

Ortak Vektör Yaklaşımına Yeni Bir Bakış Açısı

A New Point of View to Common Vector Approach

M.Bilginer Gülmezoğlu¹
bgulmez@ogu.edu.tr

Hakan Çevikalp²
hakan.cevikalp@vanderbilt.edu

Atalay Barkana¹
abarkana@ogu.edu.tr

¹Elektrik-Elektronik Mühendisliği Bölümü, Osmangazi Üniversitesi, Eskişehir

²Elektrik ve Bilgisayar Mühendisliği Bölümü, Vanderbilt Üniversitesi, Nashville, A.B.D.

Özetçe

Bu çalışmada, Ortak Vektör yaklaşımı, başka bir açıdan ele alınmıştır. Böylece, hem tüm sınıflar tek bir altuzay ile temsil edilebilmekte, hem de çok düşük boyutlu öznitelik vektörleri ile oldukça yüksek tanıma oranlarına ulaşılabilmektedir. TI-sayamak veri tabanı üzerindeki deneysel çalışmalar sonucu elde edilen tanıma oranları önerilen yöntemin başarısını göstermektedir.

Abstract

In this paper, the Common Vector Approach is handled for a new point of view. Thus, all classes can be represented by a unique subspace and high recognition rates can be obtained by using the feature vectors with very low dimensions. The recognition rates obtained from the experimental study by using TI-digit database are also given.

1. Giriş

Ortak Vektör yaklaşımı (OVY), yetersiz veri durumu (n : vektör boyutu $\geq m$: vektör sayısı) için ayrık kelime tanıma, konuşmacıyı tanıma ve motorların arıza tesbiti gibi uygulamalarda oldukça başarılı sonuçlar vermiştir [1-3]. Ayrıca OVY, yeterli veri durumu ($n < m$) için ayrık kelime tanıma uygulamaya uygulanmış ve yine oldukça iyi sonuçlar elde edilmiştir [4]. OVY kullanılarak yapılan daha önceki çalışmalarda, sınıf içi dağılımları [1-4] veya hem sınıf içi hem sınıflar arası dağılımları [5,6] göz önüne alarak her sınıf için, farklılık ve farksızlık altuzayları oluşturulmuştur. Her bir sınıfın ortalama vektörünün, o sınıfın farksızlık altuzayı üzerindeki izdüşümlerinin toplamı o sınıfın ortak vektörünü vermektedir ve bu ortak vektör, tanıma algoritmalarında kullanılmaktadır [1-4].

Bu çalışmada, OVY'ye yeni bir bakış açısı getirilmiştir. Bu bakış açısı, her sınıf için ayrı ayrı altuzaylar oluşturmak yerine, tüm sınıfları temsil eden sadece bir farklılık ve bir de farksızlık altuzayı oluşturmak fikrine dayanmaktadır. Herhangi bir sınıfın ortalama vektörünün bu farksızlık altuzayı

üzerindeki izdüşümlerinin toplamı, yine o sınıfa ait ortak vektörü vermektedir. Ortak vektörlerden elde edilen sınıflar arası ortak değişinti matrisinin sıfır olmayan özdeğerlere karşılık gelen özvektörleri kullanılarak vektörlerin boyutları, (sınıf sayısı-1) gibi oldukça düşük bir boyuta indirgenmektedir. Bu boyut için elde edilen tanıma oranlarının, sadece sınıf içi dağılımlardan elde edilen tanıma oranları ile aynı olması önerilen yöntemin önemini göstermektedir.

2. Önerilen Yöntem

İlk aşamada, her sınıfın sınıf içi dağılımlarından elde edilen ortak değişinti matrisleri (Φ_i) toplanarak, tüm sınıfları temsil eden bir ortak değişinti matrisi (Φ_w) bulunmuştur:

$$\Phi_w = \sum_{i=1}^K \Phi_i. \quad (1)$$

Burada K , sınıf sayısını göstermektedir. Φ_w matrisinin özvektörleri kullanılarak tüm sınıflar için farklılık ve farksızlık altuzayları oluşturulmuştur [7]. Her bir sınıfın ortalama vektörünün farksızlık altuzayı üzerindeki izdüşümü yine o sınıfa ait ortak vektörü vermektedir:

$$\mathbf{a}_{i,ortak} = \sum_{j=1}^r (\mathbf{m}_i^T \mathbf{v}_j) \mathbf{v}_j. \quad (2)$$

Burada \mathbf{m}_i , i 'nci sınıfa ait öznitelik vektörlerinin ortalamasını, \mathbf{v}_j ($j = 1, 2, \dots, r$), farksızlık altuzayını geren özvektörleri ve T , transpoze işlevini göstermektedir.

