Makale Türü: Araştırma Makalesi
Makale Gönderilme Tarihi: 21.10.2024
Kabul Tarihi: 9.12.2024

Değişimli Oto-Kodlayıcılar kullanarak Diyalog Geliştirme[1]
Dialogue Enhancement using Variational Autoencoders

Serap Kırbız

Mühendislik Fakültesi, Elektrik Elektronik Mühendisliği Bölümü
MEF Üniversitesi
kirbizs@mef.edu.tr
0000-0001-7718-3683

Özet

Bu makalede, kaynak ayrıştırma algoritmalarından faydalanarak birden fazla kaynaktan oluşan ses kayıtlarında konuşma işaretlerini güçlendirmek amacıyla bir yöntem sunulmaktadır. Konuşma sesleri ve diğer sesler arasındaki doğru dengeyi sağlamak, dinleyici şikayetleri arasında sıkça dile getirilen önemli bir sorun olarak öne çıkmaktadır. Bu çalışmada, diyalog içeren ses kayıtlarından diyalogların ayrıştırılmasında negatif olmayan gürültü giderici oto kodlayıcı modelleri kullanılmakta ve bu diyaloglar, diğer seslerle farklı oranlarda yeniden birleştirerek, kullanıcı tercihlerine uygun bir dinleme deneyimi sunulmaktadır. Önerilen yöntem, akan veri üzerinde çalışabilme özelliğine sahip olup, televizyon programları gibi gerçek zamanlı uygulamalara da uyarlanabilmektedir.
Anahtar kelimeler: kaynak ayrıştırma, diyalog geliştirme, derin öğrenme

Abstract

The paper proposes a method to enhance speech signals in audio recordings consisting of multiple sources by using source separation algorithms. Achieving the right balance between seç sounds and other sounds is a frequently mentioned issue among listener complaints. In this study, non-negative denoising variational autoencoder models are used to separate dialogues from audio recordings containing dialogues, and these dialogues are remixed with other sounds at different rates to provide a listening experience that suits the user's preferences. The proposed method has the ability to work on streaming data and can also be adapted to real-time applications such as television programs.
Keywords: source separation, dialogue enhancement, deep learning

1. Giriş

Bu makalede, gürültülü karışım işaretlerindeki diyalogları ayrıştırmak için derin öğrenme tabanlı modeller kullanılarak, kaynaklar istatistiksel olarak incelenmekte ve kaynak ayrıştırma için yeni yöntemler geliştirilmektedir. Geleneksel kaynak ayrıştırma yöntemleri genellikle karışım işaretinin genlik spektrogramını giriş olarak kullanır ve bu karışımı, kendisini oluşturan kaynak işaretlerine ayırmayı hedefler. Ayrıştırılacak işaretler negatif olmayan matrisler olarak ele alındığından, bu alanda yaygın bir yaklaşım olan Negatif Olmayan Matris Ayrıştırma (NOMA) [1], önemli bir rol oynamaktadır. Matris ayrıştırmanın temel amacı, $\mathbf{X} \in \mathbb{R}_+^{M\times N}$ şeklindeki giriş matrisini $\mathbf{W} \in \mathbb{R}_+^{M\times K}$ ve $\mathbf{H} \in \mathbb{R}_+^{K\times N}$ matrislerine ayrıştırmaktır. Bu işlemde, **H,** "katkılar", **W** ise "sözlükler" olarak adlandırılır ve hedef, **X** matrisinin doğru bir şekilde geri çatılmasıdır:

$$\mathbf{X} \approx \hat{\mathbf{X}} = \mathbf{WH}. \quad (1)$$

NOMA ile **X** karışım işaretinin temsili için, *K* kertesinde **H** katkıları ve **W** şablonlarının sözlüğü elde edilmektedir. NOMA [2] kullanılarak gerçekleştirilen eğitimli kaynak ayrıştırmada ise, öncelikle her bir kaynak işaretinin temsili için ayrı bir **W** sözlüğü öğrenilmektedir. Sonrasında, bir karışım işareti kaynaklarına ayrıştırılmak istendiğinde, sözlükler bir araya getirilerek, her bir kaynağın katkısı kestirilmektedir.

Önerilen çalışmada, tek kanallı kaynak ayrıştırma problemini çözmek için zayıf etiket denetimine dayalı "negatif olmayan gürültü değişimli oto-kodlayıcılar ve oto kod-çözücüler" kullanılmaktadır. Karışımı oluşturan kaynakları kestirmek için toplamsal bileşenlerin kullanılması, yöntemin NOMA' ya benzerliğini ortaya koysa da önerilen model, doğrusal şablonlar yerine doğrusal olmayan şablonlar ve etkili sinir ağı modelleri kullanarak daha esnek bir çözüm sunmaktadır.

Bunun yanı sıra, önerilen kaynak ayrıştırma yöntemi, hedeflenen işlevlerin gereksinimlerine uygun kaynak modellerini birleştirmek ve eşleştirmek amacıyla derin üretici modellerini kullanmaktadır [3]. Bu yaklaşımla, her kaynak için zayıf denetimli eğitimle değişimli oto-kodlayıcılar [4, 5] öğrenilmiş ve değişimli oto-kod çözücüler [6] gibi derin saklı-değişken modeller süreçte kullanılmıştır. [4] ile verilen çalışmamızda hem eğitim hem de test aşamalarında kaynakların sınıf etiketleri bilinirken, [3] ile verilen çalışmamızda ise, kaynak ayrıştırmanın yanı sıra karışımı oluşturan kaynakların sınıf etiketlerinin tahmini de gerçekleştirilmiştir.

Bu makalede önerilen yöntem, iki temel işlevi yerine getirmek için tasarlanmıştır: kaynak ayrıştırma, diyalog geliştirme. Deneyler, farklı eğitim stratejileri ve farklı sınıf sayıları için farklı veri tabanlarında gerçekleştirilmiştir.

Bu çalışmadaki katkılar aşağıdaki şekilde özetlenebilir:

- Kaynak işaretlerine erişim sağlanmadığı ve yalnızca sınıf etiketlerine sahip olunduğu bir senaryo için negatif olmayan bir Değişimli Oto Kodlayıcı (VAE) modeli ile kaynak ayrıştırma önerilmektedir.
- Kaynak işaretleriyle ilgili sınıf etiketlerine ihtiyaç duyulmadan, Değişimli Oto Kod Çözücü (VAD)

[1] Bu çalışma EEEAG/215E076 numaralı araştırma projesi kapsamında TÜBİTAK tarafından desteklenmektedir.

modeli ile sınıf etiketi kestirimi ve kaynak ayrıştırma eş zamanlı gerçekleştirilebilir. Modelde, yaklaşık dağılım parametreleri rasgele başlatılmakta ve gradyan-temelli yöntemlerle optimizasyon sağlanmaktadır.

- Zaman bölgesinde ses kalitesini ölçen Ortalama Karesel Hata (MSE), Ölçek-Değişmez İşaret-Gürültü-Oranı (SI-SNR) ve İşaret-Gürültü- Oranı (SNR) gibi başarım ölçütlerinin eğitim esnasında kayıp fonksiyonu olarak kullanılması sağlanmıştır.
- Geliştirilen yöntem, gerçek zamanlı olarak çalışabilme yeteneğine sahiptir.
- Önerilen modellerin iyi bir başarım elde edebilmesi için en az üç sınıftan gözleme ihtiyaç olduğu gösterilmektedir.

2. Ön Bilgi

Kaynak ayrıştırma problemlerinde, derin öğrenme yaklaşımları yaygın olarak uygulanmaktadır [7]. Bu yaklaşımlar, genellikle karışım işaretlerini alarak, bu işaretlerden kaynak işaretlerini ayırmayı hedefleyen gürültü ayırıcı değişimli oto-kodlayıcılar (VAE) gibi derin öğrenme modellerini kullanmaktadır. Derin öğrenme modellerinin başarılı bir şekilde eğitilebilmesi için büyük miktarda etiketli veri gereklidir. Ancak, zayıf denetleme, etiketli verilerin eksik olduğu veya yalnızca sınıf bilgisi ile çalışılan senaryolarda, yüksek soyutlama düzeyine sahip bilgi ve gürültü içerdiği için etkili bir yaklaşım olarak öne çıkmaktadır.

