

Ses Kaynaklarının Gamma Markov Rasgele Alanları ile Modellenmesi (Gamma Markov Random Fields for Audio Source Modelling)

Onur Dikmen, A. Taylan Cemgil, Lale Akarun

Bilgisayar Mühendisliği Bölümü
Boğaziçi Üniversitesi, İstanbul, Türkiye

{onuro,taylan.cemgil,akarun}@boun.edu.tr

Özetçe

Kaynak ayırıştırma veya gürültü temizleme gibi ses işleme problemlerinde ses sinyallerinin fiziksel özelliklerini yansıtabilecek modellere ihtiyaç vardır. Bu çalışmada, ses kaynaklarının zaman-frekans bölgesi gösterimlerindeki yerel ilintiyi kapsayabilmek için kaynak katsayılarının değişimlerini Gamma Markov rasgele alanları (GMRA) ile modelledik. Bu modelde ardışık değişinti değişkenleri arasında pozitif ilinti bulunmaktadır ve bu ilintinin büyüklüğü modeldeki hiperparametrelerin değerine bağlıdır. GMRA modellerinde her değişken koşullu eşlenik olduğu için Gibbs örnekleycisi ya da varyasyonel Bayes metodlarıyla kestirim yapılabilen, ancak hiper parametrelerin eniyilenmesi, GMRA'lar düzgelememiş dağılımlar tanımladıkları için, en büyük olabilirlik kestirimi ile yapılamamaktadır. Bu çalışmada, GMRA'lara dayalı ses kaynak modelimizi gürültü temizleme ve tek kanaldan ses kaynaklarını ayırıştırma problemlerinde kullandık. Modelin kestiriminde Gibbs örnekleycisini, hiper parametrelerin eniyilenmesinde ise karşıtlık ıraksayımı kullandık.

Abstract

Audio processing tasks, such as source separation or denoising, require the construction of realistic models that reflect physical properties of audio signals. In this paper, we modelled the variances of time-frequency coefficients of audio signals with Gamma Markov random fields (GMRFs) so that the dependencies between coefficients are captured. There is positive correlation between consecutive variance variables in this model and the strength of this correlation is determined by the coupling hyperparameters. Inference can be carried out using the Gibbs sampler or variational Bayes because the model is conditionally conjugate. However, the optimisation of the hyperparameters is not straightforward because of the intractable normalising constant. In this work, we used this model in denoising and single-channel source separation problems. The hyperparameters of the model are optimised using contrastive divergence and inference is performed using the Gibbs sampler.

1. Giriş

Ses kaynaklarını ayırma ve gürültü temizleme, aradeğerleme gibi uygulamalarda, genel olarak sistemin bilinmeyenleri bilinenlerinden fazla olduğu için çözüm tek değildir.

Makul olmayan bazı değerler de problemdeki belirsizlikler yüzünden amaç fonksiyonunu eniyileyebilmektedir. Böyle sonuçlardan geri çatılan sinyaller de yapay olgular içermektedir. Bunu engellemek için probleme ses sinyallerinin genel özelliklerini gerçekleyecek kısıtlar dahil edilmelidir. Bayesçi yaklaşım içinde bunu gerçekleştirmenin yolu, önsel dağılımlar tanımlamaktır. Elde ettiğimiz gözlemler, bu önsel dağılımların bir bakıma güncellenmesini sağlar. Böylelikle elde edilen çözüm, noktasal çözümler değil, çözümlere ait bir olasılık dağılımıdır.

Durağan olmayan ses sinyallerinin zaman-frekans bölgesi gösterimlerini incelediğimizde hem frekans hem de zaman eksenindeki ardışık katsayılar arasında büyük miktarda ilinti olduğunu görürüz. Genel olarak yüksek değere sahip katsayılar belli bölgelerde öbelenmektedir. Mesela, tonsal sinyallerde (piyano, gitar, vb. sesleri) çalınan notaların temel frekanslarında ve onların harmoniklerinde, katsayılar zaman eksenini boyunca ilintilidir. Vurmalı enstrüman sesleri gibi sıçramalar içeren sinyallerde ise çok kısa bir süre için bir aralıktaki frekansların tümü aktif olur, yani o kısa süre içinde katsayılar frekans eksenini boyunca ilinti gösterir. Konuşma içeren sinyallerde yüksek değerli katsayılar formant frekansları çevresinde öbelenir.

