

Model Tabanlı Ses Dizisi Hizalanması

Model Based Audio Sequence Alignment

Doğaç Başaran, Emin Anarım

Elektrik ve Elektronik Mühendisliği Bölümü
 Boğaziçi Üniversitesi
 dogac.basaran@gmail.com
 anarim@boun.edu.tr

Ali Taylan Cemgil

Bilgisayar Mühendisliği Bölümü
 Boğaziçi Üniversitesi
 taylan.cemgil@boun.edu.tr

ÖZETÇE

Bu çalışmada, çoklu ses dizilerinin hizalaması sorunu olasılıksal bir model yaklaşımı ile ele alınmıştır. Önerilen modelde, bağımsız ve eşzamansız kaydedilmiş ses kayıtlarından özetlenmiş, zamanla değişen öznitelikler tanımlanmıştır. Bu çalışmada çoklu ses kayıtlarının tümünün alınamadığı kayıplı, hiçbir hizalamadan gerekli bilgiyi içermediği durum ele alınmıştır. Eşleştirme işlemi, yaklaşık Bayes çıkarım ile gerçekleştirilmiştir. Burada hizalanma kaymasının kesin sonsal dağılımın öneklenmesi için bir benzetimli tavlama yaklaşımının kullanımı sergilenmiştir. Gerçek ve yapay verilerle yapılan benzetim sonuçlarıyla, zor ve muğlak senaryolar veya kısmi eşleştirme mertebe de önerilen yöntemin kullanılabilirliği gösterilmiştir.

ABSTRACT

We formulate alignment of multiple audio sequences in a probabilistic framework. Our approach defines a generative model for time varying features extracted from audio clips that are recorded independently and asynchronously. We are able to handle missing data and multiple clips where no clip is covering the entire material. The matching is achieved via approximate Bayesian inference. Here, we illustrate a simulated tempering approach for sampling from the exact posterior density of the clip offsets. The simulation results on synthetic and real data suggest that the framework is able to handle difficult ambiguous scenarios or partial matchings.

1. GİRİŞ

Ses eşleştirme genel olarak, bilinmeyen bir ses bülütünün büyük bir veri tabanında eşleştirildiği bir tanımlama problemi olarak ele alınır. Literatürde, çok gürültülü koşullarda, yüksek eşleştirme başarımı sağlayan dayanıklı ses parmakizi yöntemleri mevcuttur [1, 2]. Bu bildiride, çoklu eşleştirme problemi ele alınmış ve ses eşleştirme sorununa değişik bir açıdan bakılmıştır.

Kayıt ortamında birçok eşzamansız mikrofon olduğu ve bunların kayıtlarının birbirinden bağımsız ve değişik zamanlarda alındıkları varsayılmıştır. Amaç, örtüşen ya da örtüşmeyen ses kayıtlarının başlangıç noktalarına göre genel bir zaman çizgisinde hizalamaktır. Bu sorunun genel geçer ses eşleştirme yaklaşımlarından en önemli farkı, temiz orjinal ses

kayıtlarının olduğu bir veri tabanının değil sadece muhtemelen kaynağın gürültülü kayıtlarının bulunmasıdır. Ayrıca herhangi bir gözlemin bütün zaman çizgisini kaplamak zorunda olmadığı da düşünmek gereklidir. Çoklu ses eşleştirme sorunu ele almada itici güç tam hizalanmış kayıtların kaynak ayırtırma, iyileştirme veya yeniden oluşturmak için kullanmaktadır.

Böyle bir senaryo bir gösteri esnasında bir konser salonunda olabilir. Bazı dinleyicilerin değişik kalitede kayıt düzenekleri ile konserin kendi beğendikleri kısımlarını kaydetmekleri durumda, her bir kayıt farklı bir açıdan elde edilmiş olur. Bu ses kayıtlarını sözünü ettigimiz amaçlar doğrultusunda kullanabilmek için, her bir kaydın net bir şekilde genel zaman çizgisinde hizalanması gereklidir. Benzer yaklaşımalar değişik açılardan çekilmiş imgelerin bir araya getirilerek panoramik görüntü oluşturması probleminde de mevcuttur.