Bu çalışmada, bilgilendirilmiş kaynak ayrıştırma [8] ile ilişkili derin öğrenme yöntemleri kullanılmıştır. Önerilen çalışma, eğitim için kaynak işaretlerine erişimin olmadığı, sadece kaynakların ait olduğu sınıf bilgilerine erişimin olduğu bir senaryoyu ele almaktadır. Bu durum, birçok karışım işareti ve bu karışımların içerdiği kaynakların etiketleri gözlemlendiğinde, karışım işaretinde her bir kaynağın hangi bölümlerde yer aldığına dair sezgisel tahminlerin yapılmasına olanak tanır.

2.1. Değişimli Oto Kodlayıcılar

Değişimli Oto-Kodlayıcılar (VAE) [5], olasılıksal üretici modellerinin oluşturulmasında yaygın bir şekilde kullanılmaktadır. VAE' nin temel yapısında, gizli değişken $\mathbf{z}$ için $p_\theta(\mathbf{z}) = \mathcal{N}(\mathbf{z}|\mathbf{0},\mathbf{I})$ Gauss önsel dağılımı kullanılır ve parametresi θ olan $p_\theta(\mathbf{z}) = \mathcal{N}(\mathbf{z}|\mathbf{0},\mathbf{I})$ olasılıksal kodlayıcı modeli ile parametresi ϕ olan olasılıksal $q_\phi(\mathbf{z}|\mathbf{x})$ kod çözücü modeli tanımlanabilir. Sinir ağı modellerine dayalı kodlayıcı-kod çözücü çifti için, genel amaçlı bir fonksiyon tahmin modeli kullanılabilir. N gözlemden oluşan $\boldsymbol{\mathcal{X}} = \{\mathbf{x}^{(i)}\}_{i=1}^{N}$ eğitim veri kümesi, bileşen olabilirliğinin değişimli alt sınırının olasılıksal bayır çıkışı ile en büyüklenmesi sonucunda modelin ϕ ve θ parametrelerini kestirebilir:

$$\mathcal{L}(\theta,\phi|\mathbf{x}^{(i)}) = -D_{KL}\big(q_\phi(\mathbf{z}|\mathbf{x})\|p_\theta(\mathbf{z})\big) + \mathbb{E}_{q_\phi(\mathbf{z}|\mathbf{x}^{(i)})}\big[\log p_\theta(\mathbf{x}^{(i)}|\mathbf{z})\big]. \quad (2)$$

(2) ile verilen ifadede, D_{KL}, Kullback-Leibler (KL) ıraksayıdır. Önsel $p_\theta(\mathbf{z})$ dağılımı ve sonsal $q_\phi(\mathbf{z}|\mathbf{x})$ kestiriminin Gauss varsayımı altında, analitik yöntemlerle değişimli bir alt sınır elde edilebilmektedir. Bununla birlikte, KL ıraksayı, $q_\phi(\mathbf{z}|\mathbf{x})$ sonsal kestirimi üzerinde $p_\theta(\mathbf{z})$ önsel dağılımını zorlayan bir düzenleyici işlevi görmektedir. Geri çatma hatasını içeren $\log p_\theta(\mathbf{x}^{(i)}|\mathbf{z})$ dağılımının beklentisi, yeterince büyük bir veri kümesi mevcutsa, $q_\phi(\mathbf{z}|\mathbf{x}^{(i)})$ sonsal dağılımından tek bir örnek kullanılarak hesaplanabilir. Yeniden parametrelendirme ile $q_\phi(\mathbf{z}|\mathbf{x}^{(i)})$ dağılımından örnekleme yapılabilmektedir. Kodlayıcı fonksiyonunun çıktıları, $\mu(i)$ ve $\sigma(i)$ olacak şekilde, izotropik bir Gauss dağılımı varsayılmaktadır:

$$q_\phi(\mathbf{z}|\mathbf{x}^{(i)}) = \mathcal{N}(\boldsymbol{z}|\mu^{(i)}, \sigma^{2(i)}\mathbf{I}). \quad (3)$$

(3) ile verilen ifadede, $\epsilon \sim \mathcal{N}(\epsilon|\mathbf{0},\mathbf{I})$ yardımcı gürültü değişkeni, $\odot$ ise eleman elaman çarpma işlemidir. Yeniden parametrelendirme $\mathbf{z} = \mu + \sigma \odot \epsilon$ şeklinde yapılabilmektedir.

Önsel $p_\theta(\mathbf{z})$ dağılımının izotropik Gauss varsayımı altında, ayrık ve bağımsız gizli birimler teşvik edilmektedir. β −VAE [6], orijinal VAE' nin bir uzantısı olup, $\mathbf{z}$ gizli değişkeninin sınırlandırılmasıyla, daha ayrıştırılmış temsiller elde edilmesini sağlar. β −VAE' nin orijinal VAE' den tek farkı, alt sınırda kullanılan β katsayısıdır:

$$\mathcal{L}_\beta(\theta,\phi|\mathbf{x}^{(i)}) = -\beta D_{KL}\big(q_\phi(\mathbf{z}|\mathbf{x})\|p_\theta(\mathbf{z})\big) + \mathbb{E}_{q_\phi(\mathbf{z}|\mathbf{x}^{(i)})}\big[\log p_\theta(\mathbf{x}^{(i)}|\mathbf{z})\big]. \quad (4)$$

(4) ile verilen ifadede $\beta = 1$, (2) eşitliğindeki alt sınır iken, $\beta > 1$ durumunda gizli değişken daha fazla kısıtlanmakta ve geri çatma kalitesine daha az ağırlık verilmektedir.

Oto-kodlayıcı kullanılarak gerçekleştirilen kaynak ayrıştırmada $\mathbf{x}^{(i)}$ karışımında bulunan, $\mathbf{s}_k^{(i)}$ orijinal kaynak işareti, gürültü giderici oto-kodlayıcı aracılığıyla tahmin edilebilmektedir:

$$\hat{\mathbf{s}}_k^{(i)} = f_{\theta_k}\left(g_{\phi_k}(\mathbf{x}^{(i)})\right),\ f_{\theta_k}(\cdot) \geq 0. \quad (5)$$

(5) ile verilen ifadede $g_{\phi_k}(\cdot)$ ve $f_{\theta_k}(\cdot)$, k. kaynak sınıfı için kodlayıcı ve kod çözücü çiftini temsil eder. $\mathbf{x}^{(i)}$ ve $\mathbf{s}^{(i)}$, sırasıyla karışım işaretinin ve karışımı oluşturan orijinal işaretlerin genlik spektrogramları olmak üzere $\boldsymbol{\mathcal{X}}_s = \{(\mathbf{x}^{(i)}, \mathbf{s}^{(i)})\}_{i=1}^{N}$ eğitim veri kümesinde, (6) eşitliği ile verilen maliyet fonksiyonu kullanıldığında [9] yaklaşımına ulaşılabilir. Ancak, kayıp fonksiyonu olarak kare hata değil de genelleştirilmiş KL ıraksayı seçilmelidir.

$$D_{GKL}(\mathbf{s}_k^{(i)} \| \hat{\mathbf{s}}_k^{(i)}) = \sum_j \mathbf{s}_{k_j}^{(i)} \log \frac{\mathbf{s}_{k_j}^{(i)}}{\hat{\mathbf{s}}_{k_j}^{(i)}} - \mathbf{s}_{k_j}^{(i)} + \hat{\mathbf{s}}_{k_j}^{(i)}. \quad (6)$$

(6) eşitliğinde, j, $\mathbf{s}_k^{(i)}$ kaynak işaretinin elemanlarının indeksidir. Eğitim kümesi $\boldsymbol{\mathcal{X}}_h = \{(\mathbf{x}^{(i)}, \mathbf{h}^{(i)})\}_{i=1}^{N}$ olup, K sınıf için kaynak sınıf etiketleri $\mathbf{h}^{(i)} \in \{0,1\}^K$ ile ifade edilmektedir. Önerilen çalışmada, $\hat{\mathbf{x}}^{(i)}$ kaynaklarını kestirmek için $\mathbf{s}_k^{(i)}$ orijinal kaynakları yerine sadece $h_k^{(i)}$ kaynak etiketleri kullanılmaktadır:

$$\hat{\mathbf{x}}^{(i)} = \sum_{k=1}^{K} \hat{\mathbf{s}}_k^{(i)} h_k^{(i)}. \quad (7)$$

$\hat{\mathbf{s}}_k^{(i)}$ kaynaklarını kestirmek için, kayıp fonksiyonu olarak (6) ile verilen $D_{GKL}(\mathbf{s}_k^{(i)} \| \hat{\mathbf{s}}_k^{(i)})$ kullanılmaktadır. Böylece, $\mathbf{x}^{(i)}$ karışımının geri çatılması için sadece kaynak etiketleriyle ilişkili oto-kodlayıcıların kullanılması hedeflenmektedir. Geliştirilen model, NOMA yöntemine benzer şekilde karışımı ayrıştırmak amacıyla toplamsal bileşenleri kullanır. Ancak, bileşenleri temsil etmek için NOMA' da sadece doğrusal şablonlar alınabilirken, önerilen çalışmada doğrusal olmayan

şablonlar ve daha etkili sinir ağı yapılarıyla esnek bir çözüm sunulmaktadır. Ayrıca, modelde her bir kodlayıcı, diğer kaynaklara ilişkin gürültüyü ihmal edip, yalnızca kendi sınıfına ait öznitelikleri öğrenirken; kod çözücüler de ilişkili kaynak işaretlerini geri çatmaktadır.

