

**KARADENİZ TEKNİK ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ**

**ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI**

**NEGATİF OLMAYAN MATRİS AYRIŞTIRMA İLE TEK KANAL KÖR KAYNAK  
AYRIŞTIRMA**

**YÜKSEK LİSANS TEZİ**

**Fatih Yavuz ILGIN**

**HAZİRAN 2013  
TRABZON**

**KARADENİZ TEKNİK ÜNİVERSİTESİ**  
**FEN BİLİMLERİ ENSTİTÜSÜ**

**ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI**

**NEGATİF OLAMAYAN MATRİS AYRIŞTIRMA İLE TEK KANAL KÖR**  
**KAYNAK AYRIŞTIRMA**

**Fatih Yavuz ILGIN**

**Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsünde**  
**"YÜKSEK LİSANS (ELEKTRONİK)"**  
**Unvanı Verilmesi İçin Kabul Edilen Tezdir.**

**Tezin Enstitüye Verildiği Tarih : 14.05.2013**  
**Tezin Savunma Tarihi : 25.06.2013**

**Tez Danışmanı : Yrd. Doç. Dr. Yusuf SEVİM**

**Trabzon 2013**

**Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsü**  
**Elektrik-Elektronik Mühendisliği Anabilim Dalında**  
**Fatih Yavuz ILGIN tarafından hazırlanan**

**NEGATİF OLMAYAN MATRİS AYRIŞTIRMA İLE TEK KANAL KÖR KAYNAK  
AYRIŞTIRMA**

**başlıklı bu çalışma, Enstitü Yönetim Kurulunun 28 / 05 / 2013 gün ve 1507 sayılı  
kararıyla oluşturulan jüri tarafından yapılan sınavda**

**YÜKSEK LİSANS TEZİ**  
**olarak kabul edilmiştir.**

**Jüri Üyeleri**

**Başkan : Yrd. Doç. Dr. Ayten ATASOY** .....

**Üye : Yrd. Doç. Dr. Yusuf SEVİM** .....

**Üye : Yrd. Doç. Dr. Bekir DİZDAROĞLU** .....

**Prof. Dr. Sadettin KORKMAZ**

**Enstitü Müdürü**

## ÖNSÖZ

Karadeniz Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Elektrik-Elektronik Mühendisliği Anabilim Dalı, Yüksek Lisans Programı çerçevesinde gerçekleştirilmiş olan bu çalışma “Negatif Olmayan Matris Ayırıştırma ile Tek Kanal Kör Kaynak Ayırıştırma” işlemini ele almaktadır.

Öncelikle bu çalışmam esnasında bilgi ve tecrübelerini esirgemeyen danışman hocam Sayın Yrd. Doç. Dr. Yusuf SEVİM’e ve beni bugüne kadar yalnız bırakmayan, desteğini hiçbir zaman esirgemeyen, değerli eşim Kübra SAKA ILGIN’a bu vesileyle sevgi ve saygılarımı sunarım.

Fatih Yavuz ILGIN  
Trabzon 2013

## **TEZ BEYANNAMESİ**

Yüksek Lisans Tezi olarak sunduğum “Negatif Olmayan Matris Ayrıştırma ile Tek Kanal Kör Kaynak Ayrıştırma” başlıklı bu çalışmayı baştan sona kadar danışmanım Yrd. Doç. Dr. Yusuf SEVİM’in sorumluluğunda tamamladığımı, verileri/örnekleri kendim topladığımı, deneyleri/analizleri ilgili laboratuvarlarda yaptığımı, başka kaynaklardan aldığım bilgileri metinde ve kaynakçada eksiksiz olarak gösterdiğimi, çalışma sürecinde bilimsel araştırma ve etik kurallara uygun olarak davrandığımı ve aksinin ortaya çıkması durumunda her türlü yasal sonucu kabul ettiğimi beyan ederim.09.07.2013

Fatih Yavuz ILGIN

## İÇİNDEKİLER

	<b><u>Sayfa No</u></b>
ÖNSÖZ.....	III
TEZ BEYANNAMESİ.....	IV
İÇİNDEKİLER .....	V
ÖZET .....	VII
SUMMARY.....	VIII
ŞEKİLLER DİZİNİ .....	IX
TABLolar DİZİNİ.....	XI
SEMBOLLER DİZİNİ .....	XII
1. GENEL BİLGİLER .....	1
1.1. Giriş.....	1
1.2. Kör Kaynak Ayırıştırma .....	3
1.3. Tek Kanal Kör Kaynak Ayırıştırma .....	6
1.3.1. Bağımsız Bileşen Analizi .....	7
1.3.2. Negatif Olmayan Matris Ayırıştırma.....	8
1.3.3. Kaynak Modelleme.....	8
1.4. Karışım Modelleri.....	8
1.4.1. Anlık Karışım Modeli.....	9
1.4.2. Yansız Karışım Modeli .....	10
1.4.3. Yansızlı Karışım Modeli .....	10
1.5. Ses ve Müzik Enstrümanlarının Sesleri.....	12
1.6. Müzikal Enstrümanların Ürettikleri Frekans Bileşenleri.....	12
2. DALGACIK DÖNÜŞÜMÜ VE SKALOGRAM .....	14
2.1. Dalgacık Dönüşümünün Tarihsel Gelişimi .....	14
2.2. Durağan ve Durağan Olmayan İşaretler .....	14
2.3. Kısa Zamanlı Fourier Dönüşümü .....	15
2.4. Dalgacık Dönüşümü .....	21
2.4.1. Ana Dalgacıkların Özellikleri.....	25
2.4.1.1. Morlet Dalgacığı.....	25

2.4.1.2. DOG (Derivative of Gaussian) Dalgacıđı .....	27
2.4.1.3. Paul Dalgacıđı .....	29
3. NEGATİF OLMAYAN MATRİS AYRIŞTIRMA .....	31
3.1. Matematiksel Tanımlar .....	32
3.2. NOMA Algoritmaları .....	34
3.2.1. Lee ve Seung Algoritması .....	34
3.2.1.1. Öklid Uzaklıklı Lee ve Seung Algoritması .....	34
3.2.1.2. Kullback-Leibler Yakınsama Tabanlı Lee ve Seung Algoritması.....	38
3.3. NOMA Algoritmasının KKA Problemine Uygulanması .....	39
3.4. Skalogramın Ayrıştırılması.....	44
4. DENEYSEL ÇALIŞMALAR.....	52
5. İRDELEME VE SONUÇLAR .....	57
6. ÖNERİLER.....	58
7. KAYNAKLAR .....	59
8. EKLER.....	64
ÖZGEÇMİŞ	

Yüksek Lisans Tezi

ÖZET

NEGATİF OLMAYAN MATRİS AYRIŞTIRMA İLE TEK KANAL KÖR KAYNAK  
AYRIŞTIRMA

Fatih Yavuz ILGIN

Karadeniz Teknik Üniversitesi  
Fen Bilimleri Enstitüsü  
Elektrik-Elektronik Mühendisliği Anabilim Dalı  
Danışman: Yrd. Doç. Dr. Yusuf SEVİM  
2013, 63 Sayfa, 1 Sayfa Ek

Kör kaynak ayırıştırma, birden fazla sinyalin karışımını içeren bir veri kümesinden bu karışımı oluşturan her bir kaynağın tahmin edilmesi olarak tanımlanabilir. Bu işlemin kör olarak adlandırılması kaynaklar hakkında hiçbir ek bilgi olmadığı anlamını taşımaktadır. Kör kaynak ayırıştırma da tahmin edilecek sinyal sayısı kadar karışım sinyali varken, tek kanal kör kaynak ayırıştırma işleminde sadece bir karışım sinyali olduğundan kaynakların tahmini maliyetli bir işlemdir. Bahsedilen bu yöntemle herhangi bir işarete eklenmiş istenmeyen bir gürültü, bozucu bir etki veya başka bir sinyal kaynağı diğer bir kaynaktan ayırıştırılabilir veya bu çalışmada olduğu gibi tek bir mikrofonla kaydedilmiş 2 farklı enstrümantal işaret birbirinden ayırıştırılabilir. Yapılan bu çalışmada sürekli dalgacık dönüşümü kullanılarak negatif olmayan matris ayırıştırma ile tek kanallı olarak kaydedilen iki enstrümantal işaret birbirinden ayırıştırılmıştır. Önerilen yöntemin başarımlarını analizini değerlendirmek için sonuçlar işaret gürültü oranı cinsinden değerlendirilmiştir.

**Anahtar Kelimeler:** Kör Kaynak Ayırıştırma, Kokteyl Parti Problemi, Negatif Olmayan Matris Ayırıştırma, Sürekli Dalgacık Dönüşümü



Master Thesis

SUMMARY

SINGLE CHANNEL BLIND SOURCE SEPARATION USING NONNEGATIVE  
MATRIX FACTORIZATION

Fatih Yavuz ILGIN

Karadeniz Technical University  
The Graduate School of Natural and Applied Sciences  
Electric-Electronic Engineering Program  
Supervisor: Assist. Prof. Yusuf SEVİM  
2013, 63 Pages, 1 Pages Appendix

Blind source separation that can be described as estimating each signal from a data set comprising a mixture of more than one signal. This process is called as blind means that there is no additional information on resources. When blind source separation process has mixture signal as the number of signals to be estimated, single-channel blind source separation process has only one mixture signal and because of that estimating resources is very costly operation. This method where in the bookmarked any unwanted noise, distort or otherwise signal source separated from other source or 2 different instrumental point recorded with one microphone can be separated from each other as in this study. In this study, two instrumental points recorded as a single-channel were separated from each other with a non-negative matrix factorization using a continuous wavelet transform. To evaluate the proposed method's performance analysis, results were evaluated in terms of signal noise ratio.

**Key Words:** Blind Source Separation, Cocktail Party Problem, Nonnegative Matrix Factorization, Continuous Wavelet Transform

## ŞEKİLLER DİZİNİ

### Sayfa No

Şekil 1. SDD kullanarak NOMA ile tek kanal kör kaynak ayrıştırma için blok diyagram .	2
Şekil 2. Kör kaynak ayrıştırma ve kokteyl parti problemi .....	4
Şekil 3. Tek kanal kör kaynak ayrıştırma .....	6
Şekil 4. Anlık karışım modeli gösterimi.....	9
Şekil 5. Yansımali karışım modeli .....	11
Şekil 6. Dünya genelinde kullanılan notalar.....	12
Şekil 7. Viyolaya ait işaretin zamanla değişimi .....	13
Şekil 8. Trampete ait işaretin zamanla değişimi.....	13
Şekil 9. Durağan işaret.....	14
Şekil 10. Durağan olmayan işaret.....	15
Şekil 11. Sinüs işaret(a) ve fourier dönüşümü(b) .....	16
Şekil 12. Bir gürültü işareti(a) ve bu işaretin fourier dönüşümü(b) .....	16
Şekil 13. Kısa zamanlı fourier dönüşümü ve işaretin pencerelemesi .....	17
Şekil 14. Kısa zamanlı fourier dönüşümü ve eşit ölçekli pencereler .....	17
Şekil 15. Viyola enstrümanına ait işaret.....	18
Şekil 16. Viyola işaretine ait spektogram (pencere boyutu 128).....	19
Şekil 17. Viyola işaretine ait spektogram (pencere boyutu 2048).....	19
Şekil 18. Şekil 17'den bir kesit.....	20
Şekil 19. Şekil 18 'den bir kesit.....	20
Şekil 20. SDD ile işaretin pencerelemesi .....	22
Şekil 21. SDD ile değişken pencere boyutları .....	22
Şekil 22. SDD'nin gösterimi .....	23
Şekil 23. SDD'de dalgacığın kaydırılması .....	23
Şekil 24. SDD için geniş ve dar ölçekler.....	24
Şekil 25. Morlet dalgacığı .....	26
Şekil 26. Viyola enstrümanına ait işaret ve skalogramı (Morlet).....	26
Şekil 27. Trampet enstrümanına ait işaret ve skalogramı(Morlet) .....	27
Şekil 28. DOG dalgacığı.....	27
Şekil 29. Trampet enstrümanına ait işaret ve skalogramı (DOG) .....	28

Şekil 30. Viyola enstrümanına ait işaret ve skalogramı (DOG).....	28
Şekil 32. Trampet enstrümanına ait işaret ve skalogramı (Paul).....	29
Şekil 31. Paul dalgacığı .....	29
Şekil 33. Viyola enstrümanına ait işaret ve skalogramı (Paul).....	30
Şekil 34. NOMA'nın veri matrisini çarpan 2 matrise ayrıştırması.....	32
Şekil 35. Kokteyl parti problemi ve NOMA .....	33
Şekil 36. NOMA algoritmasının ayrıştıracağı kaynak sinyaller.....	39
Şekil 37. Dört adet kaynak sinyalinin dört sensörle kaydedilmiş şekli.....	40
Şekil 38. Öklid uzaklığının iterasyon sayısına göre değişim .....	41
Şekil 39. NOMA tarafından tahmin edilen kaynak sinyaller .....	42
Şekil 40. 1. Kaynak için Monte Carlo analizi İGO sonuçları.....	42
Şekil 41. 2. Kaynak için Monte Carlo analizi İGO sonuçları.....	43
Şekil 42. 3. Kaynak için Monte Carlo analizi İGO sonuçları.....	43
Şekil 43. 4. Kaynak için Monte Carlo analizi İGO sonuçları.....	43
Şekil 44. Viyola enstrümanına ait işaret ve skalogramı (Morlet).....	45
Şekil 45. Viyola enstrümanına ait işaret ve skalogramı (Morlet).....	45
Şekil 46. Karışmış işaretin skalogramı (Morlet) .....	46
Şekil 47. Karışmış işaretin skalogramı (Morlet) .....	47
Şekil 48. A matrisinin sütunları.....	48
Şekil 49. NOMA ile skalogramın ayrıştırılması .....	48
Şekil 50. İkili maske için ön hazırlık.....	49
Şekil 51. Birinci kaynak için ikili maske.....	50
Şekil 52. İkinci kaynak için ikili maske .....	50
Şekil 53. Trampete ait orijinal ve tahmin edilen işaretle.....	51
Şekil 54. Viyolaya ait orijinal ve tahmin edilen işaretler .....	51
Şekil 55. Öklid-NOMA algoritması için İGO sonuçlarının viyola işareti için değişimi(100 iterasyon) .....	52
Şekil 56. Öklid-NOMA algoritması için İGO sonuçlarının trampet işareti için değişimi(100 iterasyon) .....	53
Şekil 57. Kull-Back Leibler-NOMA algoritması için İGO sonuçlarının viyola işareti için değişimi(100 iterasyon).....	53
Şekil 58. Kull-Back Leibler-NOMA algoritması için İGO sonuçlarının trampet işareti için değişimi(100 iterasyon).....	54

## TABLULAR DİZİNİ

### Sayfa No

Tablo 1. Karışım modellerine özgü doğrusal operatörler ve karışım parametreleri.....	11
Tablo 2. Öklid ve kullback –leibler yakınsama tabanlı NOMA algoritmalarının iterasyon sayısına göre performans analizleri .....	44
Tablo 3. Önerilen algoritmalar için İGO sonuçları ortalaması(50 iterasyon).....	55
Tablo 4. Önerilen algoritmalar için çalışma süreleri sonuçları ortalaması (50 iterasyon) ..	55
Tablo 5. Önerilen algoritmalar için İGO sonuçları ortalaması(100 iterasyon).....	55
Tablo 6. Önerilen algoritmalar için çalışma süreleri sonuçları ortalaması (100 iterasyon)	56

## SEMBOLLER DİZİNİ

$A$	:	Karıştırma Matrisi
$BBA$	:	Bağımsız Bileşen Analizi
$C$	:	Dalgacık Dönüşümü Regresyon Katsayısı
$D_{ök}$	:	Öklid Mesafesi
$DOG$	:	Derivative of Gaussian(Gauss Türevi)
$FD$	:	Fourier Dönüşümü
$BBA$	:	Independent Component Analysis(Bağımsız Bileşen Analizi)
$İGO$	:	İşaret Gürültü Oranı
$KKA$	:	Kör Kaynak Ayırıştırma
$KZFD$	:	Kısa Zamanlı Fourier Dönüşümü
$NOMA$	:	Negatif Olmayan Matris Ayırıştırma
$SDD$	:	Sürekli Dalgacık Dönüşümü
$SKAL(a)$	:	$a$ işaretinin skalogramı
$TKKA$	:	Tek Kanal Kör Kaynak Ayırıştırma
$TSDD$	:	Ters Sürekli Dalgacık Dönüşümü
$TBA$	:	Temel Bileşen Analizi
$Y$	:	Karışım sinyalini içeren matris
$a_{11}$	:	1. kaynağın 1.sensöre olan uzaklık katsayısı
$a_{12}$	:	2. kaynağın 1.sensöre olan uzaklık katsayısı
$a_{21}$	:	1. kaynağın 2.sensöre olan uzaklık katsayısı
$a_{22}$	:	2. kaynağın 2.sensöre olan uzaklık katsayısı
$e(n)$	:	Gauss dağılımlı gürültü
$f$	:	Frekans
$S_1$	:	1. kaynak sinyali

$S_2$	:	2. kaynak sinyali
$s$	:	Sürekli Dalgacık Dönüşümü ölçek parametresi
$\hat{s}_1$	:	Tahmin edilen 1. kaynak
$\hat{s}_2$	:	Tahmin edilen 2. kaynak
$y_1(n)$	:	1. Sensör tarafından kaydedilen karışmış sinyal
$y_2(n)$	:	2. Sensör tarafından kaydedilen karışmış sinyal
$\psi_{paul}(x)$	:	Paul dalgacığı fonksiyonu
$\psi_{morlet}(x)$	:	Morlet dalgacığı fonksiyonu
$\psi_{DOG}(x)$	:	DOG dalgacığı fonksiyonu
$\tau$	:	Sürekli Dalgacık Dönüşümü öteleme parametres

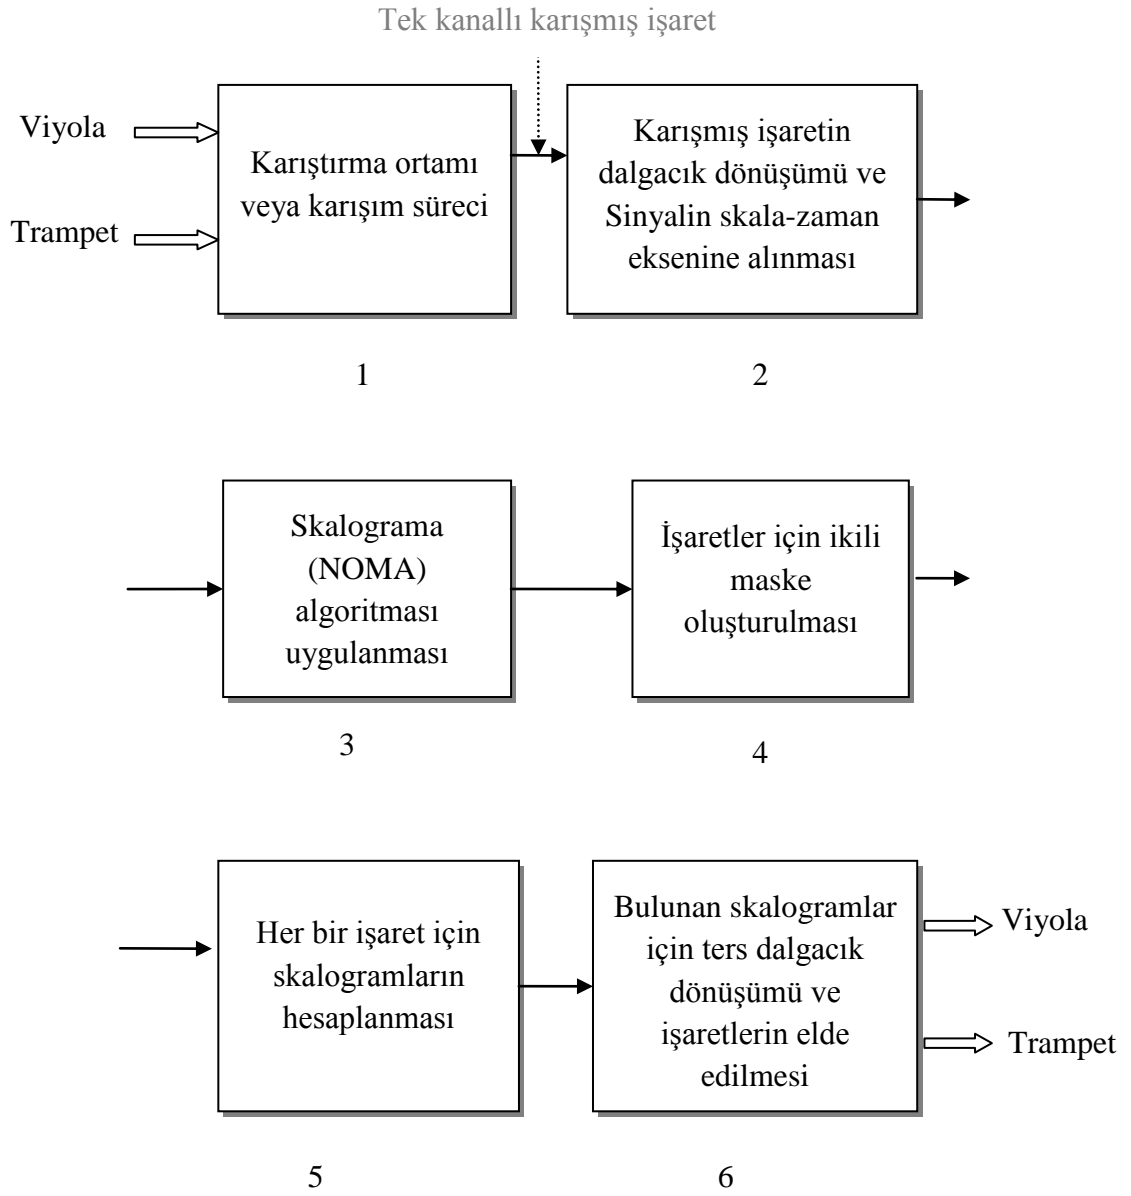
## 1. GENEL BİLGİLER

### 1.1. Giriş

Tek kanal kör kaynak ayrıştırma (TKKA) birden fazla sinyalin karışımını içeren sadece bir adet sinyal veya işaretten, kaynaklar hakkında başka hiçbir ek bilgi olmadan her bir kaynağın tahmin edilmesi işlemidir [1]. Ses uygulamalarında özellikle ortam dinlemelerinde tek bir sensörle kaydedilen karışım sinyallerinden orijinal kaynak seslerine ulaşmak için TKKA kullanılabilir. Diğer taraftan birçok pratik uygulamada sistem tarafından işlenecek olan ses nadiren temizdir. Genellikle çevreden istenmeyen gürültü sinyalleri veya başka yabancı sesler ses sinyaline eklenmiş halde bulunur. Sesin veya herhangi bir sinyalin sistem tarafından işlenmesi için gürültü ve diğer bozucu etkilerden arındırılmış olması gerekmektedir. Gürültü içeren bu sinyaller tek kaynaktan kaydedilmiş ve orijinal kaynaklar hakkında hiçbir bilgi bilinmiyorsa, istenmeyen bu sinyalleri veya gürültüleri ses kaynağından ayırmak için tek kanal kaynak ayrıştırma yöntemleri kullanılabilir.

