

İÇİNDEKİLER

ÖZET	2
ABSTRACT.....	3
GİRİŞ ve AMAÇ.....	4
YAPILAN ÇALIŞMALAR.....	6
1. Sınıf İçi Dağılımlar Göz Önüne Alınarak Yapılan Çalışmalar.....	6
1.1. Teorik çalışmalar.....	6
1.2. Deneysel çalışmalar.....	8
2. Sınıflar Arası Dağılımlar Göz Önüne Alınarak Yapılan Çalışmalar.....	10
3. Sınıf İçi Ve Sınıflar Arası Dağılımlar Göz Önüne Alınarak Yapılan Çalışmalar.....	10
3.1. Fisher'in Doğrusal Ayırtaç Analizi (FLDA) üzerinde yapılan çalışmalar..	11
3.1.1. Teorik çalışmalar.....	11
3.1.2. Deneysel çalışmalar.....	11
3.2. $W^T S_w W / W^T \Phi_{B_T} W$ ölçütünü en küçükleyecek şekilde tek bir altuzayın bulunması.....	12
3.3. $W^T \Phi_w^c W / W^T \Phi_B^c W$ ölçütünü en küçükleyecek şekilde her sınıf için ayrı ayrı altuzayın bulunması.....	13
3.4. OVY üzerinde yapılan çalışmalar.....	13
3.4.1. Sınıf içi-sınıflar arası en iyileme ölçütü.....	14
3.4.2. Sınıflar arası-sınıf içi en iyileme ölçütü.....	14
3.4.3. Karar verme ölçütleri.....	15
3.4.4. Deneysel çalışmalar.....	16
SONUÇLAR.....	20
TARTIŞMA.....	21
KAYNAKLAR.....	23
EK-I.....	26

ÖZET

Bu projede, ayrıık kelime (sınıf) tanıma oranlarının iyileştirilmesi amaçlanmıştır. Bunun için öznitelik vektörlerinin sınıf içi dağılımları, sınıflar arası dağılımları ve her ikisi birden olmak üzere üç farklı dağılım şekli ayrı ayrı incelenmiştir. Eğitim aşamasında Ortak Vektör Yaklaşımı (OVY) ve Fisher'in Doğrusal Ayrıtaç Analizi (FLDA) olmak üzere iki yöntem kullanılmıştır. OVY yönteminde üç dağılım şekli de göz önüne alınmasına rağmen FLDA yönteminde sadece üçüncü dağılım şekli göz önüne alınmıştır. Test aşamasında Öklid uzaklığı ve “borda-count” gibi karar verme ölçütleri kullanılmıştır. “TI-Digit” veri tabanı üzerinde yapılan deneysel çalışmalarda OVY yöntemi kullanıldığında eğitim kümesi için %100 ve test kümesi için %99.5 tanıma oranları elde edilmiştir. FLDA kullanıldığında ise eğitim kümesi için %97.6 ve test kümesi için %95.9 tanıma oranları elde edilmiştir. Bu sonuçlar, bilinen FLDA ve OVY yöntemleri kullanılarak elde edilen sonuçlarda iyileştirmeler yapıldığını göstermektedir.

ABSTRACT

The purpose of this project is to improve the isolated word (class) recognition rates. To do this, three types of distributions, i) within-class, ii) between-class, iii) both within- and between-class, have been investigated separately. In the training process, two methods which are the Common Vector Approach (CVA) and Fisher's Linear Discriminant Analysis (FLDA) have been used. Although three types of distributions were considered in CVA method, only third type were considered in the FLDA method. In the test process, two decision criteria, Euclidean distance and borda-count, have been used. The experimental studies are performed on the TI-digit database. When the CVA method was used, the recognition rates of 100% and 99.5% were obtained for the training and test sets respectively. In the same database the FLDA method gave the recognition rates of 97.6% and 95.9% for the training and test sets respectively. These results indicate that the recognition rates were increased when the improved FLDA and CVA methods were used.

GİRİŞ ve AMAÇ

Bilim ve teknolojinin hızla ilerlemesi ve etki alanlarını sürekli geliştirmesi insanlar arasında yegâne etkileşim araçlarından biri olan konuşmayı da etkilemiş ve konuşmanın esas alındığı bazı iletişim sistemlerinin geliştirilmesine sebep olmuştur. Bu sistemlerin işlevselleşmesi, konuşmayı tanıma üzerinde yapılan çalışmaların öneminin artmasına neden olmuştur. Konuşmayı tanıma, etkileşimli sesli yanıt sistemlerinde (IVR:interactive voice response), otomotiv ve akıllı ev gibi sesle komut istenilen uygulamalarda yaygın olarak kullanılmaktadır. Konuşmayı tanıma, ayrık (isolated), bağlı (connected) ve sürekli (continuous) olmak üzere üçe ayrılır. Bunların içinden ayrık kelime tanıma, kelimelerin başı ve sonu kolaylıkla belirlenebilmektedir. Bu nedenle ayrık kelime tanıma yapılan sistemlerin performansları diğerlerine göre daha yüksektir. Ayrık kelime tanıma her kelime ayrı ayrı değerlendirildiğinden, orta büyüklükteki bir sözlük (≤ 100 kelime) için uygundur.

Etkileşimli sesli yanıt sistemleri günümüzde özellikle banka, hastane ve şirketlerde bilgi erişimi veya çağrı yönlendirmede kullanılmaktadır. Bu sistemlerde istenilen hizmet, tuşlara basılarak üretilen DTMF (Dual-tone multi frequency) sinyalleri veya ses ile seçilmektedir. İnsanlar genelde sesi tuşlara basmaya tercih etmektedirler[1]. Diğer konuşmayı tanıma uygulamalarında da sesle komut vermenin bazı avantajları bulunmaktadır.

Konuşmayı tanıma Gizli Markov Model (HMM), sinirsel ağlar ve altuzay yöntemleri gibi değişik yöntemler kullanılmaktadır. Bu yöntemler içinde HMM, performansı açısından en çok kabul gören yöntemlerden birisidir. Bu projede kullanılan altuzay yöntemleri Fisher'in Doğrusal Ayırtaç Analizi (FLDA)'nda ve Ortak Vektör Yaklaşımı (OVY)'nda, HMM'e göre daha basit eğitim yöntemleri ve karar verme ölçütleri kullanılmaktadır. Bu yöntemlerin HMM ile karşılaştırılabilir performans göstermeleri için bazı iyileştirmelerin yapılmasına ihtiyaç vardır.

FLDA, özellik çıkarmak için ve iyileştirilmiş izge tahminleri elde etmek için çok önemli bir yöntemdir [2,3]. FLDA; insanların duygularının ve psikolojik durumlarının tanınmasında, sürekli konuşmayı tanımadaki tahmin hatasının analizinde ve telefon hatlarından kaydedilen ayrık rakamların tanınması gibi bir çok uygulamada kullanılmaktadır [4-7]. Principe, Xu ve Wang , Fisher ölçütünü kullanarak PCA ve LDA için çevrimiçi öğrenme kurallarını araştırmışlardır [8]. Yaptıkları çalışmada ayrıca, iki sınıf problemi için Fisher ölçütü ile Ortalama Karesel Hata (MSE: Mean Square Error) arasındaki ilişkiyi göstermişlerdir. Leib ve Haub-Umbach, phone ve kelime tanıma uygulamalarında yankılaşım ve yankı gibi olumsuz çevresel etkiler altında, gözlem vektörleri arasındaki ayırt ediciliği arttırmak için FLDA tabanlı filtre kullanmışlardır[9]. Poston ve Marchette, FLDA'nın iki ardışık sürümünü geliştirmişlerdir [10]. Bu yazarlar, iki sınıf problemi için FLDA'yı yenileme süreci olarak, ilk önce test vektörünün her bir gruba ait olma olasılığının bulunmasını ve sonra, verilerin sayısının, ortalamaların, katsayıların ve sınıf içi ortak değişinti matrisinin yenilenmesini önermektedir.

LDA, diğer yöntemler ile beraber de yaygın olarak kullanılmaktadır. Örneğin, HMM ile beraber el yazısı tanıma [11,12] ve En Büyük Olabilirlik (ML) ile beraber ayrık kelime tanıma kullanılmaktadır [13]. Thomae, Ruske ve Pflau, Genişletilmiş LDA (ELDA) analizindeki prototip uyarlama problemini ortadan kaldırmak için Genelleştirilmiş Olasılıksal İniş (GPD) kullanarak Model Dönüşümlü ELDA (ELDA-MT) ismini verdikleri yaklaşım ile LDA'nın ayırt ediciliğini en iyilemişlerdir. ELDA-MT, konuşmayı tanıma deneylerindeki kelime hata oranlarında belirgin azalma sağlamıştır[14].

Pseudo-Fisher sınıflandırıcı, sınıf içi ortak değişinti matrisinin sıfır özdeğerleri yönündeki bileşenleri ihmal edip, sıfır olmayan özdeğerlerine karşılık gelen temel bileşenlerin altuzayında tanımlanmıştır [15]. Halbuki, [16]'daki yazarlar, Doğrudan LDA (DLDA) teorisine göre, sınıf içi

ortak deęiřinti matrisinin büyük özdeęerlerine karřılık gelen özvektörlerin bazılarının atılması gerektięini ve sürece, kalan özvektörler ile (özellikle sıfır özdeęerlere karřılık gelen özvektörler ile) devam edilmesi gerektięini belirtmiřlerdir.