Şimdiye kadar, modelin standart oto-kodlayıcıları baz aldığı varsayılmıştır. Bu çalışma, β −VAE'nin, Poisson kod çözücü ile kullanılması önerilmektedir:

$$p_\theta\left(\mathbf{x}^{(i)}|\mathbf{z}\right) = \mathcal{PO}\left(\mathbf{x}^{(i)}|\iota = \hat{\boldsymbol{x}}^{(i)}\right). \tag{8}$$

(8) ile verilen ifadede ι, model çıktısıdır. Poisson dağılımının genlik spektrogramını modellemek için kullanılması, KL ıraksayının normalize edilmeden kullanımına karşılık gelmektedir [10].

Ayrıştırılmış kaynakları zaman bölgesinde elde etmek için karışımın işaretinin fazı ile yumuşak Wiener filtresi kullanılır:

$$\hat{\mathbf{y}}_t^{(i)} = \text{STFT}^{-1}\left(\frac{\left(\hat{\mathbf{s}}_t^{(i)}\right)^2}{\sum_c\left(\hat{\mathbf{s}}_c^{(i)}\right)^2} \odot \mathbf{x}^{(i)} \odot e^{j\boldsymbol{\Phi}}\right). \tag{9}$$

(9) eşitliğinde $\boldsymbol{\Phi}$, karışım spektrogramının fazı, c bileşen indeksi, t hedef bileşen indeksidir. STFT^{-1}, kısa zamanlı ters Fourier dönüşümüdür.

3. Önerilen Metot

3.1. Model

Oto-Kodlayıcı Değişimli Bayes (AEVB), üretici modeller arasında güçlü ve etkili bir yöntem olarak kabul edilmektedir. AEVB algoritması, sonsal dağılımın yaklaşık parametrelerini kodlayıcı kullanarak kestirir.

Ancak, tüm veriye erişimin olmadığı durumlar için AEVB algoritmasının alternatif bir uygulaması önerilmektedir. Önerilen yöntem, değişimli oto kod çözücü (VAD) olarak adlandırılmaktadır [11]. VAD ile, yaklaşık sonsal dağılımın parametreleri başlangıçta rasgele seçilir ve gradyan-temelli yöntemler ile bu parametreler güncellenir.

3.2. Değişimli Oto-Kodlayıcı

Değişimli oto-kodlayıcı (VAE) [5], üretici modelleri geliştirmek için kullanılan bir çerçevedir. $\boldsymbol{X} = \left\{\mathbf{x}^{(i)}\right\}_{i=1}^{N}$, eğitim veri kümesinin N örneğini içersin. Verinin z gizli değişkeninin rasgele bir süreci tarafından üretildiği varsayımı altında $\mathbf{z}$ için $p_\theta(\mathbf{z}) = \mathcal{N}(\mathbf{z}|\mathbf{0}, \mathbf{I})$ önsel dağılımı, ϕ ile parametrelendirilmiş kodlayıcı modeli, θ ile parametrelendirilmiş bir $p_\theta(\mathbf{x}|\mathbf{z})$ kod çözücü tanımlanabilir. $\boldsymbol{X}$ eğitim veri kümesi kullanıldığında, ϕ ve θ model parametreleri, stokastik gradyan çıkışı ve (2) numaralı denklemde ifade edilen değişimli alt sınır en büyüklenerek tahmin edilmektedir.

Gerçekleştirilen VAE modeli, [4] ile önerilen VAE modelini kullanmakla birlikte, önerilen çalışmada bir adet $g(\cdot)$ kodlayıcısı kullanılır ve bu kodlayıcı ile z_k değişkenleri ve h_k sınıf etiketleri kestirilir:

$$(\mathbf{z}, \mathbf{h}) = g\left(\mathbf{x}^{(i)}\right). \tag{10}$$

Kaynak ayrıştırma işlevi için oto-kodlayıcı kullanıldığında $\mathbf{s}_k^{(i)}$ orijinal kaynak işaretini, $\mathbf{x}^{(i)}$ karışım işaretinden ayrıştırmak için bir oto-kod çözücü kullanılmaktadır:

$$\hat{\mathbf{s}}_k^{(i)} = f_{\theta_k}(\mathbf{z}_k), \quad f_{\theta_k}(\cdot) \geq 0. \tag{11}$$

Sinir ağının tek bir ileri geçişiyle, yukarıdaki model sayesinde test aşamasında hızlı çıkarım yapılabilmektedir. Ancak bu yaklaşımda, eğitilmiş kodlayıcı yalnızca eğitim kümesindeki sınıf kombinasyonları üzerine uzmanlaşmıştır. Eğitim sırasında gözlemlenmeyen bir sınıf kombinasyonuna sahip karışım işareti test sırasında modele verildiğinde, model bu karışımı ayrıştırmada ve doğru sınıflandırmada zorlanmaktadır. Öte yandan, kod çözücüler kaynak sınıflarının üretken modellerini öğrenme kapasitesine sahiptir ve eğitim kümesindeki verinin dağılımına büyük ölçüde bağlı değillerdir. Böylece, daha uyarlanabilir ve eğitilebilir yöntemler için yalnızca eğitimli oto-kod çözücüler kullanabilmemizi sağlamaktadır.

3.3. Değişimli Oto-Kod Çözücü

Önerilen yöntemde, eğitim bittikten sonra $g(\cdot)$ kodlayıcı atılmakta ve test aşamasında kestirim için yalnızca $f_k(\cdot)$ kod çözücülerini kullanılmaktır. Bu esnada amaçlanan, z_k ve h_k tahmininde, kodlayıcının tahminleri yerine optimizasyon kullanmaktır. Bu süreçte eğitilmiş kod çözücülerin parametreleri sabit tutulmaktadır. [11] çalışmasındaki VAD benzeri bir yaklaşım benimsenmektedir.

Orijinal VAE modelinde olduğu gibi $z_k = \mu_k + \sigma_k \odot \epsilon$ yeniden parametrelendirilmesi yapılır ve KL ıraksayı kullanılır. Bu yöntemle, z_k doğrudan tahmin edilmemekte; bunun yerine normal dağılıma sahip gizli z_k değişkeni için ortalama μ_k ve varyans σ_k^2 tahmin edilmektedir. Yalnızca kod çözücü kullanan çıkarımda iki farklı yöntem uygulanmaktadır: tam kapsamlı ve birleşik.

Tam kapsamlı ters-VAE çıkarımında, tüm sınıf kombinasyonları değerlendirilerek, doğrudan birleştirme problemi çözülmeye çalışılır. $h_k^{(i)}$ için uygun değerler ayarlanır ve aşağıda verilen model bütün olabilir sınıf kombinasyonları için en iyilenir:

$$\hat{\mathbf{x}}^{(i)} = \sum_{k=1}^{K} \hat{s}_k^{(i)} h_k^{(i)}. \tag{12}$$

Son aşamada, tüm örnekler için kaybı en düşük olan $h_k^{(i)}$ değeri seçilir. Seçilmiş $h_k^{(i)}$değerleri, tahmin edilen sınıf etiketleridir ve ilgili z_k değerleri, kaynak işaretinin kestirilmesini sağlar.

Alternatif olarak, yalnızca kod çözücünün ortak çıkarımında, $h_k^{(i)}$ 'nın olası değerleri için$\{0, 1\}$ yerine $(0, 1]$ aralığı alınarak, optimizasyon probleminin konveks olmaması sağlanır.

Genelleştirilmiş KL ıraksayı kullanıldığında, z_k ve h_k değerleri tahmin edilir ve aşağıdaki ifadeyi en küçüklemek amacıyla Adam en iyileştirme uygulanır:

$$\underset{z_k \in \mathbb{R}, h_k \in (0,1]}{\arg\min} D_{GKL}\left(\mathbf{x}^{(i)} \middle\| \hat{\mathbf{x}}^{(i)}\right). \tag{13}$$

3.4. Eğitim

Eğitim esnasında, yalnızca sınıf etiketleri veya kaynak işaretleri kullanılabilir.