Bahsedilen bu problemin çözümü için şu ana kadar önerilen metotların birçoğu tek kaynaktan alınan sinyallerin kısa zamanlı fourier dönüşümü (KZFD) alınarak oluşturulan genlik spektrogramının ayrıştırılması esasına dayanır [1-3]. Önceki yıllarda yapılmış çalışmalarda karışmış halde bulunan işaretin genlik spektrogramını, zamanda süreklilik ve seyrek veri kriterlerini kullanarak çeşitli bileşenlerin toplamı olarak ayrıştıran bir yöntem geliştirmiştir [4]. Başka bir çalışmada her bir müzik aletini zamanda şiddeti değişen bir zaman-frekans imzasıyla modelleyen bir negatif olmayan matris ayrıştırma algoritması önermiştir [5]. Polifonik müzikte müzik aletlerini ayırt etmek için her bir müzik aletini log-frekans spektrogramında hem zaman hem de frekansta evrişen tek bir zaman-frekans profili ile temsil eden, negatif olmayan matris ayrıştıran ters evrişim algoritması önermişlerdir [6]. Bu tezde önerilen yeni yöntem ile tek kaynaktan alınan karışmış işaretleri içeren işaret, sürekli dalgacık dönüşümü (SDD) kullanılarak skala-zaman uzayına (skalogram) taşındıktan sonra negatif olmayan matris ayrıştırma (NOMA) algoritması kullanarak ayrıştırma işlemi yapılmaktadır. Ayrıştırılan her bir skalogramın daha sonra tekrar ters SDD'si alınarak her bir işaret kaynağına ait ayrı ayrı işaretler elde edilmiştir. Yapılan uygulamada viyola ile trampet sesleri tek kanallı olarak karıştırılmış

ve önerilen yöntemle ayrıştırılmıştır. Önerilen yöntemin performans değerlendirmesi yapılırken, Öklid uzaklıklı NOMA ve Kull-Back Leibler yakınsama tabanlı NOMA gibi farklı NOMA algoritmaları ve farklı dalgacık dönüşümleri (Paul Dalgacığı, Gaussian Türevi Dalgacığı, Morlet Dalgacığı) ile simule edilerek karşılaştırma yapılmıştır. Ayrıca bu yöntemin başarımlarını analizini daha iyi değerlendirebilmek ve diğer yöntemlerle karşılaştırabilmek için [1] nolu kaynakta önerilen yöntemle sonuçları karşılaştırılmıştır. Önerilen bu yöntem için yapılan işlemler sırası ile Şekil 1 'de gösterilmiştir.



Şekil 1. SDD kullanarak NOMA ile tek kanal kör kaynak ayrıştırma için blok diyagram



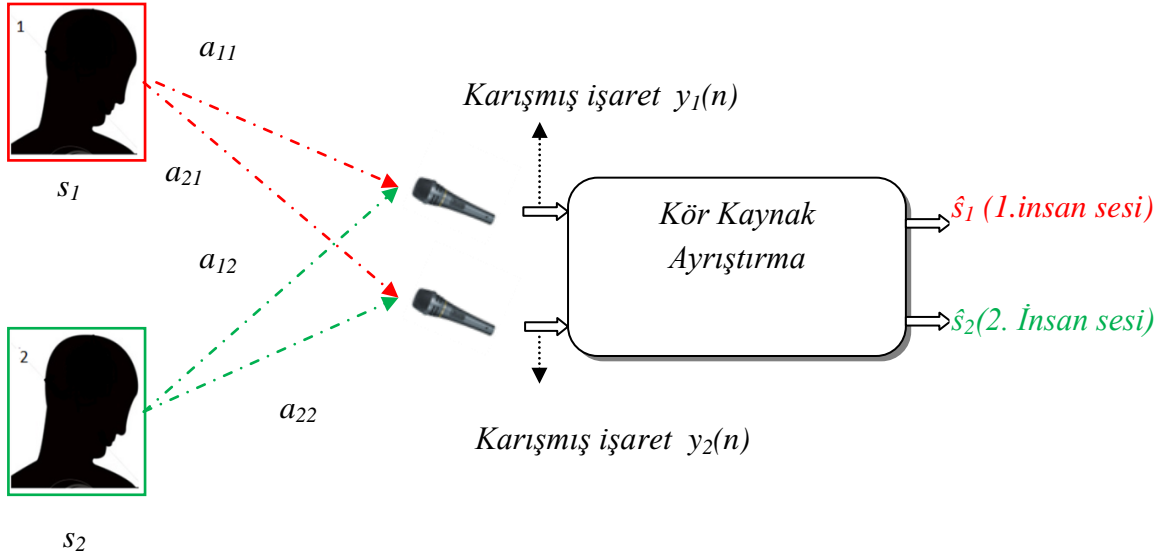
Şekil 1' de gösterilen blok diyagramda 1. kutucukta yapılan işlem de her iki ses kaynağından alınan işaretler rastgele bir karıştırma matrisi ile çarpılarak tek bir mikrofondan kaydedilmiş forma getirilmektedir. 2. kutucuktaki işlem karışmış haldeki tek kanaldan alınan ses işaretinin sürekli dalgacık dönüşümü alınarak skala-zaman eksenine taşınmasıdır. 3. kutucukta yapılan işlem işaretin skalogramına NOMA algoritması uygulamaktır. NOMA tabanlı kör kaynak ayrıştırma algoritmalarında, negatif olmayan gözlem matrisini bir veri matrisi ile bir karışım matrisi olmak üzere iki matrisin çarpımı şeklinde ayrıştırılmaktadır. Önerilen yöntemde, gözlem işareti  $Y$ , skala-zaman eksenini kullanarak temsil edilmektedir (skalogram). Skalogramı elde etmek için işaretlerin tek sensörle kaydedilmiş şekli olan  $Y$  sinyaline SDD uygulanarak karışım işareti skala uzayına taşınmaktadır. Sonraki adım ise skalogram pozitif normalize edilerek NOMA algoritması için uygun hale getirilmektedir. Teknik yazımda, NOMA algoritmaları negatif olmayan veri matrisi ile karışım matrisini özyinelemeli olarak kestirmek için kullanılmaktadır [7]. 4. kutucukta yapılan işlem ise işarete ait skalogram ayrıştırıldıktan sonra her bir kaynağın skalograma katkısını bulmak için ikili bir maskenin skalograma uygulanmasıdır. 5. kutucukta yapılan işlem ise her bir kaynak sinyali için ayrı ayrı ikili maske hesaplanması ve bulunan her maskenin karışım skalogramı ile noktasal çarpım işlemine tabi tutulmasıdır. Bu çarpım sonucunda her iki kaynak sinyaline ait skalogramlar hesaplanır ve son aşama ise ters sürekli dalgacık dönüşümü (TSDD) kullanılarak skalogramlardan işaretlerin elde edilmesidir. Böylece işaretler skala-zaman ekseninden genlik-zaman eksenine alınmış olmaktadır.

Ses işleme uygulamalarında kör kaynak ayrıştırma algoritmaları sıkça kullanılmaktadır. Örneğin bu çalışmada yapılan uygulama gibi tek kanallı olarak kaydedilen karışmış ses işaretleri birbirlerinden ayrıştırmak için [1,2,4-8] veya biyoinformatik'te farklı doku yapılarını belirlemek ve ayrıştırmak için kullanılabilir [9,10]. Kemometri de çözülmemiş bir karışım içinde kimyasal bileşenlerin spektrumları ve konsantrasyon profillerini belirlemek için kullanılmıştır [11]. Ayrıca matematik alanında ise özdeğer matrisleriyle ilgili çalışmalarda da kullanılmıştır [12].

## 1.2. Kör Kaynak Ayrıştırma

Kör kaynak ayrıştırma (KKA), birbirleriye karışmış olarak gözlemlenen sinyallerden yeniden orijinal kaynak sinyallerin elde edilmesinde kullanılan tekniklere verilen genel

addır. KKA, en iyi şekilde kokteyl-parti problemi olarak adlandırılan bir senaryo ile açıklanabilir. Bu senaryoya göre; bir partide odaya dağılmış  $n$  sayıda insan eşzamanlı olarak konuşmaktadır. Odaya yerleştirilen  $n$  tane mikrofon, bu mikrofonlara farklı uzaklıklarda bulunan insanların konuşma sinyallerini kaydetmektedir. Böylelikle her mikrofon, farklı bir sinyal karışımını kaydetmektedir. Amaç, KKA tekniklerini kullanarak alınan sinyal karışımından her bir insanın sesine ulaşmaktır. Kokteyl parti probleminde, kaynak sinyaller olarak kullanılan insan sesleri ve bu sinyallerin ne şekilde karıştığı (insanların farklı mikrofonlara olan uzaklıkları belirli olmayacağından) bilinmemektedir. Kokteyl parti problemini anlaşılmasını daha kolaylaştırmak için Şekil 2 kullanılabilir



Şekil 2. Kör kaynak ayırma ve kokteyl parti problemi

Şekil 2’de 1.mikrofondan alınan sinyal  $y_1$  ve 2. mikrofondan alınan sinyal  $y_2$  ise aşağıdaki denklem (1) ve denklem (2) yazılabilir.

$$y_1(n) = a_{11} s_1 + a_{12} s_2 \quad (1)$$

$$y_2(n) = a_{21} s_1 + a_{22} s_2 \quad (2)$$

Denklem (1) ve denklem (2) ‘ de  $a_{11}, a_{12}, a_{21}, a_{22}$  katsayıları mikrofonların kaynaklara olan uzaklığını belirtmektedir. Şekil 2’den anlaşıldığı üzere her bir mikrofondan

da iki kaynak sesinden oluşan farklı genlikteki karışımlardan oluşmaktadır. Her bir mikrofonun kaynağa olan farklı uzaklıkları bu karışım sinyallerinin şeklini yada o kaynağın karışıma etkisini belirlemektedir. Denklem (1) ve denklem (2) matris formunda yazılacak olursa denklem (3) elde edilmiş olur.

$$Y = AX \quad (3)$$

Karışım sürecinin boyutu, ayrıştırma işleminin karmaşıklığını etkilemektedir. Eğer kaynak sayısı mikrofon sayısına eşit ise karışım matrisi bir kare matris ve kaynaklar doğrusal bir dönüşüm yardımıyla bulunabilir. Eğer kaynak sayısı mikrofon sayısından az ise, karışım matrisi aşırı-tanımlı bir matris olur ve bu durumda ayrıştırma işlemi matrisin sahte tersini alma işlemi kullanılmasını içeren bir doğrusal dönüşüm yardımıyla gerçekleştirilir. Eğer kaynak sayısı mikrofon sayısından fazla ise karışım matrisi az-tanımlı olur, kaynak kestirme işlemi karmaşıklaşır ve doğrusal olmayan tekniklerin kullanılması gerekir [9].

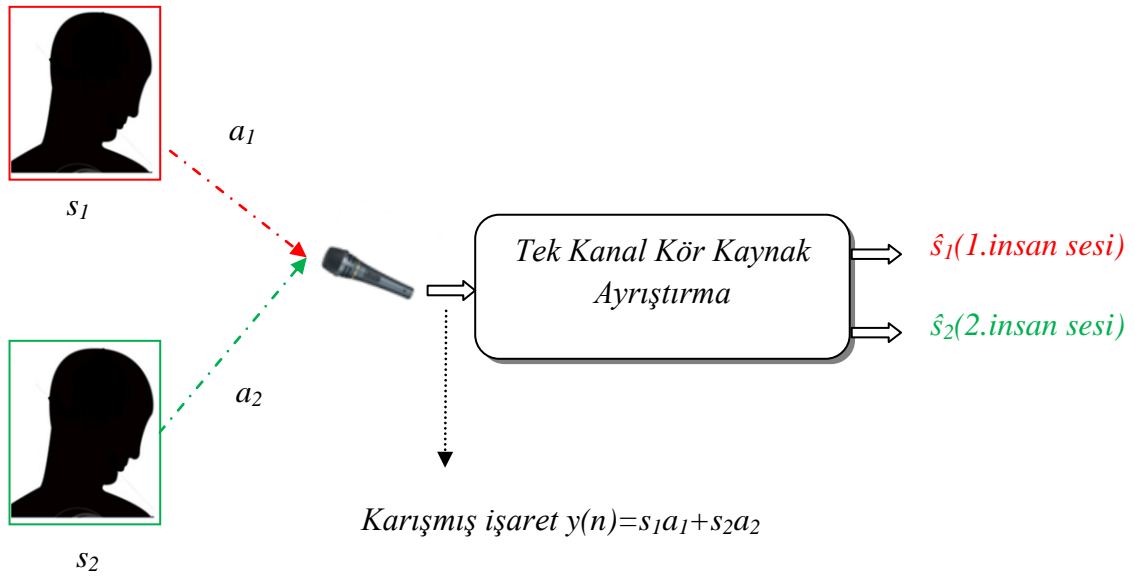
Kör kaynak ayrıştırma 20 yıldan daha fazla süredir üzerinde çalışılan bir konudur. Bu alanda yapılan ilk çalışmalar kaynak işaretlerin istatistiksel özelliklerinden yola çıkarak ayrıştırma işlemini gerçekleştirmeyi amaçlamıştır [13]. Ancak bu durum, kaynaklar hakkında bazı varsayımların yapılmasını gerektirmektedir. Bu varsayımlar [14] nolu kaynakta verilen kaynak işaretlerin istatistiksel bağımsız olması ve Gauss dağılıma sahip olmamasıdır. 1986 yılında yapılan bir çalışmada [15] Gauss olmayan bağımsız işaretlerden elde edilmiş, anlık doğrusal, tam-tanımlı karışımın ayrıştırmışlardır. Bu çalışma 1991 yılında yapılan [9] nolu kaynakta verilen çalışmaya temel olmuştur. 1994'te yapılan başka bir çalışmada kaynakların birbiriyle bağımsızlığı maksimize edilerek kaynak işaretlerin belirlenmesi işlemi başarıldı ve bu işleme Bağımsız Bileşen Analizi (ICA) ismi verildi [13]. 1995'te iki araştırmacı BS-Infomax adında, Amari ve diğerlerinin 1996'da önerdiği sade istatistiksel gradyan öğrenme kuralını kullanan [8] nolu kaynakta verilen bir kör kaynak ayrıştırma algoritması geliştirdiler. Yapılan başka bir çalışma da karşılıklı bilgi miktarı kullanılarak yapılan ayrıştırma işlemine bir alternatif yaklaşım olarak 1990 yılında maksimum olasılıklı kestirim önerildi [11]. Yansımasız ortamdaki ayrıştırma işlemi için sunulan ilk pratik algoritma 2000 yılında sunulan DUET algoritmasıdır [16]. Bu çalışmada KKA algoritmaları kullanılarak müzik sesleri birbirinden ayrıştırılmıştır fakat, KKA uygulamaları yalnızca ses işaretleri ile sınırlı değildir. KKA aynı zamanda 1999 ve 2000 de

yaptığı çalışmalarda beyin resimlerinin ayrıştırılmasında [17] ve daha birçok farklı alanda kullanılmıştır.

Son yıllarda üzerinde çalışılmaya başlanan bir diğer ayrıştırma yöntemi ise negatif olmayan matrisi çarpanlarına ayırma yöntemidir. NOMA problemine çözüm getiren ilk çalışmalar ise [18] nolu kaynakta verilen çalışmayla başlanmış olmasına rağmen, NOMA ününü daha 1999 yılında yayımlanan [19] nolu kaynakta verilen çalışma ile kazanmıştır. Söz konusu makalede NOMA için döngüsel ve çarpımsal güncelleme kuralları önerilmekle beraber NOMA'nın başarılı bir makine öğrenmesi tekniği olduğu gösterilmiş ve kokteyl parti probleminin çözümünde önemli bir rol oynamaya başlamıştır.

### 1.3. Tek Kanal Kör Kaynak Ayrıştırma

Kaynak sayısı ne kadar olursa olsun karışım sinyalleri sadece tek bir gözlemden elde ediliyorsa literatürde bu işlem tek kanallı kör kaynak ayrıştırma (TKKA) olarak tanımlanır [1]. Tek kanallı kör kaynak ayrıştırma işlemi Şekil 3'te gösterilmiştir.



Şekil 3. Tek kanal kör kaynak ayrıştırma

Tek kanal kör kaynak ayrıştırma verilen tek kanallı bir  $y(n)$  karışımından  $s_1$  ve  $s_2$  orijinal kaynak sinyallerinin tahmini olarak tanımlanabilir. Belirtilen bu problem aşağıdaki denklem (4) ile tanımlanabilir. Burada  $y(n)$  tek adet sensörden veya mikrofondan alınan

karışmış işaretleri içeren sinyal olarak tanımlanır ve matematiksel ifadesi denklem (4) gibi olur.

$$y(n) = [a_1 \ a_2] \cdot \begin{bmatrix} s_1(0) & s_2(1) & \cdots & s_1(n) \\ s_2(0) & s_2(1) & \cdots & s_2(n) \end{bmatrix} \quad (4)$$

Tek kanal kör kaynak ayrıştırma probleminin çözümü için literatürde bağımsız bileşen analizi, negatif olmayan matris ayrıştırma, kaynak modelleme gibi yaklaşımlar kullanılmıştır.

### 1.3.1. Bağımsız Bileşen Analizi

Temel ICA modelinde, her bir  $x_i$  karışımı ve her bir  $s_i$  kaynak işareti, gerçek zaman işaret veya zaman serisi yerine bir rastlantısal değişken olarak varsayılır. Yani  $N$  adet kaynak işaretinin doğrusal kombinasyonu şeklinde modellenen  $N$  adet karışım işareti aşağıdaki şekilde gösterilir.

$$x_i = a_{i1}s_1 + a_{i2}s_2 + \dots + a_{in}s_n \quad (5)$$

Burada  $a_{ij}$  katsayıları gerçel değerlerdir. Tanım gereği  $s_i$  kaynak işaretleri istatistiksel bağımsızdır. Bu model basit BBA modelidir ve karışımın nasıl meydana geldiğine dair genel bir bilgi vermektedir.  $s_i$  bağımsız bileşenler yani “gizli” değişkenlerdir, yani doğrudan gözlemlenemezler ve  $a_{ij}$  karışım katsayıları da bilinmemektedir. Tek gözlemlenen  $x_i$  karışım işaretleridir ve bu işaretlerden yola çıkılarak hem  $a_{ij}$  karışım katsayıları hem de  $s_i$  kaynak işaretleri kestirilmeye çalışılacaktır. Fakat BBA'nin uygulanabilmesi için bazı kısıtlamalar da söz konusudur. Bunlar;

- Bağımsız bileşenlerin istatistiksel olarak bağımsız oldukları varsayılır.
- Bağımsız bileşenler Gauss olmayan dağılıma sahip olmalıdır.
- İşlem karmaşıklığını azaltmak için karışım matrisinin kare matris olduğu varsayılır.

Verilen bu kısıtlamalar TKKA probleminin çözümü için sınırlamalar getirmesine rağmen yapılan çalışmaların birinde ençok olabilirlik yöntemi ve BBA ile TKKA ile ilgili çalışmalar yapılmıştır [20]. Başka bir araştırmacı zaman-frekans maskesi kullanarak tek mikrofonla kaydedilmiş sesleri kör olarak birbirinden ayırmayı başarmıştır [21]. Yine BBA, TKKA problemini çözmek için farklı araştırmacılar tarafından da kullanılmıştır[22,23].

### 1.3.2. Negatif Olmayan Matris Ayırıştırma

### 1.3.3. Kaynak Modelleme

Kaynak modelleme yöntemi de TKKA probleminin çözümü için araştırmacılar tarafında sıklıkla kullanılan bir yöntemdir. Bu yöntemlerin en başında işitsel sahne analizi yöntemi gelmektedir [24]. Bunun yanı sıra kaynak modelleme yöntemini kullanan başka araştırmacılar da olmuştur [25,26].