LDA'nın problemli taraflarından birisi, iki sınıf arasındaki sınır doğrusal olmadığı zaman, yetersiz bir hipotez üretiyor olmasıdır [17]. Hata Düzeltme Çıkış Kodları (ECOC) yöntemi LDA'ya uygulanarak LDA'nın sınırlar içinde hipotez üretme yeteneęi arttırılmıştır. Fisher ölçütünün mutlak bir ölçüt olmadığı, dolayısıyla ayırtaç vektörlerinin istatistiksel ilişkileri ile beraber kullanılması gerektięi iddia edilmektedir [18]. Ayırma özellięi en büyük olan ayırtaç vektörleri elde etmek için Fisher ölçütünün, dikgen koşulları ile beraber kullanılması gerektięi ve böylece özelliklerin ilintisiz olacağı belirtilmiştir [18]. Fisher'in İstatistiksel LDA (FSLDA) vektörlerinin oranlarının İlintisiz LDA (ULDA) vektörlerinin oranlarından çok daha büyük olduğu, fakat FSLDA'nın sınıflandırma sonuçlarının ULDA'nın sonuçlarından daha iyi olmadığı gösterilmiştir [19].

Bu çalışmada incelenecek olan diğer yöntem ise Ortak Vektör Yaklaşımı (OVY)'dır. OVY; her bir sınıf için, o sınıfın ortak özelliklerini içeren ve tek olan bir vektör bulup, bu vektörü sınıf tanımada kullanma fikrine dayanan bir altuzay yöntemidir. OVY, yetersiz veri durumu (n : vektör boyutu $\geq m$: vektör sayısı) için ayrık kelime tanıma, konuşmacıyı tanıma ve motorların arıza tesbiti gibi uygulamalarda başarılı sonuçlar vermiştir [20-22]. Ayrıca OVY, yeterli veri durumu ($n < m$) için ayrık kelime tanıma uygulamaya uygulanmış ve yine başarılı sonuçlar elde edilmiştir [23]. OVY kullanılarak yapılan daha önceki çalışmalarda sınıf içi dağılımları [20-23] veya hem sınıf içi hem sınıflar arası dağılımları [24,25] göz önüne alarak her sınıf için farklılık ve farksızlık altuzayları oluşturulmuştur. Herhangi bir sınıfın ortalama vektörünün farksızlık altuzayı üzerindeki izdüşümü, o sınıfa ait ortak vektörü vermektedir ve tanıma problemlerinde kullanılmaktadır.

Ayrık kelime tanıma problemlerinde, öznitelik vektörlerinin sınıf içi dağılımları ve sınıflar arası dağılımları ayrı ayrı incelendięi gibi, bu dağılımların her ikisi birden en iyileme ölçütü altında incelenebilmektedir. Projenin amacı, hem sadece sınıf içi dağılımları göz önüne alarak, hem de sınıf içi dağılımlar ile beraber sınıflar arası dağılımları da göz önüne alarak ayrık kelime tanıma oranlarını iyileştirmektir. Bunun için FLDA ve OVY yöntemleri kullanılmıştır. Böylece hem eğitim kümesinde, hem de test kümesinde %100'e çok yakın tanıma oranlarına ulaşılması hedeflenmiştir. Bu hedefin gerçekleşmesi, tanıma algoritmalarının ticari amaçla kullanılması yönündeki çalışmalarımıza önemli bir destek sağlayacaktır.

YAPILAN ÇALIŞMALAR

Bu proje kapsamında, eğitim kümesindeki yeterli veri durumu için FLDA ve OVY'nin inceleneceği önerilmiştir. Yeterli veri durumu, eğitim kümesindeki her bir sınıfa ait öznitelik vektörlerinin sayısının (m), öznitelik vektörlerinin boyutundan (n) büyük olduğu ($m > n$) durumudur. Projenin birinci aşamasında, öznitelik vektörlerinin sınıf içi dağılımları göz önüne alınarak OVY'nin; ikinci aşamasında, sınıflar arası dağılımları göz önüne alınarak OVY'nin ve üçüncü aşamasında ise hem sınıf içi hem de sınıflar arası dağılımları göz önüne alınarak FLDA ve OVY'nin geliştirileceği ve ayırık kelime tanımda kullanılacağı proje önerisinde taahhüt edilmiştir. Dolayısıyla yapılan çalışmaları üç grupta toplayabiliriz.

1. Sınıf İçi Dağılımlar Göz Önüne Alınarak Yapılan Çalışmalar

Bu çalışmada herhangi bir sınıfa ait öznitelik vektörlerinin dağılımını, o sınıfın ortalamasına yakınlatacak bir en iyileme ölçütü tanımlanmıştır. Yapılan çalışmalar teorik ve deneysel olmak üzere iki bölümde incelenebilir.

1.1. Teorik çalışmalar

Bu projede kullanılan OVY yöntemi, her bir sınıfı temsil eden ve tek olan bir ortak vektörün bulunması fikrine dayanmaktadır[20-22]. Bu çalışmada sınıf indisi c ($=1,2,...,C$) ve her sınıftaki öznitelik vektörleri $\mathbf{a}_i^c$ ($i=1,2,...,m$) ile gösterilsin. Doğrusal bağımsız olduğu kabul edilen her bir öznitelik vektörü,

$$\mathbf{a}_i^c = \mathbf{a}_{i,\text{fark}}^c + \mathbf{a}_{\text{ortak}}^c + \boldsymbol{\varepsilon}_i^c \quad (i=1,2,...,m) \quad (1)$$

olarak yazılabilir. Burada $\mathbf{a}_{\text{ortak}}^c$, c sınıfının değişmeyen özelliklerini içeren ortak vektörü; $\mathbf{a}_{i,\text{fark}}^c$, c sınıfına ait kişisel ve ortam farklılıklarını içeren fark vektörünü ve $\boldsymbol{\varepsilon}_i^c$ hata vektörünü temsil etmektedir. Eşitlik (1)'den $\mathbf{a}_{\text{ortak}}^c$ 'yi bulmak için hataların karelerinin toplamını ifade eden aşağıdaki ölçütün en küçüklenmesi gerekir:

$$F_w^c = \sum_{i=1}^m \|\boldsymbol{\varepsilon}_i^c\|^2 = \sum_{i=1}^m \|\mathbf{a}_i^c - \mathbf{a}_{i,\text{fark}}^c - \mathbf{a}_{\text{ortak}}^c\|^2. \quad (2)$$

Bu ölçütün $\mathbf{a}_{\text{ortak}}^c$ 'ye göre türevi alınıp sıfıra eşitlenmeden önce $\mathbf{a}_{i,\text{fark}}^c$ ve $\mathbf{a}_{\text{ortak}}^c$ aşağıdaki gibi tanımlansın. Öncelikle yetersiz veri durumunda olduğu gibi tüm uzayı, farklılık ve farksızlık altuzayları olmak üzere ikiye bölelim [21,23]. Farklılık altuzayını $\mathbf{B}$ ile gösterelim ve bu uzayı geren birimlik temel vektörler de $\mathbf{u}_j$ ($j = 1, 2, ..., k-1$) olsun. Bu durumda Eşitlik (2)'deki $\mathbf{a}_{i,\text{fark}}^c$ vektörü

$$\mathbf{a}_{i,\text{fark}}^c = \sum_{j=1}^{k-1} \mathbf{u}_j^c (\mathbf{u}_j^{cT} \mathbf{a}_i^c) = \mathbf{P}_w^c \mathbf{a}_i^c \quad (i=1,2,...,m), \quad (3)$$

olarak yazılabilir. Yani $\mathbf{a}_{i,\text{fark}}^c$ vektörü, $\mathbf{a}_i^c$ vektörünün farklılık altuzayı üzerindeki izdüşümüdür. Eşitlik (3)'de $\mathbf{P}_w^c$, farklılık altuzayının izdüşüm matrisini göstermektedir:

$$\mathbf{P}_w^c = \sum_{j=1}^{k-1} \mathbf{u}_j^c \mathbf{u}_j^{c^T} \quad (4)$$

Diğer bir kısıtlama da ortak vektör için getirilsin. Yani ortak vektörün, sadece farksızlık altuzayı $\mathbf{B}^\perp$ üzerinde bileşenleri olsun. Böylece

$$\mathbf{a}_{\text{ortak}}^c = \sum_{j=k}^n (\mathbf{a}_{\text{ortak}}^{c^T} \mathbf{u}_j^c) \mathbf{u}_j^c = \mathbf{P}_w^{c\perp} \mathbf{a}_{\text{ortak}}^c \quad (5)$$

olarak yazılabilir. Eşitlik (5)'de $\mathbf{P}_w^{c\perp}$, farksızlık altuzayının izdüşüm matrisini göstermektedir:

$$\mathbf{P}_w^{c\perp} = \sum_{j=k}^n \mathbf{u}_j^c \mathbf{u}_j^{c^T}. \quad (6)$$

