak aktardığımı ve referans gösterdiğimi belirtirim.

Hüsamettin ÇELİK

İmza

“Çok Amaçlı Optimizasyon Yöntemleri ile İşaret Ayırıştırma” adlı Doktora tezi, Erciyes Üniversitesi Lisansüstü Tez Önerisi ve Tez Yazma Yönergesi’ ne uygun olarak hazırlanmıştır.

Hazırlayan

Hüsamettin ÇELİK

İmza

Danışman

Prof. Dr. Nurhan KARABOĞA

İmza

Elektrik-Elektronik Mühendisliği ABD Başkanı

Prof. Dr. Enis GÜNAY

İmza

TEŞEKKÜR

Çalışmalarım süresince her türlü yardımı ve fedakârlığı sağlayan, bilgisini, samimiyetini ve tecrübesini benden esirgemeyen danışman hocam Sayın Prof. Dr. Nurhan KARABOĞA'ya vermiş olduğu desteklerden dolayı teşekkürlerimi sunuyorum.

Tez izleme komitesinde görev alarak çalışmalarına katkıda bulunan değerli hocalarım Sayın Prof. Dr. Mustafa ALÇI ve Sayın Prof. Dr. Bahriye AKAY'a teşekkürlerimi sunuyorum.

FDK-2022-11706 numaralı proje ile Doktora tezimi destekleyen Erciyes Üniversitesi Bilimsel Araştırma Projeleri Birimi'ne teşekkür ederim.

Beni bugüne kadar yalnız bırakmayan, maddi ve manevi desteklerini hiçbir zaman esirgemeyen, kıymetli anne ve babama, tez çalışmam süresince sabırlarından dolayı eşime ve kızıma sevgi ve saygılarımı sunarım.

Hüsamettin ÇELİK

Nisan 2024, KAYSERİ

ÇOK AMAÇLI OPTİMİZASYON YÖNTEMLERİ İLE İŞARET AYRIŞTIRMA

Hüsamettin ÇELİK

Erciyes Üniversitesi, Fen Bilimleri Enstitüsü
Doktora Tezi, Nisan 2024
Danışman: Prof. Dr. Nurhan KARABOĞA

ÖZET

İşaret işleme alanında birçok problem, Kör Kaynak Ayırıştırma problemleri olarak formüle edilmiştir. Klasik olarak bu problemler kaynak işaretlerine ilişkin bir ayırıştırma kriterinin optimizasyonu yoluyla çözülmektedir. Ancak birçok pratik durumda kaynaklara ilişkin birden fazla bilgi bulunmaktadır ve dolayısıyla sorunun çözümü için birden fazla ayırıştırma kriteri oluşturulabilmektedir. Bu nedenle bu çalışma, kör kaynak ayırıştırma problemlerini çözmek için, SPEA2 yöntemi ile birden fazla kriterin eş zamanlı optimizasyonu ile elde edilen çok amaçlı bir yaklaşım uygulanmasını önermektedir. Bu yaklaşımın uygulanabilirliğini ortaya koymak amacıyla önce üç kişiye ait konuşma sesleri ve sonrasında biyomedikal işaretlerin ayırıştırılması test edilmiştir. Ayrıca bu tez çalışmasında kullanılan çok amaçlı kör kaynak ayırıştırmasının performansını artırmak için ön işlemler uygulanarak işaret ayırıştırmadaki başarı oranı olumlu şekilde test edilmiştir. Ayrıca işaretlerin örnek sayısının azaltılması amacıyla Ayrık Dalgacık Dönüşümü uygulanarak zaman-frekans ekseninde gerekli analizler yapılmıştır. Bu analiz sonucunda elde edilen karışık işaretler çok amaçlı kör kaynak ayırma yöntemine uygulanmış ve önerilen yöntemlerle performansın arttırılabileceği görülmüştür. Aynı zamanda önerilen yöntemlerin işlem maliyetleri artmasına rağmen işlem sürelerinde az da olsa azalma sağlanmıştır. Uygulama sonuçları, birbirine karışmış konuşma sesleri veya birbirine karışmış biyomedikal işaretlerin ayırıştırılmasında önerilen yöntemin kullanılabileceğini göstermiştir.

Anahtar Kelimeler: Kör Kaynak Ayırıştırma, Çok Amaçlı Optimizasyon, SPEA2, Ayrık Dalgacık Dönüşümü, Beyazlatma, İşaret Ayırıştırma.

SIGNAL SEPARATION WITH MULTI-OBJECTIVE OPTIMIZATION METHODS

Hüsamettin ÇELİK

Erciyes University, Graduate School of Natural and Applied Sciences

PhD Thesis, April 2024

Supervisor: Prof. Dr. Nurhan KARABOĞA

ABSTRACT

Many problems in the field of signal processing have been formulated as Blind Source Separation problems. Classically, these problems are solved by optimizing a separation criterion for the source signals. However, in many practical cases, there is more than one information about the resources and therefore more than one separation criterion can be created to solve the problem. Therefore, this study proposes to apply a multi-objective approach obtained by simultaneous optimization of multiple criteria with the SPEA2 method to solve blind source separation problems. To demonstrate the feasibility of this approach, first the speech sounds of three people and then the parsing of biomedical signals has been tested. In addition, to increase the performance of the Multi-Objective Blind Source Separation used in this thesis study, the performance rate in signal separation has been tested by applying pre-processing. In addition, in order to reduce the number of samples of the signals, the necessary analyzes were obtained on the time-frequency axis by applying the Discrete Wavelet Transform. The mixed signals obtained as a result of this analysis have been applied to the multi-objective blind source separation method and it has been seen that the performance could be increased with the proposed methods. At the same time, although the transaction costs of the proposed methods increased, a slight decrease has been achieved in the processing times. Application results have shown that the proposed method can be used to separate entangled speech or biomedical signals. Application results have shown that the proposed method can be used in separating mixed speech sounds or mixed biomedical signals.

Keywords: Blind Source Separation, Multi-Objective Optimization, SPEA2, Discrete Wavelet Transform, Whitening, Signal Separation.

İÇİNDEKİLER

ÇOK AMAÇLI OPTİMİZASYON YÖNTEMLERİ İLE İŞARET AYRIŞTIRMA

BİLİMSEL ETİĞE UYGUNLUK.....	ii
YÖNERGEYE UYGUNLUK.....	ii
KABUL VE ONAY	iv
TEŞEKKÜR.....	v
ÖZET	vi
ABSTRACT.....	vii
İÇİNDEKİLER	viii
KISALTMALAR.....	xi
TABLolar LİSTESİ.....	xiv
ŞEKİLLER LİSTESİ	xv
GİRİŞ	1

1. BÖLÜM

KONUŞMA SESİ, EKG ve KÖR KAYNAK AYRIŞTIRMA HAKKINDA GENEL BİLGİLER

1.1. Kullanılan İşaretler.....	4
1.1.1. İnsan Sesinin Yapısı.....	4
1.1.2. Ses Kalitesi ve Fonetik Kalitesi.....	7
1.1.3. Fonetik Kalite.....	7
1.1.4. Ses Kalitesi.....	8
1.1.5. Ses tonu	9
1.1.6. İşitme Süreci.....	9
1.1.7. İstenmeyen Seslerin Algılanması.....	11
1.2. EKG İşareti.....	12
1.2.1. EKG Dalga Formları.....	13

1.2.2. Biyomedikal İşaretlerde Gürültü Giderme	14
1.2.3. Fetal EKG	15
1.2.4. Fetal Kalp Gelişimi	15
1.2.5. EKG İşaretlerin Ölçümü ve Önemi	17
1.3. Beyaz Gauss Gürültüsü	19
1.4. Kokteyl Parti Problemi.....	19
1.5. Ses İşleme	23

2. BÖLÜM

ÇOK AMAÇLI OPTİMİZASYON ALGORİTMALARININ KÖR KAYNAK AYRIŞTIRMADA KULLANILMASI

2.1. Çok Amaçlı Optimizasyon Algoritmaları	26
2.2. Çok Amaçlı Evrim Algoritmalarının Temel Prensipleri.....	27
2.3. Çok Amaçlı Optimizasyon Problemi.....	29
2.4. NSGAII Algoritması	31
2.5. Güçlü Pareto Evrimsel Algoritması (SPEA)	33
2.6. Güçlü Pareto Evrimsel Algoritması 2 (SPEA2).....	34
2.7. Çevresel Seçim.....	37
2.8. Çok Amaçlı Evrimsel Algoritmalarındaki Sorunlar.....	38

3. BÖLÜM

ÇOK AMAÇLI OPTİMİZASYON ALGORİTMALARINDA PERFORMANS ARTIRMA YÖNTEMLERİ

3.1. Ön İşlemler Yöntemi.....	40
3.2. Dalgacık Dönüşümü Yöntemi	42
3.2.1. Sürekli Dalgacık Dönüşümü Yöntemi	44
3.2.2. Ayrık Dalgacık Dönüşümü Yöntemi	44
3.2.3. DWT Dalga Formları Yöntemi.....	47
3.2.4. Haar Dalgacık Dönüşümü Yöntemi	48
3.2.5. Daubechies Dalgacık Dönüşümü Yöntemi	48
3.2.6. Eşik Belirleme ve Gürültü Giderme.....	50
3.3. Çözümlerin PF Yakınlığını Ölçmede Kullanılan Metrikler.....	52

3.3.1. IGD Metriği.....	53
3.3.2. HV Metriği.....	54
3.3.3. SP Metriği.....	55
3.4. Kullanılan Amaç Fonksiyonları.....	56
3.5. Benimsenen Çok Amaçlı Algoritma Hakkında Genel Hususlar	58

4. BÖLÜM

MO-BSS YÖNTEMİ ile İŞARETLERİN AYRIŞTIRILMASI

4.1 Araştırma Modeli ve Uygulama.....	62
4.2. Ön İşlem ve Ayırık Dalgacık Dönüşümü Uygulaması	70
4.3. Ön İşlem Uygulanarak İşaret Ayrıştırma.....	70
4.4. Ayırık Dalgacık Dönüşümü Uygulanmış MO-BSS Algoritması.....	77
4.5. Önerilen Yöntemlerin Farklı Seslere Uygulanması	85
4.6. Çok Amaçlı Optimizasyon Algoritmaları ile EKG İşaretlerin Ayrıştırılması .	91
4.7. EEG ve Beyaz Gauss Gürültü İşaretlerinin Ayrıştırılması.....	99

5. BÖLÜM

SONUÇ ve ÖNERİLER

KAYNAKÇA	104
ÖZGEÇMİŞ.....	117

KISALTMALAR

BSS	: Kör Kaynak Ayırıştırma (Blind Source Separation)
CPE	: Kokteyl Parti Etkisi (Cocktail Party Effect)
CPP	: Kokteyl Parti Problemi (Cocktail Party Problem)
CWT	: Sürekli Dalgacık Dönüşümü (Continuous Wavelet Transform)
dB	: Desibel
DWT	: Ayırık Dalgacık Dönüşümü (Discrete Wavelet Transform)
EA	: Evrimsel Algoritma (Evolutionary Algorithm)
EC	: Evrimsel Hesaplama (Evolutionary Computation)
EEG	: ElektroEnsefaloGram (Electroensefalogram)
EKG	: ElektroKardiyoGram (Electrocardiogram)
EMG	: ElektroMiyoGrafı (Electromyography)
FFT	: Hızlı Fourier Dönüşümü (Fast Fourier Transform)
FIR	: Sonlu Dürtü Yanıtı (Finite Impulse Response)
FT	: Fourier Dönüşümü (Fourier Transform)
GD	: Nesil Mesafesi (Generational Distance)
HV	: Hiper Hacim (Hypervolume)
IDWT	: Ters Ayırık Dalgacık Dönüşümü (Inverse Discrete Wavelet Transform)
IGD	: Ters Nesil Mesafesi (Inverted Generational Distance)
MCG	: Manyetokardiyografi (Magnetocardiography)
MO-BSS	: Çok Amaçlı Kör Kaynak Ayırıştırma (Multi-Objective Blind Source Separation)
MOEA	: Çok Amaçlı Evrimsel Algoritma (Multi-Objective Evolutionary Algorithm)

MOEA/D	: Ayrıştırma Tabanlı Çok Amaçlı Evrimsel Algoritma (Multi-Objective Evolutionary Algorithm Based on Decomposition)
MOO	: Çok Amaçlı Optimizasyon (Multi-Objective Optimization)
MOOA	: Çok Amaçlı Optimizasyon Algoritması (Multi-Objective Optimization Algorithm)
MOOP	: Çok Amaçlı Optimizasyon Problemi (Multi-Objective Optimization Problem)
MOPSO	: Çok Amaçlı Parçacık Sürü Optimizasyonu (Multi-Objective Particle Swarm Optimization)
NSGA	: Baskılanmayanları Sıralayan Genetik Algoritma (Non-dominated Sorting Genetic Algorithm)
PAES	: Pareto-Arşivlenmiş Evrim Strateji Pareto Archived Evolution Strategy)
PCA	: Temel Bileşen Analizi (Principal Component Analysis)
PESA	: Pareto Zarflama Temelli Seçim Algoritması (Pareto Envelope-Based Selection Algorithm)
PF	: Pareto Cephesi (Pareto Front)
QMF	: Dörtlü Ayna Filtresi (Quadrature Mirror Filters)
SBSE	: Arama Tabanlı Yazılım Mühendisliği (Search-Based Software Engineering)
SNR	: İşaret-Gürültü Oranı (Signal-to-Noise Ratio)
SOEA	: Tek Amaçlı Evrimsel Algoritma (Single-Objective Evolutionary Algorithm)
SOOP	: Tek Amaçlı Optimizasyon Problemi (Single-Objective Optimization Problem)
SP	: Yayılma ölçüsü (Spread)
SPEA	: Güçlü Pareto Evrimsel Algoritması (Strength Pareto Evolutionary Algorithm)
SSIM	: Yapısal Benzerlik İndeksi Ölçüsü (Structural Similarity Index Measure)

STFT	: Kısa Zamanlı Fourier Dönüşümü (Short Time Fourier Transform)
UD	: Düzgün Dağıtım (Uniform Distribution)
WT	: Dalgacık Dönüşümü (Wavelet Transform)



TABLOLAR LİSTESİ

Tablo 1.1.	EKG işaretine ait genlik ve zaman parametresi.....	14
Tablo 4.1.	Örnek sayılarına göre MO-BSS yönteminin SNR değerleri.....	65
Tablo 4.2.	MO-BSS yönteminin IGD metrik değerleri.....	68
Tablo 4.3.	MO-BSS yönteminin HV metrik değerleri	69
Tablo 4.4.	MO-BSS yönteminin SP metrik değerleri	69
Tablo 4.5.	MO-BSS yönteminin farklı örnek sayılarına göre çalışma süreleri.....	70
Tablo 4.6.	Örnek sayılarına göre ön işlemlili MO-BSS yönteminin SNR değerleri.....	71
Tablo 4.7.	Ön işlemlili MO-BSS yönteminin IGD metrik değerleri.....	74
Tablo 4.8.	Ön işlemlili MO-BSS yönteminin HV metrik değerleri	74
Tablo 4.9.	Ön işlemlili MO-BSS yönteminin SP metrik değerleri	75
Tablo 4.10.	MO-BSS ve ön işlemlili MO-BSS yöntemlerinin çalışma süreleri	76
Tablo 4.11.	Örnek sayılarına göre MO-BSS, ön işlemlili MO-BSS ve DWT MO-BSS yöntemlerinin SNR değerleri	79
Tablo 4.12.	Ön işlemlili ve DWT MO-BSS yöntemlerinin IGD metrik değerleri.....	82
Tablo 4.13.	Ön işlemlili ve DWT MO-BSS yöntemlerinin HV metrik değerleri	82
Tablo 4.14.	Ön işlemlili ve DWT MO-BSS yöntemlerinin SP metrik değerleri	83
Tablo 4.15.	MO-BSS, ön işlemlili MO-BSS ve DWT MO-BSS yöntemlerinin koşma süreleri	84
Tablo 4.16.	Örnek sayılarına göre erkek sesleri ve gürültü işaretinin SNR değerleri ..	86
Tablo 4.17.	Örnek sayılarına göre Fetal EKG ve gürültü ve Anne EKG işaretlerinin SNR değerleri	93
Tablo 4.18.	Önerilen yöntemlerin SNR cinsinden performans karşılaştırılması	99
Tablo 4.19.	Örnek sayılarına göre EEG ve gürültü işaretlerinin SNR değerleri.....	101

ŞEKİLLER LİSTESİ

Şekil 1.1.	Konuşma sistemi ve konuşma ile ilgili organlar.....	5
Şekil 1.2.	Normal bir EKG periyodu	13
Şekil 1.3.	Kokteyl parti problemi.....	20
Şekil 1.4.	Kör kaynak ayrıştırma yönteminin blok diyagramı.....	21
Şekil 2.1.	Çok amaçlı kör kaynak ayrıştırma blok diyagramı.....	25
Şekil 2.2.	Pareto cephesi kavramının gösterimi.....	28
Şekil 2.3.	Genel olarak çok amaçlı problemin gösterimi.....	30
Şekil 2.4.	Çok amaçlı problemin bileşenleri	31
Şekil 2.5.	SPEA2 blok diyagramı	35
Şekil 3.1.	Önerilen ön işlemlili MO-BSS algoritmasının blok diyagramı	42
Şekil 3.2.	Ayrık dalgacık dönüşümünde işaretin filtrelenmesi	45
Şekil 3.3.	Önerilen ayrık dalgacık dönüşümlü MO-BSS algoritmasının blok diyagramı	46
Şekil 3.4.	Ters Ayrık dalgacık dönüşümünde işaretin yeniden yapılandırılması.....	51
Şekil 4.1.	İki kadın ve bir erkek konuşma sesine ait kaynak işaretler	63
Şekil 4.2.	Kullanılan orijinal kaynak işaretler, karıştırılmış işaretler ve tahmin edilen kaynak işaretler	64
Şekil 4.3.	Algoritmanın koşma sırasında rastgele alınan Pareto cephesi.....	65
Şekil 4.4.	Birinci kadın sesi için algoritmanın 50 koşma sayısındaki SNR sonuçları.....	66
Şekil 4.5.	İkinci kadın sesi için algoritmanın 50 koşma sayısındaki SNR sonuçları.....	67
Şekil 4.6.	Erkek sesi için algoritmanın 50 koşma sayısındaki SNR sonuçları.....	67
Şekil 4.7.	Birinci kadın sesi için ön işlemlili MO-BSS'nin 50 koşmadaki SNR sonuçları	72
Şekil 4.8.	İkinci kadın sesi için ön işlemlili MO-BSS'nin 50 koşmadaki SNR sonuçları	73
Şekil 4.9.	Erkek sesi için ön işlemlili MO-BSS'nin 50 koşmadaki SNR sonuçları.....	73
Şekil 4.10.	MO-BSS ve ön işlemlili MO-BSS yöntemlerinin çalışma sürelerinin grafiksel gösterimi	77
Şekil 4.11.	Ses işaretlerinin zaman-frekans eksenindeki orijinal, karışmış ve tahmini ayrıştırılmış şekilleri	78

Şekil 4.12.	Birinci kadın sesi için Monte Carlo analizinin DWT MO-BSS'nin 50 koştaki SNR sonuçları.....	80
Şekil 4.13.	İkinci kadın sesi için Monte Carlo analizinin DWT MO-BSS'nin 50 koştaki SNR sonuçları.....	81
Şekil 4.14.	Erkek sesi için Monte Carlo analizinin DWT MO-BSS'nin 50 koştaki SNR sonuçları	81
Şekil 4.15.	MO-BSS ve önerilen her iki yöntemin koşma süreleri.....	84
Şekil 4.16.	İki erkek sesi ve gürültü işaretine ait kaynak işaretler.....	85
Şekil 4.17.	Birinci erkek ses işareti için Monte Carlo analizinin MO-BSS, ön işlemli MO-BSS ve DWT MO-BSS'nin SNR sonuçları.....	87
Şekil 4.18.	Birinci erkek ses işareti için MO-BSS ve önerilen iki yöntemin 10 koştaki SNR değerleri	88
Şekil 4.19.	İkinci erkek ses işareti için Monte Carlo analizinin MO-BSS, ön işlemli MO-BSS ve DWT MO-BSS'nin SNR sonuçları.....	89
Şekil 4.20.	İkinci erkek ses işareti için MO-BSS ve önerilen iki yöntemin 10 koştaki SNR değerleri	89
Şekil 4.21.	Gürültü işareti için Monte Carlo analizinin MO-BSS, ön işlemli MO-BSS ve DWT MO-BSS'nin SNR sonuçları.....	90
Şekil 4.22.	Gürültü işareti için MO-BSS ve önerilen iki yöntemin 10 koştaki SNR değerleri	90
Şekil 4.23.	Fetal EKG, gürültü ve Anne EKG'ye ait kaynak işaretler	91
Şekil 4.24.	EKG ayırtırmada kullanılan orijinal kaynak işaretler, karıştırılmış işaretler ve tahmin edilen kaynak işaretler	92
Şekil 4.25.	Fetal EKG işareti için Monte Carlo analizinin MO-BSS, ön işlemli MO-BSS ve DWT MO-BSS'nin SNR sonuçları.....	95
Şekil 4.26.	Fetal EKG işareti için MO-BSS ve önerilen iki yöntemin 10 koştaki SNR değerleri	95
Şekil 4.27.	Gürültü işareti için Monte Carlo analizinin MO-BSS, ön işlemli MO-BSS ve DWT MO-BSS'nin SNR sonuçları.....	96
Şekil 4.28.	Gürültü işareti için MO-BSS ve önerilen iki yöntemin 10 koştaki SNR değerleri	97
Şekil 4.29.	Anne EKG işareti için Monte Carlo analizinin MO-BSS, ön işlemli MO-BSS ve DWT MO-BSS'nin SNR sonuçları.....	97

Şekil 4.30. Anne EKG işareti için MO-BSS ve önerilen iki yöntemin 10 koştaki SNR değerleri	98
Şekil 4.31. EEG ve gürültüye ait kaynak işaretler	100



GİRİŞ

Doğada birçok ses farklı kaynakların karışımı olan işaretlerin toplamından oluşur. İnsanlar gürültülü veya karmaşık işitsel ortamlarda mevcut davranışsal açıdan en alakalı bilgiyi çıkarmak için dikkatini tek bir sese odaklama yeteneğine sahiptir. Bu durum klasik olarak Kokteyl Parti Etkisi (CPE, Cocktail Party Effect) veya Kokteyl Parti Problemi (CPP, Cocktail Party Problem) olarak adlandırılmaktadır. CPP probleminde, insanların konuşmak için bir araya geldiği bir kokteyl partisinin olduğu varsayılır. Konuşmacıların işaretlerini toplamak için bir mikrofon kullanırsa, toplanan işaretler aynı anda konuşan birçok kişinin karışımı olacaktır. Bu durumda kaynaklar olarak bilinen, bireysel seslerin bu karışık işareten nasıl ayırt edileceğidir. Bu sorun genel olarak Kör Kaynak Ayırıştırma (BSS, Blind Source Separation) olarak bilinir.

BSS hem orijinal verileri hem de karıştırma işleminin parametrelerini göz ardı ederek, bu tür kaynakların bir dizi karışımından bir dizi kaynak işaretini kurtarmayı amaçlayan işaret işleme problemidir. Bu problemle ilgili olarak, gözlenen karışımlar arasından karışımları oluşturan işaretleri tahmin etmek amaçlanmaktadır. Bu yöntemle, her ne kadar kör olduğu söylene de çözülebilmesi için kaynakların ve karıştırma süreci hakkında bazı ön bilgilerin verilmesini gerektirmektedir. Bu bilgiye dayanarak, karışık işaretlerin ayrıştırılması için bir optimizasyon kriteri oluşturulabilir.

BSS, Jutten ve Hérault tarafından ortaya atılmış ve sonraki yıllarda kaynakların çok çeşitli özelliklerine ilişkin çeşitli optimizasyon kriterleri geliştirilmiştir [1]. Bunlar arasında istatistiksel bağımsızlığa, korelasyona, zamansal yapıya ve işaretlerin seyrekliğine dayananları sayabiliriz [2]. Bu kriterleri temel alan tüm modellerde optimize edilecek tek bir amaç fonksiyonu bulunmaktadır. Tek amaçlı yöntemler başarılı olsa da bazı zorluklar söz konusudur. Tek amaçlı yöntemlerin aracılığıyla belirlenen kaynakların sayısı verinin boyutunu aşamaz. Electroensefalogram (EEG) işaret analizi gibi uygulama alanlarında, işarete yönelik kaynak sayısı her zaman veriyi toplayan elektrot sayısından daha fazladır.

Örneğin, EEG verilerine ek olarak işaret, kas ve göz hareketlerinden kaynaklanan artefaktlarla karışarak istenen sonuçlar elde edilmez. Ancak kaynaklar hakkında önceden bilgi setinin bulunduğu ve bu nedenle sorunu çözmek için birden fazla optimizasyon kriterinin oluşturulabileceği durumlar da vardır. Bu durumlarda genellikle kriterler, kaynak işaretlerinin tüm özelliklerini hesaba katan tek bir amaç fonksiyonunda birleştirilmesidir.

Kaynak işaretlerine ilişkin birden fazla bilginin varlığı birçok uygulamada yaygın olduğundan ve bu sayede bir dizi optimizasyon kriteri elde edilebildiğinden, bu çalışma kör kaynak ayırma problemlerini Çok Amaçlı Optimizasyon (MOO, Multi-Objective Optimization) yoluyla ele almayı amaçlamaktadır [3]. Bu şekilde kriterleri tek bir amaç fonksiyonunda birleştirmek yerine eş zamanlı olarak optimize edilmesi planlanmaktadır. Önerilen yaklaşımda, problemin çözümüyle sonuçlanan tek amaçlı yaklaşımdan farklı olarak bir dizi Pareto optimum çözüm üretilecektir [4].

Böylece, karar vericinin kriterler için ağırlıkları önceden belirlemesine gerek kalmayacak, bunun yerine kararına dayanak oluşturacak eşit derecede optimal çözümlere sahip olacaktır. Bir amaç fonksiyonunun formülasyonunda birden fazla kriteri dikkate alan çalışmalar olmasına rağmen, bunların eşzamanlı optimizasyonunun kör kaynak ayrımı bağlamında çok az araştırıldığı bilinmektedir [5].

Bu tez çalışmasının temel amacı, BSS problemlerinde çok amaçlı optimizasyonun uygulanabilirliği gösterilerek performansının geliştirilmesidir. Çok amaçlı optimizasyon modellerinden olan Güçlü Pareto Evrimsel Algoritması 2 (SPEA2, Strength Pareto Evolutionary Algorithm) yöntemine dayalı bir teknik kullanılarak çözülecektir. Bu nedenle bu çalışmada bu tekniğin ve burada ele alınan problemlere uygunluğunun araştırılması gerçekleştirilecektir. Bahsedilen bu amaçlara ek olarak, çok amaçlı optimizasyon kör kaynak ayrımı bağlamında çok az araştırıldığı için bu çalışma aynı zamanda bu konudaki araştırmaları teşvik etmeyi de amaçlamaktadır.

Bu tezde, uygulama için üç farklı ses işareti olarak iki kadın ve bir erkek konuşma ses karışımının ayrıştırılması incelenmiştir. Aynı yöntemlerle iki erkek konuşma sesi ve bir Beyaz Gauss Gürültü işaretinin ayrıştırılması da sağlanmıştır. Bu konuşma sesleri iletişim, güvenlik, biyomedikal, kontrol sistemleri ve istihbarat gibi analiz gerektiren birçok alanda yol gösterici olarak kullanılmaktadır. İletişim için konuşma işaretlerinin

kodlanması ve kodunun çözülmesi, güvenlik için konuşma sesi tanıma, biyotıpta hastalık teşhisi, konuşma bozuklukları ve düzeltilmesi, kontrol alanında sesli komut kontrol sistemleri ve istihbarat alanında kelime yakalama gibi uygulamalarda sıklıkla kullanılmaktadır.

Uygulama gerçek hayattan esinlenerek planlanmış ve her koşmada işaretler yapay olarak rastgele matris kullanılarak birbirine karıştırılmıştır. Önerilen yöntemde kullanılan algoritmanın 50 koşma sonucu ortalama İşaret-Gürültü Oranı (SNR, Signal-to-Noise Ratio) değerleri alınarak performans analizleri yapılmıştır. Kullanılan yöntemlerin performanslarını kanıtlamak için biyomedikal işaretler üzerinde de uygulama yapılmıştır.

Birbirine rastgele olarak karıştırılmış Fetal Electrocardiogram (EKG) işareti, beyaz Gauss gürültü işareti ve anne EKG işaretlerinin ayrıştırılması sağlanmıştır. Ayrıca birbirine karıştırılmış EEG ve beyaz Gauss gürültü işaretlerinin ayrıştırılması da test edilmiştir.

Tez çalışmasına göre önerilen yöntemle BSS probleminin çözümünde SPEA2 yöntemi kullanılmış, böylece eş zamanlı olarak belirlenen amaç fonksiyonları ile karışmış işaretlerin ayrıştırılması sağlanmıştır. Devamında önerilen yöntemin performansını artırmak için ön işlem olarak beyazlatma kullanılması önerilmiştir. Ayrıca işaretler üzerinde Ayrik Dalgacık Dönüşümü (DWT, Discrete Wavelet Transform) kullanılarak gerekli analizler sonucunda Çok Amaçlı Kör Kaynak Ayrıştırma (MO-BSS, Multi-Objective Blind Source Separation) ile işaret ayrıştırmadaki başarı oranında artış sağlanmıştır.

Tez çalışmasının ilk bölümünde insan sesinin oluşumu, yapısı, özellikleri ve bu seslerin işitilme süreci anlatılmıştır. Devamında EKG işareti, CPP ve BSS yöntemleri anlatılmıştır. İkinci bölümde çok amaçlı optimizasyon algoritmaları ve bu algoritmaların BSS yönteminde kullanımları hakkında bilgi verilmiştir. Üçüncü bölümde yöntemlerin işaret ayrıştırmadaki performanslarını arttırmak için önerilen ön işlem ve ayrik dalgacık dönüşümü hakkında bilgi verilmiştir. Ayrıca bu yöntemlerin performanslarını ölçmek için performans metrikleri anlatılmıştır. Dördüncü bölümde MO-BSS yöntemi ile ses işaretleri ayrıştırılmıştır. Ayrıca tasarlanan ön işlemlili MO-BSS ve DWT MO-BSS yöntemleri ile konuşma sesleri ve biyomedikal işaretler ayrıştırılmış ve sonuçlar tablo ve grafiklerle yorumlanmıştır. Son bölümde ise çalışmanın deneysel sonuçlarına göre değerlendirme yapılmıştır.

1. BÖLÜM

KONUŞMA SESİ, EKG VE KÖR KAYNAK AYRIŞTIRMA HAKKINDA GENEL BİLGİLER

Kör kaynak ayırıştırma birden fazla işaretin karışımını içeren işaretlerden kaynaklar hakkında başka hiçbir ek bilgi olmadan her bir kaynağın tahmin edilmesi işlemidir. Ses uygulamalarında özellikle ortam dinlemelerinde sensörlerle kaydedilen karışım işaretlerinden orijinal kaynak seslerine ulaşmak için yaygın bir şekilde kullanılır. Hayatın her aşamasında kullanılan işaretlerin gürültüsüz ve orijinaline yakın biçimde elde edilmesi haberleşme, biyomedikal ve güvenlik gibi birçok alanda çoğu zaman hayati önem taşımaktadır. Konuşma seslerinde kulağımız her ne kadar istenmeyen sesleri ayırırsa da çoğu işaretlerde yetersiz kalmaktadır. Bu durumda işaret ayırıştırma algoritmalarından faydalanılarak karışmış işaretlerden orijinaline en yakın kaynak işaretlerin elde edilmesi amaçlanmaktadır.


1.1. Kullanılan İşaretler

İşaret ayırıştırma yöntemlerinde en yaygın kullanılan işaret olarak insan sesleri gelmektedir. Bu tezde önerilen yöntemler ile farklı insan sesleri ayrıştırılacak olup devamında biyomedikal işaretler de ayrıştırılacaktır. İnsan seslerinin ve EKG işaretlerinin detaylı incelenmesi aşağıda verilmiştir.

1.1.1. İnsan Sesinin Yapısı

İnsan sesi, konuşma ve işitme süreci, birçok kompleks mekanizmanın bir araya gelmesiyle oluşur. Konuşma ve ses üretimi, gırtlak (Larenks), solunum sistemleri olarak akciğer, göğüs ve karın kasları, çene, dudaklar ve dilin koordinasyonu ile gerçekleşir. İşitme ise, kulakların dış, orta ve iç kısımları arasında gerçekleşen bir dizi mekanik ve elektriksel süreçlerden sonra beyne iletilen işaretlerle ortaya çıkar.

Ses üretimi, gırtlak adı verilen bir organda gerçekleşir. Gırtlak, solunum yolunun üst kısmında yer alır ve birçok önemli fonksiyona sahiptir. Ses telleri, gırtlak içinde bulunan iki ince elastik yapıya sahiptir. Ses telleri, hava akımı geçtiği zaman titreşerek ses oluştururlar. Bu titreşimler, sesin temel frekansını belirler. Ses tellerinden çıkan ses, ağız ve burun boşluklarından geçerken şekillendirilir. Dil, dudaklar, dişler ve çene gibi yapılar, sesin şeklini değiştirebilir ve farklı sesleri oluşturabilir. Bu şekillendirme süreci, konuşma sırasında harflerin ve kelimelerin doğru bir şekilde oluşmasını sağlar. Konuşma sistemi ve organlar Şekil 1.1’de gösterilmiştir. Aynı zamanda sesler erkek ve kadınlarda farklı tonlarda oluşur. Erkeklerin ses telleri genellikle daha kalın ve daha uzundur, bu da daha düşük bir ses tonuna neden olur. Kadınların ses telleri ise genellikle daha ince ve daha kısa olduğu için daha yüksek bir ses tonuna sahiptir. Bu farklılık, cinsiyet hormonlarından kaynaklanır. Bununla birlikte, her bireyin ses tonu birbirinden farklıdır çünkü ses tellerinin boyutu ve şekli genetik faktörlere, yaşa ve kullanıma bağlı olarak değişebilir.



Şekil 1.1. Konuşma sistemi ve konuşma ile ilgili organlar [6]

Konuşmanın akciğerlerde değil beyinde başladığını ve bunun için de konuşma organlarımız tarafından yerine getirilebilmesi amacıyla zihnimizde birtakım komutlara ihtiyaç duyulmaktadır. Yani bir ses bilime (fonetik plana) ve bir motor plana (dil, dudak ve damak hareketleri) ihtiyacımız vardır [7]. Bu işlemlerden sonra seslerin fiziksel üretimine başlanır. O halde konuşma, akciğerlerden gelen ve nefes borusu ile ağız ve burun boşluklarından geçen bir hava akımı tarafından üretilir. Bu da dört süreci içerir:

Başlatma, fonasyon/seslendirme, oro-nazal süreç ve artikülasyon yani ses ve sözcüklerin oluşması sürecidir.

Başlatma süreci, havanın akciğerlerden dışarı atıldığı andır.

Fonasyon süreci gırtlakta meydana gelir. Gırtlak, hava geçişinde iki yatay doku kıvrımına sahiptir; bunlar ses telleridir. Bu kıvrımlar arasındaki boşluğa glottis denir. Glottisin kapatılması ile hava geçişi engellenir veya ses tellerini titreterek “sesli sesler” üretebilecek dar bir açıklığa sahip olabilir. Son olarak, normal nefes almada olduğu gibi tamamen açık olabilir ve böylece ses tellerinin titreşimi azaltılarak "sessiz sesler" üretilir. Hava, gırtlak ve farenksten yani yutaktan geçtikten sonra burun veya ağız boşluğuna girebilir. Oro-nazal süreç sayesinde burun ünsüzleri (m, n) ile diğer sesler ayırt edilebilir hale gelir. Son olarak artikülasyon yani sesletim süreci en bariz olanıdır, yani ağızda gerçekleşir ve konuşma seslerinin çoğunun ayırt edilebildiği süreçtir. Alınan havanın gırtlaktan geçerek artikülatör dediğimiz üst ve alt dudaklar, üst ve alt dişler, dil ve damak tarafından biçimlenerek ses, hece ve konuşma sesine dönüştürülmesidir. Böylece konuşma sesleri, söylendiği yer ve nasıl söylendiği açısından birbirinden ayrılır [8].