Bu yönteme göre;

Tek kaynaktan alınan karışmış işaret KZFD gibi yöntemlerle zaman-frekans hücrelerine bölünür ve ikinci aşama olarak sinyalin harmonikliği veya periyodik olması gibi özellikleri kullanılarak baskın olan kaynak karışımdan ayrıştırılır [27,28].

## 1.4. Karışım Modelleri

TKKA probleminin matematiksel olarak ifadesi denklem (5) ile ifade edilebilir.

$$Y(n) = A \cdot S(n) + e(n) \quad (6)$$

Burada  $S(n)$  ;

$$S(n) = \begin{bmatrix} s_1(0) & s_1(1) & \cdots & s_1(n) \\ s_2(0) & s_2(1) & \ddots & s_2(n) \\ \vdots & \vdots & \ddots & \vdots \\ s_N(0) & s_N(1) & \ddots & s_N(n) \end{bmatrix} \quad (7)$$

olmak üzere  $N$  adet kaynak işaretinin  $n$  gözlem sayısı ile kaydedilmiş şekli  $Y(n)$ ;

$$Y(n)=[y(0) \ y(1) \ \dots \ y(n)] \quad (8)$$

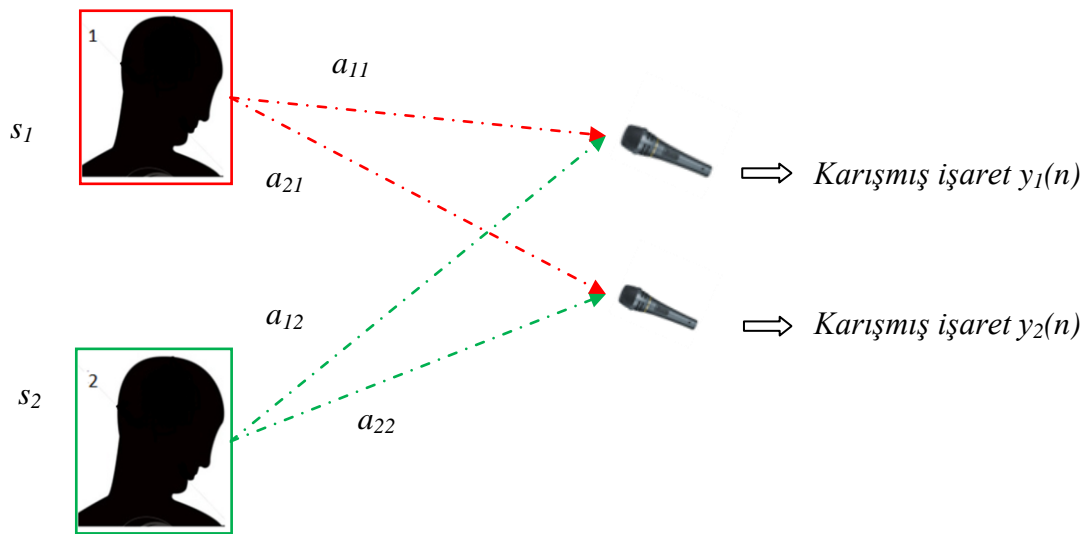
olmak üzere tek adet sensörle (mikrofonla) kaydedilen  $n$  adet gözlemin oluşturduğu karışım işaretleridir.  $A$  ise;

$$A=[a_1 \ a_2 \ \dots \ a_N] \quad (9)$$

olmak üzere doğrusal karışım matrisidir [29].  $e(n)$  gauss dağılımlı gürültüyü ifade etmek için kullanılır. Karışım matrisinin elemanları olan  $a_{ij}$  katsayıları karışım modeline bağlıdır ve modelin anlık, yansız ya da yansız olacağını belirler.

#### 1.4.1. Anlık Karışım Modeli

Anlık karışım modelinde karışım matrisi  $A$  basit olarak işaret genliklerini gösteren değerlerden oluşur. Örneğin, iki adet kaynak işaretinin tek kanallı olarak karışımını gösteren aşağıdaki şekilde gösterecek olursak 1. ve 2. insanın konuşma seslerinin hiçbir gecikmeye maruz kalmadan mikrofon tarafından algılandığı varsayımına dayanır. (Şekil 4)



Şekil 4. Anlık karışım modeli gösterimi

Şekil 4. için karışımın matematiksel denklemi aşağıdaki gibi yazılabilir (denklem 10). Burada  $s_1$  ve  $s_2$  1. ve 2. insana ait sesler,  $a_{11}$ ,  $a_{12}$ ,  $a_{21}$ ,  $a_{22}$  ses kaynaklarının mikrofonlara olan uzaklıklarını  $y_1$  ve  $y_2$  ise 1. ve 2. mikrofonlardan elde edilen karışmış işaretlerdir.

$$\begin{bmatrix} y_1(n) \\ y_2(n) \end{bmatrix} = \begin{bmatrix} a_{11} & a_{12} \\ a_{21} & a_{22} \end{bmatrix} \begin{bmatrix} s_1(n) \\ s_2(n) \end{bmatrix} \quad (10)$$

#### 1.4.2. Yansız Karışım Modeli

Yansız karışımında anlık karışımından farklı olarak, kaynak işaretlerinin sensörlere olan farklı uzaklıklarından dolayı iletim gecikmeleri ortaya çıkmaktadır. Örnek olarak  $N$  adet kaynağın tek kanallı karışımını göz önüne alacak olursak, karışım modeli aşağıdaki gibi olur [29]. Burada  $(t - \delta_{1j})$  iletim gecikmesini temsil eder.

$$y_1(t) = \sum_{j=1}^N a_{1j} s_j(t - \delta_{1j}) \quad (11)$$

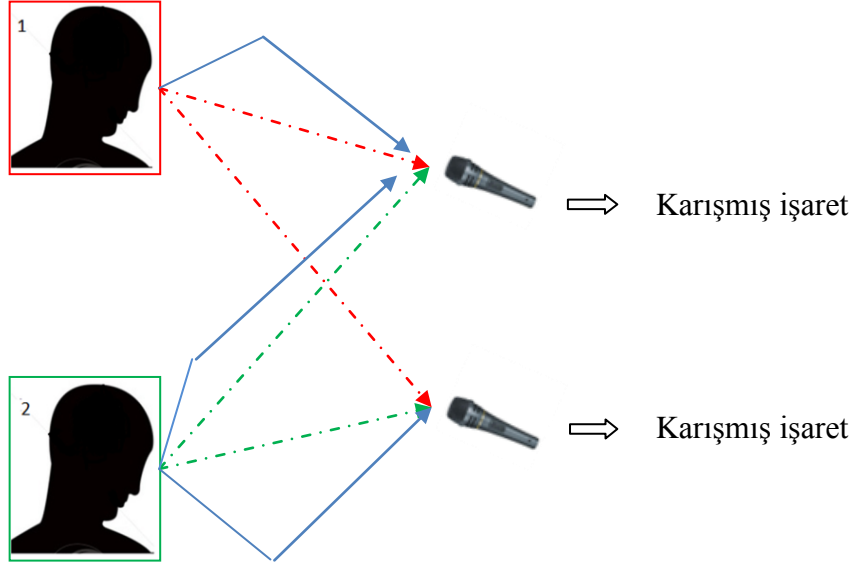
#### 1.4.3. Yansılmalı Karışım Modeli

Yansılmalı karışım modelinde ise iletim gecikmelerinin yanı sıra iletim yansımaları da göz önünde bulundurulur. Dolayısıyla bu yaklaşım daha karmaşık bir model ortaya çıkarır. Örnek olarak yine  $N$  adet kaynağın tek kanallı karışımını göz önüne alacak olursak, karışım modeli aşağıdaki gibi olur [29].

$$y_1(t) = \sum_{k=1}^L a_{11}^k s_1(t - \delta_{11}^k) + a_{12}^k s_2(t - \delta_{12}^k) \quad (12)$$

Yansılmalı karışım modeli Şekil 5' te gösterilmiştir. Şekilde mavi ve kırmızı şekilde çizilen dalgalar yansıyan dalgaları göstermektedir.  $L$  katsayısı işaretlerin sensörlere ulaştığı farklı yolların sayısıdır. İletim yansımaları ses kaynağından çıkan seslerin birtakım engellere çarparak sensörlere ulaştığı yollar olarak da tanımlanabilir.





Şekil 5. Yansımali karışım modeli

Tablo 1. Karışım modellerine özgü doğrusal operatörler ve karışım parametreleri.

Karışım Modeli	Doğrusal Operatör	Genel Model	$a_{ij}$
Anlık	Matris Çarpımı	$y(t) = As(t)$	$c_{ij}$
Yansımaz	Konvolüsyon	$y(t) = A * s(t)$	$c_{ij} \delta(t - \delta_{ij})$
Yansımali	Konvolüsyon	$y(t) = A * s(t)$	$\sum_{k=1}^L c_{ij}^k \delta(t - \delta_{ij}^k)$

Tablo-1, her üç model için kullanılan doğrusal operatör ve karışım matrisi elemanlarını göstermektedir. Burada  $\delta(t - \delta_{ij})$ ,  $j$  kaynağı ve  $i$  sensörü arasındaki gecikmeyi;  $c_{ij}$  ise  $j$  kaynağı ve  $i$  sensörü arasındaki sönmleme katsayısını göstermektedir [29].  $\delta_{ij}^k$  ve  $c_{ij}^k$   $k$ .

varış yolu için gecikme ve sönümlenme parametreleri;  $L$  ise kaynakların sensörlere ulaştığı yolların sayısıdır.

### 1.5. Ses ve Müzik Enstrümanlarının Sesleri

Kendine özel bazı frekans ve genlik değerlerine sahip ses dalgalarının bir araya gelmesi ile müzik sesleri meydana gelmektedir. Seslerin şiddeti, yüksekliği ve tınısı gibi kendine özel karakteristik değerleri bulunabilir. Sesin şiddeti sesin ne kadar uzaktan duyulabileceğinin bir ölçütü olarak tanımlanırken sesin yüksekliği ise ince sesi kalın sestene ayıran bir özelliktir. Başka bir anlatımla ince sesler kalın seslere göre daha yüksek frekans bileşeni içerirler. Sesin tınısı ise her ses kaynağının kendine özel çıkardığı ses olarak bilinir. Bu kendine özel bazı frekans ve genlik değerlerine nota adı verilir. Dünyanın başka bölgelerinde, o bölgede yaşayan toplumlarca geliştirilmiş başka nota sistemleri de mevcut olmasına rağmen dünya müziğinde kullanılan notalar Şekil 6' da verilmiştir [30].




Şekil 6. Dünya genelinde kullanılan notalar


### 1.6. Müzikal Enstrümanların Ürettikleri Frekans Bileşenleri

Her bir notanın frekans özellikleri incelendiğinde, oluşan harmoniklerinden dolayı bütün çalgı aletleri aynı notaya akord edilse bile farklı sesleri çıkarmaktadır. O halde notaların her birini saf frekans değerleri olarak kabul etmek hatalı olacaktır [30]. Örneğin La notasına akort edilmiş bir Keman ve bir Gitar ele alındığında, bu iki çalgı aletinin de aynı notaları çıkarttıkları varsayılınsın. İnsan kulağı çalınan bu iki çalgı aletinin de aynı notaları çaldığını fakat müziğin farklı iki çalgı aleti tarafından yapıldığını anlayacaktır. Bunun sebebi bu çalgı aletlerinin aynı notaya akort edilmesine rağmen kendilerine has genlikleri olması ve seslendirdikleri notanın genliğinden düşük olan yan sesleri de

oluşturmalarıdır. Aşağıda şekillerde viyola ve trampet sesleri zaman-genlik ekseninde gösterilmiştir. İşaretlerin genlik değerleri belirli bir sınıra normalize edildiğinden pozitif tepe değerlerinin yaklaşık olarak eşit olduğu görülmektedir. Şekil 7 ve Şekil 8'e bakıldığında her iki enstrümana ait işaretin kendine özgü zaman ve genlik bileşenleri olduğunu görmekteyiz. Örneğin viyola işaretinin genlik seviyelerinin üst bölgelerinde frekansının azaldığı söylenebilir.



Şekil 7. Viyolaya ait işaretin zamanla değişimi



Şekil 8. Trampete ait işaretin zamanla değişimi

Bu çalışmada kullanılan viyola ve trampet sesi işlem yoğunluğunu azaltmak adına örnek sayıları 150000 ile sınırlandırılmıştır. 150000 adet örnekten oluşan bu kaynak sesleri yaklaşık 4 sn uzunluktadır.


## 2. DALGACIK DÖNÜŞÜMÜ VE SKALOGRAM

### 2.1. Dalgacık Dönüşümünün Tarihsel Gelişimi

Sayısal işaret işlemenin tarihsel gelişimine bakıldığında dalgacık dönüşümünün son yıllarda kullanıma başlanmasıyla beraber tarihteki başlangıcı Joseph Fourier' e yani 19.yy'a kadar uzanmaktadır [31]. J. Fourier herhangi bir periyodik fonksiyonun, sonsuz sayıda periyodik-karmaşık-üstel fonksiyonun toplamı şeklinde oluşturulabileceğini göstermiştir. J.Fourier' in sinyaller üzerindeki bu düşüncesi ilk yıllarda sadece periyodik sinyaller için uygulanabilse de ilerleyen yıllarda periyodik olmayan ayrık zamanlı sinyaller içinde uygulanabilir duruma gelmiştir.

### 2.2. Durağan ve Durağan Olmayan İşaretler

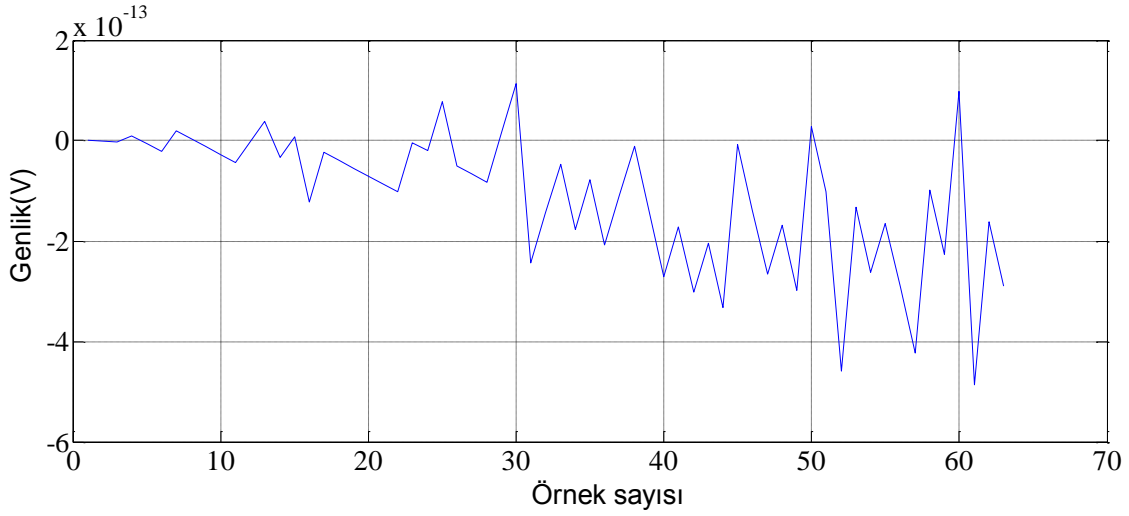
Elektriksel bir işaret, fiziksel dünyadan elde edilen büyüklüklerin zamanın bir fonksiyonu olarak tanımlanmasıdır. Eğer bir işaretin genliği zamanla değişmesine rağmen işaretin istatistiksel karakteristikleri (frekans, güç, ortalama değer) değişmiyorsa işaret durağan olarak tanımlanır aksi takdirde durağan değildir. Şekil 9 'da durağan bir işaret örneği verilmiştir. Bazı kaynaklarda bu sinyaller periyodik ve periyodik olmayan sinyaller olarak ta görülebilir.



Şekil 9. Durağan işaret

Durağan bir sinyalde de beklenmeyen değerler görülebilir, fakat bu değerlerin olma olasılığı istatistik olarak tahmin edilebilir bilgilerdir.

Durağan işaretler için istatistikî bilgiler zamanın bütün noktaları için aynıdır. Bu durumu formülle ifade edecek durağan sinyaller için  $x(t)$  ve  $x(t-t_0)$  işaretlerinin istatistikî bilgileri aynı olmakla beraber durağan olmayan sinyaller için bu bilgiler farklılık göstermektedir [31]. Şekil 10'da durağan olmayan sinyale örnek verilmiştir.




Şekil 10. Durağan olmayan işaret

Durağan olmayan işaretler ise zamanın hangi noktasında işaretin hangi genlik değerini alacağını kestirmek zordur. Şekil 10'a bakıldığında sinyalin başlangıcındaki genlik ve frekans değerleri ile bitişindeki genlik ve frekans değerleri oldukça farklı olduğu görülmektedir.


### 2.3. Kısa Zamanlı Fourier Dönüşümü

Fourier dönüşümü (FD), durağan işaretler için geliştirilmiş bir yöntemdir. FD herhangi bir işarette yalnızca belirli bir frekans bileşeninin varlığını göstermek için kullanılabilir. Aşağıdaki şekilde fourier dönüşümü örnekleri verilmiştir. Şekil 11'e bakıldığında frekansı 1000 Hz olan bir sinüs işaret ve bu işaretin fourier dönüşümü verilmiştir. Şekilden anlaşıldığı üzere FD durağan bir işaretteki frekans bileşeninden başka bize herhangi bir bilgi vermemektedir. Şekil 12'de ise durağan olmayan bir gürültü işareti

ve bu işaretin FD gösterilmiştir. İşaretin FD'ne bakıldığında farklı frekans bileşenlerine sahip olduğunu görmekteyiz.

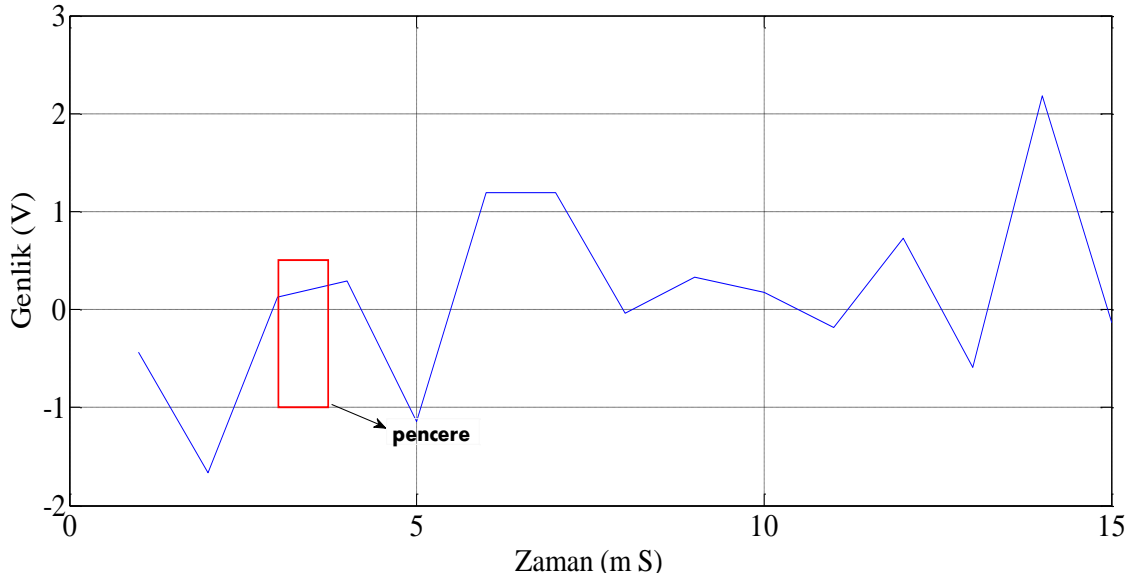


Şekil 11. Sinüs işaret(a) ve fourier dönüşümü(b)



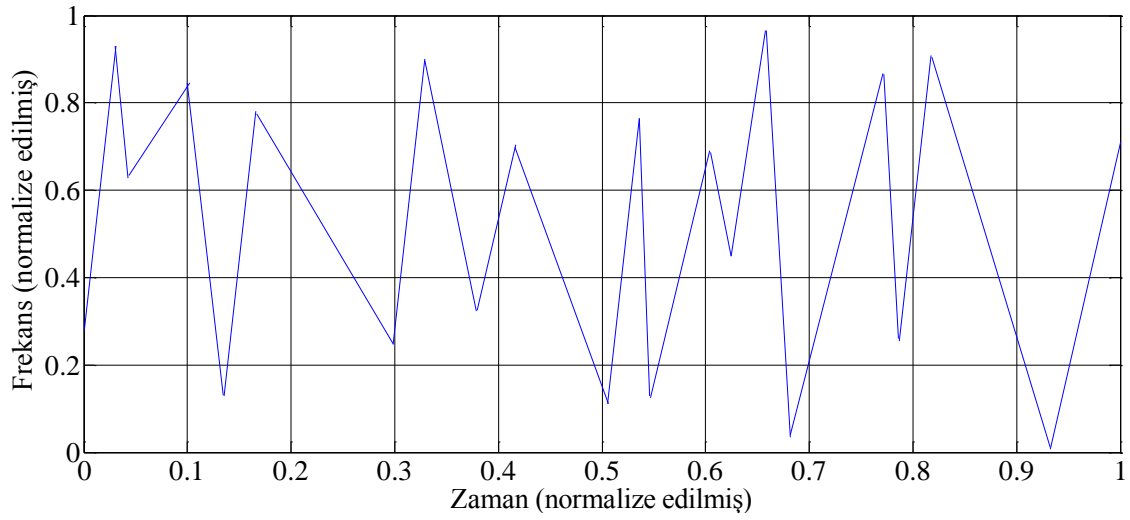
Şekil 12. Bir gürültü işareti(a) ve bu işaretin fourier dönüşümü(b)

KZFD'de ise durağan olmayan işaret, zamanda durağan kabul edilebilecek küçük parçalara bölünür. Diğer bir deyişle FD'den farklı olarak, işarete dar pencerelerden bakılır ve pencere içinde kalan işaretin durağan olduğu varsayılır [32]. Bu pencereleme işlemi Şekil 13'te gösterilmiştir.