3.4.1. Kaynak İşaretiyle Eğitim

Eğitim esnasında kaynak işaretlerinin mevcut olduğu durumlarda, otomatik kodlayıcılar kullanılarak başlanır. $\mathbf{x}^{(i)}$, karışım işaretinin genlik spektrogramı olmak üzere, karışım işaretini oluşturan her bir $\mathbf{s}_k^{(i)}$ orijinal kaynak işareti, (5) eşitliği

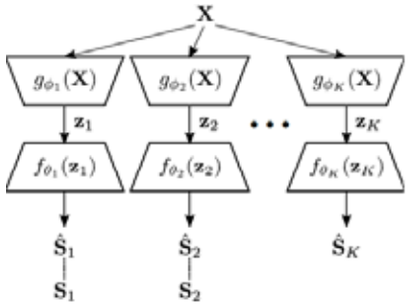

Şekil 1: Kaynak İşareti ile eğitim için model mimarisi

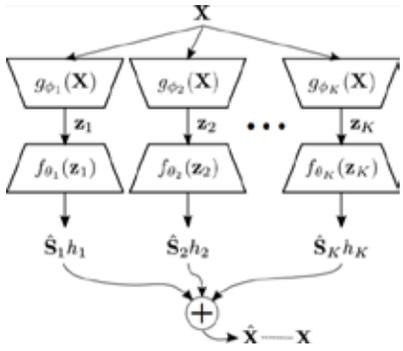

Şekil 2: Kaynak sınıfı ile eğitim için model mimarileri.

ile verilen oto-kodlayıcıların kullanımı sonucunda tahmin edilebilir.

$\mathbf{x}^{(i)}$ ve $\mathbf{s}^{(i)}$, sırasıyla karışım işareti ve orijinal kaynak işaretlerinin genlik spektrogramları olmak üzere; $\boldsymbol{\mathcal{X}}_s = \{(\mathbf{x}^{(i)}, \mathbf{s}^{(i)})\}_{i=1}^{N}$ eğitim kümesinden [9] çalışmasında anlatılan yaklaşıma ulaşılabilir. Ancak, kayıp fonksiyonu olarak karesel hata yerine, (6) ile verilen KL ıraksayı kullanılmış olmalıdır.

Kaynak işaretleri kullanılarak eğitilen modelin yapısı Şekil 1' de verilmektedir. Şekil 1' de genelleştirilmiş KL ıraksayı noktalı çizgilerle belirtilmiştir. Daha sade bir gösterim için $^{(i)}$ örnek indeksleri gösterilmeyip, karışım işareti $\mathbf{x}$' in, sadece 1. ve 2. kaynak işaretlerinden oluştuğu varsayılır. Kaynak işaretleri kullanılarak eğitilen modelde kayıp, genelleştirilmiş KL ıraksayı $D_{GKL}(s_1||\hat{s}_1) + D_{GKL}(s_2||\hat{s}_2)$ kullanımı ile orijinal ve kestirilen kaynak işaretleri arasında hesaplanır.

3.4.2. Kaynak Sınıfı ile Eğitim

$\mathbf{h}^{(i)} \in \{0,1\}^K$, kaynak sınıf etiketleri olmak üzere, eğitim kümesi olarak $\boldsymbol{\mathcal{X}}_h = \{(\mathbf{x}^{(i)}, \mathbf{h}^{(i)})\}_{i=1}^{N}$ kullanılmaktadır. Modelde, kaynakları kestirmek için $\mathbf{s}_k^{(i)}$ orijinal işaretlerine erişim olmayıp, yalnızca $h_k^{(i)}$ kaynak etiketleri kullanılır:

$$\hat{\mathbf{x}}^{(i)} = \sum_{k=1}^{K} \hat{\mathbf{s}}_k^{(i)} h_k^{(i)}. \qquad (14)$$

$\hat{\mathbf{s}}_k^{(i)}$ kaynaklarını kestirmek için,

$$D_{GKL}\left(\mathbf{x}^{(i)} \| \hat{\mathbf{x}}^{(i)}\right) = \sum_j \mathbf{x}_j^{(i)} \log \frac{\mathbf{x}_j^{(i)}}{\hat{\mathbf{x}}_j^{(i)}} - \mathbf{x}_j^{(i)} + \hat{\mathbf{x}}_j^{(i)} \qquad (15)$$

ile verilen $D_{GKL}\left(\mathbf{x}^{(i)} \| \hat{\mathbf{x}}^{(i)}\right)$ genelleştirilmiş ıraksayında, j, $\mathbf{x}^{(i)}$'nin elemanlarının indeksidir.

Böylelikle, $\mathbf{x}^{(i)}$ karışımının geri çatılması için sadece kaynak etiketleriyle ilişkili oto-kodlayıcılar kullanılmaktadır. Önerilen model, NOMA' daki gibi toplamsal bileşenler kullanmasına rağmen, NOMA' dan farklı olarak bileşenlerin temsilinde doğrusal yerine doğrusal olmayan şablonlar ile daha etkili sinir ağı modelleri kullanabilir. Model, her bir kaynak işaretinin geri çatılmasında kod çözücü kullanırken, kodlayıcılar karışımı oluşturan diğer kaynaklara ait gürültü ve girişimleri ihmal eder ve oto-kodlayıcı kullanarak yalnızca ilişkili kaynak sınıfını öğrenir.

Eğitim esnasında kaynak sınıflarını kullanan model, Şekil 2' de görülmektedir. Kaynak sınıfları kullanılarak eğitilen modelde, maliyet fonksiyonu $D_{GKL}(x\|\hat{x} = \hat{s}_1 + \hat{s}_2)$, karışım işareti $\mathbf{x}$ ile kestirilen kaynaklar $\hat{\mathbf{s}}_k$, $k = 1,2$ arasında hesaplanmaktadır.

3.5. Çıkarım

Tek kanallı kaynak ayrıştırma probleminde, kaynak işaretleri ile ilgili yeterince önsel bilgi mevcut değilse, sonsuz sayıda geçerli çözüm vardır. Kaynaklar hakkındaki önsel bilgi, üretici kaynak ayrıştırma yaklaşımlarında bir veya daha fazla üretici model aracılığıyla modele verilir. Bu yüzden, üretici modellerin yeni kaynak işaretleri oluşturmak için yeterince ön bilgisi bulunmaktadır. Çıkarım aşamasında, VAE ve VAD modelleri kullanılır. İleri çözüm, giriş işaretini (10) eşitliği ile gösterildiği gibi kodlayıcıya giriş olarak alarak, daha düşük boyutta gizli değişkenler üretir. Ters çözümde, kod çözücü, kodlayıcı tarafından üretilen gizli değişkenleri giriş olarak alarak, kaynak işaretlerini kestirir. İleri-çözümde VAE modeli kullanılırken, ters-çözümde test aşamasında kodlayıcı yerine VAD modeli kullanılmaktadır.

Ayrıştırılmış kaynakları zaman bölgesinde geri çatmak için karışım fazı ve (9) eşitliği ile verilen Wiener filtresi kullanılmaktadır.

3.6. Performans Tabanlı Maliyet Fonksiyonları

Kaynak ayrıştırma yöntemleri, ağırlıklı olarak genlik spektrogramları üzerinde çalışmaktadır. Kaynak ayrıştırma yöntemlerinde maliyet fonksiyonu olarak, genellikle ortalama karesel hata (MSE) [1], KL ıraksayı [1], Itakura-Saito ıraksayı [2], Bregman ıraksayı [12] kullanılır.

Son yıllarda derin öğrenme tabanlı kaynak ayrıştırma yöntemleri, doğrudan zaman bölgesinde çalışmaktadır ve ayrıştırılan işaretleri doğrudan zaman bölgesinde geri çatmaktadır. Kaynak ayrıştırma yöntemlerinde ayrıştırma başarımı zaman bölgesinde ölçüldüğü için, maliyet fonksiyonu olarak doğrudan zaman bölgesindeki başarım ölçütleri kullanılabilmektedir. Böylelikle en iyileştirmek istenen kayıp fonksiyonu, kaynak ayrıştırma başarımını da ölçtüğünden hedeflenen uygulamada, ayrıştırma daha başarılı hale gelmektedir.