İlkeler olarak soruna ilinti ve şablon eşleştirme gibi belirlenimci yöntemlerle yaklaşmak mümkündür. Fakat bunlarda da belirli sınırlar mevcuttur. Öncelikle ses sinyalleriyle ilgilenirken örnek sayısı genelde çok olur ve çok sayıda kayıt olduğunda işlem maliyeti çok fazladır. Birçok ses eşleştirme uygulaması, çoklu ses kayıtlarında bile ikişerlik şekilde çalışır. K tane ses kaydı olduğunda $O(K^2)$ mertebesinde ikili eşleştirme yapmak gerekmektedir. Buna ek olarak eğer ses kayıtları örtüşmezse veya bir kayıtta bazı veri noktaları kaçırlırsa, ilinti ve şablon eşleştirme yöntemlerinin nasıl uygulanacağı çok açık değildir. İşlem karmaşaklığını ve veri sayısını azaltmanın açık bir yolu direk ses sinyalinin üstünde çalışmak yerine öznitelik uzayında çalışmaktır. Kısa süreli izge büyülüğu, yerel renk doygunluğu enerji dağılımı, eksiz olmayan dizey çarpanlarına ayırma ve kısa süreli pencerelerdeki sinyal enerjisi, ses eşleştirme çatısı altında en çok kullanılan özniteliklerdir [1, 2]. Fakat özniteliklerle çalışırken bile bir referans zaman çizgisini olmadan, birçok kısa kayıtla çalışmak zordur.

Burada, model bazlı bir yaklaşım ve ses öznitelikleri için üretimsel bir model tanımlanmaktadır. Modelleme yaklaşımı herhangi bir öznitelik yönünü kullanmaya müsaade etse de, biz pozitif öznitelikleri bu çalışmada kullanmaktadır. Bu modelin bir üstünlüğü de ses kayıtlarında ikili eşleştirme yapmak yerine her kaydı gizli bir ses içeriğine hizalıyor olması ve bunun işlemsel karmaşaklığını azaltmasıdır. Uygun bir puan işlevi tanımlanarak eksikli kayıtlar için bile sinyalleri eşleştirmek mümkündür. Sadece 2 tane kayıt olduğu durumda ise olası

her hizalama için puan işlevi, yarı örtüşme ve örtüşmeme durumlarını tanımlayarak yapmak mümkündür. Ancak, çoklu dizilerde net skorlama mümkün değildir. Bu çalışmada, ortak zaman çizgisi üzerinde çoklu ses sinyallerini eşleştirmek için benzetimli tavlama çatısı altında Gibbs örneklemeye yaklaşımı önerilmektedir.

Bölüm 2'de önerilen model ayrıntılı bir şekilde tanımlanmakta ve eşleştirme için uygun bir puan işlevi verilmektedir. Gibbs örnekleyicisi için benzetimli tavlama yaklaşımı Bölüm 3'te ve deney düzeneği, benzetim sonuçları ve tartışmalar Bölüm 4'te verilmektedir.

2. ÖNERİLEN MODEL

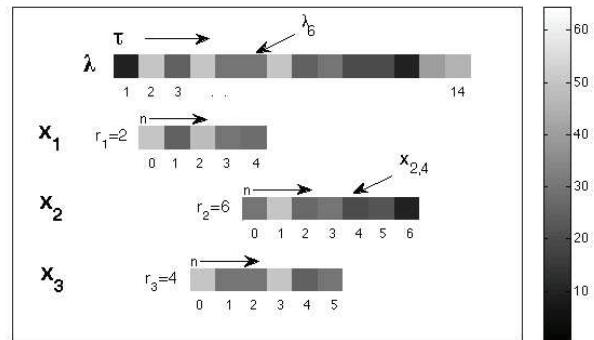
Bu bölümde, eşleştirme problemi için oluşturulan olasılık modeli, basit bir örnekle Şekil 1'de verilmektedir. Model içinde doğrudan ses sinyali yerine, öznitelik dizilerini tanımlamıştır. Burada öznitelik olarak, altbantlardaki zamanla değişen enerji bilgisi ele alınmaktadır. Enerji bilgisi, 20 ms'lik örtüşmeyen pencerelerde kısa zamanlı Fourier dönüşümü alarak ve dönüşüm katsayılarının karelerini sıkılık indeksi üzerinden toplayarak elde edilmiştir. Modelin gösterimini kolaylaştırmak amacıyla, örnekte spektrogramın yalnızca bir altbandı kullanılmaktadır. Ancak çeşitli altbantların eşzamanlı kullanıldığı çok değişkenlik durumlar için yaklaşımın genelleştirilmesi mümkündür. Modelin anafikri, gözlemlenmiş ve doğru şekilde hizalanmış öznitelik dizilerinin, aslında alta yatan ve gözlemlenemeyen gerçek ses kaynağının öznitelik dizilerinin gürültülü uyarlamaları olarak ele alınmasıdır.