Şekil 13. Kısa zamanlı fourier dönüşümü ve işaretin pencerelemesi

Şekil 14 ise FD'de kullanılan sabit pencere genişliklerini göstermektedir. Burada önemli olan işaretin bütün zaman ve genlik noktalarında pencere boyutunun sabit olmasıdır.

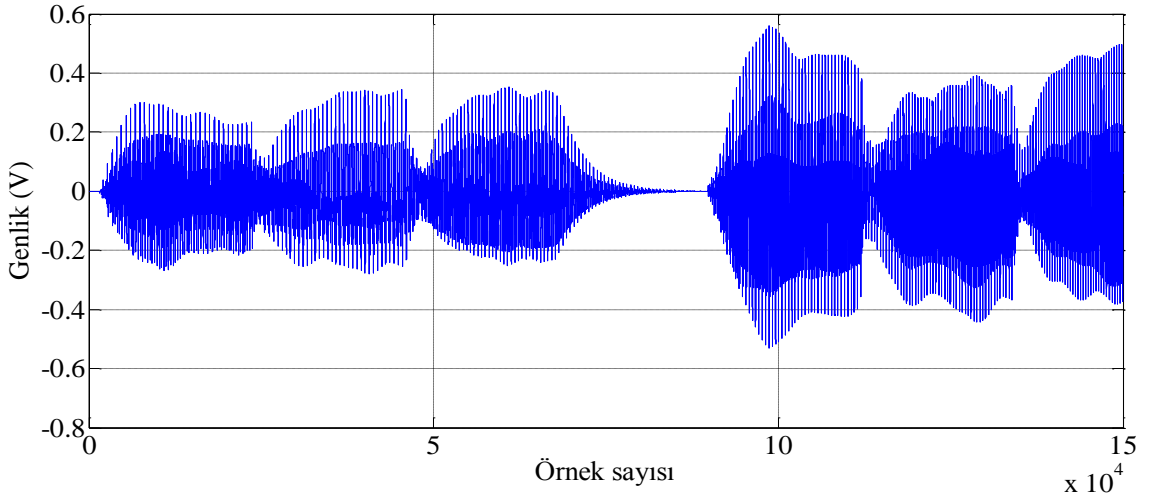


Şekil 14. Kısa zamanlı fourier dönüşümü ve eşit ölçekli pencereler

Aşağıda eşitlikte KZFD'nin ifadesi görülmektedir [33].

$$KZFD(\tau, f) = \int_{-\infty}^{\infty} [x(t) \cdot w^*(t - \tau)] e^{-2\pi f t} \cdot dt \quad (13)$$


formülde  $x(t)$ , KZFD 'si alınacak işaret,  $w(t)$  pencere fonksiyonunu ve \* karmaşık eşleniği göstermektedir.  $f$  frekans;  $\tau$  ise zamanda öteleme miktarıdır. Her  $\tau$  ve  $f$  için yeni bir KZFD katsayısı hesaplanır. FD sadece frekansın bir fonksiyonu iken, KZFD hem frekansın hem de zamanın bir fonksiyonudur ve dönüşüm bu haliyle iki boyutludur [33]. İşaretin zaman-frekans temsili elde edilmesine rağmen, seçilen pencerenin genişliği dönüşümün etkinliğinde önemli rol oynamaktadır. KZFD'de pencere genişliği ile ilişkili bir çözünürlük problemi bulunmaktadır. FD'de frekans domeninde çözünürlük problemiyle karşılaşılmaz. Çünkü hangi frekansların var olduğu kesin olarak bilinir. KZFD'de seçilen pencerenin sonlu uzunlukta olması nedeniyle işaretin bir parçası ele alınır ve frekansta çözünürlük kötüleşir [33]. Frekans çözünürlüğünün artırılması uğruna pencerenin geniş tutulması ise belirli bir frekans bandının hangi zaman aralığında ortaya çıktığını belirsiz kılar [31]. Pencere genişledikçe frekans çözünürlüğü artar; ancak zamanda çözünürlük azalır. Sonuçta işarete KZFD uygulanacaksa zamanda veya frekansta çözünürlük kavramlarından birinde işaret iyi ifade edilirken diğerinde zayıf kalacaktır [31]. Aşağıdaki Şekil 15'te viyolaya ait ses işareti ve bu işaretin KZFD ile genlik spektogramı gösterilmektedir.(Şekil 16)



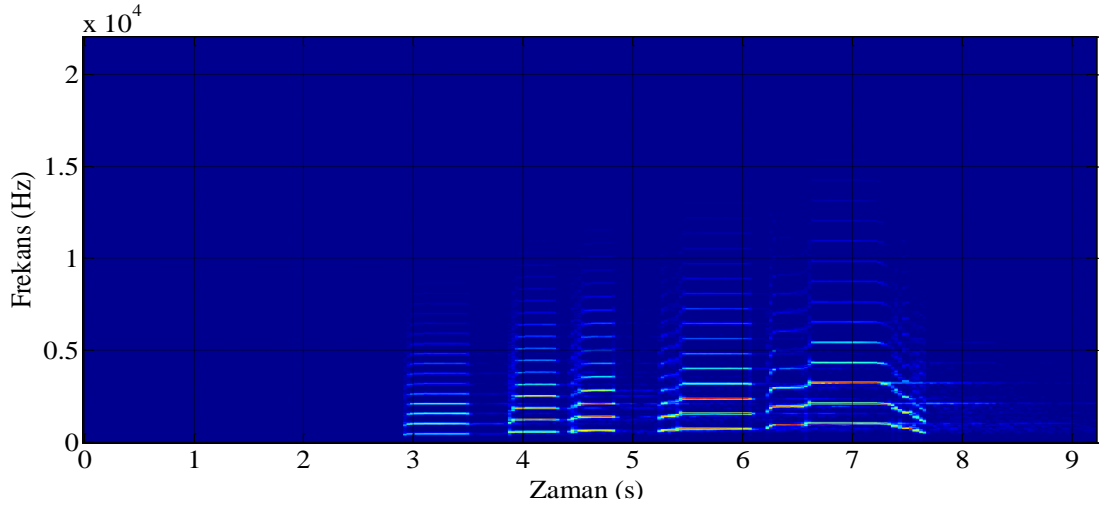
Şekil 15. Viyola enstrümanına ait işaret



Şekil 16 viyola işareti için pencere boyu 128 seçilerek hesaplanmış KZFD'yi, Şekil 17 ise pencere boyu 2048 seçilerek alınmış KZFD'yi göstermektedir.

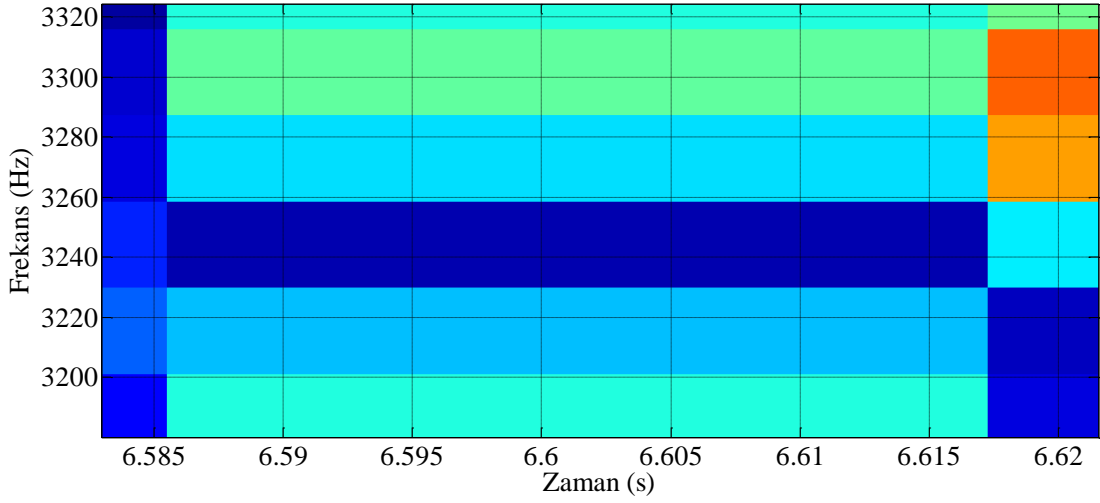


Şekil 16. Viyola işaretine ait spektrogram (pencere boyutu 128)




Şekil 17. Viyola işaretine ait spektrogram (pencere boyutu 2048)

Aşağıdaki Şekil 18 ise pencere boyu 128 seçilerek alınmış KZFD'den bir kesittir. Şekil 18'e dikkatli bakıldığında frekans çözünürlüğünün yaklaşık 16 Hz, zaman çözünürlüğünün ise yaklaşık 30 ms olduğunu görmekteyiz.



Şekil 18. Şekil 17'den bir kesit

Şekil 19'a bakıldığında ise frekans çözünürlüğünün yaklaşık 60 Hz, zaman çözünürlüğünün ise yaklaşık 30 ms olduğunu görmekteyiz. Bu örnekte pencere boyutlarının 128 ve 2048 gibi farklı seçilmesindeki amaç frekans ve zaman çözünürlüğündeki farkın anlaşılması içindir.



Şekil 19. Şekil 18 'den bir kesit

KZFD, tüm zamanlarda sabit çözünürlük verdiği için KZFD'nin çözünürlük ile ilgili problemlerini gidermek üzere zamanda değişken çözünürlük veren sürekli dalgacık

dönüşümü (SDD) geliştirilmiştir [30]. SDD'ne frekans cevabı zamanla değişen durağan olmayan işaretlerin analizinde ihtiyaç duyulmaktadır.

#### 2.4. Dalgacık Dönüşümü

Dalgacık dönüşümü KZFD'nün zamanda veya frekansta çözünürlük problemini ortadan kaldırmak için KZFD 'ne alternatif bir yöntem olarak ortaya çıkmıştır. İlk bölümlerde de bahsedildiği üzere özellikle durağan olmayan işaretler için KZFD 'de sabit pencere genişliği kullanılması bu tür işaretlerin ifade edilmesinde etkisiz kalmaktadır. Dalgacık dönüşümünün en önemli özelliklerinden birisi değişken pencere boyutu sunmasıyla durağan olmayan işaretler için bölgesel çözümler sunmasıdır [33]. Dalgacık dönüşümü KZFD'nin yakalayamadığı eğilimleri, bozulma noktalarını, yüksek dereceli türevlerde süreksizlikleri ve benzerlikleri çıkarmada daha başarılı sonuçlar sunmaktadır. Dalgacık dönüşümü sürekli dalgacık dönüşümü ve ayrık dalgacık dönüşümü olarak temel de ikiye ayrılmakla beraber biz sadece sürekli dalgacık dönüşümü üzerinde duracağız.

Dalgacık analizi KZFD'ye benzer şekilde yapılır; işaret, KZFD'de bir pencere fonksiyonu ile çarpılırken, SDD'de dalgacık olarak adlandırılan bir fonksiyonla çarpılır ve dönüşüm zaman domeni işaretin farklı segmentleri için ayrı ayrı hesaplanır. Ancak KZFD ve SDD arasında iki belirgin fark vardır; SDD'de

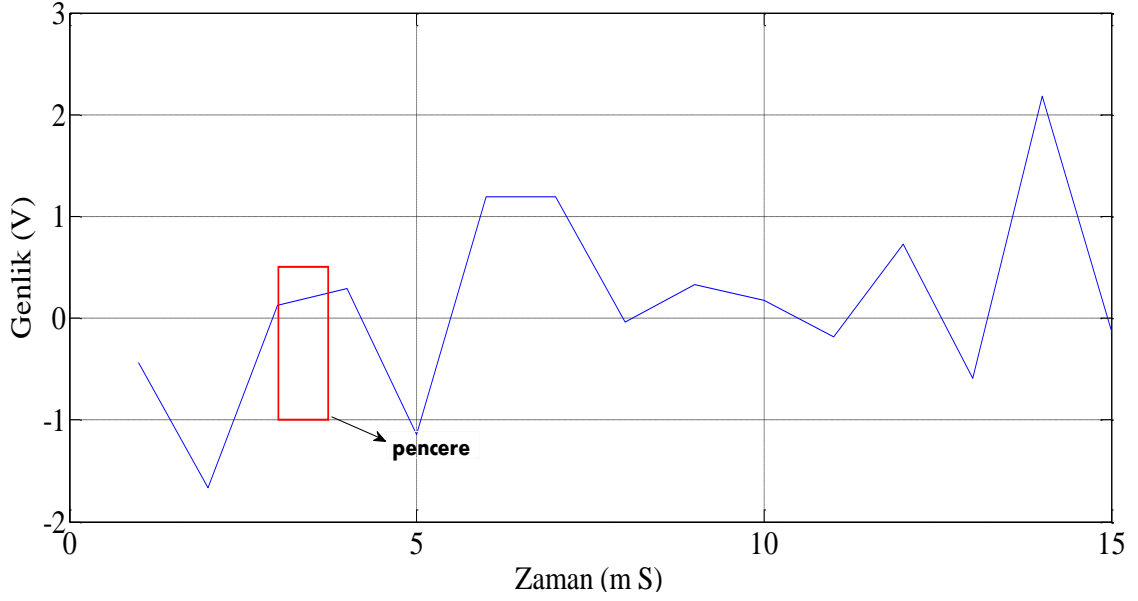
- a) Pencereleyen işaretin FD'si alınmaz sadece bir pencere fonksiyonu ile çarpılır
- b) Her bir spektral bileşen için dönüşüm hesaplanırken pencerenin genişliği değiştirilir (Şekil 21).

Son şık, SDD'nin en önemli özelliğidir. SDD Şekil 20 ile ifade edilebilir [30]. Dalgacık dönüşümü matematiksel olarak denklem (14) ile verilmiştir.

$$SDD_x^\Psi(\tau - s) = \frac{1}{\sqrt{|s|}} \int_{-\infty}^{\infty} x(t) \psi^+ \left( \frac{t - \tau}{s} \right) dt \quad (14)$$

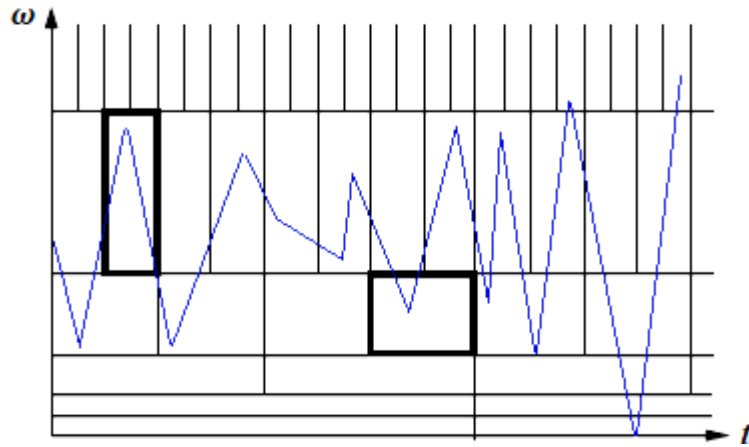
Şekil 20'de durağan olmayan bir işaret örneği ve bu işaretin SDD ile nasıl pencerelendiğini

göstermektedir. Şekil 21 SDD ile değişken pencere boyutlarını göstermektedir. Pencerelemlerin değişken boyutta olması durağan olmayan işaretteki ani değişimleri yakalayabilmesi açısından çok önemlidir.




Şekil 20. SDD ile işaretin pencerelemesi

Şekil 21'e bakıldığında y ekseninde ölçek veya skala x ekseninde ise zaman parametresi bulunur. Hem zaman hem de ölçek ekseninde değişken pencereler olması SDD için önemli bir özelliktir. Şekilde  $t$  zaman  $w$  ölçek eksenini göstermektedir.



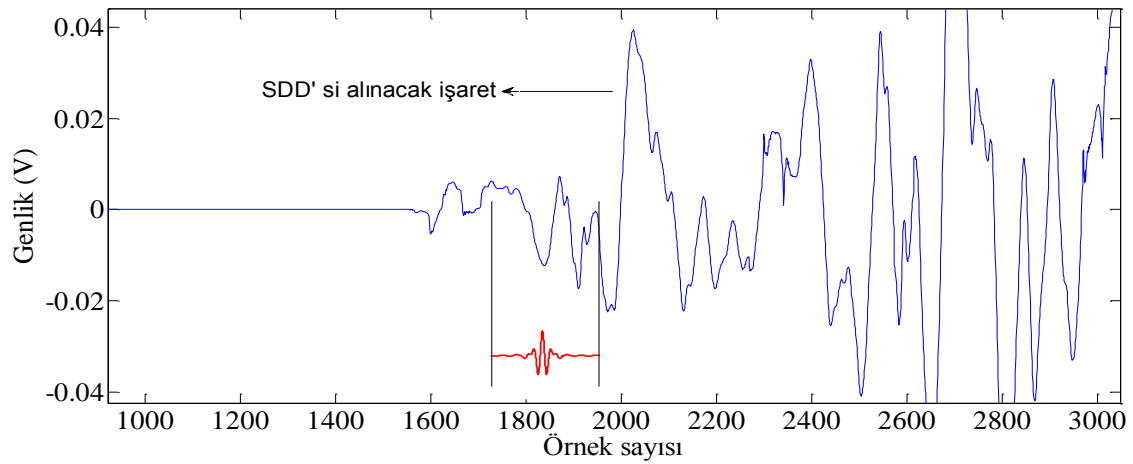
Şekil 21. SDD ile değişken pencere boyutları

Herhangi bir işaretin dalgacık dönüşümü alınırken yapılan işlemler aşağıdaki şekille gösterilebilir. Şekli biraz daha açıklayacak olursak; öncelikle kullanılacak dalgacık seçimi yapılır ve sinyalin ilk bölümü ile karşılaştırılır. (Şekil 22)



Şekil 22. SDD'nin gösterimi

Karşılaştırma sonucunda bir regresyon analizi yapılır ve bir C katsayısı elde edilir. Hesaplanan bu C katsayısı sinyalimizin o bölümünün kullanılan dalgacığa ne kadar benzediğinin de ölçüsüdür [34]. Daha sonra ana dalgacık sağa doğru kaydırılır ve bu işlem tüm sinyali kapsayana kadar devam eder (Şekil 23).

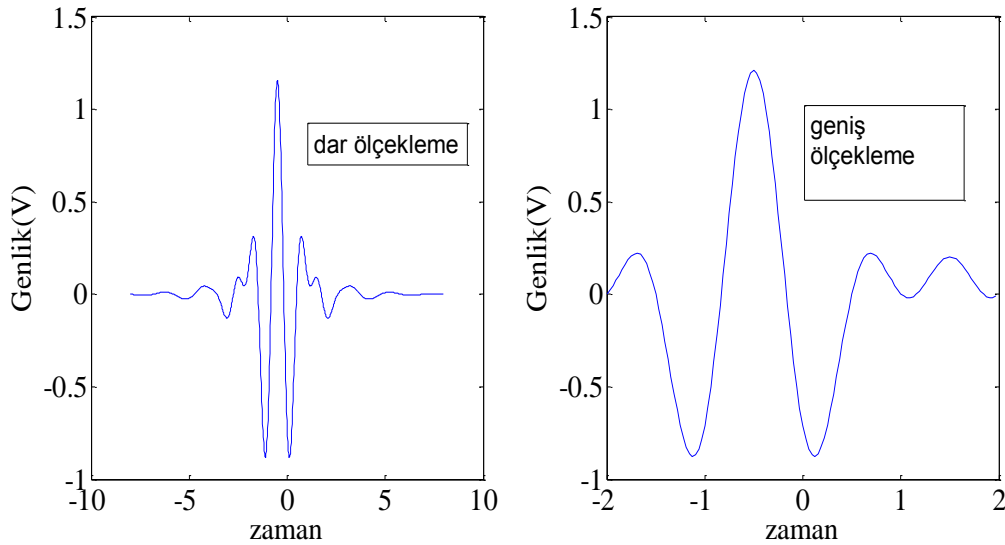


Şekil 23. SDD'de dalgacığın kaydırılması

Yukarıdaki adımları tamamladığımızda sinyalin farklı bölgelerinde farklı ölçeklerde elde edilmiş katsayıları elde etmiş oluruz. Bu katsayılar sinyalimizin dalgacıklar üzerine uygulanmış regresyon sonuçlarıdır [34]. Elde edilen bu katsayılar bize skalogram adı verilen görsel bilgileri oluşturmaktadır [35].

$$SKAL(a) = SDD|a|^2 \quad (15)$$

Görüldüğü gibi SDD,  $\tau$  ve  $s$  değişkenlerinin (öteleme ve ölçek parametreleri) bir fonksiyonudur.  $\psi(t)$  dönüşüm (pencere) fonksiyonudur ve ana dalgacık olarak adlandırılır [30]. Dönüşümde kullanılan farklı genişliğe sahip diğer pencere fonksiyonları ana dalgacıktan ölçekleme yoluyla türetilir. Öteleme terimi, KZFD’de rastlanılan şekliyle pencerenin zaman eksenindeki yerini ifade etmektedir. Pencere, işaret üzerinde gezdirilir. Dönüşümden zaman bilgisi öteleme ile sağlanır. KZFD’deki gibi bir frekans parametresi yoktur; bunun yerini  $1/frekans$  olarak tanımlanan ölçek parametresi ( $s$ ) almıştır [34]. Ölçek değeri büyük ise (düşük frekanslar) işaret hakkında bütünsel bir bilgi elde edilir. Ölçek değeri küçük ise özellikle yüksek frekanslı işaretteki detaylar veya zamana göre hızlı değişimler yakalanır. Ölçek parametresinin değeri değiştirilerek, ana dalgacığın sıkıştırılması ya da genişletilmesiyle SDD’de kullanılan pencereler elde edilir.