Önerilen çalışmada KL ıraksayına ek olarak İşaret Gürültü Oranı (SNR), ortalama karesel hata (MSE), ve ölçek-değişmez İşaret Bozulma Oranı (SI-SDR) gibi ölçütler de kullanılmaktadır. Böylece, kaynak ayrıştırma başarımını değerlendiren ölçütler, eğitim esnasında da kullanılmakta ve başarımın yükselmesi amaçlanmaktadır.

Ortalama karesel hata (MSE), aşağıdaki şekilde hesaplanmaktadır:

$$MSE = \frac{1}{L}\sum_{k=1}^{L}\left(y_t^{(i)}(k) - \hat{y}_t^{(i)}(k)\right)^2. \quad (16)$$

Burada k, zaman indeksini verirken, L, işaretin boyutudur.

BSS-Eval ölçütlerinden [13] İşaret Hata Oranı (SAR), İşaret Bozulma Oranı (SDR) ve İşaret Girişim Oranı (SIR), başarımı ölçmek için konuşma ayırma uygulamalarında yaygın olarak kullanılmaktadır.

İşaret-Gürültü-Oranı (SNR) aşağıdaki gibi hesaplanır:

$$SNR = 10\log_{10}\left(\frac{\left\|y_t^{(i)}\right\|^2}{\left\|y_t^{(i)} - \hat{y}_t^{(i)}\right\|^2}\right). \quad (17)$$

SNR, BSS-Eval ölçütlerinden SDR' ye karşılık gelmektedir. (17) ile verilen eşitlikte, $y_t^{(i)}$ orijinal işaret, $\hat{y}_t^{(i)}$ kestirilen işaret, $y_t^{(i)} - \hat{y}_t^{(i)}$, ise gürültüdür. Gürültünün, yani orijinal ve kestirilen işaretler arasındaki farkın, orijinal kaynak işaretine göre ortogonal olması için orijinal veya kestirilen işaretler yeniden ölçeklendirilmelidir [14]. Gürültünün orijinal işarete dik olacağı şekilde orijinal işaretin yeniden ölçeklendirilmesi; $\hat{y}_t^{(i)}$ kestiriminin, $y_t^{(i)}$ tarafından kapsanan çizgi üzerine dik izdüşümünün alınmasına ya da bu çizgi boyunca $\hat{y}_t^{(i)}$ kestirimi için en yakın noktanın bulunmasına karşı gelir.

Ölçek-değişmez işaret-bozulma oranı (SI-SDR), SNR ölçütüne dayalı olarak, işaretin bozulma oranını daha doğru bir şekilde değerlendirmek için tanımlanmış bir ölçüttür. Orijinal işaretin ve kestirilen işaretin yeniden ölçeklendirilmesi ile bu değer, kaynak ayrıştırma başarımını daha iyi temsil etmeyi amaçlar. SI-SDR aşağıdaki şekilde tanımlanmaktadır [14]:

$$SI-SDR = \frac{\left\|y_t^{(i)}\right\|^2}{\left\|y_t^{(i)} - \beta\hat{y}_t^{(i)}\right\|^2} = \frac{\left\|\alpha y_t^{(i)}\right\|^2}{\left\|\alpha y_t^{(i)} - \hat{y}_t^{(i)}\right\|^2}. \quad (18)$$

(18) ile verilen tanımda, α ölçeklendirme çarpanı olup, orijinal kaynak işareti için en iyi değer $\alpha = \frac{y_t^{(i)T} y_t^{(i)}}{\left\|y_t^{(i)}\right\|^2}$ olacak şekilde elde edilir.

3.7. Mimari

T ve F , sırasıyla zaman ve frekans bileşenlerinin sayısını ifade ederken, önerilen model $T \times F$ boyutunda spektrogramları giriş işareti olarak alan Evrişimsel sinir ağları (CNN) kullanmaktadır [15]. Kodlayıcı mimarisinin yapısı Tablo 1 ile verilmiştir. Kodlayıcı, üç evrişimsel katman, bir tam bağlı katman ve Gauss gizli katmanından oluşmaktadır. İlk evrişimsel katman, $1 \times F$ boyutunda 128 filtre kullanarak, tıpkı NOMA' da olduğu gibi frekans ekseni boyunca şablonlar öğrenir. İkinci ve üçüncü katmanlar, 4×1 boyutunda filtreler kullanan evrişimsel katmanlar olup, zamansal şablonları öğrenmektedir. Tam Bağımsız katmanda ve Gauss gizli çıktı katmanında sırasıyla 512 ve 128 filtre kullanılmaktadır. Kodlayıcı ve kod çözücünün yapısı simetriktir. Kod çözücü, devrik evrişimler kullanır. Kodlayıcı ve kod çözücüde son katmanlar hariç diğer katmanların tümü düzeltilmiş doğrusal birim (ReLU) sapmaları kullanmaktadır. Son katmanlar dışındaki her katmana toplu normalleştirme uygulanmaktadır. Çıktının negatif olmasını önlemek için kod çözücüde son katman olarak yumuşak artı işlevi (softplus) $o(x) = \log(1 + e^x)$ kullanılmaktadır.

4. Deneyler

Önerilen yöntemin ayrıştırma başarımı, tek gözlem içeren kaynak ayrıştırma problemi çerçevesinde değerlendirilmiştir.

4.1. Veri Kümeleri

Geliştirilen modelin başarımı üç veri kümesi üzerinde değerlendirilmektedir. Kullanılan ilk veri kümesi, Sıfırdan Dokuza Konuşma Komutları (SC09) içeren 10 sınıflı bir veri kümesidir [16]. Bu küme, bir saniye süresine sahip rakam ifadelerinden oluşmaktadır. Eğitim kümesi, farklı kayıt koşulları altında farklı konuşmacıları, farklı ses yüksekliği, gürültü, hizalama ve yanlış etiketleme gibi durumlar içerdiğinden zorludur. Veri kümesinde tamamı sessizlik olan kısımlar ve farklı dillerde ifade edilen sayılar dahi bulunmaktadır.

Diyalog seslerinin arka plan seslerinden ayrıştırılması hedeflendiği için, ikinci ve üçüncü veri kümelerinde film sesleri kullanılmaktadır. Başarımı nesnel olarak ölçebilmemiz için, tüm kaynaklara ayrı ayrı erişimimiz olmalıdır. Ancak, gerçek film kayıtlarında tüm kaynaklara erişim mümkün olmayacağı için başarım, nesnel olarak ölçülemez. Bu nedenle, diyalog ayrıştırmada nesnel başarımı ölçebilmek için, [1] adresinde bulunan film sesleri ile SC09 [16] ve GRID [17] veri tabanlarından alınan konuşma sesleri kullanılmaktadır.

İkinci veri kümesindeki kaynaklar konuşma ve arka plan sesleri şeklinde iki farklı tür içerdiğinden, sınıf-tabanlı eğitilen modeller için tanımlanabilirlik problemi yaratabilir. Bu problemi aşmak amacıyla üçüncü bir veri kümesi daha oluşturulmuştur. Üçüncü veri kümesi, ikinci veri kümesinde bulunan arka plan sesleri ile GRID veri Kümesinden [17] bir kadın ve bir erkek konuşmacının sesleri birleştirilerek oluşturulmuştur.

Her üç veri kümesi için, kayıtlar, 8,600 Hz ile alt örneklenmekte ve tüm kayıtların Karesel Ortalamalarının Kökü (RMS), hedeflenen RMS değerine normalleştirilmektedir. Bu RMS normalizasyonu, kayıtların ses yüksekliğindeki farklılıkları azaltmak için elzemdir.

İlk veri kümesi, 10 sınıflı SC09 veri kümesinden beş sınıf seçilerek oluşturulmuştur. Karışım işaretlerini elde etmek için $C(5;\ 2) = 10$ etiket kombinasyonunun $\{0,1\}$, $\{0,2\}$, vb. şekilde bir listesi oluşturulur. Sonrasında, kombinasyondaki sınıf etiketlerinden seçilen kayıtlar 0 dB ile karıştırılır. Veri kümesi sırasıyla 15,000 eğitim, 1,875 sağlama ve 1,875 test verisi içermektedir.

İkinci veri kümesi, iki sınıflı kaynak ayrıştırma deneyi için kullanılmaktadır. Birinci sınıfta konuşma sesleri, ikinci sınıfta film arka plan sesleri bulunmaktadır. Arka plan sesleri, [1] adresinde bulunan film seslerinin konuşma işareti içermeyen kayıtlarından seçilmektedir. İlk veri kümesinde olduğu gibi, tüm sesler bir saniye süresindeki seslere bölünerek toplam 828 arka plan, 15,928 konuşma sesi oluşturulmaktadır. İki sınıftan rasgele seçilen işaretler 0 dB ile karıştırılmaktadır. İkinci veri kümesinde 15,000 eğitim, 1,875 sağlama ve 1,875 test verisi bulunmaktadır.