Sesler dış dünyayla birçok iletişim kurduğumuz işaretlerdir, elbette fikirlerimiz, ayrıca duygularımız ve kişiliğimizdir. Ses, konuşmanın dokusuna silinmez bir şekilde dokunmuş, konuşmacının amblemidir. Bu anlamda, konuşulan dildeki her bir ifademiz yalnızca kendi mesajını taşımakla kalmaz, aynı zamanda vurgu, ses tonu ve alışılmış ses kalitesiyle belirli toplumsal ya da bölgesel gruplara üyeliğimizin, toplumsal cinsiyetimizin sesli bir beyanıdır. Sesimiz bireysel, fiziksel ve psikolojik kimliğimiz ve anlık ruh halimizin bir aynasıdır. Sesler aynı zamanda bizim için önemli olan ailemizin üyeleri, medya kişilikleri, dostlarımız ve düşmanlarımız gibi diğer insanları çoğu zaman başarılı bir şekilde tanımamızı sağlayan araçlardan biridir. Her ne kadar DNA analizinden elde edilen deliller, seslerden elde edilen delillerden potansiyel olarak çok daha etkili olsa da DNA konuşamaz. Bir suçun planlanması, gerçekleştirilmesi veya itiraf edilmesi kayıt altına alınamaz. Bu kadar açık bir şekilde doğrudan suçlayıcı olamaz. Hızlı bir şekilde ortaya çıkacağı gibi, sesler son derece karmaşık işaretlerdir ve adli-fonetik yöntemin doğasında olan bazı sınırlamalar, kısmen bunların karmaşıklığı ile kullanıldıkları gerçek dünya arasındaki etkileşimin bir sonucudur [9].

Ses belirli bir kişi tarafından çıkarıldığı ve bu şekilde tanınabileceği düşünüldüğünde farklı kişilerce de seslendirmeler yani taklitler olabilir.

Bu yaklaşımda tartışılması gereken üç önemli konu vardır:

- Ses kalitesi ile fonetik kalite arasındaki fark,
- Ses tonu,
- Ses modeli.

Bir noktada, ilk ikisini, bir sesi öncelikle dinleyicinin bakış açısından yani işitme açısından ve modeli de konuşmacının bakış açısından ele almak ve onu karakterize etmek mümkündür. Ses modeli bir dereceye kadar ses kalitesi/fonetik kalite ayrımını varsaydığından öncelikle bu ayrım ses tonuyla birlikte ele alınır. Dilsel, dil dışı ve dil ötesi veya parafonolojik terimleri genellikle sırasıyla fonetik kalite, ses kalitesi ve ses tonunu işaret etme işlevi gören özellikleri nitelendirmek için kullanılır [10].

1.1.2. Ses Kalitesi ve Fonetik Kalitesi

Daha önce de belirttiğimiz gibi, birinin konuşması duyulduğunda öncelikle iki şeyin farkına varılır: söylenenler ve bunu söyleyen kişinin özellikleri. Sesin içeriği ve kaynağına ilişkin bu iki tür yargıya en yakın şekilde karşılık gelen ses yönleri, sırasıyla fonetik kalite ve ses kalitesi olarak adlandırılır [11].

1.1.3. Fonetik Kalite

Fonetik kalite, bir sesin dilsel özelliklerle fonolojik bilgiyi işaret eden yönlerini ifade eder. Daha teknik terimlerle ifade edersek, fonetik kalite, ünlü ve ünsüz ses birimleri gibi dilsel birimlerin tam olarak belirlenmiş gerçekleştirmelerini veya ses birimlerini oluşturur [12].

Fonetik kalite, ünsüzler ve ünlüler gibi bölümsel seslerle sınırlı değildir; aynı zamanda tonlama, ton, vurgu ve ritim gibi bölümler üstü dilsel kategorilere de bağlıdır. Bu nedenle, “HAKARET” ve “hakaret” arasındaki vurgu farkı aynı zamanda fonetik kalitenin bir yönünü oluşturur, çünkü bir fiil ile bir isim arasındaki dilsel farklılığa işaret eder. Birçok fonetikçi, fonetik kalite kavramını, farklı dilleri veya lehçeleri karakterize eden ve bir dili /lehçeyi diğerinden farklı kılan seslerin özelliklerini de kapsayacak şekilde genişletmektedir [13].

1.1.4. Ses Kalitesi

Ses kalitesi, fonetik kalite kaldırıldığında kişinin duyabileceği kalitedir; örneğin birisinin bir kapının arkasında konuştuğunun duyulabildiği ancak aslında söylediklerinin duyulamadığı veya anlaşılamadığı durumlardır [10].

Ses kalitesinin genellikle iki bileşene sahip olduğu anlaşılır: bir organik bileşen ve bir ayar bileşeni. Organik bileşen, sesin, belirli bir konuşmacının ses yolu anatomisi ve fizyolojisi tarafından belirlenen, örneğin ses yolu uzunluğu veya burun boşluğunun hacmi gibi ve üzerinde hiçbir kontrolü olmayan yönlerini ifade eder. Bir konuşmacının anatomik donanımı tipik olarak ses özelliklerinin kapsamına sınırlar getirir; dolayısıyla anatomik olarak belirlenmiş bir özelliğe iyi bir örnek, konuşmacının temel frekans aralığının üst ve alt sınırları olacaktır [14].

Çoğunlukla ortam veya artikülatör ortam olarak adlandırılan ses kalitesinin ikinci bileşeni, bireyin konuşurken benimsediği alışılmış kas ortamlarını ifade eder. Bir konuşmacı alışkanlık olarak hafif yuvarlak dudaklarla, örneğin genizle veya düşük perde aralığıyla konuşabilir. Bu ayar özellikleri kasıtlı olarak benimsendiğinden, konuşmacının kontrolü altında olması açısından ilk bileşenden farklılık göstermektedir.

Ses kalitesi ile fonetik kalite arasındaki fark, fonetik özelliklerin algılanmasındaki farklı rolleri açısından da açıklanabilir. Ses kalitesinin, fonetik kalite rakamının değerlendirilmesi için gerekli arka planı sağladığına dikkat çekilmiştir. Örneğin, bir konuşmacının dilsel perdesi yani bir ton dilinde yüksek ton ile alçak ton arasındaki farkı işaret eden perde yalnızca genel perde aralığının arka planına göre doğru şekilde değerlendirilebilir [10].

Bazen konuşmanın hem ses hem de fonetik kalitesini duyabilmek mümkündür. Dolayısıyla, bir ses dilini konuşan bir erkek ve bir kadın konuşmacının yükselip alçalan tona sahip bir kelime söylemesini dinlediğinizde, fonetik perdenin aynı olduğu duyulabilir [14]. Ayrıca ses kalitesi perdesine dikkat edip, fonetik kalite kimliğine rağmen kadının erkekten farklı, daha yüksek bir ses kalitesi perdesine sahip olduğu da fark edilebilir. Ancak bu, yüksek tonlu şarkı söyleme gibi özel tekniklerin dışında vokal kalitesiyle mümkün değildir. Örneğin hem kadın hem de erkeğin aynı sesli harfi aynı fonetik kalitede söylediğini duymak muhtemeldir, ancak eşlik eden ses kalitesi farkını

cinsiyet dışında formant yani insan ses yolunun akustik rezonansından kaynaklanan geniş frekans bölgesi frekanslarında duymak imkansızdır [15].

1.1.5. Ses tonu

Varsayımsal olarak bazı kişilerin gerçekte ne söylediğini duyamasak da bunu nasıl söylediklerine dair bir şeyler duyabilmemiz akla yatkındır. Örneğin kızgın ya da sızlanıyor gibi görünebilirler. Bu bilgiyi ileten ses özellikleri, ses tonu olarak adlandırılır ve bu nedenle ses tonu, geçici duygusal durumları sözlü olarak işaret ettiğimiz ana yollardan biridir [16].

Ses tonunun, fonetik kalite ve ses kalitesiyle aynı ses boyutlarını paylaşması belki de sürpriz olmayacaktır. Fonetik kalite, ses kalitesi ve ses tonu aynı boyutlarda gerçekleştiğinden, farklılıkları nasıl algıladığımız sorusu ortaya çıkar. Fonetik kalite, ses kalitesi ve ses tonu özellikleri arasındaki farkın öncelikle özelliklerin ne kadar süreyle korunduğuna bağlı olduğu varsayılmaktadır. Ses tonu özellikleri, yarı kalıcı ses kalitesi ile anlık fonetik kalite özellikleri arasında bir süre boyunca korunur [9,10].

1.1.6. İşitme Süreci

Konuşma olayı devamında işitme sürecini başlatır. İşitme, etraftaki seslerin kulak vasıtasıyla algılamaya dönüştüğü süreçtir. Dış ortamdaki ses titreşimlerinin sinir uyarılarına dönüştürülerek beyne iletilmesi ve burada ses olarak yorumlanmasıdır. Sesler, gitarın kopmuş teli gibi titreşen nesneler, daha çok ses dalgaları olarak bilinen ve titreşen hava moleküllerinin basınç darbelerini ürettiğinde meydana gelir.

İşitme sistemi genel olarak üç kısma ayrılır; dış kulak, orta kulak ve iç kulak. Dış kulak, başın dışındaki kulaktan kulak zarına kadar her şeyi içerir. Orta kulak, kulak zarından koklea'ya (kafatasının içindeki salyangoz kabuğu yapısı) kadar olan boşluğu ve yapıları, iç kulak ise içindeki tüm yapılarla birlikte koklea'yı ve sesi beyne taşıyan işitme sinirini anlatır. İşitme sisteminin bu üç bölümünün her biri işitmeye ve işitme kaybına neden olabilecek bazı sorunlara katkıda bulunur.

Dış Kulak: Ses ilk olarak kulak kepçesinden yani kulağın başımızın dışından görünen kısmından dışarı çıkar. Kulak kepçesi ses dalgalarını toplar ve bunları kulak kanalından kulak zarına iletir.

Orta Kulak: Orta kulak, kulak zarı ile koklea'nın oval penceresi arasında kalan kısımdır. Dış taraftan gelen ses dalgaları orta kulağa girdiğinde kulak zarını titreştirir. Kulak zarının arkasında vücuttaki en küçük kemikler olan üç orta kulak kemiğini içeren hava dolu bir boşluk vardır. Kulak zarı titreştiğinde orta kulaktaki kemiklerin de titreşmesine neden olur. Orta kulakta sorun varsa kulak zarının veya orta kulaktaki kemiklerin hareketini kısıtlayabilir ve geçmesi gereken sesin azalmasına neden olabilir.

İç Kulak: İşitme ve denge organımız olan koklea, işitme siniriyle birlikte iç kulak olarak adlandırılır. Ses, bir ucu kokleaya bağlı olan orta kulak kemiklerinin titreşimleriyle iç kulağa geçer. Koklea içindeki minik tüy hücreleri, ses titreşimlerini elektriksel uyarılara dönüştürür ve bu uyarılar, sesi işitme sinirinden beyne taşır ve burada ses ve konuşma olarak yorumlanır [17,18].

Ses, parçacıkların komşu parçacıklara enerji aktarırken ileri geri titreştiği uzunlamasına bir dalga olarak hareket eder. Sesin özelliklerini keşfederken sesi enine bir dalga olarak görselleştirilebilir. Kulak, dalgaların farklı fiziksel özelliklerini algılayıp analiz ederek sesin yüksekliği ve perdesi gibi farklı öznel yönlerini ayırt edebilir. Perde, ses dalgalarının frekansının algılanmasıdır; yani birim zamanda sabit bir noktadan geçen dalga boyu sayısıdır. Frekans genellikle saniye başına devir veya hertz cinsinden ölçülür. Frekans ne kadar yüksek olursa diğer bir deyişle dalga boyu kısa olursa, perde de o kadar yüksek olur. Bir ses dalgasının şiddeti genliğiyle ilgilidir. Daha büyük bir genlik daha yüksek bir sese neden olur. Ses yüksekliği, sesin yoğunluğunun, yani ses dalgalarının kulak zarına uyguladığı basıncın algılanmasıdır. Genlikleri veya güçleri ne kadar büyük olursa, sesin basıncı veya yoğunluğu ve dolayısıyla ses yüksekliği de o kadar büyük olur. İnsan kulağı 1.000 ile 4.000 hertz arasındaki frekanslara en duyarlıdır ve bunları en kolay şekilde algılar, ancak en azından normal genç kulaklar için tüm duyulabilir ses aralığı yaklaşık 20 ila 20.000 hertz arasındadır. Sesin yoğunluğu, sesin göreceli büyüklüğünü logaritmik ölçeğe ifade eden bir birim olan desibel (dB) cinsinden ölçülür ve raporlanır. Başka bir deyişle desibel, herhangi bir sesin yoğunluğunu, kulağın en hassas olduğu aralıktaki bir frekansta, normal insan kulağı tarafından ancak algılanabilen standart bir sesle karşılaştıran bir birimdir. Desibel ölçeğinde, insanın işitme aralığı, 0 dB neredeyse duyulamayan yani en düşük ses seviyesi, 30 dB fısıltılı konuşma, 60 dB normal konuşma,

90 dB trafik gürültüsü ve 130/140 dB ise çok aşırı ses yani insana acı verici hale geldiği seviye olarak kabul edilmektedir [19].

1.1.7. İstenmeyen Seslerin Algılanması

İşitme sürecinde kulak sadece istenen kaynaktan gelen sesleri algılamaz. Bunu yanında istenmeyen birçok ses veya gürültü de aynı zamanda işitilir. Mutlak sessizlik yalnızca boşlukta var olduğundan, aynı anda veya birbiri ardına meydana gelebilecek yararlı veya istenmeyen ses kaynaklarıyla sürekli olarak karşı karşıya kalınır. Basitçe söylemek gerekirse, kulaklarımız bize ulaşan farklı ses mesajlarını kodlar ve beynimiz, dikkat ve hafızayı kullanarak bunları yeniden yapılandırma ve sıralama görevini yerine getirir. Bu, örneğin farklı sesleri tanımamıza, konuşmayı anlamamıza, etrafta başka sesler varken bir konuşmayı takip etmemize veya karmaşık bir sesin farklı öğelerini ayırt etmemize olanak tanır. Her zaman bu sürecin geçerli olması veya seslerin ayırt edilmesi mümkün olmamaktadır. Aynı anda birden fazla kişinin konuşmacı olması ya da çok gürültülü ortamlarda sesleri ayırt etmek çoğu zaman imkânsız hale gelmektedir. Bu soruna geçerli bir çözüm bularak elde edilen sesler birçok alanda önemli rol oynamaktadır. Daha önce belirttiğimiz gibi kontrol sistemleri, güvenlik sistemleri, tıp, haberleşme gibi pek çok alanda sesleri ayırt etmemiz teknolojik açıdan önemli roller üstlenmektedir [20].

Sadece konuşma sesi olarak değil aynı zamanda tıp alanında EKG, Fetal EKG, EEG ve EMG gibi gürültülü işaretlerin ayrıştırılması, müzik enstrümanlarının ya da şarkı sözlerinin birbirinden ayrıştırılması, ortam dinlemelerinde seslerin ve gürültünün ayrıştırılması, haberleşme alanındaki işaretlerin ayrıştırılması ve görüntü ayrıştırma gibi pek çok alanda istenen işaretlerin istenmeyen işaretlerden ayrıştırılması için birçok çalışma yapılmaktadır.

Bu tez çalışmasında kör kaynak ayrıştırma olarak tanımlanan ve literatürde kokteyl parti problemi olarak geçen yöntemle önerilen yöntem kullanılarak birbirine karışmış olan işaretlerin birbirlerinden ayrıştırılması sağlanmıştır. Kör kaynak ayrıştırma işlemine çok amaçlı optimizasyon yöntemi olan SPEA2 yöntemi uygulanmış ve iki amaç fonksiyonu ile ayrıştırma işlemi yapılmıştır. Ayrıca konuşma ve biyomedikal işaretler üzerinde denemeler yapılarak sonuçlar görsel ve nicel olarak yorumlanmıştır. Aşağıda bu tezde kullanılan biyomedikal işaretlerden anne EKG, beyaz Gauss gürültü ve Fetal EKG işaretleri hakkında bilgi verilmiştir.

1.2. EKG İşareti

İnsan sağlığı açısından ve erken tedavi için ölçülen biyomedikal işaretler gürültüden ayrıştırılmış şekilde elde edilmelidir. Bu tez kapsamında önerilen yöntem ile birbirlerine karıştırılmış anne EKG, beyaz Gauss gürültü ve Fetal EKG işaretlerinin ayrıştırılması sağlanmıştır.

EKG, insan kalbinin farklı kalp rahatsızlıkları hakkında önemli bilgiler vermektedir. EKG işaretinin analizi, yaşamı tehdit eden kalp durumlarını tespit etmek ve önlemek için araştırma topluluğunun ana hedefi olmuştur. Geleneksel işaret işleme yöntemleri, makine öğrenimi ve bunun derin öğrenme gibi alt dalları, EKG işaretini analiz etmek ve sınıflandırmak ve esas olarak kalp rahatsızlıkların ve aritmilerin erken tespiti ve tedavisine yönelik uygulamalar geliştirmek için popüler tekniklerdir [21–23].


Elektrokardiyografi, bir asırdan fazla bir süre önce Hollandalı fizyolog Willem Einthoven tarafından icat edilmiştir. EKG, insan kalbinin elektriksel aktivitesini gösterir ve EKG işaret morfolojileri, farklı kalp koşullarına bağlı olarak çeşitli aritmi türleri hakkında bilgi sağlar. EKG dalga grafiğinden aritminin hızlı ve doğru bir şekilde tanımlanması, potansiyel olarak birçok hayat kurtarabilir ve dünya çapında sağlık bakım maliyetleri açısından çok fazla tasarruf sağlayabilir. Bu bizi, EKG analizinin ayrıntılı bir incelemesini yapmaya ve EKG işaret analizinin her aşamasının akışını ve önemini daha fazla açıklığa kavuşturmak ve kategorize etmek için EKG işaretlerinin sağlıklı bir şekilde elde edilmesine motive etmiştir. Etkin EKG işaret analizinin halk sağlığı ve ekonomi üzerinde sunduğu muazzam etkiyle birlikte, donanım ve yazılım araçlarının yanı sıra gerçek zamanlı izlemenin yanı sıra, taşınabilir ve giyilebilir cihazlar kullanarak EKG işaretini aşamalara dayalı bir süreç halinde analiz etmek için çeşitli uygulamalar sunulmuştur. Fakat tüm bu çalışmaların temelinde EKG işaretinin doğru yorumlanabilmesi için ilgili kişiden gürültüsüz ve en az hata oranı ile EKG işaretinin elde edilmesi gerekir.

Elektriksel aktivite, kalp dokuları tarafından üretilen ve EKG elektrotlarının elektrotları aracılığıyla toplanan küçük potansiyel biçimindedir. Minyatür işaretler güçlendirilir ve EKG olarak kaydedilir. Elektriksel aktivite normalde Sinüs Düğümün (SA düğümü) otomatiklik sergileyen özel hücreleri tarafından kendiliğinden üretilir. İmpulsun oluşması, normal dinlenme durumunda dış yüzeyi daha pozitif yüklü olan kalp hücre

duvarının elektriksel polaritesinin tersine çevrilmesinden kaynaklanmaktadır. Bu tersine çevirme, hücre duvarının dış yüzeyinde, bitişik kalp dokusuna bir uyarı olarak yayılan olumsuzlukları üretmektedir [21,22].

1.2.1. EKG Dalga Formları

Vücut yüzeyinde ölçülen EKG, kalp kasının aşamalı aktivasyonunun bir sonucudur ve Şekil 1.2’de gösterilen PQRST kompleksi ile sonuçlanır. Bu harf gösterimi ilk kez 1895 yılında Einthoven tarafından icat edilmiştir [24–26].



Şekil 1.2. Normal bir EKG periyodu [27]

Farklı EKG dalgaları alfabetik sırayla P, QRS ve TU dalgaları olarak adlandırılır. Şekilleri, genlikleri ve zaman aralıkları sağlık ve kalbin durumu hakkında önemli bilgiler vermektedir. P dalgası atriyal depolarizasyonu yansıtır. QRS kompleksi ventriküler depolarizasyonu yansıtır. Ventriküllerin repolarizasyonu TU dalgası tarafından yansıtılır. Elektrokardiyograf, depolarizasyon akımı ilgili elektrot telinin pozitif kutbuna doğru yayıldığında EKG elektrot teli için pozitif bir dalga kaydeder. Buna karşılık akımın kutuptan uzağa yayılması durumunda negatif bir dalga ortaya çıkmaktadır.

Sağlıklı bir bireyden ölçülen EKG işaretine ait genlik ve zaman değerleri Tablo 1.1’de gösterilmiştir.

Tablo 1.1. EKG işaretine ait genlik ve zaman parametresi

EKG Dalgası	Genlik Değerleri	EKG Aralığı	Süresi (sn)
P	0.25 mV	P-R	0.12-0.20 sn
R	1.6 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

1.2.2. Biyomedikal İşaretlerde Gürültü Giderme

EKG analizi ve sınıflandırması, birincil giriş olarak önceden kaydedilmiş veya gerçek zamanlı EKG işaretlerini gerektirir. Her iki durumda da EKG verisi alımı, sensörlerin ve kabloların vücuda takılmasıyla sağlanır. EKG işaretinin alınması sırasında, orijinal işarette birlikte gürültü de yakalanır ve bu EKG'nin kalitesini ve sınıflandırmasını önemli ölçüde etkiler. Gürültünün giderilmesine ve farklı anormallikleri doğru bir şekilde tanımlamak için EKG işaretinden gürültüyü çıkarmak araştırmacıların en büyük ilgi alanlarından birini oluşturmuştur. EKG işaretinin gürültüsünü gidermeye yönelik geleneksel yöntemler, kaliteyi doğrulamak için örnek entropili bant geçiren filtrelerin (0,05-45Hz) uygulanmasını içerir. Gürültü, sağlık durumunun değerlendirilmesinde hayati önem taşıyan yanlış alarmlara neden olabilir. Gürültü herhangi bir biçimde olabilir ancak iki ana biçimde kategorize edilebilir: dahili gömülü gürültü ve harici gürültü. Dış gürültü, elektrik hattı gürültüsü veya başka herhangi bir beyaz gürültü olabilir. EKG analizinde gürültü genellikle veri kaynaklarından veri alındıktan sonra giderilir. Gürültülü işareti temizlemenin birçok farklı yöntemi vardır. EKG işaretinin kalitesi Yapısal Benzerlik İndeksi Ölçüsü (SSIM, Structural Similarity Index Measure) ile kontrol edilebilir ve işaret-gürültü oranı gibi ölçümlerle değerlendirilebilir [28]. EKG gürültü giderme aşamasında araştırmacılar tarafından bildirilen diğer performans ölçümleri arasında Doğruluk (acc), Ortalama Kare Hatası (mse), Ortalama Karekök Hatası (rsme) veya Yakınsama Oranı yer almaktadır [22]. Bu tezde gürültü giderme işlemi MO-BSS yöntemleri yardımıyla gürültü ayrıştırma yapılacak ve sonuçlar SNR cinsinden değerlendirilecektir.

1.2.3. Fetal EKG

Fetal elektrokardiyogram ilk kez 1906 yılında M. Cremer tarafından gözlemlenmiştir [29]. Bu alandaki ilk çalışmalar, fetal işaretlerin genliğinin çok düşük olması nedeniyle sınırlı olan o zamanın galvanometrik cihazları kullanılarak gerçekleştirilmiştir. Ölçüm ve amplifikasyon teknikleri geliştikçe fetal elektrokardiyografi daha uygulanabilir ve popüler hale gelmiştir [30,31]. 1960'da fetal EKG için farklı yöntemler uygulansa da istenen seviyede işaretler elde edilememiştir [32]. Sonrasında bilgisayar bilimi ve işaret işleme tekniklerindeki gelişmelerle birlikte, fetal R dalgası tespiti ve abdominal elektrotlardan annenin kalp girişiminin iptali için otomatik işaret işleme ve uyarlamalı filtreleme teknikleri kullanılmıştır [33]. Bununla birlikte, teknikler hiçbir zaman yaklaşık fetal kalp hızı tahminlerinden daha fazlasını sağlayamamış ve fetal EKG analizi konusu, o zamandan beri hem biyomedikal hem de işaret işleme toplulukları için zorlu bir sorun olarak kabul edilmiştir. 2000 yılına kadar fetal EKG işaretlerinden sağlıklı bir şekilde veri elde edilmesi pek sağlanamamıştır. Yaklaşık son 20 yılda özellikle fetal Manyetokardiyografiye (MCG, Magnetocardiography) olan ilgi yeniden artmıştır. Bu kısmen yeni düşük gürültülü ve düşük fiyatlı ölçüm ve dijitalleşme sistemlerinin bir sonucu olarak, kısmen de bir dizi işaret işleme ve uyarlanabilir filtreleme tekniklerindeki gelişmelere bağlanmıştır.

1.2.4. Fetal Kalp Gelişimi

Kalp, fetüste geliştirilen ilk organlardan biridir ve hamileliğin çok erken evrelerinde önemli miktarda büyümeye uğrar. Bu gelişimin en kritik dönemi, basit kalp tüpünün dört odacıklı kalp şeklini aldığı döllenmeden sonraki 3 ile 7'nci hafta arasındaki süreçtir.

Kalbin yaşamın 3'üncü haftasında atmaya başladığına ve kendi kanını, kendi kan grubuyla ayrı bir kapalı dolaşım sistemi aracılığıyla pompaladığına inanılıyor. Kısa bir süre sonra göz, kulak ve solunum sistemleri oluşmaya başlar. Fetal kalp daha sonra 7 ile 9'uncu haftalarda ultrason görüntüleme ile harici olarak izlenebilir; ancak bu adımda yalnızca belirsiz görüntüler kaydedilebilir. Kalp dalga formları ve kalp atış hızının atımdan atıma değişkenliği ultrason görüntülemeye ölçülemez. 20'nci haftada, fetal kalp atışı, dakikada yaklaşık 120-160 atışla amplifikasyon olmadan duyulabilir, ancak kalp atış hızının üzerindeki oskültasyondan (stetoskop ile dinleme) çok az ilave tanı bilgisi elde edilebilir [24].

Bu nedenle kalp aktivitesinin morfolojik bilgisini içeren fetal EKG ve MCG büyük ilgi görmüştür. Bu işaretler, gebe kaldıktan sonraki 18 ile 20'nci haftalar gibi erken bir dönemde annenin karnından kaydedilebilir [34].

Hamileliğin sonlarına doğru, yaklaşık 26'ncı haftada fetüs nefes alıp vermeye başlar. Elbette ki fetüs bu hareketle hava solumuyor ve kanı oksijenlendirmiyor. Bunun yüzey aktif madde üretimine yardımcı olduğu ve doğumdan önce solunum sistemini çalıştırdığı düşünülmektedir. Her ne kadar fetüs 23-24 haftada rahim dışında yaşayabiliyor olsa da doğumda bu erken kabul edilir ve normal gebelik süresi yaklaşık 40 haftadır. Aslında 23 haftada rahim dışında yaşama şansı yalnızca %15'tir ve yaşama olasılığı 24 haftada %56'ya, 25 haftada ise %79'a yükselir [35].

Annenin karın bölmelerindeki deri ve deri altı yağının iletkenliği de zayıftır; kas dokusundan yaklaşık on kat daha küçüktür. Bu nedenle, yüzey elektrotları ile iç dokuların arayüzü olan bu iki katmanın, kaydedilen fetal EKG üzerinde önemli bir etkisi vardır. Bu farklı doku ve katmanların tümü, fetal kalp işaretlerinin annenin vücut yüzeyine kadar yayıldığı, hacim iletkeni olarak adlandırılan bir yapı oluşturur. Bu hacim iletkeni sabit bir iletken değildir ve elektrik iletkenliği ve geometrik şekli gebelik boyunca sürekli değişmektedir. Spesifik olarak, EKG ve MCG'nin harici elektrotlardan kaydedilebildiği gebeliğin ikinci yarısında yani 20'nci haftalar, amniyotik sıvının, plasentanın ve fetüsün hacminin arttığı bilinmektedir. İletkenliği çok düşük olan bebeğin cildindeki ilk koruma tabakası gebeliğin 28'inci ve 32'nci haftaları arasında oluşur. Fetüse neredeyse elektriksel olarak koruma sağlar ve fetal yüzey EKG'sinin kaydedilmesini çok zorlaştırır. Ancak normal gebeliklerde veya prematüre olmayan doğumlarda bu tabaka gebeliğin 37 ile 38'inci haftalarında yavaş yavaş erir [36,37].

Fetal kalbin mekanik işlevi yetişkin kalbinden farklı olsa da atıştan atıma elektriksel aktivitesi oldukça benzerdir. Kalbin dalga benzeri pompalama hareketi, kalbin kasılıp gevşemesinden sorumlu olan ve kalp kasını oluşturan tabaka boyunca dağıtılan ve onun düzenli kasılmasını ve gevşemesini koordine eden bir sinir lifleri ağı tarafından kontrol edilir.

Morfolojik olarak yetişkinler ve fetüsler oldukça benzer EKG modellerine sahiptir; ancak fetal komplekslerin göreceli genlikleri gebelik boyunca ve hatta doğumdan sonra önemli değişikliklere uğrar. En önemli değişiklik fetüsler ve yenidoğanlar için oldukça zayıf olan

T dalgalarıyla ilgilidir [34]. Şu anda fetal EKG analizi klinik alanda neredeyse tamamen kalp atış hızını ve ilişkili değişkenliği analiz etmek için kullanılmaktadır.

1.2.5. EKG İşaretlerin Ölçümü ve Önemi

Gözlemlenen işaretleri ayırtmak ya da gürültülü kısımlarını ayırmak için doğrusal veya doğrusal olmayan dönüşümler kullanılır. Elbette doğrusal olmayan dönüşümler daha çok geçicidir ve işaretin istenen ve istenmeyen kısımları hakkında bazı ön bilgiler gerektirmektedir. [38] nolu kaynakta doğrusal olmayan yöntemler kullanılarak bir dizi anneye ait EKG'nin iptali ve fetal EKG'nin ise iyileştirme yöntemleri geliştirilmiştir. Bu yöntemler, işaretin durum-uzay gösterimini oluşturmak için gürültülü işaret ve onun gecikmeli versiyonlarını kullanmayı, geleneksel veya Temel Bileşen Analizi (PCA, Principal Component Analysis), uygulamaları kullanarak durum-uzay yörüngesini yumuşatmayı ve örnekleri zaman-alanı gösterimine geri aktarmayı içerir. Bu yöntemler tek bir anne karın kanalına kadar uygulanabilmesi açısından oldukça caziptir. Bununla birlikte, gerekli zaman gecikmelerinin seçimi kalp işaretlerinin atımlar arası önemli değişimleri, durum-uzayı yumuşatma sırasında silinebilir. Üstelik doğrusal yöntemlerle karşılaştırıldığında daha yüksek hesaplama karmaşıklığına sahiptirler ve gürültü istatistikleri değiştikçe doğru yerleştirme boyutu da değişebilir.

Daha önceki çalışmalarda, çok kanallı ayırtma yöntemleri, gözlemlenen işaretlere oldukça 'körü körüne' yaygın olarak uygulanmıştır ve genellikle fetal bileşenlerin ayrı bileşenler olarak çıkarılmasının garantisi olmadığı anlaşılmıştır. Bu nedenle önemli bir konu, uygun ön işleme ve işaret/gürültü karışımları hakkındaki ön bilgilerin kullanılması yoluyla fetal bileşenlerin farklı yöntemler ile elde edilme olasılığının artırılması ve ayrıca elde edilen işaret bileşen kalitesinin iyileştirilmesidir. Bu, hatasız fetal EKG çıkarma yöntemleri geliştirmek için gerekli bir adımı oluşturur.

İlgili diğer bir konu da çok kanallı kaynak ayırma teknikleriyle çıkarılan bileşenler için fizyolojik yorumların bulunmasıdır. Bu yöntemler genellikle istatistiksel bağımsızlık gibi oldukça soyut istatistiksel kriterlerin en üst düzeye çıkarılmasına dayansa da gerçek verilere uygulandığında ortaya çıkan bileşenlerin fiziksel olarak neye karşılık geldiği çok açık değildir. Kalbin noktasal bir kaynak değil, dağıtılmış bir kaynak olduğu dikkate alındığında, kalp işaretleri açısından bu konu daha da önem kazanmaktadır.

Yetişkin klinik elektrokardiyografisi, işaret işleme teknikleri ve hızlı dijital işlemcilerdeki önemli ilerlemelere rağmen, fetal EKG'lerin analizi henüz başlangıç aşamasındadır. Bu kısmen standart veri tabanlarının bulunmamasından, kısmen de fetal EKG'nin anne EKG'sine kıyasla nispeten düşük işaret-gürültü oranına bağlı olmasından veya fetal kalp ile ölçüm elektrotları arasındaki çeşitli ortamlardan ve fetal kalbin daha küçük olmasından ve kısmen fetal kalp fonksiyonu ve gelişimine ilişkin klinik bilginin daha az olmasından kaynaklanmaktadır.

Kalp kusurları en sık görülen doğum kusurları arasındadır ve doğum kusurlarına bağlı ölümlerin önde gelen nedenidir. Kusur, bebeğin doğumdan sonra uzun yıllar sağlıklı görünmesine neden olacak kadar hafif olabileceği gibi, yaşamını doğrudan tehlikeye sokacak kadar ciddi de olabilir. Doğuştan gelen kalp kusurları, kalbin olduğu hamileliğin erken evrelerinde ortaya çıkar ve kalbin herhangi bir bölümünü veya işlevini etkileyebilir. Genetik bir sendrom, kalıtsal bir bozukluk veya enfeksiyonlar veya ilaç kötüye kullanımı gibi çevresel faktörler nedeniyle kalp atış bozukluğu ortaya çıkabilir. Ancak doğum eylemi dışında, fetal EKG spesifik yapısal bozuklukların görüntülenmesinde etkili bir araç olduğu kanıtlanmamıştır. Bunun yerine fetal EKG, göbek kordonunu boğan spesifik fetal pozisyon nedeniyle genel kansızlık gibi daha global sorunlarla sınırlandırılmıştır [39,40].

Fetal kalp hızı izlemenin ortaya çıkışından bu yana, doğum sırasında fetal izlemede klinik olarak anlamlı bir ilerleme kaydedilmemiştir. Ayrıca, Amerika Birleşik Devletleri'ndeki doğum olaylarının %85'inden fazlasında sürekli fetal izleme kullanılmaktadır ve bakım standardını temsil etmektedir. Günümüzde fetal izleme tamamen fetal kalp hızına dayanmaktadır ve hem çocukların hem de yetişkinlerin kardiyak değerlendirmesinin temel taşı olan fetal EKG dalga biçimi özelliklerini içermemektedir. Bu en kritik bilgi kaynağının klinik uygulamadan hariç tutulmasının birincil nedeni, fetal EKG'yi güvenilir bir şekilde ölçecek teknolojinin büyük ölçüde mevcut olmamasıdır [41].

