



Hüsamettin Çelik, Fatih Yavuz Ilgın

Erzincan Binali Yıldırım University, Erzincan-Turkey

hcelik@hotmail.com; fyilgin@erzincan.edu.tr

Yusuf Sevim

Karadeniz Teknik University, ysevim61@gmail.com, Trabzon-Turkey

DOI	http://dx.doi.org/10.12739/NWSA.2019.14.1.1A0428		
ORCID ID	0000-0002-7662-0674	0000-0002-7449-4811	0000-0001-9649-2465
CORRESPONDING AUTHOR	Fatih Yavuz Ilgın		

MÜZİK İŞARETLERİN TEK KANAL KÖR KAYNAK AYRIŞTIRMA İLE AYRIŞTIRILMASI

ÖZ

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 olmadığını belirtmektedir. 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 kaynak işaretinden ayrıştırılabilir. Benzer şekilde bu çalışmada olduğu gibi tek bir mikrofonla kaydedilmiş 2 farklı enstrümental işaret kaynağı birbirinden ayrıştırılabilir. Yapılan bu çalışmada sürekli dalgacık dönüşümü kullanılarak negatif olmayan matris ayırıştırma ile tek kanallı olarak kaydedilen iki işaret birbirinden ayrıştırılmıştır. Önerilen yöntemin başarımlı analizini değerlendirmek için sonuçlar işaret gürültü oranı ve işaret bozulma oranı cinsinden değerlendirilmiştir.

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

AUDIO SIGNAL SEPERATION WITH SINGLE CHANNEL BLIND SOURCE SEPERATION

ABSTRACT

Blind source separation can be defined as estimating each source that makes up this mixture from a data set containing a mixture of more than one signal. Calling this process as blind specifies that there is no additional information about resources. Since it has as many signals as the number of signals to be estimated on the blind source separation, estimating sources is a cost process because of there is only one mixing signal on the single-channel blind source separation process. An unwanted noise attached to any signal can be separated from the source signal thanks to said method. Similarly two different instrumental signal sources recorded with a single microphone can be separated from each other as in this study. In this study, two signals recorded as single channel were separated from each other with non-negative matrix separation using continuous wavelet transform. The results were evaluated in terms of signal noise ratio and signal distortion ratio to evaluate the performance analysis of the proposed method.

Keywords: Blind Source Separation, Cocktail Party Problem, Non-Negative Matrix Factorization, Continuous Wavelet Transform

How to Cite:

Çelik, H., Ilgın, F.Y. ve Sevim, Y., (2019). Müzik İşaretlerin Tek Kanal Kör Kaynak Ayırıştırma İle Ayırıştırılması, **Engineering Sciences (NWSAENS)**, 14(1):26-38, DOI: 10.12739/NWSA.2019.14.1.1A0428.

1. GİRİŞ (INTRODUCTON)

Karışmış biçimde bulunan işaretlerden, bu karışımı oluşturan her bir kaynağın elde edilmesi işlemi kör kaynak ayrıştırma olarak tanımlanmaktadır [1 ve 2]. Kör kaynak ayrıştırma uygulamaları tıp elektroniği ve biyomedikal uygulamalar, sayısal işaret işleme uygulamaları ve radar sistemleri gibi çok farklı uygulamalarda sıklıkla kullanılmaktadır [3]. Biyomedikal uygulamalarda vücuttan alınan herhangi bir biyomedikal işaretin algılanmasında veya ayrıştırılmasında, ortam dinleme gibi ses uygulamalarında ise insan seslerinin birbirinden ayrıştırılmasında kendine yer bulmaktadır. Burada önemli olan ayrıştırılma işlemi yapılırken kaynaklar hakkında ek bir bilgiye ihtiyaç duyulmamasıdır. Bu ayrıştırma işlemi yapılırken karışmış işaret sadece bir adet ise bu işlem Tek Kanal Kör Kaynak Ayrıştırma (TKKA) olarak tanımlanmaktadır. Tek kanal kör kaynak ayrıştırma, doğrusal olarak karışmış halde bulunan bir adet karışım sinyalinden yola çıkarak, karışımı oluşturan kaynakların her birinin tahmin edilmesi işlemidir [3 ve 5]. TKKA'da karışım oranları ve tahmin edilecek işaretler hakkında herhangi bir ön bilgiye ihtiyaç duyulmaması bu yöntemlerin kullanılabilirliğini ve uygulama alanlarını artırmaktadır [6 ve 7].

