İlntropi Kullanarak Müzik Aletlerinin Ayırıştırılması

Separation of Musical Instruments Using Correntropy

M. Erdal Özbek, F. Acar Savacı

Elektrik-Elektronik Mühendisliği Bölümü
İzmir Yüksek Teknoloji Enstitüsü
{erdalozbek, acarsavaci}@iyte.edu.tr

Özetçe

Yakın zamanda, çekirdek yöntemlerini kullanarak zaman serisinden hem zaman yapısı hem de istatistiksel dağılım özelliklerini ortaya çıkaran ilintropi adı verilen bir genelleştirilmiş ilinti işlevi önerilmiştir. Bu çalışmada, ilintropi kullanılarak elde edilen istatistiksel bağımsızlık ölçütü, aynı notayı çalan farklı müzik aletleri örneklerinin ayırıştırılmasında kullanılmıştır.

Abstract

Recently, a generalized correlation function called correntropy, extracting both the time structure and the statistical distribution of time series using kernel methods, have been proposed. In this work, the statistically independence criterion obtained using correntropy has been used in separation of different musical instrument samples playing the same note.

1. Giriş

Ses işaretlerinin ayırıştırılması amacıyla yapılan çalışmalar bir çok alanda uygulanmaktadır. Bu alanlardan biri olan müzikte de, müzik aletlerinin seslerinin ayırıştırılması ve sınıflandırılması için temel işaret işleme teknikleri ve örüntü tanıma algoritmaları kullanılmaktadır [1]. Araştırmalar sonucunda farklı amaçlara hizmet eden farklı işlevlere sahip çok sayıda öznelik elde edilmiştir. Bunlara örnek olarak özilinti katsayıları, sıfır geçiş sayısı, izgesel akı, izgesel kitle merkezi, mel frekans kepsral katsayıları gibi hem işaretin zaman serisinde hem de izgesinde hesaplanan öznelikler verilebilir [2]. Oluşturulan öznelik vektörleri, yaygın olarak kullanılan destek vektör makineleri [3] gibi sınıflandırıcılar aracılığıyla temel titreşim frekansı, ritim, tür ve benzeri amaçlara göre farklı sınıflara ayırıştırılmaktadır [4].

Çekirdek yöntemleri, destek vektör makinelerinde olduğu gibi veri uzayından öznelik uzayına dönüşümü sağlayan bir çekirdek işlevi aracılığıyla veri uzayında doğrusal olmayan örüntünün öznelik uzayında doğrusal örüntü haline gelmesi için kullanılır [5]. Çekirdek işlevi κ ,

$$\kappa(\mathbf{x}_i, \mathbf{x}_j) = \langle \phi(\mathbf{x}_i) \cdot \phi(\mathbf{x}_j) \rangle, \quad \forall \mathbf{x}_i, \mathbf{x}_j \in X \quad (1)$$

veri uzayı X 'ten verilerin doğrusal olarak sınıflandırılabilceği daha büyük (genellikle sonsuz) boyutlu $\mathcal{H}$ iç çarpım uzayına ϕ dönüşümü ile geçişi sağlayan bir işlevdir. $\mathcal{H}$ 'daki iç çarpım,

çekirdek hilesi olarak bilinen bir değişim sayesinde ϕ işlevinin açık ifadesine gerek kalmadan hesaplanmaktadır. Böylece bir uzayda iç çarpım olup olmadığını belirleyen Mercer şartını sağladığı sürece herhangi bir işlev çekirdek işlevi olarak kullanılabilir [3]. En sık kullanılan çekirdek işlevleri,

$$\begin{aligned} \kappa(\mathbf{x}_i, \mathbf{x}_j) &= (\mathbf{x}_i \cdot \mathbf{x}_j) && : \text{doğrusal} \\ \kappa(\mathbf{x}_i, \mathbf{x}_j) &= (\mathbf{x}_i \cdot \mathbf{x}_j + 1)^d && : \text{çokterimli} \\ \kappa(\mathbf{x}_i, \mathbf{x}_j) &= \exp \left\{ -\frac{\|\mathbf{x}_i - \mathbf{x}_j\|^2}{2\sigma^2} \right\} && : \text{radyal taban işlevi} \end{aligned}$$

olarak verilebilir. Belirli amaçlar ve uygulamalar için bir çok çekirdek işlevi kullanılmaktadır [5]. Ayrıca çekirdek yöntemlerini kullanan temel bileşen analizi (KPCA) [6] ve çekirdek bağımsız bileşen analizi (KICA) [7] gibi analiz yöntemleri de bulunmaktadır.