Yukarıdaki kısıtlamalar altında, F_w^c ölçütü:

$$F_w^c = \sum_{i=1}^m \left\| \mathbf{a}_i^c - \mathbf{P}_w^c \mathbf{a}_i^c - \mathbf{P}_w^{c\perp} \mathbf{a}_{\text{ortak}}^c \right\|^2 = \sum_{i=1}^m \left\| \mathbf{P}_w^{c\perp} (\mathbf{a}_i^c - \mathbf{a}_{\text{ortak}}^c) \right\|^2 \quad (7)$$

olur. $\mathbf{P}_w^c$ ve $\mathbf{P}_w^{c\perp}$, simetrik ve idempotent $n \times n$ matrisler olduğundan $\mathbf{P}_w^c + \mathbf{P}_w^{c\perp} = \mathbf{I}$ eşitliği her zaman geçerlidir ($\mathbf{I}$, birim matris). Eşitlik (7)'deki F_w^c ölçütünün $\mathbf{a}_{\text{ortak}}^c$ 'a göre türevi alınıp sıfıra eşitlenirse

$$\mathbf{a}_{\text{ortak}}^c = \mathbf{P}_w^{c\perp} \mathbf{a}_{\text{ort}}^c = \mathbf{P}_w^{c\perp} \left(\frac{1}{m} \sum_{i=1}^m \mathbf{a}_i^c \right) \quad (8)$$

sonucu elde edilir. Bu eşitliği kullanarak F_w^c ölçütü,

$$F_w^c = \sum_{j=k}^n \mathbf{u}_j^{c^T} \mathbf{\Phi}_w^c \mathbf{u}_j^c \quad (9)$$

olarak yazılabilir. Burada $\mathbf{\Phi}_w^c$, c sınıfının ortak değişinti matrisini göstermekte ve

$$\mathbf{\Phi}_w^c = \sum_{i=1}^m (\mathbf{a}_i^c - \mathbf{a}_{\text{ort}}^c)(\mathbf{a}_i^c - \mathbf{a}_{\text{ort}}^c)^T \quad (10)$$

olarak ifade edilmektedir. F_w^c ölçütünün, $\|\mathbf{u}_j^c\|=1$ kısıtı altında $\mathbf{u}_j^c$ 'lere göre en küçüklenmesinden, farklılık ve farksızlık altuzaylarının temel vektörlerinin ($\mathbf{u}_j^c$), ortak değişinti matrisi $\mathbf{\Phi}_w^c$ 'nin özvektörleri olduğu bulunur. $\mathbf{\Phi}_w^c$ 'nin özdeğerlerinin büyükten küçüğe doğru sıralandığını kabul edelim ($\lambda_1 > \lambda_2 > \dots > \lambda_k > \dots > \lambda_n$). En küçüklemekten sonra, F_w^c ölçütünün değeri

$$F_{w,\min}^c = \lambda_k + \lambda_{k+1} + \dots + \lambda_n$$

olur. Burada $\lambda_k, \lambda_{k+1}, \dots, \lambda_n$, ortak değışinti matrisinin en küçük özdeğerleridir. Bu özdeğerlere karşılık gelen özvektörler de, farksızlık altuzayı $\mathbf{B}^\perp$ 'in temel birimdik vektörleridir. $\mathbf{B}$ 'nin temel birimdik vektörleri ise, Φ_w^c 'nin en büyük özdeğerlerine karşılık gelen özvektörlerdir.

Sonuç olarak, c sınıfının ortak vektörü $\mathbf{a}_{\text{ortak}}^c$, c sınıfının ortalama vektörünün, o sınıfın farksızlık altuzayı üzerindeki izdüşümünün hesaplanması ile bulunabilir ve tanıma problemlerinde kullanılabilir.

1.2. Deneysel çalışmalar

Bilinmeyen bir sınıfa ait öznitelik vektörü $\mathbf{a}_x$ 'in, farksızlık altuzayı üzerindeki izdüşümü $\mathbf{a}_{\text{kalan}}^c$ ile gösterilmekte ve

$$\mathbf{a}_{\text{kalan}}^c = \sum_{j=k}^n (\mathbf{a}_x^T \mathbf{u}_j^c) \mathbf{u}_j^c = \mathbf{P}_w^{c\perp} \mathbf{a}_x \quad (11)$$

olarak ifade edilmektedir.

Kalan vektör ile ortak vektör arasındaki Öklid uzaklığı karar verme ölçütü olarak kullanılabilir ve

$$K^* = \underset{1 \leq c \leq C}{\operatorname{argmin}} \left\| \mathbf{a}_{\text{kalan}}^c - \mathbf{a}_{\text{ortak}}^c \right\|^2 = \underset{1 \leq c \leq C}{\operatorname{argmin}} \left\| \mathbf{P}_w^{c\perp} (\mathbf{a}_x - \mathbf{a}_{\text{ortak}}^c) \right\|^2 \quad (12)$$

olarak yazılabilir. Eğer $\mathbf{a}_x$ öznitelik vektörü, c sınıfına ait ise; $\mathbf{a}_{\text{kalan}}^c$ ile $\mathbf{a}_{\text{ortak}}^c$ arasındaki uzaklığın en küçük olması beklenir.

Deneysel çalışmalarda, 11 ayrıık sayamaktan oluşan “TI-Digit” veri tabanı kullanılmıştır. Bu veri tabanında, 225 konuşmacının her sayamağı iki kere söylemesinden oluşan toplam 450 söyleyiş bulunmaktadır. Her bir söyleyiş, sessizlik bölgeleri ayıklandıktan sonra önvurgulamadan geçirilmiş ve iki farklı pencereleme yöntemi kullanılmıştır:

i) Öncelikle her bir söyleyiş, 256 örnekten oluşan çerçevelere ayrılmıştır. Her bir çerçeveye 64’lük üst üste binme yapıp “Hamming” pencereleme uygulandıktan sonra 11 adet “root-melcep” parametresi hesaplanmış ve bu parametreler alt alta eklenmek suretiyle öznitelik vektörleri oluşturulmuştur. Bu işlem sonucunda öznitelik vektörlerinin boyutları, 110 ile 407 arasında değışmektedir. Boyutu 407’den küçük olan öznitelik vektörlerinin sonuna, “Matlab” programından üretilen rastgele sayılar eklenmiştir.

Bu çalışmada, $m > n$ şartını sağlamak için 427 söyleyiş eğitim kümesi olarak, 20 söyleyiş (3 söyleyiş hatalı olduğu için) ise test kümesi olarak kullanılmıştır. Her sınıf için elde edilen ortak değışinti matrislerinin boyutu 407×407 ’dir. Ortak değışinti matrisinin bütün özdeğerleri sıfırdan farklı olduğundan, en küçük $(n-k+1)$ özdeğere karşılık gelen özvektörler tanıma işlemlerinde kullanılmıştır. Bu bölümde normalize edilmiş (Nor) ve edilmemiş (NNor) öznitelik vektörleri kullanarak iki farklı çalışma yapılmıştır. Elde edilen doğru tanıma oranları Çizelge 1’de verilmiştir. Eğitim kümesinde minimum 3 özdeğere karşılık gelen özvektörler kullanıldığında %100 ve test kümesinde minimum 315 özdeğere karşılık gelen özvektörler kullanıldığında %99.5 tanıma oranına ulaşılmıştır.

Çizelge 1. Sınıf içi ortak değişinti matrisi kullanılarak elde edilen ortalama tanıma oranları (yüzde olarak)

λ^*	k	EĞİTİM KÜMESİ		TEST KÜMESİ	
		OVY		OVY	
		NNor	Nor.	NNor	Nor.
1	407	86.1	91.4	14.1	15.9
2	406	99.3	99.8	20.5	25.5
3	405	100	100	31.8	26.8
50	358	100	100	85.9	87.7
90	318	100	100	91.8	92.7
100	308	100	100	92.7	92.3
200	208	100	100	97.3	95.9
250	158	100	100	98.6	98.6
282	126	100	100	98.2	99.1
315	93	100	100	99.5	99.1
323	85	100	100	99.5	99.1
325	83	99.9	100	98.6	99.1
333	75	99.9	100	99.5	99.5
350	58	99.8	100	98.2	99.5
357	51	99.7	100	98.2	98.2
358	50	99.7	99.9	98.2	98.2
371	37	99.6	99.8	97.3	98.2
390	18	98.9	99.3	97.7	98.6
400	8	97.9	98.9	96.8	96.8
405	3	96.6	95.8	91.4	94.5
406	2	92.6	93.2	88.6	93.6
407	1	88.4	89.4	80.9	89.5

ii) Her bir söyleyiş, 8 adet çerçeveye ayrılmıştır. Her bir çerçeveye, içerdiği örnek sayısının 1/4'ü kadar üst üste binme yapıp “Hamming” pencereleme uygulandıktan sonra 33 adet “root-melcep” parametresi hesaplanmıştır. Bu parametreler alt alta eklenmek suretiyle 330 boyutlu öznitelik vektörleri oluşturulmuştur. Bu yöntem, Değişken Uzunlukta Çerçeve (DUÇ) yöntemi olarak isimlendirilmektedir. Eğitim kümesinde, ortak değişinti matrisinin minimum 3 özdeğerine karşılık gelen özvektörler kullanıldığında %100 ve test kümesinde minimum 309 özdeğerine karşılık gelen özvektörler kullanıldığında %98.82 tanıma oranına ulaşılmıştır. Test kümesinin tanıma oranı, 407 boyutlu öznitelik vektörleri kullanıldığında elde edilen tanıma oranına göre çok az düşük olmakla beraber, öznitelik vektörlerinin boyutunun biraz daha düşük olması ve daha az sayıda özvektör kullanılması işlem zamanı ve bellek ihtiyacı açısından avantaj sağlamaktadır.

Sınıf içi ortak değişinti matrisi kullanılarak yapılan sınıflamanın performansını ölçmek için çapraz-geçerlemeye (cross-validation) benzeyen bir yöntem kullanılmıştır. Çapraz geçerleme çoğunlukla istatistiksel sınıflandırıcıların daha önce ortaya çıkmayan veri durumunda sınıflama performanslarını tahmin etmek için kullanılır[26]. Çapraz geçerlemede tüm veri kümesinden k adet farklı küme oluşturulur. Bunlardan $k-1$ adeti eğitimde kullanılır; geri kalan küme ise test için kullanılır. Çapraz geçerlemede her k 'nci küme ve ona karşılık gelen test kümesi için istatistiksel bir değerlendirme yapılır. Burada, “TI-Digit” veri tabanından üç farklı eğitim ve test kümesi oluşturulmuştur. Her eğitim kümesi 346 ve her test kümesi 100 örnek içermektedir. Oluşturulan üç kümeye daha önce kullandığımız kümenin katılması ile oluşturulan toplam dört küme üzerinde istatistiksel başarımlar elde edilmiştir. Eğitim kümeleri için en küçük üç özdeğer kullanıldığında tanımda %100 başarımlar elde edilmektedir. Test kümeleri için elde edilen ortalama tanıma oranları

Çizelge 2’de verilmektedir. Dört küme üzerinden sınıf içi ortak değişinti matrisi için ortalama %98,93 başarımla elde edilmiştir. Çizelge 2’de yeni oluşturulan kümeler 2-4 küme numaraları ile gösterilmiştir. Diğer deneysel çalışmaların hepsinde kullanılan küme ise 1 nolu kümedir.