TKKA problemini çözmek için tek bir alıcı tarafından kaydedilmiş işaretlerin iki boyutlu olarak ifade edilmesi gerekmektedir. Fakat literatürde önerilen metotların birçoğu tek kaynaktan alınan işaretlerin kısa zamanlı fourier dönüşümünü (KZFD) kullanarak, işaretin genlik spektrogramına ayrıştırılması esasına dayanmaktadır [4 ve 8]. Böylece işaret hem zaman hem de genlik bakımından iki boyutlu olarak ifade edilmektedir. Fakat bilindiği üzere KZFD'de pencere boyutu her zaman sabittir. Bu durum ses veya biyomedikal işaretler gibi durağan olmayan sinyallerin iki boyutlu olarak temsil edilmesinde bazı kısıtlar oluşturmaktadır. Bu nedenle KZFD kullanmak yerine sürekli dalgacık dönüşümü kullanmak, ayrıştırılacak işaretin iki boyutlu temsil edilmesinde daha doğru sonuçlar sunacaktır [9 ve 10]. Literatürde TKKA problemi için farklı yöntemler önerilmiştir. Bunlardan biri karışım işaretinin genlik spektrogramının seyrek veri kriterlerini kullanarak çeşitli işaretlerin toplamı olarak ayrıştıran bir yöntemdir [11]. Farklı çalışmalarda ise bir müzik aleti işaretini, bir zaman-frekans ölçütü ile modelleyen bir negatif olmayan matris ayrıştırma algoritması önerilmiştir [9 ve 10]. Bu çalışmada önerilen yöntem ile doğrusal olarak karışmış ve tek kanallı olarak kaydedilen bir karışım işareti, Sürekli Dalgacık Dönüşümü (SDD) kullanılarak skala-zaman uzayına (skalogram) taşındıktan sonra Negatif Olmayan Matris Ayrıştırma (NOMA) algoritması kullanarak ayrıştırma işlemi yapılmaktadır [12]. Çalışmanın temelinde, viyola ile trampet'ten alınan işaret örnekleri tek kanallı ve doğrusal olarak karıştırılmış, önerilen yöntemle ayrıştırılarak işaretler yeniden elde edilmiştir [13 ve 15]. Önerilen yöntemin performans değerlendirmesi yapılırken, dalgacık dönüşümü için paul ve morlet dalgacıkları kullanılmıştır. Ayrıca dalgacık dönüşümü yerine KZFD kullanılarak sonuçlar yorumlanmıştır.

2. ÇALIŞMANIN ÖNEMİ (RESEARCH SIGNIFICANCE)

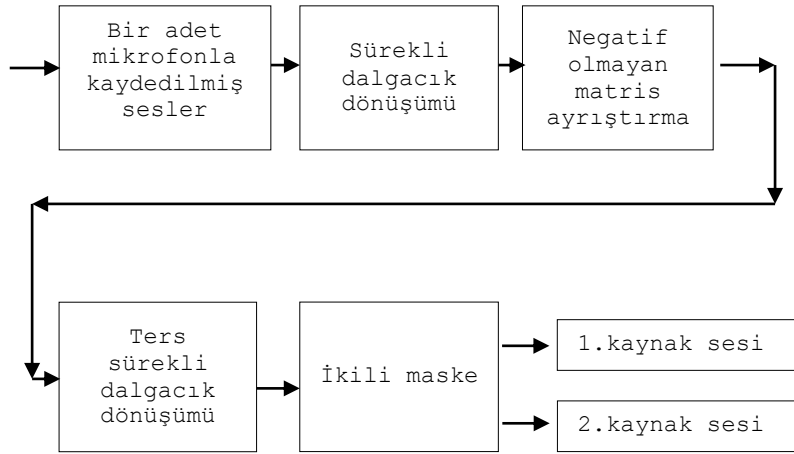
Tek kanal kör kaynak ayrıştırma, özellikle ortam dinleme uygulamalarında karışmış seslerden tek bir kaynağın elde edilmesi ve biyomedikal uygulamalarda tanı belirlemek için önemli bir konudur. Bu yöntemde amaç, karışmış şekilde bulunan iki farklı veriyi birbiriyle en az karışım oluşturacak şekilde ayrıştırmaktır. Diğer çalışmaların aksine yapılan bu çalışmada, negatif olmayan matris ayrıştırma yöntemi için, performans artışı sağlamak adına veriye dalgacık dönüşümü

uygulanmıştır. Böylece yöntemin başarımında gözle görülür bir artış sağlanmıştır.

3. ÖNERİLEN YÖNTEM VE DALGACIK DÖNÜŞÜMÜ

(PROPOSED METHODS AND WAVELET TRANSFORM)

Önerilen yöntemde yapılan işlemler sırası ile Şekil 1’de verilmektedir. Şekil 1’e dikkat edilirse blok diyagrama giren işaret tek mikrofonla kaydedilmiş farklı sesler iken, işlemin en sonunda bu farklı kaynaklara ait sesler elde edilmektedir. Çalışmanın giriş bölümünde de söylendiği üzere bu çalışmayı diğerlerinden ayıran en önemli özelliği işaretlerin iki boyutlu ifade etmek için, KZFD yerine SDD yöntemi kullanılmasıdır. Dalgacık dönüşümü, KZFD’nün sabit pencere genişliği kullanması sebebiyle ortaya çıkan problemleri çözmek için kullanılan bir yöntemdir [16]. Durağan olmayan işaretler için KZFD ‘de sabit pencere genişliği kullanılmasından dolayı, bu tür işaretlerin KZFD kullanılarak ifade edilmesi bazı problemler oluşturmaktadır. Dalgacık dönüşümünün en önemli özelliği, pencere boyutunun değişken olması nedeni ile durağan olmayan işaretler için daha uygun olma özelliğidir [17].