Gizli öznitelik yöntemi λ_τ ile tanımlanmakta ve $\tau = 1 \dots T$ her yerde geçerli bir zaman çerçevesi indeksi olarak tanımlanmaktadır. Bir tane altbant için öznitelik yöntemi bir sayıldır. Şekil 1'de verilen örnekte, üç tane gözlemlenmiş kayıt ve x_k k 'inci kaydın öznitelik vektörünü, N_k da bu öznitelik vektörünün uzunluğunu ifade etmektedir. Ayrıca $T = 14$, $N_1 = 5$, $N_2 = 7$, ve $N_3 = 6$ almıştır. Burada n yerel bir zaman çerçevesi indeksidir ve k 'inci kaydın n 'inci spektrum katsayısı $x_{k,n}$ olarak ve k 'inci kaydın hizalama değişkeni r_k olarak ifade edilmektedir. Örneğin ikinci kayıt her yerde geçerli zamanda $\tau = 6$ noktasında başladığından, $r_2 = 6$ olmaktadır. Bu senaryoda, kayıtlar çeşitli noktalarda örtüşmekte ve tam olarak $x_{1,4}, x_{2,0}$ ve $x_{3,2}$ her yerde geçerli zamanla $\tau = 6$ 'da çakışmaktadır. Şekilden de görülebileceği gibi bütün bu katsayı değerleri birbirine çok yakın değerlerdedir. Böyle olmalarının sebebi, bunların ortak gizli kaynak λ_6 'nın gürültülü uyarlamaları olmalarıdır.

Üretimsel model aşağıdaki gibi verilmiştir:

$$\begin{aligned} \lambda_\tau &\sim \mathcal{IG}(\lambda_\tau; \alpha_\lambda, \beta_\lambda) \\ r_k &\sim \prod_{\tau=1}^{T-N_k+1} \pi_{k,\tau}^{[r_k=\tau]} \\ x_{k,n}|r_k, \lambda_\tau &\sim \prod_{\tau=1}^T \mathcal{G}(x_{k,n}; \alpha, \alpha/(\lambda_\tau))^{[n=\tau-r_k]} \end{aligned}$$

Burada \mathcal{IG} ve \mathcal{G} sırasıyla ters gamma ve gamma dağılımlarını ifade etmektedir. Bu dağılımlar pozitif rastgele değişkenleri modellemektedeki esneklikleri ve eşleniklik özellik-



Şekil 1: Model açıklaması. λ gizli, x_1, x_2 ve x_3 gözlemlenmiş

leri nedeni ile seçilmişlerdir. k 'inci kaydın hizalama değişkeni r_k 'ın τ zamanında olma olasılığı $\pi_{k,\tau}$ ile ifade edilmektedir. Ayrıca r_k hizalama değişkeninin birbirçimli dağılımlı olduğu varsayılmıştır. Spektrogram büyüğlüğü, öznitelik yönü olarak kullanıldığından, hem λ_τ hem de $x_{k,n}$ pozitif dağılımlardır.

Modelin daha iyi anlaşılmasını için hiper-parametre α 'yı incelemek gerekmektedir. Üretimsel modele göre $x_{k,n}$ değişkeninin ortalaması ve değişimini sırasıyla λ_τ ve $\frac{\lambda_\tau^2}{\alpha}$ olarak tanımlanmıştır.