Çizelge 2. Farklı test kümeleri için elde edilen ortalama tanıma oranları

Küme Numarası	Ortalama Tanıma Oranı(%)	Özvektör Sayısı
1	98.82	319
2	99.00	274
3	98.80	309
4	99.09	320

2. Sınıflar Arası Dağılımlar Göz Önüne Alınarak Yapılan Çalışmalar

Bu çalışmada, 11 sınıftan oluşan “TI-Digit” veri tabanı iki sınıftan oluşan veri tabanı gibi kullanılmıştır. Yani, hangi sınıf için en iyileme ölçütü tanımlanacak ise geriye kalan sınıflar bir sınıf gibi düşünülmüştür. Öznitelik vektörlerinin sınıflar arası dağılımlarını göz önüne alan OVY’de; herhangi bir sınıfa ait öznitelik vektörlerinin, diğer sınıfların (ikinci sınıfın) ortalamasından uzak olması beklenir. Bu durumda en iyileme ölçütü

$$F_B^c = \sum_{i=1}^m \left\| \mathbf{P}_B^c (\mathbf{a}_i^c - \mathbf{a}_{d,ort}^c) \right\|^2 \quad \mathbf{a}_{d,ort}^c = \frac{1}{C-1} \sum_{\substack{i=1 \\ i \neq c}}^C \mathbf{a}_{ort}^i \quad (13)$$

olarak tanımlanır. Bu ölçütün en büyüklenmesi, c ’inci sınıfın sınıf içi dağılımını, diğer sınıfların ortalamasından uzaklaştıracak bir farklılık altuzayı verecektir. Eşitlik (13)’de $\mathbf{P}_B^c$, bu altuzay için izdüşüm matrisini ve $\mathbf{a}_{d,ort}^c$, c ’inci sınıfın dışında kalan sınıfların ortalama vektörünü göstermektedir.

Böylece F_B^c ölçütünün değeri, c ’inci sınıfın sınıflar arası ortak değişinti matrisi Φ_B^c ’nin

$$\Phi_B^c = \sum_{i=1}^m (\mathbf{a}_i^c - \mathbf{a}_{d,ort}^c)(\mathbf{a}_i^c - \mathbf{a}_{d,ort}^c)^T \quad (14)$$

en büyük özdeğerlerinin toplamına karşılık gelir. Tanıma aşamasında, ortak değişinti matrisinin en büyük özdeğerlerine karşılık gelen özvektörler kullanılır. Böylece elde edilen ortak ve kalan vektörler arasındaki uzaklık hangi sınıf için minimum ise, bilinmeyen test vektörünün o sınıfa ait olduğu kabul edilir.

Yapılan deneysel çalışmalarda, 330 boyutlu öznitelik vektörleri kullanıldığında, eğitim kümesinde en büyük 55 özdeğer için %99.58 ve test kümesinde en büyük 16 özdeğer için %98.1 tanıma oranları elde edilmiştir.

3. Sınıf İçi Ve Sınıflar Arası Dağılımlar Göz Önüne Alınarak Yapılan Çalışmalar

Bu çalışmada hem FLDA, hem de OVY yöntemleri incelenmiş ve bu yöntemlerde iyileştirmeler yapılmıştır. En iyileme ölçütlerinin çoklu-sınıf kelime tanımadaki başarımla bulunurken veri tabanı olarak, “TI-Digit” ve öznitelik olarak “root-melcep” parametreleri

kullanılmıştır. Her bir öznitelik vektörü, DUÇ yöntemiyle elde edilen 330 adet “root-melcep” parametresi içermektedir.

3.1. Fisher’in Doğrusal Ayırtaç Analizi (FLDA) üzerinde yapılan çalışmalar

Hem sınıf içi, hem de sınıflar arası dağılımları göz önüne alan yöntemlerin başında Fisher’in en iyileme ölçütü gelmektedir. Fisher, düşük boyutlu uzaylarda, sınıflar arası ortak değişinti matrisinin sınıf içi ortak değişinti matrisine oranını en büyükleyerek çoklu sınıf problemlerini çözmek için LDA’yı kullanmıştır [27,28]. LDA, kelime tanıma problemlerinde, doğrusal boyut indirgeme amacıyla yaygın olarak kullanılan bir yöntemdir. Bu bölümde yapılan çalışmalar da teorik ve deneysel olarak ikiye ayrılmıştır.

3.1.1. Teorik çalışmalar

Fisher’in en büyüklenmesine çalışılan ölçütü

$$\mathbf{J}(\mathbf{W}) = \text{Tr}\{(\mathbf{W}^T \mathbf{S}_w \mathbf{W})^{-1} (\mathbf{W}^T \mathbf{S}_B \mathbf{W})\} \quad (15)$$

olarak ifade edilir. Burada $\mathbf{S}_w$ ve $\mathbf{S}_B$ sırasıyla, Fisher’in tanımladığı sınıf içi ve sınıflar arası ortak değişinti matrislerini ve $\mathbf{W}$, izdüşüm matrisini göstermektedir [27]. Eşitlik (15)’de verilen ölçütü en iyilemenin sonucunda elde edilen altuzayın boyutu, sınıf sayısından bir eksiktir ve bu altuzayda sınıfların ayırt edilebilme oranları çok yüksek olmamaktadır. Bu kısıtlama aslında, sınıflar arası ortak değişinti matrisinin tanımından kaynaklanmaktadır. Eşitlik (15)’de verilen ölçütü iyileştirmek için literatürde yapılmış çalışmaları aşağıdaki gibi özetleyebiliriz.

- i) $\mathbf{w}_i^T \mathbf{w}_j = 0, \forall i \neq j, i, j = 1, 2, \dots, d$ şartının yerine $\mathbf{w}_i^T \mathbf{S}_t \mathbf{w}_j = 0, \forall i \neq j$ şartının kullanılması [18]. Burada $\mathbf{S}_t = \mathbf{S}_w + \mathbf{S}_B$.
- ii) Sınıflar arası ortak değişinti matrisinin, sınıfların ortalamalarının farkı cinsinden yazılması [28].
- iii) Sınıflar arası ortak değişinti matrisini, özdeğerleri cinsinden tanımlanan ağırlık fonksiyonu ile çarparak ayırt edici özelliğinin arttırılmaya çalışılması [29].

3.1.2. Deneysel çalışmalar

Eşitlik (15)’de verilen Fisher’in en iyileme ölçütünü en büyükmek için $\mathbf{S}_w^{-1} \mathbf{S}_B$ ’nin sıfır olmayan özdeğerleri kullanılır. Bu özdeğerlere karşılık gelen özvektörler $\mathbf{v}_j$ ile ve bu özvektörlerin gerdiği uzaya izdüşüm matrisi $\mathbf{P}_f$ ile gösterilsin:

$$\mathbf{P}_f = \sum_{j=1}^{C-1} \mathbf{v}_j \mathbf{v}_j^T \quad (16)$$

Bu durumda karar verme ölçütü,

$$\mathbf{K}^* = \underset{1 \leq c \leq C}{\text{argmin}} \left\| \mathbf{P}_f (\mathbf{a}_x - \mathbf{a}_{\text{ort}}^c) \right\|^2 \quad (17)$$

olarak yazılabilir.

Karar verme ölçütü hangi c sınıfı için minimum değer verir ise, bilinmeyen öznitelik vektörü $\mathbf{a}_x$, o sınıfa ait demektir.

- i) Tanıma aşamasında 407 boyutlu öznitelik vektörleri kullanıldığında eğitim kümesi için %96.5 ve test kümesi için %92.3 tanıma oranları elde edilmiştir. Yukarıda bahsedilen iyileştirme çalışmaları Fisher ölçütüne uygulanmış, fakat [30]'da da belirtildiği gibi tanıma oranlarının artmadığı gözlenmiştir.
- ii) 330 boyutlu öznitelik vektörleri kullanıldığında ise eğitim kümesi için %97.6 ve test kümesi için %95.9 tanıma oranları elde edilmiştir.
- iii) Yine 330 boyutlu öznitelik vektörleri kullanıldığında Fisher'in tanımladığı sınıf içi ortak değişinti matrisi $\mathbf{S}_w$ için ayrı altuzay ve sınıflar arası ortak değişinti matrisi $\mathbf{S}_B$ için ayrı altuzay bularak deneysel çalışmalar tekrarlanmıştır. Bu durumda eğitim kümesinde sadece $\mathbf{S}_B$ için %90.9, sadece $\mathbf{S}_w$ için %92.5 ve bu sonuçlar "borda-count" yöntemi [31,32] ile birleştirildiğinde ise %96.5 tanıma oranları elde edilmiştir. Test kümesinde, sadece $\mathbf{S}_B$ için %87.6, sadece $\mathbf{S}_w$ için %90.3 ve bu sonuçlar "borda-count" yöntemi ile birleştirildiğinde %95.1 tanıma oranları elde edilmiştir.