Eşitlik (2)'den elde edilen n boyutlu ortak vektörlerin, sınıf içi ortak değişinti matrisinin r adet sıfır özdeğerine karşılık gelen özvektörler üzerindeki izdüşümleri alınarak boyutları r 'ye indirgenmiştir [7]. Her sınıfın, r boyutlu ortak vektörleri kullanılarak Fisher'in sınıflar arası ortak değişinti matrisi (Φ_B) hesaplanmıştır [8]:

$$\Phi_B = \sum_{i=1}^K (\mathbf{m}_i - \mathbf{m}_t)(\mathbf{m}_i - \mathbf{m}_t)^T. \quad (3)$$

Burada m_i , tüm sınıflardaki öznelik vektörlerinin ortalamasını göstermektedir. Bilindiği gibi Φ_B 'nin sıfır olmayan özdeğerlerinin sayısı, $(K-1)$ 'e eşit olduğundan, bu özdeğerlere karşılık gelen özvektörler kullanılarak ortak vektörlerin boyutları $K-1$ gibi oldukça düşük bir boyuta indirgenmektedir. Herbir sınıfa ait $K-1$ boyutlu ortak vektörler ayrık kelime tanımada kullanılmış ve sadece sınıf içi dağılımlardan elde edilen tanıma oranları ile aynı sonuçlar elde edilmiştir.

3. Deneysel Çalışmalar

TI-sayamak veri tabanında bilindiği gibi 11 sayamak ve, herbir sayamak için eğitim kümesinde 224 ve test kümesinde 226 olmak üzere toplam 450 söyleyiş bulunmaktadır. Bu veri tabanı üzerinde yapılan çalışmalarda öncelikle, n boyutlu öznelik vektörlerinin sınıf içi dağılımlarından her sınıfa ait bir ortak vektör bulunmuştur. Ortak vektörlerin boyutları, farksızlık altuzayının boyutuna (r) indirgenmiştir. Yeni ortak vektörlerin sınıflar arası dağılımlarından elde edilen $10(=11-1)$ boyutlu farklılık altuzayı kullanılarak, ortak vektörlerin boyutları 10 'a indirgenmiştir.

Test aşamasında öncelikle, bilinmeyen test vektörünün sınıf içi ortak değişinti matrisinden elde edilen farksızlık altuzayındaki izdüşümü alınarak boyutu r 'ye indirgenmektedir. Daha sonra bu indirgenmiş öznelik vektörünün, ortak vektörlerden elde edilen sınıflar arası ortak değişinti matrisinin sıfır olmayan özdeğerlerine karşılık gelen özvektörler üzerindeki izdüşümünü kullanarak boyutu 10 'a indirgenmekte ve kalan vektör (a_{kalan}) olarak isimlendirilmektedir.

Tanıma işlemi, her sınıfa ait ortak vektör ile kalan vektör arasındaki Öklid uzaklığın minimum değerine göre yapılmaktadır. Bu durumda tanıma kriteri,

$$C^* = \underset{i}{\operatorname{argmin}} \|a_{kalan} - a_{ortak}^i\| \quad (4)$$

olarak ifade edilebilir.

Bu çalışmada tüm sınıfları temsil eden tek bir altuzay oluşturulması amaçlandığından, eğitim kümesinde $11 \times 224 = 2464$ adet öznelik vektörü kullanılmaktadır. Deneysel çalışmalar, yetersiz veri durumu ve yeterli veri durumu olmak üzere iki grupta toplanabilir.

Yeterli veri durumunda, öznelik vektörlerinin boyutları, öznelik vektörlerinin sayısından az olduğu için sınıf içi ortak değişinti matrisinin özdeğerlerinin hepsi sıfırdan farklıdır. Yeterli veri durumu için yapılan çalışmaları şu şekilde özetleyebiliriz.

1- Zaman düzlemindeki ses verileri önvurgulamadan geçirildikten sonra 256 örnekten oluşan çerçevelere ayrıldığında, en uzun ses verisinin 37 çerçeveden

oluştugu görülmüştür. Her çerçeve için 44 adet "root-melcep" parametresi hesaplanmış ve boyutu $37 \times 44 = 1628$ 'den az olan öznelik vektörlerinin sonuna rastgele sayılar ilave edilmiştir. Bu durumda elde edilen sınıf içi ortak değişinti matrisinin minimum 358 özdeğerine karşılık gelen özvektörler kullanıldığında eğitim kümesinde %98.5 tanıma oranı elde edilmiştir. Fakat test kümesinde minimum 1618 özdeğere karşılık gelen özvektörler kullanıldığında %25.3 tanıma oranı elde edilmiştir. Öznelik vektörlerinin boyutları $11-1=10$ 'a indirgenildiğinde yine aynı sonuçlara ulaşılmıştır.

2- Zaman düzlemindeki herbir ses verisi 10 çerçeveye ayrılıp, öznelik vektörlerinin boyutları 1600 olacak şekilde "root-melcep" parametreleri (her çerçeve için 160 adet) hesaplanmıştır. Bu durumda eğitim kümesinde, minimum 447 özdeğere karşılık gelen özvektörler kullanıldığında %100 ve test kümesinde, minimum 1598 özdeğere karşılık gelen özvektörler kullanıldığında %89.5 tanıma oranı elde edilmiştir. Öznelik vektörlerinin boyutları 10 'a indirgenildiğinde yine aynı sonuçlara ulaşılmıştır.