Ses sinyalleri hakkındaki bu önsel bilgiyi kullanarak katsayılar arasındaki ilintileri daha iyi modelleyebilmek için Gamma Markov rasgele alanlarını (GMRA) önermiştik [1]. Bu yapılar değişinti değişkenlerinin hem zaman hem de frekans eksenindeki komşularına bağlı olarak tanımlanmasını mümkün kılmaktadır. Değişimlerin GMRA'lar ile, değişimlere koşullu kaynak katsayılarının ise Gauss dağılımıyla modellendiği durumda modeldeki her değişken koşullu eşlenik olmaktadır. Yani o değişken hakkındaki önsel bilgimizle değişkenin bağımlı olduğu değişkenlere koşullu dağılımı aynı yapıda olmaktadır. Bu da modeldeki gizli değişkenlerin çıkarımını varyasyonel Bayes ve Gibbs örnekleycisi gibi yöntemler kullanarak yapabilmemizi sağlar. Modelin başarısını etkileyen önemli bir faktör de, değişinti değişkenleri arasındaki ilintinin büyüklüğünü belirleyen hiper parametrelerin değerleridir. Bu hiper parametreler sayesinde GMRA'lar genel ses sinyallerini modelleyebilecek esnek bir yapıya sahip olmaktadır. Ancak, bu modelde birleşik dağılımın düzgeleme katsayısını hesaplayamadığımız için modelin marjinal olabilirliğini de hesaplayamıyor olmamız modelin hiper parametrelerinin eniyilenmesini oldukça zorlaştırmaktadır.

Düzgeleme katsayısının bilinmediği modellerde çıkarım ve

optimizasyon yapabilmek için önerilmiş bir takım yakınsama metodları bulunmaktadır. Bunlar sözde olabilirlik [2], karşıtlık ıraksayı [3], skor eşitleme [4] metodlarıdır. Bu metodlardan sözde olabilirlik ve skor eşitleme sadece tamamı gözlemlenen modellerde kullanılabilir. Karşıtlık ıraksayı ise gizli değişkenler içeren modellere de uyarlanabilir. Bizim ses kaynak modelimizde, zaman-frekans bölgesi katsayılarının değışintileri GMRA'larla modellenmektedir. Katsayılar ise bu değışintilere koşullu olarak Gauss dağılımından gelmektedir. Kaynakları kestirmeye çalıştığımız bir ses işleme probleminde, ne katsayılar ne de değışintiler gözlemlenebilir değışkenler değildir. Bu yüzden bu problemlerde, GMRA hiper parametrelerini, gizli değışkenlerin varlığında eniyileme yapabilmemizi sağlayan karşıtlık ıraksayını kullanarak eniyileyebiliriz. Bu çalışmada, GMRA'lara dayalı ses kaynak modelimizi gürültü temizleme ve tek kanaldan ses kaynaklarını ayırıştırma problemlerinde kullandık. Kestirimlerden geri çatılan ses sinyalleri hem nesnel kriterlerce başarılıdır hem de oldukça az yapay olgu içermektedir.

2. Gamma Markov Rasgele Alanları

Bir Gamma Markov rasgele alanı, iki kısımlı yönsüz bir çizge vasıtasıyla iki grup değışkenin (v ve z) birleşik dağılımını ($p(v, z)$) tanımlar. Çizgenin, düğüm kümesi $\mathcal{V} = \mathcal{V}_v \cup \mathcal{V}_z$ ($\mathcal{V}_v$ ve $\mathcal{V}_z$ değışken gruplarına v and z karşılık gelmektedir) ve ayrıt kümesi $\mathcal{E}$ (a_{ij} hiper parametresi ile birbirlerine bağlanan her v_i ve z_j değışkeni için (i, j) ikililerinden oluşan) ile tanımlandığı düşünürsek, birleşik dağılım $p(v, z)$, şu şekilde verilebilir:

$$p(v, z|a) = \frac{1}{Z_a} \prod_{i: v_i \in \mathcal{V}_v} \phi_v \left(v_i, \sum_{(v_i, z_j) \in \mathcal{E}} a_{ij} \right) \prod_{j: z_j \in \mathcal{V}_z} \phi_z \left(z_j, \sum_{(v_i, z_j) \in \mathcal{E}} a_{ij} \right) \prod_{i, j: (v_i, z_j) \in \mathcal{E}} \phi_e(v_i^{-1}, a_{ij} z_j)$$