Şekil 1. Önerilen yöntem için blok diyagram
(Figure 1. Block diagram for proposed method)

Bu nedenle dalgacık dönüşümü KZFD’nün yakalayamadığı eğilimlerde çok daha başarılı sonuçlar sunmaktadır. Dalgacık dönüşümü sürekli dalgacık dönüşümü ve ayrık dalgacık dönüşümü olarak temel de ikiye ayrılmakla beraber bu çalışmada sadece sürekli dalgacık dönüşümü kullanılmıştır. Sürekli dalgacık dönüşümü matematiksel olarak Eşitlik (1) ile verilmiştir [8].

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


Burada $x(t)$ dalgacık dönüşümü alınacak olan işaret, t ve τ ise sırasıyla pencere boyutu ve kaydırma katsayısını temsil etmektedir. Ψ^+ ise dalgacık şeklini belirtmektedir. Bu çalışmada SDD işlemi morlet dalgacığı ve paul dalgacığı kullanılarak yapılmıştır. Morlet dalgacığı fonksiyon olarak [16];

$$\Psi_{\text{morlet}}(x) = e^{-x^2/2} \quad (2)$$

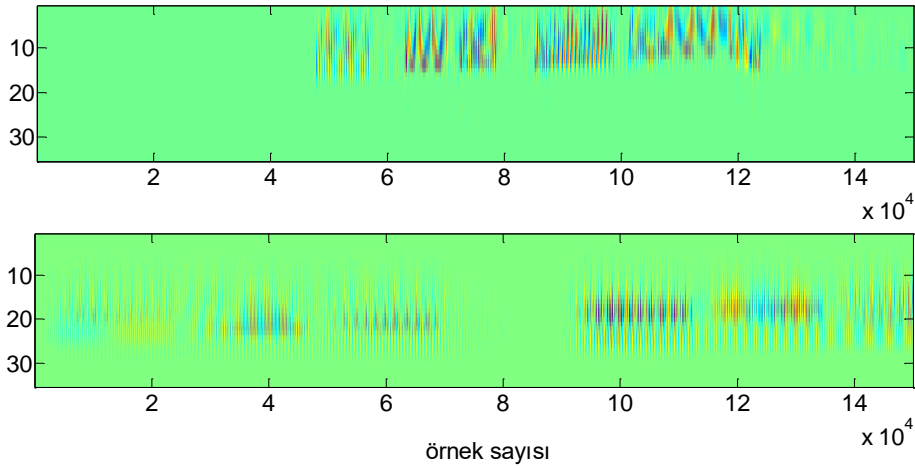
Şeklinde tanımlanırken, paul dalgacığı fonksiyonu ise aşağıdaki gibidir.

$$\Psi_{\text{paul}}(x) = \frac{2^{n!}(1-ix)^{-(n+1)}}{2\pi\sqrt{\frac{(2n)!}{2}}} \quad (3)$$

Bu çalışmada ayrıştırılacak olan kaynak işaretler (Şekil 2) ve bu işaretlere ait dalgacık dönüşümleri (skalogramlar) ise Şekil 3'te verilmektedir. Şekil 3'de verilen dalgacık dönüşümleri morlet dalgacığı kullanılarak oluşturulmuştur. Bu işaretlerden ilk olanı viyola diğeri ise klarnete aittir.



Şekil 1. Viyola ve keman işaretleri
(Figure 2. Violin and trumpet sounds)