Yakın zamanda *ilintropi* olarak adlandırdığımız bilgi kuramıyla öğrenme ve çekirdek yöntemlerine dayanan genelleştirilmiş ilinti işlevi bildirilmiştir [8, 9]. Zaman serisinin hem zaman yapısı hem de istatistiksel dağılımını aynı noktada buluşturan bu ölçü ile sadece zaman yapısı hakkında bilgi veren özilinti işlevi ile istatistiksel dağılım bilgisini içeren yöntemler bir noktada birleştirilmiş olmaktadır.

Bu çalışmada ilintropi kullanılarak elde edilmiş karışımları ayırma ölçütüne [10] dayanarak müzik aletlerinin ayırıştırılması gerçekleştirilmiştir. Bu amaçla izleyen bölümde ilintropi işlevi ve kullanılan ölçüt anlatılacaktır. Yapılan ayırıştırma çalışmaları ve sonuçlarını değerlendirme bölümü izleyecektir.

2. İlntropi

Özilintropi işlevi, verilen bir rastgele süreç $x(t), t \in T$ için T indis kümesi olmak üzere $T \times T$ 'den R^+ 'a tanımlanan,

$$V(t_1, t_2) = E[\kappa(x(t_1), x(t_2))] \quad (2)$$

ile verilen bir işlevdir. Burada $E[\cdot]$ istatistiksel beklenti göstermektedir ve görüldüğü üzere özilinti işlevinin bir çekirdek işlevi kullanılarak bulunması ile tanımlanmaktadır [8]. Burada yaygın olarak kullanılan işlevlerden biri bakışım Gauss çekirdek işlevidir.

$$\kappa(x_i, x_j) = \frac{1}{\sqrt{2\pi}\sigma} \exp \left\{ -\frac{(x_i - x_j)^2}{2\sigma^2} \right\}. \quad (3)$$

Denklem (2)'deki ifadede, Denklem (3)'te verilen çekirdek işlevini kullanıp daha sonra Taylor seri açılımını uygularsak

$$V(t_1, t_2) = \frac{1}{\sqrt{2\pi\sigma}} \sum_{k=0}^{\infty} \frac{(-1)^k}{(2\sigma^2)^k k!} E[(x(t_1) - x(t_2))^{2k}] \quad (4)$$

ile verilen ilintropi ifadesinde rastgele süreç $(x(t_1) - x(t_2))$ 'nin çift dereceden momentlerini elde ederiz. Yani, ilintropi rastgele süreçlerin yüksek derecede istatistiklerini içermektedir. Tek değişkenli bir genelleştirilmiş ilinti işlevi için bütün çift dereceden momentlerin zaman kaymasından (τ) bağımsız olması gerekir $(V(t, t - \tau) = V(\tau), \forall t)$. Bu da sadece ikinci dereceden momentleri içeren geniş anlamda durağanlıktan (WSS) daha kuvvetli bir şarttır [8].

Özilintropi işlevinin daha genel bir ifadesi olan çapraz ilintropi işlevi Denklem (2)'ye benzer şekilde iki farklı rastgele değişken X ve Y için

$$V(X, Y) = E[\kappa(X, Y)] \quad (5)$$

olarak tanımlanır. Özilintropide olduğu gibi çapraz ilintropi de aynı özelliklere sahip ve yüksek dereceden istatistikleri içermektedir. Pratikte elimizde bulunan sınırlı sayıda veri $\{(x_i, y_i)\}_{i=1}^N, x_i \in X, y_i \in Y$ ile,

$$\hat{V}(X, Y) = \frac{1}{N} \sum_{i=1}^N \kappa(x_i - y_i) \quad (6)$$

denklemini kullanarak çapraz ilintropiyi kestirmemiz mümkündür. Benzer şekilde, ayrıt zamanda durağan rastlantısal süreçler için zaman kayması ya da gecikme değişkeni τ 'ya bağlı çapraz ilintropi

$$\hat{V}[\tau] = \frac{1}{N - \tau + 1} \sum_{i=\tau}^N \kappa(x_i - y_{i-\tau}) \quad (7)$$

kullanılarak kolaylıkla elde edilebilir [8].