Çoğu kalp kusuru, elektrokardiyografi ile kaydedilen ve geleneksel ultrasonik yöntemlerle karşılaştırıldığında çok daha fazla bilgi içerdiğine inanılan kalp elektrik işaretlerinin morfolojisinde bazı belirtileri vardır. Ancak hiçbir işaret işleme tekniği, annenin vücut yüzeyinden kaydedilen fetal EKG'nin düşük SNR nedeniyle anne karnına yerleştirilen elektrotlardan güvenilir bir şekilde bozulmamış bir fetal EKG işareti

iletememiştir. Bu nedenle fetal elektrokardiyografinin uygulanması neredeyse kalp atışı analizi ve doğum sırasında fetal kafa derisine bir elektrot yerleştirilmesi ile sınırlı olmuştur. Şu anda fetal EKG dalga formunu güvenilir bir şekilde ölçmenin tek yolu bu olsa da, yalnızca sınırlı klinik koşullar altında gerçekleştirilebilir ve fetüsün güvenliği için risk oluşturur [24,42].

1.3. Beyaz Gauss Gürültüsü

Beyaz Gauss gürültüsü, düz frekans spektrumuna sahip bir tür rastgele sinyal veya gürültüyü ifade eder. Bu, tüm frekanslarda eşit güce sahip olduğu anlamına gelir. "Gauss" terimi, Gauss veya normal dağılıma uyan gürültünün genliğinin olasılık dağılımını ifade etmektedir. Pratik anlamda, beyaz Gauss gürültüsü genellikle elektronik iletişim kanalları, elektronik bileşenler ve çevresel gürültü gibi sinyal ve sistemlerdeki çeşitli rastgele bozulma türlerini modellemek için kullanılır.


1.4. Kokteyl Parti Problemi

Kokteyl parti problemi, kişinin kalabalık ve gürültülü bir ortamda işitsel dikkatini belirli seslere odaklayıp, diğer istemediği sesleri filtreleyerek duyma dışında bırakma sürecidir [43]. Kör kaynak ayrımı ilk olarak 1982'de Bernard Ans, Jeanny Hérault ve Christian Jutten ile sinir bilimci Jean-Pierre Roll arasında omurgalılarda hareket kodunun çözülmesi hakkında yapılan basit bir tartışmayla başlamıştır [20]. İşaretleri bağımsız bir şekilde ayrıştırma fikri ise ilk olarak Jutten ve Hérault tarafından 1991 yılında ortaya çıkmıştır [1].

İnsanlar, birden fazla konuşmacının ve arka plan gürültülerinin olduğu durumlarda akustik arka planı maskeleyerek işitsel dikkati belirli bir sese odaklama konusunda dikkate değer bir yeteneğe sahiptir. Buna kokteyl parti etkisi veya kokteyl parti sorunu denir. Bu olağanüstü yetenek üç aşamadan oluşur: düşük seviyeli uyaran niteliklerinin doğru şekilde işlenmesi, işitsel bilgilerin tutarlı seslere ayrılması ve daha yüksek seviyeli işlemeyi kolaylaştırmak için diğerlerinin hariç tutulmasıyla bir sese seçici olarak katılmaktır. Konuşma ayırma, insanın ilk iki aşama olan doğru işleme ve ayırma yeteneğini taklit ederek bu kokteyl parti sorununu çözmeyi amaçlamaktadır [20].

Kokteyl parti problemi Şekil 1.3'te üç sesin karışım modeli olarak gösterilmektedir. Genel olarak bağımsız kişilerden gelen ses dalgalarının üst üste bindirildiği ve uzaysal

olarak ayrılmış ancak diğer açılardan aynı veya farklı olan mikrofonda biraz farklı faz ve hacimlere sahip karışık kaynak vektörü olarak kaydedildiği bu paradigmayı göstermektedir [44]. Bu problemlerde kaynak işaretlerin bilinmeyen karışım ve filtreleme işlemlerine göre matematiksel ve fiziksel modelleme olarak farklı yöntemler uygulanabilir.



Şekil 1.3. Kokteyl parti problemi


CPP’de, en az iki konuşmacının aynı ortamda rastgele olarak birbirleri ile konuştuğu ve bu konuşmaların en az iki mikrofona kaydedildiği düşünülür. Buradaki amaç, S_1 ve S_2 kaynakları olarak konuşmacıların sesleri ve a_{ij} karışım işlemini yani ortamın özelliğini bilmeden, sensörler ile kaydedilmiş x_1 ve x_2 karışım işaretlerinden her bir kaynak işaretlerin yeniden oluşturulmasıdır [45].

Karışmış halde bulunan/kaydedilmiş işaretlerin birbirinden ayrıştırılması sürecinde BSS yöntemi uygulanmaktadır. Bu süreçte işaret kaynaklarının ve bu kaynakların birbirine nasıl karıştığı hakkında çok az bilgi ya da hiçbir bilgi olmaksızın gözlemlenen istatistiksel olarak bağımsız karışımlardan her bir kaynak işaretin ayrıştırılması sağlanmaktadır [43,44].

Kör terimi, karıştırma işlemi veya mevcut kaynak işaretleri hakkında özel bir bilginin bulunmadığı anlamına gelir. BSS’de doğrusal olarak karışık gözlemlerin kökenine ilişkin herhangi bir ön bilgi eksikliği, tüm kaynaklar arasında istatistiksel olarak güçlü ancak

fiziksel olarak makul bir istatistiksel bağımsızlık varsayımı ile iyi bir şekilde telafi edilebilir [46–48]. Doğrusal karıştırmaya ilişkin bu hipotez, doğal veya tipik bir akustik ortam içindeki işaret yayılımı açısından gerçekçi olmayabilir. Yankılanan ortamda her mikrofona, kaynakların çoklu zaman gecikmeli versiyonlarının ağırlıklı toplamını yakalar; bu aslında her işaretin odanın veya mekânın akustik transfer fonksiyonuyla evrişimidir. Buna göre BSS'nin görevi, yalnızca mikrofona dizisinin her bir giriş kanalında yakalanan gözlemlenen evrişimli karışımlardan elde edilen bilgilerin birleştirilmesine dayanarak bilinmeyen oda transfer fonksiyonlarını veya bunların tersini tahmin etmeye eşdeğer hale gelmektedir [43].

BSS'nin bazı uygulama alanları arasında biyomedikal işaret analizi, jeofizik veri işleme, veri madenciliği, kablosuz iletişim ve sensör dizisi işleme yer almaktadır [49]. Kör Kaynak Ayırıştırma sorunu Şekil 1.4'te gösterildiği gibi bir dizi kaynak süreci, bir karışım modeli ve bir dizi varsayımla tanımlanır.



Şekil 1.4. Kör kaynak ayırıştırma yönteminin blok diyagramı

Genel olarak bir partide m karışmış sensör işareti $x_i(t)$ ($i = 1, 2, \dots, m$), n tane sıfır ortalamalı, birbirinden bağımsız ve gürültü işaretlerinin doğrusal karışımı olarak matematiksel gösterimi;

$$x_i(t) = \sum_{j=1}^n a_{ij} s_j(t) + v_i(t) \quad (i = 1, 2, \dots, m) \quad (1.1)$$

ile ifade edilir. Bu denklemden $x_i(t)$ sensörler tarafından alınan karışık işaretleri, $s_j(t)$ kaynak işaretlerini, $v_i(t)$ i 'inci sensörün gözlem gürültüsünü belirtir. Bu ifadeler

doğrultusunda Denklem (1.1), bir matris olarak Denklem (1.2)'de gösterildiği gibi ifade edilebilir.

$$x(t) = As(t) + v(t) \quad (1.2)$$

Belirtilen bu denklemde $x(t)$ ve $s(t)$ birer vektör olarak şu şekilde ifade edilir [50].

$$x(t) = [x_1(t), x_2(t), \dots, x_m(t)]^T \quad (1.3)$$

$$s(t) = [s_1(t), s_2(t), \dots, s_n(t)]^T \quad (1.4)$$

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 işaretler, kaynakların doğrusal karışımı olarak elde edilmektedir. Uygulamada bu kaynaklar sıfır ortalamalı, zamanla değişen, birbirlerine göre bağımsız veya tam olarak bağımsız oldukları ve sayılarının bilinmediği varsayılır. Buradaki amaç kör kaynak ayrıştırmada sadece sensör işaretleri $x(t)$ yardımıyla ve uygun bir yöntem ile kaynak işaretlerinin tahmin edilmesidir. BSS'nin blok diyagramında görüldüğü gibi rastgele değişken olarak verilen kaynak işaretlerinin ($s(t)$) tahmini olan $y(t)$ işaretlerinin bulunması için;

$$s_j(t) = y_j(t) = \sum_{i=1}^m w_{ji} x_i(t) \quad (j = 1, 2, \dots, n) \quad (1.5)$$

$$y(t) = Wx(t) \quad (1.6)$$

denklemini kullanılır. Denklemde W matrisi kullanılarak doğrusal bir dönüşüm ile $y(t)$ tahmini işaretler bulunur. Dönüşüm ile bulunan işaretlerin mümkün olduğunca birbirlerinden bağımsız oldukları varsayılır. BSS'de gerçek kaynak işaretleri bağımsız olmasalar bile bulunmaya çalışılır. Bu işlemi yaparken sadece ikinci dereceden istatistik kullanılır [51,52]. İkinci dereceden istatistik kaynakların ilintisiz olduklarını varsayar. Ayrıca ikinci dereceden istatistik birden fazla Gauss işareti üzerine uygulanabilir.

İşaret işleme kapsamında kör kaynak ayrıştırmanın diğer alanlardaki uygulamalarından bazıları şunlardır:

Makine izleme: İşaret ayırma, akustik özelliği ile hasar esnasında mekanik bir aygıt tarafınca yayılan ses ve potansiyel olarak normal çalışma parçaları da dahil olmak üzere

diğer kaynakların karışımından oluşan bir ortamdan izole ederek muhtemel mekanik arızaları belirlemek için kullanılabilir.

Tıbbi teşhis: Birçok tıbbi aygıt çoğunlukla insan vücudundan gelen birçok işareti mesela EEG işaretleri veya EKG işaretlerini elde etmek için kullanılır. Bunun sonucunda mevcut olabilecek belirli bir bedensel fonksiyona/uyaranlara bağlanabilecek sensörler yardımıyla alınan işaretler hasta teşhisi ve tedavisi için ayrıştırılır. İşaretlerin elde edilmesinde problemlerden, kişinin kas hareketlerinden yada ölçüm sırasında çevresel nedenlerden dolayı gürültü karışabilmektedir. Bu sayede sistemdeki gürültünün etkisinden kaynaklanan yanlış teşhisleri önleyebilmek amacıyla kullanılabilir.

Müzik Performansı: Bu, genellikle müzik performanslarının kaydedilmesinde, yalnızca kayıtlardaki belirli enstrüman seslerine ve şarkı sözlerine odaklanmak için sıklıkla kullanılabilen uygulamaların başında gelmektedir. Bu bilhassa belirli bir enstrümanın, örneğin normalden biraz daha yüksek veya düşük olması gereken bir enstrüman aletinin sesini yükseltmek veya farklı bir amaç için kullanılabilir.

Sismik İzleme: Sismik aktivitenin uzun vadeli tahmini çoğu zaman dünyanın tektonik plakalarının hareketlerine ilişkin prensipte yapılabilecek bir şeydir. Ancak kısa vadeli tahmin sorunlar oluşturabilir. Genellikle bir depremi karakterize eden şeylerden biri, akustik dalgalar ve bunların iyonosfer boyunca nasıl yayıldıkları hakkında elde edilen farklı işaretlerdir. Bu işaretleri izole etmek için kör kaynak ayırma teknikleri kullanılabilir. Böylece depremin kısa bir süre önce tahmin edilmesi sağlanabilmekte ve bu alanda çalışmalar devam etmektedir [53].

1.5. Ses İşleme

Sesin işlenmesi birçok farklı uygulamayı içerir. Bu bölümde tez için ses işlemenin ilgili kısımları basit bir şekilde sunulmuş ve açıklanmıştır. Yöntemlerin uygulanmasını ve sonuçları anlamak için ses işlemeyle ilgili temel bir anlayış gereklidir. Basitçe söylemek gerekirse, ses işleme, onu iyileştirmek için bir ses işareti üzerinde bazı uygulamaları gerektirir. Ses işleme, gürültüyü filtreleyerek, arka plan gürültüsünü baskılayarak veya işareti sezgisel bir şekilde temsil ederek gerçekleştirilebilir.

Uzak mikrofonlarla kaydedilen konuşma işaretleri, hoparlörden, gürültüden ve yankılanmadan dolayı kaçınılmaz olarak bozulur; bu da yakalanan konuşma işaretlerinin algısal kalitesini ciddi şekilde bozmaktadır.

Konuşma ve diğer birçok doğal ses kaynağıyla ilgili dikkate değer olaylardan biri, enerjinin zaman-frekans düzleminde yayılması ve eşzamanlı kaynakların bu şekilde temsil edildiğinde sıklıkla yoğun bir şekilde serpiştirilmiş olmasıdır. Bu nedenle, ses kaynakları genellikle çok sayıda frekans ürettiğinden ve zamanla değiştiğinden, yalnızca çevresel frekans ayrışımına dayalı olarak çoğunlukla istenen performans sağlanamayabilir.


Olası bir çözüm, kaynakların karakteristik değerlere sahip olabileceği bir özellik uzayına yansıtma yapmaktır. Ses yüksekliği, ses perdesi veya tını gibi algısal boyutlar iyi adaylar gibi görünmektedir ve başkaları tarafından yapılan çalışmaların sonuçları, işitsel algısal organizasyonun büyük ölçüde bu gibi boyutlardaki sesler arasındaki benzerlik temelinde gerçekleştiğini göstermektedir. Bu nedenle algısal olarak benzer olan sesler aynı kaynağa atanma eğilimindedir. Bu, kaynakların eşzamanlı olmasına rağmen ilgili özelliklerin tahmin edilebileceğini ve sorunun, ses özelliklerinin zaman içinde uygun şekilde bağlanarak kaynaklara atanması yani akış sorunu veya akış ayrımı olduğunu varsayar. Her ne kadar öznelitliklerin tahmini ile bunların kaynak tahminleri halinde gruplandırılması arasında etkileşimler olsa da, çoğu durumda bunlar büyük ölçüde ayrılabilir problemler olabilir [54,55].

BSS kullanılırken çoğu zaman birçok farklı Sonlu Dürtü Yanıtlı (FIR, Finite Impulse Response) filtrenin kullanılması gerekir ve gerçekçi senaryolarda binlerce filtre katsayısı bulunmalıdır. Geleneksel uyarlanabilir filtreleme teknikleri yalnızca zaman alanında çalışmayı seçer; bu durumda filtre güncellemeleri örnek bazında gerçekleştirilir. Bu gibi durumlarda algoritmanın karmaşıklığı engelleyici hale gelebilir. Bunun yerine, aşırı hesaplama gereksinimlerini azaltmak ve karmaşıklıktan önemli ölçüde tasarruf etme potansiyeli elde etmek için, Hızlı Fourier Dönüşümünün (FFT, Fast Fourier Transform) verimli kullanımına güvenerek çerçeve tabanlı veya diğer adıyla blok tabanlı uygulamalarda kullanılabilir [43].

2. BÖLÜM

ÇOK AMAÇLI OPTİMİZASYON ALGORİTMALARININ KÖR KAYNAK AYRIŞTIRMADA KULLANILMASI

Çok Amaçlı Optimizasyon Algoritmalarının (MOOA, Multi-Objective Optimization Algorithm) BSS problemleri çözümünde kullanımı 2016 yılına dayanmaktadır [5,56]. Bu yöntemlerin karışmış işaretlerin ayrıştırılmasındaki kullanımı ile literatürde çok amaçlı BSS olarak adlandırılmaktadır. Evrimsel Algoritma (EA, Evolutionary Algorithm) olarak literatürde kullanılan SPEA2 yöntemi BSS yönteminde kullanılarak karışmış işaretler ayrıştırılmıştır. Tez çalışmasının bu bölümünde çok amaçlı optimizasyon ve SPEA2 yöntemi ile ilgili genel bilgiler açıklandıktan sonra literatürdeki çok amaçlı BSS algoritmalarının tasarım ve performansları analiz edilmiştir. Şekil 2.1’de çok amaçlı BSS modelinin blok diyagramı verilmiştir. Ayrıca, literatürdeki çok amaçlı BSS metotları ile ilgili bazı çıkarımlar ve yorumlar yapılmış ve önerilen yöntemlerin hesaplama karmaşıklıkları özetlenmiştir.



Şekil 2.1. Çok amaçlı kör kaynak ayrıştırma blok diyagramı

2.1. Çok Amaçlı Optimizasyon Algoritmaları

Problemi çözmek için farklı MOO yöntemleri vardır. Bu algoritmalar evrimsel algoritmaların ve optimizasyon yaklaşımlarının geliştirilmesine büyük katkılar sağlamaktadır. Aşağıda en yaygın kullanılan yöntemlerden kısaca bahsedilmiştir [57].

(1) NSGAI: Yüksek hesaplama karmaşıklığını, seçkinlik eksikliğini ve Baskılanmayanları Sıralayan Genetik Algoritma'nın (NSGA, Non-Dominated Sorting Genetic Algorithm) paylaşım parametresinin belirlenmesini çözmek için önerilmiştir. NSGAI'de, ebeveyn popülasyonu ve yavru popülasyonunu birleştirmek için bir çiftleşme havuzu oluşturularak bir seçim operatörü tasarlanmıştır. Algoritmada baskın olmayan sıralama ve kalabalıklaşma mesafesi sıralaması da uygulanmaktadır [58].

(2) PAES: Pareto-Arşivlenmiş Evrim Strateji (PAES, Pareto Archived Evolution Strategy) basit bir evrimsel algoritmadır. Algoritma, bir kişilik bir popülasyondan yerel aramayı kullanan ancak mevcut ve aday çözüm vektörlerinin yaklaşık baskınlık sıralamasını belirlemek için önceden bulunan çözümlerin referans arşivini kullanan (1 + 1) bir evrim stratejisi olarak kabul edilmektedir [59].

(3) SPEA2: Güçlü Pareto evrimsel algoritması, 1999 yılında Zitzler tarafından önerildi. SPEA'ya dayanarak, ayrıntılı bir uygunluk ataması, bir yoğunluk tahmin tekniği ve gelişmiş bir arşiv kesme yöntemini içeren geliştirilmiş bir versiyon, yani SPEA2 yöntemi önerilmiştir [60].

(4) MOEA/D: Ayrıştırmaya Dayalı Çok Amaçlı Evrimsel Algoritma (MOEA/D, Multi-Objective Evolutionary Algorithm Based on Decomposition), Li ve Zhang tarafından önerildi. Çok amaçlı bir optimizasyon problemini çok sayıda skaler optimizasyon alt problemine ayrıştırır ve bunları eş zamanlı olarak optimize etmektedir. Her alt problem yalnızca komşu alt problemlerden gelen bilgiler kullanılarak optimize edilir, bu da algoritmayı etkili ve verimli kılmaktadır [61].


(5) MOPSO: Çok Amaçlı Parçacık Sürü Optimizasyonu (MOPSO, Multi-Objective Particle Swarm Optimization), Pareto baskınlığına ve mevcut liderlerin listesini filtrelemek için ses çıkarma faktörünün kullanımına dayanmaktadır. Farklı mutasyon operatörleri sürünün farklı alt bölümlerine etki etmektedir. Epsilon-baskınlık kavramı da algoritmaya dahil edilmiştir [62].

2.2. Çok Amaçlı Evrim Algoritmalarının Temel Prensipleri

Evrimsel Hesaplama (EC, Evolutionary Computation) algoritmaları doğadan ilham alan yöntemlerdir. Esas olarak optimizasyon problemlerini çözmek için kullanılırlar, bir çözüm popülasyonu sağlarlar ve bu noktalar arasındaki etkileşim, bir arama alanı boyunca optimizasyon sürecini yönlendirir. Temel mekanizmaları basit olmasına rağmen evrimsel hesaplama algoritmaları, diğer optimizasyon yöntemleriyle çözülemeyen veya zorlukla çözülebilen sorunlara başka çözümler üretebilen genel, sağlam ve güçlü bir arama mekanizması olarak kendilerini kanıtlamıştır. Kapalı optimizasyon yöntemlerinin çoğu ileri sürülen varsayımlara dayanır. Örneğin, gradyan inişine dayalı yöntemler, amaç fonksiyonlarının türevini hesaplama becerisini gerektirir. Doğrusal Programlama gibi diğer yöntemler yalnızca tek amaçlı problemleri çözebilir ve çoğu zaman her değişkenin bütünlük kısıtlamasını kaldırarak bir gevşeme gerektirir. Ayrıca, birçok gerçek problem doğrusal değildir ve doğrusal olmayan fonksiyonlara doğrusal fonksiyonlarla yaklaşmak gerçekten tatmin edici olmayabilir. EC algoritmaları problem çözümü için arzu edilen çeşitli özelliklere sahiptir. Kontrol edilemeyecek kadar büyük ve son derece karmaşık arama alanlarında birden fazla çelişen hedefi ele alma yeteneğine sahiptirler. Kombinatoriyal optimizasyonda, arama alanının geniş olduğu problemlerde, Evrimsel Algoritmalar sonlu bir çözüm kümesinden en uygun çözümü bulmaya çalışırlar. Çözümler, belirli bir problem örneğini ne kadar iyi çözdüklerini belirleyen bir uygunluk fonksiyonu aracılığıyla değerlendirilir. Darwin'in doğal seçim ilkesine benzer şekilde, en güçlü bireyler hayatta kalır ve daha uyumlu çözümler üretecek şekilde evrimleşir. Popülasyonun en iyi üyelerine odaklanarak ve küçük varyasyonlar (mutasyon) ve çiftleşme işlemleri uygulayarak, popülasyonun makul bir süre içinde iyi ve hatta optimal çözümlere doğru evrilmesi beklenir [63].

Gerçek dünyadaki optimizasyon problemleri genellikle tek bir hedefle değil, aday çözümlerin değerlendirilmesi gereken bir dizi kriterle karakterize edilir. Tek-amaçlı bir bağlamda "optimizasyon" iyi anlaşılmış bir görev olsa da yani amaç fonksiyonunun uç noktasını bulmak anlamına gelirken, çok-amaçlı problemler için aynı şey söylenemez. Çok amaçlı bir problemin hedefleri sıklıkla birbiriyle çelişir; yani, hedeflerden birini iyileştiren bir çözüm, eninde sonunda diğerlerinden en az birini bozacaktır. Sonuç olarak, tek bir küresel çözüm yoktur ve bir Pareto Cephesini (PF, Pareto Front) dolduran bir dizi optimal noktanın, yani bir Pareto Kümesinin belirlenmesi gereklidir. Şekil 2.2'de Pareto

cephesinin genel yapısı gösterilmiştir. Pareto kümesinin oluşturulması hesaplama açısından pahalı olabilir ve temeldeki uygulamanın karmaşıklığı kesin yöntemlerin uygulanmasını engellediğinden çoğu zaman gerçekleştirilemez [64]. Bu nedenle Evrimsel Algoritmalar için bir dizi stokastik arama stratejisi geliştirilmiştir. Bunlar genellikle optimum dengeyi belirlemeyi garanti etmezler ancak iyi bir yaklaşım, yani amaç vektörleri optimal amaç vektörlerinden çok da uzakta olmayan bir çözüm kümesi bulmaya çalışırlar.



Şekil 2.2. Pareto cephesi kavramının gösterimi

1980'lerin sonlarında Çok Amaçlı Evrimsel Algoritmalar (MOEA, Multi-Objective Evolutionary Algorithm), artık birden fazla hedefi aynı anda dikkate alması ve vektör değerli bir maliyet fonksiyonunun bileşenlerini optimize etmeye çalışması gereken optimizasyon problemlerini çözmek için kullanılmaktaydı [65]. Tipik olarak, MOEA'lar uygunluk atamasında baskınlık kavramını kullanır. İlk olarak Goldberg tarafından Evrimsel algoritmalarla tanıtılan bu fikir, çok amaçlı problemin tek bir objektif probleme dönüştürülmesini gerektirmeyen avantaja sahiptir [66]. Ayrıca, Pareto optimal, Şekil 2.2'de yer alan bir dizi çeşitlendirilmiş çözümü tek seferde üretebilirler. Bu yüzeydeki her nokta, bir maliyet vektörü bileşeninde, geri kalan bileşenlerden en az birinde bozulmaya yol açmayan hiçbir iyileştirmenin elde edilemeyeceği anlamında optimaldir. Bu, tüm hedeflerde diğerinden daha kötü olmayan ve aynı anda en az bir hedefte kesinlikle diğerinden daha iyi olan bir çözümün diğerine hükmedildiği Pareto hakimiyeti kavramına yol açmaktadır.

Hakimiyet temelli yaklaşımlarda muhtemelen birbiriyle çelişen iki önemli hedef vardır: yakınsama ve çeşitlilik. Yakınsama, Pareto-optimal cephede yer alan bir çözüm kümesi bulma yeteneğini ifade ederken, çeşitlilik, Pareto-optimal cephenin tüm aralığını kapsaması gereken bu tür çözümlerin heterojenliğini ifade etmektedir. Çoğu MOEA, yoğunluk bilgisini seçim sürecine dahil ederek mevcut Pareto kümesi yaklaşımı içindeki çeşitliliği korumaya çalışmaktadır. Belirli bir bireyi seçme olasılığı, çevresindeki bireylerin yoğunluğu arttıkça azalır. Bu konu, istatistikte olasılık yoğunluk fonksiyonlarının tahmini ile yakından ilgilidir.

Optimum cepheye olan mesafe minimuma indirilirken, üretilen çözümlerin çeşitliliği maksimuma çıkarılmalıdır. Bununla birlikte, farklı MOEA'lar, farklı Çok Amaçlı Optimizasyon Problemler (MOOP, Multi-Objective Optimization Problem) için belirgin yakınsama ve çeşitlilik ile baskın olmayan çözümler sunar. MOEA'nın çeşitliliğini ve yakınsamasını iyileştirmek için, 1990'lardan beri ek bir elitizm kavramı çok popüler hale geldi. Elitizm, rastgele etkiler nedeniyle optimizasyon sürecinde iyi çözümlerin kaybedilmesi sorununu ele almaktadır. Bu sorunla başa çıkmanın bir yolu, arama sırasında bulunan baskın olmayan veya en çok tercih edilen tüm çözümlerin saklanması izin veren, arşiv adı verilen harici bir kümeyi sürdürmektir. Bu arşiv, temel olarak optimizasyon sürecinde bu çözümlerin kaybolmasını önlemeyi amaçlamaktadır. Alternatif olarak, eski popülasyon ve o kaynak, yani varyasyondan sonraki çiftleşme havuzu, eski popülasyonun modifiye edilmiş çiftleşme havuzuyla değiştirilmesi yerine deterministik bir seçim prosedürü uygulanarak birleştirilir. Hepsi tutulacak çözümlerin seçildiği varyant kriterleri tanımlayarak seçkinliği sürdürmek için farklı stratejiler olarak baskınlık kriteri ve yoğunluk tahmini gibi kriterler önerirler. Sonuç olarak, farklı MOEA'ların farklı avantajları ve dezavantajları vardır ve sonuç olarak, farklı problemler için eşit derecede iyi çözümler sunmayabilir.

2.3. Çok Amaçlı Optimizasyon Problemi


Çok amaçlı bir optimizasyon problemi, kısıtlamalara ve değişken sınırlara tabi olarak minimize edilmesi veya maksimize edilmesi gereken birden fazla amaç fonksiyonu içerirler. m adet optimizasyon hedefini içeren bir MOOP, şu şekilde formüle edilebilir:

$$\text{Minimize } F(x) = [f_1(x), f_2(x), \dots, f_m(x)]^T;$$

$$g_j(x) \leq 0, \quad j = 1, \dots, J; \quad (2.1)$$

$$x_i^{(L)} \leq x_i \leq x_i^{(U)}, \quad i = 1, \dots, n.$$

burada uygun bir çözüm $x \in X^n$, n karar değişkeninin bir vektörüdür, $x = (x_1, x_2, \dots, x_n)$. Karar uzayındaki uygulanabilir çözümler kümesi, $g_j(x) \leq 0$ kısıtlamaları ve değişken sınırlar tarafından tanımlanır. Çok amaçlı fonksiyon vektörü $F \in X^n \times Y^m$, burada $f_i: X^n \rightarrow Y$, $i = 1, \dots, m$, belirli bir çözümün kalitesini Y^m , amaç uzayında bir amaç vektörü $(y_1, y_2, \dots, y_m)$ atayarak değerlendirir, Şekil 2.3'te karar uzayı ve amaç uzayı genel yapısı gösterilmiştir.



Şekil 2.3. Genel olarak çok amaçlı problemin gösterimi

Örnek olarak, amaç uzayının gerçek sayıların, yani $Y \subset \mathbb{R}$ 'nin bir alt kümesi olduğunu ve optimizasyonun amacının tek bir hedefi $m = 1$ en aza indirmek olduğunu varsayalım. Böyle tek amaçlı bir optimizasyon probleminde, $y_1 = F(x_1)$ ve $y_2 = F(x_2)$ olmak üzere $y_1 < y_2$ ise $x_1 \in X^n$ çözümü diğer $x_2 \in X^n$ çözümünden daha iyidir. Karar uzayında birkaç optimal çözüm bulunabilmesine rağmen, hepsi aynı amaç değerine eşlenir, yani amaç uzayında yalnızca tek bir optimum bulunmaktadır.


$Y^m \subset \mathbb{R}^m$ ve $m > 1$ ile vektör değerli F değerlendirme fonksiyonu durumunda, x_1 ve x_2 çözümlerini karşılaştırma durumu daha karmaşıktır. Pareto hakimiyeti kavramını takiben, y_1 'in hiçbir bileşeni y_2 'nin karşılık gelen bileşeninden büyük değilse ve bileşenlerinden en az biri daha küçükse, bir y_1 amaç vektörünün başka bir y_2 ($y_1 < y_2$) hedef vektörüne baskın olduğu söylenir. Buna göre, bir x_1 çözümünün başka bir x_2 çözümünden daha iyi

olduğunu söyleyebiliriz, yani $x_1, x_2 (x_1 < x_2)$ 'ye baskındır, eğer $y_1 = F(x_1)$, $y_2 = F(x_2)$ üzerinde hakimse, yani $(y_1 < y_2)$ diyebiliriz. Burada, optimal çözümler, yani başka herhangi bir çözümün baskın olmadığı çözümler, farklı amaç vektörlerine eşlenebilir. Başka bir deyişle, hedefler arasında farklı değiş tokuşları temsil eden birkaç optimal amaç vektörü olabilir.

Genel bir stokastik arama algoritması üç bölümden oluşur:

- a) O anda dikkate alınan çözüm adaylarını içeren bir çalışma belleği,
- b) Bir seçim modülü,
- c) Bir varyasyon modülü.

Seçim prosedürleri, çiftleşme ve çevresel seçim olarak sınıflandırılır. Çiftleşme seçimi, varyasyon için umut verici çözümler seçmeyi amaçlar ve genellikle stokastik bir tarzda gerçekleştirilir. Buna karşın çevresel seçim, önceden depolanan çözümlerden ve yeni oluşturulan çözümlerden hangisinin dahili bellekte tutulacağını belirlemektedir. Varyasyon modülü bir dizi çözüm alır ve yeni çözümler üretmek için bu çözümleri sistematik veya rastgele değiştirilir. Bir stokastik optimize edicinin bir yinelemesi, ardışık eşleştirme seçimi, varyasyon ve çevresel seçim adımlarını içerir; bu döngü belirli bir durdurma kriteri sağlanana kadar tekrarlanır (Şekil 2.4).



Şekil 2.4. Çok amaçlı problemin bileşenleri

2.4. NSGAIİ Algoritması

Hakim olmayan sıralama ve paylaşımı kullanan çok amaçlı evrimsel algoritmalar, bir süredir hesaplama karmaşıklıkları, elitizm olmayan yaklaşımları ve bir paylaşım parametresi belirleme ihtiyacı nedeniyle eleştirilmiştir. NSGAIİ, bu sorunları ele almayı

amaçlamaktadır. NSGAII algoritması, çok amaçlı bir optimizasyon probleminde birden çok Pareto-optimal çözümü bulmaya çalışırken, üç ana fikre odaklanmaktadır:

- 1) Elitist bir ilke kullanır;
- 2) Açık bir çeşitlilik koruma mekanizması kullanır;
- 3) Domine edilmemiş çözümleri vurgular.

Çoğu yönden, bu algoritmanın orijinal NSGA ile pek çok benzerliği yoktur, ancak yazarlar, oluşumunu ve menşe yerini vurgulamak için NSGA-II adını korumuştur [67].

Her nesilde, ilk olarak ana popülasyon üzerinde uygulanan genetik operatörler kullanılarak yavru popülasyon oluşturulur. Bu durumda, çoğaltma işlemleri yukarıda Tek Amaçlı Evrimsel Algoritmalar (SOEA, Single-Objective Evolutionary Algorithm) için tanımlananla aynı olacaktır. İki çözüm seti daha sonra $2N$ büyüklüğünde yeni bir popülasyon oluşturmak için birleştirilir ve buradan baskınlığa dayalı seçim yoluyla N boyutlu bir popülasyon oluşturulur. NSGAII algoritmasının temel yapısı şu şekildedir [68].

Algoritma 1. NSGA-II Algoritması

- 1: Tanımlar, NSGA-II (ebeveyn, çocuk ve referans noktaları oluştur)
- 2: Popülasyonu başlat
- 3: Popülasyonu hedeflere göre değerlendir
- 4: Pareto hakimiyetine göre sıralama ata
- 5: Yeni birey (çocuk) nüfusu oluşturun
 - 5.1: Ebeveyn ikili turnuva seçimi
 - 5.2: Rekombinasyon ve Mutasyon
- 6: **while** Durdurmama koşulu **do**
 - 6.1: **for** Popülasyondaki her Ebeveyn ve Çocuk için **do**
 - 6.2: Pareto'ya göre sıralama atayın
 - 6.3: Pareto cephesi boyunca baskın olmayan vektör kümeleri oluştur
 - 6.4: İlk cepheden başlayarak N birey bulunana kadar sonraki nesile çözümler ekleyerek döngü yapın ve her cephedeki noktalar arasındaki kalabalıklaşma mesafesini belirle

6.5: **end for**

6.6: Ön alt taraftaki yani daha düşük sıradaki noktaları seçin

6.7: Gelecek nesili oluştur

6.7.1: Ebeveyn ikili turnuva seçimi

6.7.2: Rekombinasyon ve Mutasyon

7: **end while**

8: sonlandır

2.5. Güçlü Pareto Evrimsel Algoritması (SPEA)

SPEA ve SPEA-II, 1999 ve 2001'de Zitzler ve ark. tarafından sunulmuştur. SPEA, SPEA-II'nin temelini oluşturduğundan burada SPEA'nın kısa bir özeti verilmektedir. SPEA çok amaçlı bir optimizasyon algoritmasıdır ve aynı zamanda evrimsel çok amaçlı algoritmalar alanına da aittir. Güçlü Pareto'nun SPEA'da önemli bir rolü vardır çünkü bu, çözümlerin birinci sıraya ne kadar yakın olduğunu göstermektedir. Algoritmanın amacı, bir dizi baskın olmayan çözümü, ideal olarak bir Pareto optimal çözüm kümesini tanımlamak ve korumaktır [60,69]. Pareto optimal çözümlerinin tümüne Pareto optimal seti denir. Pareto optimal seti, amaç uzayındaki en iyi baskın olmayan çözümlerden oluşur. Her çözüm için iki ana parametre dikkate alınır: ilk durum, aşağıdaki gibi tanımlanan Pareto kuvvetidir:

$$S(i) = \frac{n}{N+1} \quad (2.2)$$

burada N popülasyon büyüklüğüdür ve n , bireysel i 'nin hakim olduğu veya ona eşit olan bireylerin sayısıdır. Bu nedenle, baskın çözümler, Denklem (2.2)'ye göre diğerlerinden daha düşük güce sahip olan yanıtlardır. Ayrıca ikinci parametre, aşağıdaki tanımla j bireyi için uygunluk değeridir [70]:

$$F(j) = 1 + \sum_{i < j} S(i) \quad (2.3)$$

Denklem (2.3)'e göre popülasyondaki j bireyinin $F(j)$, ($<$) baskın olan veya j bireyine eşit olan tüm dış popülasyon üyelerinin güç değerleri $S(i)$ 'nin toplamı kullanılarak hesaplanmaktadır. Bu uygunluk atama yöntemi, daha düşük uygunluk değerine sahip bir çözümün daha iyi olduğunu öne sürmektedir [70,71].