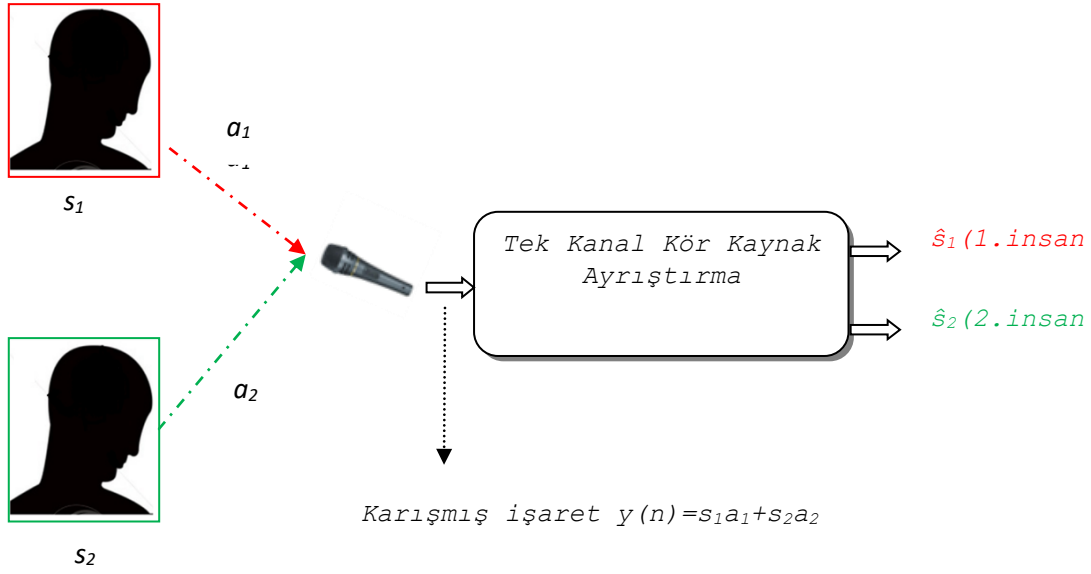


Şekil 2. Viyola ve keman işaretlerine ait skalogramlar
(Figure 3. Scalogram for violin and trumpet sounds)

Giriş bölümünde de bahsedildiği üzere işaretler iki boyutlu ifade edildikten sonra, sıradaki aşama bu skalogramlara TKKA işlemi uygulanmasıdır. Buradaki amaç, tek kanallı bir $y(n)$ karışım işaretinden yola çıkarak s_1 ve s_2 orijinal kaynak sinyallerinin tahmin edilmesidir. Bu problem aşağıdaki Eşitlik 4 ile tanımlanabilir. Burada $y(n)$ bir adet mikrofondan alınan karışmış işaretleri içeren işaret olarak belirtilmektedir [10].

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

Burada $[a_1 \ a_2]$ karışım matrisini belirtmektedir. Karışım matrisi için bu çalışmada anlık karışım modeli kullanılmakla beraber, bu karışım modeli zaman gecikmesi ve yansıma gibi etkileri içermemektedir. Fakat farklı çalışmalarda yansımalı karışım modeli veya gecikmeli karışım modelleri de kullanılmaktadır [10].



Şekil 3. Tek kanal kör kaynak ayırıştırma
(Figure 4. Single channel blind source separation)

4. NEGATİF OLMAYAN MATRİS AYRIŞTIRMA (NONNEGATIVE MATRIX FACTORIZATION)

Bağımsız bileşen analizi (BBA) ve temel bileşen analizi (TBA) gibi yöntemlerin temel amaçlarından birisi de, herhangi bir veriden gereksiz verileri ayıklayarak önemli bilgi bileşenlerini ortaya çıkarmaktır [13 ve 14]. İteratif bir şekilde herhangi bir matrisi çarpanlarına ayırma işlemi gerçekleştirilerek, verinin öz niteliklerini ortaya çıkarmayı amaçlayan negatif olmayan matris ayırıştırma (NOMA) bu amaçla kullanılan yöntemlerden birisidir. NOMA ilk olarak [18] nolu kaynak ile sunulmakla beraber, gerçek ününü [9] çalışma ile kazanmıştır. Diğer birçok yöntemin aksine, NOMA'da ayırıştırılacak olan matris içinde negatif eleman olmama koşulu vardır. NOMA'da, ayırıştırılacak olan veri matrisi n satır büyüklüğünde m adet gözlemden oluşan bir Y matrisi olduğu varsayılırsa, Y matrisini, bir A ile X matrisinin çarpımları şeklinde elde edecek şekilde oluşturmaya çalışır.

$$Y = AX \quad (5)$$

Bu matrislerden biri olan A matrisi karışım matrisi, X matrisi ise kaynak matrisi olarak isimlendirilir. NOMA yönteminin uygulanmasında genelde Eşitlik 6 ile verilen ifade amaç fonksiyonu olarak seçilip minimize edilir [18].

$$F = \sum_{i,j} (Y - AX)_{ij}^2 \quad (6)$$

Eşitlik 6'da verilen yöntemlerle, amaç fonksiyonunu en aza indirmek için çarpımsal güncelleme kuralları önerilmiştir. Bu kurallardan maliyet olarak en azı Öklid uzaklıklı hesaplama yöntemidir. Bu yöntem Eşitlik 7'de verilmiştir.

$$F = \sum_{i,j} (Y - AX)_{ij}^2 = \sum_{i=1}^n \sum_{j=1}^m (Y_{ij} - (AX)_{ij})^2 \quad (7)$$