Şekil 24. SDD için geniş ve dar ölçekler

Morlet, Gaussian Türevi ve Paul dalgacıkları pencere fonksiyonu olarak kullanılan fonksiyonlara örnektir. Herhangi bir işaretin dalgacık dönüşümü alınırken ana dalgacık bir kez belirlenir ve seçilen  $s$  değeri için dalgacık, analiz edilen  $x(t)$  işaretinin  $t=0$ 'a karşılık gelen başlangıç noktasına yerleştirilir. İşaret ile dalgacık çarpılır ve tüm zaman üzerinden integrali alınır. İntegrasyon sonucu  $\frac{1}{\sqrt{s}}$  sabit sayısı ile çarpılarak enerji normalizasyonu sağlanmış olur. Daha sonra, dalgacık zamanda  $\tau$  kadar sağa ötelenir ve aynı işlem tekrarlanır. Bu şekilde işaretin sonuna ulaşıldığında zaman-ölçek düzlemi üzerinde bir satırda ( $s$ 'in bir tek değerine karşılık) bulunan tüm noktalar hesaplanmış olur. Arzu edilen tüm  $s$  değerleri için işlemler tekrarlandığında işaretin SDD'si hesaplanmış olur ve işaretin zaman-ölçek değerlerinden oluşan iki boyutlu bir gösterilimi analizler için hazırdır. Pencerenin zamanda kaydırılması işaretin zamanda sınırlandırılmış olmasını, ölçek değerinin değiştirilmesi ise işaretin frekansta sınırlandırılmış olmasını sağlar.

#### 2.4.1. Ana Dalgacıkların Özellikleri

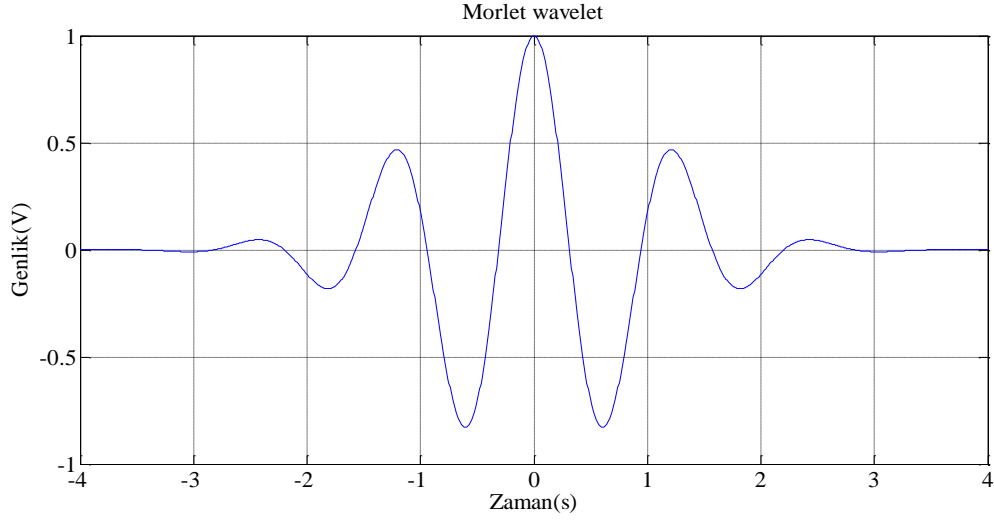
Dalgacıklar, dalgacık dönüşümü için temel görevi üstlenen fonksiyonlardır. Bir işaretin dalgacık dönüşümü alınırken hangi dalgacığın kullanılacağı tamamen bize düşmektedir. Bu durumda önemli olan nokta, hangi dalgacığın işaretimizi daha iyi tanımlamasıdır. Yapılan bu çalışmada Morlet dalgacığı, Gauss türevi dalgacığı (DOG) ve Paul dalgacığı kullanılmıştır. Bu fonksiyonları aşağıda verilmiştir [34].

##### 2.4.1.1. Morlet Dalgacığı

Şekil 25 Morlet dalgacığını ve denklem (16) ise Morlet dalgacığı fonksiyonunu göstermektedir [34]. Morlet dalgacığı kullanılarak kaynak işaretlerin skalogram örnekleri alınarak aşağıdaki şekillerde gösterilmiştir. Skalogramlar hesaplanırken ölçek sayısı 60 olarak belirlenmiştir. Skala boyutunun seçimi tamamen kullanıcıya bağlı bir değerdir. Fakat ölçek sayısının çok küçük seçilmesi durumunda işaretin dalgacık dönüşümü alındığında eksik ifade edilmesine neden olabilir. Ölçek sayısının gereğinden fazla miktarda büyük seçilmesi ise SDD hesaplanırken gereksiz yere işlem ve hesaplama maliyeti artıracaktır. Aynı şekilde SDD'nin hesaplanmasında ölçek faktöründe önemli


ölçüde rol oynamaktadır. Küçük seçilen ölçek değeri işlem maliyetini artırmakla birlikte gereğinden fazla büyük seçilen ölçek parametresi işaretimizi yeterince temsil etmeyebilir.

$$\psi_{morlet}(x) = e^{-x^2/2} \quad (16)$$



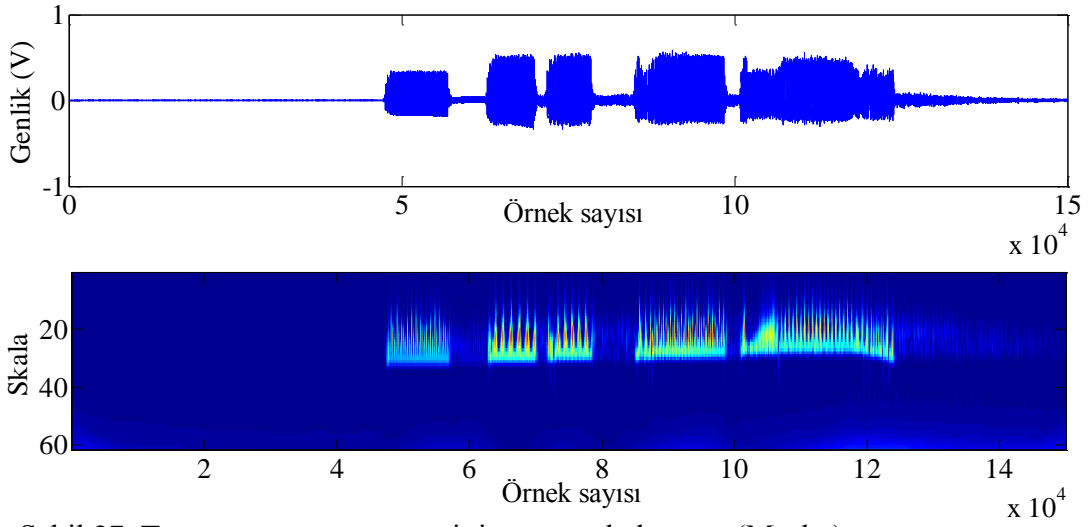
Şekil 25. Morlet dalgacı

Şekil 26 ve şekil 27’de viyola ve trampete ait skalogram örnekleri görülmektedir.



Şekil 26. Viyola enstrümanına ait işaret ve skalogramı (Morlet)






Şekil 27. Trampet enstrümanına ait işaret ve skalogramı(Morlet)

#### 2.4.1.2. DOG (Derivative of Gaussian) Dalgacığı

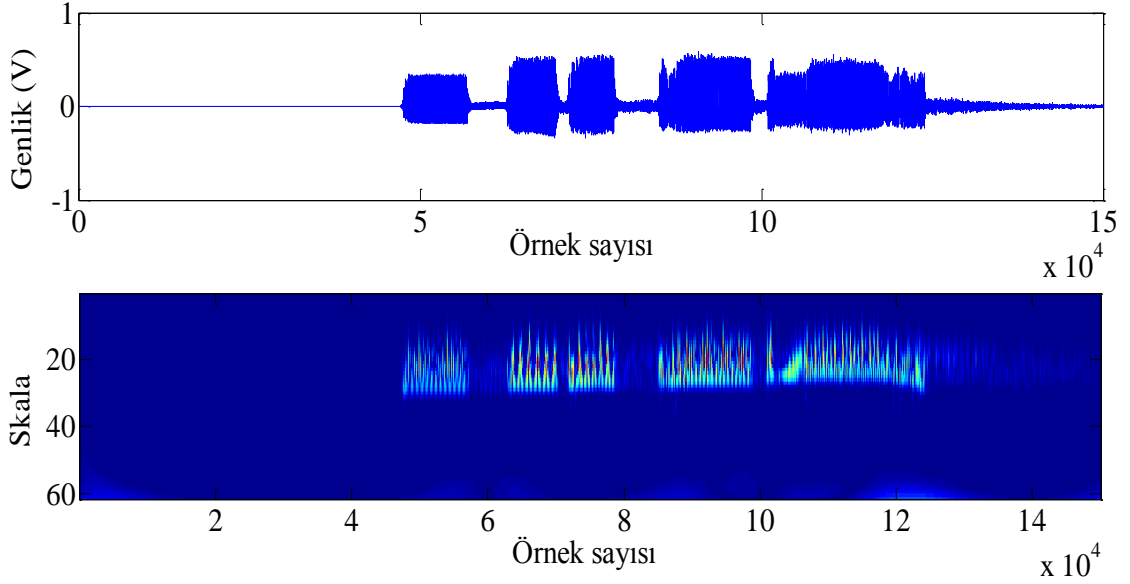
DOG dalgacığı fonksiyonu denklem (17)'da verilmiştir [34]. Şekil 28 ise DOG dalgacığının sinyal şeklini göstermektedir.

$$\psi_{DOG}(x) = C_p e^{-x^2} \quad (17)$$



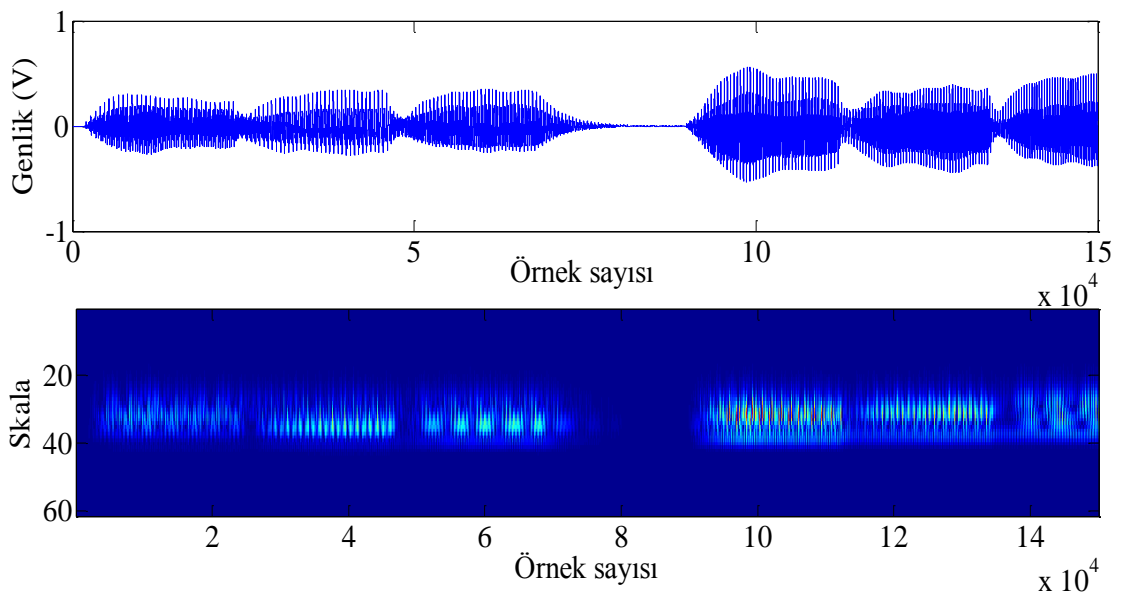
Şekil 28. DOG dalgacığı

DOG dalgacığı kullanılarak viyola ve trampet seslerinin örnek skalogramları aşağıdaki şekillerde verilmiştir. Bir önceki örnekte olduğu gibi ölçek boyutu 60 seçilmiştir.



Şekil 29. Trampet enstrümanına ait işaret ve skalogramı (DOG)

Aynı işaretin farklı skalogramlarına bakıldığında kullanılan dalgacık fonksiyonlarından dolayı küçükte olsa farklılıklar görülmektedir. Bu farklılıklar kör kaynak ayrıştırma işleminde ortaya farklı performansların çıkmasına neden olacaktır.




Şekil 30. Viyola enstrümanına ait işaret ve skalogramı (DOG)

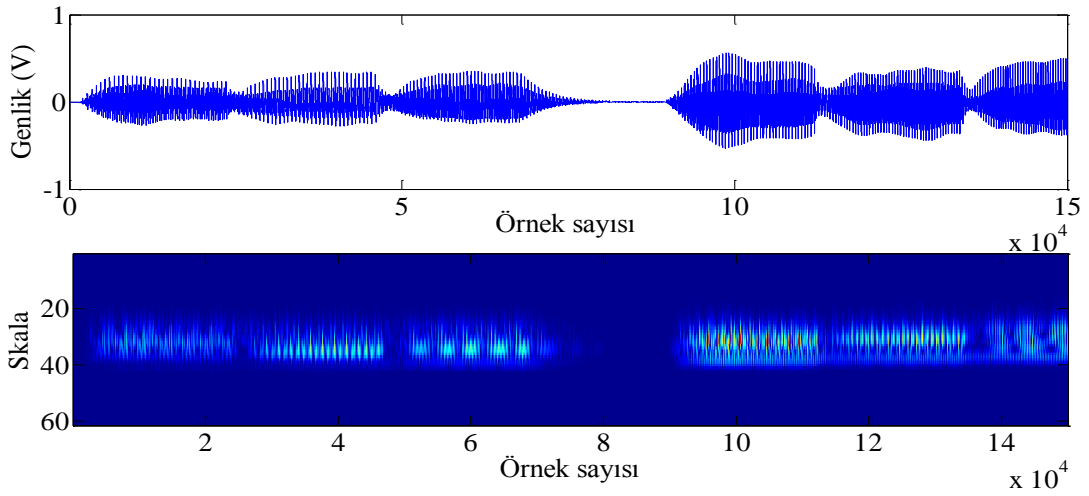
### 2.4.1.3. Paul Dalgacı

Şekilde Paul dalgacı fonksiyonu denklem (18)'de Paul dalgacı şekli ise Şekil 31 'de verilmiştir [36]. Şekil 31' de dalgacığın sanal kısmı kırmızı renkle gerçel kısmı ise mavi renkle çizilmiştir.

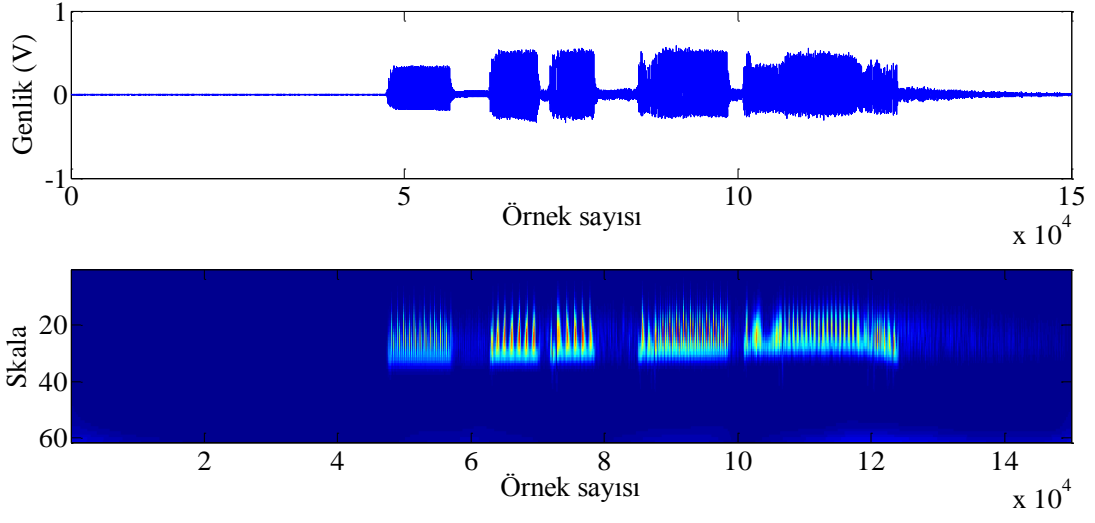
$$\psi_{paul}(x) = \frac{2^n n! (1-ix)^{-(n+1)}}{2\pi \sqrt{\frac{(2n)!}{2}}} \quad (18)$$



Şekil 31. Paul dalgacı



Şekil 32. Trumpet enstrümanına ait işaret ve skalogramı (Paul)



Şekil 33. Viyola enstrümanına ait işaret ve skalogramı (Paul)

### 3. NEGATİF OLMAYAN MATRİS AYRIŞTIRMA

Sensör teknolojisi ve bilgisayar sistemlerindeki son teknolojik gelişmeler beraberinde veri boyutlarının artmasına da neden olmuştur. Artan veri boyutları, bu verileri işlemek için gerekli sistemlere oldukça fazla yük getirmiş olup bunun sonucunda artan işlem maliyetleri ortaya çıkmıştır. Veri analiz yöntemlerinde temel amaçlardan biri çok boyutlu verilerdeki fazlalık bilgileri azaltarak, veri içinde bulunan önemli bileşenleri açığa çıkarmaktır. Bağımsız bileşen analizi [13] (BBA) ve temel bileşen analizi (TBA) [37-39] başta olmak üzere, birçok ayrışım yöntemi işlenen veriden gereksiz verileri ayıklayarak önemli bilgi bileşenlerini açığa çıkarmayı amaçlar. Bu yöntemlere ek olarak, döngülü çarpımsal bir şekilde matris çarpanlarına ayırma işlemi gerçekleştirilerek, verinin özneliklerini çıkarmayı amaçlayan negatif olmayan matris ayrıştırma (NOMA) çok boyutlu veriler üzerinde kullanılmak üzere önerilen yeni tekniklerden birisidir. NOMA ilk olarak [18] nolu kaynakta verilen çalışma bize sunulmakla birlikte gerçek ününü [19] nolu kaynaktaki çalışma ile kazanmıştır.

Negatif olmayan matris ayrıştırma, içinde negatif elemanı olmayan bir veri kümesinden fiziksel anlama sahip gizli bileşenleri tahmin etmek için kullanılan çok değişkenli bir veri analiz tekniğidir [40]. Bu teknik, lineer cebir ve sayısal sinyal işleme alanlarında son yıllarda giderek önemini artırmıştır. Negatif olmayan matrisi çarpanlarına ayırma orijinal veri matrisini, iki tane çarpan matrisine belirli bir yaklaşıklık ile ayırarak verinin boyutunu azaltmakla beraber yararlı gösterimler oluşturur. NOMA sonucunda elde edilen çarpan matrislerin orijinal veri içerisindeki gizli ve önemli bileşenleri barındırmaları beklenir [41]. Diğer birçok yöntemin aksine, NOMA'da ayrıştırılacak olan matris içinde negatif eleman olmama koşulu vardır ve bu koşul neden olduğu toplanabilirlik ilkesi sebebiyle sezgisel ve parça tabanlı gösterimlerin oluşturulmasına olanak sağlar [41].

Boyut küçültme ve sezgisel gösterimler oluşturma özellikleri nedeniyle NOMA algoritmaları çok çeşitli uygulama alanlarında kullanılmıştır. Bunlara örnek olarak yüz tanıma [42-45], çeşitli biyomedikal uygulamalar [46,50], nota tanıma [51], ses ayrıştırma [52,53] ve görüntü kısıymı [54] verilebilir. NOMA'nın bu alanlarda kullanımında tercih nedenlerinin en önemlilerinden birisi, kullanılan verilerin doğasına uyumlu olmasıdır. Bu tür uygulamalarda genelde negatif olmayan elemanlardan oluşan veriler söz konusudur, bu da NOMA'nın çalıştırılmasını son derece elverişli kılar. Toplanabilir ve sezgisel


gösterimler oluşturma yetisinin yanında, seyreklik de NOMA'nın değişik uygulamalarda fayda sağlayabilecek özelliklerinden biridir [29,55]. Değişik uygulamaların ihtiyaçlarını karşılamak için NOMA'nın değişik versiyonları da önerilmiştir. Bunlara örnek olarak negatif değerlere sahip verilerde kullanılmak üzere veri ve karışım matrislerindeki negatif olmama koşulunu ortadan kaldıran yarı-NOMA [56] kullanılmıştır. Özellikle öbekleme uygulamalarında kullanılmak üzere ortaya atılmış olan ve karışım matrisi sütunlarının veri matrisi sütunları tarafından belirlenerek bir uzayda yer almasını sağlayan konveks-NOMA [57] verilebilir. Bunların yanında çekirdek-NOMA [58], üçlü çarpan ayırma ve simetrik NOMA gibi farklı türler de mevcuttur [59].