3.2. $|\mathbf{W}^T \mathbf{S}_w \mathbf{W}| / |\mathbf{W}^T \Phi_{B_T} \mathbf{W}|$ ölçütünü en küçükleyecek şekilde tek bir altuzayın bulunması

Bu bölümde tüm sınıfları temsil eden tek bir altuzay bulacak şekilde en iyileme ölçütü tanımlanacaktır. En küçüklenecek olan bu ölçütte $\mathbf{S}_w$, Fisher'in toplam sınıf içi ortak değişinti matrisini göstermektedir. Toplam sınıflar arası ortak değişinti matrisi Φ_{B_T} , iki farklı biçimde tanımlanmıştır:

- i) Φ_{B_T} , her bir sınıfın ortalamasının, diğer sınıfların ortalamasından uzak olacak şekilde tanımlanmıştır:

$$\Phi_{B_T}^1 = \sum_{c=1}^C (\mathbf{a}_{\text{ort}}^c - \mathbf{a}_{d,\text{ort}}^c)(\mathbf{a}_{\text{ort}}^c - \mathbf{a}_{d,\text{ort}}^c)^T \quad (18)$$

Burada $\mathbf{a}_{\text{ort}}^c$, c'inci sınıfın ortalama öznitelik vektörünü ve $\mathbf{a}_{d,\text{ort}}^c$, c'inci sınıfın dışında kalan sınıfların ortalama öznitelik vektörünü göstermektedir. Burada, $\Phi_{B_T}^1$ 'in determinantı sıfır olduğundan, en büyüklenecek ölçüt $|\mathbf{W}^T \Phi_{B_T}^1 \mathbf{W}| / |\mathbf{W}^T \mathbf{S}_w \mathbf{W}|$ olarak tanımlanmıştır. $\mathbf{S}_w^{-1} \Phi_{B_T}^1$ matrisinin en büyük özdeğerlerine karşılık gelen özvektörler kullanıldığında eğitim kümesi için %97.6 ve test kümesi için %95.9 tanıma oranları elde edilmiştir.

- ii) Φ_{B_T} için diğer bir yaklaşım, her bir sınıfın öznitelik vektörlerinin diğer sınıfların ortalamasından ayrı ayrı uzak olacak şekilde tanımlanmasıdır:

$$\Phi_{B_T}^2 = \sum_{i=1}^m (\mathbf{a}_i^1 - \mathbf{a}_{d,\text{ort}}^1) + \dots + \sum_{i=1}^m (\mathbf{a}_i^C - \mathbf{a}_{d,\text{ort}}^C) \quad (19)$$

Bu durumda $\Phi_{B_T}^2$ 'nin determinantı sıfır olmamaktadır. Böylece, $|\mathbf{W}^T \mathbf{S}_w \mathbf{W}| / |\mathbf{W}^T \Phi_{B_T}^2 \mathbf{W}|$ ölçütünün en küçüklenmesi veya $|\mathbf{W}^T \Phi_{B_T}^2 \mathbf{W}| / |\mathbf{W}^T \mathbf{S}_w \mathbf{W}|$ ölçütünün en büyüklenmesi aynı

sonucu vermektedir. $(\Phi_{B_T}^2)^{-1} S_w$ matrisinin en küçük özdeğerlerine karşılık gelen özvektörler kullanıldığında eğitim kümesi için %97.32 ve test kümesi için %95.1 tanıma oranları elde edilmiştir.

3.3. $|\mathbf{W}^T \Phi_w^c \mathbf{W}| / |\mathbf{W}^T \Phi_B^c \mathbf{W}|$ ölçütünü en küçükleyecek şekilde her sınıf için ayrı ayrı altuzayın bulunması

Bu bölümde ise her sınıf için ayrı ayrı altuzay bulacak şekilde en küçüklenecek ölçüt tanımlanmıştır. Bunun için Bölüm 1.1’de tanımlanan sınıf içi ortak değişinti matrisi Φ_w^c ile Bölüm 2’de verilen ve iki farklı şekilde tanımlanan sınıflar arası ortak değişinti matrisi Φ_B^c kullanılmıştır.

- i) İlk olarak Eşitlik (14)’de verilen Φ_B^c kullanılmıştır. $(\Phi_B^c)^{-1} \Phi_w^c$ ’nin en küçük özdeğerlerine karşılık gelen özvektörler kullanıldığında eğitim kümesi için %96.16 ve test kümesi için %88.91 tanıma oranları elde edilmiştir.

$|\mathbf{W}^T \Phi_w^c \mathbf{W}| / |\mathbf{W}^T \Phi_B^c \mathbf{W}|$ oranını her sınıf için en küçüklemek yerine, $|\mathbf{W}^T \Phi_w^c \mathbf{W}|$ ’yi her sınıf için en küçükleyip $|\mathbf{W}^T \Phi_B^c \mathbf{W}|$ ’yi ise her sınıf için en büyükleyip elde edilen sonuçlar “borda-count” yöntemi ile birleştirilebilir[31,32]. Eğitim kümesinde Φ_w^c ’nin en küçük özdeğerlerine karşılık gelen özvektörler kullanıldığında %100 ve Φ_B^c ’nin en büyük özdeğerlerine karşılık gelen özvektörler kullanıldığında %90.88 tanıma oranları elde edilmesine rağmen “borda-count” yöntemi ile sınıflandırıcılar birleştirildiğinde %98.27 tanıma oranı elde edilmiştir. Test kümesinde Φ_w^c ’den %98.82, Φ_B^c ’den %87.55 ve “borda-count” yönteminden %97.36 tanıma oranları elde edilmiştir.

- ii) İkinci olarak; herhangi bir sınıfa ait öznitelik vektörlerinin, diğer sınıfların her birinin ortalamasından ayrı ayrı uzak olacak şekilde ortak değişinti matrisi tanımlanmıştır:

$$\Phi_{B_i}^c = \sum_{\substack{j=1 \\ j \neq c}}^C \sum_{i=1}^m (\mathbf{a}_i^c - \mathbf{a}_{ort}^j)(\mathbf{a}_i^c - \mathbf{a}_{ort}^j)^T \quad (20)$$

$(\Phi_{B_i}^c)^{-1} \Phi_w^c$ ’nin en küçük özdeğerlerine karşılık gelen özvektörler kullanıldığında eğitim kümesi için %100 ve test kümesi için %86 tanıma oranları elde edilmiştir.

Bir önceki bölümde olduğu gibi Φ_w^c ’nin en küçük özdeğerlerine karşılık gelen özvektörlerden elde edilen sonuçlar ile $\Phi_{B_i}^c$ ’nin en büyük özdeğerlerine karşılık gelen özvektörlerden elde edilen sonuçlar “borda-count” yöntemi ile birleştirildiğinde eğitim kümesi için %98.32 ve test kümesi için %97.36 tanıma oranları elde edilmiştir.

3.4. OVY üzerinde yapılan çalışmalar

Bu çalışmada, çoklu-sınıf kelime tanıma probleminin çözümünde, hem sınıf içi hem sınıflar arası dağılımları göz önüne alan iki farklı en iyileme ölçütünün başarısı araştırılmıştır. Birinci en

iyileme ölçütünde, sınıf içi dağılımlara bakılarak elde edilen farklılık altuzayında sınıflar arası uzaklıkların en büyüklenmesine çalışılmıştır. İkinci en iyileme ölçütünde ise sınıflar arası dağılımlara bakılarak elde edilen farklılık altuzayında sınıf içi uzaklıkların en küçüklenmesine çalışılmıştır.

3.4.1. Sınıf içi-sınıflar arası en iyileme ölçütü

Bu bölümde, sınıf içi dağılımlara bakılarak elde edilen farklılık altuzayında sınıflar arası uzaklıkların en büyüklenmesine çalışılmıştır.

Her sınıftaki öznitelik vektörlerinin sayısı m , öznitelik vektörlerindeki eleman sayısı n ve öznitelik vektörü $\mathbf{a}_i^c$ ($i=1,2,...,m$) ile gösterilsin. Öncelikle, sınıf içi dağılımlara bakılarak farklılık altuzayı oluşturulacaktır. Buna göre

$$F_w^c = \sum_{i=1}^m \left\| \mathbf{P}_w^{c\perp} \left(\mathbf{a}_i^c - \mathbf{a}_{ort}^c \right) \right\|^2 \quad (21)$$

sınıf içi ölçütünün en küçüklenmesi, c 'inci sınıfın sınıf içi dağılımını kendi sınıf ortalamasına yakınlaştıracak bir farklılık altuzayı verecektir. Ortak değişinti matrisi Φ_w^c 'nin özdeğerleri büyükten küçüğe doğru sıralansın ve özvektörler $\mathbf{u}_j^c$ ile gösterilsin. $(n-k+1)$ adet en küçük özdeğere karşılık gelen özvektörler farklılık altuzayını oluşturmaktadır [23]. Eşitlik (21)'de verilen $\mathbf{P}_w^{c\perp}$, farklılık altuzayına izdüşüm matrisini göstermektedir ve Eşitlik (6)'dan bulunabilir.

İyi bir ayırt etme için aynı zamanda sınıfların birbirinden uzak olması istenir. Sınıfların birbirinden uzaklaştırılması için kullanılacak olan yeni eniyileme ölçütü aşağıdaki gibi tanımlanmıştır:

$$F_l^c = \sum_{i=1}^m \left\| \mathbf{P}_{B_n}^c \left(\mathbf{P}_w^{c\perp} \mathbf{a}_i^c - \mathbf{P}_w^{c\perp} \mathbf{a}_{ort}^c \right) \right\|^2 \quad (22)$$

Bu ölçütün en büyüklenmesi, yeni altuzaydaki sınıflar arası ortak değişinti matrisi $\Phi_{B_n}^c$ 'nin özdeğerlerinden en büyüklerinin alınması ile sağlanır. Burada yine özdeğerlerin büyükten küçüğe doğru sıralandığını ve r adet en büyük özdeğere karşılık gelen özvektörlerin yeni farklılık altuzayını oluşturduğunu kabul edelim. Yeni farklılık altuzayının izdüşüm matrisi $\mathbf{P}_{B_n}^c$ aşağıdaki gibi bulunur:

$$\mathbf{P}_{B_n}^c = \sum_{j=1}^r \mathbf{y}_j^c \mathbf{y}_j^{cT} \quad (23)$$

Burada $\mathbf{y}_j^c$ 'ler yeni farklılık altuzayını geren dikgen temel vektörlerdir.

En büyükleme işlemi her sınıf için ayrı ayrı yapılır. Böylelikle sınıfların sınıf içi dağılımları diğer sınıfların ortalamalarından uzak hale getirilir.