Burada i ve j alt indisleri sırasıyla ilgili matrislerin satır ve sütunlarını belirtir. Karesel hata fonksiyonunun, amaç fonksiyonu gradyan inişi yöntemi ile eniyilendiğinde A ve X matrisleri için ayrı ayrı çarpımsal güncelleme kuralları bulunabilir. Bu güncelleme kuralları ile Öklid uzaklıklı NOMA algoritması aşağıdaki şekilde gösterilebilir.

```

mxr boyutunda rastgele seçilmiş karışım matrisi oluşturulur
rxn boyutunda rastgele seçilmiş veri matrisi oluşturulur

for i=1: maksimum iterasyon

    (A)ia = (A)ia × [(AXT)ia / ((AXXT) + 10-9)ia]
    (X)ia = (X)ia × [(YAT)ia / ((AXAT) + 10-9)ia]

durdurma kriterine kadar
    
```

Şekil 5. Öklid uzaklıklı NOMA algoritması
(Figure 5. NOMA algorithm with euclidean distance)

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. NOMA yöntemi için öklid uzaklıklı algortimanın yanısıra Kullback-Leibler Yakınsama Tabanlı Lee ve Seung Algoritması da önerilmiştir. Bu yöntem aşağıda verilen eşitlik ile tanımlanır [19].

$$D(A||B) = \sum_{ij} \left[A_{ij} \log \frac{A_{ij}}{B_{ij}} - A_{ij} + B_{ij} \right] \quad (8)$$

Güncelleme kuralları ise Eşitlik 9 ve Eşitlik 10 'da belirtilmiştir.

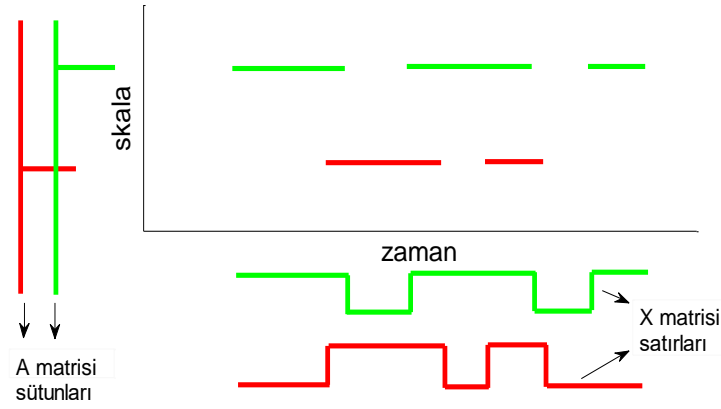
$$(X)_{ia} \leftarrow (X)_{ia} \frac{\sum_i (A_{ia} Y_{i\mu} / (AX)_{i\mu})}{\sum_k A_{ka}} \quad (9)$$

$$(A)_{ia} \leftarrow (A)_{ia} \frac{\sum_\mu (A_{a\mu} Y_{i\mu} / (AX)_{i\mu})}{\sum_v A_{av}} \quad (10)$$

Kullback-Leibler Yakınsama Tabanlı Lee ve Seung algoritmasında işlem maliyetinin fazla olması nedeni ile Öklid uzaklıklı NOMA daha fazla tercih sebebi olmaktadır [9].

4.1. Skalogramın Ayrıştırılması (Scalogram Factorization)

NOMA skalogramı ayrıştırırken skala ve zaman ekseninde ayrışım yapmaktadır. Aşağıdaki şekilde skalograma NOMA algoritması uygulanması gösterilmiştir [6].




Şekil 6. NOMA ile skalogramın ayrıştırılması
(Figure 6. Scalogram factorization with NOMA)

NOMA ayrıştırılacak olan Y skalogramını A ve X matrislerinin çarpımı şeklinde iki matrisin çarpımı şeklinde Eşitlik 11'de olduğu gibi iki matrisin çarpımı şeklinde ayrıştırır.

$$[Y]_{64 \times 150000} = [A]_{64 \times 4} \times [X]_{4 \times 150000} \quad (11)$$

Burada görüldüğü gibi A ve X matrislerinin çarpımları boyut olarak A matrisini vermektedir. Ayrıca skalogramın boyutu olan 1500000 değeri örnek sayısını belirtirken, 64 ise sürekli dalgacık dönüşümü uygulanırken seçilen pencere boyutunu göstermektedir. Pencere boyutu işareti tam olarak temsil edecek şekilde seçilmelidir aksi takdirde bilgi kaybı oluşmaktadır. Şekil 7'de ise tek mikrofonla anlık olarak karıştırılmış kaynak işaretleri ve bu işarete ait morlet skalogramı verilmiştir.