### 3.1. Matematiksel Tanımlar

Ayrıştırılacak olan veri matrisi  $n$  satır büyüklüğünde  $m$  adet gözlemden oluşan bir  $Y \in R^{n \times m}$  matrisi olsun. Şekilde gösterildiği gibi NOMA,  $Y \in R^{n \times m}$  matrisini, iki adet çarpan matrisine belirli bir yaklaşıklık denklem (19)'deki gibi ayrıştırır.

$$Y \approx AX \quad (19)$$

Bu matrislerden biri  $A \in R^{n \times r}$  matrisi karışım matrisi,  $X \in R^{r \times m}$  matrisi ise kaynak matrisi olarak isimlendirilir.  $r$  ise ayrıştırma rankı olarak tanımlanır ve seçilecek olan rankın değeri kör kaynak ayrıştırma sorununu çözmek için genellikle kaynak sayısına eşit seçilir. Şekil 34'te NOMA'nın veri matrisini 2 adet çarpan matrisine ayrıştırmasını göstermektedir.



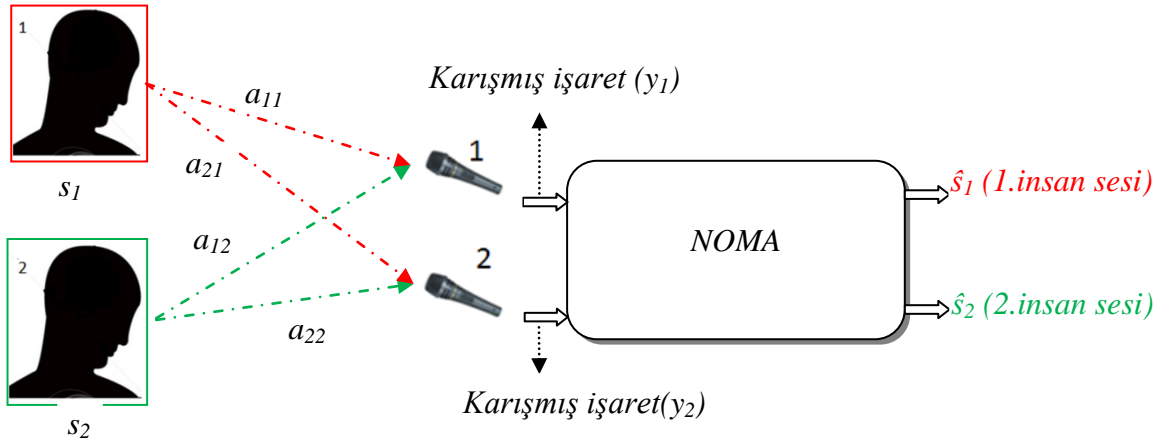
Şekil 34. NOMA'nın veri matrisini çarpan 2 matrise ayrıştırması

Şekil 34 'e bakıldığında  $Y$  matrisi ayrıştırılacak olan matris veya sensörlerden alınan temel veri matrisini temsil etmektedir ( $n$  adet sensörle kaydedilmiş  $m$  adet örnekten oluşan veri matrisi).

NOMA yönteminin uygulanmasında genelde denklem (20) ile verilen ifade amaç fonksiyonu olarak seçilip minimize edilir. [59].

$$F = \sum_{i,j} (Y - AX)_{i,j}^2 \quad (20)$$

Literatürde değişik amaç fonksiyonları tanımlanıp kullanılmıştır. Bu amaç fonksiyonları olasılık dağılımları veya en küçük kareler yöntemi kullanarak iki matris arasındaki hata oranını bulmaya yöneliktir. Bu durum Şekil 35 üzerinde daha anlaşılır bir şekilde anlatılmıştır.



Şekil 35. Kokteyl parti problemi ve NOMA

Yukarıdaki şekile bakacak olursak 1. ses kaynağı olan  $s_1$ 'in birinci mikrofonu olan uzaklığı  $a_{11}$  ve ikinci mikrofonu olan uzaklığı  $a_{21}$  gibi katsayılar olsun. Aynı şekilde 2. ses kaynağı olan  $s_2$ 'nin birinci mikrofonu olan uzaklığı  $a_{12}$ , ikinci mikrofonu olan uzaklığı ise  $a_{22}$  olsun. Birinci mikrofonun kaydettiği ses karışımı  $y_1$  ikinci mikrofonun kaydettiği ses karışımı  $y_2$  ise bu şeklin anlık karışım modeline göre matematiksel modeli;

$$\begin{bmatrix} a_{11} & a_{12} \\ a_{21} & a_{22} \end{bmatrix} \cdot \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} = \begin{bmatrix} y_1 \\ y_2 \end{bmatrix} \quad (21)$$

gibi olur. NOMA ile  $Y$  matrisinden  $A$  ve  $X$  matrislerini bulmak için öncelikle;

$$\begin{bmatrix} a_{11} & a_{12} \\ a_{21} & a_{22} \end{bmatrix} \text{ ve } \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} \quad (22)$$

gibi tamamen rastgele iki matris seçilir ve bu matrislerin çarpımları  $Y$  matrisine ne kadar benzediği hesaplanır. Benzerlik oranı ne kadar fazla ise  $A$  ve  $X$  matrislerinin her bir elemanı o kadar doğru tahmin edildiği anlamına gelir.

### 3.2. NOMA Algoritmaları

#### 3.2.1. Lee ve Seung Algoritması

Negatif olmayan matris ayrıştırma problemi için yapılan ilk çalışmalardan olan Lee ve Seung yaptıkları çalışmada NOMA için çarpımsal güncelleme kuralları önermiş ve bu önerilen bu kurallar ile NOMA birçok farklı alanda kullanılmaya başlanmıştır [19].

##### 3.2.1.1. Öklid Uzaklık Lee ve Seung Algoritması

Denklem (23) ile verilen denklemde  $Y$  matrisi ile  $A \cdot X$  arasındaki uzaklık minimize edilmelidir. En küçük kareler yöntemi kullanarak NOMA ile amaç fonksiyonu hesaplanması kullanılan en yaygın ve hesaplama maliyeti en az olan yöntemdir [60].

$$F = \sum_{i,j} (Y - AX)_{i,j}^2 \quad (23)$$

Denklem (24)'de verilen yöntemlerle amaç fonksiyonunu en aza indirmek için çarpımsal güncelleme kuralları önerilmiştir. Denklem (24) NOMA algoritması tarafından ayrıştırılacak olan veri matrisi için düzenlenirse denklem (25) elde edilir.



$$F = \sum_{i,j} (Y - AX)^2 = \sum_{i,j} \sum_{i=1}^n \sum_{j=1}^m (Y_{ij} - (AX)_{ij})^2 \quad (24)$$

Burada  $i$  ve  $j$  alt indisleri sırasıyla ilgili matrislerin satır ve sütunlarını belirtir. Karesel hata fonksiyonunun, amaç fonksiyonu gradyan inişi yöntemi ile eniyilendiğinde  $W$  ve  $H$  matrisleri için ayrı ayrı çarpımsal güncelleme kuralları bulunabilir [19].

$X$  matrisinin elemanları için gradyan inişi yöntemi kullanılarak bulunan güncelleme bağıntısı denklem (25)'te gösterildiği gibi formüle edilir. Burada  $j=1, \dots, m$ ,  $a=1, \dots, r$  olup  $\eta_{aj}$  eniyileme adım boyunu (step size) göstermektedir.

$$(X)_{aj} \leftarrow (X)_{aj} - \eta_{aj} \frac{\partial F}{\partial (X)_{aj}} \quad (25)$$

Burada görüldüğü gibi güncelleme kuralı henüz çarpımsal bir formda değildir. Bu güncelleme adımını çarpımsal hale dönüştürebilmek için denklem (26)'daki kısmi türev denklem (27) eşitliğindeki gibi açılabilir.

$$\frac{\partial F}{\partial (X)_{aj}} = \frac{\partial}{\partial (X)_{aj}} \left( \frac{1}{2} \sum_{i=1}^n \sum_{k=1}^m (Y_{ik} - (AX)_{ik})^2 \right) \quad (26)$$

$$= \frac{1}{2} \sum_{i=1}^n 2 \left( (A)_{ij} - (AX)_{ij} \right) \frac{\partial}{\partial (X)_{aj}} \sum_{k=1}^m \left( (A)_{ik} - (AX)_{ik} \right) \quad (27)$$

$$= - \sum_{j=1}^m \left( (A)_{ij} - (AX)_{ij} \right) (A)_{ia} \quad (28)$$

$$= -(A^T Y)_{aj} + (A^T AX)_{aj} \quad (29)$$

Denklem (28)'de verilen kısmi türev eşitliği, adım boyunun denklem (30) gibi seçilmesi koşulu ile (27)'de kullanıldığında,  $X$  matrisinin elemanları için güncelleme kuralı elde edilebilir. Yapılan işlemler bitirildiğinde  $X$  matrisi için bulunan güncelleme kuralı denklem (31) gibi olur.

$$\eta_{aj} = \frac{(X)_{aj}}{(A^T AX)_{aj}} \quad (30)$$

$$(X)_{aj} \leftarrow (X)_{aj} \frac{(A^T Y)_{aj}}{(A^T AX)_{aj}} \quad (31)$$

Benzer şekilde, A matrisinin elemanları için güncelleme kuralı elde etmek amacıyla gradyan inişi yöntemi kullanılabilir. Bu işlemler sırası ile aşağıda gösterilmiştir.

$$(A)_{ia} \leftarrow (A)_{ia} - \lambda_{ia} \frac{\partial F}{\partial (A)_{ia}} \quad (32)$$

A matrisi için çarpımsal güncelleme kuralı elde etmek için denklem (33)deki kısmi türev (34)' deki gibi düzenlenebilir.

$$\frac{\partial F}{\partial (A)_{ia}} = \frac{\partial}{\partial (A)_{ia}} \left( \frac{1}{2} \sum_{k=1}^n \sum_{j=1}^m \left( (Y)_{kj} - (AX)_{kj} \right)^2 \right) \quad (33)$$

$$= \frac{1}{2} \sum_{j=1}^m 2 \left( (Y)_{ij} - (AX)_{ij} \right) \frac{\partial}{\partial (A)_{aj}} \sum_{k=1}^n \left( (Y)_{kj} - (AX)_{kj} \right) \quad (34)$$

$$= - \sum_{j=1}^m \left( (Y)_{ij} - (AX)_{ij} \right) (X)_{ia} \quad (35)$$

$$= -(Y^T X)_{ia} + (A X X^T)_{ia} \quad (36)$$

Denklem (34)'de verilen türev eşitliği adım boyu denklem (37)'deki gibi seçilmesi durumunda A matrisi için çarpımsal güncelleme kuralları denklem(38)'deki gibi olur.

$$\lambda_{ia} = \frac{(A)_{ia}}{(A X X^T)_{ia}} \quad (37)$$

$$(A)_{ia} \leftarrow (A)_{ia} \frac{(YX^T)_{ia}}{(AXX^T)_{ia}} \quad (38)$$

Genel olarak gradyan inişi yönteminde seçilecek adım boyutunun önemi büyüktür. Küçük seçilen adım boyu eniyilemede yakınsamayı yavaşlatırken, adım boyunun gereğinden büyük seçilmesi iraksamaya neden olabilir. Ancak, denklem (30) ve denklem (37)'de verilen adım boylarının seçilmesi durumunda amaç fonksiyonunun dögüsel olarak güncelleme sırasında hiç artmayacağı, Lee ve Seung tarafından ispatlanmıştır. Adım boylarının bu şekilde seçilmesinin bir başka önemli noktası ise güncelleme döngüleri sırasında adım boylarının otomatik olarak değişmeleridir. Yani herhangi bir kontrol ya da atama yapmaya gerek kalmadan adaptif olarak belirlenen adım boyları NOMA algoritmasında kullanılmaktadır.

Denklem (31) ve denklem (38)'da verilen güncelleme kuralları ile aşağıda verilen şekle göre hata fonksiyonu en küçük olana kadar algoritma çalışmaktadır.

Algoritma 1. Öklid uzaklığı ile NOMA

$A = rand(m,r)$       %  $m \times r$  boyutunda rastgele seçilmiş karışım matrisi

$X = rand(r,n)$       %  $r \times n$  boyutunda rastgele seçilmiş veri matrisi

for  $i=1$  : maksimum iterasyon

$$(A)_{ia} = (A)_{ia} \times \left[ \frac{(AX^T)_{ia}}{((AXX^T) + 10^{-9})_{ia}} \right]$$

$$(X)_{ia} = (X)_{ia} \times \left[ \frac{(A^T Y)_{ia}}{(A^T A X + 10^{-9})_{ia}} \right]$$

Durdurma kriterine kadar

Burada  $r$  sabiti ayrıştırma rankıdır .  $r$  sabiti kör kaynak ayrıştırma probleminin çözümünde yani kaynak sayısı kadar karışım sinyali olduğunda kaynak sayısına eşit seçilmelidir. Fakat bu çalışmada esas olarak tek kanal kör kaynak ayrıştırma üzerinde durulacağından  $r$  sabiti

kaynak sayısına eşit olmayabilir. Bunun daha geniş anlatımı ilerleyen bölümlerde verilecektir.

### 3.2.1.2. Kullback-Leibler Yakınsama Tabanlı Lee ve Seung Algoritması

Denklem (39) herhangi iki matris olan  $A$  ve  $B$  arasındaki uzaklığı bulmak için kullanılabilir [27]. Burada  $A$  ve  $B$  ayrık olasılık dağılımlarıdır. Denklem (39) NOMA algoritması için yazılacak olursa denklem (40) elde edilir. Burada ayrıştırılacak olan  $Y$  matrisi  $A \cdot X$  matrisleri arasındaki hatayı bulmak için kullanılabilir [19].

$$D(A\|B) = \sum_{ij} \left( A_{ij} \log \frac{A_{ij}}{B_{ij}} - A_{ij} + B_{ij} \right) \quad (39)$$

Denklem (40) 'de  $Y$  matrisi ile  $A \cdot X$  matrisleri arasındaki her bir elemanın hata oranları bulunarak toplanır.

$$D(Y\|AX) = \sum_{ij} \left( Y_{ij} \log \frac{Y_{ij}}{AX_{ij}} - Y_{ij} + AX_{ij} \right) \quad (40)$$

Kullback-Leibler yakınsaması bazı kaynaklarda I-yakınsaması olarakta kendine yer bulabilir. I-yakınsaması için Lee ve Seung tarafından önerilen güncelleme kuralları aşağıdaki gibidir.

$$(X)_{ia} \leftarrow (X)_{ia} \frac{\sum_i A_{ia} Y_{i\mu} / (AX)_{i\mu}}{\sum_k A_{ka}} \quad (41)$$

$$(A)_{ia} \leftarrow (A)_{ia} \frac{\sum_{\mu} A_{a\mu} Y_{i\mu} / (AX)_{i\mu}}{\sum_v X_{av}} \quad (42)$$

Kull-Back Leibler tabanlı NOMA ve Öklid uzaklı NOMA algoritmalarının KKA problemini çözmedeki başarımlarını daha iyi anlayabilmek için 4 farklı sinyal kaynağı MATLAB ortamında farklı karışım matrisleri ile karıştırılıp tekrar ayrıştırılmıştır. Böylece


NOMA'nın kör kaynak ayrıştırma problemini nasıl çözdüğünü anlamak ve iki farklı algoritma arasındaki başarımlarını değerlendirmek daha kolay olacaktır.

### 3.3. NOMA Algoritmasının KKA Problemine Uygulanması

KKA problemi ve NOMA algoritmalarının bu problemi nasıl çözdüğünü anlayabilmek için elimizde Şekil 36'da gösterildiği gibi dört farklı kaynak sinyaliz olduğunu varsayalım. Sinyallerden ikisi frekansları zamanla değişen sinüs işaretlerin sadece pozitif kısımları, diğer iki işaret ise gürültü işaretleridir. Şekil 36'dan anlaşıldığı üzere bu 4 farklı sinyalde de negatif veri bulunmamaktadır. Sinyallerden herhangi birinde negatif veri bulunması durumunda o sinyalin pozitive normalize edilerek NOMA algoritması için uygun hale getirilmesi gerekmektedir. Bu işlemi herhangi bir  $x[n]$  işareti için uygulamak için sinyalin minimum genlik noktası belirlenir ve sinyal bu değerle toplanır. Yapılan işlemin matematiksel ifadesi;

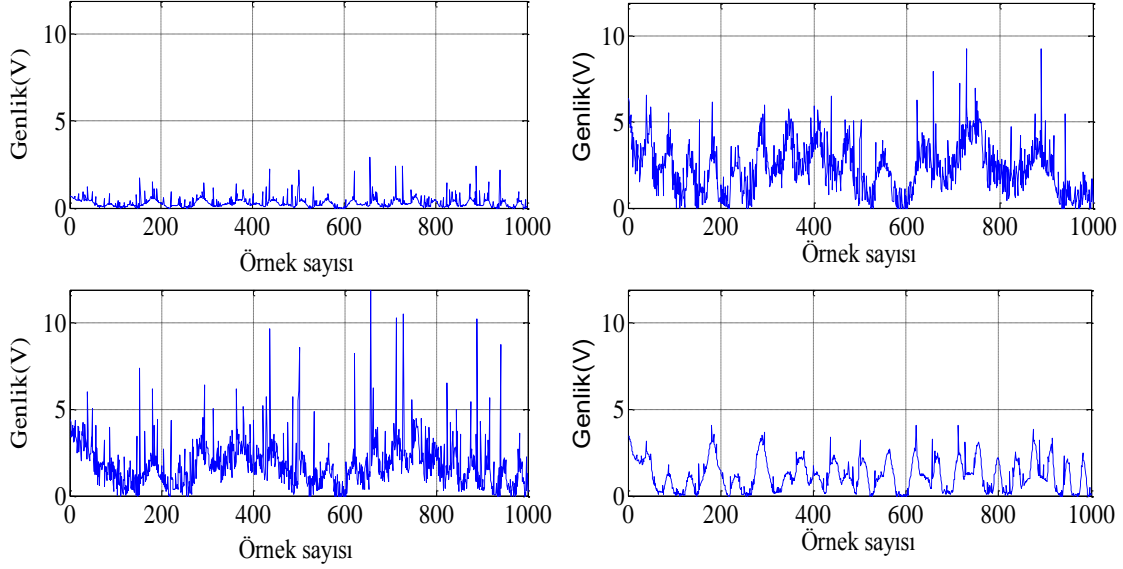
$$Y[n] = X[n] - \min[X[n]] \quad (43)$$

şeklinde olur. Burada  $Y[n]$  pozitive normalize edilmiş sinyali göstermektedir. Şekil 36 ise yapılacak olan bu işlem için kaynak teşkil eden 4 farklı sinyali göstermektedir.



Şekil 36. NOMA algoritmasının ayrıştıracağı kaynak sinyaller

Şekil 36’da da verilen dört farklı sinyalin 4 sensör tarafından kaydedilen karışmış halleri Şekil 37’deki gibi olmaktadır. Burada her bir sensörün kaynağa olan uzaklığı o sensördeki sinyalin şeklini etkilemektedir.



Şekil 37. Dört adet kaynak sinyalinin dört sensörle kaydedilmiş şekli

Bu durumun matematiksel ifadesi  $S$ ;

$$S = \begin{bmatrix} s_{11} & s_{12} & \cdots & s_{1N} \\ s_{21} & s_{22} & \cdots & s_{2N} \\ s_{31} & s_{32} & \cdots & s_{3N} \\ s_{41} & s_{42} & \cdots & s_{4N} \end{bmatrix} \quad (44)$$


Olmak üzere dört adet kaynak işaretinin  $N$  adet örnekleme sonucu oluşan temel veri matrisi veya kaynak matrisi  $A$ ;

$$A = \begin{bmatrix} a_{11} & a_{12} & a_{13} & a_{14} \\ a_{21} & a_{22} & a_{23} & a_{24} \\ a_{31} & a_{32} & a_{33} & a_{34} \\ a_{41} & a_{42} & a_{43} & a_{44} \end{bmatrix} \quad (45)$$

olmak üzere kaynakların sensörlere olan uzaklıklarını gösteren karıştırma matrisidir.  $Y$  matrisi ise her bir sensörden alınan karışmış verileri içeren sinyallerdir ve ifadesi ;

$$Y = AS \quad (46)$$

şeklinde olur. Önceki bölümlerde de belirtildiği gibi NOMA  $Y$  matrisini iki matrisin çarpımı şeklinde ayrıştırır [19]. Amaç  $A$  ve  $S$  matrislerini bulmaktır. Algoritmada gösterildiği gibi başlangıçta  $A$  ve  $S$  matrislerine rastgele değerler atanır ve her bir iterasyonda  $Y$  değerine biraz daha yaklaşılr. Bu durum Şekil 38’de gösterilmiştir.