Bu nedenle $x_{k,n}$ 'in λ_τ 'dan ne kadar saplığını ayarlayan parametrenin α olduğu açıklanır. Eğer α büyükse, değişim çok küçük demektir, bu da $x_{k,n}$ 'in λ_τ 'ya yakın bir değeri olduğunu anlamına gelmektedir. Fakat eğer α küçükse, bu değişimin yüksek olması yani $x_{k,n}$ 'in λ_τ 'dan yüksek miktarda sapabilmesi anlamına gelmektedir.

Burada asıl amaç, gizli öznitelik yönünü kestirmek değil, $r_{1:K}^*$ ile ifade edilen en olasılıklı diziliyi bulmaktır. Bu birleşik koşullu dağılım $p(r_{1:K}|x_{1:K,0:N_k-1})$ 'in kipine karşılık gelmektedir. Doğru dizilime dair hiçbir öncül bilginin olmadığı varsayırsak, sonsal dağılım yerine olabilirlik dağılımı $p(x_{1:K,0:N_k-1}|r_{1:K})$ kullanılabileceği açıklanır. Modele göre tam olabilirlik dağılımı aşağıda verilmektedir:

$$\begin{aligned} p(x_{1:K,0:N_k-1}|r_{1:K}) &= \int d\lambda_{1:T} \prod_{k=1}^K \prod_{n=0}^{N_k-1} p(x_{k,n}|r_k, \lambda_{1:T}) \prod_{\tau=1}^T p(\lambda_\tau) \end{aligned}$$

Gizli öznitelik yönünün her bir elemanı λ_τ , birbirlerinden bağımsızdır ve $x_{k,n}, \lambda_{1:T}$ verildiğinde ise birbirlerinden koşullu olarak bağımsız olacakları açıklanır. Gamma ve ters gamma dağılımlarının eşleniklikleri sayesinde tümlevin analitik olarak elde edilmesi mümkündür. Sonuçta oluşan olabilirlik dağılımının logaritması, $\mathcal{L}(r_{1:K})$, aşağıdaki gibi ifade edilmektedir.

$$\begin{aligned}
\mathcal{L}(r_{1:K}) = & -T \log \Gamma(\alpha_\lambda) + T \alpha_\lambda \log \beta_\lambda \\
& + \sum_{\tau=1}^T \sum_{k=1}^K \sum_{n=0}^{N_k-1} [n = \tau - r_k] \left((\alpha - 1) \log x_{k,n} \right. \\
& \quad \left. - \log \Gamma(\alpha) + \alpha \log \alpha \right) \\
& + \sum_{\tau=1}^T \log \Gamma(\alpha_\lambda + \sum_{k=1}^K \sum_{n=0}^{N_k-1} [n = \tau - r_k] \alpha) \\
& - \sum_{\tau=1}^T (\alpha_\lambda + \sum_{k=1}^K \sum_{n=0}^{N_k-1} [n = \tau - r_k] \alpha) \\
& \log (\beta_\lambda + \sum_{k=1}^K \sum_{n=0}^{N_k-1} [n = \tau - r_k] \alpha x_{k,n})
\end{aligned}$$

Daha sonra $\mathcal{L}(r_{1:K})$ 'in $r_{1:K}$ 'ya göre enbüyüğünü bularak, eniyi dizilim noktalarına aşağıdaki gibi ulaşmak mümkündür,

$$\begin{aligned}
r_{1:K}^* &= \arg \max_{r_{1:K}} \mathcal{L}(r_{1:K}) \\
&= \arg \max_{r_{1:K}} \log p(x_{1:K, 0:N_k-1} | r_{1:K})
\end{aligned}$$

Hızalama değişkenleri r_k ayrik oldukları için arama uzayı sonludur ve her olası hızalama $r_{1:K}$ için puanlama yaparak en doğru hızalamayı bulmak anamlıdır. Fakat büyük K değerleri için arama uzayı çok büyük, dolayısıyla Gibbs örnekleyicisi gibi yaklaşık çıkarmış yöntemlerine başvurmak gereklidir.