Şekil 7. Karışmış kaynak işaretleri ve bu işaretlere ait skalogram
(Şekil 7. Mixed source signals and it's scalograms)

Bu işlemden bir sonraki adım Şekil 8'de verilen yöntemle skalogramı zaman ekseninde de ayrıştırmak ve her bir kaynağa ait skalogramı elde etmektir. Bu işlem için A matrisinin birinci sütunu karışım skalogramının her bir satırı ile ayrı ayrı noktasal çarpım işlemine tabi tutulur. Böylece skalogramda her bir kaynağın zaman eksenindeki yeri de tahmin edilmiş olmaktadır. Her bir kaynağa ait skalogram bulunduktan sonra işareti yeniden elde etmek için ikili

maske oluşturulmalıdır. İkili maske oluşturulurken Eşitlik 12 ile verilen matematiksel yöntem kullanılmaktadır.

$$M_{ij} = \begin{cases} 1 & \text{eğer } SKAL(a)_{ij} \geq 0.5 \\ 0 & \text{eğer } SKAL(a)_{ij} < 0.5 \end{cases} \quad (12)$$

Böylece Şekil 7'de verilen ikili maskeyi oluşturmuş olmaktadır. İkili maskeyi oluşturduktan sonraki adım bu maskeyi Şekil 7'de verilen karışım işaretinin skalogramı ile noktasal çarpım işlemine tabii tutulmasıdır. Böylece karışım skalogramında 1'lerin karşısına gelen veriler alınır diğerleri kaybolur ki kaybolan bu veriler kaynaklardan birine ait verilerdir.




Şekil 8. Birinci kaynak için ikili maske
(Figure 8. Binary mask for first signal)

Bu işlemler sonunda elde edilen skalogram sadece tek kaynağa ait skalogram olduğundan ters sürekli dalgacık dönüşümü alınırsa kaynaklardan birine ulaşılmış olur. Diğer kaynağın tahmin edilmesi için aynı işlemler tekrar uygulanır [6].

5. DENEYSEL ÇALIŞMALAR (EXPERIMENTAL STUDY)

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 kullanılarak, üç farklı dalgacık dönüşümü ile ayrıştırılmıştır. Önerilen algoritmanın başarımlarını analizini daha iyi yapabilmek için sonuçlar işaret gürültü oranı (SNR) ve işaret girişim oranı (SIR) cinsinden ölçülmüş ve sonuçlar karşılaştırılmıştır. SNR ve SIR parametrelerinin nasıl hesaplandığı aşağıdaki eşitliklerle verilmiştir [4]. Ayrıca yöntemlerin çalışma şeklinin daha anlaşılır olması açısından Şekil 9 verilmiştir.




Şekil 9. SNR ve SIR hesaplama şekli
(Figure 9. Calculation of SNR and SIR)

SNR ve SIR değerleri ise Eşitlik 13 ve Eşitlik 14 ile tanımlanmaktadır.

$$\text{SNR} = 10 \log_{10} \frac{E\{s^2\}}{E\{(y-s)^2\}} \quad (13)$$


$$\text{SIR} = 10 \log_{10} \frac{\sum(y^2)}{\sum_{i \neq j} \sum_t(y^2)} \quad (14)$$

Burada s , orijinal kaynak işaretini, y ise ayrıştırılmış işareti tanımlamaktadır. Ayrıştırılan kaynak işaretlerinden biri Gauss gürültü olduğundan, ayrıştırılan işaret içinde gürültü işaretinin olup olmadığını belirlemek için SNR değerine bakılabilir. Aynı şekilde SIR ise ses kalitesinin bir ölçüsü olarak Sinyal-Parazit Oranını (SIR) belirlemektedir. Şekil 10'da görsel olarak ayrıştırılan ve kaynak işaret şekillerini içermektedir. Görüldüğü gibi ayrıştırılan işaretlerin genlik ekseninde azalma görülmektedir. Fakat kör kaynak ayrıştırma probleminin çözümünde, ayrıştırılan işaretin genliğindeki azalma önemli olmamakla birlikte, temel bir normalizasyon işlemi ile bu problem çözülebilir. Fakat şekle bakıldığında ayrıştırılan işaretlerin orijinallerine oldukça yakın olduğu da görülmektedir. Özellikle sonuçların bu kadar net tahmin edilmesi karışım matrisi ile de doğrudan ilgilidir. Bu çalışmada Monte Carlo analizi kullanılarak rasgele bir karıştırma matrisi oluşturulduğu için, her defasında işaretler bu kadar net görülmeyebilir. Fakat işaretlerin nasıl ayrıştırıldığını daha açık görmek için, Şekil 10 en başarılı ayrıştırmalardan bir tanesinden alınmıştır.