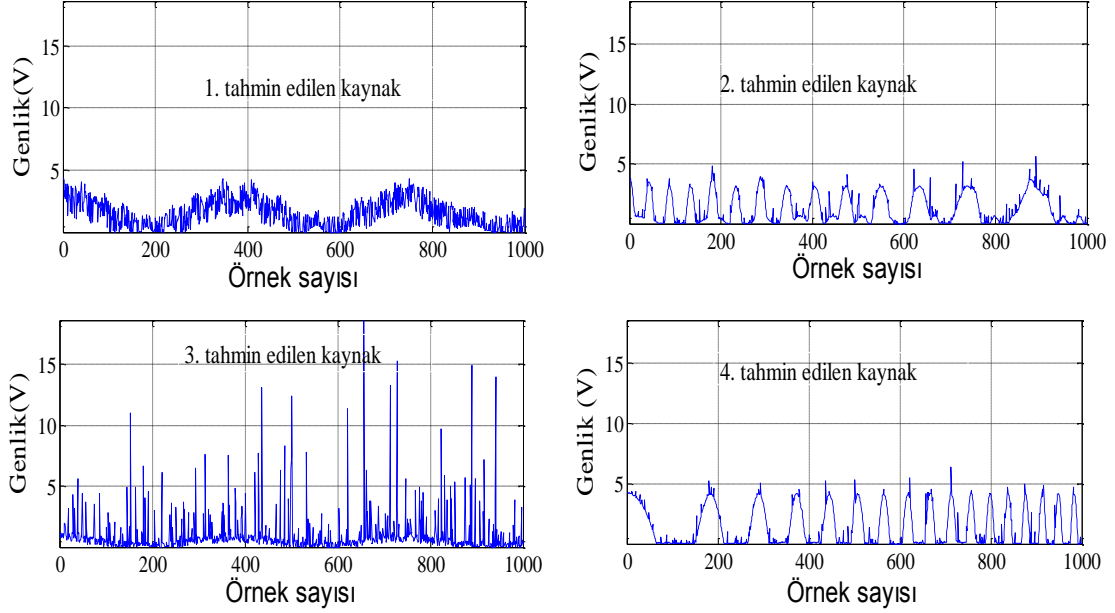


Şekil 38. Öklid uzaklığının iterasyon sayısına göre değişim

NOMA algoritması ile bu ayrıştırmayı yaparken bulunan öklid uzaklığı ne kadar küçük ise kaynak tahminleri o oranda doğru olur [19]. Şekil 39’da NOMA tarafından tahmin edilen 4 farklı kaynak sinyalleri verilmiştir.


NOMA’nın yapacağı iterasyon sayısı iki kriterle bağlıdır. Bunlardan birincisi kullanıcı tarafından belirtilen maksimum iterasyon sayısıdır. Maksimum iterasyon sayısı algoritmanın amaç fonksiyonu değerinden bağımsız bir şekilde istenilen kadar iterasyonu gerçekleştirmesidir. Fakat bu Şekil 38’e bakıldığında algoritmanın 150. İterasyondan sonra yakınsamadığı görülmektedir. İkincisi ise durdurma kriteridir. Durdurma kriteri iki matris arasındaki uzaklığın belirli bir noktaya gelmesi durumunda algoritmanın maksimum iterasyon sayısını beklemeden işlemi bitirmesidir. Şekil 38’e bakıldığında yaklaşık 0’a

geldiğinde algoritmanın durduğunu görmekteyiz. Durdurma kriterinin çok küçük seçilmesi algoritmanın çalışma süresini gereksiz yere artırmasının yanı sıra çok büyük seçilmesi ise algoritmanın yeterince yakınsamayacağını göstergesidir.




Şekil 39. NOMA tarafından tahmin edilen kaynak sinyaller

Öklid-NOMA ve Kullback-Leibler NOMA algoritmalarının performans analizini daha iyi görebilmek için Şekil 36'da verilen kaynak sinyaller 100 farklı karıştırma matrisi ile karıştırılmış ve her iki algoritmayla tekrar ayrıştırılmıştır. Algoritma başarımlarının iterasyon sayısına nasıl tepki verdiklerini gözlemlemek için de algoritmalar 50, 100 ve 200 iterasyonla çalıştırılmıştır.




Şekil 40. 1. Kaynak için Monte Carlo analizi İGO sonuçları






Şekil 41. 2. Kaynak için Monte Carlo analizi İGO sonuçları



Şekil 42. 3. Kaynak için Monte Carlo analizi İGO sonuçları



Şekil 43. 4. Kaynak için Monte Carlo analizi İGO sonuçları

Monte Carlo analizi İGO sonuçlarına bakıldığında her iki algoritmanın da rastgele seçilen giriş değerlerinden oldukça etkilendiği görülmüştür. Özellikle Öklid-NOMA'nın en iyi ve en kötü sonuçları arasında 16 dB'lik fark olduğu gözlenmiştir. Tablo 2.'ye bakıldığında ise Öklid-NOMA'nın iterasyon sayısına göre İGO değerleri ortalamasında artış olduğu gözlenmiştir. Fakat Kullback-Leibler NOMA'nın iterasyon sayısının artması İGO değerlerinde bir iyileştirme ortaya koymamaktadır. Bunun nedeni algoritmanın durdurma kriteri değerini 50 iterasyondan daha önce yakalamasıdır.


Tablo 2. Öklid ve kullback –leibler yakınsama tabanlı NOMA algoritmalarının iterasyon sayısına göre performans analizleri

İGO(dB)	50 iterasyon ortalaması		100 iterasyon ortalaması		200 iterasyon ortalaması	
	öklid	kullback	öklid	kullback	öklid	Kullback
1. kaynak	5,60	4,66	6,39	4,50	7,00	4,38
2. kaynak	3,12	4,65	4,13	4,46	4,03	4,37
3. kaynak	5,79	4,78	7,64	4,40	7,24	4,43
4. kaynak	7,01	4,49	8,10	4,21	9,60	4,34

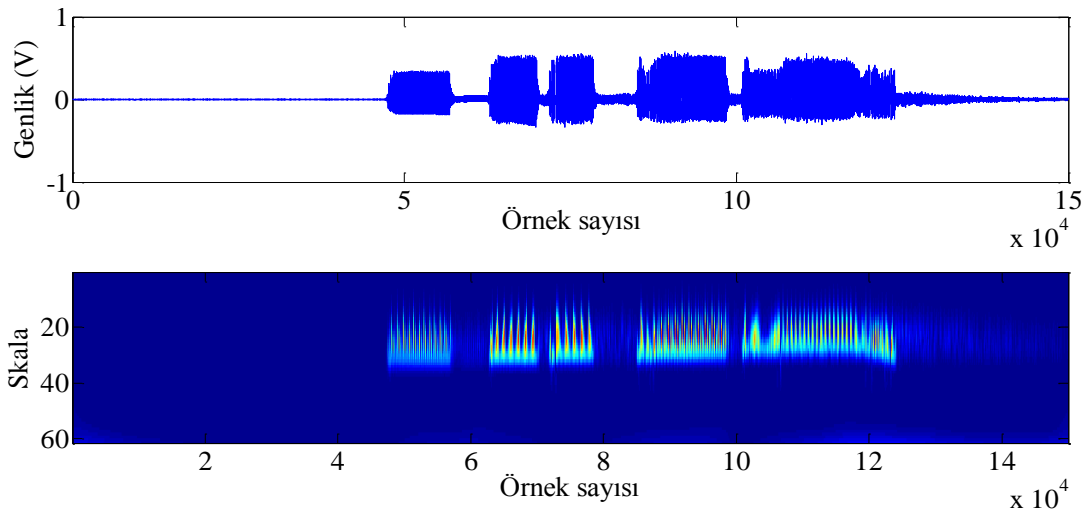
### 3.4. Skalogramın Ayırıştırılması

Herhangi bir sinyalin dalgacıklar üzerine uygulanmış regresyon sonuçlarının skalogram adı verilen görsel bilgileri oluşturduğu 2. bölümde anlatılmıştı. Tek kanal kör ayırışımı yapabilmek için ayırıştırılacak olan kaynak sinyallerin skalogram üzerinde farklı ölçeklerde bulunuyor olması ayırıştırma performansını önemli ölçüde artırmaktadır. Skalogram üzerinde farklı kaynaklara ait bileşenler skala ve genlik düzleminin aynı bölgesinde yer alıyorsa bu verileri ayırıştırmak, performans açısından başarılı sonuçlar vermeyebilir. Bu çalışmada kullanacağımız ses kaynakları ve bu ses sinyallerine ait skalogram örnekleri aşağıda verilmiştir.

Şekil 44’de verilen viyola işaretini skalogramına bakıldığında skala ekseninin 30. bölgesinde yoğunlaştığını görmekteyiz. Aynı şekilde Şekil 45 ‘te verilen trampet işaretinin skalogramına bakıldığında bu işaretin skala ekseninde 25. seviyelerde yoğunlaştığı görülmektedir. Önerilen yöntem hem skala hem de zaman ekseninde ayrışım yapmakta olduğundan işaretlerin skala ekseninde farklı bölgelerde yoğunlaşması yöntemin başarımını artırmaktadır. Daha açık bir anlatımla aynı skala ve zaman ekseninde üst üste gelen verilerin hangi kaynaktan geldiğini tahmin etmek oldukça zor bir yoldur. Önerilen yöntem ve şimdiye kadar yapılan çalışmalarda temel problemlerden biri de budur.

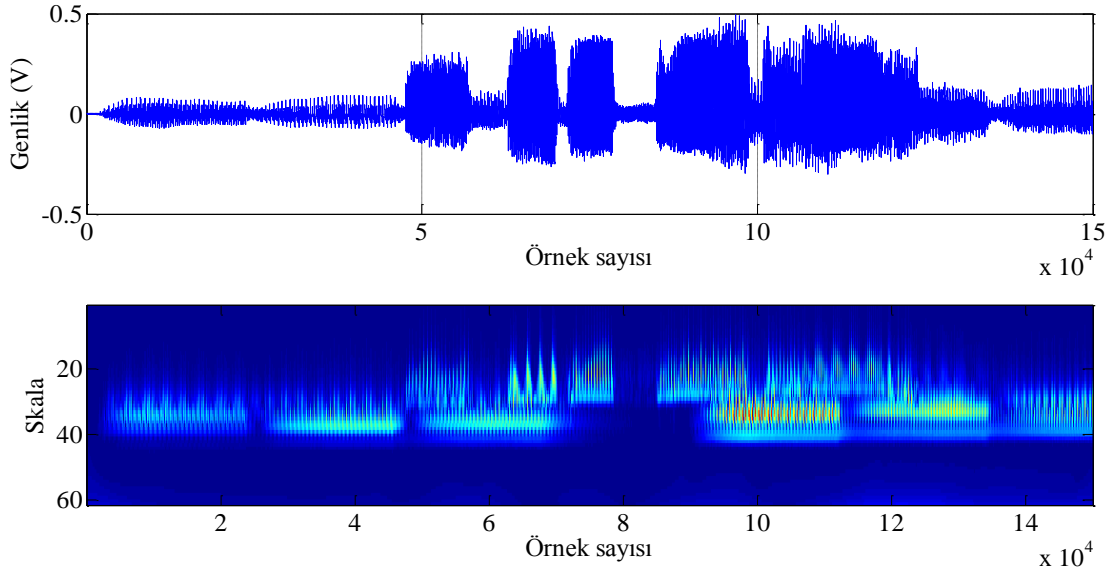


Şekil 44. Viyola enstrümanına ait işaret ve skalogramı (Morlet)



Şekil 45. Viyola enstrümanına ait işaret ve skalogramı (Morlet)

Şekil 46’da verilen karışmış işaretin skalogramı görülmektedir. Bu skalogramda işaretlerin skala eksenindeki yerlerini görebilmek için karıştırma matrisi her iki kaynak için de eşit değerlerden seçilmiştir.




Şekil 46. Karışmış işaretin skalogramı (Morlet)

NOMA skalogramı ayrıştırırken skala ve zaman ekseninde ayrışım yapmaktadır. Aşağıdaki şekle bakıldığında skalograma NOMA algoritması uygulanması gösterilmiştir. Şekil 44 ve Şekil 45’e bakıldığında işaretlerin SDD’si alınırken skala boyutu 60 seçilmiştir. Eğer skala boyutu daha küçük seçilecek olursa skalogram sinyalimizi eksik temsil edeceğinden ayrıştırma NOMA algoritmasının ayrıştırma performansı düşecektir. NOMA ayrıştırılacak olan  $Y$  skalogramını  $A$  ve  $X$  matrislerinin çarpımı şeklinde iki matrisin çarpımı şeklinde denklem (47)’de olduğu gibi iki matrisin çarpımı şeklinde ayrıştırır.

$$[Y]_{64 \times 150000} = [A]_{64 \times 4} \times [X]_{4 \times 150000} \quad (47)$$

Bu durum Şekil 40’a bakıldığında daha açık görülmektedir. Şekil üzerinde her iki kaynağın skala eksenindeki yerleri işaretlenerek belirtilmiştir. Bu iki sütunun seçilme nedenleri şekilden anlaşıldığı üzere en büyük 2 tepe noktası olmasıdır. 2. Sütunda tepe noktası yaklaşık 5 üçüncü sütunda tepe noktası yaklaşık olarak 13 tür. Dolayısıyla iki kaynaktan

biri skala ekseninde 13 seviyelerinde, diğer kaynak ise skala ekseninde 5 ile ölçeklenen seviyede yoğunlaşmıştır.




Şekil 47. Karışmış işaretin skalogramı (Morlet)

Bu yöntemden yola çıkarak biz karışım skalogramını denklem (48)'de gösterilen boyutlarda ayrıştıracağız.

$$[Y]_{64 \times 150000} = [A]_{64 \times 2} \cdot [X]_{2 \times 150000} \quad (48)$$


Bu ayrışmada kaynaklardan sadece birisinin skala eksenindeki yerini tahmin etmek ayrışım yapmak için bize yeterli olacaktır. Şekil 48'e bakıldığında kaynaklardan bir tanesinin skala ekseninin yaklaşık 32. bölgesinde yoğunlaştığını anlamaktayız. Burada

amaç skalogramı hem skala hem de zaman ekseninde ayrıştırmaktır. Buraya kadar yapılan işlemlerde skalogramı skala ekseninde ayrıştırmış olmaktadır.




Şekil 48. A matrisinin sütunları

Bu işlemden bir sonraki adım Şekil 42’de verilen yöntemle skalogramı zaman ekseninde de ayrıştırmak ve her bir kaynak skalogramını elde etmektir. Bu işlem için A matrisinin birinci sütunu karışım skalogramının her bir satırı ile ayrı ayrı noktasal çarpım işlemine tabi tutulur. Bu işlem Şekil 49’de gösterilmiştir. Böylece skalogramda her bir kaynağın zaman eksenindeki yeri de tahmin edilmiş olmaktadır.



Şekil 49. NOMA ile skalogramın ayrıştırılması

Şekil 49’de verilen yöntemle Şekil 50’de gösterilen sadece 1 kaynağa ait skalogram bulunabilir.



Şekil 50. İkili maske için ön hazırlık

Şekil 50’yi elde edebilmek için NOMA algoritması tarafından bulunan 60x2 boyutundaki A matrisinin dışbükey olan sütunu karışım skalogramı ile noktasal çarpma işlemine tabi tuulur. Şekil 50 ‘ye bakıldığında her skalograma katkısı olan en fazla kaynağın skala ve zaman bilgilerini bulabilmek için şekle göre bir ikili maske oluşturmamız gerekmektedir. İkili maskeyi oluştururken uygulanacak olan matematiksel ifade denklem (49)’da verilmiştir.


Verilen denklemde  $M_{ij}$  oluşturulacak olan maskeyi temsil etmektedir.

$$M_{ij} = \begin{cases} 1 & \text{eğer } SKAL(a)_{ij} \geq 0.5 \\ 0 & \text{eğer } SKAL(a)_{ij} \leq 0.5 \end{cases} \quad (49)$$

Burada denklem (49 ) ile verilen yöntemle kaynak skalogramların bulunabilmesi için öncelikle NOMA tarafından hesaplanan skalogramın 1’e normalize edilmesi gerekmektedir. Şekil 50 ‘ye dikkatli bakıldığında skalogram yanındaki bar çubukta bu durum görülebilir.


Şekil 51’ de verilen ikili maskeyi oluşturduktan sonra bu maskeyi Şekil 46’da verilen karışım işaretinin skalogramı ile noktasal çarpım işlemine tabii tutulur. Böylece

kariřim skalogramında 1'lerin karřısına gelen veriler alınır diđerleri kaybolur ki kaybolan bu veriler kaynaklardan birine ait verilerdir. Bu iřlemler sonunda elde edilen skalogram sadece tek kaynađa ait skalogram olduđundan TSDD'si alınırsa kaynaklardan birine ulařılmıř olur. Diđer kaynađın tahmin edilmesi iin aynı iřlemler tekrar uygulanır.



řekil 51. Birinci kaynak iin ikili maske


Uygulanan yntemle řekil 52'de gsterildiđi üzere 2. kaynak iinde ikili maske oluřturulabilir.



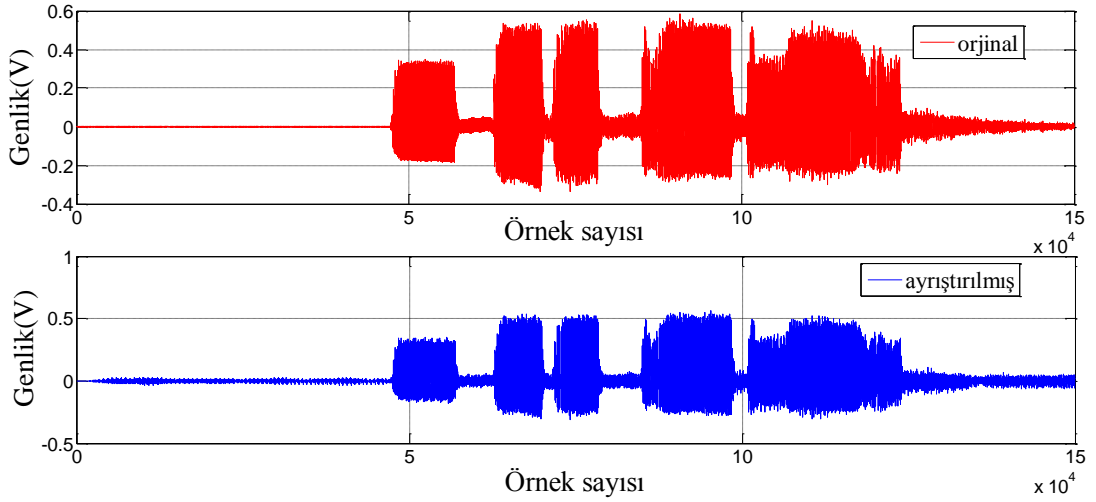
řekil 52. İkinci kaynak iin ikili maske



Bulunan ikili maskeler yardımı ile her bir kaynağa ait skalogram bulunduktan sonra , skalogramların TSDD alınarak kaynak işaretler kestirilmiş olur. Şekil 53 ve Şekil 54 kestirilen kaynak işaretlerin zamana göre değişimini vermektedir.




Şekil 53. Trampete ait orijinal ve tahmin edilen işaretler



Şekil 54. Viyolaya ait orijinal ve tahmin edilen işaretler

#### 4. DENEYSEL ÇALIŞMALAR


Yapılan deneysel çalışmalarda viyola ve trampete ait 150000 adet örnekten oluşan veriler rastgele seçilmiş 100 farklı karışım matrisi kullanılarak karıştırılmış ve Öklid uzaklığı ile NOMA, Kull-back Leibler NOMA kullanılarak üç farklı dalgacık dönüşümü ile ayrıştırılmıştır. Önerilen algoritmanın başarımlarını analizini iyi yapabilmek için sonuçlar işaret gürültü oranı (İGO) cinsinden ölçülmüş ve sonuçlar karşılaştırılmıştır.



Şekil 55. Öklid-NOMA algoritması için İGO sonuçlarının viyola işareti için değişimi(100 iterasyon)

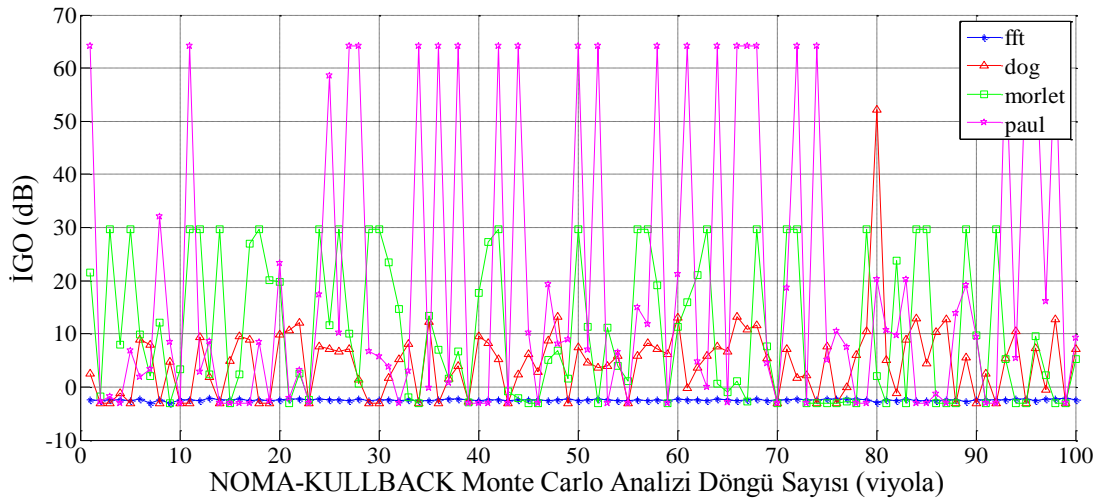
Şekil 55 Öklid uzaklığı kullanan NOMA algoritmasının viyola işaretini tahmin etme başarımının İGO bakımından değerlendirilmesidir. Öklid uzaklığı kullanan NOMA'ya bakıldığında Paul dalgacık dönüşümünün diğer dalgacık dönüşümlerine göre daha yüksek İGO değerleri verdiği görülmüştür. Fakat bu algoritmanın olumsuz yanı, karışım matrisinin rastgele alınan değerlerinden oldukça fazla etkilenmesidir. Bu sonuçlardan çıkarılacak diğer bir durum ise Şekil 55 ve Şekil 56'da verilen grafikler karşılaştırıldığında önerilen algoritmanın kaynaklardan birini çok yüksek bir doğrulukla tahmin ediyor olması diğer kaynağın tahmin başarımını aynı oranda kötüleştirmekte olduğudur. Örneğin Şekil 55'de x eksenindeki 70. döngüye bakıldığında İGO oranının yaklaşık 65 dB' lerde olduğu

görülmektedir. Fakat 2. Kaynak için İGO değerlerinin verildiği Şekil 56'a bakıldığında x eksenindeki 70. döngüde yaklaşık İGO değeri negatif değerlerde olduğu görülmektedir.