Buradaki tekli ve ikili potansiyeller de tanımlanmıştır:

$$\begin{aligned} \phi_v(\xi; \alpha) &= \exp(-(\alpha + 1) \log \xi) \\ \phi_z(\xi; \alpha) &= \exp((\alpha - 1) \log \xi) \\ \phi_e(\xi, \eta) &= \exp(-\xi \eta) \end{aligned}$$

GMRA'larda her v_i değışkeninin tam koşullu dağılımı ters Gamma'dır:

$$\begin{aligned} p(v_i | M(v_i)) &= \frac{p(v_i, M(v_i) | v_{-i})}{p(M(v_i) | v_{-i})} \\ &= \phi_v \left(v_i, \sum_{j: z_j \in M(v_i)} a_{ij} \right) \frac{\prod_{j: z_j \in M(v_i)} \phi_e(v_i^{-1}, a_{ij} z_j)}{Z'} \\ &= \mathcal{IG} \left(v_i; \sum_{j: z_j \in M(v_i)} a_{ij}, \sum_{j: z_j \in M(v_i)} a_{ij} z_j \right) \end{aligned}$$

Burada $M(v_i)$, v_i değışkenini ile bağlantısı olan tüm z_j değışkenlerinin kümesini gösterir ve tüm toplamlar bu



Şekil 1: 3×3 'lük v değışkenlerinden ve ardışık v 'leri birbirine bağlayan z değışkenlerinden oluşan bir GMRA. Burada $a = [a_w \ a_e \ a_n \ a_s]$, modelin hiper parametrelerdir.

değışkenler üzerindendir, v_{-i} , $\mathcal{V}_v$ kümesindeki v_i dışındaki tüm değışkenleri temsil eder. Z' ise aynı terimin pay kısmında geçen dağılımın düzgeleme katsayısıdır. Benzer bir şekilde, modeldeki tüm z_j değışkenleri tam koşullu olarak Gamma dağılımından gelmektedir:

$$p(z_j | M(z_j)) = \mathcal{G} \left(z_j; \sum_{i: v_i \in M(z_j)} a_{ij}, \left(\sum_{i: v_i \in M(z_j)} a_{ij} / v_i \right)^{-1} \right)$$

GMRA'lar asıl olarak ses kaynaklarının zaman-frekans bölgesi katsayılarının değışintilerini modellemek için önerilmiştir. Buradaki amaç ardışık katsayıların ilintilerini modele yansıtmaktır. Genel olarak, birbirinden uzak katsayılar arasında (mesela tonsal sinyallerde harmonikler) da ilinti vardır ama bu ilintiyi genel bir modele dökmek kolay değildir. Bunun yerine, katsayıların büyüklüklerinin yavaş değışir olması modellenebilir. GMRA'lar bunu gerçekleştirecek şekilde, ardışık katsayıların değışintileri arasında pozitif ilinti olmasını sağlar.

Şekil 1'de ses modelimizi dayandırdığımız GMRA yapısını görmekteyiz. Katsayıların değışintileri bu GMRA'daki $v_{\nu, \tau}$ değışkenleri ile modellenir. z değışkenleri ses katsayılarıyla doğrudan ilgisi olmayan, değışintiler arasındaki ilintiyi sağlamaya yarayan ek değışkenlerdir. Kaynak katsayıları, değışinti değışkenlerine koşullu Gauss olarak tanımlanır: $p(s_{\nu, \tau} | v_{\nu, \tau}) = \mathcal{N}(s_{\nu, \tau}; 0, v_{\nu, \tau})$.