3.4.2. Sınıflar arası-sınıf içi en iyileme ölçütü

Bu bölümde ise, sınıflar arası dağılımlara bakılarak elde edilen farklılık altuzayında sınıf içi uzaklıkların en küçüklenmesine çalışılmıştır. İlk önce sınıflar arası dağılımlara bakılarak farklılık altuzayı oluşturulacaktır. Buna göre Eşitlik (13)'de verilen

$$F_B^c = \sum_{i=1}^m \left\| \mathbf{P}_B^c \left(\mathbf{a}_i^c - \mathbf{a}_{d,ort}^c \right) \right\|^2$$

sınıflar arası ölçütünün en büyüklenmesi, c'inci sınıfın ortalamasını, diğer sınıfların ortalamasından uzaklaştıracak bir farklılık altuzayı verecektir. Yukarıdaki eşitlikte $\mathbf{P}_B^c$, farklılık altuzayına izdüşüm matrisini göstermektedir. Ortak değişinti matrisi Φ_B^c 'nin özdeğerleri büyükten küçüğe doğru sıralandığında, r adet en büyük özdeğere karşılık gelen özvektörler farklılık altuzayını oluşturmaktadır.[25].

İyi bir ayırt etme için aynı zamanda sınıfların kendi ortalamalarına yakın olması istenir. Bunun için kullanılacak olan yeni eniyileme ölçütü aşağıdaki gibi tanımlanır:

$$F_2^c = \sum_{i=1}^m \left\| \mathbf{P}_{w_n}^{c\perp} \left(\mathbf{P}_B^c \mathbf{a}_i^c - \mathbf{P}_B^c \mathbf{a}_{d,ort}^c \right) \right\|^2 \quad (24)$$

Bu ölçütün en küçüklenmesi, yeni altuzaydaki sınıf içi ortak değişinti matrisinin özdeğerlerinden en küçüklerinin alınması ile sağlanır. Burada yine özdeğerlerin büyükten küçüğe doğru sıralandığını ve (n-k+1) adet en küçük özdeğere karşılık gelen özvektörlerin farksızlık altuzayı oluşturduğunu kabul edelim. Yeni farksızlık altuzayının izdüşüm matrisi $\mathbf{P}_{w_n}^{c\perp}$

$$\mathbf{P}_{w_n}^{c\perp} = \sum_{j=k}^n \mathbf{z}_j^c \mathbf{z}_j^{cT} \quad (25)$$

olarak ifade edilir. Eşitlik (25)'de $\mathbf{z}_i^c$, yeni farksızlık altuzayını geren dikgen temel vektörlerdir. En küçükleme işlemi her sınıf için ayrı ayrı yapılır. Böylelikle sınıfların sınıf içi dağılımları kendi ortalamalarına yakın hale getirilir.

3.4.3. Karar verme ölçütleri

Eşitlik (22)'de verilen en iyileme ölçütü F_1^c 'e göre sınıflama yapılırken aşağıdaki karar verme ölçütü kullanılmıştır.

$$K^* = \underset{1 \leq c \leq C}{\operatorname{argmin}} \left\| \mathbf{P}_{B_n}^c \mathbf{P}_w^{c\perp} \mathbf{a}_x - \mathbf{P}_{B_n}^c \mathbf{P}_w^{c\perp} \mathbf{a}_{ort}^c \right\|^2 \quad (26)$$

Eşitlik (26)'da verilen karar verme ölçütünde bilinmeyen test vektörü $\mathbf{a}_x$, c'inci sınıfa ait ise yukarıdaki ölçütün en küçük olması beklenir. Eşitlik (26)'da $\mathbf{P}_w^{c\perp}$, sınıf içi dağılımları kendi sınıf ortalamalarına yaklaştırırken $\mathbf{P}_{B_n}^c$, sınıflar arası uzaklığı en büyük yapmaya çalışır.

Eşitlik (24)'de verilen en iyileme ölçütü F_2^c 'ye göre sınıflama yapılırken aşağıdaki karar verme ölçütü kullanılmıştır:

$$K^* = \underset{1 \leq c \leq C}{\operatorname{argmin}} \left\| \mathbf{P}_{w_n}^{c\perp} \mathbf{P}_B^c \mathbf{a}_x - \mathbf{P}_{w_n}^{c\perp} \mathbf{P}_B^c \mathbf{a}_{d,ort} \right\|^2 \quad (27)$$

Bu karar verme ölçütünde bilinmeyen test vektörü $\mathbf{a}_x$, c 'inci sınıfa ait ise yukarıdaki ölçütün en küçük olması beklenir. Eşitlik (27)'de sınıflar arası uzaklıklar en büyük yapılmaya çalışılırken, sınıf içi uzaklıklar ise en küçük yapılmaya çalışılır.

3.4.4. Deneysel çalışmalar

Deneysel çalışmaları F_1^c ölçütü için ve F_2^c ölçütü için yapılan çalışmalar olmak üzere iki grupta toplayabiliriz.

i. F_1^c ölçütünde bir vektöre iki izdüşüm uygulanmaktadır. Bu izdüşümlerden birincisi sınıf içi dağılımlardan, ikinciside sınıflar arası dağılımlardan elde edilmektedir. Bu durumda net boyut indirgeme son uygulanan izdüşüm tarafından belirlenmektedir.

Çizelge 3'de F_1^c ölçütünü kullanarak, sınıf içi dağılımlardan elde edilen 1–30 özdeğere karşılık gelen altuzayda sınıflar arası dağılımlara göre eğitim kümesinin tanıma oranları verilmektedir.

Çizelge 3'den görüleceği gibi F_1^c ölçütü, sınıflar arası dağılımlardan bulunan özdeğerlerden sadece bir tanesi kullanıldığında %100 tanıma oranını vermektedir. Halbuki sadece sınıf içi dağılımlar kullanıldığında ilk üç özdeğer için %100 tanıma oranına ulaşılmaktadır.

Çizelge 3. F_1^c ölçütüne göre eğitim kümesinden elde edilen ortalama yüzde tanıma oranları

Sınıflar Arası Dağılım Özdeğer Sayısı	→ Sınıf İçi Dağılım Özdeğer Sayısı				
	1	5	10	20	30
1	18.18	99.97	100.00	100.00	100.00
5		73.52	100.00	100.00	100.00
10			90.88	100.00	100.00
15				100.00	100.00
20				100.00	100.00
25					100.00
30					100.00

Çizelge 4'de F_1^c ölçütünü kullanarak sınıf içi dağılımlarından elde edilen 220–315 özdeğere karşılık gelen altuzayda sınıflar arası dağılımlara göre test kümesinin tanıma oranları verilmektedir.

Çizelge 4. F_1^c ölçütüne göre test kümesinden elde edilen ortalama yüzde tanıma oranları.

Sınıflar Arası Dağılım Özdeğer Sayısı	→ Sınıf İçi Dağılım Özdeğer Sayısı							
	220	240	260	280	300	311	313	315
10	89.27	92.82	93.09	92.27	94.73	95.55	94.45	93.82
30	87.09	91.36	93.45	94.55	95.82	96.36	96.64	97.27
50	87.09	89.18	93.18	95.09	96.00	98.64	97.45	97.91
73	88.36	89.36	92.55	95.36	96.64	98.45	98.45	98.73
80	86.64	89.64	91.27	94.91	97.09	97.73	98.55	98.45
100	85.18	90.00	93.64	94.18	96.00	97.27	98.27	98.18
120	88.36	89.18	93.00	96.09	95.82	97.09	97.45	97.27
150	89.18	91.45	94.00	95.91	96.64	96.82	97.18	97.09
180	88.64	92.18	94.27	94.82	95.27	96.36	97.09	97.73
200	90.73	92.55	94.18	95.27	95.09	95.73	96.27	96.36
250			94.27	94.00	94.27	95.18	95.91	95.55
280				94.09	93.55	95.55	95.91	95.09
300					93.91	94.91	95.27	94.73
310						94.82	95.27	94.09

F_1^c ölçütünün test kümesindeki başarımı sadece sınıf içi ölçütü kullanmaya göre 0.09 puan daha azdır. Bu nedenle başarımları birbirine yakın olarak düşünebiliriz. Bu durumda, F_1^c ölçütünü kullanmanın avantajı daha düşük altuzayda iyi bir sınıflama imkanı getirmesidir. Sadece sınıf içi ölçüt kullanılsaydı altuzay boyutu 309 olacak iken, F_1^c ölçütü ile altuzay boyutumuz 73 olmaktadır. Düşük boyutta sınıflama yapmak, hem işlem süresini kısaltacak hem de bellek gereksinimini azaltacaktır.

Sınıf içi ortak değişinti matrisi kullanılarak yapılan sınıflamanın performansını ölçmek için kullanılan çapraz geçerlemeye benzer bir yöntem F_1^c ölçütü için de kullanılmıştır. F_1^c ölçütü için sınıflar arası dağılımlardan bir özdeğer kullanıldığında eğitim kümelerinde 100% başarımlar elde edilmiştir. Test kümeleri için elde edilen sonuçlar Çizelge 5’de verilmektedir. Tanıma yüzdelерinin yanındaki parantezde ilk değer sınıf içi dağılımından ve ikinci değerde sınıflar arası dağılımından kaç özdeğer alındığını göstermektedir. F_1^c ölçütünün en iyilenmesinde, sınıf içi dağılımlardan elde edilen özdeğerlerin en küçük olanları ve sınıflar arası dağılımlardan elde edilen özdeğerlerin en büyük olanları Çizelge 5’de parantez içinde gösterilmiştir. Parantez içinde verilen ikinci değerler bize hangi boyutta tanıma oranlarının elde edildiğini göstermektedir. F_1^c ölçütü için dört küme üzerinden istatistiksel ortalama olarak %98 başarımlar elde edilmiştir.