Şekil 10. Orijinal işaretler ve ayrıştırılan işaretler
(Figure 10. Original signals and seperated signals)

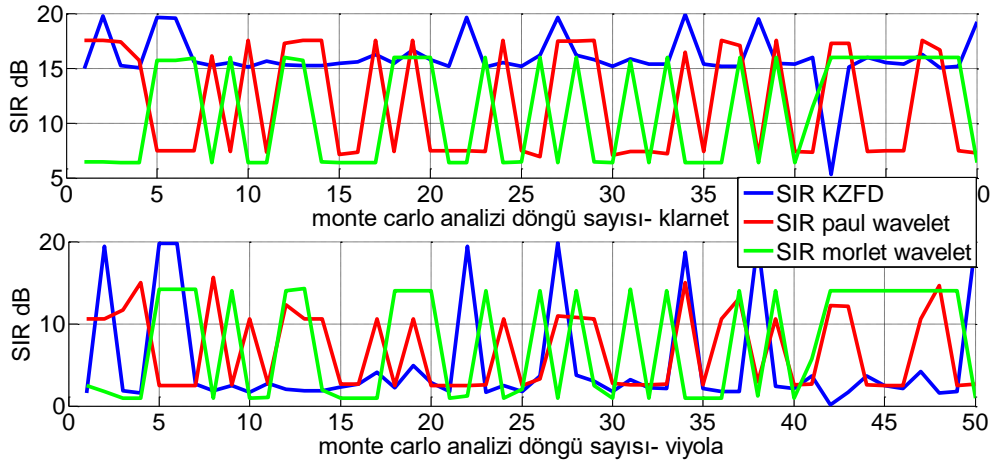
Şekil 11' de ise monte carlo analizi sonuçları işaret gürültü oranı cinsinden verilmiştir. Burada algoritmalar 50 kere çalıştırılarak her defasında farklı karışım matrisi kullanılmıştır. Ayrıca Şekil 11'de KZDF ve iki farklı dalgacık dönüşümünün (Paul ve Morlet) ayrıştırma performansları beraber incelenmiştir. Sonuçlarda dalgacık dönüşümünün yansira işaretin kısa zamanlı fourier dönüşümü de alınarak sonuçlara katkısı görülmektedir. Giriş bölümünde bahsedildiği gibi kısa zamanlı fourier dönüşümünde sabit pencere genişliği kullanılmasından dolayı durağan olmayan işaretlerin ifade edilmesinde zayıf kalmaktadır. Bu durumun algoritma sonuçlarına olumsuz bir şekilde yansıdığı görülmektedir. Ayrıca Şekil 11'e dikkatli bakıldığında önerilen yöntemin viyola işaretini daha başarılı ayrıştırdığı görülmektedir. Klarnet işaretinde ise seslerin ilişkinin aynı anda başarılı şekilde ayrıştırılamadığı görülmektedir. Bunun nedeni işaretin olasılık dağılımı olarak gösterilebilir.



Şekil 11. SNR cinsinden Monte carlo analizi sonuçları
(Figure 11. Results for Monte carlo (SNR))

Şekil 12'de ise monte carlo analizi sonuçlarını SIR cinsinden ifade etmektedir. Burada dikkat edilmesi gerek nokta kısa zamanlı fourier dönüşümünün daha başarılı sonuçlar vermesidir. Ayrıca Şekil 11 ve Şekil 12'de göze çarpan önemli bir nokta işaretler ayrıştırılırken bir işaretin doğru ayrıştırılması diğer işaretin daha kötü ayrıştırıldığını göstermektedir. Ayrıca Şekil 12 için klarnet işaretinin KZDF ile diğerlerine oranla çok daha başarılı

ayrıştırıldığını görmekteyiz. Bu durum işaretin olasılık dağılımı dalga şekli ve genliği ile ilgili olmaktadır.



Şekil 12. SIR cinsinden Monte carlo analizi sonuçları
(Figure 12. Results for Monte carlo (SIR))

Başka bir ifadeyle grafik sonuçları bize her iki işaretin aynı anda doğru bir şekilde ayrıştırılmadığını göstermektedir. Önerilen yöntemin dezavantajlarından en önemlisi bu durumdur. Bu durum farklı enstrümental işaretler için farklı olabilen bir dolgudur. Bunu enstrümental işaretlerin birbirleri ile olan ilinti (korelasyon) katsayıları da etkilidir.

6. SONUÇ (RESULT)

Bu çalışmada negatif olmayan matris ayrıştırma yöntemi kullanılarak tek kanal kör kaynak ayrıştırma problemi incelenmiştir. Tek kanal kör kaynak ayrıştırma yöntemlerinde farklı kaynaklar sadece tek kanallı olarak kaydedildiğinden, ayrıştırma yapabilmek için bu işaretleri iki boyutlu olarak ifade etmek gereklidir. Yapılan önceki çalışmalara bakıldığında işareti iki boyuta taşımak için genellikle KZFD kullanıldığı görülmektedir. Fakat KZDF sabit pencere genişliği kullandığından ses işareti gibi durağan olmayan işaretleri modellemek için uygun bir yöntem değildir. Bu nedenle bu çalışmada önceki çalışmaların aksine, işareti zaman ve skala ekseninde ifade edebilmek için, sürekli dalgacık dönüşümü kullanılmıştır. Bu amaçla, yapılan çalışmada iki adet enstrümental işaret kaynağı tek kanallı ve anlık karışım modeli ile karıştırılarak, önce skalogram biçimine getirilip NOMA algoritması uygulanmış, sonuçlar SNR ve SIR değeri cinsinden yorumlanmıştır. Sonuçlarda özellikle SNR açısından dalgacık dönüşümünün KZFD'ne göre daha başarılı olduğu görülmüştür. Bu durumun sebebi ise durağan olmayan işaretleri ifade etmek için KZFD'nün fazla verimli olmamasıdır.