SPEA'nın genel adımları aşağıdaki gibi açıklanabilir:

Tanımlar: T maksimum nesil sayısıdır, t yineleme sayısıdır ve dış küme Pareto optimal çözüm kümesidir. Çözümlerin harici olarak depolandığını ve ayrıca sürekli olarak yükseltildiğini unutmayın. Son olarak bu sette saklanan çözümler Pareto optimal setini temsil etmektedir.

(1) Başlatma: ilk popülasyon oluşturulur ve boş harici Pareto optimal seti oluşturulur.

(2) Pareto optimal seti güncellenir. Pareto optimal kümesinin boyutu önceden tanımlanmış bir sınırı aşarsa, diğer Pareto kümeleri bir kümeleme tekniğiyle silinir. Pareto setini yönetilebilir bir boyuta indirmek için ortalama bağlantı bazlı hiyerarşik kümeleme algoritması kullanılır. Gerekli sayıda grup elde edilene kadar bitişik kümeleri birleştirerek yinelemeli olarak gerçekleştirilir [70].

(3) Uygunluk değerleri dış Pareto optimal seti ve popülasyon için hesaplanır.

(4) İkili turnuva seçimi: popülasyon ve dış kümedeki bireyler birleştirilir ve herhangi iki birey rastgele seçilir. Uygunluk fonksiyonlarına göre daha iyi olan çiftleşme havuzuna taşınır. Çiftleşme havuzu, çapraz geçen bir popülasyon kümesidir ve yeni bir popülasyon üretmek için bunlar üzerinde mutasyon işlemleri gerçekleştirilir.

(5) Mutasyon ve çaprazlama işlemleriyle yeni bir popülasyon üretilir.


(6) $t = t + 1$ 'i ayarlayın. Durdurma kriteri ($t > T$) karşılanmazsa Adım 2'ye gidin; ya da arşiv üyeleri Pareto optimal kümesi olarak sunulur [69].

2.6. Güçlü Pareto Evrimsel Algoritması 2 (SPEA2)

NSGA-II, yeni popülasyonu doldurmak için çözümlerin baskınlık derinliği sıralamasını kullanırken, SPEA2 kısmen sıralı çözüm uzayında baskınlık sayımı ve baskınlık sıralaması sıralama stratejilerine başvurur. Baskınlık sıralaması stratejisinde, bir çözümle ilişkilendirilen sıralama, popülasyondaki ele alınan çözüme hakim olan çözümlerin sayısı ile ilişkilidir. Bu tezde, SPEA2 sürümü kullanılmıştır, çünkü bu sürüm selefinin yani SPEA'nın aksine ince taneli bir uygunluk atama stratejisi, bir yoğunluk tahmin tekniği ve gelişmiş bir arşiv kesme yöntemi içermektedir.

SPEA2'nin SPEA'ya kıyasla temel farklılıkları şunlardır:

Her bir birey için, kendisinin ve kendisinin kaç kişi tarafından domine edildiğini hesaba katan geliştirilmiş bir uygunluk atama şeması kullanılır. Arama sürecinin daha kesin bir şekilde yönlendirilmesine izin veren bir en yakın komşu yoğunluğu tahmin tekniği dahil edilmiştir [60].



Şekil 2.5. SPEA2 blok diyagramı

Temel SPEA için sunulan adımlara benzer şekilde, geliştirilmiş algoritmanın, yani SPEA2'nin ayrıntıları aşağıdaki paragraflarda verilmektedir. Ayrıca Şekil 2.5'te SPEA2'nin blok diyagramı verilmiştir.

Tanımlar: P_t (t yinelemesindeki ana popülasyon), $\bar{P}_t$ (t yinelemesindeki arşiv popülasyonu), $\bar{N}$ (arşiv boyutu) ve T (maksimum nesil sayısı).

Başlatma: $t = 0$ 'ı ayarlayın ve başlangıç popülasyonunu oluşturun P_0 ve boş arşiv $\bar{P}_t = \varphi$.

Bireyler için uygunluk değerlerini hesaplayın. P_t ve $\bar{P}_t$ (hem popülasyon hem de arşiv setleri).

Arşivdeki her bir kişi için $\bar{P}_t$ ve nüfus P_t , güç değeri $S(i)$ aşağıdaki denklem kullanılarak hesaplanır:

$$S(i) = |\{j | j \in P_t + \bar{P}_t \wedge i \succ j\}| \quad (2.4)$$

+ sembolü çoklu küme birleşimini temsil ederken, sembol $\succ$ Pareto baskınlık ilişkisine karşılık gelir ve sembol $\wedge$ VE anlamına gelir.

SPEA2 için $F(i)$ şu şekilde tanımlanır:

$$F(i) = R(i) + D(i) \quad (2.5)$$

i birey için hesaplanan uygunluk $R(i)$ değeri aşağıdaki denklemle hesaplanır:

$$R(i) = \sum_{j \in P_t + \bar{P}_t, j \succ i} S(j) \quad (2.6)$$

Ancak optimizasyon hedefi simge durumuna küçültülmüş bir arama ise $F(i)$, ham uygunluk burada en aza indirilmelidir, yani, $R(i) = 0$, baskın olmayan bir bireye karşılık gelir [60].

Uygunluk fonksiyonu genelde Pareto baskınlığı sayesinde iyi bir sınıflama sağlasa da birçok bireyin birbirini domine etmediği durumlarda başarısız olabilir. Bu gibi durumlarda ayırım sağlamak amacıyla başka yoğunluk bilgilerine bakmak gerekmektedir. (i) çözümünün yoğunluğu;

$$D(i) = \frac{1}{\sigma_i^{(k)} + 2} \quad (2.7)$$

eşitliği ile bulunur. Paydası $0 < D(i) < 1$ olduğundan paydaya 2 eklenir.

SPEA2'de kullanılan yoğunluk tahminleme tekniği k . en yakın komşuluk metodunun bir uyarlamasıdır. Bir noktadaki yoğunluk k . en yakın veri noktasına olan uzaklığın azalan bir fonksiyondur.

$$k = \sqrt{N + \bar{N}} \quad (2.8)$$

Yoğunluk fonksiyonu olarak k . en yakın komşuya olan uzaklığın tersi alınmaktadır. Yani, her bir birey i için arşiv ve popülasyonlardaki tüm bireylere olan uzaklıklar hesaplanır ve bir listede tutulmaktadır. Liste artan sırada sıralandıktan sonra, i 'ninci ve k 'ninci en yakın komşular arasındaki amaç-uzay mesafesini temsil eder ve $\sigma_i^{(k)}$ olarak gösterilir [72,73].

2.7. Çevresel Seçim

SPEA2'deki arşiv güncelleme işlemi, SPEA'dakinden iki açıdan farklılık gösterir: i) arşivde yer alan bireylerin sayısı sürekli fazla mesaidir ve ii) kesme yöntemi, sınır çözümlerinin kaldırılmasını engeller. Çevresel seçim sırasında ilk adım, baskın olmayan bireylerin tamamını, yani uygunluğu birden düşük olanları arşivden ve popülasyondan gelecek neslin arşivine kopyalamaktır [60]:

Güncellenmiş arşiv kümesi $\bar{P}_{t+1}$ 'in boyutu, seçilen sabit boyut $\bar{N}$ 'yi aşarsa $\bar{P}_{t+1}$ 'in boyutunu azaltmak için bir kesme operatörü kullanılmaktadır. $\bar{P}_{t+1}$ 'in boyutu $\bar{N}$ 'ye eşitse işlem tamamlanır. Aksi takdirde $\bar{N}$ 'nin boyutu $\bar{N}$ 'den daha büyük veya daha küçüktür.

Eğer küme $\bar{N}$ 'den küçükse, önceki arşivdeki $\bar{N} - |\bar{P}_{t+1}|$ 'nin baskın olduğu en iyi bireyler yeni arşive kopyalanır. Küme $\bar{N}$ 'yi aşarsa, bireyleri $\bar{P}_{t+1}$ 'den $|\bar{P}_{t+1}| = \bar{N}$ 'ye kadar çıkarmak için bir arşiv dönüştürme yöntemi kullanılır. Her yinelemede, tüm $j \in \bar{P}_t + 1$ için $i \leq_d j$ olan birey i seçilir ve

$$\begin{aligned} i \leq_d j &: \Leftrightarrow \forall 0 < k < |\bar{P}_{t+1}| : \sigma_i^k = \sigma_j^k \vee \\ &\exists 0 < k < |\bar{P}_{t+1}| : [(\forall 0 < l < k: \sigma_i^l = \sigma_j^l) \wedge \sigma_i^k < \sigma_j^k] \end{aligned} \quad (2.9)$$

burada σ_i^k , i bireyinin i 'nin $\bar{P}_{t+1}$ 'deki k 'inci komşusuna olan uzaklığıdır. Her aşamada, minimum mesafeli komşu kaldırılmak üzere seçilir ve bir sonraki en küçük mesafeye sahip olan komşular art arda kaldırılarak bağlar koparılır.

Bu çalışmalar ışığında SPEA2 algoritması yakınsama ve çeşitlilik açısından iyi performans sağlamıştır. Böylece SPEA'dan daha iyi performans gösterir ve iyi bilinen çeşitli test problemlerinde Pareto Zarflama Temelli Seçim Algoritması (PESA, Pareto Envelope-Based Selection Algorithm) ve NSGA-II ile karşılaştırılmalı uygulamalar yapılmaktadır.

2.8. Çok Amaçlı Evrimsel Algoritmalarındaki Sorunlar

Pareto-optimal kümenin yaklaşımı muhtemelen birbiriyle çelişen iki hedefi içerir: optimal cepheye olan mesafenin en aza indirilmesi ve üretilen çözümlerin çeşitliliğinin yani amaç veya parametre değerleri açısından maksimize edilmesidir. Bu bağlamda, çok amaçlı bir evrimsel algoritma tasarlanırken iki temel konu vardır: çiftleşme seçimi ve çevresel seçimdir. İlk konu, aramanın Pareto-optimal cepheye doğru nasıl yönlendirileceği sorusuyla doğrudan ilgilidir. Bir birey havuzu verildiğinde, yavru üretimi için hangi bireylerin seçildiği temelinde uygunluk değerleri atanmalıdır. Çiftleşme havuzunu doldurma prosedürü genellikle rastgele seçilmektedir. İkinci konu, evrim sürecinde hangi bireylerin tutulacağı sorusunu ele almaktadır. Sınırlı zaman ve depolama kaynakları nedeniyle, belirli bir nesildeki bireylerin yalnızca belirli bir kısmı bir sonraki neslin havuzuna kopyalanabilir. Burada deterministik bir seçim kullanmak yaygın bir uygulamadır.

Çoğu modern MOEA algoritmasında, bu iki kavram, ayrıntılar farklı olsa da şu şekilde gerçekleştirilir:

Çevresel seçim: Nüfusun yanı sıra, şu ana kadar ele alınan tüm çözümler arasında baskın olmayan cephenin bir temsilini içeren bir arşiv tutulur. Arşivin bir üyesi ancak i) ona hakim olan bir çözüm bulunursa veya ii) maksimum arşiv boyutu aşılsa ve arşiv üyesinin bulunduğu ön kısım aşırı kalabalıksa kaldırılmaktadır. Genellikle tesadüfen meydana gelebilecek saf üremeye ek olarak, bir bireyin birkaç nesil boyunca hayatta kalabilmesinin tek yolu arşive kopyalanmasıdır. Bu teknik, rastgele etkiler nedeniyle mevcut baskın olmayan cephenin belirli kısımlarını kaybetmemek için dahil edilmiştir.

Çiftleşme seçimi: Her nesildeki birey havuzu iki aşamalı bir süreçte değerlendirilir. Öncelikle tüm bireyler, bu çoklu küme üzerinde kısmi bir düzen tanımlayan Pareto baskınlık ilişkisi temelinde karşılaştırılır. Temel olarak, her bireyin hakim olduğu, veya kayıtsız kaldığı bilgiler, nesil havuzunda bir sıralama tanımlamak için kullanılmaktadır. Daha sonra, bu sıralama, yoğunluk bilgisinin dahil edilmesiyle iyileştirilir. Belirli bir bireyin bulunduğu yerin boyutunu ölçmek için çeşitli yoğunluk tahmin teknikleri kullanılmaktadır.

Prensip olarak, her iki seçim şeması da birbirinden tamamen bağımsızdır. Böylece, birincisi Pareto tabanlı olabilirken ikincisi uygunluk değerlerini hesaplamak için ağırlıklandırma yaklaşımını kullanabilir. Bununla birlikte, birçok evrimsel yöntemle her iki kavram da benzer şekilde uygulanmaktadır.

Örneğin, PESA'da, eşleştirme seçimi yalnızca geçerli baskın olmayan kümeyi depolayan arşivde gerçekleştirilir [74]. Histogram tekniği olarak sınıflandırılacak belirli bir yoğunluk ölçüsü, arşiv elemanlarının kalabalıklaşma derecesine göre farklı örneklenebilmesi sağlanır. Gerçek popülasyonu oluşturan oluşturulan çocuklar daha sonra arşive dahil edilmek üzere kontrol edilmektedir. Arşive girmeyen kişiler, bir sonraki nesil döngüsü başlamadan önce kaldırılır. Bu yaklaşımla, çiftleşme ve çevresel seçim, seçim kriterleri yani mevcut baskın olmayan cephenin üyesi açısından aynıdır ve yalnızca seçim sürecine göre farklılık gösterir. Aynı şey gelecek vaat eden diğer bir algoritma olan NSGA-II için de geçerlidir [60,75]. Burada bireyler havuzu önce Pareto hakimiyeti kavramına göre farklı cephelere ayrılır. Birinci baskın olmayan cepheye ait bireyler en yüksek rütbeye, ikinci hakim olmayan cephedekilere ikinci en yüksek rütbeye vb. atanır. Her sıra içinde, bireyler arasında bir sıralama tanımlamak için her hedef boyunca en yakın iki bireye olan mesafelerin toplamını temsil eden özel bir dışlama ölçüsü kullanılır. Bu sıralama temelinde hem çevresel hem de çiftleşme seçimi yapılır. Ebeveyn popülasyonu ve yavru popülasyonu birleştirip en kötü %50'yi silerek birey havuzu kesilir. Daha sonra, bir sonraki yavru popülasyonu oluşturmak için kalan bireyler üzerinde ikili turnuvalar gerçekleştirilir. PESA'nın aksine, arşivin yalnızca baskın olmayan bireyleri değil, aynı zamanda baskın bireyleri de içerebileceğini unutmayın; NSGA-II ile arşiv her zaman tamamen doldurulurken, PESA ile sadece kısmen doldurulabilir [60].

3. BÖLÜM

ÇOK AMAÇLI OPTİMİZASYON ALGORİTMALARINDA PERFORMANS ARTIRMA YÖNTEMLERİ

MO-BSS algoritmalarının hem işlem performanslarını artırmak hem de işlem sürelerini iyileştirmek için karışım işaretleri üzerinde bir dizi yöntemler uygulanmıştır. Ön işlem ve DWT yöntemlerinin kullanımına dayalı yeni yöntemler önerilmiştir. Ön işlem olarak beyazlatma dönüşümü yöntemi önerilmiştir. Bu yöntem ile kovaryans matrisine sahip rastgele değişkenlerden oluşan bir vektörü korelasyonsuz ve varyansı bir olan yeni vektöre dönüşümü sağlanır. Böylece verilerin istatistiksel özelliklerini değiştirerek gürültüyü azaltmak veya özellik çıkarmayı kolaylaştırmak için kullanılmaktadır. DWT ise bir sinyalin temel fonksiyonların olduğu frekans bileşenlerini bulmak için önerilen diğer bir yöntemdir. Bu yöntemler yapısı ve MO-BSS'ye uygulanması hakkında genel bilgiler şu şekildedir:

3.1. Ön İşlemler Yöntemi

Gözlemlenen işaretler üzerinde ayrıştırma işlemini basitleştirmek ve işlem yükünü azaltmak amacıyla işaretler ön işleme tabi tutulması algoritmaların performansını artıracaktır. İşaret işlemede beyazlatma yaygın olarak kullanılan ön işleme tekniğidir. Beyazlaştırma, bir veri kümesindeki tüm doğrusal bağımlılıkları ortadan kaldırır ve tüm boyutlar boyunca varyansı normalleştirir; bu işlem sezgisel olarak veri kümesini küresel olarak simetrik bir dağılım sağlar. Beyazlaştırma işlemi; PCA'da özellik çıkarma ve veri sıkıştırmada yaygın olarak kullanılan ve Hotelling dönüşümü olarak da bilinen bir tekniktir. Elde edilen verileri ayrıştırmadan önce ön işlem olarak bilinen beyazlatma işleminin kullanılması işaretler üzerinde olumlu etkiye sahip olacaktır. Genel olarak PCA veri boyutu indirgeme amacıyla kullanılmıştır. Beyazlaştırma işleminde sıfır

ortalamasına sahip rastgele bir vektör (x) beyazsa, bileşenleri ilişkisizdir ve kovaryans matrisi Σ birim matrise (I) eşittir.

$$\Sigma = E\{xx^T\} = I \quad (3.1)$$

Beyaz olmayan verileri dönüşüm matrisi kullanarak beyazlaştırmak için gözlemlenen bir vektör x , doğrusal bir dönüşümle beyaz bir vektöre z dönüştürülebilir [1].

$$z = Vx \quad (3.2)$$

Beyazlatma için birçok farklı dönüşüm yöntemleri bulunmaktadır. Bunlardan en çok kullanılanı kovaryans matrisinin özdeğerlerinin ayrıştırılmasıdır. Bu yöntemde E özdeğerlerin ortogonal matrisi ve $E\{xx^T\}$ ve $D = \text{diag}(d_1, \dots, d_n)$ özdeğerlerden oluşan köşegen bir matristir.

$$E\{xx^T\} = EDE^T \quad (3.3)$$

Denklem (3.3)'e uygun olarak beyazlatma matrisi V , Denklem (3.4)'teki gibi oluşturulabilir.


$$V = ED^{-1/2}E^T \quad (3.4)$$

$D^{-1/2} = \text{diag}(d_n^{-1/2}, \dots, d_1^{-1/2})$ eşitliği, karıştırma matrisi A 'nın üzerindeki etkisi,

$$V = ED^{-1/2}E^TAs = \tilde{A}s \quad (3.5)$$

ile bulunur ve $\tilde{A}$ matrisi ortogonal matris olarak hesaplanır [76–83].

Ön işlem olarak beyazlatma yöntemi kör kaynak ayrıştırma olarak çok amaçlı optimizasyon algoritmalarına uyarlanması Şekil 3.1 ile gösterilen blok diyagramında verilmiştir. Gözlemlenen karışık veriler önce beyazlatma işlemine tabi tutulur ve sonrasında MO-BSS yöntemi ile işaretler ayrıştırılır.



Şekil 3.1. Önerilen ön işlemli MO-BSS algoritmasının blok diyagramı

3.2. Dalgacık Dönüşümü Yöntemi

MO-BSS’de önerilen bir diğer yöntem dalgacık dönüşümüdür. Dalgacık dönüşümü işaret ve görüntü işleme, örüntü tanıma ve bilgisayarlı görme, astronomi, akustik ve jeofizik gibi çeşitli alanlarda uygulama alanı bulan popüler bir tekniktir. Bu popülerliğin iki temel nedeni vardır. Birinci neden, iyi bir zaman frekansı lokalizasyon özelliğine sahip olan dalgacık dönüşümünün içsel doğasından kaynaklanmaktadır. Bunu anlayabilmek için öncelikle standart Fourier tekniklerinin incelenebilir. Bu teknikler, sonsuz üstel dalgalar kullanarak bir işaretin toplam frekans içeriğini analiz eder. Fourier dönüşümü (FT, Fourier Transform), periyodik işaretlerin analizi için uygun olduğundan, eğer bir işaretin belirli bir zamandaki frekans içeriği gerekiyorsa, örneğin; işarete bir yükselişin meydana

geldiği an gerekliyse FT bilgiyi sağlayamayacaktır. FT'nin eksikliği, iyi bir frekans yerelleştirmesi sağlaması ancak zaman yerelleştirmesi sağlayamamasıdır.

Bu sorunun üstesinden gelmek için, pencereli üstel dalgaları kullanarak işareti belirli zaman konumlarında analiz eden Kısa Zamanlı Fourier dönüşümü (STFT, Short Time Fourier Transform) geliştirilmiştir. Bu, üstel dalgaların gerekli zaman anında ortalananmış uygun bir pencere fonksiyonu ile çarpılması yoluyla yapılmaktadır. Bu çalışmada kullanılan Gabor dönüşümü, pencere fonksiyonu olarak Gauss çekirdeğini kullanan STFT'nin özel bir durumudur. Gabor bu pencereyle STFT'nin en iyi ortak zaman-frekans lokalizasyonuna ulaştığını kanıtlamıştır [18]. İyi ortak zaman-frekans yerelleştirme özelliğinin yanı sıra, STFT hala pencere fonksiyonunun neden olduğu ölçek bağımlılığı sorununu sunmaktadır. Bunu anlamak için, işarettaki ani yükselişin zaman konumu göz önüne alınmaktadır. Yükselişin genişliği analiz penceresinin genişliğinden çok daha küçük veya daha büyükse, yine de yükselişin meydana geldiği zaman anının belirlenememe sorunu olacaktır. Bu sorunun üstesinden gelmek için, bir işareti farklı zaman konumlarında, farklı boyutlardaki çekirdeklerle analiz eden WT, çekirdeklerin, ana dalgacık adı verilen bir prototip fonksiyonun ötelenmesi ve genişletilmesiyle oluşturulduğu yerde kullanılmaktadır. Dalgacık dönüşümünün popüleritesindeki ikinci faktör Mallat'tan kaynaklanmaktadır [11]. Gerçekleştirilen çalışmada çoklu çözünürlüklü ayrıştırma fikrini kullandı ve dalgacık katsayılarının aynı işaretin iki farklı çözünürlük versiyonu arasındaki bilgi farkını temsil etmeye uygun olduğunu göstermiştir. Bu, WT'nin ayrı bir versiyonunun verimli bir şekilde uygulanmasını sağlamıştır [84].

DWT'nin ismine ilk yayınlanan referans Daubechies [85] tarafından yapılmıştır. İç çarpımları almak yerine, vektör olarak sakladığımız zaman serileri ile filtrelerin evrişimleri kullanılarak ayrık dönüşümler alınmaktadır.

Tez çalışmasında işaret analizi için yaygın olarak kullanılan iki tür dalgacık dönüşümüne odaklanılmıştır: Sürekli Dalgacık dönüşümü (CWT, Continuous Wavelet Transform) ve ayrık dalgacık dönüşümleridir. İsmine rağmen CWT sıklıkla ayrık işaret analizi için kullanılmaktadır. Ana dalgacık adı verilen sürekli bir fonksiyondan türetilen ölçeklenmiş ve çevrilmiş dalgacıklar cinsinden bir işaretin yedekli bir temsilini sağlarken DWT, bir işaretin bir dizi ayrı ortonormal dalgacık aracılığıyla yedeksiz bir temsilini sağlamaktadır.

3.2.1. Sürekli Dalgacık Dönüşümü Yöntemi

CWT, denklemle ana dalgacık ψ 'dan türetilen ölçeklenmiş ve çevrilmiş dalgacıklar $\psi_{s,\tau}$ ile bir işareti temsil eder.

Sürekli dalgacık dönüşümü, ana dalgacıktan türetilen ölçeklenmiş ve çevrilmiş dalgacıklar açısından bir fonksiyonun yedekli bir temsilini sağlar. CWT'nin matematiksel tanımını şu şekildedir.

$$\psi_{s,\tau}(t) = \frac{1}{\sqrt{s}} \psi\left(\frac{t-\tau}{s}\right) \quad (3.6)$$

s ve τ parametrelerine ölçek ve öteleme adı verilir. CWT uygulaması genellikle işaretin katsayılarından yeniden oluşturulmasını içermez. Ancak işlemin tersinirliği bize orijinal işarettaki tüm bilgilerin CWT'de de mevcut olduğunu garanti eder. Bu nedenle yeniden yapılandırmaya gerek olmasa da kabul edilebilir dalgacıklar yaygın olarak kullanılmaktadır [86,87].

3.2.2. Ayırık Dalgacık Dönüşümü Yöntemi

Dalgacık dönüşümlerini hesaplarken CWT'nin yaklaşık bir sonucunu elde etmek için, ayırık dalgacık dönüşümü, Fourier dönüşümüne bir yaklaşım hesaplanırken ayırık Fourier dönüşümünün kullanıldığı gibi kullanılabilir. $x(t)$ işareti için ayırık bir yaklaşım için aşağıdaki denklem yazılır,

$$x(t) = \sum_{j,k} a_{j,k} \psi_{j,k}(t) \quad (3.7)$$

burada $a_{j,k}$ katsayılarına $x(t)$ işaretinin DWT'si denir. DWT'nin arkasındaki fikir CWT ile aynıdır ancak yöntemler farklıdır.

CWT, dalgacığı doğrudan işaretle evriştirirken DWT, giriş işaretini bir alçak geçiş ve bir yüksek geçiş filtresiyle eşzamanlı olarak evriştirir. İki filtre birbiriyle ilişkilidir ve bir sonraki paragrafta sunulan Dörtlü Ayna Filtresinin (QMF, Quadrature Mirror Filters) kriterlerini karşılar. Şekil 3.2 QMF'nin arkasındaki fikri göstermektedir. Alçak geçişli bir filtre, yüksek geçişli bir filtre oluşturmak için yansıtılır. İkisinin birleştirilmesi, yalnızca belirli frekansların geçmesine izin veren bir bant geçiren filtre oluşturur. QMF, tipik olarak yalnızca birkaç sıfır olmayan değerin bulunduğu g_n dizisi tarafından tanımlanan

bir alçak geçiş filtresi kullanılarak oluşturulur. Daha sonra alçak geçiş değerleri kullanılarak h_n sırasına sahip bir yüksek geçiş filtresi oluşturulur:

$$h_n = (-1)^n g_{1-n} \quad (3.8)$$

Her iki filtre de iç ortogonallığı karşılar

$$\sum_n h_n h_{n+2j} = 0 \quad (3.9)$$

tüm tamsayılar için $j \neq 0$ ve karelerin toplamına sahip


$$\sum_n h_n^2 = 1 \quad (3.10)$$

Karşılıklı diklik ilişkisi

$$\sum_n h_n g_{n+2j} = 0 \quad (3.11)$$

tüm tamsayılar için j 'nin de sağlanması gerekmektedir.

Her filtrenin uzunluğu işaretin uzunluğunun yarısı kadardır. Her iki filtreyi de işarette evriştirdikten sonra, her iki çıkış da iki kat aşağı örneklenir. Birleştirilen iki çıkış, giriş işaretinin uzunluğuna sahiptir. Yüksek geçişli filtreleme yapıldıktan sonraki çıktıya detay katsayıları, alçak geçişli filtrelemeden sonraki çıktıya ise yaklaşım katsayıları adı verilir. Filtreleme sonucu oluşan katsayıların örnek sayısı alt örnekleme (downsampling) ile yarıya indirgenir. Süreç Şekil 3.2’de gösterilmiştir.



Şekil 3.2. Ayrık dalgacık dönüşümünde işaretin filtrelenmesi

Şekilde, giriş işaretini çeşitli bileşenlere ayıran, ağaç yapılı bir filtre dizisi olan bir filtre bankası gösterilmektedir. Her düzeydeki çıktı bileşenleri daha da filtrelenerek ağaç yapılı şekle ulaşılabilir. Frekans çözünürlüğünü arttırmak için ayrıştırma tekrarlanabilir.


Yaklaşım katsayıları bir sonraki ayrıştırma seviyesinin girdisidir ve hesaplamalar, çıktının uzunluğu bir olana kadar tekrarlanabilir. Başlangıçtaki alçak geçiren filtre, daha sonra anlatılacak olan ölçeklendirme fonksiyonu kullanılarak oluşturulur.

Genişleme σ ve öteleme τ olan bir dalgacık fonksiyonu Denklem (3.12)'de tanımlanmıştır. σ ve τ parametrelerini, σ genişlemesinin logaritmik ayrıklaştırılmasıyla örneklenir. Daha sonra, ayrıklaştırılmış bir dalgacık fonksiyonu elde etmek için, genişleme σ ile orantılı olan her bir τ 'ye ayrı adımlarla hareket ederek çeviri parametresi τ 'ye bağlantı kurulur:

$$\psi_{m,n}(t) = \frac{1}{\sqrt{\sigma_0^m}} \psi\left(\frac{t - n\tau_0\sigma_0^m}{\sigma_0^m}\right) \quad (3.12)$$

burada $\sigma_0 > 1$ ve $\tau_0 > 0$ 'dır ve genişleme ve öteleme m ve n tarafından belirlenir. Daha sonra sürekli bir $x(t)$ işaretinin ayırık dalgacıkları ile dalgacık dönüşümü tanımlanır:

$$T_{m,n} = \int_{-\infty}^{\infty} x(t) \frac{1}{\sqrt{\sigma_0^m}} \psi(\sigma_0^{-m}t - n\tau_0) dt \quad (3.13)$$



Şekil 3.3. Önerilen ayırık dalgacık dönüşümlü MO-BSS algoritmasının blok diyagramı

Dalgacık katsayıları veya detay katsayıları olarak da adlandırılan ayrık dalgacık dönüşüm değerleri $T_{m,n}$, m, n üzerinden bir genişleme-öteleme ızgarasında şu şekilde verilir,

$$x(t) = \sum_{m=-\infty}^{\infty} \sum_{n=-\infty}^{\infty} T_{m,n} \psi_{m,n}(t) \quad (3.14)$$

ve Ters Ayrık Dalgacık Dönüşümü (IDWT, Inverse Discrete Wavelet Transform) formüle edilir [88].

DWT yönteminin MO-BSS algoritmasına uyarlanma işlemine ait blok diyagramı Şekil 3.3'te gösterilmiştir.

3.2.3. DWT Dalga Formları Yöntemi

Kullanılan dalgacık dönüşümü teorisinin karmaşıklığı, dalgacık yapışmasının orijinal işaret tasvirine yakınlığını belirler. Bir işaretin bu tasviri, geniş bant alıcısının performansının iyileştirilebilmesi için dönüşüm alanındaki işaretin farklı çözünürlüklerine yönelik bir kriterin oluşturulmasını gerektirir. Değişen karmaşıklık derecelerine sahip bir sistem entegrasyonunda kullanılabilecek birkaç dalgacık dönüşümü şeması vardır; bu şemalar, dönüşüm seçimini donanım karmaşıklığı ile orijinal işaretin doğruluğu arasında bir denge haline getirerek eşikleme kesimini gürültünün daha doğru bir şekilde ortadan kaldırılmasını sağlar [89].

Sonraki aileler özellikle DWT'de kullanılmak üzere tasarlanmıştır. Bu dalgacıklar kompakt bir şekilde desteklenir ve ortogonal veya biortogonaldır. Bir QMF yapısı oluşturabilen bir yüksek geçiş ve alçak geçiş analizi ve sentez filtresi ile karakterize edilirler. Her aile, dört filtreye yol açan belirli tasarım kurallarına göre tasarlanmıştır. Filtreler birkaç sıra için oluşturulabilir, ancak çoğu aile daha düşük derecelerle sınırlıdır. Bu filtrelerden, dalga biçimleri hiç düzgün görünmeyebilir, ancak dalgacık filtrelerinin hepsi frekans alanında düzgün geçiş bantlarına sahiptir. Genel olarak, daha yüksek düzeylerde işlevler zaman alanında daha düzgün hale gelir ve bu da onları gerçek hayattaki işaretleri analiz etmek için daha uygun hale getirmiş olur.

Dalgacık dönüşümünde yaygın olarak kullanılan Daubechies olarak da bilinen dalgacık dönüşümü kullanılır. Ayrık zamanda dalgacık analizini uygulanabilir hale getiren kompakt destekli ortonormal dalgacığı icat edilmiştir. Ölçeklendirme fonksiyonlarına

göre farklı katsayıları içeren bir aileden oluşur. Bu ailenin birinci dereceden üyesi aynı zamanda Haar dalgacığı olarak da bilinir.

3.2.4. Haar Dalgacık Dönüşümü Yöntemi

Bu dalgacık dönüşümü, dönüştürülmekte olan dalga formunun şeklini ve ayrıntısını tahmin edecek temel yaklaşım fonksiyonlarını kullanan dikdörtgen bir fonksiyona dayanır. Basitleştirilmiş Haar dalgacık dönüşümü, adım fonksiyonunun bir varyasyonu olan yaklaşık bir fonksiyon kullanır.

Haar'ın temel dönüşümü, bitişik adım çiftini daha geniş bir adım ve bir dalgacıkla değiştirerek f fonksiyonuna dalgacıklarla yaklaşmayı ifade eder. Daha geniş adım, ilk adım çiftinin ortalamasını ölçerken, iki alternatif adımdan oluşan dalgacık, ilk adım çiftinin farkını ölçer [90,91]. Bu yöntem temel dalgacık dönüşümü olup, geniş bantlı bir alıcı tasarımından beklendiği gibi yüksek çözünürlüklü işaretler için uygun değildir. Daha düşük (4 ila 6 dB) iki işaret dinamik aralığı için kabul edilebilir olsa da elde edilen işaret adım fonksiyonları olarak tanımlandığından +18 dB'de benzer performans beklenemez. Dolayısıyla bu dönüştürme yöntemi, işaret spektrumunun daha doğru bir şekilde tanımlanmasına ve dolayısıyla daha doğru gürültü gidermeye dayalı olarak sistem performansının iyileştirilmesine uygun bir aday değildir.