Bu ses modeli GMRA'larla koşullu eşleniktir, yani v ve z değışkenlerinin tam koşullu dağılımları, bu gözlem modelinin eklenmesinden sonra da ters Gamma ve Gamma olmaya devam eder. Modeldeki tüm değışkenlerin koşullu dağılımları standart dağılımlar olduğu için bu dağılımlardan örnek çekmek kolaydır ve böylece sonsal dağılımlar Gibbs örnekleycisi tarafından kestirilebilir. Gibbs örnekleycisi, modeldeki her değışkenin diğer değışkenlerin o anki değerlerine bağlı tam koşullu dağılımlarından örnekler çekmekle elde edilen bir geçiş çekirdeği olan bir Markov zinciri Monte Carlo yöntemidir. Bu zincirin durağan dağılımı değışkenlerin sonsal dağılımıdır.

3. Karşıtlık ıraksayı ile Eniyileme

Karşıtlık ıraksayı [3], düzgeleme katsayısı Z_θ 'nın logaritmasının gradyanını Markov zinciri Monte Carlo (MZMC)

örnekleri kullanarak yakınsamaya çalışan bir yaklaşık en yüksek olasılık metodudur. Olabilirliğin, $\mathcal{L}(\theta; \mathbf{x})$, logaritmasının gradyanı

$$\frac{\partial \mathcal{L}(\theta; \mathbf{x})}{\partial \theta} = \frac{1}{T} \sum_{t=1}^T \frac{\partial \log \pi(\mathbf{x}(t); \theta)}{\partial \theta} - \frac{\partial \log Z_\theta}{\partial \theta} \quad (1)$$

şeklinde ifade edilebilir. Burada T gözlemlenen veri vektörlerinin sayısıdır. Düzgeleme katsayısının logaritmasının gradyanı aşağıdaki ifadeye eşittir.

$$\frac{\partial \log Z_\theta}{\partial \theta} = \left\langle \frac{\partial \log \pi(\mathbf{x}; \theta)}{\partial \theta} \right\rangle_{p(\mathbf{x}|\theta)} \quad (2)$$

θ_k , θ parametresinin k inci döngüdeki değerini ifade edecek şekilde, bu gradyan $p(\mathbf{x}|\theta_k)$ dağılımından örnekler çekerek yakınsanabilir:

$$\frac{\partial \log Z_\theta}{\partial \theta} \approx \frac{1}{N_i} \sum_{j=1}^{N_i} \frac{\partial \log \pi(\mathbf{x}^{(j)}(\theta_k); \theta)}{\partial \theta} \quad (3)$$

En yüksek olasılık kestirimi döngüsel bir şekilde bulunabilir. Burada örnekler, θ_k değerine bağlı olduklarını göstermek için, $\mathbf{x}^{(j)}(\theta_k)$ şeklinde gösterilmiştir. Gradyanı bu şekilde hesaplamının, durağan dağılımı $p(\mathbf{x}|\theta)$ olan Markov zincirinin yakınsamasını gerektirdiği için, hesaplama karmaşıklığı çok yüksek olmaktadır.

Hinton [3], gözlemlenen veriden başlanırsa Markov zincirinin sadece birkaç adımının gradyanın yönünü tahmin etmek için yeterli olduğunu göstermiştir. Bu yöntem, karşılıklı ıraksayı (KI) ölçeviden enküçültülmesine denk gelmektedir:

$$KI_n = KL(p_{\mathbf{x}}(\mathbf{x})||p(\mathbf{x}|\theta)) - KL(p^n(\mathbf{x}|\theta)||p(\mathbf{x}|\theta)) \quad (4)$$

Bu denklemde, $p^n(\mathbf{x}|\theta)$ dağılımı, Markov zincirinin n adım çalıştırılmasıyla elde edilmiş olan dağılımdır. En yüksek olasılık metodunun $KL(p_{\mathbf{x}}(\mathbf{x})||p(\mathbf{x}|\theta))$ ölçevidi $p_{\mathbf{x}}(\mathbf{x})$ ve $p(\mathbf{x}|\theta)$ dağılımlarını birbirine mümkün olduğunca yaklaştırmak için, enküçülttüğü düşünülürse, karşılıklı ıraksayını enküçültmek, durağan dağılıma değışintiyi küçük tutarak biraz yaklaşmak anlamına gelmektedir. Bu ölçevede düzgeleme katsayısıyla ilgili terimler birbirini götürür:

$$KI_n = -\langle \log \pi(\mathbf{x}; \theta) \rangle_{p_{\mathbf{x}}(\mathbf{x})} + \langle \log \pi(\mathbf{x}; \theta) \rangle_{p^n(\mathbf{x}|\theta)}$$