Tüm veri kümelerinde, karışım işaretlerine %50 örtüşme ile 400 noktalı Hanning penceresi kullanılarak kısa zamanlı Fourier Dönüşümü (STFT) uygulanmaktadır. Elde edilen spektrogramlar, $F = 201$ frekans bileşeni ve $T = 44$ zaman bileşeni içermektedir.

4.2. Değerlendirme Ölçütleri

Kaynak ayrıştırma sonuçları BSSEVAL araç kutusundaki [13] İşaret Hata Oranı (SAR), İşaret Bozulma Oranı (SDR) ve İşaret-Girişim Oranı (SIR) ile değerlendirilmektedir. Diğer kaynak işaretlerinden kalan girişim yani gürültü miktarı SIR ile,

[1] https://soundbible.com/tags-movies.html

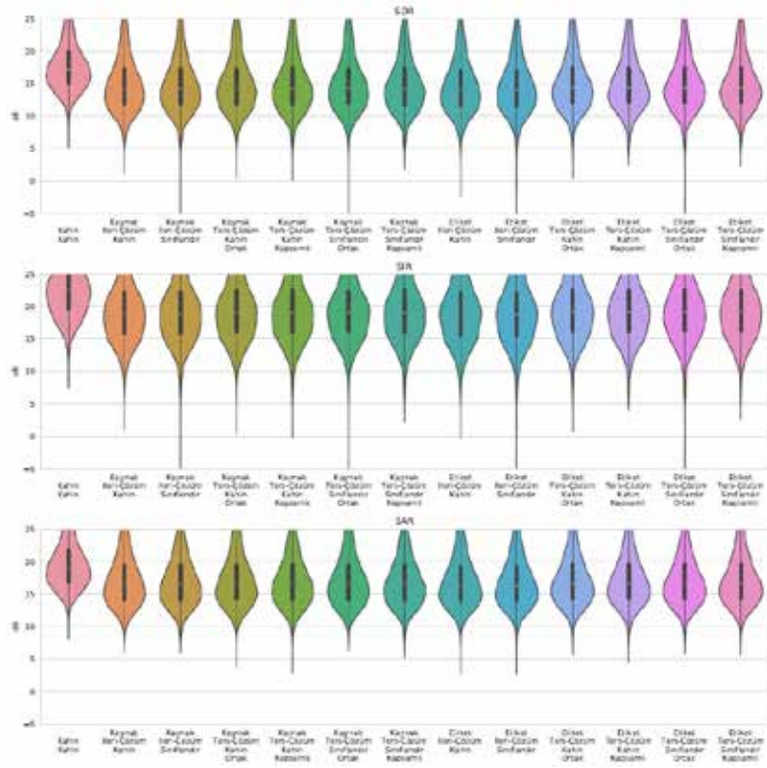

Şekil 3: VAE modeli kullanılarak kaynak işaret ile eğitim-sınıf etiket ile eğitim; ileri çözüm ile çıkarım-ters çözüm ile çıkarım yöntemi ile ilk veri kümesi üzerinde elde edilen SAR, SDR ve SIR türünden başarım.

ayrıştırma işleminden kaynaklı hatalar SAR ile ve genel ayrıştırma başarımı SDR ile ölçülür.

Önerilen yöntem sonucunda elde edilen işaretlerin algısal kalitesini ölçmek için, üçüncü veri kümesinde Algısal Konuşma Kalitesi (PESQ) [21] ölçülmüştür. PESQ değeri, ses kalitesini algısal olarak ölçer ve $[-0.5, 4.5]$ aralığında bir değer almaktadır. PESQ değerinin yüksek olması, algısal konuşma kalitesinin yüksek olduğunu ifade eder.

4.3. Deneysel Sonuçlar

Tüm deneyler PyTorch 0.4.1 ve NVIDIA Tesla K80 GPU kullanılarak gerçeklenmiştir. Varsayılan parametreler ile Adam optimizasyon algoritması [18] kullanılmaktadır. $\beta = 10$ olarak seçilmiştir. Toplu iş boyutu olarak 100 alınmıştır. Her 200 yineleme sonrası doğrulama kümesinde hesaplanan geri çatma kaybında, 5 yineleme boyunca bir iyileştirme olmazsa eğitime son verilmektedir. Fazla hiperparametre ayarına gereksinim duyulmadan başarılı sonuçlar elde edilmiştir.

Eğitim iki farklı şekilde gerçeklenmektedir: kaynaklar kullanılarak ve sınıf etiketi kullanılarak. Kestirim için, VAE ve VAD modelleri kullanılmıştır. İleri çözümde, VAE modeli kullanılırken, ters-çözümde VAD modeli kullanılmaktadır. Sınıf etiketinin mevcut olduğu durum kâhin olarak adlandırılmakta ve eğitim kümesinde olduğu gibi, $\boldsymbol{\mathcal{X}}_{test} = \{(\mathbf{x}^{(i)}, \mathbf{h}^{(i)})\}_{i=1}^{N}$ test kümesinde, $\mathbf{h}^{(i)}$ kaynak sınıfı etiketlerinin mevcut olduğu varsayılmaktadır. Test kümesinin sadece karışım işaretlerinden oluştuğu durumda, sınıf bilgisi kestirilmektedir ve bu durum için grafiklerde "sınıflandır" etiketi kullanılmaktadır. VAD modeli, ters çözüm için iki yöntem incelemektedir: kapsamlı çözüm ve ortak çözüm.

[4] ile verilen çalışmamızda, önerdiğimiz VAE yöntemi, kaynak sınıfı ile eğitim ve kaynak işareti ile eğitim durumlarında oto-kodlayıcı (AE) ile kıyaslanmış olup, AE yöntemi ile kaynak ayrıştırma uygulandığında; kaynak işaretlerine erişim olmadığında başarımın düştüğü gözlemlenirken, önerilen VAE kullanıldığında başarım düşmemektedir. Bu çalışmanın [4] numaralı çalışmamıza göre katkısı, sınıf etiketlerine erişimin de olmadığı durumda sınıf etiketlerini de kestirebilmesidir.

İlk deney, VAE modeli kullanılarak kaynak işareti ile eğitim-sınıf etiketi ile eğitim; ileri-ters çözüm ile çıkarım yöntemi ile ilk veri kümesi üzerinde gerçeklenmektedir. Orijinal kaynaklara erişimin olduğu uzman ölçümleri de karşılaştırma için dahil edilmiştir.

Şekil 3, elde edilen SAR, SDR ve SIR türünden ölçümleri keman grafiği olarak göstermektedir. Her bir grafik açıklaması dört ayrı bileşenden oluşmaktadır. (1) eğitim yöntemi, (2) işaret kestirimi (3) sınıf kestirimi ve (varsa) (4) ters çözüm yöntemi. Yatay eksende belirtilen yöntemlerle ilgili dört ifade bulunmaktadır. İlk ifade, eğitim yöntemini belirtmektedir. İki farklı eğitim yöntemi incelenmiştir: Kaynak ve Sınıf. Kaynak, eğitim esnasında kaynak işaretlerinin kullanılmasına; sınıf, eğitim esnasında sınıf etiketlerinin kullanılmasına karşılık gelmektedir. İkinci ifadede, işaret kestirimi için kullanılan yöntemler verilmiştir: Kâhin, İleri-Çözüm ve Ters-Çözüm. Bu yöntemlerden Kâhin, kâhin kestirimini; İleri-Çözüm, ileri çözüm işaret kestirimini; Ters-Çözüm, ters çözüm işaret kestirimini temsil eder. Üçüncü ifade sınıf kestirim yöntemi ile ilgili bilgi taşımakta olup, iki şekilde sınıf kestirimi yapılmaktadır: Kâhin ve Sınıflandır. Kâhin, sınıf kestiriminin dışardan verildiği; Sınıflandır, modelin kendisinin sınıf

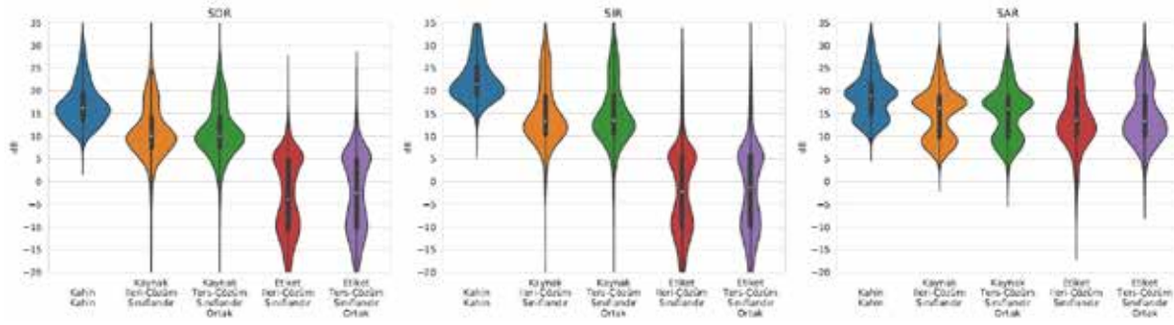

Şekil 4: VAE modeli kullanılarak ikinci veri kümesi üzerinde elde edilen SAR, SDR ve SIR türünden başarım.