Çizelge 5. Farklı test kümeleri için elde edilen tanıma oranları

Küme Numarası	Ortalama Tanıma (%)	Özvektör Sayısı
1	98,73	(315-73)
2	97,64	(317-64)
3	97,82	(311-76)
4	97,91	(318-54)

ii. F_2^c ölçütünde önce sınıflar arası dağılımlar göz önüne alınmakta ve daha sonra sınıf içi dağılımlara bakılmaktadır. F_2^c ölçütünü kullanarak sınıflar arası dağılımlarından elde edilen 220–300 özdeğere karşılık gelen altuzayda sınıf içi dağılımlara göre eğitim kümesinin tanıma oranları Çizelge 6’da verilmektedir.

Çizelge 6. F_2^c ölçütüne göre eğitim kümesinden elde edilen ortalama yüzde tanıma oranları.

Sınıf İçi Dağılım Özdeğer Sayısı	→ Sınıflar Arası Dağılım Özdeğer Sayısı								
	220	230	240	250	260	270	280	290	300
10	72.49	72.60	68.39	81.06	81.27	92.75	93.41	93.62	98.90
20	88.60	90.75	90.44	92.98	95.80	98.21	98.90	99.47	99.84
30	94.82	96.03	96.61	98.06	98.24	99.55	99.61	99.82	100.00
40	96.87	97.87	98.45	99.42	99.42	99.74	99.87	99.89	99.95
50	97.85	98.69	98.92	99.71	99.79	99.97	99.92	99.97	100.00
60	98.79	98.95	99.40	99.74	99.95	99.95	99.97	99.97	100.00
70	98.98	99.37	99.61	99.79	99.97	99.97	100.00	99.97	100.00
80	99.32	99.55	99.66	99.84	99.89	100.00	100.00	100.00	100.00
90	99.13	99.71	99.82	99.92	99.95	99.97	100.00	100.00	100.00
100	99.26	99.58	99.84	99.89	99.95	100.00	99.97	100.00	100.00
110	99.40	99.58	99.74	99.97	99.92	99.95	100.00	100.00	100.00
120	99.32	99.58	99.66	99.87	99.97	99.95	99.97	100.00	100.00
130	99.16	99.53	99.61	99.74	99.97	100.00	99.97	100.00	100.00
140	99.32	99.29	99.63	99.68	99.87	99.97	100.00	99.97	100.00
150	98.98	99.50	99.32	99.74	99.82	99.89	99.97	100.00	100.00
160	98.90	99.13	99.63	99.42	99.76	99.84	99.89	99.97	100.00
170	98.45	99.05	99.19	99.68	99.55	99.87	99.87	99.95	99.97
180	98.13	98.55	99.16	99.32	99.79	99.66	99.92	99.87	99.97
190	97.92	98.32	98.63	99.24	99.40	99.84	99.79	99.92	99.87
200	97.00	97.95	98.34	98.66	99.32	99.47	99.84	99.82	99.92
210	95.43	97.03	98.03	98.48	98.77	99.34	99.47	99.84	99.82
220	94.43	95.48	97.06	98.11	98.50	98.92	99.34	99.47	99.87
230		94.43	95.48	97.08	98.19	98.53	99.03	99.40	99.53
240			94.43	95.48	97.11	98.21	98.53	99.08	99.47
250				94.46	95.51	97.16	98.27	98.55	99.08
260					94.48	95.56	97.16	98.37	98.58
270						94.48	95.56	97.16	98.40
280							94.51	95.64	97.21
290								94.5	95.66
300									94.53

F_2^c ölçütünü kullanarak sınıflar arası dağılımlarından elde edilen 250–310 özdeğere karşılık gelen altuzayda sınıf içi dağılımlara göre test kümesinin tanıma oranları Çizelge 7’de verilmektedir.

Çizelge 7. F_2^c ölçütüne göre test kümesinden elde edilen ortalama yüzde tanıma oranları.

Sınıf İçi Dağılım Özdeğer Sayısı	→ Sınıflar Arası Dağılım Özdeğer Sayısı						
	250	260	270	280	290	300	310
200	96.00	95.00	95.45	94.09	95.27	94.82	93.55
210	96.91	95.91	95.00	95.27	94.36	95.36	94.91
220	97.00	97.00	95.91	95.27	95.64	94.45	95.36
230	96.45	96.91	97.18	96.09	95.27	95.91	94.91
240	93.64	96.45	97.09	97.09	96.09	95.36	95.82
250	94.73	93.73	96.64	97.09	97.18	96.27	95.36
260		94.73	93.73	96.55	97.09	97.27	96.18
263			93.91	95.91	97.09	97.73	96.55
270			94.82	93.73	96.55	97.18	97.18
280				94.82	93.73	96.55	97.09
290					94.82	93.73	96.55
300						94.82	93.73
310							94.82

SONUÇLAR

Bu çalışmada, sadece sınıf içi dağılımlar göz önüne alınarak OVY kullanıldığında, eğitim kümesi için %100 ve test kümesi için %99.5 tanıma oranlarına ulaşılmıştır. Aynı veri tabanı (TI-Digit) için HMM kullanıldığında eğitim kümesi için %99.4 ve test kümesi için %97.27 tanıma oranlarına ulaşılması OVY'nin HMM ile karşılaştırılabilir sonuçlar verdiğini göstermektedir [33]. Sadece sınıflar arası dağılımlar göz önüne alındığında ise eğitim kümesi için %99.6 ve test kümesi için %98.1 tanıma oranlarına ulaşılması OVY'nin bu dağılım şekli için de kullanılabilir bir yöntem olduğunu göstermektedir.

Konuşmayı tanımada, sadece sınıf içi dağılımları veya sadece sınıflar dağılımları kullanan Temel Bileşen Analizi ve altuzay sınıflayıcıları ile istenilen başarımlar elde edilemeyebilir. Bu durum ile özellikle sınıf sayısı arttıkça karşılaştırılabilir. Dolayısıyla konuşmayı tanımada sınıf içi dağılımlarla beraber sınıflar arası dağılımların da göz önüne alınması gerekir.

Bu çalışmada FLDA ve OVY'nin, sınıf içi ve sınıflar arası dağılımların birlikte göz önüne alındığı durumdaki sınıflama performansı incelenmiş ve karşılaştırılmıştır. FLDA için en iyi sonuçlar, DUÇ yöntemi ile aynı boyda (330) çekilmiş öznitelik vektörleri için elde edilmiştir. Bu durumda eğitim kümesi için %97.6 ve test kümesi için %95.9 tanıma oranları elde edilmiştir. Bu oranlar, literatürde FLDA'nin ayırık kelime tanımada kullanılması ile elde edilen oranlardan [2,18] biraz daha yüksektir. Her sınıf için; sınıf içi dağılımlardan ayrı, sınıflar arası dağılımlardan ayrı altuzaylar bulunup, bu altuzaylardan elde edilen tanıma oranları “borda-count” yöntemi ile birleştirildiğinde eğitim kümesi için %98.32 ve test kümesi için %97.36 tanıma oranları elde edilmiştir. Fakat sadece sınıf içi dağılımlar kullanıldığında daha iyi tanıma oranlarının elde edilmesi, sınıflar arası dağılımlara bakmanın gereksiz olduğunu veya FLDA'deki gibi göz önüne alınmasının yanlış olduğunu göstermektedir.

Hem sınıf içi hem sınıflar arası dağılımlar göz önüne alınarak OVY kullanıldığında en iyi sonuçlar, geliştirilmiş olan sınıf içi-sınıflar arası en iyileme ölçütü F_1^c için elde edilmiştir. Bu durumda eğitim kümesi için tanımlanan yeni farklılık altuzayında sadece en büyük özdeğere karşılık gelen özvektör kullanıldığında %100 tanıma oranı elde edilmiştir. Test kümesi için yine yeni tanımlanan altuzayda en büyük 73 özdeğere karşılık gelen özvektörler kullanıldığında %98.73 tanıma oranı elde edilmiştir.


Sonuç olarak hem FLDA, hem de OVY kullanılarak daha önce elde edilen tanıma oranlarında iyileştirmeler sağlanmıştır. İyileşme sağlanmadığı durumlarda ise, daha az özvektör kullanılarak aynı tanıma oranlarına ulaşılması da avantaj getirmektedir. Böylece proje başlangıcında amaçlanan hedeflere ulaşılmıştır. Çünkü eğitim kümesi için %100 ve test kümesi için %99.5 tanıma oranları oldukça yüksektir. Bu sonuçlar, tanıma algoritmalarının ticari amaçla kullanılması yönündeki çalışmalarımıza önemli bir destek sağlayacaktır.

Sınıf sayısının daha fazla olduğu ayırık kelime veri tabanları için FLDA'nin ve OVY'nin sınıflamadaki performansları daha net karşılaştırılabilir. Bu konu üzerinde çalışmalara devam edilmektedir.


TARTIŞMA

Geliştirilen sınıf içi-sınıflar arası en iyileme ölçütü F_1^c ile dikkat çekici bir sonuç elde edilmiştir. F_1^c ölçütünün sınıf içi ve sınıflar arası dağılımları kullanıldığından daha az boyutlu altuzaylarda hem eğitim hem de test kümesi için OVY’de elde edilen tanıma oranlarına yakın oranlar elde edilmektedir. Bu sonuç, çoklu sınıf problemlerinde, sınıf içi ve sınıflar arası dağılımların kullanılması gerektiğini göstermektedir. F_1^c ölçütü için sınıflar arası dağılımlardan elde edilen en büyük özdeğere karşılık gelen özvektör kullanılarak eğitim kümesi için %100 tanıma oranı elde edilmektedir. OVY’de bu tanıma oranına sınıf içi dağılımlardan elde edilen en küçük ilk üç özdeğer kullanılarak ulaşılmaktadır. Altuzay boyutundaki esas iyileşme test kümesinden elde edilen sonuçlarda görülmektedir. F_1^c ölçütünde sınıflar arası dağılımların en büyük 73 özdeğeri için test kümesinden elde edilen tanıma oranları, OVY’de sınıf içi dağılımların en küçük 309 özdeğeri için elde edilmektedir. Bu sonuç bize iki ölçüt arasındaki boyut indirgeme farkını göstermektedir. F_1^c ölçütü özellikle altuzay tekniği kullanılan ayrık kelime tanıyıcısı geliştirmede işlem zamanı ve bellek ihtiyacı açısından kolaylıklar sağlayacaktır.