3.2.5. Daubechies Dalgacık Dönüşümü Yöntemi

Ingrid Daubechies, Daubechies dalgacık dönüşümünün Haar'ın süreksiz adım tasarımından ziyade sürekli bir işaret olması açısından Haar'ın dalgacık dönüşümünden farklı olan dalgacıkları kullanarak dönüşüm yapan yeni bir algoritma serisini tanıtmıştır. Sürekliliğin bir sonucu olarak sürekli işaretler daha doğru bir temsile sahiptir; ancak bu sürekliliğin karmaşık denklemler ve uygulamalar kullanma maliyeti vardır ve bu da daha karmaşık donanımlarla sonuçlanır. Bu fonksiyonların bazıları matris hesaplamalarına dayanmaktadır. Zaman açısından verimli ve sistem kullanımında uygulanabilir sürekli dalgacıklar tasarlamak için Daubechies, φ ile gösterilen temel bir yapı bloğu veya ölçeklendirme fonksiyonu tanıtılmıştır. Başlangıç koşulları için Daubechies dalgacıklarının nasıl hesaplandığına dair bir örnek aşağıda belirtilmiştir [89–91]:

$$\varphi(0) := 0$$

$$\varphi(1) := \frac{1+\sqrt{3}}{2}$$

$$\varphi(2) := \frac{1-\sqrt{3}}{2}$$

$$\varphi(3) := 0 \quad (3.15)$$

Bu koşullar şu koşulu karşılar:

$$\begin{aligned} \varphi(r) = & \frac{1+\sqrt{3}}{4} \varphi(2r) + \frac{3+\sqrt{3}}{4} \varphi(2r-1) + \\ & \frac{3-\sqrt{3}}{4} \varphi(2r-2) + \frac{1-\sqrt{3}}{4} \varphi(2r-3) \end{aligned} \quad (3.16)$$

Ayrıca, φ değerlerinin ortalama veya ağırlıklandırma faktörleri olarak görev yapabilmesi için başlangıç değerlerinin toplamının 1 olması da gereklidir.

$$\varphi(0) + \varphi(1) + \varphi(2) + \varphi(3) = 0 + \frac{1+\sqrt{3}}{2} + \frac{1-\sqrt{3}}{2} + 0 = 1 \quad (3.17)$$

φ fonksiyonu, ψ ile gösterilen ve aşağıdaki gösterimle tanımlanan ilgili dalgacık için temel yapı taşı görevi görmektedir:

$$\begin{aligned} \psi(r) := & -\frac{1+\sqrt{3}}{4} \varphi(2r-1) + \frac{3+\sqrt{3}}{4} \varphi(2r) - \\ & \frac{3-\sqrt{3}}{4} \varphi(2r+1) + \frac{1-\sqrt{3}}{4} \varphi(2r+2) \end{aligned} \quad (3.18)$$

$$= -h_0 \varphi(2r-1) + h_1 \varphi(2r) - h_2 \varphi(2r+1) + h_3 \varphi(2r+2) \quad (3.19)$$

$$\begin{aligned} = & (-1)^1 h_{1-1} \varphi(2r-1) + (-1)^0 h_{1-0} \varphi(2r-0) + \\ & (-1)^{-1} h_{1-[-1]} \varphi(2r-[-1]) + (-1)^{-2} h_{1-[-2]} \varphi(2r-[-2]) \end{aligned} \quad (3.20)$$

Daubechies dalgacı bu şekilde hesaplanır. Daubechies dalgacık yönteminin kaybolan momentleri kullandığı görülmektedir. Kaybolan anlar, fonksiyonda frekans ekseninin altına düştüğü bir nokta olarak tanımlanır. Kaybolan anlar, dönüştürülen dalgacığın düzgünlüğüne katkıda bulunur çünkü sistemin, pahalı donanım uygulamasından ödün

vermeden transfer fonksiyonundaki farklılıkları telafi etmesine olanak tanır [89]. Daubechies dalgacık dönüşümünde işaret yapışması, Haar dalgacığından daha belirgindir, bu da Daubechies dalgacık dönüşümünü ayrık dalgacık dönüşümünün daha popüler uygulamalarından biri haline getirmektedir [92]. Bu dönüşüm ve eşikleme yöntemi, alıcının sistem performansını iyileştirme konusunda Haar dalgacık dönüşümünden çok daha umut verici hale gelmiştir.

3.2.6. Eşik Belirleme ve Gürültü Giderme

Daha önce tartışıldığı gibi, dalgacık dönüşümü zamana dayalı işareti ayrıntılara ve işaret için genel bir forma ayırır. Frekans genliği açısından ayrıntılar çok daha küçük olduğundan, gürültünün büyük kısmı ayrıntılarda sorun yaratır. Gürültülü katsayıların olduğu yere sıfır eklemek, daha temiz bir işaret oluşturmak için olası bir çözümdür [93]. Bu yöntemin ana motivasyonları aşağıdaki varsayımlar ve gözlemlerle özetlenebilir:


1. Dalgacık dönüşümünün korelasyonsuzlaştırma özelliği seyrek bir işaret yaratır: dokunulmamış katsayıların çoğu sıfıra yakındır veya sıfırdadır.
2. Gürültü tüm katsayılara eşit olarak yayılır.
3. Gürültü seviyesi, işaretin gürültüden ayırt edilemeyecek kadar yüksek olmaması.

Belirli bir değerin altına sıfır ekleyen bir eşik eklemek, işaretin basit ve etkili bir tasarımla temizlenmesini sağlar. Bu basitlik, eşiklemeyi bir işarettaki gürültüyü azaltmak için yaygın bir çözüm haline getiren şeydir. Belirli bir eşik değerinin altındaysa küçük katsayıların sıfırla değiştirilmesine sert eşikleme adı verilir. Bir katsayının üzerindeki katsayıların mutlak bir değere indirildiği başka bir yöntem, katsayılarda daha fazla süreklilik sağlar. Gürültü katsayıları ile işaret katsayıları arasında temiz bir geçiş vardır. Yumuşak eşikleme adı verilen bu yöntem özellikle matematiksel kontrol edilebilirliğin korunmasında etkilidir; örneğin sürekli işaretler için yapılmış bir sistemde süresiz bir işaret kullanılamaz veya bazı istenmeyen sonuçlara neden olabilir. Bu durumlarda sürekliliği sağlayan yumuşak eşik, süresiz sert eşik yönteminden açıkça daha iyi bir seçim olacaktır. Ancak eşik türünün ayarlanması, ayarlanması gereken parametrelerden yalnızca biridir. Önemli bir parametre eşik seçimidir. Bu eşik birkaç öğeye dayandırılabilir: varyans sapmaları, yani ortalama mutlak sapma ve sayısal standart tahmin veya ortalama karesel hata kullanan eşik tahmin edicileri. Ortalama karesel hata,

öncelikle yumuşak eşikleme için bir eşik tahmincisi olarak kullanılır ve uygulamalar, ses işlemenin yanı sıra görüntü işlemeyi de içerir [93].

Gürültü giderme için kullanılabilecek çok sayıda DWT dalga formu vardır. Dalgacık katsayıları işaret ve dalgacık arasındaki benzerliğin bir ölçüsü olduğundan, dalga biçimi ayrıştırmanın kalitesini belirler. En iyi sonuçlar, dalga biçimi işarete iyi uyduğu zaman elde edilir. Çoğu işaret için, özellikle de kontrolde, düzgün bir dalga biçimi seçilmelidir. Kontroldeki ölçümlerin çoğu, alçak geçiş davranışına sahip nedensel sistemler tarafından üretilir, dolayısıyla çıktıları düzgün olacaktır. Bununla birlikte, yüksek dereceli dalgacıklar daha düzgün olduğundan, dalga biçimlerinin düzgünlüğü ile hesaplama süresi arasında her zaman bir denge olacaktır. Bu örnekte, az çok keyfi olarak, “Db1” dalgacığı seçilmiştir [94] .

Ters ayrık dalgacık dönüşümü, türetilen yaklaşım ve detay katsayılarından bir işareti yeniden oluşturur. Her ayrıştırma seviyesinde yarım bant filtreleri, frekans bandının yalnızca yarısını kapsayan işaretler üretir. Bu yöntemle zaman çözünürlüğü yüksek frekanslarda iyi olurken, frekans çözünürlüğü düşük frekanslarda iyi hale gelir. Filtreleme ve yok etme işlemine istenen seviyeye ulaşıncaya kadar devam edilir. Maksimum seviye sayısı işaretin uzunluğuna bağlıdır. Orijinal işaretin DWT'si daha sonra ayrıştırmanın son seviyesinden başlanarak elde edilir.



Şekil 3.4. Ters Ayrık dalgacık dönüşümünde işaretin yeniden yapılandırılması [96]

Şekil 3.4’te orijinal işaretin dalgacık katsayılarından yeniden yapılanma süreci gösterilmiştir. Yeniden yapılanma süreci ayrıştırma sürecinin tersidir. Her seviyede yaklaşıklık ve detay katsayıları iki ile üst örneklenir (upsampling), alçak geçiş ve yüksek geçiş filtrelerinden geçirilir ve daha sonra toplanır. Orijinal işaret elde edinceye kadar bu işleme devam edilir [95].

3.3. Çözümlerin PF Yakınlığını Ölçmede Kullanılan Metrikler

Çok amaçlı optimizasyon problemleri, aynı anda optimize edilecek birçok birbiriyle çelişen hedefi içerir [67,97–100]. Çok amaçlı evrimsel algoritmalar gibi çok sayıda yaklaşım, şu anda mühendislik, finans, lojistik gibi alanlarda yaygın olan problemleri çözmek için etkili ve farklı yöntemler geliştirilmiştir [101–104]. Farklı yaklaşımları değerlendirmek için çeşitli bağlamlarda uygun performans ölçümlerini tasarlamak kritik öneme sahiptir. Örneğin, Tek Amaçlı Optimizasyon Problemlerinin (SOOP, Single-Objective Optimization Problem) amacı, minimizasyon veya maksimizasyon açısından en uygun çözümü bulmaktır. SOOP'lerde iki çözümü karşılaştırmak ve daha iyi uyuma sahip olanı üstün olarak görmek nispeten kolaydır. Ancak MOOP'lerde çözüm üstünlüğünü değerlendirmek, çatışan hedeflerin varlığı nedeniyle çok daha karmaşıktır. Çeşitli yaklaşımlar sıklıkla Pareto baskınlık kavramına göre eşit derecede adil olan bir dizi çözümden oluşan bir optimal çözüm seti elde eder [105]. Bununla birlikte, Çok amaçlı optimizasyonda farklı optimal çözüm kümelerinin niceliksel bir karşılaştırmasını sağlamak da önemli derecede etkilidir. Bugüne kadar, MOOP'de çözüm seti optimallliğini tanımlamak ve MOEA'ların değerlendirilmesi için bir dizi niceliksel ölçüm önerilmiştir [106,107]. Her metrik, bir veya daha fazla performans kriterini dikkate alan bir bakış açısıyla tasarlanmıştır.

Tipik performans kriterleri, baskın olmayan çözüm kümesinin kapasitesini, çözümlerin gerçek Pareto cephelerine yakınsamasını, amaç uzayındaki çözümlerin çeşitliliğini, referans kümelerine göre baskın çözüm hacmi gibi durumları içerir. Örneğin Van Veldhuizen ve ark. baskın olmayan çözümlerin sayısını hesaplamak için metrikler tasarlamışlardır [107]. Çözümlerin gerçek PF'lere yakınlığını ölçmek için Nesil Mesafesi (GD, Generational Distance) metriği tanıtılmıştır [58,108]. Zhou ve ark. yüksek boyutlu MOOP'lerdeki çözüm çeşitliliğini ölçmek için Genelleştirilmiş Yayılım (Δ^*), Li ise Yayılma ölçü (SP, Δ , Spread) metriğini tanıtmışlardır [109]. Zitzler ve ark. ise referans setlerine göre optimal çözüm setlerinin hakim hacmini hesaplamak için popüler Hiper Hacim (HV, Hypervolume) metriğini geliştirmişlerdir [69,106]. Son yirmi yılda önerilen performans metriklerinin çokluğuyla birlikte, MOOA metrikleri üzerine yapılan araştırmalara yönelik çalışmalarda bulunmaktadır [110–114]. Örneğin Okabe ve ark. araştırmalarında MOOA metriklerini önem, mesafe, hacim, dağılım ve yayılma açısından sınıflandırmıştır [110].

Zitzler ve ark. MOOA metriklerini matematiksel bir çerçeveye kullanarak sınıflandırmıştır [111]. Klasik MOOA metriklerini analiz ettikten sonra Tan ve ark., Düzgün Dağıtım (UD, Uniform Distribution) parametresine bağlı bir ölçüm önermişlerdir [112]. Wu ve ark. öte yandan, HV ile ilişkili altı ölçüm çeşidini özetlemiş ve bunları MOOA'ları üzerinde uygulaması yapılmıştır [115]. MOO metrikleri üzerine yapılan birçok önemli anket, deneysel çalışma ve analizin bireysel metriğe odaklanmakla sınırlı olduğunu belirtmekte fayda vardır [110–114]. MOO ölçümleri arasındaki ilişkileri kurmaya yönelik bugüne kadar çok az çalışma yapıldı veya hiç çalışma yapılmadı. Dolayısıyla bu makale bu boşluğu doldurmaya çalışmaktadır. Bu tezde, çok amaçlı optimizasyonun farklı hedeflerine yönelik farklı algoritmalar arasındaki sayısal karşılaştırmayı göstermek için yaygın olarak kullanılan temel performans kriterlerine göre Ters Nesil Mesafesi (IGD, Inverted Generational Distance), HV ve SP dahil olmak üzere üç temsili ölçüt dikkate alınarak uygulama sonuçları test edilmiştir [116].

Metriklerden IGD ve HV algoritmaların hem yakınsama hem de çeşitlilik başarısını ölçerken, SP metriği çeşitlilik başarısını ölçmektedir. Bu metriklerden HV metriğinin değeri maksimum olması istenirken diğer IGD ve SP metrik değerinin minimum olması istenmektedir [117].

3.3.1. IGD Metriği

Bu gösterge, çok amaçlı optimizasyonun yakınlık ve çeşitlilik hedefi için niceliksel bir ölçüm sağlayan temsili bir ölçümdür. Adından da anlaşılacağı gibi GD'nin tersi olan IGD, Pareto cephesinin elde edilen çözüm kümesine ne kadar yakın olduğunu ölçmek için kullanılır.

IGD metriğinde P_T , nesnel uzayda eşit olarak dağılmış noktaların bir kümesidir. P_O , önerilen algoritma tarafından elde edilen baskın olmayan çözüm kümesidir ve P_T 'den P_O 'a olan ortalama mesafe şu şekilde tanımlanır [118]:

$$IGD(P_T, P_O) = \frac{\sum_{v \in P_T} dist(v, P_O)}{|P_T|} \quad (3.21)$$

burada $dist(v, P_O)$ iki nokta arasındaki minimum Öklid mesafesini gösterir. Hesaplanan IGD değerinin düşük olması P_T ile P_O arasındaki mesafenin yakınlığını gösterir. Önerilen algoritmalar için bu değer düşük olması tercih edilir [57,119–121].

IGD, bir çözüm kümesinin kalitesini dört yönün tamamı açısından yansıtmaya yeteneğine sahiptir: yakınsama, yayılma, tekdüzellik ve önem. Ancak IGD'nin önemli bir zayıflığı, değerlendirme sonuçlarının büyük ölçüde referans kümesinin davranışına bağlı olmasıdır. Pareto cephesi boyunca yoğun ve düzgün bir şekilde dağıtılmış çözümlerden oluşan bir referans seti gereklidir; aksi takdirde kolayca yanıltıcı sonuçlar verebilir [122]. Referans seti normal olarak elde edilen tüm çözümlerin toplanmasından oluşturulduğu için bu durum özellikle Arama Tabanlı Yazılım Mühendisliğinde (SBSE, Search-Based Software Engineering) sorunludur; dağıtımı kontrol edilemez. Ek olarak, referans kümesinin oluşturulma şekli, IGD'nin, dikkate alınan çözüm kümelerinin çoğunluğuyla tutarlı, belirli bir dağıtım modelini tercih etmesine neden olur [122]. Başka bir deyişle, eğer bir çözüm seti diğerlerinden çok farklı bir şekilde dağıtılsa, o zaman setin gerçek dağılımı ne olursa olsun, muhtemelen zayıf bir IGD değeri ataması muhtemeldir [119].

3.3.2. HV Metriği

IGD gibi HV de bir çözüm kümesinin kalitesini dört açıdan değerlendirir. Arzu edilen pratik kullanılabilirliği ve teorik özellikleri nedeniyle, HV muhtemelen SBSE'de tartışmasız en yaygın kullanılan göstergelerden biridir [123–131].

Bu hiper hacim metriği, tüm hedeflerin en aza indirileceği MOEA'lar tarafından elde edilen baskın olmayan çözüm setlerinin üyeleri tarafından kapsanan hacmi (hedef uzayında) hesaplar [132]. Belirtilen HV şu şekilde hesaplanabilir:

$$HV = volume \left(\bigcup_{i=1}^{|P_{oI}} \delta_i \right) \quad (3.22)$$

burada δ_i referans noktasına göre baskın hypervolume olarak adlandırılır. Yüksek bir HV değeri tercih edilir. HV göstergesinin bir sınırlaması, hedeflerin sayısına göre katlanarak artan hesaplama süresidir. Göstergenin 10'dan fazla hedefe sahip veya makul bir küme boyutu altında bir çözüm kümesinde uygulanabilir olmasını sağlayan teorik ve pratik olarak çalışma süresini azaltmak için birçok çaba sarf edilmiştir. Daha önce belirtildiği gibi, HV bir çözüm kümesinin diz noktaları lehinedir, dolayısıyla karar verici problemlerin Pareto cephesinin diz noktalarını tercih ettiğinde iyi bir seçimdir. Ayrıca referans noktasının ayarları değerlendirme sonuçlarını etkileyebilir [57,119].

3.3.3. SP Metriği

SP, çözümler arasındaki yayılmanın dağılımını ve kapsamını ölçmede kullanılır. SP göstergesi ve onun varyantları [58,109,133], alandaki çözüm kümelerinin çeşitliliğini yani, yayılma ve tekdüzelik özelliklerini değerlendirmek için yaygın olarak benimsenmiştir [129,134–138]. Özellikle çözümlerin yayılması sonucunda elde edilen komşu Pareto optimal çözümlerin Öklid uzaklıklarının ortalamasını verir. Pareto optimal çözümlerinin dağılımı aynı biçimde yinelenen olduğunda yayılma sıfıra eşittir. Spesifik olarak, iki amaçlı bir senaryoda bir çözüm kümesi A'nın göstergesi Δ aşağıdaki gibi tanımlanır.

$$\Delta(A) = \frac{\sum_{m=1}^M d_m^e + \sum_{i=1}^{|\varphi|} |d_i - \bar{d}|}{\sum_{m=1}^M d_m^e + |\varphi| \bar{d}} \quad (3.23)$$

Burada d_i , $\bar{d}$ ve d_m^e sırasıyla ardışık çözümler arasındaki Öklid uzaklığını, Öklid uzaklığının ortalamasını (d_i) ve P_T ve P_O uç çözümleri arasındaki mesafeyi belirtir [126].

Kümenin hem yayılma hem de tekdüzelik açısından iyi bir dağılımını gösteren küçük bir Δ değeri tercih edilir. $\Delta = 0$, kümedeki çözümlerin eşit uzaklıkta olduğu ve sınırlarının Pareto cephe uçlarına ulaştığı anlamına gelmektedir.

Δ 'nin (varyantları da dahil olmak üzere) önemli bir zayıflığı, baskın olmayan çözümlerin her iki hedefte de ardışık olarak konumlandırıldığı iki amaçlı problemlerde güvenilir bir şekilde çalışmasıdır. Daha fazla hedef olduğunda, bir hedefteki çözümün komşusu, başka bir hedefteki çözümün çok uzağında olabilir [139].

Bu sorun herhangi bir mesafeye dayalı çeşitlilik göstergesi için geçerlidir. İki'den fazla hedefi olan problemler için bölge bölünmesine dayalı çeşitlilik göstergeleri daha doğrudur [122]. Tipik olarak alanı birçok eşit boyutlu hücreye bölerler ve daha sonra çözümler yerine hücreleri dikkate alırlar (örneğin, bu hücrelerin sayısını saymak). Bu, daha çeşitli çözümlerin genellikle daha fazla hücreyi doldurduğu gerçeğine dayanmaktadır. Bununla birlikte, bu tür göstergeler, tipik olarak her hücrenin bilgisini kaydetmeleri gerektiğinden, boyut olumsuzluğundan zarar görebilir.

3.4. Kullanılan Amaç Fonksiyonları

Genel olarak BSS’de tek amaçlı optimizasyon problemlerinde W ayrıştırma matrisinin çözümü:

$$\min_W J(W) \quad (3.24)$$

ile ifade edilirken, $J(W)$ kaynakların seyreklik, Gauss olmama veya zamansallık gibi özellikleri içerir. Bu nedenle, kaynak ayrımının istenen özelliği temsil etmede $J(W)$ ayırma kriterine güçlü bir şekilde bağlı olduğu belirtilebilir. Bu bağlamda $J(W)$ kaynak işaretlerinin mükemmel bir şekilde ayrılmasını sağladığında kontrast fonksiyonu gibi davrandığı söylenebilir [4]. Ancak pratik durumlarda bu her zaman mümkün değildir, çünkü örneğin rastgele gürültünün karışması söz konusu olabilir.

Denklem (3.24)’ün çözümünde dikkate değer bir diğer husus, kişinin BSS problemi için tek bir çözüme, yani kaynak kümesinin tek bir tahminine ulaşmasıdır. Ancak biyomedikal işaret işleme gibi gerçek uygulamalarda karar vermek için birden fazla olası tahminin olması istenebilir. Belirli kriter çerçevesinde problemi tek amaçlı çözmek yerine, sunulan problemlerin çözümü için çok amaçlı optimizasyon uygulanması önerilmiştir. Birçok pratik durumda birden fazla kaynak karakteristiğine ilişkin bilgi mevcut olduğundan optimizasyon probleminde birden fazla kriter kullanılabilir. Bu durumda birden fazla kriteri dikkate alan ancak bunları tek bir maliyet fonksiyonunda birleştiren bazı yaklaşımlar sunulmuştur. Bu durumla ilgili olarak, problem için bir dizi optimal çözüme yol açan çok amaçlı optimizasyona dayalı bir yaklaşım olarak birden fazla kriteri dikkate alan modeli şu şekilde gösterebiliriz.

$$\min_W \lambda_1 J_1(W) + \lambda_2 J_2(W) + \dots + \lambda_K J_K(W) \quad (3.25)$$

burada $\lambda = (\lambda_1, \lambda_2, \dots, \lambda_K)$ ağırlık vektörüdür. λ ’yı önceden belirleyerek problem çözümlerse optimal bir ayrıştırma matrisi elde edilebilir. λ ağırlık değerleri değiştirilirse farklı çözümler elde edilebilir. Bu da farklı kaynaklar için farklı çözümler elde etmemize sebep olabilir. Kaynak işaretlerin iki özelliğine ilişkin iki farklı kriterden oluşan bir optimizasyon modeli Denklem (3.26)’da verilmiştir. Seyreklik ve korelasyon olarak iki farklı amaç fonksiyonu işaret ayrıştırma için kullanılacaktır. Bu şekilde, her bir kriter kombinasyonu için bir sonuç çözümü olacaktır. Çok amaçlı optimizasyonda bir kaynağın

seyrekliği ve aralarındaki ilişki hakkında bilgi olduğunu varsayalım. Seyreklik ve korelasyon kriterlerine dayalı optimizasyon problemi şu şekilde verilmektedir:

$$\min_W \lambda_1 J_{seyreklik}(W) + \lambda_2 J_{korelasyon}(W) \quad (3.26)$$

Bazı alanlarda seyrek olduğu söylenen işaretleri çıkarmak için kullanılan optimizasyon kriteri olarak l_1 -normu sunulmaktadır. Çok amaçlı optimizasyon için önerilen l_1 -normu yeniden ağırlıklandırılmış minimizasyon problemine bağlı olarak işaret tahmininde kullanılmaktadır. Bu şekilde istenen seyreklik değerinin elde edilmesi l_1 -norm minimizasyon yöntemi ile elde edilmektedir. Kaynak işaretlerine ilişkin bir dizi bilgiyi hesaba katmayı amaçlayan, ancak λ ağırlık kümesinin önsel tanımından kaçınarak, BSS problemleriyle başa çıkmak için çok amaçlı bir optimizasyon yaklaşım uygulanmasını aşağıdaki denklem ile çözümü verilmektedir.

$$\min_W [J_{seyreklik}(W), J_{korelasyon}(W)] \quad (3.27)$$

Verilen bu denklem ile kullanıcının problem hakkındaki öznel bilgisine göre en iyi olanı seçmesine temel olarak kullanılabilecek bir dizi baskın olmayan tahmin kümesi elde edilir. Bu tez kapsamında optimizasyon kriterlerini formüle etmek için hem seyreklik hem de zaman korelasyon kriterleri kullanılmıştır.

İlk kriter olarak l_1 -norm minimizasyonu yoluyla alınan kaynakların seyrekliğini hesaba katan bir ayırma kriteri oluşturularak işlem yapılmıştır. Ölçeklendirme sorunlarından kaçınmak için l_1 -normunu normalleştirebiliriz;

$$J_1(W) = \sum_{i=1}^2 \frac{\|W_i^T x(t)\|_1}{\|W_i^T x(t)\|_2} \quad (3.28)$$

burada W_i^T , i . kaynağın tahminiyle ilişkili W ayrıştırma matrisinin i . satırını temsil eder.

İkinci olarak, minimizasyon problemine uyarlanmış optimizasyon işlemi Denklem (3.29)'de verilmektedir.

$$J_2(W) = -\sum_{i=1}^2 |E[W_i^T x(t)x(t-\tau)^T w_i]| \quad (3.29)$$

$J_2(W)$ 'nin hesaplanmasının önceden tanımlanmış bir τ gecikmesine bağlı olarak belirlenir. Bu parametre, zamansal yapının görsel olarak daha belirgin olduğu karışımın otokorelasyon fonksiyonundan doğrudan bulunabilir.

Dikkate alınan her iki kriterin de farklı özelliklere sahip olduğunu belirtmekte fayda var. Seyreklik, elemanlarının çoğunun sıfıra yakın olduğu vektörlerle ilgilidir. Öte yandan, otokorelasyon, alınan kaynakların zamansal yapısından yararlanır. Bu nedenle çok amaçlı problemin çözümü

$$\min_W \left[\sum_{i=1}^2 \frac{\|W_i^T x(t)\|_1}{\|W_i^T x(t)\|_2}, - \sum_{i=1}^2 |E[W_i^T x(t)x(t-\tau)^T w_i]| \right] \quad (3.30)$$

ile ifade edilir. Böylece her iki özellik arasındaki dengeyi temsil eden ve baskın olmayan çözümlerin elde edilmesi sağlanır.

Kör kaynak ayrıştırma uygulamasında, yapay olarak oluşturulmuş bir A matrisinden, literatürden alınan kaynaklar kullanılacak ve karıştırılacaktır. Karışık veriler daha sonra baskın olmayan çözümler bulmak için çok amaçlı algoritmaya sunulacaktır. Her iki amaç fonksiyonunda da çok amaçlı modelin çözümü, soruna yönelik bir dizi baskın olmayan çözümle sonuçlanır. Bu çalışmada gerçekleştirilen deneyler, kaynakların bazı spesifik özelliklerinin kullanımını içerse de, çok amaçlı modelin herhangi bir veri seti ve optimizasyon kriterine genellenebileceğini doğrulamaktadır [81].

3.5. Benimsenen Çok Amaçlı Algoritma Hakkında Genel Hususlar

Kör kaynak ayrımı kapsamındaki amaç fonksiyonlarının dışbükeylik açısından analiz edilmesi zor olduğundan, özellikle çok amaçlı optimizasyonda eş zamanlı olarak ele alındığında deneyler için SPEA2 algoritması tercih edilmiştir. Bu nedenle, maliyet fonksiyonları tanımlandıktan ve çok amaçlı model formüle edildikten sonra sorunun çözümü için SPEA2 uygulanmıştır. Algoritmanın her yinelenmesinde, değişkenler (çıkarma vektörü, ayırma matrisi, doğrusal olmayanların veya kaynakların parametreleri ve ele alınan soruna bağlı olarak karıştırma matrisi), baskın olmayan çözümlere yaklaşıma kadar evrimsel operatörlerden geçer. Ayrıca, bu çalışmada gerçekleştirilen tüm deneyler için bazı başlangıç değerlendirmeleri yapılmıştır. Bunlar:

Girdi: Tüm deneylerde dikkate alınan rekombinasyon oranı $c = 0,5$ 'tir. Ters problem bağlamındaki deney haricinde, başlangıç popülasyonu P_1 'in bireyleri rastgele oluşturuldu ve tüm arama uzayını kapsayabildi. Çıkarma vektörü veya ayırma matrisi ile ilgili bireyler durumunda, $[-1, 1]$ aralığı dikkate alınmıştır, çünkü BSS tekniklerinin doğasında bulunan ölçek belirsizliği göz önüne alındığında, bu, kaynak kurtarma işlemiyle ilgisizdir.

Varyasyon: $c = 0,5$ rekombinasyon oranına göre, varyasyon popülasyonunun %50'si rekombinasyona, %50'si ise mutasyona uğrar. Ayrıca bu aşamada dikkate alınması gereken önemli bir nokta da bu operatörlerin kaç değişkene göre hareket edeceğidir. SPEA2'nin yakınsamasını hızlandırmak için, bu miktarı, seçim mekanizmasındaki rastgele bir karaktere ek olarak, algoritmanın bulunduğu mevcut nesil ve maksimum nesil sayısı T 'nin bir fonksiyonu olarak belirledik. Böylece ilk nesillerde daha fazla değişken değiştirilebiliyor, algoritma ilerledikçe bu sayı azalıyor. Aşağıda her operatör için bu miktarı elde etme mekanizmasını (buna B diyeceğiz) sunuyoruz.

Rekombinasyon: $Nvar$ her bireydeki elementlerin (değişkenlerin) sayısı ve g mevcut neslin sayısı olsun. İlk olarak, rekombinasyonun etki edeceği elementlerin B sayısını şu şekilde belirleriz:

$$B = randi\left(1, round\left(\frac{(g-1)*(1-(Nvar-1))}{T-1} + (Nvar - 1)\right)\right) \quad (3.31)$$

burada $round(\beta)$, çıkışı β 'ya en yakın tam sayı olan bir fonksiyondur ve $randi(\vartheta_1, \vartheta_2)$ çıkışı $[\vartheta_1, \vartheta_2]$ aralığında bir tam sayı olan rastgele bir üretectir. Daha sonra, varyasyon popülasyonundan iki bireyi i ve j 'yi rastgele seçiyoruz. B pozitif tamsayılar $z = [z_1, \dots, z_B]$, burada $0 \leq z_B \leq Nvar$ biçiminde ifade edilir.

Rekombinasyon, bireysel i 'nin z elemanlarının, j bireyinin z elemanları ile değiştirilmesi ve bunun tersi ile yeni bireyler i' ve j' oluşturularak gerçekleştirilir. Yeniden birleştirilen bireylerin orijinalerle aynı olması durumundan kaçınmak için, rekombinasyon operatöründe dikkate alınan maksimum B 'nin $Nvar - 1$ olduğunu belirtmek gerekir.

Mutasyon: Mutasyon durumunda B 'yi elde etme mekanizması, rekombinasyon mekanizmasına benzer, yalnızca $Nvar$ için maksimum değerini değiştirir (bu da ilk nesillerdeki tüm elementlerde mutasyona izin verir). Böylece, Denklem (3.32) ile B sayısını belirlenir.

$$B = randi\left(1, round\left(\frac{(g-1)*(1-Nvar)}{T-1} + Nvar\right)\right) \quad (3.32)$$

Burada varyasyon popülasyonundan rastgele bir i bireyi ve $0 \leq z_i \leq Nvar$ olan B pozitif tamsayılar $z = [z_1, \dots, z_B]$ 'yi seçiyoruz. Mutasyon bireyin z_b elemanlarını değiştirerek gerçekleştirilir ve burada $b = 1, 2, \dots, B$ olmak üzere i bireyin $i'_{z_B} = (1 + 0,1 * randn) * i_{z_B}$ olarak bulunur. Ayrıca i_{z_B} , i bireyin z_b 'inci elemanıdır, i'_{z_B} de i' bireyin z_b 'inci elemanıdır. $randn$ ise , ortalaması 0 ve standart sapması 1'e eşit olan Normal dağılımdan elde edilen rastgele bir sayıdır [4,81].



4. BÖLÜM

MO-BSS YÖNTEMİ İLE İŞARETLERİN AYRIŞTIRILMASI

Başlangıçta uygulamaya ait gerekçeler sunulacak ve sonrasında önerilen sorunların çözümü için düşünülen modeller sunulmuştur. Benimsenen çok amaçlı algoritmaya ilişkin ek hususlar da gösterilmiştir.

Kör kaynak ayırıştırma genelde tek amaçlı optimizasyon yöntemleri kullanılmaktadır. Bu da ayırıştırmanın doğrulanması yönünde soru işaretlerine sebebiyet vermektedir. Çok amaçlı optimizasyon ile ayırıştırma işleminin doğruluğunun teyit edilmesi ve farklı amaç fonksiyonları ile sonuç değerlendirmenin daha verimli olması sağlanacaktır.

Tez çalışmasının uygulama bölümünde kullanılan yöntemlerden MO-BSS, Ön işlemlerli MO-BSS ve DWT MO-BSS yöntemlerinin SNR değeri ile performansları ve işlem süreleri test edilmiştir. Uygulamada kullanılan test işaretleri konuşma ve biyomedikal işaret olarak iki farklı türde ayırıştırılmış ve algoritmaların performansları değerlendirilmiştir. Konuşma işareti olarak iki kadın ve bir erkek konuşma sesi kullanılmıştır. Algoritma performanslarının teyiti için birbirlerine karışmış iki erkek ve bir gürültü işaretinin ayırıştırılması yapılmıştır. Ayrıca biyomedikal işaret olarak Anne EKG, Fetal EKG ve beyaz Gauss gürültü işaretleri kullanılmıştır. Aynı zamanda EEG ve beyaz Gauss gürültü işaretlerinin ayırıştırılması da aynı yöntemler ile test edilmiştir. Tez kapsamında BSS için SPEA2 algoritması ile çok amaçlı ayırıştırma yapılarak SNR değerleri ölçülmüştür. Kör kaynak ayırıştırma için kullanılacak olan SPEA2 algoritmasından önce işaretler rastgele karıştırılarak ön işlemler uygulanması ve bu sayede veri işlemeyi kolaylaştırmanın yanı sıra boyut indirgeme ve hızlı yakınsama sağlanmıştır. Sonrasında MO-BSS yöntemine ayrık dalgacık yöntemi uygulanarak test işlemleri ayrıca değerlendirilmiştir.

Bazı çalışmalarda işaret sayısına göre sabit karıştırma matrisleri kullanılırken yani iki işaret için Denklem (4.1)'de verilen ifadeler yaygın şekilde ele alınırken bu çalışmada günlük hayatta işaretlerin nasıl karıştığını bilmediğimizden rastgele oluşturulmuş karıştırma matrisleri kullanılmıştır ($A = rand_orth(2)$).

$$A = \begin{bmatrix} 1 & 0.5 \\ 0.5 & 1 \end{bmatrix} \text{ veya } A = \begin{bmatrix} 1 & 0.7 \\ 0.7 & 1 \end{bmatrix} \text{ v.b.} \quad (4.1)$$

Değerlendirmede SNR değeri aşağıdaki denklem ile hesaplanmıştır.

$$SNR_{dB} = 10 \log_{10} \left(\frac{P_s}{P_n} \right) \quad (4.2)$$

burada P_s ve P_n sırasıyla işaret ve gürültü işaretlerinin gücünü temsil etmektedir.

4.1 Araştırma Modeli ve Uygulama


Yapay ve doğrusal şekilde karıştırılmış işaretleri birbirinden ayırmak için yapılan bu çalışmada üç farklı kaynaktan alınan işaretler üç sensör tarafından kaydedilmiş ve tekrar kaynak işaretleri elde etmek için farklı algoritmalar üzerinde uygulamalar yapılmıştır. İşaretlerin karıştırılmasında kaynak ve sensör uzaklıkları eşit kabul edilerek doğrusal karışım rastgele matris kullanılarak yapılmıştır. Rastgele matris kullanılarak daha doğal ve ayrıştırılması zor olan karışımlar elde edilmiştir.

Uygulamalar iki farklı işaret grupları üzerinde yapılmıştır. İlk uygulama konuşma sesleri üzerinde, ikinci uygulama ise biyomedikal işaretler üzerinde yapılmıştır. İlk yapılan uygulamalarda belirlenen amaç fonksiyonları doğrultusunda iki kadın ve bir erkek konuşma seslerine ait veriler ile gerekli simülasyon çalışmaları yapılmıştır. Bu tezde kullanılan konuşma sesleri [140] numaralı kaynaktan alınmıştır. Üç sese ait veriler her seferinde farklı karıştırma matrisleri ile karıştırılmak suretiyle algoritmaların 50 koşma sonucundaki değerleri incelenmiş ve elde edilen tahmini işaretler yorumlanmıştır. Öncelikle MO-BSS algoritmasında uygulamalar yapılmıştır. Sonuçlar 50 koşmanın her adımında SNR değerleri kaydedilmiş ve bunların ortalaması da alınarak grafik ve tablolar eşliğinde sunulmuştur. Aynı zamanda algoritma performans metrikleri ile de değerlendirilmiştir. Her algoritma için ayrıca çalışma sürelerinin ortalamaları da tablo şeklinde verilmiştir.