Karşılıklı ıraksayı ayrıca gizli değişkenlerin var olduğu durumlarda da uygulanabilir. Gözlemlenen değişkenlerin, $\mathbf{y}$, ve gizli değişkenlerin, $\mathbf{x}$, birleşik dağılımının $p(\mathbf{x}, \mathbf{y}|\theta) = \pi(\mathbf{x}, \mathbf{y}; \theta)/Z_\theta$ şeklinde olduğu bir modelde, karşılıklı ıraksayı şu şekilde tanımlanabilir:

$$KI_n = -\langle \log \pi(\mathbf{y}, \mathbf{x}; \theta) \rangle_{p(\mathbf{x}|\mathbf{y}, \theta)} \langle \log \pi(\mathbf{y}, \mathbf{x}; \theta) \rangle_{p^n(\mathbf{x}, \mathbf{y}|\theta)}$$

Burada $p^n(\mathbf{x}, \mathbf{y}|\theta)$ dağılımı tüm değişkenlerin Markov zincirinin n inci adımında elde edilen dağılımdır. KI_n ölçeviden enküçültülmesi Beklenti-Enyükseltme algoritmasındaki gibi yapılabilir. Önce, KI_n ölçeviden gradyanı $p(\mathbf{x}|\mathbf{y}, \theta_k)$ dağılımına göre yakınsanır, sonra θ_k buna göre güncellenir. $p^n(\mathbf{x}, \mathbf{y}|\theta_k)$ dağılımı, $T_x = p(\mathbf{x}|\mathbf{y}, \theta_k)$ geçiş çekirdeğinin gözlemlenen veri üzerinde, $T_y = p(\mathbf{y}|\mathbf{x}, \theta_k)$ çekirdeğinin

üretilen gizli değişkenler üzerinde n defa uygulanmasıyla elde edilir. Eğer gözlemlenen değişkenler, $\mathbf{y}$, gizli değişkenlere, $\mathbf{x}$, göre veya gizli değişkenler gözlemlenen değişkenlere göre koşullu bağımsız değilse, geçiş çekirdekleri bir Markov zincirinin yakınsayana kadar çalıştırılmasına denk gelmektedir.

Karşılıklı ıraksayı belli bazı modellerde en yüksek olasılık kestirimiyle tutarlı sonuçlar vermektedir. Bu modeller iki boyutlu Gauss dağılımı [5] ve Gauss Boltzmann makineleridir [6, 7]. Ama genel olarak, karşılıklı ıraksayı yanlı kestirimler üretmektedir [5].

4. Deneyler ve Sonuçlar

Bu çalışmada iki tip deney yaptık: gürültü temizleme ve tek kanaldan ses kaynaklarını ayırıştırma. Bu deneylerde zaman-frekans bölgesindeki ses kaynak katsayılarını GMRA'larla modelledik. Değişkenlerin sonsal dağılımının kestirimi Gibbs örnekleyicisi ile, modelin hiper parametreleri ise karşılıklı ıraksayını enküçültürerek gerçekleştirildi. Deneylerde 6-10 sn. uzunluğunda ses sinyalleri kullanıldı. Bu sinyaller değıştirilmiş ayırık kosinüs dönüşümü (DAKD) ile 512 selelik zaman-frekans gösterimine geçirilmiştir. DAKD dikgen bir dönüşüm olduğu için bahsettiğimiz problemler zaman ve aktarım bölgesinde denktir.

İlk deneyde ses kaynaklarına eklenmiş beyaz gürültüleri temizleme problemine baktık. Bu problemde ses kaynak katsayılarının, $\mathbf{s}$, ve gözlemlenen sinyalin katsayıları, $\mathbf{x}$, aşağıdaki gibi modellenir:

$$s_{\nu, \tau} \sim \mathcal{N}(0, v_{\nu, \tau}), \quad x_{\nu, \tau} \sim \mathcal{N}(s_{\nu, \tau}, r) \quad (5)$$