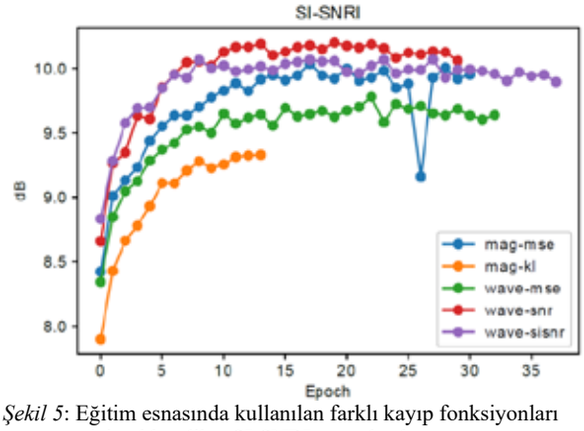

Şekil 5: Eğitim esnasında kullanılan farklı kayıp fonksiyonları için elde edilen SI-SNRI türünden başarım

kestirimi yaptığı yöntemleri ifade eder. Eğer işaret kestirimi için ters-çözüm kullanıldıysa, dördüncü ifadede hangi ters çözüm yönteminin kullanıldığı belirtilmektedir: Ortak ve Kapsamlı. Yatay eksende SAR, SDR ve SIR türünden verilen başarımlarda ilk yöntemin altında sadece Kâhin, Kâhin yazmakta olup, bu durum sınıf etiketlerinin ve kaynak işaretlerinin bilindiği senaryoya karşılık gelmektedir ve önerilen yöntemlerin başarımını kıyaslamak için verilmiştir.

Öncelikle, Kaynak eğitimli modellerin SAR, SDR ve SIR değerlerinin beklenildiği üzere daha yüksek olduğu görülmektedir. Kaynak eğitimli modeller arasında SDR değerleri karşılaştırıldığında Ters-Çözüm işaret kestirimi kullanan modellerin 1-2 dB daha iyi başarım sergilediği dikkat çekmektedir. Bu sonuç, üretici modellerin öğrenebildiği senaryolarda, Ters-Çözüm işaret kestiriminin İleri-Çözüm işaret kestirimine kıyasla bir avantaj sunduğunu ortaya çıkarmaktadır. Etiket eğitimli modellerde de benzer bir başarım farkı gözlemlenmiş olup, yaklaşık 0.5 dB civarındaki bu fark, Kaynak eğitimli modellere kıyasla daha düşük seviyededir. Bu farkın, üretici modelin öğrenme kapasitesine bağlı olduğunu düşündüğümüzden, beklentilerimizle uyumlu olduğu görülmektedir.

İkinci deneyde, ikinci veri kümesi üzerinde VAE modeli kullanılarak kaynak işaret eğitimi ile sınıf etiket eğitimi karşılaştırılmıştır. Sonuçlar Şekil 4'te sunulmuştur. SDR ve SIR değerleri açısından değerlendirildiğinde, kaynak eğitimli ayrıştırmada SDR değeri ortalama 10 dB civarındayken, etiket eğitimli ayrıştırmada ortalama SDR değeri yaklaşık -5 dB olarak elde edilmiştir. Girişim miktarını ölçen SIR değerlerinde de benzer bir durum gözlemlenmiş ve kaynak eğitimli ayrıştırmanın, etiket eğitimine kıyasla ortalama 15 dB daha yüksek performans gösterdiği belirlenmiştir.

Bu veri kümesinde yalnızca iki sınıfın bulunması, yalnızca sınıf etiketleri kullanılarak çözülemeyen bir tanımlanabilirlik sorununa yol açmaktadır. Bu nedenle, sadece iki sınıf içeren durumlarda, etiket eğitimi ile gerekli üretici modelleri öğrenilememektedir. Bu sorunu aşmak amacıyla üçüncü deneyde, üç sınıflı bir diyalog geliştirme senaryosu tasarlanmıştır.

Üçüncü deneyde, Bölüm 3.5'te açıklanan başarım ölçütlerinin maliyet fonksiyonu olarak kullanılmasının başarıma etkisi incelenmiştir. Deneyler, SC09 kümesinden seçilen üç sınıflık bir alt küme üzerinde gerçekleştirilmiştir. Bu kapsamda, 1,500 eğitim ve 1,000 test karışım işareti oluşturulmuştur. Deneylerde, kaynak işareti denetimi ve standart oto-kodlayıcı ile birlikte aşağıdaki maliyet fonksiyonları kullanılmıştır:

- **mag-mse**: Genlik spektrogramında ortalama karesel hata.
- **mag-KL**: Genlik spektrogramında Kullback-Leibler (KL) ıraksağı.
- **wave-mse**: Sesin zaman bölgesinde ortalama karesel hata.
- **wave-snr**: Sesin zaman bölgesinde İşaret-Gürültü-Oranı (SNR).
- **wave-sisnr**: Sesin zaman bölgesinde ölçek-değişmez İşaret-Gürültü-Oranı (SI-SNR).

Bu makalede önerilen evrişimli yapay ağ mimarilerimiz, genlik spektrogramına uygulanır. Ancak, zaman bölgesinde tanımlanan maliyet fonksiyonlarının kullanılabilmesi ve uçtan uca eğitim [19] gerçekleştirilebilmesi için PyTorch kütüphanesinden türevi alınabilir bir kısa zamanlı ters Fourier Dönüşümü (ISTFT) işlevi kullanılmaktadır. Bu sayede, gradyan bilgisi ISTFT aracılığıyla geri yayılabilmektedir.

Adil bir karşılaştırma sağlamak amacıyla, eğitim sırasında maliyet fonksiyonu değerlendirme kümesinde hesaplanmakta ve bu metrik erken durdurma için kullanılmaktadır. Değerlendirme kümesinde hesaplanan maliyet fonksiyonu 10 ardışık iterasyon boyunca azalma göstermezse, eğitim süreci sonlandırılmaktadır.

Farklı kayıp fonksiyonları kullanıldığında elde edilen SI-SNRI türünden başarım sonuçları Şekil 5'te görülmektedir. Kayıp fonksiyonları zaman bölgesinde hesaplandığında, ayrıştırma başarımı daha yüksek olurken, en başarılı ayrıştırma **wave-snr** kayıp fonksiyonu olarak kullanıldığında elde edilmiştir.

Üçüncü veri kümesinde yapılan deneylerde algısal konuşma kalitesi PESQ [20] değerleri ile ölçülmüş olup, sonuçlar Şekil 6 ile raporlanmaktadır. Kaynak ve etiket eğitimli

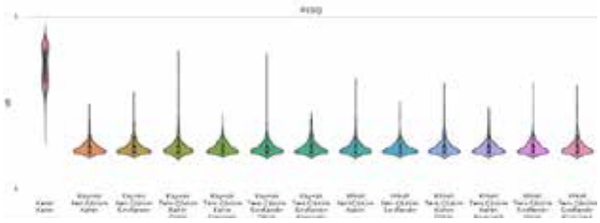

Şekil 6: Üçüncü veri kümesi üzerinde PESQ türünden başarım keman grafikleri olarak gösterilmiştir.

modeler için PESQ değeri 1.14 dB civarında olup, tüm eğitim-çıkarım çeşitleri için yakın sonuçlar elde edilmiştir.