MO-BSS algoritmasının hesaplama performansını artırmak için ön işlem yöntemi dediğimiz beyazlatma işlemi uygulanmıştır. MO-BSS algoritmasında yapılan simülasyon çalışmaları ve değerlendirme yöntemleri bu algoritma için de yapılmış olup kıyaslama sonuçları tablolarda gösterilmiştir.

Önerilen ön işlemlili MO-BSS uygulamasından sonra DWT ile MO-BSS uygulaması yapılmıştır. Aynı şekilde tüm sonuçlar diğer algoritma verileri ile de karşılaştırılarak ayrıntılı olarak SNR ve performans metrikleri tablo şeklinde gösterilmiştir. Tüm uygulamalarda veriler değerlendirilirken 1000, 2000, 5000, 10000, 20000 ve 30000 örnek sayısı dikkate alınarak farklı uzunluktaki veri miktarlarına göre SNR oranları değerlendirilmiştir.

Şekil 4.1’de kullanılan iki kadın ve bir erkek konuşma işaretlerinin 10000 örnek sayısı olarak gösterimi verilmiştir. Bu veriler kaynak veri veya kaynak işaret olarak adlandırılmaktadır.




Şekil 4.1. İki kadın ve bir erkek konuşma sesine ait kaynak işaretler

Bu üç işaret rastgele karıştırılarak MO-BSS algoritmasına uygulanmış ve performans sonuçları kaydedilmiştir. Bu algoritmanın kararlılığını ölçmek için her işaret ayrıştırma adımında rastgele karıştırma matrisi değiştirilmiş ve 50 koşma olarak Monte Carlo uygulaması yapılmıştır. Monte Carlo simülasyonu birçok alanda problem çözümlerinde kullanılmaktadır [141]. Burada Monte Carlo simülasyonu her koşmada farklı karıştırma

matrisleri kullanarak kaydedilen SNR değerlerinin ortalaması alınmaktadır. Bu yöntem ile algoritmaların gerçek performansları değerlendirilmiştir. Önerilen SPEA2 simülasyonunda kullanılan parametre değerleri popülasyon büyüklüğü 100, harici küme büyüklüğü 50, çapraz geçiş oranı 50 ve maksimum yineleme sayısı 60 olarak belirlenmiştir.


Uygulamada Şekil 4.2'de görüldüğü gibi orijinal kaynak işaretler, rastgele karışım işaretler ve MO-BSS algoritma sonucu tahmin edilen kaynak işaretlerin daha iyi gözlemlenmesi için 4000 örnek büyüklüğündeki değişimleri gösterilmektedir. Şekilde karışım işaretleri üç işaretin karışımı olduğundan genlik durumlarına göre karışım oranları değişiklik göstermektedir. İşaret ayrıştırma sonucunda elde edilen tahmini işaretler ne kadar orijinal işaretlere benzese de görsel olarak bunu anlamak çok zordur. Dolayısıyla SNR ve metrik değerleri gerçek tahmini işaretler hakkında bilgi verecektir.



Şekil 4.2. Kullanılan orijinal kaynak işaretler, karıştırılmış işaretler ve tahmin edilen kaynak işaretler

Uygulamada SPEA2 algoritması kullanılarak baskın olmayan kümenin yanı sıra her bir kriteri ayrı ayrı en aza indiren çözümler ve baskın olmayan kümedeki en iyi çözüm Şekil

4.3'te gösterilmektedir. İşaretler rastgele karıştırıldığı için her koşmada Pareto cephesindeki çözümler de değişmektedir.



Şekil 4.3. Algoritmanın koşma sırasında rastgele alınan Pareto cephesi


MO-BSS algoritma performansını daha ayrıntılı incelemek için Tablo 4.1'de verilen değerler SNR cinsinden kaydedilmiştir. Kullanılan işaretler 1000, 2000, 5000, 10000, 20000 ve 30000 örnek boyutlarında ayrıştırma işlemine tabi tutulmuştur. Bu örnek sayıları rastgele seçilmiş olup algoritmanın performansı hakkında yeterince bilgi sahibi olmaya yeterlidir. Tablodaki değerler algoritmanın 50 koşma sonucundaki ortalama değerlerini göstermektedir.

Tablo 4.1. Örnek sayılarına göre MO-BSS yönteminin SNR değerleri

Örnek Sayısı	1.Kadın Sesi İçin MO-BSS	2.Kadın Sesi İçin MO-BSS	Erkek Sesi İçin MO-BSS
1000	20.56	21.09	24.64
2000	22.41	20.35	25.37
5000	23.18	22.94	22.61
10000	25.64	23.15	24.33
20000	22.73	21.11	23.15
30000	26.10	25.84	27.42

Çok amaçlı optimizasyon yardımıyla karışmış işaretlerin ayrıştırılmasında Tablo 4.1'deki değerler incelendiğinde özellikle kadın seslerinde birbirine yakın sonuçlar dikkat çekerken erkek sesinin ayrıştırılmasının daha iyi sonuçlar verdiği gözlemlenmiştir. Kadın seslerinde örnek sayısı arttıkça SNR değerinin de arttığı, erkek ses işaretinde ise artış oranının sınırlı kaldığı görülmektedir. Birinci kadın sesinde en iyi ayrıştırma değeri 26.10 dB ile 30000 örnek boyutunda en düşük ayrıştırma ise 20.56 dB ile 1000 örnek boyutunda olduğu görülmektedir. İkinci kadın sesinin ayrıştırılmasında, en yüksek 25.84 dB ile 30000 örnek boyutunda en düşük ise 20.35 dB ile 2000 örnek boyutunda hesaplanmıştır. Erkek sesinde ise ölçülen en yüksek 27.42 dB ile 30000 örnek boyutu ve en düşük değer olarak 22.61 dB ile 5000 örnek boyutundaki verilerde elde edilmiştir.


Birinci kadın sesinin ayrıştırılmasında algoritmanın 50 koşmada alınan her bir SNR değeri Şekil 4.4'te verilen grafikte gösterilmiştir. Bu değerler 10000 örnek boyutunun ayrıştırılmasından alınmıştır. Birinci kadın ses işareti için algoritmanın her koşmadaki SNR değerleri tam sayı olarak alınmış olup 18 dB ile 32 dB arasında değiştiği anlaşılmaktadır. Bu değişik normal olup işaretlerin her örnek adımındaki genlik değerleri ve karıştırma matrisinin her koşmada farklı değerler almasından kaynaklanmaktadır.




Şekil 4.4. Birinci kadın sesi için algoritmanın 50 koşma sayısındaki SNR sonuçları

Şekil 4.5'te ikinci kadın ses işaretinin algoritmanın 50 koşmadaki ayrıştırılmasında SNR değerleri 17 dB ve 35 dB arasında değişiklik göstermiştir. 10000 örnek boyutundan alınan

bu değerlerin ortalaması 23 dB olarak hesaplanmıştır. Birinci kadın sesinde olduğu gibi burada da değerler değişkenlik göstermiştir.



Şekil 4.5. İkinci kadın sesi için algoritmanın 50 koşma sayısındaki SNR sonuçları



Şekil 4.6. Erkek sesi için algoritmanın 50 koşma sayısındaki SNR sonuçları

Şekil 4.6'da gösterilen erkek ses işaretinin ayrıştırılmasında ise değerlerin tam sayısı alınarak 19 dB ile 35 dB arasında değişen SNR değerleri elde edilmiştir. Ortalama SNR değeri ise 24 dB'dir. Burada kaynak işaretlerin iki kadın ve bir erkek sesi olarak seçilmesi algoritmanın performansını olumsuz yönde etkileyen verilerdir. Genel olarak çalışmalarda iki işaret kullanılmakta ve bu işaretlerin biri ses olurken diğeri gürültü

şeklinde verilmektedir. Dolayısıyla bu işaret karışımların ayrıştırılması nispeten daha kolay olacağından SNR değerleri de yüksek çıkabilmektedir. Tezde kullandığımız işaretler ve kaynak sayısı gerçek hayatta karşılaştığımız doğal ortamlar göz önüne alınarak üç farklı işaret olarak seçilmiş ve en zor şartlarda bu işaretlerin ayrıştırılması sağlanmıştır.

MO-BSS algoritmasının performans değerleri ölçmek için ise performans metrikleri kullanılmıştır. Tablo 4.2’de IGD metriği için en iyi değer, en kötü değer ve ortalama değerleri verilmiştir. Metrik değerlerinin ölçümü için de verilerin örnek boyutları aynı değerler kullanılarak simülasyonlar yapılmıştır. IGD değerinin küçük olması istenirken örnek sayısı arttıkça en iyi, en kötü ve dolayısıyla ortalama değerlerinde arttığı gösterilmiştir. En iyi IGD değeri 0.00012 ile 5000 örnek boyutunda en kötü IGD değeri ise 0.12644 ile 30000 örnek boyutunda hesaplanmıştır. Ortalama değerler incelendiğinde, işaretlerin örnek sayısı arttıkça IGD değerlerinin de arttığı gözlemlenmiştir.

Tablo 4.2. MO-BSS yönteminin IGD metrik değerleri

Örnek Sayısı	IGD Metriği		
	En İyi Değer	En Kötü Değer	Ortalama Değer
1000	0.00013	0.01348	0.00557
2000	0.00016	0.02910	0.00612
5000	0.00012	0.07097	0.00916
10000	0.00057	0.05611	0.01648
20000	0.00346	0.08078	0.01935
30000	0.00448	0.12644	0.02354

Tablo 4.3’te HV metriği için ölçümler yapılmıştır. Ortalama değerlere baktığımızda en iyi değer 10000 örnek boyutunda 0.65848 değer aldığı, en kötü ise 1000 örnek boyutu ile 0.22645 değer aldığı tabloda gösterilmiştir. Genelde örnek sayısına göre artış olsa da işaret karışımlarından dolayı baskın olmayan çözüm setlerindeki verilerin değerleri farklı olacaktır. Bu da örnek sayısından bağımsız olarak tüm metrikler de değişkenlik göstermektedir.

Tablo 4.3. MO-BSS yönteminin HV metrik değerleri

Örnek Sayısı	HV Metriği		
	En İyi Değer	En Kötü Değer	Ortalama Değer
1000	0.80568	0.02318	0.22645
2000	0.83521	0.03684	0.23634
5000	0.76841	0.04582	0.34405
10000	0.97748	0.03845	0.65848
20000	0.96826	0.05461	0.52021
30000	0.98645	0.05867	0.54244

Tablo 4.4'te ise SP metriğinin ölçüm sonuçları verilmiştir. Burada metrik değerlerinin küçük değerler alması istenir. Dolayısıyla en iyi 5000 örnek boyutunda 0.66842 değeri ve en kötü değer olarak 20000 örnek boyutundaki 1.69834 değeri görmekteyiz. Ortalamaya baktığımızda ise istenen metrik değeri 2000 örnek boyutunda 1.15457 olarak hesaplanmıştır.

Tablo 4.4. MO-BSS yönteminin SP metrik değerleri

Örnek Sayısı	SP Metriği		
	En İyi Değer	En Kötü Değer	Ortalama Değer
1000	0.68425	1.60145	1.25843
2000	0.71121	1.51641	1.15457
5000	0.66842	1.59831	1.18412
10000	0.74645	1.56112	1.17398
20000	0.88684	1.69834	1.21780
30000	0.94365	1.48079	1.23452

Tasarlanan algoritmanın çalışma süreleri örnek sayılarına göre incelenmiştir. Tablo 4.5'te belirtilen değerler 50 koşmada Monte Carlo analizi sonucundaki ortalama sürelerdir. Örnek sayısı arttıkça hesaplama yükü de artacaktır. Yalnız örnek sayısına göre aynı oranda artış olmamıştır. Tablo 4.5'te verilen süreler tek amaçlı optimizasyon algoritmalarına göre yüksek olsa da çok amaçlı optimizasyon algoritmalarının işlem

yüklerinden dolayı yüksektir. Çünkü işlem yükü tek amaçlı optimizasyonlara göre fazladır.

Tablo 4.5. MO-BSS yönteminin farklı örnek sayılarına göre çalışma süreleri

Örnek Sayısı	MO-BSS (sn)
1000	3.36
2000	5.67
5000	7.39
10000	11.42
20000	18.24
30000	23.69

Genel olarak bakıldığında MO-BSS algoritmasının çalışmasında SNR değerlerinin yüksek olması istenmektedir. Bu doğrultuda algoritmanın performansını artırmak için bir dizi işlemler yapılmıştır. Ayırıştırma işlemine başlamadan önce işaretleri korelasyonsuz bir değişkene dönüştürüp işaretlerin daha yüksek SNR değerlerinde ayrıştırılması amaçlanmıştır. Bu yöntem ön işlem dediğimiz beyazlatma işlemi olarak işaretlere uygulanarak algoritmanın işlem performansı incelenmiştir.

4.2. Ön İşlem ve Ayrık Dalgacık Dönüşümü Uygulaması

Çok amaçlı optimizasyon yöntemi ile uygulanan SPEA2 algoritmasına ön işlem olarak beyazlatma uygulanıp sonuçlar değerlendirilmiştir. Devamındaki uygulamada ise MO-BSS yöntemine DWT uygulanmış ve bu sayede işaretlerde boyut indirgeme yapılarak algoritmanın başarı oranı test edilmiştir.

4.3. Ön İşlem Uygulanarak İşaret Ayırıştırma

Bu bölümdeki ilk uygulamada MO-BSS ile ön işlemlili MO-BSS algoritmalarının karşılaştırmalı bir değerlendirilmesi yapılmıştır. Şekil 3.1'deki blok diyagramına göre algoritma tasarlanmış ve aynı işaretler ile uygulama yapılmıştır. Algoritma performansı daha ayrıntılı incelemek için Tablo 4.6'da verilen değerler SNR cinsinden kaydedilmiştir.

Bu tabloda ilk yapılan uygulama ile ön işlemlili MO-BSS algoritmalarının sonuçları kıyaslama açısından birlikte verilmiştir. Aynı şekilde işaretler 1000, 2000, 5000, 10000, 20000 ve 30000 örnek boyutlarında ayrıştırma işlemine tabi tutulmuştur.


Tablo 4.6. Örnek sayılarına göre ön işlemlili MO-BSS yönteminin SNR değerleri

Örnek Sayısı	1. Kadın Sesi İçin		2. Kadın Sesi İçin		Erkek Sesi İçin	
	MO-BSS	Ön İşlemlili MO-BSS	MO-BSS	Ön İşlemlili MO-BSS	MO-BSS	Ön İşlemlili MO-BSS
1000	20.56	29.08	21.09	31.37	24.64	32.47
2000	22.41	34.61	20.35	33.28	25.37	36.31
5000	23.18	32.13	22.94	32.17	22.61	35.92
10000	25.64	35.71	23.15	34.63	24.33	37.34
20000	22.73	33.52	21.11	36.97	23.15	37.63
30000	26.10	38.02	25.84	38.36	27.42	39.18

Tablo 4.6'daki değerler algoritmanın 50 koşma sonucundaki ortalama değerleridir. Ön işlemlili MO-BSS algoritmasının her üç ses işaretinin ayrıştırılmasında daha iyi sonuçlar verdiği tabloda gösterilmiştir. Ayrıca ikinci kadın sesinin birinci kadın sesinden daha iyi ayrıştırıldığı, erkek sesinin ise örnek sayısı arttıkça SNR değerinin de arttığı gözlemlenmiştir. Bu durum işaret ayrıştırma tekniklerinde örnek sayısı ile SNR değerinin artması genel olarak paralellik göstermektedir. Tablodaki değerler ayrıntılı olarak incelendiğinde MO-BSS algoritmasında birinci kadın sesinin en düşük SNR değeri 20.56 dB iken ön işlemlili MO-BSS'de 29.08 dB'ye yükselmiştir. En yüksek değer ise 26.10 dB'den 38.08 dB'ye çıkarılmıştır. Bu sonuçlar ile yaklaşık %45 oranında performans artışı sağlanmıştır. İkinci kadın sesinin ayrıştırılmasında MO-BSS algoritmasında en düşük SNR değeri 20.35 dB olarak hesaplanmışken ön işlemlili MO-BSS algoritmasında bu değer 33.28 dB'ye çıkarılmıştır. En yüksek 25.84 dB olarak hesaplanan değer ise 38.36 dB'ye yükseltilmiştir. Genel olarak tüm örnek sayısındaki değerlere bakıldığında yaklaşık %50-65 arasında artış olduğu hesaplanmaktadır. Erkek sesinin ayrıştırma sürecinde ise MO-BSS algoritmasında en düşük SNR değeri 22.61 dB olarak hesaplanırken ön işlemlili MO-BSS algoritmasıyla bu değer 35.92 dB'ye yükseltilmiştir. En yüksek hesaplanan

27.42 dB değeri de önerilen algoritma yöntemi ile 39.18 dB'ye çıkarılmıştır. Tüm örnek sayılarındaki SNR değerleri incelendiğinde yaklaşık %40-60 arasında algoritmanın performans artışı sağlanmıştır.


10000 örnek boyutundaki birinci kadın sesinin ayrıştırılmasında 50 kez çalıştırılan Monte Carlo analizinin her koşmadaki ön işlemleri MO-BSS algoritmasının SNR değerleri ise Şekil 4.7'deki grafikte gösterilmiştir. SNR değerleri 22 dB ile 43 dB arasında değişkenlik göstermektedir. 10000 örnek sayısındaki ortalama SNR değeri MO-BSS'de 25 dB iken ön işlemleri algoritmada 35 dB ile kayda değer bir artış sağlanmıştır.




Şekil 4.7. Birinci kadın sesi için ön işlemleri MO-BSS'nin 50 koşmadaki SNR sonuçları

İkinci kadın sesi için ise SNR değerleri 21 dB ile 47 dB arasındaki değişen değerler ile Şekil 4.8'de gösterilmektedir. 10000 örnek sayısındaki ortalamaya bakıldığında SNR'si 34 dB değeri ile MO-BSS algoritmasında ölçülen 23 dB değerinden oldukça iyi olduğu anlaşılmaktadır.

Erkek sesinin ayrıştırılmasında SNR değerinin 29 dB ile 45 dB arasında değişen grafiği Şekil 4.9'da gösterilmiştir. Erkek sesinde diğer iki sese nazaran SNR değerleri arasındaki farkın yani en düşük ile en yüksek değerlerin birbirine yakın olduğu görülmektedir. Bu değişikliklerin ana nedeni karıştırma matrisidir. Daha önce de belirtildiği gibi karıştırma matrisi rastgele oluşturulmuştur.



Şekil 4.8. İkinci kadın sesi için ön işlemlili MO-BSS'nin 50 koşmadaki SNR sonuçları



Şekil 4.9. Erkek sesi için ön işlemlili MO-BSS'nin 50 koşmadaki SNR sonuçları

Algoritmaların performanslarını daha iyi görmek ve karşılaştırmak için Tablo 4.7'de IGD metrik değerleri verilmiştir. Ön işlemlili MO-BSS algoritmasının IGD değerleri MO-BSS yönteminden daha iyi olduğu ve özellikle 30000 örnek sayısındaki performansının başarılı olduğu görülmektedir. En iyi değerler kategorisi incelendiğinde 10000 örnek boyutu hariç diğer IGD metrik değerlerinde azalma görülerek başarımlar sağlanmıştır. En kötü değerler kısmında 1000 örnek boyutu hariç diğer örnek boyutlarında istenen sonuçlar elde edilmiştir. Ortalama değerler kategorisinde ise önerilen yöntemin IGD

metrik değerleri incelendiğinde tüm örnek boyutlarında başarımlar sağlandığı anlaşılmaktadır.

Tablo 4.7. Ön işlemlili MO-BSS yönteminin IGD metrik değerleri

Örnek Sayısı	IGD Metriği					
	En İyi Değer		En Kötü Değer		Ortalama Değer	
	MO-BSS	Ön İşlemlili MO-BSS	MO-BSS	Ön İşlemlili MO-BSS	MO-BSS	Ön İşlemlili MO-BSS
1000	0.00013	0.00011	0.01348	0.01813	0.00557	0.00548
2000	0.00016	0.00010	0.02910	0.02437	0.00612	0.00564
5000	0.00012	0.00011	0.07097	0.04534	0.00916	0.00837
10000	0.00057	0.00061	0.05611	0.04916	0.01648	0.01241
20000	0.00346	0.00127	0.08078	0.06852	0.01935	0.01608
30000	0.00448	0.00189	0.12644	0.05054	0.02354	0.01385

Tablo 4.8. Ön işlemlili MO-BSS yönteminin HV metrik değerleri

Örnek Sayısı	HV Metriği					
	En İyi Değer		En Kötü Değer		Ortalama Değer	
	MO-BSS	Ön İşlemlili MO-BSS	MO-BSS	Ön İşlemlili MO-BSS	MO-BSS	Ön İşlemlili MO-BSS
1000	0.80568	0.80845	0.02318	0.02387	0.22645	0.22942
2000	0.83521	0.84789	0.03684	0.03945	0.23634	0.24181
5000	0.76841	0.79645	0.04582	0.04834	0.34405	0.34975
10000	0.97748	0.93411	0.03845	0.04127	0.65848	0.66337
20000	0.96826	0.97086	0.05461	0.05864	0.52021	0.51845
30000	0.98645	0.98048	0.05867	0.05785	0.54244	0.55013

Tablo 4.8’de HV metriğine ait veriler gösterilmiş olup MO-BSS ile ön işlemlili MO-BSS algoritma arasında farkın çok az olduğu gösterilmiştir. En iyi değer incelendiğinde 10000 ve 30000 örnek boyutlarında ön işlemlili MO-BSS algoritma sonuçlarının MO-BSS algoritmasına göre düşük çıktığı görülmektedir. Diğer örnek sayılarında istenen sonuçlar elde edilmiştir. En kötü değer kısmında 30000 örnek boyutu hariç diğer örnek boyutlarında önerilen algoritmanın performansı MO-BSS algoritmasına göre yüksek değerler bulunmuş ve HV metriğinde istenen sonuçlar elde edilmiştir. Ortalama değerlere bakıldığında sadece 20000 örnek boyutunda düşük değer çıktığı, yani MO-BSS algoritmanın performansının daha iyi olduğu ve diğer örnek sayılarında çok az da olsa yüksek değerler ölçüldüğü tabloda gösterilmiştir.

SP metriğine ait algoritmaların performansını gösteren değerler Tablo 4.9’da gösterilmiştir. En iyi değerlerde 20000 örnek boyutunda az da olsa MO-BSS algoritması önerilen algoritmadan daha iyi sonuç vermiştir. Diğer örnek sayılarında ise önerilen algoritmanın performansının başarılı olduğu görülmektedir. En iyi değerler her iki algoritmada da yakın sonuçlar verirken en kötü değerlerde kayda değer değişkenlik gözlemlenmiştir. Ortalama verilere bakıldığında örnek sayısı arttıkça önerilen algoritmanın metrik değerinin daha iyi sonuç verdiği görülmektedir.

Tablo 4.9. Ön işlemlili MO-BSS yönteminin SP metrik değerleri

Örnek Sayısı	SP Metriği					
	En İyi Değer		En Kötü Değer		Ortalama Değer	
	MO-BSS	Ön İşlemlili MO-BSS	MO-BSS	Ön İşlemlili MO-BSS	MO-BSS	Ön İşlemlili MO-BSS
1000	0.68425	0.67576	1.60145	1.53786	1.25843	1.11678
2000	0.71121	0.69785	1.51641	1.59345	1.15457	1.14875
5000	0.66842	0.65374	1.59831	1.24560	1.18412	1.17067
10000	0.74645	0.73045	1.56112	1.42457	1.17398	1.15236
20000	0.88684	0.88757	1.69834	1.33485	1.21780	1.16104
30000	0.94365	0.93478	1.48079	1.19748	1.23452	1.11352


MO-BSS ve ön işlemlili MO-BSS algoritmalarının örnek boyutlarına göre çalışma süreleri Tablo 4.10’da verilmiştir. Her iki algoritmanın da çalışma süreleri benzer olup çok az fark vardır. İşlem yoğunluğu dikkate alınırsa önerilen algoritmanın MO-BSS’den az da olsa işlem süresinin düşük olması olumlu etki yaratmaktadır. İşlem süreleri saniye cinsinden ölçülmüştür. Özellikle 30000 örnek sayısındaki veri ayrıştırılırken önerilen algoritmanın işlem maliyeti MO-BSS algoritmasına göre 1.5 saniye daha kısa sürede sonuç vermektedir. Diğer örnek sayılarında ise kayda değer fark olmadığı tabloda gösterilmiştir.

Tablo 4.10. MO-BSS ve ön işlemlili MO-BSS yöntemlerinin çalışma süreleri

Örnek Sayısı	MO-BSS (sn)	Ön İşlemlili MO-BSS (sn)
1000	3.36	3.11
2000	5.67	5.58
5000	7.39	7.46
10000	11.42	11.02
20000	18.24	17.49
30000	23.69	22.37

Şekil 4.10’da işlem sürelerinin daha iyi anlaşılması amacıyla grafiksel gösterimi verilmiştir. İki algoritma arasında değişim az da olsa bar grafiğinde daha net anlaşılmaktadır.

Genel olarak her iki algoritmanın SNR değerlerine bakıldığında ön işlemeli MO-BSS algoritmasında başarılı sonuçlar elde edilmiştir. Performans metriklerindeki değerler de bunu desteklemektedir. Hesaplama maliyeti bakımından önerilen yöntemlerin işlem yükü arttığından istenen seviyede işlem süresi olmasa da yaklaşık olarak aynı süreyi korumuş veya çok az da olsa işlem süresinde azalmalar görülmüştür.




Şekil 4.10. MO-BSS ve ön işlemlili MO-BSS yöntemlerinin çalışma sürelerinin grafiksel gösterimi

Kullanılan algoritmanın hesaplama yükünü azaltmak için çalışmalara devam edilmiştir. Bu doğrultuda işaretin zaman ve frekanstaki davranışları incelenmiştir. İşaretin düşük ve yüksek frekanslı bileşenlerine ayırdığımızda düşük frekanslı bileşenler genellikle işaretin tanınma özelliği hakkında bilgi verdiğinden bu doğrultuda çalışmalar yapılmıştır. İşaret bileşenleri hakkında yeterince bilgiye ulaşılması durumunda işaret ayrıştırma olumlu etki yaratmıştır. Bunun için alçak geçiren filtreler ile işaretin bileşenlerine ayrıştırılması sağlanmıştır. Bu doğrultuda tasarlanan MO-BSS algoritması için Dalgacık Dönüşümünden (WT, Wavelet Transform) yararlanılmıştır.

4.4. Ayırık Dalgacık Dönüşümü Uygulanmış MO-BSS Algoritması

Önerilen bu ikinci çalışmada aynı kaynak işaretler kullanılarak rastgele karışımları elde edilmiştir. Sonrasında ayırık dalgacık dönüşümü ile uygun filtreleme yapıp ve devamında SPEA2 yöntemi ile de kör kaynak ayrıştırma işlemi yapılmıştır. Elde edilen işaretler tekrar ters ayırık dalgacık dönüşümü ile kaynak işaretlerin tahmini değerlerine ulaşılmıştır. Tezde önerilen bu ikinci yöntemle ön işlemlili MO-BSS’de olduğu gibi işaret ayrıştırma SNR cinsinden ve performans metrikleri dikkate alınarak uygulamalar yapılmış ve sonuçlar MO-BSS algoritmasıyla karşılaştırılmıştır.

Şekil 4.11’de iki kadın ve bir erkek ses işaretlerinin zaman-frekans eksenindeki orijinal, karışmış ve tahmini ayrıştırılmış şekilleri gösterilmektedir. Bu kısımdaki tüm uygulamalarda da işaretlerin 1000, 2000, 5000, 10000, 20000 ve 30000 örnek sayılarına göre testler yapılmıştır.



Şekil 4.11. Ses işaretlerinin zaman-frekans eksenindeki orijinal, karışmış ve tahmini ayrıştırılmış şekilleri

DWT ile yapılan uygulama sonuçlarının SNR değerleri Tablo 4.11’de gösterilmiştir. Tablodaki değerler algoritmaların 50 koşma sonucundaki ortalama değerleridir. Tabloda MO-BSS, ön işlemlili MO-BSS ve DWT MO-BSS yöntemlerinin SNR değerleri verilmiş ve DWT MO-BSS yönteminin diğer iki yöntemlerden de başarılı sonuçlar verdiği görülmektedir.

Birinci kadın ses işaretinde 1000 örnek sayısında 38.30 dB ile en düşük değer, 20000 örnek sayısında 52.47 dB ile de en yüksek SNR değerleri elde edilmiştir. DWT MO-BSS yöntemiyle MO-BSS yönteminin SNR değerleri karşılaştırıldığında yaklaşık olarak %100’lük bir artış olduğu görülmektedir. Ön işlemlili MO-BSS yöntemi ile

karşılaştırıldığında değişen örnek sayısına göre yaklaşık %30-55 arasında SNR değerlerinde artış olduğu hesaplanmıştır.


İkinci kadın ses ayrıştırılmasında en düşük SNR değeri 37.87 dB ile 1000 örnek boyutunda, en yüksek 50.78 dB ile de 30000 örnek boyutlarında elde edilmiştir. DWT MO-BSS yöntemiyle MO-BSS yönteminin SNR değerleri karşılaştırıldığında farklı örnek boyutlarında %100'ü aşan başarılı bir performans sağlanmıştır. Aynı şekilde DWT MO-BSS yöntemiyle ön işlemlili MO-BSS karşılaştırıldığında ise değişen örnek sayısına göre yaklaşık %20-40 arasında SNR değerlerinde artış olduğu hesaplanmıştır.

Tablo 4.11. Örnek sayılarına göre MO-BSS, ön işlemlili MO-BSS ve DWT MO-BSS yöntemlerinin SNR değerleri

Örnek Sayısı	1. Kadın Sesi İçin			2. Kadın Sesi İçin			Erkek Sesi İçin		
	MO-BSS	Ön İşlemlili MO-BSS	DWT MO-BSS	MO-BSS	Ön İşlemlili MO-BSS	DWT MO-BSS	MO-BSS	Ön İşlemlili MO-BSS	DWT MO-BSS
1000	20.56	29.08	38.30	21.09	31.37	37.87	24.64	32.47	42.21
2000	22.41	34.61	43.57	20.35	33.28	41.43	25.37	36.31	45.34
5000	23.18	32.13	49.62	22.94	32.17	45.57	22.61	35.92	49.63
10000	25.64	35.71	50.15	23.15	34.63	48.51	24.33	37.34	53.72
20000	22.73	33.52	52.47	21.11	36.97	50.08	23.15	37.63	55.46
30000	26.10	38.02	51.13	25.84	38.36	50.78	27.42	39.18	56.04

Erkek ses işaretinin ayrıştırılmasında ise 42.21 dB ile 56.04 dB arasında değişen SNR değerleri gösterilmiştir. Kadın seslerinde olduğu gibi DWT MO-BSS yöntemi ile MO-BSS yönteminin SNR değerleri karşılaştırıldığında farklı örnek boyutlarında %100'ü aşan değerler bulunmuştur. Aynı şekilde DWT MO-BSS yöntemi ile ön işlemlili MO-BSS karşılaştırıldığında ise değişen örnek sayısına göre yaklaşık %30-50 arasında SNR değerlerinde artış olduğu hesaplanmıştır. Tüm örnek sayıları içerisinde DWT MO-BSS yöntemi ile en yüksek SNR değeri 56.04 dB olarak 30000 örnek boyutundaki erkek sesi ayrıştırılmıştır. Özellikle erkek ses işaretinin daha iyi ayrıştırıldığı ve örnek sayısının artmasına göre SNR değerlerinin de arttığı görülmektedir. Bu sonuçlara göre algoritmanın

başarım oranında çok iyi derecede iyileştirmeler yapıldığı uygulama sonuçları ile gösterilmiştir.




Şekil 4.12. Birinci kadın sesi için Monte Carlo analizinin DWT MO-BSS'nin 50 koşmadaki SNR sonuçları


DWT MO-BSS yöntemi için 10000 örnek boyutundaki birinci kadın sesinin ayrıştırılmasında 50 kez çalıştırılan Monte Carlo analizinin her koşmadaki SNR değerlerinin grafiği ise Şekil 4.12'de gösterilmiştir. 50 koşma içerisinde tam sayı olarak alınan 42 dB ile 58 dB arasında değişen değerler ile diğer yöntemlere göre daha sabit değerler elde edildiği görülmektedir.

Şekil 4.13'te verilen ikinci kadın sesi için 10000 örnek boyutundaki SNR değerleri 40 dB ile 56 dB arasında değişmektedir. Bu aralıktaki değerlerin ortalaması ise 48 dB'dir. Ortalama değerlere bakıldığında her iki kadın sesinin ayrıştırılmasındaki değerler birbirine yakındır.

Erkek sesi için 50 kez çalıştırılan Monte Carlo analizinin SNR değerleri ise Şekil 4.14'te gösterilmiştir. En düşük 44 dB ve en yüksek 60 dB arasında değişen değerler ile işaret ayrıştırma için başarılı sonuçlar elde edilmiştir. Ortalama SNR değeri ise 10000 örnek boyutunda 53 dB olarak en yüksek değere ulaşılmıştır. Tüm kaynak işaretler içerisinde ortama SNR değeri 56 dB ile 30000 örnek boyutundaki erkek sesinin ayrıştırılması olmuştur.



Şekil 4.13. İkinci kadın sesi için Monte Carlo analizinin DWT MO-BSS'nin 50 koşmadaki SNR sonuçları



Şekil 4.14. Erkek sesi için Monte Carlo analizinin DWT MO-BSS'nin 50 koşmadaki SNR sonuçları

DWT MO-BSS yönteminin de performans metrikleri incelenmiştir. Aşağıda verilen tablolarda ön işlemlili MO-BSS ile DWT MO-BSS yöntemlerinin metrik değerlerinin karşılaştırılması yapılmıştır. Tablo 4.12'de verilen IGD metriği incelendiğinde en iyi olarak değerlendirilen kategoride örnek sayısının yüksek olduğu 20000 ve 30000'de metrik değerlerinin düşük olduğu görülmektedir. IGD metriği için değerinin düşük olması algoritmalarda istenen bir durumdur. 1000, 2000, 5000 ve 10000 örnek değerlerinde ön

işlemleri MO-BSS yönteminin MO-BSS'ye göre daha başarılı olduğu anlaşılmaktadır. En kötü değerler kategorisi incelendiğinde genel anlamda ön işlemleri MO-BSS yöntemine göre daha düşük değerlerin ölçülmesi ile beklenen durumun elde edildiği kanıtlanmıştır. Yöntemlerin ortalama değerleri incelendiğinde de DWT MO-BSS yönteminin ön işlemleri MO-BSS yöntemine göre daha iyi sonuçlar verdiği tablodan anlaşılmaktadır. Ön işlemleri MO-BSS yönteminde ortalama değerler daha fazla değişkenlik göstermiştir.