F_1^c ölçütü kullanıldığında eğitim kümesinde sınıfların iki boyutlu altuzayda nasıl dağıldıkları Şekil 1’de gösterilmektedir. Şekil 1(a-f), altı sınıf için, sınıf içi dağılımlardan elde edilen altuzayda sınıflar arası dağılımlardan elde edilen en büyük iki özdeğere karşılık gelen özvektörlerin gerdiği altuzaylarda bütün sınıfların dağılımını göstermektedir. Şekil 1(a-f)’de kare sembolü () bir sınıfa ait altuzayda izdüşüm alınmış öznitelik vektörlerini, yıldız sembolü (*) ise geri kalan 10 sınıfa ait öznitelik vektörlerinin izdüşümlerini göstermektedir. Şekillerde, iki boyutlu uzayda bir sınıf ve geri kalan 10 sınıfın kolaylıkla ayırt edilebildiği görülmektedir. Sınıfların kolaylıkla ayırt edilebildikleri, bir boyutlu altuzayda da gösterilebilir.




a) “one” () ve diğerleri (*)




b) “two” () ve diğerleri (*)




c) “five” () ve diğerleri (*)



d) “six” () ve diğerleri (*)



e) “nine” () ve diğerleri (*)



f) “zero” () ve diğerleri (*)

Şekil 1. F_1^c ölçütünden elde edilen iki boyutlu altuzayda sınıfların dağılımı

KAYNAKLAR

- [1] Bates J.R., Gregory D.W., Voice and Data Communication Handbook, McGraw-Hill, New York, 1998, p. 193
- [2] Yong X., Jing-Yu Y., Zhong J., “A Novel Method for Fisher Discriminant Analysis”, The Journal of The Pattern Recognition Society, Vol.37, pp. 381-384, 2004.
- [3] Zivogovic V., Noll D., “Minimum Fisher Information Spectral Analysis”, ICASSP, Munich, Germany, (1997), pp. 3957-3960.
- [4] Petek B., Ferligoj A., “Exploiting Prediction Error In a Predictive-Based Connectionist Speech Recognition System”, ICASSP, Minneapolis, Minnesota, (1993), pp. 267-270.
- [5] Healey J., Picard R., “Digital Processing of Affective Signals”, ICASSP, Seattle, Washington, (1998), pp.2285-2288.
- [6] Bauer J., “Enhanced Control and Estimation of Parameters for a Telephone-Based Isolated Digit Recognizer”, ICASSP, Munich, Germany, (1997), pp. 1531-1534.
- [7] Aubert X., Haeb-Umbach R., Ney H., “Continuous Mixture Densities And Linear Discriminant Analysis For Improved Context-Dependent Acoustic Models”, ICASSP, Minneapolis, Minnesota, (1993), pp. 648-651.
- [8] Principe J.C., Xu D., Wang C., “Generalized Oja’s Rule For Linear Discriminant Analysis With Fisher Criterion”, ICASSP, Munich, Germany, (1997), pp.3401-3404.
- [9] Lieb M, Haeb-Umbach R., “ LDA Derived Cepstral Trajectory Filters In Adverse Environmental Conditions”, ICASSP, Istanbul, Türkiye, (2000), pp. 1671-1674.
- [10] Poston W.L., Marchette D.J., “Recursive Dimensionality Reduction Using Fisher’s Linear Discriminant”, The Journal of The Pattern Recognition Society, Vol.31, No.7, pp. 881-888, 1998.
- [11] Dolfing D.G.A, Haeb-Umbach R., “Signal Representations for Hidden Markov Model Based On-Line Handwritting Recognition”, ICASSP, Munich, Germany, (1997), pp. 3385-3388.
- [12] Sukkar R.A, Wilpon J.G., “A Two Pass Classifier For Utterance Rejection In Keyword Spotting”, ICASSP, Minneapolis, Minnesota, (1993), pp. 451-454.
- [13] Hauenstien A., Marschall E., “Methods For Improved Speech Recognition Over Telephone Lines”, ICASSP, Detroit, Michigan, (1995), pp. 425-428.
- [14] Thomae M, Ruske G., Pfau T., “ A New Approach To Discriminative Feature Extraction Using Model Transformation”, ICASSP, Istanbul, Türkiye, (2000), pp. 987-990.
- [15] Raudys S., Duin P.W., “Expected Classification Error of the Fisher Linear Classifier with Pseudo-Inverse Covariance Matrix”, Pattern Recognition Letters, Vol. 19, pp. 385-392, 1998.

- [16] Jing Y., Zhang D., Yao Y., “Improvements on The Linear Discrimination Technique with Application to Face Recognition”, Pattern Recognition Letters, Vol. 24, pp. 2695-2701, 2003.
- [17] Nomiya H., Uehara K., “Improvement of Linear Discriminant Analysis by Applying The Ensemble Method ”, IPSJ SIGNotes Mathematical modeling and Problem Solving, No.046
- [18] Yang J., Yang J-Y., Zhang D., “What’s Wrong with Fisher Criterion”, The Journal of The Pattern Recognition Society, Vol.35, pp. 2665-2668, 2002.
- [19] Xu Y., Yang J-Y., Jin Z., “Theory Analysis on FSLDA and ULDA”, The Journal of The Pattern Recognition Society, Vol.36, pp. 3031-3033, 2003.
- [20] Gülmezoğlu M. B., Dzhafarov V., Barkana A., “Ortak Vektör Yaklaşımı ile Önemli Bileşen Analizi Arasındaki Çelişki”, 6. Sinyal İşleme ve Uygulamaları Kurultayı, Kızılcabamam, pp. 290-295, 1998.
- [21] Gülmezoğlu, M.B., Dzhafarov, V., Barkana, A., “The Common Vector Approach and Its Relation to the Principal Component Analysis”, IEEE Trans. on Speech and Audio Processing, Vol. 9, pp. 655-662, 2001.
- [22] Gülmezoğlu M.B., 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.
- [23] Gülmezoğlu, M.B., Dzhafarov, V., Barkana, A., “Eğitim Kümesinde Yeterli Veri Olduğunda Ortak Vektör Yaklaşımının Diğer Altuzay Yöntemleri ile Karşılaştırılması”, 8. Sinyal İşleme ve Uygulamaları Kurultayı, Belek, pp. 13-18, 2000.
- [24] Gülmezoğlu, M.B., Dzhafarov, V., Edizkan R., Barkana, A., “Ses Tanıma İçin Ortak Vektör Yaklaşımı: Çoklu Sınıf Problemi”, 8. Sinyal İşleme ve Uygulamaları Kurultayı, Belek, pp. 19-24, 2000.
- [25] Gülmezoğlu, M.B., Dzhafarov, V., Edizkan R., 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), Bursa, pp. 117-121, 2001.
- [26] Cawley G.C, Talbot N.L.C , “Efficient leave-one-out cross-validation of kernel Fisher discriminant classifier”, Pattern Recognition, Vol. 36, pp. 2585-2592, 2003.
- [27] Bishop, C.M., Neural Networks for Pattern Recognition, 1st ed., Clarendon Press, Oxford, 1995.
- [28] Loog, M., Duin, R.P.W., Haeb-Umbach, R., “Multi-Class Linear Dimension Reduction by Weighted Pairwise Fisher Criteria”, IEEE Trans. on Pattern Analysis and Machine Intelligence, Vol. 23, pp. 762-766, 2001.

- [29] Loog, M., Haeb-Umbach, R., “Multi-Class Linear Dimension Reduction by Generalized Fisher Criteria”, Proc. Int. Conf. On Spoken Language Processing, pp. 1069-1072, 2000.
- [30] Saon, G., Padmanabhan, M., Gopinath, R., “ Maximum Likelihood Discriminant Feature Spaces”, Proc. IEEE Int Conf. Acoust. Speech, Signal Processing, pp. 1747-1750, 2000.
- [31] Ho T.K., Hull J.J., Srihari S. N., “Decision Combination in Multiple Classifier Systems”, IEEE Trans. on Pattern Analysis and Machine Intelligence, Vol. 16, pp. 66-75, 1994.
- [32] Black D., The Theory of Committees and Elections, 2nd ed., Cambridge University Press, London, 1963.
- [33] Edizkan R., Barkana A., “Yalıtık Kelime Tanımada Altuzay Yöntemleri ile Gizli Markov Modelin Çeşitli Yönlerden Karşılaştırılması”, 8. Sinyal İşleme ve Uygulamaları Kurultayı, Belek, pp. 1-6, 2000.

EK-I

PROJE DESTEĞİ	:	30.465.000.000 TL
HARCANAN MİKTAR	:	18.986.200.000 TL
EK DESTEK	:	

PROJE KAPSAMINDA ALINAN CİHAZ VE DEMİRBAŞLAR:

No	Adı	Markası	Yeri
1	3 Adet Tip 1 Bilgisayar	P4 3.0 GHz.	OGÜ MMF Elek.-Elektro. Müh. İşaret İşleme Lab.
2	1 Adet Tip 1 Sunucu	IBM	OGÜ MMF Elek.-Elektro. Müh. İşaret İşleme Lab.
3	1 Adet Tip 1 Yazıcı	HP	OGÜ MMF Elek.-Elektro. Müh. İşaret İşleme Lab.
4	1 Adet Tip 1 Kesintisiz Güç Kaynağı	ENEL	OGÜ MMF Elek.-Elektro. Müh. İşaret İşleme Lab.