NOT (NOTICE)

Bu çalışma, 11-13 Nisan 2018 tarihinde Antalya'da düzenlenen 1st International Symposium on Innovative Approaches in Scientific Studies Konferansında sözlü bildiri olarak sunulmuş ve yeniden yapılandırılmıştır.

KAYNAKLAR (REFERENCES)

- [1] Niknazar, M., (2014). Blind Source Separation of Underdetermined Mixtures Of Event-Related Sources. Signal Processing: Cilt:101, Sayı:8, ss:52-64.
- [2] Nikunen, J.T. and Virtanen, T., (2014). Direction of Arrival Based Spatial Covariance Model for Blind Sound Source Separation IEEE/ACM Trans. Audio Speech Lang. Process., Cilt:22, Sayı:3, ss:727-739.
- [3] Pengju, H., Tingting, S., Wenhui, L., and Weibiao, Y., (2018). Single Channel Blind Source Separation on The Instantaneous Mixed Signal Of Multiple Dynamic Sources. Mechanical Systems and Signal Processing. Cilt:113, ss:22-35.
- [4] Smaragdis, P., (2004). Non-negative Matrix Factor Deconvolution; Extraction of Multiple Sound Sources from Monophonic Inputs. Lecture Notes in Computer Science, Cilt:319, Sayı:5, ss:494-499.
- [5] Schmidt, M.N. and Olsson, R.K., (2006). Singlechannel Speech Separation Using Sparse Non-negative Matrix Factorization, International Conference on Spoken Language Processing (INTERSPEECH), Glasgow.
- [6] Kirbız, S. ve Günsel, B., (2009). Negatif Olmayan Matris Ayırıştırma ile Tek-Kanaldan Algısal Ses Ayırıştırma, IEEE, Antalya.
- [7] He, P., She, T., Li, W., and Yuan, W., (2018). Single Channel Blind Source Separation on The Instantaneous Mixed Signal of Multiple Dynamic Sources. Mechanical Systems and Signal Processing. Sayı:113, ss: 22-35.
- [8] Schmidt, M.N., (2008). Single-Channel Source Separation Using Non-negative Matrix Factorization, Doktora Tezi, Technical University of Denmark.
- [9] Mateo, C. and Talavera, J.A., (2018). Short-time Fourier transform with the window size fixed in the frequency domain. Digital Signal Processing. Cilt:77, ss:13-21.
- [10] Mateo, C. and Talavera, J.A., (2018). Short-Time Fourier Transform with the Window Size Fixed in the Frequency Domain (STFT-FD): Implementation. SoftwareX, Cilt:8, ss:5-8.
- [11] Choukri, D. and Mehdi, A., (2017). A New Data-Driven Deep Learning Model for Pattern Categorization using Fast Independent Component Analysis and Radial Basis Function Network. Taking Social Networks resources as a case Procedia Computer Science, Cilt:113, ss:97-104.
- [12] Vanluyten, B., Jan, C., and Bart De Moor, B.M., (2008). Structured Nonnegative Matrix Factorization with Applications to Hidden Markov Realization and Clustering. Linear Algebra and its Applications, Cilt:429, Sayı:7, ss:1409-1424.
- [13] Cardoso, J.F. and Comon, P., (1996). Independent Component Analysis, A Survey of Some Algebraic Methods, Proc. ISCAS96, ss:93-96.
- [14] Comon, P., (1994). Independent Component Analysis: A New Concept, Signal Processing, 36, 287-314.
- [15] O'Grady, P.D., Pearlmutter, B.A., and Rickard, S.T., (2005). Survey of Sparse and Non-sparse Methods in Source Separation, IJIST International Journal of Imaging Systems and Technology, 18, ss: 78-85.
- [16] Kanailal Mahato K., (2018). the composition of fractional hankel wavelet transform on some function spaces. Applied Mathematics and Computation, Cilt:337, ss:76-86.
- [17] Dai, H., Zheng, Z., Wang, W., (2018). A new ractional wavelet transform. Communications in Nonlinear Science and Numerical Simulation, Sayı:44, ss:19-36.



-
- [18] Lee, D. and Seung, H., (1999). Learning the Parts of Objects by Nonnegative Matrix Factorization. *Nature* Sayı:401, ss:788-791.
- [19] Vasiloglou, N., Gray, A.G., and Anderson, D.V., (2009). Non-Negative Matrix Factorization, Convexity and Isometry. *Computer Science, Artificial Intelligence*.