Önerilen yöntem, akan veri üzerinde de uygulanabilir. Bir sistemin gecikmesi G_{toplam}, iki ana bileşenden oluşur: G_b, ilk çıktıyı üretmek için gereken işlem süresi ve G_i, her bir çıktının üretilmesi için gerekli işlem zamanıdır. Model, öncelikle, NVIDIA Tesla K80 GPU' suna yüklenmektedir. İşlemler, 400 örneklik zaman çerçeveleri için gerçekleştirilmektedir. Örnekleme frekansı olarak 8,600 Hz kullanıldığı için, 400 örneğe sahip bir çerçeve 47 ms' lik bir süreyi kapsamaktadır. Bu koşullarda $G_b = 3.3\ ms$ olup, bir çerçeve, $G_i = 1\ ms$ sürede ayrıştırılmaktadır. Böylece, sistemin toplam gecikmesi $G_{toplam} = 4.3\ ms$ olmaktadır. Bu süre, sistemin filmlerde diyalogları ayırmak amacıyla rahatlıkla kullanılabileceğini gösterir. Buna ek olarak, ortak ve kapsamlı ters çözüm en iyileme yöntemleri de $10.06\ s$ ve $14.52\ s$ sürmektedir. Her iki yöntem de dengeli olmayan veri kümelerinde yüksek başarımlı ayrıştırma yapabilmekte olup, filmlerde diyalog ayrıştırmak için ihtiyaç duyulan işlem süreleri gereksinimlerin üzerindedir.

5. Sonuç

Bu makale, kaynak işaretlerine erişim sağlanmadığı ve yalnızca sınıf etiketlerine sahip olunduğu ve olunmadığı senaryolar için negatif olmayan VAE ve VAD modelleri önermektedir.

Kaynak işaretleriyle ilgili sınıf etiketlerine ihtiyaç duyulmadan, sınıf etiketi kestirimi ve kaynak ayrıştırma eş zamanlı gerçekleştirilebilmektedir. Ayrıca, yalnızca karışım işaretlerine erişimin olduğu ve sınıf etiketleri ile kaynak işaretlerine erişimin olmadığı bir senaryo için VAD modeli önerilir. VAD ve VAE modelleri kullanılarak, kaynak ayrıştırma başarımı üç farklı veri kümesinde değerlendirilmiştir. Başarım, SAR, SDR ve SIR türünden ölçülmüş olup, eğitimde sınıf etiketlerinin ve orijinal kaynak işaretlerinin kullanıldığı senaryolarda elde edilen başarımların benzer olduğu gösterilmiştir. Kaynak işaretlerinin kestirimi için ileri çözüm ve ters çözüm yöntemleri karşılaştırıldığında, ters çözüm ile elde edilen başarımın daha iyi olduğu görülmüştür. Eğitim sırasında kaynak sınıflarına erişim olduğu durum ile kaynak sınıflarının kestirildiği durumlar karşılaştırılmış; kaynak sınıfına erişimin olmadığı durumda da benzer bir başarımla kaynakların ayrıştırılabildiği gözlemlenmiştir.

Ayrıca, zaman bölgesinde, uçtan uca çalışabilen bir kaynak ayrıştırma yöntemi geliştirilmiştir. Uçtan uca çalışan kaynak ayrıştırma ile, zaman bölgesinde ses kalitesini ölçen MSE, SI-SNR ve SNR gibi başarım ölçütlerinin eğitim esnasında kayıp fonksiyonu olarak kullanılması da sağlanmıştır. Geliştirilen yöntem, gerçek zamanlı olarak çalışabilme yeteneğine sahiptir.

6. Kaynaklar

[1] D. D. Lee, ve H. S. Seung, "Algorithms for non-negative matrix factorization", *Advances in neural information processing systems*, 2000.

[2] C. Févotte, E. Vincent, ve A. Ozerov. "Single-channel audio source separation with NMF: divergences, constraints and algorithms", *Audio Source Separation*, Springer, 2018, 1-24.

[3] Ç. Hızlı, E. Karamatlı, A. T. Cemgil, ve S. Kırbız, "Değişimli Oto-Kodlayıcılar Kullanılarak Birleşik Kaynak Ayrıştırma ve Sınıflandırma-Joint Source Separation and Classification Using Variational Autoencoders", *In 28th IEEE Signal Processing and Communications Applications Conference (SIU)*, 2020.

[4] E. Karamatli, A. T. Cemgil, ve S. Kirbiz, "Audio Source Separation Using Variational Autoencoders and Weak Class Supervision", *IEEE Signal Processing Letters*, 2019, 1349-1353.

[5] D. P. Kingma, ve M. Welling, "Auto-encoding Variational Bayes". *In Proc. ICLR*, 2014.

[6] I. Higgins, L. Matthey, A. Pal, C. Burgess, X. Glorot, M. Botvinick, S. Mohamed, ve A. Lerchner, "beta-vae: Learning basic visual concepts with a constrained variational framework", *In Proc. ICLR*, 2017.

[7] D. Wang, ve J. Chen, "Supervised Speech Separation Based on Deep Learning: An Overview", *IEEE/ACM transactions on audio, speech, and language processing* 26.10 (2018): 1702-1726.

[8] S. Kırbız, A. Ozerov, A. Liutkus, ve L. Girin, "Perceptual coding-based Informed Source Separation," *2014 22nd European Signal Processing Conference (EUSIPCO)*, Lisbon, Portugal, 2014, pp. 959-963.

[9] E. M. Grais, ve M. D. Plumbley, "Single channel audio source separation using convolutional denoising autoencoders". *2017 IEEE global conference on signal and information processing (GlobalSIP)* 2017.

[10] A. T. Cemgil, "Bayesian inference for nonnegative matrix factorisation models", *Computational intelligence and neuroscience*, *2009*(1), 785152

[11] A. Zadeh, Y. C. Lim, P. P. Liang, ve L. P. Morency, "Variational auto-decoder: A method for neural generative modeling from incomplete data." *arXiv preprint arXiv:1903.00840,* 2019.

[12] S. Sra, ve I. S. Dhillon, "Generalized nonnegative matrix approximations with bregman divergences". *Advances in neural information processing systems*, 2006, pp. 283–290).

[13] E. Vincent, R. Gribonval, ve C. Fevotte, "Performance measurement in blind audio source separation", *EEE transactions on audio, speech, and language processing* 14.4 (2006): 1462-1469.

[14] J. Le Roux, S. Wisdom, H. Erdogan, ve J. R. Hershey, "SDR–Half-Baked or Well Done?", *2019 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*. IEEE, 2019, (pp. 626–630).

[15] W. Hsu, Y. Zhang, ve J. Glass, "Learning Latent Representations for Speech Generation and Transformation", *Interspeech 2016; Sep 8-12; San Francisco, CA. 2016. p. 1770-1774.*

[16] P. Warden, "Speech Commands: A Dataset for Limited-Vocabulary Speech Recognition". *arXiv preprint arXiv:1804.03209*, 2018.

[17] M. Cooke, J. Barker, S. Cunningham, ve X. Shao, "An audio-visual corpus for speech perception and automatic speech recognition". *The Journal of the Acoustical Society of America* 120.5, 2006: 2421-2424.
[18] D. P. Kingma, ve J. Ba, "Adam: A method for stochastic optimization *arXiv preprint arXiv:1412.6980*, 2014.
[19] S. Venkataramani, E. Tzinis, ve P. Smaragdis, "End-to-end Non-Negative Autoencoders for Sound Source Separation", *ICASSP 2020-2020 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, 2020. p. 116-120.
[20] A. W. Rix, J. G. Beerends, M. P. Hollier, ve A. P. Hekstra, "Perceptual evaluation of speech quality (PESQ)-a new method for speech quality assessment of telephone networks and codecs". *IEEE International Conference on Acoustics, Speech, and Signal Processing*, vol. 2, 2001, (pp. 749–752).

Özgeçmişler

Serap Kırbız, doktora derecesini İstanbul Teknik Üniversitesi Telekomünikasyon Mühendisliği Bölümünden almıştır. Doktora çalışması sırasında Hollanda'nın Eindhoven kentinde bulunan Philips Araştırma Merkezinde ve Amerika Birleşik Devletlerinde bulunan Boston Üniversitesi, Bilişsel ve Sinir Sistemleri Bölümünde misafir araştırmacı olarak çalışmıştır. Fransa'nın Grenoble kentine bulunan Gipsa-Lab'da doktora sonrası araştırmacı olarak görev yapmıştır. Halen MEF Üniversitesi, Elektrik ve Elektronik Mühendisliği Bölümünde doktor öğretim üyesi olarak çalışmaktadır. Araştırma alanları arasında sayısal işaret işleme, örüntü tanıma, ses damgalama, ses kaynak ayrıştırma, matris ve tensör ayrıştırma, yüz ifadelerinden duygusu tanıma ve makine öğrenmesi yer almaktadır.