Bağımsız ve ayrıt zamanda durağan rastlantısal süreçler X ve Y için, birbirinden bağımsız olma şartı ise

$$V[\tau] = V[0] \quad \forall \tau \quad (8)$$

olarak verilmiştir [10]. Bu şekilde gecikme değişkenine bağlı olmayan çapraz ilintropi işlevi ve zaman kaymalarındaki Öklid uzaklığını kullanarak süreçlerin bağımsızlığını belirleyecek bir ölçüt [10]'da önerilmiştir. Benzer şekilde bu çalışmada da $V[\tau]$ ve $V[0]$ için

$$J = \sum_{\tau=1}^L (V[\tau] - V[0])^2 \quad (9)$$

ile verilen zaman kaymalarındaki Öklid uzaklığını kullanarak, iki sürecin ne kadar bağımlı olduklarına dair bir ölçüt elde edilmiştir. Burada L , kullanıcı tarafından belirlenmekte ve en büyük zaman kaymasının değerini göstermektedir.

3. Yapılan Ayırıştırma Çalışmaları ve Sonuçları

Bu çalışmada Iowa Üniversitesi Elektronik Müzik Stüdyosu [11] nota örnekleri kullanılmıştır. Bu notalar 44100Hz'de örneklenmiş ve tek kanallı (mono) olarak kaydedilmiştir.

Nota örneklerinden Viyolonsel (V), Saksofon (S), Keman (K), Flüt (F), ve Obua (O)'dan oluşan 5 farklı müzik aletinin ayırıştırılmış A4 notaları (440Hz) seçilmiştir. Veri boyutu N , en kısa süren nota örneğinin zaman örneği uzunluğu olarak belirlenmiş ve diğer nota örneklerinin ilk N uzunluktaki zaman örnekleri alınmıştır. İkili nota örnekleri eşit oranla karıştırılarak olası bütün ikili karışımlar elde edilmiştir. Daha sonra her bir karışım ile her bir müzik aleti örneğinin çapraz ilintropileri hesaplanmıştır. İlintropi hesaplanmasındaki en büyük zamanda kayma değeri, bir yönde bütün değerleri alacak şekilde seçilmiştir ($L = N$). Daha sonra Denklem (9) yardımıyla hesaplanan iki müzik alet örneğinin ne kadar bağımsız olduğunun ölçüsü, doğrusal, çokterimli ve Gauss çekirdek işlevleri kullanılarak çıkarılmıştır.

Tablo 1'de, doğrusal çekirdek işlevi için hesaplanan uzaklık değerleri verilmiştir. İlintropi işlevinin doğrusal çekirdek işlevi kullanılarak hesaplanması özel durumu, çapraz ilinti işlevine karşılık gelmektedir. Bu nedenle, bu sonuç aynı zamanda çapraz ilinti işlevinin kullanılması durumunda elde edilen sonuçtur.

Tablo 1: Doğrusal çekirdek işlevi için hesaplanan uzaklık değerleri

	Viyolonsel	Saksofon	Keman	Flüt	Obua
V-S	18.04	44.77	0.60	0.12	0.88
V-K	17.99	0.54	24.31	0.08	0.28
V-F	17.80	0.03	0.02	77.39	0.05
V-O	18.04	0.42	0.08	0.06	237.45
S-K	< 0.01	54.57	32.09	0.24	1.14
S-F	< 0.01	44.20	0.70	77.31	1.00
S-O	< 0.01	37.37	0.98	0.16	220.80
K-F	< 0.01	0.51	24.83	78.64	0.33
K-O	< 0.01	0.20	26.49	0.15	243.45
F-O	< 0.01	0.51	0.13	77.97	237.51

Değerlerden de görüldüğü gibi karışımın, karışımı oluşturan müzik aletleri ile uzaklık değerleri karışımında bulunmayan müzik aletlerine göre yüksek çıkmaktadır. Bu durum, o müzik aletlerinin oluşturdıkları karışım ile istatistiksel bağımlılık, diğer müzik aletlerinin de bağımsızlık derecesini ifade etmektedir. Benzer sonuçlar Tablo 2'de verilen çokterimli çekirdek işlevinin $d = 2$ için hesaplanan uzaklık değerlerinde de gözlenmiştir.