Tablo 4.12. Ön işlemleri ve DWT MO-BSS yöntemlerinin IGD metrik değerleri

Örnek Sayısı	IGD Metriği					
	En İyi Değer		En Kötü Değer		Ortalama Değer	
	Ön İşlemleri MO-BSS	DWT MO-BSS	Ön İşlemleri MO-BSS	DWT MO-BSS	Ön İşlemleri MO-BSS	DWT MO-BSS
1000	0.00011	0.00028	0.01813	0.01249	0.00548	0.00364
2000	0.00010	0.00050	0.02437	0.01768	0.00564	0.00438
5000	0.00011	0.00041	0.04534	0.03141	0.00837	0.00433
10000	0.00061	0.00075	0.04916	0.03298	0.01241	0.00364
20000	0.00127	0.00086	0.06852	0.03482	0.01608	0.00418
30000	0.00189	0.00116	0.05054	0.03640	0.01385	0.00462

Tablo 4.13. Ön işlemleri ve DWT MO-BSS yöntemlerinin HV metrik değerleri

Örnek Sayısı	HV Metriği					
	En İyi Değer		En Kötü Değer		Ortalama Değer	
	Ön İşlemleri MO-BSS	DWT MO-BSS	Ön İşlemleri MO-BSS	DWT MO-BSS	Ön İşlemleri MO-BSS	DWT MO-BSS
1000	0.80845	0.92548	0.02387	0.01732	0.22942	0.33847
2000	0.84789	0.93684	0.03945	0.01768	0.24181	0.35621
5000	0.79645	0.97325	0.04834	0.01245	0.34975	0.36314
10000	0.93411	0.86478	0.04127	0.01261	0.66337	0.45871
20000	0.97086	0.89641	0.05864	0.01295	0.51845	0.52389
30000	0.98048	0.92175	0.05785	0.01364	0.55013	0.59642

Tablo 4.13'te HV metriğine ait değerler verilmiştir. En iyi değerler kategorisindeki DWT MO-BSS yöntemi için örnek sayısının 1000, 2000 ve 5000 olduğu durumlarda işaretlerde ayrıştırma işlemi daha iyi yapılırken örnek sayılarının 5000'in üzerine çıktığı durumda da ise ön işlemlili MO-BSS daha iyi performans sergilemiştir. En kötü değerler kategorisinde önerilen yöntemlerin her biri için elde edilen değerler çok değişkenlik göstermemiştir. Ancak ön işlemlili MO-BSS yönteminin DWT MO-BSS yönteminden daha iyi sonuçlar verdiği de tablodan görülmektedir. Ortalama değerler de ise 10000 örnek boyutu hariç diğer örnek sayılarında ön işlemlili MO-BSS yönteminden daha yüksek sonuçlar elde edilmesi sağlanmıştır.

SP metrik değerlerinde ise Tablo 4.14'te gösterilen en iyi değerler kategorisinde ön işlemlili MO-BSS yöntemiyle ölçülen değerlerden düşük olmasıyla istenen veriler elde edilmiştir. En kötü değerler kategorisinde ise 5000 örnek sayısı hariç diğerlerinde daha iyi sonuçlar elde edilmiştir. Ortalama değerlere bakıldığında DWT MO-BSS yöntemi ile elde edilen sonuçların daha düşük olması sebebiyle ön işlemlili MO-BSS yöntemine göre daha başarılı olduğu yani işaretleri daha iyi ayrıştırdığı anlaşılmaktadır.

Tablo 4.14. Ön işlemlili ve DWT MO-BSS yöntemlerinin SP metrik değerleri


Örnek Sayısı	SP Metriği					
	En İyi Değer		En Kötü Değer		Ortalama Değer	
	Ön İşlemlili MO-BSS	DWT MO-BSS	Ön İşlemlili MO-BSS	DWT MO-BSS	Ön İşlemlili MO-BSS	DWT MO-BSS
1000	0.67576	0.60154	1.53786	1.51684	1.11678	1.00584
2000	0.69785	0.61364	1.59345	1.52486	1.14875	1.00837
5000	0.65374	0.70485	1.24560	1.49854	1.17067	1.01681
10000	0.73045	0.71254	1.42457	1.12682	1.15236	1.09632
20000	0.88757	0.79545	1.33485	1.30125	1.16104	1.08365
30000	0.93478	0.76451	1.19748	1.16436	1.11352	1.09965

MO-BSS, ön işlemlili MO-BSS ve DWT MO-BSS yöntemlerinin çalışma yani koşma süreleri Tablo 4.15'te gösterilmiştir. İşlem yükü artmasına rağmen işlem sürelerinde küçük değerlerde olsa azalma olduğu tabloda gösterilmiştir.

Tablo 4.15. MO-BSS, ön işlemlili MO-BSS ve DWT MO-BSS yöntemlerinin koşma süreleri

Örnek Sayısı	MO-BSS (sn)	Ön İşlemlili MO-BSS (sn)	DWT MO-BSS (sn)
1000	3.36	3.11	3.15
2000	5.67	5.58	5.55
5000	7.39	7.46	7.12
10000	11.42	11.02	10.78
20000	18.24	17.49	17.37
30000	23.69	22.37	21.18

Özellikle 30000 örnek sayısındaki veriler ayrıştırılırken önerilen DWT MO-BSS yönteminin işlem maliyeti MO-BSS yöntemine göre yaklaşık 2.5 saniyeye yakın daha kısa sürede, ön işlemlili MO-BSS yöntemine göre ise 1.2 saniyeye yakın daha kısa sürede işlem sonuçları elde edilmiştir. Diğer örnek sayılarında ise yaklaşık bir saniyenin altında değişen farklı sürelerde algoritmalar çalışmalarını tamamlamıştır. Algoritmaların koşma süreleri Şekil 4.15'te ki grafikte daha iyi görüleceği üzere örnek sayısı arttıkça işlem sürelerinde de azalma olduğu net bir şekilde gösterilmiştir.




Şekil 4.15. MO-BSS ve önerilen her iki yöntemin koşma süreleri

Bu bölümde, karışmış işaretlerin birbirinden ayrıştırılmasında birden fazla optimizasyon kriterinin mevcut olması ve sorunlarla ilgili nesnel bilgiye dayalı olarak gerçekleştirilen bu çalışmada ele alınan metodoloji incelenmiştir. Tezde kullanılan BSS yöntemi, SPEA2 yöntemi ve bu yöntemlerle ilgili performans artışı sağlamak için yapılan çalışmalar ve deneysel sonuçlar açıklanmıştır. Önerilen yöntemler farklı ses gruplarına uygulanmış ve algoritmaların sergiledikleri performanslar incelenmiştir.

4.5. Önerilen Yöntemlerin Farklı Seslere Uygulanması

MO-BSS ve önerilen yöntemler ile birbirine karıştırılmış iki erkek ve bir beyaz Gauss gürültü işaretinin ayrıştırılması sağlanarak algoritmaların performansları test edilmiştir. Şekil 4.16'da orijinal işaretler, karışım işaretleri ve önerilen yöntemler yardımıyla tahmin edilen işaretlerin 4000 örnek sayısındaki şekilleri gösterilmiştir.



Şekil 4.16. İki erkek sesi ve gürültü işaretine ait kaynak işaretler

MO-BSS, ön işlemlili MO-BSS ve DWT MO-BSS algoritmalarının performansları belirtilen işaretlerde test edilmiş ve SNR değerleri Tablo 4.16'da gösterilmiştir.

Birinci erkek ses işaretinin MO-BSS yöntemi ile ayrıştırılmasında en düşük SNR değeri 16.84 dB ile 1000 örnek boyutunda hesaplanmış, en yüksek SNR değeri 24.31 dB ile 30000 örnek boyutunda elde edilmiştir. MO-BSS yöntemi üzerinde yapılan ön işlemlili uygulamada 1000 örnek boyutunda 19.37 dB ile düşük, 30000 örnek boyutunda 32.39 dB ile en yüksek SNR değeri bulunmuştur. En yüksek %40'a yakın bir artış ile 5000 örnek boyutunda SNR değeri hesaplanmıştır. Aynı ölçümler DWT MO-BSS yöntemi ile de yapılmış ve en düşük 30.34 dB ile en yüksek 41.18 dB arasında değişen SNR değerleri hesaplanmıştır. DWT MO-BSS ile MO-BSS arasında %100'i geçen en fazla ayrıştırma değeri 1000 örnek boyutunda sağlanmıştır. Ayrıca ayırık dalgacık dönüşümü uygulanan yöntemin ön işlemlili MO-BSS yönteminden ise %70 oranında daha başarılı sonuç elde edildiği görülmektedir.

Tablo 4.16. Örnek sayılarına göre erkek sesleri ve gürültü işaretinin SNR değerleri


Örnek Sayısı	1. Erkek Sesi İçin			2. Erkek Sesi İçin			Gürültü Sesi İçin		
	MO-BSS	Ön İşlemlili MO-BSS	DWT MO-BSS	MO-BSS	Ön İşlemlili MO-BSS	DWT MO-BSS	MO-BSS	Ön İşlemlili MO-BSS	DWT MO-BSS
1000	16.84	19.37	33.02	15.67	20.04	29.37	13.05	20.37	28.37
2000	20.04	23.44	30.34	19.27	21.18	37.91	13.16	19.16	28.16
5000	18.19	25.23	36.67	22.31	27.45	36.53	15.37	21.46	31.65
10000	21.67	22.68	38.29	21.05	25.97	38.12	18.75	22.67	32.02
20000	23.38	28.82	39.34	20.34	32.64	39.24	20.61	25.37	32.37
30000	24.31	32.39	41.18	22.08	35.82	40.76	23.37	29.61	34.62

İkinci erkek sesinin MO-BSS yöntemi ile ayrıştırılmasında 15.67 dB ile 22.08 dB arasında değişen SNR değerleri elde edilmiştir. Ön işlemlili MO-BSS yöntemi ile 1000 örnek boyutunda 20.04 dB ile en düşük, 30000 örnek boyutunda 35.82 dB ile en yüksek ayrıştırma oranı sağlanmıştır. Böylece MO-BSS yöntemine göre %60 oranında en yüksek ayrıştırma 20000 örnek boyutunda elde edilmiştir. DWT MO-BSS yönteminde ise 29.37 dB ile 40.76 dB arasında değişen SNR değerleri ile ayrıştırma en iyi şekilde sağlanmıştır.

Gürültü işaretinin MO-BSS algoritması ile ayrıştırılmasında ise 1000 örnek boyutunda 13.05 dB ile en düşük, 23.37 dB ile 30000 örnek boyutunda en yüksek SNR değeri hesaplanmıştır. Ön işlemlili MO-BSS yönteminde ise 2000 örnek boyutunda 19.16 dB ile en düşük, 30000 örnek boyutunda 29.61 dB ile en yüksek SNR değeri elde edilmiştir. Böylece en yüksek oran olarak yaklaşık %55 oranında MO-BSS yöntemine göre başarımlı sağlanmıştır. DWT MO-BSS yönteminde ise en yüksek 34.62 dB ile 30000 örnek boyutunda SNR değeri elde edilmiştir.

Genel olarak incelendiğinde erkek seslerinin gürültüden daha iyi ayrıştırıldığı ve önerilen yöntemlerin kararlı bir şekilde ayrıştırma işlemi yaptığı görülmektedir. Örnek sayılarına göre en iyi ayrıştırma 30000 örnek boyutunda birinci erkek sesinin DWT MO-BSS yöntemi ile ayrıştırılmasında sağlanmıştır.

Şekil 4.17’de gösterilen grafikte 10000 örnek boyutu için birinci erkek sesinin ayrıştırılmasında algoritmaların 50 koşma için Monte Carlo analizinin sonuçları verilmiştir.




Şekil 4.17. Birinci erkek ses işareti için Monte Carlo analizinin MO-BSS, ön işlemlili MO-BSS ve DWT MO-BSS’nin SNR sonuçları

Ön işlemlili MO-BSS, önerilen birinci yöntem olarak ve DWT MO-BSS ise önerilen ikinci yöntem olarak ifade edilmiştir. MO-BSS yöntemi için en düşük SNR değeri 17 dB ve en yüksek SNR değeri ise 28 dB aralığında değişmektedir. MO-BSS ile önerilen birinci yöntem grafikte benzer gibi görünse de önerilen birinci yöntem 16 dB ile 30 dB arasında


değişen SNR değerlerine sahiptir. Birinci erkek sesi için önerilen ikinci yöntemin başarısı açık bir şekilde grafikte gösterilmiştir. En düşük 27 dB ve en yüksek 48 dB olan SNR değerleri ile en iyi ayırıştırma sağlanmıştır.

Şekil 4.18’de ise bar grafiği olarak algoritmaların 10 koşma sonucundaki SNR değerlerindeki farklılığının net anlaşılması için verilmiştir. Önerilen ikinci yöntemin açık ara işaret ayırıştırmadaki performansı görülmektedir.




Şekil 4.18. Birinci erkek ses işareti için MO-BSS ve önerilen iki yöntemin 10 koşmadaki SNR değerleri

Şekil 4.19’da verilen grafikte ikinci erkek sesinin ayırıştırılmasında algoritmaların 50 koşma sonucundaki SNR değerleri verilmiştir. MO-BSS yöntemi için 16 dB ile 29 dB arasında değişen SNR değerlerinin ayırıştırılması sağlanmıştır. Önerilen birinci yöntem de en düşük SNR değeri 17 dB ve en yüksek 33 dB arasında değişen değerler ile MO-BSS yönteminden daha iyi bir ortalama SNR değerine sahiptir. İkinci önerilen yöntem de ise 31 dB ve 45 dB arasında değişen SNR değerleri ile en iyi şekilde ayırıştırma işlemi sağlanmıştır.




Şekil 4.19. İkinci erkek ses işareti için Monte Carlo analizinin MO-BSS, ön işlemli MO-BSS ve DWT MO-BSS'nin SNR sonuçları

Şekil 4.20'de bar grafiği olarak gösterilen verilerde algoritmaların 10 koşma sonucundaki SNR değerleri gösterilmiştir. Algoritmaların farklı koşmalarında MO-BSS ve ön işlemli MO-BSS yöntemlerinin SNR değerleri değişiklik gösterse de önerilen ikinci yöntem her koşmada en iyi SNR değerine sahiptir.




Şekil 4.20. İkinci erkek ses işareti için MO-BSS ve önerilen iki yöntemin 10 koşmadaki SNR değerleri

Gürültü işaretinin ayrıştırılması için algoritmaların 50 koşma sonucundaki SNR değerleri ise Şekil 4.21’de gösterilmiştir. 10000 örnek boyutundan alınan veriler için MO-BSS yöntemi 13 dB ile 24 dB arasında değişen SNR değerleri ile ayrıştırılmıştır. Önerilen birinci yöntemde 14 dB ile 28 dB arasında değişen değerler alırken, önerilen ikinci yöntemde 25 dB ile 40 dB arasında değişen SNR değerleri ile başarılı bir şekilde işaretler ayrıştırılmıştır.



Şekil 4.21. Gürültü işareti için Monte Carlo analizinin MO-BSS, ön işlemli MO-BSS ve DWT MO-BSS’nin SNR sonuçları



Şekil 4.22. Gürültü işareti için MO-BSS ve önerilen iki yöntemin 10 koşmadaki SNR değerleri


Şekil 4.22’de algoritmaların 10 koşmadaki SNR değerleri verilmiş olup karıştırma matrislerindeki değişikliklere göre MO-BSS ve önerilen birinci yöntem arasında değişimler daha net gösterilmiştir. Gürültü işareti için önerilen ikinci yöntemin her koşulunda SNR değeri en yüksek seviyeyi yakalamıştır.

Genel olarak değişen SNR aralıklarında işaretler ayrıştırılsa da ortalama değerlere bakıldığında önerilen birinci ve ikinci yöntemler MO-BSS yöntemine göre daha yüksek değerlerde işaretler ayrıştırılmıştır.

Her ne kadar ses işaretleri üzerinde yapılan Matlab uygulamalarında başarılı sonuçlar elde edilmiş ve kanıtlanmış olsa da farklı işaretler üzerinde de deneysel işlemler yaparak önerilen yöntemlerin performansını görmemiz gerekir. Bu doğrultuda önerilen yöntemlerde de biyomedikal işaretler (Fetal EKG, Anne EKG, EEG ve beyaz Gauss gürültü) için gerekli uygulamalar yapılmıştır.

4.6. Çok Amaçlı Optimizasyon Algoritmaları ile EKG İşaretlerin Ayrıştırılması

Tasarlanan yöntemler aynı zamanda karışmış EKG işaretlerinin ayrıştırılmasında da uygulanmıştır. Uygulamada üç farklı işaret olarak fetal EKG işareti, beyaz Gauss gürültü işareti ve anne EKG işaretleri kullanılmıştır.




Şekil 4.23. Fetal EKG, gürültü ve Anne EKG’ye ait kaynak işaretler

İşaretlerin karıştırılması doğrusal olarak ve karışım rastgele matris kullanılarak yapılmıştır. Ses işaretlerinde olduğu gibi biyomedikal işaretlerin ayrıştırılmasında da

algoritmaların 50 koşma sonucundaki her bir değeri ve bunların ortalamaları alınmıştır. MO-BSS, ön işlemlili MO-BSS ve DWT MO-BSS yöntemlerinin işlem sonuçları SNR cinsinden verilmiştir. Uygulamada kullanılan işaretler [142] numaralı kaynaktaki veri tabanından alınmıştır. Beyaz Gauss gürültü ise yapay olarak oluşturulmuştur. Şekil 4.23'te kullanılan biyomedikal işaretlerin 2000 örnek sayısı olarak gösterimi verilmiştir. Bu veriler kaynak veri, kaynak işaret veya orijinal işaret olarak adlandırılmaktadır.

Tüm uygulamalarda veriler değerlendirilirken 1000, 2000, 5000, 10000, 20000 ve 30000 örnek sayısı dikkate alınarak farklı uzunluktaki veri miktarlarına göre SNR oranları değerlendirilmiştir. Uygulamada kullanılan biyomedikal işaretler rastgele karıştırılarak önce MO-BSS, Ön işlemlili MO-BSS ve sonrasında DWT MO-BSS yöntemlerine uygulanmış ve performans sonuçları kaydedilmiştir.



Şekil 4.24. EKG ayırtırmada kullanılan orijinal kaynak işaretler, karıştırılmış işaretler ve tahmin edilen kaynak işaretler

Uygulama sonucunda Şekil 4.24'te görüldüğü gibi orijinal işaretler, rastgele karışım işaretleri ve MO-BSS yöntemlerinin işlem sonucu tahmin edilen kaynak işaretlerin şekli gösterilmektedir. Şekilde karışım işaretleri üç işaretin karışımı olduğundan genlik

durumlarına göre karışım oranları değişiklik göstermektedir. İşaretlerin 2000 örnek boyutları dikkate alınarak grafikler oluşturulmuştur.

Tablo 4.17’de yöntemlerin her koşmada farklı karıştırma matrisleri kullanarak kaydedilen SNR değerlerinin ortalaması gösterilmiştir. Üç yöntemin örnek sayılarına göre SNR değerleri tek tabloda verilmiştir.

Tablo 4.17. Örnek sayılarına göre Fetal EKG ve gürültü ve Anne EKG işaretlerinin SNR değerleri

Örnek Sayısı	Fetal EKG İşareti İçin			Gürültü İşareti İçin			Anne EKG İşareti İçin		
	MO-BSS	Ön İşlemlili MO-BSS	DWT MO-BSS	MO-BSS	Ön İşlemlili MO-BSS	DWT MO-BSS	MO-BSS	Ön İşlemlili MO-BSS	DWT MO-BSS
1000	22.26	23.41	38.95	20.56	21.67	38.35	21.33	21.91	37.06
2000	24.43	25.30	38.46	23.47	25.48	39.91	21.43	20.32	36.57
5000	23.08	28.61	42.38	21.39	26.38	41.54	24.47	28.71	43.76
10000	24.49	33.78	44.21	22.52	27.23	40.67	25.09	32.76	42.85
20000	27.67	34.67	45.73	24.03	31.06	41.17	26.67	32.81	43.41
30000	30.88	38.34	47.02	25.32	34.19	42.39	29.62	37.64	46.85

Fetal EKG işaretinin MO-BSS yöntemi ile ayrıştırılmasında en düşük SNR değeri 22.26 dB ile 1000 örnek boyutunda, en yüksek SNR değeri 30.88 dB ile 30000 örnek boyutunda hesaplanmıştır. MO-BSS yöntemi üzerinde yapılan ön işlemlili uygulama ile aynı işaret tekrar ayrıştırılmıştır. Bu kez 1000 örnek boyutunda 23.41 dB ile en düşük, 30000 örnek boyutunda 38.34 dB ile en yüksek SNR değeri elde edilmiştir. Düşük örnek boyutlarında MO-BSS ile ön işlemlili MO-BSS arasında SNR değerleri birbirine yakinken örnek sayısı arttıkça SNR değerinde de artış sağlanmıştır. En yüksek %40’a yakın bir artış ile 10000 örnek boyutunda SNR değeri hesaplanmıştır. Aynı işlemler DWT MO-BSS yöntemi ile de yapılmış ve en düşük 38.95 dB ile en yüksek 47.02 dB arasında değişen SNR değerleri hesaplanmıştır. DWT MO-BSS ile MO-BSS arasında %80’i geçen ayrıştırma performansı sağlanmıştır. Ayrık dalgacık dönüşümü uygulanan yöntemin ön işlemlili MO-BSS yönteminden ise %50 oranında daha başarılı sonuç elde edildiği görülmektedir.


Genel olarak her üç yöntemde de örnek sayısı arttıkça SNR değerlerinin de arttığı görülmektedir.

Beyaz Gauss gürültü işaretinin ayrıştırılmasında ilk önce MO-BSS yöntemi uygulanmış ve en düşük 20.56 dB ile 1000 örnek boyutunda, en yüksek 25.32 dB ile 30000 örnek boyutunda SNR değerleri tabloda gösterilmiştir. Ön işlemlili MO-BSS yöntemi ile yapılan ayrıştırmada ise en düşük 21.67 dB ile 1000 örnek boyutunda, en yüksek 34.19 dB ile 30000 örnek boyutunda SNR değerleri hesaplanmıştır. Bunun sonucunda ön işlemlili yöntemin MO-BSS yöntemine göre en fazla %40 SNR değerleri ile daha başarılı olduğu hesaplanmıştır. Ayrık dalgacık dönüşümü uygulanan MO-BSS yönteminde de en düşük 38.35 dB ile 1000 örnek boyutunda, en yüksek 42.39 dB ile 30000 örnek boyutunda SNR değerleri tabloda gösterilmiştir. Ayrıca Tablo 4.17’de sadece gürültü işaretinin DWT MO-BSS ile ayrıştırılmasındaki tüm örnek sayılarına bakılırsa hesaplanan SNR değerlerinin birbirine yakın olduğu yani 1000 örnek boyutu ile 30000 örnek boyutu arasındaki ayrıştırmada yaklaşık 4 dB değerinde fark olduğu görülmektedir. Bu yöntemin MO-BSS yöntemine göre en fazla %90 oranında, ön işlemlili MO-BSS yöntemine göre de en fazla %80 oran ile 1000 örnek boyutunda başarımlı sağladığı kanıtlanmıştır.


Anne EKG işaretinin MO-BSS yöntemi ile ayrıştırılmasında farklı örnek boyutlarına 21.33 dB ile 29.62 dB arasında değişen SNR değerleri hesaplanmıştır. Ön işlemlili MO-BSS yönteminde ise 20.32 dB ile 37.64 dB arasında değişen değerler bulunmuştur. Düşük örnek boyutlarında MO-BSS ile yaklaşık aynı değerler elde edilmişken örnek sayısı arttıkça SNR değerlerinde de artış paralellik göstermiştir. MO-BSS yönteminden yaklaşık olarak en fazla %30 oranında performans artışı sağlanmıştır. 2000 örnek boyutunda ise MO-BSS yönteminde daha düşük bir ayrıştırma elde edilmiştir. Ayrık dalgacık dönüşümü uygulanan MO-BSS yönteminde en düşük SNR değeri 36.57 dB ile 2000 örnek boyutunda hesaplanırken, en yüksek SNR değeri 46.85 dB ile 30000 örnek boyutunda hesaplanmıştır. DWT MO-BSS ile MO-BSS arasında yaklaşık %80’i oranında ayrıştırma performansı sağlanmıştır. Ayrık dalgacık dönüşümü uygulanan yöntemin ön işlemlili MO-BSS yönteminden ise en fazla %75 oranında daha başarılı sonuç verdiği görülmektedir.

Şekil 4.25’te Fetal EKG işaretinin 10000 örnek boyutundan alınan 50 koşma için Monte Carlo analizinin SNR sonuçları verilmiştir. Grafikte ön işlemlili MO-BSS, önerilen birinci yöntem olarak ve DWT MO-BSS ise önerilen ikinci yöntem olarak ifade edilmiştir. MO-

BSS yöntemi için en düşük SNR değeri 16 dB ile 32 dB arasında değişen değerler ile Fetal EKG işareti ayrıştırılmıştır. Önerilen birinci yöntem de 25 dB ile 42 dB arasında değişen değerler alırken, önerilen ikinci yöntemde 35 dB ile 51 dB arasında değişen SNR değerleri ile Fetal EKG işareti başarılı bir şekilde ayrıştırıldığı görülmektedir.




Şekil 4.25. Fetal EKG işareti için Monte Carlo analizinin MO-BSS, ön işlemleri MO-BSS ve DWT MO-BSS'nin SNR sonuçları



Şekil 4.26. Fetal EKG işareti için MO-BSS ve önerilen iki yöntemin 10 koştaki SNR değerleri


Şekil 4.26’da algoritmaların 10 koşmadaki SNR değerleri verilmiş olup karıştırma matrislerindeki değişikliklere göre her koşmada farklı SNR değerleri elde edilmiştir. Önerilen birinci ve ikinci yöntemin, MO-BSS yöntemine kıyasla yüksek sonuçlar verdiği daha net anlaşılmaktadır. Önerilen ikinci yöntem ise tüm örnek boyutlarında açıkça Fetal EKG işaretini çok daha iyi ayırttığı görülmektedir.

Şekil 4.27’de gürültü işaretinin 50 koşma için ayrıştırılma değerleri verilmiştir. 10000 örnek boyutunda ölçülen MO-BSS yönteminin SNR değerleri için en düşük 17 dB iken en yüksek 30 dB olarak hesaplanmıştır. Önerilen birinci yöntem de SNR değerleri 20 dB ile 37 dB arasında değişirken önerilen ikinci yöntemde 30 dB ile 48 dB arasında değişen değerler ile gürültü işaretinin ayrıştırılması sağlanmıştır.




Şekil 4.27. Gürültü işareti için Monte Carlo analizinin MO-BSS, ön işlemlili MO-BSS ve DWT MO-BSS’nin SNR sonuçları

Şekil 4.28’de algoritmaların 10 koşmadaki SNR değerleri verilmiş olup karıştırma matrislerindeki değişikliklere göre önerilen ikinci yöntemin genel anlamda yüksek sonuçlar verdiği, MO-BSS ile önerilen birinci yöntemin ise koşma sayılarına göre değişkenlik gösterdiği anlaşılmaktadır. Grafiğe göre önerilen birinci yöntemin kullanılabilirliği yine de MO-BSS yönteminden iyi SNR sonuçları verdiği grafikten görülmektedir.




Şekil 4.28. Gürültü işareti için MO-BSS ve önerilen iki yöntemin 10 koşmadaki SNR değerleri

Şekil 4.29’da anne EKG işaretinin her yöntem için 50 koşma sonucundaki SNR değerlerinin grafiği gösterilmiştir. MO-BSS yöntemi ile SNR değerleri 19 dB ve 32 dB arasında değişen değerler hesaplanmıştır. Önerilen birinci yöntem de ise 25 dB ile 39 dB arasında değişen değerler ile anne EKG işaretinin daha yüksek değerlerde ayrıştırıldığı gözlemlenmiştir. Önerilen ikinci yöntem de 32 dB ile 49 dB arasında değişen değerler ile anne EKG işaretinin ayrıştırılması başarılı bir şekilde tamamlanmıştır.



Şekil 4.29. Anne EKG işareti için Monte Carlo analizinin MO-BSS, ön işlemlili MO-BSS ve DWT MO-BSS’nin SNR sonuçları

Şekil 4. 30’da verilen bar grafiğinde algoritmaların 10 koştaki SNR değerleri incelendiğinde özellikle önerilen birinci yöntemin diğer yöntemlere nazaran daha değişken değerler aldığı görülmektedir. Kullanılan her üç işarete de önerilen ikinci yöntemin işaret ayırtırmadaki başarısı açıkça grafiklerden görülmektedir.



Şekil 4.30. Anne EKG işareti için MO-BSS ve önerilen iki yöntemin 10 koştaki SNR değerleri

Yapılan bu çalışmalar farklı ses işaretleri ya da biyomedikal işaretler olsun önerilen her iki yöntemin de birbirlerine karışmış olarak elde edilen işaretleri başarılı bir şekilde ayırttığı anlaşılmaktadır. 10000 örnek boyutunda ses işaretleri ile biyomedikal işaretlerin SNR değerleri karşılaştırıldığında önerilen birinci yöntemin biyomedikal işaretlerde MO-BSS yönteminden daha iyi sonuçlar verdiği grafiklerde görülmektedir.

Ayrıca [83] nolu kaynakta yapılan çalışmada da anne EKG, Fetal EKG ve beyaz Gauss gürültü işaretinin ayırtılması yapılmıştır. Yapılan çalışmada tek amaçlı optimizasyon yöntemi ile en fazla 5000 örnek boyutu olarak işaretler ele alınmıştır. Tablo 4.18’de [83] nolu kaynaktaki SNR değerleri ile bu tez çalışmasında önerilen yöntemlerin SNR değerleri verilmiştir.

Tablo 4.18. Önerilen yöntemlerin SNR cinsinden performans karşılaştırılması

Örnek Sayısı	Fetal EKG İşareti İçin			Gürültü İşareti İçin			Anne EKG İşareti İçin		
	[83] Nolu kaynak	Ön İşlemli MO-BSS	DWT MO-BSS	[83] Nolu kaynak	Ön İşlemli MO-BSS	DWT MO-BSS	[83] Nolu kaynak	Ön İşlemli MO-BSS	DWT MO-BSS
1000	35.18	23.24	38.39	9.08	21.42	38.15	12.56	21.77	37.61
2000	34.64	25.68	38.57	11.19	25.71	39.69	14.44	20.23	36.38
5000	37.94	28.17	42.08	14.34	26.33	41.24	19.03	28.62	43.47


Tablodaki değerlere göre, kıyaslanan çalışmada Fetal EKG işareti ön işlemli MO-BSS yöntemine göre yüksek SNR değerleri ile dikkat çekerken DWT MO-BSS yöntemine göre düşük SNR değerleri hesaplanmıştır. Gürültü ve Anne EKG işaretlerinde önerilen her iki yöntemde [83] nolu kaynaktaki yöntemden daha iyi sonuçlar verdiği görülmektedir.

4.7. EEG ve Beyaz Gauss Gürültü İşaretlerinin Ayırıştırılması

Önerilen yöntemler, iki işaretin karışımı olan EEG ve beyaz Gauss gürültü işaretleri üzerinde de test edilmiştir. EEG işaretleri beyin aktivitesi olarak epilepsi, beyin tümörleri, beyin hasarı, uyku bozuklukları ve felç gibi hastalıkların teşhisinde sıklıkla ölçülmektedir. Tüm biyomedikal işaretlerde olduğu gibi EEG işaretinin de gürültüsüz bir şekilde ölçülmesi gerekir. Bu kapsamda ele alınan işaret sayısı iki farklı şekilde belirlenmiş ve bu işaretlerin ayırıştırılmasında kullanılan yöntemlerin performansları ölçülmüştür.

Şekil 4.31’de EEG ve beyaz Gauss gürültü işaretine ait 2000 örnek boyutunda kaynak işaretler gösterilmiştir. Bu iki işaret rastgele karıştırılarak üç yönteme uygulanmış ve performans sonuçları kaydedilmiştir.

Tablo 4.19’da işaretlerin farklı örnek boyutlarında ayırıştırma sonuçlarının SNR değerleri verilmiştir. Genel olarak bakıldığında DWT MO-BSS yöntemin SNR değerleri diğer iki yöntemin SNR değerlerinden yüksek olduğu görülmektedir.



Şekil 4.31. EEG ve gürültüye ait kaynak işaretler

EEG işareti için MO-BSS yöntemi 26.48 dB ile 41.52 dB arasında değişen SNR değerleri hesaplanmıştır. Ön işlemli MO-BSS yöntemindeki değerler incelendiğinde en yüksek 43.04 dB ile 30000 örnek boyutunda ayrıştırma sağlanmıştır. En fazla artış ise 5000 örnek boyutunda sağlanmış ve MO-BSS yöntemine göre %10'luk bir artış olmuştur. Önerilen ikinci yöntem olan DWT MO-BSS yönteminde ise 33.55 dB ile 47.64 dB arasında değişen SNR değerleri hesaplanmıştır. Oransal olarak incelendiğinde önerilen ikinci yöntemin SNR değerlerindeki artışın daha fazla olduğu görülmektedir. Her iki işaretin ayrıştırılmasında MO-BSS yöntemi ile önerilen birinci yöntem birbirlerine yakın SNR sonuçları verse de önerilen birinci yöntemin daha iyi ayrıştırma yaptığı tabloda gösterilmiştir.

Gürültü işaretinin ayrıştırılmasında MO-BSS yöntemi ile ön işlemli MO-BSS yöntemi arasında SNR değerleri olarak çok fark olmasa da ön işlemli MO-BSS yönteminin işaretleri daha iyi ayrıştırdığı tablo 4.19'da görülmektedir. Önerilen ikinci yöntemde ise en düşük 32.24 dB ile en yüksek 45.64 dB arasında değişen değerler olarak başarılı bir şekilde gürültü işareti ayrıştırılmıştır.

Tablo 4.19. Örnek sayılarına göre EEG ve gürültü işaretlerinin SNR değerleri

Örnek Sayısı	EEG İşareti İçin			Gürültü İşareti İçin		
	MO-BSS	Ön İşlemlili MO-BSS	DWT MO- BSS	MO-BSS	Ön İşlemlili MO-BSS	DWT MO- BSS
1000	26.48	28.73	33.55	26.47	27.08	32.24
2000	28.94	29.67	34.47	26.89	27.37	33.67
5000	30.73	33.33	37.83	28.48	29.67	36.61
10000	29.42	30.70	36.91	29.39	31.48	38.22
20000	37.11	38.16	44.87	37.73	38.93	42.08
30000	41.52	43.04	47.64	40.17	41.74	45.64

İşaret sayılarına göre incelendiğinde birbirine karışmış iki işaretin ayrıştırılmasının üç işaretin ayrıştırılmasına oranla SNR değerlerinin daha yüksek sonuçlar verdiği yapılan deneysel sonuçlardan anlaşılmıştır. Bu kapsamda özellikle birbirine karışmış biyomedikal işaretlerde önerilen yöntemler kullanılarak güvenli bir şekilde hastalık teşhisi ve tedavisi için işaret ayrıştırma işlemi yapılabilir.

5. BÖLÜM

SONUÇ VE ÖNERİLER

BSS, birbirine karışmış işaretlerin frekans özellikleri, sensör tarafından elde edilme konumları veya kaynakların birbirine karıştırılma şekilleri hakkında herhangi bir ön bilgi olmadan işaretlerin birbirlerinden ayrıştırılması problemidir. Bu problemle ilgili olarak, gözlenen karışımlar arasından karışımları oluşturan işaretleri tahmin etmek amaçlanmaktadır. Kör kaynak ayırma problemleri olarak formüle edilen çeşitli durumlar vardır. Hangi işaretlerin karıştırıldığını ve karıştırma işleminin parametrelerini bilmeden, bu tür verilerin karışımından bir dizi girdi verisinin tahmin edilmesini içeren bu tür problemler, optimizasyon modelleri kullanılarak çözülür. Kural olarak bu modeller, kaynak işaretlerine ilişkin bir kriterin belirlenmesi yani tek amaç fonksiyonu belirlenerek en uygun çözüm aranmaktadır. Pratikte kaynak işaretleri hakkında birden fazla bilgi bulunabileceğinden, bu çalışma, sorunun çok amaçlı optimizasyon yoluyla çözülmesi için bu bilgi kümesinin dikkate alınarak çözülmesini hedeflemiştir. Bu doğrultuda ele alınan MO-BSS yöntemi ile uygulanan deneyler, dikkate alınan modelin uygulanabilirliğini doğrulamaktadır.