Burada r gürültü değışintisini, ν ve τ ise frekans ve zaman indekslerini gösterir. Karşılıklı ıraksayı ölçevidi burada

$$KI_n = -\langle \log \pi(\mathbf{x}, \mathbf{s}, \mathbf{v}, \mathbf{z}, r; \mathbf{a}) \rangle_{p(\mathbf{s}, \mathbf{v}, \mathbf{z}, r|\mathbf{x}, \mathbf{a}_k)} + \langle \log \pi(\mathbf{x}, \mathbf{s}, \mathbf{v}, \mathbf{z}, r; \mathbf{a}) \rangle_{p^n(\mathbf{x}, \mathbf{s}, \mathbf{v}, \mathbf{z}, r|\mathbf{a}_k)}$$


şeklinde dir. İlk terimi hesaplamak için sonsal dağılımdan çekilen N_i tane örnek kullanılırken, ikinci terim bu Markov zincirinden üretilen $\mathbf{x}^1$ değerleri ve bu değerlerden başlayan Markov zincirinden elde edilen $\mathbf{s}^1, \mathbf{v}^1$ ve $\mathbf{z}^1$ değerleriyle hesaplanır.

Şekil 2'de gürültülü bir konuşma sinyalini (solda) ve gürültüden temizlenmiş sinyali (sağda) görüyoruz. Gürültülü sinyali temiz bir konuşma sinyaline 17.5dB beyaz gürültü ekleyerek elde ettik. Geri çatılan sinyal orijinaline çok yakındır ve hiçbir yapay olgu taşımamaktadır. Orijinal sinyal ile iki sinyalin farkı arasındaki sinyal gürültü oranı 20.77dB'dir. Aynı kaynağa Gamma Markov zincirlerini (GMZ) [1] kullanarak durağan olamayan bir gürültü ekleyip, ses kaynağını GMRA ile gürültüyü GMZ ile modellediğimiz deneyde ise Şekil 3'deki sonucu elde ettik. Burada eklenen gürültünün sinyal gürültü oranı yaklaşık 1.4dB'dir. Orijinal sinyalin hataya oranı ise 6.4dB'dir.

Son olarak, müzik sinyallerinde tonsal ve vurmali kaynakları birbirinden ayırmak için, modelimizi tek kanaldan kaynak ayırıştırma probleminde kullandık. Tonsal kaynağı GMRA'yla, vurmali kaynağı GMZ'yle modelledik [1]. Tablo 1'de, elde edilen sonuçları bir yatay ve bir dikey GMZ ile elde edilen sonuçlarla [8] karşılaştırdık.



Şekil 2: Beyaz gürültü eklenmiş konuşma sinyali (solda) ve geri çatılan sinyal (sağda).



Şekil 3: Durağan olmayan gürültü eklenmiş konuşma sinyali (solda) ve geri çatılan sinyal (sağda).

Burada kullanılan başarı kriterleri sinyal bozulma oranı (SBO), sinyal girişim oranı (SGO) ve sinyal yapay olgu oranıdır (SYO). Bu kriterler, bir kaynak kestiriminin, hedef sinyal, s_{hedef} , diğer kaynakların girişimi, e_{gir} ve ayrıştırma algoritmasının oluşturduğu yapay olgular, e_{yap} , bileşenlerinden oluştuğu kabulüyle şu şekilde tanımlanmaktadır [9]:

$$\text{SBO} \equiv 10 \log_{10} \frac{\|s_{\text{hedef}}\|^2}{\|e_{\text{gir}} + e_{\text{yap}}\|^2} \quad (6)$$

$$\text{SGO} \equiv 10 \log_{10} \frac{\|s_{\text{hedef}}\|^2}{\|e_{\text{gir}}\|^2} \quad (7)$$

$$\text{SYO} \equiv 10 \log_{10} \frac{\|s_{\text{hedef}} + e_{\text{gir}}\|^2}{\|e_{\text{yap}}\|^2} \quad (8)$$

Bu deneyde, GMRA kestirimlerinden geri çatılan sinyallerin yukarıdaki kriterlere göre GMZ sonuçlarından genel olarak daha başarılı olduğunu görüyoruz. Dinleyerek yapılan öznel testlerde de GMRA sonuçları daha doğal ve temiz duyulmaktadır. Bu deney sonuçlarına <http://www.cmpe.boun.edu.tr/~dikmen/siu09/> adresinden ulaşılabilir.