Tablo 2: Çokterimli çekirdek işlevi için ($d = 2$) hesaplanan uzaklık değerleri

	Viyolonsel	Saksofon	Keman	Flüt	Obua
V-S	79.9	199.8	2.8	0.6	4.5
V-K	78.8	2.9	104.9	0.4	1.1
V-F	79.5	0.2	0.1	339.9	0.4
V-O	81.3	1.1	0.5	0.5	1035.8
S-K	0.1	246.3	142.0	1.2	5.2
S-F	0.1	202.1	3.5	342.6	5.6
S-O	0.1	169.4	4.9	0.9	948.1
K-F	0.1	3.2	108.5	346.0	1.3
K-O	0.1	1.1	116.8	1.0	1071.0
F-O	0.1	1.1	0.9	349.8	1028.9

Çokterimli çekirdek işlevinin değişen parametreleri ($d = 3, 4, 5$) için hesaplanan uzaklık değerleri de benzerlik göstermektedir. Tablo 3'te, $d = 5$ için hesaplanan uzaklık değerleri verilmiştir.

Tablo 3: Çokterimli çekirdek işlevi için ($d = 5$) hesaplanan uzaklık değerleri

	Viyolonsel	Saksofon	Keman	Flüt	Obua
V-S	719	1854	30	24	67
V-K	684	41	867	15	14
V-F	742	18	5	2986	28
V-O	774	7	13	35	9317
S-K	7	2410	1313	33	81
S-F	10	2075	44	3115	106
S-O	11	1654	61	42	8125
K-F	7	63	957	3063	28
K-O	10	28	1040	36	10008
F-O	17	15	21	3302	9358

Tablolar arasında farklı çekirdek işlev parametresinin neden olduğu sayısal değerlerde bir artış gözlenmekteyse de, karışımında bulunan müzik aletleri kolaylıkla belirlenebilmektedir. Ancak burada dikkat edilmesi gereken bir nokta, belirlenimin karışımların ayrı ayrı alındığı durumlarda yapılmış olmasıdır. Bütün karışımların bulunduğu durumda bir düzgeleme yapılması ve müzik aletleri ya da karışımların karşılaştırılmasının da bu şekilde adil olarak yapılması gerekmektedir.

Tablo 4-7’de, Gauss çekirdek işlevinin değişen parametreleri için hesaplanan uzaklık değerleri verilmiştir.

Tablo 4: Gauss çekirdek işlevi için ($\sigma = 0.001$) hesaplanan uzaklık değerleri ($\times 10^8$)

	Viyolonsel	Saksofon	Keman	Flüt	Obua
V-S	1.74	1.73	0.19	0.67	0.01
V-K	0.34	0.34	0.35	0.16	0.01
V-F	1.93	0.46	0.09	2.02	0.01
V-O	0.04	0.01	0.01	0.01	0.05
S-K	0.09	0.56	0.57	0.19	0.01
S-F	0.96	1.97	0.14	2.01	0.01
S-O	0.04	0.04	0.03	0.03	0.04
K-F	0.18	0.30	0.31	0.31	0.02
K-O	0.04	0.03	0.03	0.03	0.04
F-O	0.03	0.03	0.02	0.04	0.04

Tablo 5: Gauss çekirdek işlevi için ($\sigma = 0.01$) hesaplanan uzaklık değerleri ($\times 10^6$)

	Viyolonsel	Saksofon	Keman	Flüt	Obua
V-S	6.51	6.48	0.62	5.10	0.06
V-K	1.60	1.19	1.78	0.94	0.07
V-F	6.85	5.79	0.73	6.92	0.07
V-O	0.36	0.33	0.34	0.34	0.57
S-K	1.19	1.77	1.91	1.08	0.09
S-F	3.73	9.41	0.58	9.55	0.05
S-O	0.16	0.32	0.11	0.14	0.42
K-F	1.44	1.55	1.70	1.69	0.08
K-O	0.10	0.07	0.11	0.08	0.25
F-O	0.16	0.17	0.11	0.22	0.32

Sonuçlar incelendiğinde, çokterimli çekirdek işlevi sonuçlarındaki gibi çekirdek işlevinin sonucunda sayısal değerlerde bir değişim gözlenmekteyse de esas önemli sonucun işlev parametresinin değişmesi ile ayrıştırmanın başarımının değişikliğe uğraması olarak görülmektedir. Uygun bir çekirdek işlev parametre değeri seçilmediğinde bazı karışımların ayrıştırılmadığı görülmektedir.