3- Öznelik vektörlerinin boyutları 2200 olacak şekilde "root-melcep" parametreleri hesaplanıp, yukarıda bahsedildiği gibi öznelik vektörlerinin boyutları 10 'a indirgenildiğinde eğitim kümesinde %100 ve test kümesinde %88.5 tanıma oranları elde edilmiştir.

Yetersiz veri durumu için yapılan çalışmaları da aşağıdaki gibi özetleyebiliriz.

1- Öznelik vektörleri aynı boyutta olacak şekilde çerçevelerin uzunlukları ayarlanıp 2500 adet "root-melcep" parametresi (her çerçeve için 250 adet) hesaplandığında, sınıf içi ortak değişinti matrisinin sıfır olan özdeğerlerinin sayısı $47(=2500-11 \times 223)$ 'dir. Herbir sınıfın ortalama vektörünün 47 boyutlu farksızlık altuzayı üzerindeki izdüşümü o sınıfa ait ortak vektörü vermektedir. 2500 veya 10 boyutlu öznelik vektörleri kullanıldığında, eğitim kümesinde %100 ve test kümesinde %26.7 tanıma oranları elde edilmiştir.

2- Öznelik vektörlerinin boyutları 4000'e ayarlandığında 1547 boyutlu farksızlık altuzayı oluşmaktadır. 4000 veya 10 boyutlu öznelik vektörleri kullanıldığında, eğitim kümesinde %100 ve test kümesinde %61.5 tanıma oranları elde edilmiştir.

3- 5500 ve 7500 boyuttan 10 boyuta indirgenmiş öznelik vektörleri ile yapılan çalışmalarda test kümesi için sırasıyla %68.2 ve %75.4 tanıma oranları elde edilmiştir. Eğitim kümesi için her iki boyutta da yine %100 tanıma oranlarına ulaşılmıştır.

4. Sonuçlar

Tüm sınıfların tek bir altuzay ile temsil edilmesi ve binlerce boyuttaki öznelik vektörlerinin sınıf içi

dağılımlarından elde edilen tanıma oranları ile 10 boyutlu öznitelik vektörleri ile elde edilen tanıma oranlarının aynı olması, bu çalışmanın önemini ortaya koymaktadır. Böylece tanıma problemlerinde, hem işlem yükü hem de zaman açısından önemli avantajlar sağlanmaktadır. Özellikle eğitim kümesinde %100 ve test kümesinde %90'lar civarında tanıma oranlarına ulaşılması önerilen yöntemin başarısını göstermektedir. Ayrıca, farklılık altuzayının boyutu arttıkça test kümesindeki tanıma oranlarının artacağı da bir gerçektir. Önerilen yöntem, zaman düzleminde dinamik zaman uygunlaştırılması (DTW) yapılmış ses verileri üzerinde de denenecektir.

5. Kaynakça

- [1] Gülmezoğlu, M. B., Dzhafarov, V. ve Barkana, A., "Ortak Vektör Yaklaşımı ile Önemli Bileşen Analizi Arasındaki Çelişki", 6. *Sinyal İşleme ve Uygulamaları Kurultayı*, pp. 290-295, Kızılcahamam, 1998.
- [2] Gülmezoğlu, M. B., Dzhafarov, V. ve Barkana, A., "The Common Vector Approach and Its Relation to Principal Component Analysis", *IEEE Trans. Speech and Audio Proc.*, 9(6):655-662, 2001.
- [3] Gülmezoğlu, M. B. ve Barkana, A., "Text-Dependent Speaker Recognition by Using Gram-Schmidt Orthogonalization Method", *IASTED Int. Conf. Signal Processing and Applications*, pp. 438-440, Canary Islands, 1998.
- [4] Gülmezoğlu, M. B., Dzhafarov, V. ve Barkana, A., "Eğitim Kümesinde Yeterli veri Oldığında Ortak Vektör Yaklaşımının Diğer Altuzay Yöntemleri ile Karşılaştırılması", 8. *Sinyal İşleme ve Uygulamaları Kurultayı*, pp. 13-18, Belek, 2000.
- [5] Gülmezoğlu, M. B., Dzhafarov, V., Edizkan, R. ve Barkana, A., "Ses Tanıma İçin Ortak Vektör Yaklaşımı: Çoklu Sınıf Problemi", 8. *Sinyal İşleme ve Uygulamaları Kurultayı*, pp. 19-24, Belek, 2000.
- [6] Gülmezoğlu, M. B., Dzhafarov, V., Edizkan, R. ve Barkana, A., "Common Vector Approach in Multi-Class Problems and Its Relation to Fisher's Linear Discriminant Analysis", 2nd *Int. Conf. Electrical and Electronics Engineering (ELECO'2001)*, pp. 117-121, Bursa, 2001.
- [7] Çevikalp, H., Wilkes, M., Neamtu, M. ve Barkana, A., "Discriminative Common Vectors for Face Recognition", *IEEE Trans. Pattern Analysis and Machine Intelligence* dergisine sunuldu, 2003.
- [8] Bishop, C. M., *Neural Networks for Pattern Recognition*: Oxford, U.K.:Clarendon, 1995.