5. Vargılar

GMRA'ları kullanarak elde edilen ses kaynak modeli, zaman-frekans gösteriminde katsayıların yerel ilintisini kapsayabilen bir yapıdır. Model oldukça esnek olup, hiper parametrelerinin eniyilenmesiyle değişik özellikteki ses sinyallerine uygun hale getirilebilmektedir. Bu eniyileme işlemi, GMRA'ların düzgeleme katsayıları hesaplanamadığı için en yüksek olabilirlik kestirimiyle yapılamamaktadır. Bu çalışmada GMRA hiper parametrelerini karşıtlık ıraksayımı kullanarak eniyiledik.

Ses modelimizi gürültü temizleme ve tek kanaldan kaynak ayrıştırma problemlerinde test ettik. Hiper parametreleri KI kullanılarak eniyilenmiş GMRA ses modeli ile geri çatılan

Tablo 1: İki müzik sinyali üzerinde tek kanaldan kaynak ayrıştırma sonuçları.

	$\hat{s}_1$			$\hat{s}_2$		
	SBO	SGO	SYO	SBO	SGO	SYO
GMZ	-4.23	-2.42	4.82	1.34	13.13	1.85
GMRA	-0.85	3.5	2.74	7.67	10.61	11.11
GMZ	-7.74	-6.19	4.62	-1.14	16.62	-0.97
GMRA	-4.27	-1.61	3.0	5.59	19.82	5.8

sinyallerin daha önce önerilmiş Gamma Markov zincirleriyle elde edilen sonuçlardan daha temiz ve doğal duyulduğunu gözlemledik. Nesnel karşılaştırma kriterlerine göre de sonuçlar genel olarak daha başarılıdır.

Modelin eniyilenmesinde, gözlemlenen veriden başlayarak bir adımlık Markov zinciri çalıştırmak dahi, gizli değişkenlerin aralarındaki ilişkilerden dolayı, uzun sürmektedir. Ayrıca, metodun gradyana dayalı olması kazanç parametresinin ayarlanmasını gerektirmektedir. Düzgeleme katsayısının bilinmediği durumlar için önerilmiş ama gizli değişkenlerin varlığında uygulanamayan sözde olabilirlik ve skor eşleme metodlarının bu model için geliştirilmesi faydalı olacaktır.

6. Teşekkür

Bu çalışma TÜBİTAK/107E050 no'lu proje tarafından desteklenmektedir.

7. Kaynakça

- [1] A. T. Cemgil and O. Dikmen, "Conjugate Gamma Markov random fields for modelling nonstationary sources," in *ICA'07*, 2007, pp. 697–705.
- [2] J. Besag, "Statistical Analysis of Non-lattice Data," *Statistician*, vol. 24, no. 3, pp. 179–195, 1975.
- [3] G. E. Hinton, "Training products of experts by minimizing contrastive divergence," *Neural Computation*, vol. 14, no. 8, pp. 1771–1800, 2002.
- [4] A. Hyvärinen, "Estimation of non-normalized statistical models using score matching," *Journal of Machine Learning Research*, vol. 6, pp. 695–709, 2005.
- [5] M. Á. Carreira-Perpiñán and G. E. Hinton, "On contrastive divergence learning," in *10th Int. Workshop on Artificial Intelligence and Statistics (AISTATS 2005)*, 2005, pp. 59–66.
- [6] C. K. I. Williams and F. V. Agakov, "An analysis of contrastive divergence learning in Gaussian Boltzmann machines," Tech. Rep. EDI-INF-RR-0120, Division of Informatics, University of Edinburgh, 2002.
- [7] A. Hyvärinen, "Consistency of pseudolikelihood estimation of fully visible Boltzmann machines," *Neural Computation*, vol. 18, no. 10, pp. 2283–2292, 2006.
- [8] O. Dikmen and A. T. Cemgil, "Inference and parameter estimation in Gamma chains," Tech. Rep. CUED/F-INFENG/TR.596, University of Cambridge, February 2008.
- [9] C. Févotte, R. Gribonval, and E. Vincent, "BSS-EVAL Toolbox User Guide," Tech. Rep. 1706, IRISA, Rennes, France, 2005.