Farklı çekirdek işlevlerinin etkisine örnek olarak ve

Tablo 6: Gauss çekirdek işlevi için ($\sigma = 0.1$) hesaplanan uzaklık değerleri ($\times 10^4$)

	Viyolonsel	Saksofon	Keman	Flüt	Obua
V-S	4.57	4.73	0.48	0.41	0.35
V-K	3.15	0.15	4.97	0.08	0.57
V-F	6.06	2.64	0.97	6.84	0.11
V-O	2.77	4.55	3.40	4.93	6.45
S-K	0.76	4.05	5.62	0.10	0.27
S-F	2.47	4.34	0.88	4.85	0.12
S-O	0.23	0.58	0.25	0.52	3.61
K-F	1.86	1.43	4.68	4.47	0.09
K-O	0.69	1.36	0.69	1.58	4.26
F-O	0.08	0.03	0.06	0.71	3.33

Tablo 7: Gauss çekirdek işlevi için ($\sigma = 1$) hesaplanan uzaklık değerleri

	Viyolonsel	Saksofon	Keman	Flüt	Obua
V-S	1.37	2.52	0.18	2.83	2.52
V-K	1.12	1.12	2.10	3.31	2.29
V-F	1.60	0.93	0.16	4.06	2.19
V-O	1.10	4.77	1.80	6.50	26.51
S-K	0.10	4.09	4.20	1.79	1.28
S-F	0.10	3.42	0.19	4.75	1.27
S-O	1.34	1.60	0.87	5.39	24.68
K-F	0.10	0.44	3.10	4.39	1.26
K-O	1.57	3.41	1.58	5.82	26.49
F-O	0.98	3.06	0.84	3.37	27.45

adil karşılaştırma amacıyla Viyolonsel-Saksofon karışımı için, tablolardaki değerlerin herbir çekirdek işlevi için ayrı ayrı düzelenmesi sonucunda elde edilen sonuç Şekil 1’de gösterilmiştir.

Şekil 1: Viyolonsel-Saksofon karışımı için çekirdek işlevlerinin etkisi

Viyolonsel ve Saksofon karışımında beklendiği gibi yüksek değerler ancak Gauss çekirdek işlevi kullanıldığında elde edilebilmektedir. Flüt örneğinin de belirgin değerler alması bu karışımı oluşturan müzik aletleri ile olan bağımlılığını göstermektedir.

Şekil 2’de bütün karışımlar arasından Flüt’ün bulunduğu karışımların doğru bir şekilde bulunduğu, en iyi başarımın yine Gauss çekirdek parametreleri ile sağlandığı gösterilmiştir. Ancak, $\sigma = 1$ olduğunda elde edilen başarımın özellikle ilinti işlevine karşılık gelen doğrusal çekirdek işlevinden ya

da çokterimli çekirdek işlevlerinin bütün parametrelerinin elde ettiğinden iyi olmaması, Gauss çekirdek işlevi parametresinin önemli rolünü ortaya çıkarmaktadır.

Şekil 2: Flüt için karışımlara göre ayrıştırmada çekirdek işlevlerinin etkisi

4. Değerlendirme

Müzik aletlerinin ayrıştırılması için yakın zamanda geliştirilmiş ilinti işlevi olarak önerilen ilintropi işlevinden elde edilen istatistiksel bağımsızlık için bir ölçüt kullanılmıştır. Farklı müzik aletlerinin aynı notalarının karışımı ile nota örneklerinin kendileri arasındaki çapraz ilintropi işlevi hesaplanarak, zaman kaymasından bağımsızlığı temel alan Öklid uzaklığı ölçütüne göre müzik aletlerinin ayrıştırılması gerçekleştirilmiştir.

Sonuçlardan da gözlendiği gibi ilintropi kullanılarak karışımı oluşturan müzik aletleri kolayca belirlenebilmektedir. İlinti işlevinin tek bir karışım temel alındığında başarılı görüldüğü ancak karışımların tümünün ele alınarak düzgeleme yapıldığı adil bir karşılaştırma durumunda doğrusal çekirdek işlevinin yanı sıra çokterimli çekirdek işlevinin de yetersiz kaldığı görülmüştür. Bunun yanında, müzik aletleri karışım örneklerinin bağımsızlık ölçülerinin çekirdek işlevleri ve parametrelerine göre değişiklik gösterdiği de gözlenmiştir. Literatürde, kullanılan çekirdek işlevinin ve veri saçılımını kontrol eden parametresinin önemi bilinmektedir ve ilintropi de çekirdek yöntemlerine dayandığından, çekirdek işlev ve parametresinin önemi bu çalışmada da ortaya çıkmaktadır.