3. BENZETİMLİ TAVLAMA İLE GIBBS ÖRNEKLEYİCİSİ

Gibbs örneklemesi, en az 2 boyutlu dağılımlardan örneklemek için kullanılan ünlü Markov Chain Monte Carlo (MCMC) yöntemlerinden biridir [4, 5]. Örnekleme yöntemleri çoğunlukla hedef dağılımin analitik hesaplamaları yapmak için çok karışık olduğu durumlarda kullanılır. Önerilen modelde, koşullu birleşik dağılımlardan örneklemeye yapmak için Gibbs örnekleyicisi kullanılmıştır. Gibbs örnekleyicisi, tam koşullu dağılımları kullanarak, değişkenleri tek tek örnekler [3]. Tam koşullu dağılım, diğer tüm rastgele değişken ve verilere göre şekillenmiş değişkenin olasılığı anlamına gelir. Bu tam koşullu dağılımlar çoğunlukla tek boyutlu, izlenebilir ve modele bağlı örneklemeye için uygundur.

Örneğin θ değişkeninin tam koşullu dağılımı, $p(\theta|.)$ olarak ifade edilir. Öne sürülen modelden, tam koşullu dağılımlar $p(\lambda_\tau|.)$ ve $p(r_k|.)$ aşağıdaki gibi türetilmiştir.

$$\begin{aligned}
p(\lambda_\tau|.) &= \mathcal{IG}(\lambda_\tau; \alpha_\lambda + \sum_{k=1}^K \sum_{n=0}^{N_k-1} [n = \tau - r_k] \alpha, \\
&\quad \beta_\lambda + \sum_{k=1}^K \sum_{n=0}^{N_k-1} [n = \tau - r_k] \alpha x_{k,n}) \\
p(r_k|.) &= \prod_{n=0}^{N_k-1} \prod_{\tau=1}^T \mathcal{G}(x_{k,n}; \alpha, \frac{\alpha}{\lambda_\tau})^{[n=\tau-r_k]}
\end{aligned}$$

Genel olarak MCMC yöntemleri hedef dağılımların yerel kiplerinde takılabilir. Bu yüksek oranda parametre kümelerinin ve

rastgele değişkenlerin başlangıç değerleriyle doğrudan ilgilidir. Bütün rastgele değişkenlerin başlangıç değerleri orjinal modelden elde edilse bile, ki bu hiper-parametrelerin bilinmesi veya doğru kestirilmesi anlamına gelmektedir, örnekleyicinin yerel bir enbüyükte takılma olasılığı her zaman vardır. Bu durumu engellemek amacıyla kullanılan yöntemlerden birisi aşağıda verilmektedir:

Döngülerin başında örnekler tam koşullu $p(r_k|.)$ dağılımdan değil, bunun bir katı olan $p(r_k|.)^\beta$ dağılımdan çekilir. β parametresi küçük bir değerden başlar ve döngü sayısı arttıkça 1'e doğru yaklaşır. β küçük olduğunda tam koşullu dağılımin doruk noktaları sönümlenir ve daha düz bir hale gelir, böylece daha az olası örneklerin de çekilebilmesi sağlanır. β 1'e doğru yaklaşıkça, örnekler gerçek tam koşullu dağılımdan çekilir. Buna Benzetimli Tavlama (BT) denir [3, 6]. Eğer değişkenlerin başlangıç değerleri birleşik dağılımin yerel bir enbüyüğüne götürürse, bu yöntemle dağılımı düzleştirerek örnekleyicinin yerel bir enbüyükte takılı kalmasına sağlanabilir ve dağılımin birincil kipinden örnek çekmeye başlaması beklenebilir. Ayrıca β arttıkça, birincil kip yanı global enbüyükte kalır. Fakat bu yöntemle bile örnekleyicinin sonunda birincil kipi bulacağının garantisini yoktur.