Şekil 56. Öklid-NOMA algoritması için İGO sonuçlarının trumpet işareti için değişimi (100 iterasyon)

Şekil 56 ise Öklid uzaklığı kullanan NOMA algoritmasının trumpet işaretini tahmin etme başarımının İGO bakımından değerlendirilmesidir. Grafiğe bakıldığında yine Paul dalgacık dönüşümünün diğer dönüşümlere oranla daha iyi sonuçlar verdiği gözlemlenmiştir.



Şekil 57. Kull-Back Leibler-NOMA algoritması için İGO sonuçlarının viyola işareti için değişimi (100 iterasyon)

Şekil 57 ise Kull-Back Leibler uzaklığı kullanan NOMA algoritmasının viyola işaretini tahmin etme başarımının İGO bakımından değerlendirilmesidir. Verilen grafiğe bakıldığında yine Paul dalgacık dönüşümünün diğer dalgacık dönüşümüne göre üstünlüğü görülmektedir. DOG dalgacık dönüşümünün sonuçlarına bakıldığında ise karışım matrisi değerlerinden en az etkilenen algoritma olduğu anlaşılmaktadır.



Şekil 58. Kull-Back Leibler-NOMA algoritması için İGO sonuçlarının trumpet işareti için değişimi (100 iterasyon)

Şekil 58 Kull-Back Leibler uzaklığı kullanan NOMA algoritmasının trumpet işaretini tahmin etme başarımının İGO bakımından değerlendirilmesidir. Grafiğe bakıldığında yine Paul dalgacık dönüşümünün diğer dalgacık dönüşümlerine göre daha iyi sonuçlar verdiği görülmüştür. Sonuçların daha iyi irdelenmesi için grafik şeklinde verilen sonuçların ortalamaları alınarak tablo haline dönüştürülmüştür. Ayrıca önerilen yöntemde kullanılan iki farklı NOMA algoritması için iterasyon sayısına göre algoritma başarımını gözlemlemek için algoritmalar 50 şer ve 100 er kez çalıştırılarak İGO değerlerinin ortalamaları tablo halinde verilmiştir.

Tablo 3. Önerilen algoritmalar için İGO sonuçları ortalaması(50 iterasyon)

İGO(dB)	KZFD		DOG	PAUL	MORLET
VİYOLA	-2,45	Öklid NOMA	-0,9	-0,45	-0,03
		Kullback-leibler NOMA	5,54	<b>17,45</b>	0,03
TRAMPET	-2,74	Öklid NOMA	5,01	4,41	5,76
		Kullback-leibler NOMA	2,5	<b>7,56</b>	5,76

Tablo 4. Önerilen algoritmalar için çalışma süreleri sonuçları ortalaması (50 iterasyon)

KZFD		DOG	PAUL	MORLET
12 sn	Öklid NOMA	19 sn	20 sn	19 sn
	Kullback-leibler NOMA	96sn	98 sn	92 sn

Tablo 5. Önerilen algoritmalar için İGO sonuçları ortalaması(100 iterasyon)

İGO(dB)	FFT		DOG	PAUL	MORLET
VİYOLA	-2,45	Öklid NOMA	5,1	12,2	8,06
		Kullback-leibler NOMA	4,54	<b>18,82</b>	10,32
TRAMPET	-2,74	Öklid NOMA	5,01	5,21	5,45
		Kullback-leibler NOMA	4,31	<b>7,69</b>	6,6

Tablo 6. Önerilen algoritmalar için çalışma süreleri sonuçları ortalaması (100 iterasyon)

<b>KZFD</b>		<b>DOG</b>	<b>PAUL</b>	<b>MORLET</b>
12 sn	Öklid NOMA	41 sn	43 sn	39 sn
	Kullback-leibler NOMA	189 sn	183 sn	192 sn

## 5. İRDELEME VE SONUÇLAR

Tek kanal kör kaynak ayırıştırma probleminin çözümü için günümüzde farklı yaklaşımlar mevcuttur. Bunlardan en çok rastlanan yöntem ise karışmış şekilde bulunan tek kanalla kaydedilmiş verinin KZFD' si alınarak frekans ve zaman ekseninde ayırıştırma yapmaktır. Fakat bu yöntemin temel problemi işaretin KZFD'si alındığında bu yöntemin işareti yeterince iyi temsil etmemesidir. Pencere boyu küçük seçildiğinde zaman çözünürlüğü, büyük seçildiğinde ise frekans çözünürlüğü iyileşmektedir. Tek kanal kör kaynak ayırıştırmanın amacına yeterince ulaşabilmesi için bize hem zamanda hemde frekansta iyi çözünürlük veren dalgacık dönüşümü gibi bir yöntem kullanmamızın kör olarak yapılan ayırıştırmanın performansını olumlu derecede artırdığını görmekteyiz. Yapılan bu çalışmada üç farklı dalgacık dönüşümünün sonuçlarına bakıldığında Paul dalgacık dönüşümünün diğer dalgacık dönüşümlerine göre daha olumlu sonuçlar verdiği gözlemlenmiştir. Önerilen yöntemin İGO ortalamaları göz önüne alındığında Kullback-Leibler yakınsama tabanlı NOMA'nın özellikle viyola işaretini ayırıştırmadaki başarımı oldukça iyi seviyelerde olduğu gözlemiştir. Yine İGO ortalamalarına göre Kullback-Leibler yakınsama tabanlı NOMA'nın DOG dalgacık dönüşümü ile beraber kullanıldığında algoritma performansının azalmakta olduğu görülmektedir. Morlet dalgacık dönüşümünün ise İGO ortalama sonuçlarına göre performansının diğer iki algoritmaya göre orta seviyelerde olduğu görülmüştür.

KZFD ve dalgacık dönüşümü kullanan algoritmaların çalışma sürelerine baktığımızda ise Öklid-NOMA algoritmasının KZFD kullanan algoritmaya göre yaklaşık 3,5 kat daha fazla süre çalışmakta olduğu görülmektedir. Özellikle en yüksek başarıyı sunan kullback-leibler yakınsama tabanlı NOMA algoritmasının çalışma süresi önemi bir dezavantaj olarak karşımıza çıkmaktadır. Önerilen yöntemin süre dezavantajını azaltmak için kullanılan NOMA algoritmalarının iterasyon sayısı azaltılabilir fakat iterasyon sayısının azaltılması beraberinde algoritmanın daha az yakınsamasını bu da algoritma performanslarında önemli bir düşüş oluşturmaktadır.

## 6.ÖNERİLER

Yapılan bu çalışmada literatürde zor ve maliyetli bir işlem olarak bilinen tek kanal kör kaynak ayrıştırma işlemi, sürekli dalgacık dönüşümü kullanılarak gerçekleştirilmiştir. Önerilen yöntemde İGO değerleri diğer yöntemlere göre daha başarılı bulunmuştur. Önerilen yöntemin dezavantajlarından biri algoritmanın her iki kaynağı da yüksek doğrulukla tahmin edememesi, diğer dezavantajı ise algoritma işletim sürelerinin oldukça yüksek olmasıdır. İşaretlerin sürekli dalgacık dönüşümü alınıp işaret NOMA algoritması için hazır hale getirilirken aynı zamanda fazla bir veri artışı olmaktadır. Her iki kaynağın aynı anda yüksek doğrulukla tahmin edilmesi ve işletim sürelerinin azaltılması üzerine yeni çalışmalar yapılabilir.



## 7.KAYNAKLAR

1. Schmidt, M. N., Single-Channel Source Separation Using Non-negative Matrix Factorization, Doktora Tezi, Technical University of Denmark, 2008.
2. Davies, M. E. ve James, C. J., Source separation using single channel ICA, Signal Process, 87,8 (2007) 1819–1832.
3. Wang, B. ve Plumbley, M. D., Musical Audio Stream Separation by Nonnegative Matrix Factorization, DMRN Summer Conference, 2005, Glasgow.
4. Virtanen, T., Monaural Sound Source Separation by Nonnegative Matrix Factorization with Temporal Continuity and Sparseness Criteria, IEEE Trans. on Audio, Speech and Language Processing, 15, 3 (2007) 1066–1074.
5. Smaragdis, P., Non-negative Matrix Factor Deconvolution; Extraction of Multiple Sound Sources from Monophonic Inputs, Lecture Notes in Computer Science, 319,5 (2004) 494–499.
6. Schmidt, M. N. ve Olsson, R. K., Singlechannel Speech Separation Using Sparse Non-negative Matrix Factorization, International Conference on Spoken Language Processing (INTERSPEECH), 2006, Glasgow.
7. Kırılmaz S. ve Günsel B., Negatif Olmayan Matris Ayırıştırma ile Tek-Kanaldan Algısal Ses Ayırıştırma, IEEE, 9-11Nisan 2009, Antalya.
8. Bell, A. J. ve Sejnowski, T. J., An Information-maximization Approach to Blind Separation and Blind Deconvolution, Neural Computation, 7, 6 (1995) 1129-1159.
9. Herault, J. ve Jutten, C., Blind Separation of Sources Adaptive Algorithm Based on Neuromimetic Architecture, Signal Processing, 18-23 (1991) 1-10.
10. Amari, S., Cichoki, A. ve Yang, H. H., A New Learning Algorithm for Blind Signal Separation, Advances in Neural Information Processing Systems, 87,8 (1996) 451-468.
11. Gaeta, M. ve Lancome, J. L., Source Separation Without Prior Knowledge: the Maximum Likelihood Solution, Proc. Of EUSIPCO'90, 55 (1990) 621-624.
12. Cardoso, J. F. ve Comon, P., Independent Component Analysis, A Survey of Some Algebraic Methods, Proc. ISCAS96, 2 (1996) 93-96.
13. Comon, P., Independent Component Analysis: A New Concept, Signal Processing, 36 (1994) 287-314.

14. O'Grady, P. D., Pearlmutter B. A. ve Rickard S. T., Survey of Sparse and Non-sparse Methods in Source Separation, IJIST International Journal of Imaging Systems and Technology, 18 (2005) 78-85.
15. Herault, J. ve Jutten, C., Space or Time Adaptive Signal Processing by Neural Models, Proceedings AIP Conference: Neural Networks for Computing, (1986) 206-211.
16. Rickard,S., The DUET Blind Source Separation Algorithm, Blind Speech Separation, 15 (2007) 217-240.
17. Jung, T. P., Makeig, S., Westerfield, M. ,Townsend, J. , Courchesne, E. ve Sejnowski, T. J., Removing Electroencephalographic Artifacts by Blind Source Separation, Psychophysiology, 37 (2000)163-178.
18. Paatero, P. ve Tapper, U., 1994, Positive Matrix Factorization Nonnegative Factor Model with Optimal Utilization of Error Estimates of Data Values, Environmetrics, 5 (1994) 111-126.
19. Lee, D.D. ve Seung, H.S., Algorithms for Nonnegative Matrix Factorization, Proceedings of Neural Information Systems, 15 (2000) 942-948.
20. Jang, G.J. ve Lee, T. V., A Maximum Likelihood Approach to Singlechannel Source Separation, The Journal of Machine Learning Research, 4, 8 (2004) 1365–1392.
21. Pedersen M., Wang, D.L., Larsen J., ve Kjems U., Overcomplete Blind Source Separation by Combining Ica and Binary Time-Frequency Masking, Machine Learning for Signal Processing, 12 (2005) 15 –20.
22. Pedersen M., Wang, D.L., Larsen J., ve Kjems U., Separating underdetermined convolutive speech mixtures, Independent Component Analysis and Blind Signal Separation, 3889 (2006) 674–681.
23. Pedersen M., Wang, D.L., Larsen J., ve Kjems U., Two-Microphone Separation of Speech Mixtures, Speech Communication 19, 3 (2008) 475 –492.
24. Pedersen M., Wang, D.L.,Larsen J., ve Kjems U., Monaural Speech Segregation Based on Fusion of Source-Driven with Model-Driven Techniques, Speech Communication, 49, 6 (2007) 464– 476.
25. G. Hu ve D. L. Wang, Monaural Speech Segregation Sased on Pitch Tracking and Amplitude Modulation, Speech Communication 15, 5 (2004) 1135–1150.
26. T. Quatieri ve R. Danisewicz, An Approach to Co-channel Talker Interference Suppression Using a Sinusoidal Model for Speech, Speech, Signal Process., 38, 1 (1990) 56–69.

27. Ellis, D. P. W., Model-Based Scene Analysis, Computational Auditory Scene Analysis: Principles, Algorithms, and Applications, 4 (2006) 115–146.
28. Hershey, J., Rennie, S., Olsen, P. ve Kristjansson, T., Super-Human Multitalker Speech Recognition: A graphical Modeling Approach, Elsevier Computer Speech and Language, 24,1 (2010) 45–66.
29. Elmas, M., Kör Kaynak Ayırıştırmada Seyreklik Tabanlı Yöntemler ve Düet Algoritması, Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi, 2010.
30. Baygün, B. K., Türkçe Komutları Tanıyan Ses Tanıma Sistemi Geliştirilmesi, Yüksek Lisans Tezi, Pamukkale Üniversitesi, 2006.
31. Altınbaş, A., EMG Sinyallerinin Kısa Zamanlı Fourier Dönüşümü ve Dalgacık Dönüşümü kullanarak Analiz Edilmesi, Yüksek Lisans Tezi, Gazi Üniversitesi Bilişim Enstitüsü, Ankara, 2007.
32. Türkoğlu M.Y., EEG Sinyallerinin Analizinde performansı Yüksek olanların belirlenmesi, Yüksek Lisans Tezi, TOOB Ekonomi ve Teknoloji Üniversitesi, Ankara, 2010.
33. Tepe C., EKG Sinyallerinde Gürültü Gidermede Ayrık Dalgacık Dönüşümü, Yüksek Lisans Tezi, Ondokuz Mayıs Üniversitesi, Samsun, 2009.
34. Aygün O., Konuşmacı Tanıma Sistemlerinde Dalgacık Dönüşümü, Yüksek Lisans Tezi, Selçuk Üniversitesi, Konya, 2006.
35. Çekiç Y., Durağan Olmayan İşaretler İçin Zaman-Frekans Analizi, Doktora Tezi, İstanbul Teknik Üniversitesi, İstanbul, 2004.
36. <http://www.ljmu.ac.uk/GERI/98293.htm> .10 Mart 2013.
37. Jolliffe I., Principle Component Analysis, Second Edition, Springer, New York, 2000.
38. Bokman, L., Syungkwon, R. ve Park, F. C., Movement Primitives, Principal Component Analysis, and the Efficient Generation of Natural Motions, Proceedings of the 2005 IEEE International Conference on Robotics and Automation, 10 (2005) 4630-4635.
39. Jackson, J. E., A User Guide to Principle Component, John Wily, Second Edition ,Canada,1991.
40. Schachtner, R., Extensions of Non-negative Matrix Factorization and their Application to the Analysis of Wafer Test Data, Doktora Tezi, Universitat Regensburg, Regensburg, 2010.
41. Bucak S. S., Gözetleme Videolarında Artımlı Negatif Olmayan Matris Ayırıştırma ile Arka Plan Modelleme, İstanbul Teknik Üniversitesi, Yüksek Lisans Tezi, 2008.

42. Guillaumet, D. ve Vitria, J., 2002. Nonnegative Matrix Factorization for Face Recognition, Fifth Catalanian Conference on Artificial Intelligence, 45 (2002) 336-344.
43. Chen, X. L., Gu, S. Z. ve H. Zhang. Learning Representative Local Features for Face Detection, In CVPR, 1 (2001) 1126-1131.
44. Ho, N.D., Blondel, V. ve Van, D. P., Weighted Nonnegative Matrix Factorization and Face Feature Extraction, Submitted to Image and Vision Computing, 12 (2007) 1232-1243.
45. Hoyer, P.O., Nonnegative Sparse Coding, IEEE Workshop on Neural Networks for Signal Processing, 15 (2002) 557-565.
46. Lin, C.J., Projected Gradient Methods for Non-negative Matrix Factorization, Neural Computation, 19 (2007) 2756-2779.
47. Fogel, P., Young, S.S., Hawkins, D.M. ve Ledirac, N., Inferential Robust Non-negative Matrix Factorization Analysis of Microarray Data, Bioinformatics, 23 (2007) 44-49.
48. Pascual, M. A., Carazo, J.M., Kochi, K., Lehmann, D. ve Pascual, R.D., Nonsmooth Nonnegative Matrix Factorization, IEEE Transactions and Pattern Analysis and Machine Intelligence, 42 (2006) 403-415.
49. Lee, D.D. ve Seung, H.S., Unsupervised Learning by Convex and Conic Coding. Advances in Neural Information Processing Systems, 9 (1997) 515-521.
50. Cichocki, A., Zdunek, R. ve Amari, S., New Algorithms for Non-negative Matrix Factorization in Applications to Blind Source Separation, IEEE International Conference on Acoustics, Speech and Signal Processing, 2006, 621-624.
51. Smaragdis, P. ve Brown, J.C., Nonnegative Matrix Factorization for Polyphonic Music Transcription, IEEE Workshop Applications of Signal Processing to Audio and Acoustics, 54 (2003) 177-180.
52. Monga, V. ve Mihcak, M.K., Robust Image Hashing via Non-negative Matrix Factorizations, IEEE International Conference on Acoustics, Speech and Signal Processing, 18 (2006) 225-228.
53. Gürsoy, O., Kutluk, S. ve Günsel B., Negatif Olmayan Matris Ayırıştırma ile İkili Video Kısımlama, IEEE 18.Sinyal İşleme ve İletişim Uygulamaları kurultayı, 2010, Diyarbakır.
54. Elmas V., Gözü Kapalı Kaynak Ayırıştırmada Seyreklik Tabanlı Yöntemler ve Düet algoritması, Yüksek Lisans Tezi , İstanbul Teknik Üniversitesi, İstanbul, 2010.

55. Li T., Convex and Semi-Nonnegative Matrix Factorizations, University of California, Doktora Tezi, California ,2006.
56. Zhang D., Zhou Z., ve Chen S., Non-negative Matrix Factorization on Kernels, Proceedings of the 9th Pacific Rim international conference on Artificial intelligence, 15 (2006) 404-412.
57. Wang H., Nie F., Huang, H. ve Makedon, F., Fast Nonnegative Matrix Tri-Factorization for Large-Scale Data Co-Clustering, IJCAI'11 Proceedings of the Twenty-Second International Joint Conference on Artificial Intelligence, 2 (2011) 1553-1558.
58. Bucak S. S., Artımsal Negatif Olmayan Matris Ayrıştırma ile Gözetleme Türü Videolarda Arkaplan Modelleme, Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi, İstanbul, 2008.
59. Schmidt, M.N. ve Mørup, M., Nonnegative Matrix Factor 2-d Deconvolution for Blind Single Channel Source Separation, Proceedings of ICA , 6 (2006)151-159.

## 8.EKLER

### EK 1

#### İşaret Gürültü Oranı (İGO)

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

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

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

## ÖZGEÇMİŞ

Fatih Yavuz ILGIN, 23.03.1982 tarihinde Erzincan'da doğmuştur. İlköğretim öğrenimini Fırat İlkokulu'nda orta öğrenimini Cumhuriyet Ortaokulu'nda, lise öğrenimini ise Fatih Anadolu Teknik Lisesi'nde 2001 yılında tamamlamıştır. 2002-2003 eğitim öğretim yılında Gazi Üniversitesi Teknik Eğitim Fakültesi Elektronik Öğretmenliği Bölümünü kazanmıştır. 2007 yılında bu bölümden mezun olmuş aynı yıl Erzincan Üniversitesi Meslek Yüksekokulu'nda öğretim görevlisi kadrosunda göreve başlamıştır. 2008 yılında Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsü Elektrik-Elektronik Mühendisliği Anabilim Dalı'nda yüksek lisans öğrenimine başlamıştır. Halen Erzincan Üniversitesi Meslek Yüksekokulu'nda öğretim görevlisi kadrosunda çalışmaya devam etmektedir. Çalışma alanları sayısal işaret işleme ve kör kaynak ayrıştırma üzerinedir.