Kaynakların kör kaynak ayrıştırılmasına ilişkin olarak, doğrusal karışımlarda hem gürültülü senaryolarda hem de gürültüsüz senaryolarda ideale en yakın çözüm, baskın olmayan küme içinde bulunur ve her iki senaryoda da ayrıştırma başarılı bir şekilde yapılır. Ayrıca ayrıştırma işleminde örnek sayısının az olması nedeniyle ayırma işlemindeki zorluğun yüksek olduğu gerçek verilere uygulandığında bile ayrıştırma işlemi başarılı bir şekilde yapılmıştır.

Elbette problemler kör olduğundan yani kaynaklar ve karışım matrisi bilgisi olmadan, baskın olmayan küme içinde hangisinin en iyi çözüm olduğunu belirlemek imkansızdır. Ancak problemin yer aldığı bağlamda yer alan karar verici, konuya ilişkin bilgisine göre en doğru görünen çözümü seçebilecek bir dizi çözüme sahip olacaktır. Bu şekilde,

problemin çözümü, kriterlerin ağırlıklandırılmasının önceden seçilmesiyle değil, eşit derecede optimal çözümlerin bir kümesiyle elde edilir.

Bu tez çalışmasında birbirlerine karışmış farklı konuşma sesleri ve biyomedikal işaretler MO-BSS yöntemi kullanılarak işaretlerin orijinal kaynak şekilleri tahmin edilmiştir. MO-BSS yöntemi ile Tablo 4.1’de iki kadın ve bir erkek sesinin ayrıştırılması, Tablo 4.6’da aynı sesler ile ön işlemli MO-BSS yöntemi ile ayrıştırma sonuçları ve Tablo 4.11’de ise DWT MO-BSS yöntemi ile işaretlerin ayrıştırma sonuçları SNR cinsinden verilmiştir. Aynı yöntemler üzerinde farklı işaretlerin de testi sağlanmıştır. Bu kapsamda Tablo 4.16’da iki erkek ve bir beyaz Gauss gürültü işareti, Tablo 4.17’de anne EKG, beyaz Gauss ve Fetal EKG işaretlerinin ayrıştırılma sonuçları, Tablo 4.19’da ise EEG ve beyaz Gauss gürültü işaretlerinin ayrıştırılma sonuçları SNR cinsinden verilmiştir.

Uygulama sonuçları önerilen ön işlemli ve DWT MO-BSS yöntemlerinin işaretleri yüksek SNR oranları ile ayrıştırdığı kanıtlanmıştır. Genel olarak DWT MO-BSS yönteminin ön işlemli MO-BSS yöntemine göre işaretleri daha iyi ayrıştırdığı görülmüştür. İşlem süreleri açısından incelendiğinde önerilen yöntemlerin işlem yükleri artmasına rağmen çok az da olsa işlem sürelerinde azalma sağlanmıştır.

Ancak sunulan sorunların çözümüne yönelik literatürde çok az araştırılan bir yaklaşım olması nedeniyle elde edilen sonuçlar bu alanda çalışmayı teşvik etmektedir. Deneyler belirli veri setleri ve kriterleri içerse de diğer durumlar için çok amaçlı yaklaşım genel bir başarı sağlamaktadır. Bu sayede çok çeşitli uygulamalarda kullanılabilir.

Gelecekteki diğer çalışmalar, söz konusu problemin çözümündeki yöntemlerin performanslarını karşılaştırmak amacıyla BSS bağlamında farklı çok amaçlı yöntemlerin uygulanmasını içermektedir. Bu nedenle bu yeni yaklaşımda diğer veri kümeleri ve optimizasyon kriterleri test edilecektir. Problemden mevcut olan çok sayıda değişkenle başa çıkmak için daha etkili tekniklerin araştırılması yapılacaktır. Ayrıca, kullanılan yöntemlerin hesaplama süresini azaltmak amacıyla, bulunan çözümlerin yakınsaması ve çeşitliliği ile ilgili durdurma kriterleri araştırılacaktır.

KAYNAKÇA

1. Jutten, C., Hérault, J., 1991. Blind separation of sources, part I: An adaptive algorithm based on neuromimetic architecture. **Signal Processing**, **24**: 1–10.
2. Comon, P., Jutten, C., 2010. Handbook Of Blind Source Separation : Independent Component Analysis and Applications, In Elsevier, p: 831.
3. Miettinen, K., 1999. Nonlinear Multiobjective Optimization, In: Boston: Kluwer Academic Publishers, p: 298.
4. Pelegrina, G.D., Attux, R., Duarte, L.T., 2019. Application of multi-objective optimization to blind source separation. **Expert Systems with Applications**, **131**: 60–70.
5. Goh, S.K., Abbass, H.A., Tan, K.C., Al-Mamun, A., 2016. Decompositional independent component analysis using multi-objective optimization. **Soft Computing**, **20**(4): 1289–1304.
6. Siegfried, T., 2019. Why speech is a human innovation. **Knowable Magazine**.
7. Belinchón Carmona, M., Rivière, A., Igoa González, J.M., 1992. Psicología del Lenguaje :Investigación y teoría, In: Trotto, ed., pp: 439–449.
8. Giegerich, H.J., English phonology : an introduction, In: Cambridge University Press, p: 333.
9. Tiwari, M., Tiwari, M., 2012. Voice - How humans communicate? **Journal of Natural Science, Biology, and Medicine**, **3**(1): 3.
10. Rose, P., 2002. Forensic Speaker Identification, In: CRC Press, pp: xvi, 364.
11. Rose, P., 1999. Differences and distinguishability in the acoustic characteristics of hello in voices of similar-sounding speakers: A forensic phonetic investigation. **Australian Review of Applied Linguistics**, **22**(1): 1–42.
12. Laver, J.D.M., 1991. Voice quality and indexical information. **International Journal of Language & Communication Disorders**, **9**(1): 147.
13. Laver, J., 1991. The description of voice quality in general phonetic theory. **The Gift of Speech: Papers in the Analysis of Speech and Voice**, 184–208.

14. Kohler, K.J., 2000. The future of phonetics. **Journal of the International Phonetic Association**, 30(1–2): 1–24.
15. Nolan, F., 1991. Forensic phonetics. **Journal of Linguistics**, 27(2): 483–493.
16. Broeders, A.P.A., Rietveld, T., 1995. Speaker Identification by Earwitnesses, *In*: 38, Trier : Wissenschaftlicher Verlag, pp: 24–40.
17. Celesia, G.G., 2013. Disorders of Peripheral and Central Auditory Processing, *In*: Elsevier Health Sciences, p: 476.
18. <https://www.happyyearshearing.com/hearing-loss/how-the-ear-works/>. (Erişim tarihi: Ocak 2024).
19. Heffner, H.E., Heffner, R.S., 2007. Hearing ranges of laboratory animals. **Journal of the American Association for Laboratory Animal Science**, 46(1): 20–22.
20. Jain, S.N., 2012. Blind source separation and ica techniques: a review. **International Journal of Engineering Science and Technology**, 4(4): 1–14.
21. Braunwald, E., Fauci, A.S., Kasper, D.L., Hauser, S.L., Longo, D.L., Jameson, J.L., 2008. *Harrisons Principles of Internal Medicine*. 17th edi. McGraw-Hill Pro.
22. Wasimuddin, M., Elleithy, K., Abuzneid, A.S., Faezipour, M., Abuzagheh, O., 2020. Stages-based ECG signal analysis from traditional signal processing to machine learning approaches: A survey. **IEEE Access**, 8: 177782–177803.
23. Çelik, H., Karaboğa, N., 2021. Negatif olmayan matris ayrıştırma yöntemlerinde fetal elektrokardiyogram işaretin ayrıştırılması. **European Journal of Science and Technology**, 24: 247–251.
24. Sameni, R., Clifford, G.D., 2010. A review of fetal ECG signal processing; issues and promising directions. **The Open Pacing, Electrophysiology & Therapy Journal**, 3: 4.
25. Einthoven, W., 1895. Ueber die form des menschlichen Electrocardiogramms. **Pflügers Archiv European Journal of Physiology**, 60(3): 101–123.
26. Hurst, J.W., 1998. Naming of the waves in the ECG, with a brief account of their genesis. **Circulation**, 98(18): 1937–1942.
27. Chen, H., *Signal Processing of Electrocardiogram for Arrhythmia Prediction and Classification*, University Of Southampton, 2022.

28. Shahriari, Y., Fidler, R., Pelter, M.M., Bai, Y., Villaroman, A., Hu, X., 2018. Electrocardiogram signal quality assessment based on structural image similarity metric. **IEEE Transactions on Biomedical Engineering**, **65**(4): 748–753.
29. M, G., 1906. Ueber die direkte direkte ableitung der aktionsstrome des menschlichen herzens vom oesophagus und ueber das electrokardiogram des foetus. **Muenchener Medizinischen Wochenschrift**, **53**: 811–813.
30. Lindsley, D.B., 1942. Heart and brain potentials of human fetuses in utero. **The American Journal of Psychology**, **55**(3): 412.
31. Goodyer, A.V.N., Geiger, A.J., Monroe, W.M., 1942. Clinical fetal electrocardiography. **The Yale Journal of Biology and Medicine**, **15**(1): 1.
32. Hon, E.H., 1963. Instrumentation of fetal heart rate and fetal electrocardiography: II. A vaginal electrode. **American Journal of Obstetrics and Gynecology**, **86**(6): 772–784.
33. Oosterom, A., 1986. Spatial filtering of the fetal electrocardiogram. **Journal of Perinatal Medicine**, **14**(6): 411–419.
34. Van Leeuwen, P., Lange, S., Klein, A., Geue, D., Grönemeyer, D.H.W., 2004. Dependency of magnetocardiographically determined fetal cardiac time intervals on gestational age, gender and postnatal biometrics in healthy pregnancies. **BMC Pregnancy and Childbirth**, **4**(1): 1–10.
35. Allen, M.C., Donohue, P.K., Dusman, A.E., 1993. The limit of viability -- neonatal outcome of infants born at 22 to 25 weeks' Gestation. **<https://doi.org/10.1056/NEJM199311253292201>**, **329**(22): 1597–1601.
36. Brace, R.A., Wolf, E.J., 1989. Normal amniotic fluid volume changes throughout pregnancy. **American Journal of Obstetrics and Gynecology**, **161**(2): 382–388.
37. Oostendorp, T.F., van Oosterom, A., Jongsma, H.W., 1989. Electrical properties of tissues involved in the conduction of foetal ECG. **Medical & Biological Engineering & Computing**, **27**(3): 322–324.
38. Richter, M., Schreiber, T., Kaplan, D.T., 1998. Fetal ECG extraction with nonlinear state-space projections. **IEEE Transactions on Biomedical Engineering**, **45**(1): 133–137.

39. Zuckerwar, A.J., Pretlow, R.A., Stoughton, J.W., Baker, D.A., 1993. Development of a piezopolymer pressure sensor for a portable fetal heart rate monitor. **IEEE Transactions on Biomedical Engineering**, **40**(9): 963–969.
40. Pajkrt, E., Weisz, B., Firth, H. V., Chitty, L.S., 2004. Fetal cardiac anomalies and genetic syndromes. **Prenatal Diagnosis**, **24**(13): 1104–1115.
41. Gynecol, A.C. of O. and G.-O., 2009, undefined, ACOG Practice Bulletin No. 106: Intrapartum fetal heart rate monitoring: nomenclature, interpretation, and general management principles. **Cir.Nii.Ac.Jp**.
42. Peters, M., Crowe, J., Piéri, J.F., Quartero, H.W.P., Hayes-Gill, B., James, D., Stinstra, J., Shakespeare, S., 2001. Monitoring the fetal heart non-invasively: A review of methods. **Journal of Perinatal Medicine**, **29**(5): 408–416.
43. Kokkinakis, K., Loizou, P.C., 2008. Using blind source separation techniques to improve speech recognition in bilateral cochlear implant patients. **The Journal of the Acoustical Society of America**, **123**(4): 2379.
44. Clifford, G., 2005. Chapter 15 - Blind source separation: principal & independent component analysis. **Computer Science, Engineering**, 1–47.
45. Celik, H., Karaboga, N., 2022. Blind source separation with multi-objective optimization for denoising. **Elektronika Ir Elektrotechnika**, **28**(5): 62–67.
46. Comon, P., 1994. Independent component analysis, A new concept? **Signal Processing**, **36**(3): 287–314.
47. Hyvärinen, A., Oja, E., 2000. Independent component analysis: algorithms and applications. **Neural Networks**, **13**(4–5): 411–430.
48. Stone, J. V., 2004. Independent Component Analysis: A Tutorial Introduction, *In*: A Bradford B., MIT, Cambridge, MA.
49. Karhunen, J., 1999. Neural approaches to independent component analysis and source separation. **Helsinki University of Technology**, 1–18.
50. Çelik, H., Karaboğa, N., 2020. Ses işaretlerinin ayrıştırılmasında kör kaynak algoritmalarının performans analizleri. **Avrupa Bilim ve Teknoloji Dergisi**, **1**: 399–404.
51. Belouchrani, A., Abed-Meraim, K., Cardoso, J.F., Moulines, E., 1997. A blind

- source separation technique using second-order statistics. **IEEE Transactions on Signal Processing**, 45(2): 434–444.
52. Celik, H., Karaboga, N., 2023. Blind source separation with strength Pareto evolutionary algorithm 2 (SPEA2) using discrete wavelet transform. **Electronics** 2023, Vol. 12, Page 4383, 12(21): 4383.
 53. Douglas, S.C., 2001. Blind separation of acoustic signals. **Springer Berlin Heidelberg**, 355–380.
 54. Carlyon, R.P., 2004. How the brain separates sounds. **Trends in Cognitive Sciences**, 8(10): 465–471.
 55. Moore, B.C.J., Gockel, H., 2002. Factors influencing sequential stream segregation. **Acta Acust. United Acust**, 88: 320–332.
 56. Pelegrina, G.D., Duarte, L.T., 2016. A multi-objective approach for blind source extraction. 1-5. *Proceedings of the IEEE Sensor Array and Multichannel Signal Processing Workshop*, 10-13 July 2016, Rio de Janeiro, Brazil, IEEE.
 57. Yu, X., Lu, Y., Yu, X., 2018. Evaluating multiobjective evolutionary algorithms using MCDM methods. **Mathematical Problems in Engineering**, 2018:.
 58. Deb, K., Pratap, A., Agarwal, S., Meyarivan, T., 2002. A fast and elitist multiobjective genetic algorithm: NSGA-II. **IEEE Transactions on Evolutionary Computation**, 6(2): 182–197.
 59. Knowles, J., Corne, D., 1999. The Pareto archived evolution strategy: A new baseline algorithm for Pareto multiobjective optimisation. 98-105. *Proceedings of the 1999 Congress on Evolutionary Computation*, 06-09 July 1999, Washington, DC, USA, IEEE.
 60. Zitzler, E., Laumanns, M., Thiele, L., Zitzler, E., Laumanns, M., 2001. SPEA2: Improving the strength pareto evolutionary algorithm. TIK Report, 103.
 61. Li, H., Zhang, Q., 2009. Multiobjective optimization problems with complicated pareto sets, MOEA/ D and NSGA-II. **IEEE Transactions on Evolutionary Computation**, 13(2): 284–302.
 62. Sierra, M.R., Coello Coello, C.A., 2005. Improving PSO-based Multi-Objective optimization using crowding, mutation and ϵ -dominance. **Lecture Notes in**

Computer Science, **3410**: 505–519.

63. Carlos, A.C.C., Lamont, G.B., Veldhuizen, D.A. Van, 2007. Evolutionary Algorithms for Solving Multi-Objective Problems (Genetic and Evolutionary Computation), *In*: Springer Science & Business Media, p: 800.
64. Celik, H., Karaboga, N., 2023. Pareto front estimation in multi-objective optimization for signal separation, *In 2023 Innov. Intell. Syst. Appl. Conf. ASYU 2023, Institute of Electrical and Electronics Engineers Inc.*, pp: 1–4.
65. Schaffer, J.D., 1985. Multiple objective optimization with vector evaluated genetic algorithms, *In Proceedings of the 1st International Conference on Genetic Algorithms*, Pittsburgh, pp: 93–100.
66. Goldberg, D.E., **1989**. Genetic Algorithms in Search, Optimization and Machine Learning. Addison-Wesley Longman Publishing Co.
67. Deb, K., **2001**. Multi-objective optimization using evolutionary algorithms. John Wiley & Sons.
68. Pereira, V.M.S., Intradomain routing optimization based on evolutionary computation, Universidade do Minho, 2019.
69. Zitzler, E., Thiele, L., 1999. Multiobjective evolutionary algorithms: A comparative case study and the strength Pareto approach. **IEEE Transactions on Evolutionary Computation**, **3**(4): 257–271.
70. Subbaraj, P., 2011. Strength Pareto evolutionary algorithm based multi-objective optimization for shortest path routing problem in computer networks. **Article in Journal of Computer Science**.
71. Gharari, R., Poursalehi, N., Abbasi, M., Aghaie, M., 2016. Implementation of strength Pareto evolutionary algorithm in the multiobjective burnable poison placement optimization of KWU pressurized water reactor. **Nuclear Engineering and Technology**, **48**(5): 1126–1139.
72. Yuan, X., Zhang, B., Wang, P., Liang, J., Yuan, Y., Huang, Y., Lei, X., 2017. Multi-objective optimal power flow based on improved strength Pareto evolutionary algorithm. **Energy**, **122**: 70–82.
73. Sheng, W., Liu, Y., Meng, X., Zhang, T., 2012. An Improved Strength Pareto

- Evolutionary Algorithm 2 with application to the optimization of distributed generations. **Computers & Mathematics with Applications**, **64**(5): 944–955.
74. Corne, D.W., Knowles, J.D., Oates, M.J., 2000. The Pareto envelope-based selection algorithm for multiobjective optimization. *International Conference on Parallel Problem Solving from Nature*, 1917: 839–848.
 75. Deb, K., Agrawal, S., Pratap, A., Meyarivan, T., 2000. A Fast Elitist Non-Dominated Sorting Genetic Algorithm for Multi-Objective Optimization: NSGA-II, *In: Int. Conf. Parallel Probl. Solving from Nat.*, Springer, Berlin, Heidelberg, pp: 849–858.
 76. Lee, T.W., Ziehe, A., Orglmeister, R., Sejnowski, T., 1998. Combining time-delayed decorrelation and ICA: Towards solving the cocktail party problem. *ICASSP, IEEE International Conference on Acoustics, Speech and Signal Processing - Proceedings*, 15-15 May 1998, Seattle, WA, USA, pp/ 1249–1252.
 77. Ainhoren, Y., Engelberg, S., Friedman, S., 2008. The cocktail party problem. **IEEE Instrumentation and Measurement Magazine**, **11**(3): 44–48.
 78. Belkin, M., Rademacher, L., Voss, J., 2013. Blind Signal Separation in the Presence of Gaussian Noise. **30**: 270–287.
 79. Girolami, M., Fyfe, C., 1997. An extended exploratory projection pursuit network with linear and nonlinear anti-hebbian lateral connections applied to the cocktail party problem. **Neural Networks**, **10**(9): 1607–1618.
 80. Hamza, H.S., 2020. Comparative study of performance of particle swarm optimization and fast independent component analysis method in cocktail party problem. **Journal of University of Babylon for Pure and Applied Sciences**, (28):pp/217-225.
 81. Pelegrina, G.D., 2017. Uma Abordagem Baseada Em Otimização Multiobjetivo Para o Problema de Separação Cega de Fontes, Universidade Estadual de Campinas, Mestrado, Limeira, SP, pp/95.
 82. Bursa, N., Tatlidil, H., 2020. Evaluation of independent components analysis from statistical perspective and its comparison with principal components analysis. **Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Dergisi**. **24**(2):474-486.

83. Sevim, Y., 2009, Yapay Toplamsallık Yaklaşımı ile Anne ve Karnındaki Çocuğa Ait EKG İşaretlerinin Ayırıştırılması, Karadeniz Teknik Üniversitesi, Doktora Tezi, Trabzon, 164.
84. Sarı, H., 2003. Motion Estimation Using Complex Discrete Wavelet Transform, The Middle East Technical University, Master Thesis, Ankara, 82.
85. Daubechies, I., 1988. Orthonormal bases of compactly supported wavelets. **Communications on Pure and Applied Mathematics**, **41(7)**: 909–996.
86. Aguiar-Conraria, L., Soares, M.J., 2014. The continuous wavelet transform: moving beyond uni- and bivariate analysis. **Journal of Economic Surveys**, **28(2)**: 344–375.
87. Rioul, O., Duhamel, P., 1992. Fast algorithms for discrete and continuous wavelet transforms. **IEEE Transactions on Information Theory**, **38(2)**: 569–586.
88. Nason, G.P., Silverman, B.W., 1995. The Stationary Wavelet Transform and some Statistical Applications. Springer, New York, NY, 281–300.
89. Walnut, D.F., 2004. An Introduction to Wavelet Analysis, *In*: Birkhäuser Boston, p: 451.
90. Wickerhauser, M.V., Jensen, A., la Cour-Harbo, A., Boggess, A., Narcowich, F.J., 2003. Ripples in Mathematics: The discrete wavelet transforma first course in wavelets with fourier analysis. **The American Mathematical Monthly**, **110(2)**: 163.
91. Nievergelt, Y., 1999. Wavelets Made Easy. Birkhäuser Boston.
92. Vaidyanathan, P.P., 1992. NoMultirate Systems and Filter Banks. 1st editio. Pearson College Div.
93. Jansen, M., 2001. Noise Reduction by Wavelet Thresholding. Springer New York.
94. Skodras, A.N., 2015. Discrete wavelet transform: an introduction. Hellenic Open University, Technical Report, 26.
95. Addison, P.S., 2002. The Illustrated Wavelet Transform Handbook : Introductory Theory and Applications in Science, Engineering, Medicine and Finance. 1st Editio. CRC Press.
96. Semmlow, J.L., 2004. Biosignal and Biomedical Image Processing MATLA B-

Based Applications. CRC Press.

97. Coello Coello, C.A., 2006. Evolutionary multi-objective optimization: A historical view of the field. **IEEE Computational Intelligence Magazine**, 1(1): 28–36.
98. Abbass, H., Bender, A., Gaidow, S., Whitbread, P., 2011. Computational red teaming: Past, present and future. **IEEE Computational Intelligence Magazine**, 6(1): 30–42.
99. Durillo, J.J., Nebro, A.J., Alba, E., 2010. The jMetal framework for multi-objective optimization: Design and architecture. *2010 IEEE World Congress on Computational Intelligence, WCCI 2010 - 2010 IEEE Congress on Evolutionary Computation*, 18-23 July 2010, Barcelona, Spain, IEEE, pp/1-8.
100. Durillo, J.J., Nebro, A.J., 2011. jMetal: A Java framework for multi-objective optimization. **Advances in Engineering Software**, 42(10): 760–771.
101. Goh, C.K., Tan, K.C., 2009. A competitive-cooperative coevolutionary paradigm for dynamic multiobjective optimization. **IEEE Transactions on Evolutionary Computation**, 13(1): 103–127.
102. Wang, Y., Cai, Z., Guo, G., Zhou, Y., 2007. Multiobjective optimization and hybrid evolutionary algorithm to solve constrained optimization problems. **IEEE Transactions on Systems, Man, and Cybernetics, Part B: Cybernetics**, 37(3): 560–575.
103. Le, M.N., Ong, Y.S., Menzel, S., Seah, C.W., Sendhoff, B., 2012. Multi co-objective evolutionary optimization: Cross surrogate augmentation for computationally expensive problems. *2012 IEEE Congress on Evolutionary Computation, CEC 2012*, 10-15 June 2012, Brisbane, QLD, Australia, IEEE, 1-8.
104. Jiang, S., Zhang, J., Ong, Y.S., 2011. Asymmetric pareto-adaptive scheme for multiobjective optimization. **Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)**, 7106 LNAI: 351–360.
105. Goh, C.K., Tan, K.C., Cheong, C.Y., Ong, Y.S., 2007. Noise-induced features in robust multi-objective optimization problems. *2007 IEEE Congress on Evolutionary Computation, CEC 2007*, 25-28 September 2007, Singapore, IEEE, 568–575.

106. Zitzler, E., Thiele, L., 1998. Multiobjective optimization using evolutionary algorithms - A comparative case study. **Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)**, 1498 LNCS, Springer, Berlin, Heidelberg, 292–301.
107. Van Veldhuizen, D.A., Lamont, G.B., 2000. On measuring multiobjective evolutionary algorithm performance. *Proceedings of the 2000 Congress on Evolutionary Computation, CEC 2000*, 16-19 July 2000, La Jolla, CA, USA, IEEE, 204–211.
108. Van Veldhuizen, D.A., Lamont, G.B., 1999. Multiobjective Evolutionary Algorithm Test Suites. *ACM Symposium on Applied Computing*, 351–357.
109. Zhou, A., Jin, Y., Zhang, Q., Sendhoff, B., Tsang, E., 2006. Combining model-based and genetics-based offspring generation for multi-objective optimization using a convergence criterion. *2006 IEEE Congress on Evolutionary Computation, CEC 2006*, 16-21 July 2006, Vancouver, BC, Canada, IEEE, 892–899.
110. Okabe, T., Jin, Y., Sendhoff, B., 2003. A critical survey of performance indices for multi-objective optimisation. *2003 Congress on Evolutionary Computation, CEC 2003 - Proceedings*, 08-12 December 2003, Canberra, ACT, Australia, IEEE, 878–885.
111. Zitzler, E., Thiele, L., Laumanns, M., Fonseca, C.M., Da Fonseca, V.G., 2003. Performance assessment of multiobjective optimizers: An analysis and review. **IEEE Transactions on Evolutionary Computation**, 7(2): 117–132.
112. Tan, K.C., Lee, T.H., Khor, E.F., 2002. Evolutionary algorithms for multi-objective optimization: Performance assessments and comparisons. **Artificial Intelligence Review**, 17(4): 251–290.
113. Knowles, J., Corne, D., 2002. On metrics for comparing nondominated sets. *Proceedings of the 2002 Congress on Evolutionary Computation, CEC 2002*, 12-17 May 2002, Honolulu, HI, USA, IEEE, 711–716.
114. Riquelme, N., Von Lücken, C., Barán, B., 2015. Performance metrics in multi-objective optimization. *Proceedings - 2015 41st Latin American Computing Conference, CLEI 2015*.
115. Wu, J., Azarm, S., 2001. Metrics for Quality Assessment of a Multiobjective

- Design Optimization Solution Set. **Journal of Mechanical Design**, 123(1):18–25.
116. Jiang, S., Ong, Y.-S., Zhang, J., Feng, L., 2014. Consistencies and Contradictions of Performance Metrics in Multiobjective Optimization. **IEEE Transactions on Cybernetics**, 1–14.
 117. Karakoyun, M., Kodaz, H., 2021. Çok amaçlı mühendislik tasarımı ve kısıtlı problemler için hibrit birçok amaçlı optimizasyon algoritması. **Mühendislik Bilimleri ve Tasarım Dergisi**, 9(4): 1200–1211.
 118. Akay, B., 2013. Synchronous and asynchronous Pareto-based multi-objective Artificial Bee Colony algorithms. **Journal of Global Optimization**, 57(2): 415–445.
 119. Li, M., Chen, T., Yao, X., How to evaluate solutions in pareto-based search-based software engineering? a critical review and methodological guidance. **IEEE Transactions on Software Engineering**, 48(5): 1771-1799.
 120. Zhang, Q., Zhou, A., Zhao, S., Suganthan, P.N., Liu, W., Tiwari, S., 2009. Multiobjective optimization Test Instances for the CEC 2009 Special Session and Competition, University of Essex, 1-30.
 121. Liu, Y., Gong, D., Sun, J., Jin, Y., 2017. A Many-Objective Evolutionary Algorithm Using A One-by-One Selection Strategy. **IEEE Transactions on Cybernetics**, 47(9): 2689–2702.
 122. Li, M., Yao, X., 2019. Quality evaluation of solution sets in multiobjective optimisation: A survey. **ACM Computing Surveys (CSUR)**, 52(2): 1–38.
 123. Chicano, F., Luna, F., Nebro, A.J., Alba, E., 2011. Using multi-objective metaheuristics to solve the software project scheduling problem. *Genetic and Evolutionary Computation Conference, GECCO'11*, 1915–1922.
 124. Durillo, J.J., Nae, V., Prodan, R., 2014. Multi-objective energy-efficient workflow scheduling using list-based heuristics. **Future Generation Computer Systems**, 36: 221–236.
 125. Ferrer, J., Chicano, F., Alba, E., 2012. Evolutionary algorithms for the multi-objective test data generation problem. **Software: Practice and Experience**, 42(11): 1331–1362.

126. Fleck, M., Troya, J., Kessentini, M., Wimmer, M., Alkhazi, B., 2017. Model transformation modularization as a many-objective optimization problem. **IEEE Transactions on Software Engineering**, 43(11): 1009–1032.
127. Hierons, R.M., Li, M., Liu, X., Segura, S., Zheng, W., 2016. SIP: Optimal product selection from feature models using many-objective evolutionary optimization. **ACM Transactions on Software Engineering and Methodology (TOSEM)**, 25(2): 1–39.
128. Olaechea, R., Rayside, D., Guo, J., Czarnecki, K., 2014. Comparison of exact and approximate multi-objective optimization for software product lines. *ACM International Conference Proceeding Series*, 1: 92–101.
129. Ouni, A., Kula, R.G., Kessentini, M., Ishio, T., German, D.M., Inoue, K., 2017. Search-based software library recommendation using multi-objective optimization. **Information and Software Technology**, 83: 55–75.
130. Panichella, A., Oliveto, R., Di Penta, M., De Lucia, A., 2015. Improving multi-objective test case selection by injecting diversity in genetic algorithms. **IEEE Transactions on Software Engineering**, 41(4): 358–383.
131. Pascual, G.G., Lopez-Herrejon, R.E., Pinto, M., Fuentes, L., Egyed, A., 2015. Applying multiobjective evolutionary algorithms to dynamic software product lines for reconfiguring mobile applications. **Journal of Systems and Software**, 103: 392–411.
132. Nebro, A.J., Luna, F., Alba, E., Dorronsoro, B., Durillo, J.J., Beham, A., 2008. AbYSS: Adapting scatter search to multiobjective optimization. **IEEE Transactions on Evolutionary Computation**, 12(4): 439–457.
133. Shen, X., Minku, L.L., Bahsoon, R., Yao, X., 2016. Dynamic Software Project Scheduling through a Proactive-Rescheduling Method. **IEEE Transactions on Software Engineering**, 42(7): 658–686.
134. Durillo, J.J., Zhang, Y., Alba, E., Nebro, A.J., 2009. A study of the multi-objective next release problem. *Proceedings - 1st International Symposium on Search Based Software Engineering, SSBSE 2009*, 49–58.
135. Sayyad, A.S., Ingram, J., Menzies, T., Ammar, H., 2013. Optimum feature selection in software product lines: Let your model and values guide your search.

2013 1st International Workshop on Combining Modelling and Search-Based Software Engineering, CMSBSE 2013 - Proceedings, 22–27.

136. Sayyad, A.S., Menzies, T., Ammar, H., 2013. On the value of user preferences in search-based software engineering: A case study in software product lines. *Proceedings - International Conference on Software Engineering*, 492–501.
137. Shen, X.N., Minku, L.L., Marturi, N., Guo, Y.N., Han, Y., 2018. A Q-learning-based memetic algorithm for multi-objective dynamic software project scheduling. **Information Sciences**, **428**: 1–29.
138. Zhang, Y., Harman, M., Lim, S.L., 2013. Empirical evaluation of search based requirements interaction management. **Information and Software Technology**, **55**(1): 126–152.
139. Li, M., Yang, S., Liu, X., 2014. Shift-based density estimation for pareto-based algorithms in many-objective optimization. **IEEE Transactions on Evolutionary Computation**, **18**(3): 348–365.
140. <https://www.kecl.ntt.co.jp/icl/signal/sawada/demo/bss2to4/index.html>. (Erişim tarihi: Eylül 2023).
141. Hartland, N.P., Maltoni, F., Nocera, E.R., Rojo, J., Slade, E., Vryonidou, E., Zhang, C., 2019. A Monte Carlo global analysis of the Standard Model Effective Field Theory: the top quark sector. **Journal of High Energy Physics** **2019** **2019**:4, **2019**(4): 1–78.
142. <https://physionet.org/about/database/>. (Erişim tarihi: Eylül 2023).

ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı Soyadı: Hüsamettin ÇELİK

Uyruğu: Türkiye (T.C)

Doğum Tarihi ve Yeri:

Medeni Durum:

e-mail:

Yazışma Adresi:

EĞİTİM

Derece	Kurum	Mezuniyet Tarihi
Yüksek Lisans	Karadeniz Teknik Üniversitesi, Elektrik-Elektronik Mühendisliği	2015
Lisans	Atatürk Üniversitesi, Elektrik-Elektronik Mühendisliği	2021
Lisans	Gazi Üniversitesi, Elektronik-Bilgisayar Eğitimi	2006
Lise	Fatih Mesleki ve Teknik Anadolu Lisesi, Erzincan	2001

İŞ DENEYİMLERİ

Yıl	Kurum	Görev
2011-Halen	Erzincan Binali Yıldırım Üniversitesi	Öğretim Görevlisi
2009-2010	Atatürk Üniversitesi	Okutman
2007-2009	MEB	Öğretmen

YABANCI DİL

İngilizce

YAYINLAR

1. Celik, H., Karaboga, N. 2023. Blind source separation with strength Pareto evolutionary algorithm 2 (SPEA2) using discrete wavelet transform. **Electronics**, **12** (21), 4383.
2. Celik, H., Karaboga, N. 2022. Blind source separation with multi-objective optimization for denoising. **Elektronika ir Elektrotechnika**, **28** (5), 62-67.
3. Çelik, H., Karaboğa, N. 2021. Negatif Olmayan Matris Ayırıştırma Yöntemlerinde Fetal Elektrokardiyogram İşaretin Ayırıştırılması. **Avrupa Bilim ve Teknoloji Dergisi**, **(24)**, 252-257.
4. Çelik, H., Karaboğa, N. 2020. Wishart Matris' lerinde En Büyük Özdeğer Olasılık Dağılım Fonksiyonlarının Karşılaştırılması. **Avrupa Bilim ve Teknoloji Dergisi**, 393-398.
5. Çelik, H., Karaboğa, N. 2020. Ses işaretlerinin ayırıştırılmasında kör kaynak algoritmalarının performans analizleri. **Avrupa Bilim ve Teknoloji Dergisi**, 399-404.
6. Celik, H., Karaboga, N. 2023. Pareto front estimation in multi-objective optimization for signal separation. In *2023 Innovations in Intelligent Systems and Applications Conference (ASYU)* (pp. 1-4). IEEE.
7. Celik, H., Karaboga, N. Blind source separation with multi-objective optimization for denoising. *26th International Conference ELECTRONICS 2022*, Kaunas, Litvanya, 19- 21 Haziran 2022, ss.62-67
8. Celik, H., Karaboga, N. Negatif olmayan matris ayırıştırma yöntemlerinde fetal elektrokardiyogram işaretin ayırıştırılması. *ARACONF 2021-2 nd International Conference on Access to Recent Advances in Engineering and Digitalization*, Kayseri, Türkiye, 10- 12 Mart 2021, ss.117-118

9. Celik, H., Karaboga, N. Beyin tümörünün konum tespitinde trilineer interpolasyon yönteminin kullanımı. *Engineers of Future International Student Symposium*, Zonguldak, Türkiye, 7- 08 Mayıs 2020, ss.125-128
10. Celik, H., Karaboga, N. Ses işaretlerinin ayrıştırılmasında kör kaynak algoritmalarının performans analizleri. *International Conference On Access To Recent Advances In Engineering And Digitalization*, Kayseri, Türkiye, 5- 07 Mart 2020, ss.138-139
11. Celik, H., Karaboga, N. Wishart matris'lerinde en büyük özdeğer olasılık dağılım fonksiyonlarının karşılaştırılması. *International Conference On Access To Recent Advances In Engineering And Digitalization*, Kayseri, Türkiye, 5- 07 Mart 2020, ss.137