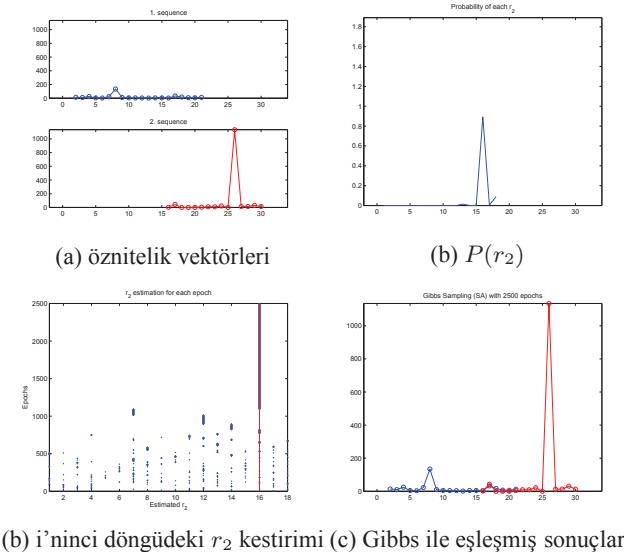
Başka bir BT stratejisi de döngüler sırasında α parametresini değiştirmek olabilir. Dikkat edilirse, tam koşullu dağılım $p(r_k|.)$ 'in değişintisi α parametresiyle ters orantılı olduğu görülebilir. Dolayısıyla küçük bir α değerinden başlayarak, orjinal değere doğru artırmak da yine bir tavlama yöntemidir. α parametresi küçükken, tam koşullu dağılımin değişintisi yüksektir ve bu nedenle daha düz bir dağılıma dönüşür. α orjinal değerine yaklaşıkça, örnekler gerçek tam koşullu dağılımdan çekilecektir.

4. SONUÇLAR

Deneysel sonuçlar, hem yapay hem gerçek verilerle elde edilmiştir. Yapay veri, hiper-parametre kümesi $\{\alpha_\lambda, \beta_\lambda, \alpha\}$ ile öne sürülmüş modelden elde edilmiştir. Gibbs örnekleyicisinin herhangi bir tavlama olmaksızın sonsal dağılımin yerel eniyiye sıkılıkla takıldığı gözlemlenmiştir. Öte yandan benzetimli tavlama yaklaşımı uygulandığında, tavlama stratejisine bağlı olarak daha iyi bir başarına ulaşılmıştır. Daha önce de belirtildiği gibi, örnekleyicinin sonsal dağılımin öncül kipinden örnek alacağını garantilemek mümkün değildir. Bu sıkıntıyı ortadan kaldırmanın tek yolu Gibbs örnekleyicisini farklı başlangıç noktalarından çok defalar çalıştırarak ve paysal olabilirlik dağılımını, $p(r_{1:K}|x_{1:K, 0:N_k-1})$, kullanarak en uygun çıktıyı kabul etmektir.

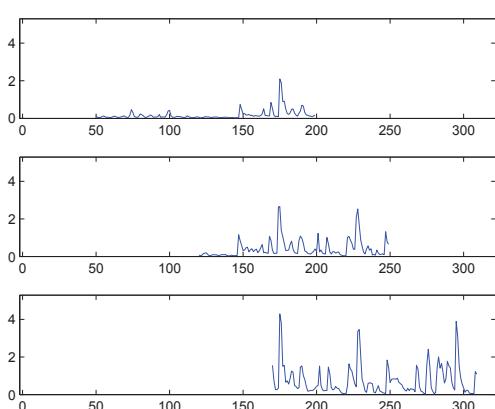
Önerilen model bazı örnekler kayıp olduğunda bile, sınıyalleri başarıyla eşleştirmektedir. Şekil 2'de böyle bir durum sergilenmektedir. Burada kayıt 2'nin kayıt 1 ile örtüsen örneklerinden bazıları silinmiştir. Kayıtlar Şekil 2.a da gösterilmektedir. Şekil 2.b, r_1 verildiğinde her olasılık hızalama için r_2 'nin olasılığını göstermektedir. Yukarıda dephinildiği gibi benzetimli tavlama, tam koşullu dağılımı düzleştirir ve tavlanmış dağılımdan alınan örnekler, birbirimli örneklerden daha iyi sonuç vermektedir. Fakat döngü sayısı arttıkça, örnekler orjinal tam koşullu dağılımdan çekilir ve böylece örnekleyici çoğunlukla dağılımin kipinden örnekler alır. Şekil 2.b'de r_2 kestirimi, her döngü için gösterilmiştir. Şekil 2.d kayıtlar arasındaki son eşleşmeyi göstermektedir. Gerçek veri benze-

timi için ilk adım öznitelik yöneylerini çıkarmaktır. Veriler, ses kanalları, örtüşmeyen 25ms uzunluğundaki pencelerle bölünenek $F_s = 8\text{kHz}$ ile örneklenerek ve her pencerenin spektrum büyülüğu bulunarak elde edilmiştir.