Gauss çekirdek işlevinin parametresinin uygun bir seçimi için [12]'de verildiği gibi Silverman kuralı uygulanabilir. N uzunluğundaki verinin eniyi çekirdek parametresi

$$\sigma_S = 0.9AN^{-1/5} \quad (10)$$

ile hesaplanabilmektedir. Burada A , verilerin standart sapması ile çeyrek değerler genişliği olarak bilinen aralığının 1.34 ile oranlanmasıyla bulunan değerden küçük olanıdır. Ancak [12]'deki çalışmada özilintropi kullanıldığından hesaplanan çekirdek parametresi bir tek işaret için bulunabilmektedir. Çapraz ilintropi durumunda elimizdeki iki işaret için kullanılacak çekirdek parametresini hesaplayan bir yöntemin yararlı olacağı görülmektedir.

Karışımın doğrusal ve eşit ağırlıklı olduğu durumlarda, ayrıştırma işleminde ilintropi işlevinin ilinti işlevinden özellikle uygun Gauss çekirdek işlev parametresi kullanılmasıyla daha yararlı olduğu gözlenmiştir. Karışımın doğrusal ama eşit ağırlıklı olmadığı durumlarda da benzer sonuçların elde edileceği beklenmektedir. Ancak ilintropi işlevinin, çekirdek yöntemlere dayanan doğrusal olmayan örüntüyü ayırma yeteneğinden dolayı karışımın doğrusal olmadığı durumlarda daha etkili olacağı düşünülmektedir.

Gelecekte tek bir nota yerine daha çok nota ve müzik aleti örneğinin ilintropilerinin hesaplanması, bu amaçla kullanılacak çekirdek işlev ve parametresinin seçimi ve müzik aletlerinin ayrıştırılmasında kullanılabilecek daha iyi bir ölçütün bulunması ile doğrusal olmayan karışımlar incelenecektir.

5. Kaynakça

- [1] P. Herrera-Boyer, G. Peeters, and S. Dubnov, "Automatic classification of musical instrument sounds," *Journal of New Music Research*, vol. 32, no. 1, pp. 3–21, September 2003.
- [2] S. Essid, G. Richard, and B. David, "Instrument recognition in polyphonic music based on automatic taxonomies," *IEEE Trans. on Audio, Speech and Language Processing*, vol. 14, no. 1, pp. 68–80, January 2006.
- [3] V. N. Vapnik, *The Nature of Statistical Learning Theory*. New York: Springer Verlag, 1995.
- [4] A. Klapuri and M. Davy, Eds., *Signal Processing Methods for Music Transcription*. Springer, 2006.
- [5] J. Shawe-Taylor and N. Cristianini, *Kernel Methods for Pattern Analysis*. Cambridge University Press, 2004.
- [6] B. Schölkopf, A. Smola, and K.-R. Müller, "Nonlinear component analysis as a kernel eigenvalue problem," *Neural Computation*, vol. 10, pp. 1299–1319, 1998.
- [7] F. R. Bach and M. I. Jordan, "Kernel independent component analysis," *Journal of Machine Learning Research*, vol. 3, pp. 1–48, 2002.
- [8] I. Santamaría, P. P. Pokharel, and J. C. Principe, "Generalized correlation function: Definition, properties, and application to blind equalization," *IEEE Transactions on Signal Processing*, vol. 54, no. 6, pp. 2187–2197, June 2006.
- [9] W. Liu, P. P. Pokharel, and J. C. Principe, "Correntropy: Properties and applications in non-gaussian signal processing," *IEEE Transactions on Signal Processing*, vol. 55, no. 11, pp. 5286–5298, November 2007.
- [10] R. Li, W. Liu, and J. C. Principe, "A unifying criterion for instantaneous blind source separation based on correntropy," *Signal Processing*, vol. 87, no. 8, pp. 1872–1881, August 2007.
- [11] The University of Iowa Electronic Music Studios, <http://theremin.music.uiowa.edu>.
- [12] J. Xu and J. C. Principe, "A novel pitch determination algorithm based on generalized correlation function," in *Proc. of the IEEE Workshop on Machine Learning for Signal Processing (MLSP-07)*, Thessaloniki, Greece, August, 27–29 2007, pp. 270–275.