Şekil 2: sentetik verideki eşleşme

Daha sonra, spektrum büyülüğu sıklık aralıkları [400Hz - 800Hz],[800Hz - 1600Hz] ve [1600Hz - 3200Hz] olan 3 oktava ayrılmıştır. Katsayılar, tüm oktav için sıklık üzerinden toplanarak öznitelik yöneyi oluşturulmuştur. Bu işlemin sonunda her kaynak 3 spektral öznitelik yöneyi ile gösterilmiştir. Bunun tek band durumundan farkı, bu kez yordam öznitelik yöneyleri yerine öznitelik dizeylerini eşlestirecektir. Şekil 3'de birinci oktav için benzetim sonuçları gösterilmektedir.



Şekil 3: 2000 döngülü Gibbs kullanarak gerçek verideki eşleştirme

Burada çoklu ses eşleştirme sistemleri için olasılıksal bir model önerilmiş ve Gibbs örnekleyici için oluşturulmuş tavlama yaklaşımı incelenmiştir. Gerçek ve sentetik veriler

üzerine benzetimlerle belirsiz durumlarla nasıl başedileceği gösterilmiştir. Ayrıca örnekleyicinin başarımı, hiper-parametre kümesi $\{\alpha_\lambda, \beta_\lambda, \alpha\}$ seçimlerine bağlı olduğu ve bazı durumlarda örnekleyici başlangıçla bağlı olarak, yerel eniyi kısımlarda takılı kaldığı tespit edilmiştir.

İlerideki çalışmalarında, önerilen modelin, çıkarımını hızlandırmak, modelin hiper-parametrelerini eğitmek, EM gibi değişik yaklaşık çıkarım yöntemlerini kullanmak ve daha gelişmiş tavlama stratejileri üretmek gibi birçok ilginç yönde araştırma yapmak mümkündür.

5. Teşekkür

Bu çalışma 2007K120610 numaralı TAM Projesi kapsamında Türkiye Devlet Planlama Teşkilatı tarafından desteklenmiştir.

Ali Taylan Cemgil, bu çalışmada, TUBİTAK tarafından 110E292 Bayesci Tensör ayırtırma (BAYTEN) projesi kapsamında desteklenmektedir.

6. KAYNAKÇA

- [1] Wang, A.L, "An Industrial-Strength Audio Search Algorithm", 2008.
- [2] M. Muller and F. Kurth and M. Clausen, "Audio Matching via Chroma-based statistical features", 2003
- [3] Cemgil, A. T. and Fevotte, C. and Godsill, S. J., "Variational and Stochastic Inference for Bayesian Source Separation", Digital Signal Processing, Vol. 17,no. 5 2007, p 891-913.
- [4] Troughton, P.T.; Godsill, S.J.; , "Bayesian model selection for time series using Markov chain Monte Carlo," Acoustics, Speech, and Signal Processing, 1997. ICASSP-97., 1997 IEEE International Conference on , vol.5, no., pp.3733-3736 vol.5, 21-24 Apr 1997 doi: 10.1109/ICASSP.1997.604681
- [5] Kashino, K.; Godsill, S.J.; , "Bayesian estimation of simultaneous musical notes based on frequency domain modelling," Acoustics, Speech, and Signal Processing, 2004. Proceedings. (ICASSP '04). IEEE International Conference on , vol.4, no., pp. iv-305- iv-308 vol.4, 17-21 May 2004 doi: 10.1109/ICASSP.2004.1326824
- [6] Soo-Young Lee; Kyung Geun Lee; , "Synchronous and asynchronous parallel simulated annealing with multiple Markov chains," Parallel and Distributed Systems, IEEE Transactions on , vol.7, no.10, pp.993-1008, Oct 1996 doi: 10.1109/71.539732