

**YEREL ZERNİKE MOMENTLERİ VE
METRİK ÖĞRENME YÖNTEMLERİYLE
YÜZ ÇİFTİ EŞLEME**

YÜKSEK LİSANS TEZİ

Şeref Emre KAHRAMAN

Bilgisayar Mühendisliği Anabilim Dalı

Bilgisayar Mühendisliği Programı

OCAK 2015

**YEREL ZERNİKE MOMENTLERİ VE
METRİK ÖĞRENME YÖNTEMLERİYLE
YÜZ ÇİFTİ EŞLEME**

YÜKSEK LİSANS TEZİ

**Şeref Emre KAHRAMAN
(504111531)**

Bilgisayar Mühendisliği Anabilim Dalı

Bilgisayar Mühendisliği Programı

Tez Danışmanı: Prof. Dr. Muhittin GÖKMEN

OCAK 2015

İTÜ, Fen Bilimleri Enstitüsü'nün 504111531 numaralı Yüksek Lisans Öğrencisi **Şeref Emre KAHRAMAN**, ilgili yönetmeliklerin belirlediği gerekli tüm şartları yerine getirdikten sonra hazırladığı “**YEREL ZERNİKE MOMENTLERİ VE METRİK ÖĞRENME YÖNTEMLERİYLE YÜZ ÇİFTİ EŞLEME**” başlıklı tezini aşağıdaki imzaları olan jüri önünde başarı ile sunmuştur.

Tez Danışmanı : **Prof. Dr. Muhittin GÖKMEN**
İstanbul Teknik Üniversitesi

Jüri Üyeleri : **Doç. Dr. Hazım Kemal EKENEL**
İstanbul Teknik Üniversitesi

Yrd. Doç. Dr. Serap KIRBIZ
MEF Üniversitesi

.....

Teslim Tarihi : **15 Aralık 2014**

Savunma Tarihi : **26 Ocak 2015**

Aileme,

ÖNSÖZ

Tez sürecim boyunca bilgi ve tecrübelerini benden esirgemeyen değerli danışman hocam Sayın Prof. Dr. Muhittin Gökmen’e teşekkür ederim.

Bugüne kadar maddi manevi her anlamda yanımda olup, benden desteğini hiç esirgemeyen aileme teşekkür ederim.

112E201 numaralı projesine verdiği finansal destekten ötürü TÜBİTAK’a teşekkürlerimi sunarım.

OCAK 2015

Şeref Emre KAHRAMAN
Bilgisayar Mühendisi

İÇİNDEKİLER

Sayfa

ÖNSÖZ	vii
İÇİNDEKİLER	ix
KISALTMALAR.....	xi
ÇİZELGE LİSTESİ.....	xiii
ŞEKİL LİSTESİ.....	xv
ÖZET	xvii
SUMMARY	xix
1. GİRİŞ.....	1
1.1 Tezin Amacı.....	2
1.2 Literatür Araştırması	2
1.3 Tezin Organizasyonu	4
2. ÖZNİTELİK ÇIKARMA YÖNTEMLERİ.....	5
2.1 Yerel Zernike Momentleri	5
2.1.1 Yerel Zernike Momentleri dönüşümü.....	6
2.1.2 Yerel Zernike Momentleri öznitelik vektörü oluşturulması	9
2.2 Yerel İkili Örüntüler	10
3. BOYUT İNDİRGEME YÖNTEMLERİ.....	13
3.1 Temel Bileşenler Analizi	13
3.1.1 Temel Bileşenlerin Hesaplanması	13
4. METRİK ÖĞRENME YÖNTEMLERİ.....	15
4.1 L2-Norm Metrik Öğrenme	15
4.2 Eşitlik Kısıtları ile Geniş Ölçekte Metrik Öğrenme	18
5. SINIFLANDIRMA YÖNTEMLERİ.....	21
5.1 k-En Yakın Komşuluk	21
5.2 Uzaklık Ölçütleri	22
6. DENEYSEL ÇALIŞMALAR	23
6.1 Kullanılan Veritabanı.....	23
6.2 İmgeler Üzerinde Yapılan Ön İşlemler.....	25
6.3 Öznitelik Vektörlerinin Hazırlanması.....	26
6.3.1 Yerel Zernike Momentleri	26
6.3.2 Yerel İkili Örüntüler	28
6.4 Öznitelik Vektörlerinin Boyutlarının İndirgenmesi.....	29
6.5 Metrik Öğrenme	30
6.5.1 L2-Norm Metrik Öğrenme	31
6.5.2 Eşitlik Kısıtları ile Geniş Ölçekte Metrik Öğrenme	35
7. SONUÇ VE ÖNERİLER	39

KAYNAKLAR.....	43
ÖZGEÇMİŞ	45

KISALTMALAR

FGH	: Faz Genlik Histogramları
GYİÖ	: Genişletilmiş Yerel İkili Örüntü
ITML	: Information Theoretic Metric Learning
LARK	: Locally Adapted Regression Kernels
LFW	: Labeled Faces in the Wild imge veritabanı
LDML	: Logistic Discriminant Metric Learning
LMMN	: Large Margin Nearest Neighbor Learning
LSML	: Large Scale Metric Learning from Equivalence Constraints
L2ML	: L2-Norm Metric Learning
SIFT	: Scale Invariant Feature Transform
TYİÖ	: Tekdüze Yerel İkili Örüntü
TBA	: Temel Bileşenler Analizi
YÇE	: Yüz Çifti Eşleme
YİÖ	: Yerel İkili Örüntü
YZM	: Yerel Zernike Momentleri
ZM	: Zernike Momentleri

ÇİZELGE LİSTESİ

Sayfa

Çizelge 2.1: YZM'nin literatürdeki diğer yöntemlerle karşılaştırılması [1]	5
Çizelge 4.1: Karşılaştırılan yöntemlerin işlem zamanları [2]	20
Çizelge 6.1: İmgelerin ayrıştırmasının başarıma etkisi	26
Çizelge 6.2: YZM dönüşümünde k ve n değerlerinin başarıma etkisi	27
Çizelge 6.3: YZM dönüşümünde blok sayısının başarıma etkisi	27
Çizelge 6.4: YZM ve $\sqrt{YZM}$ yöntemlerinin başarımları	28
Çizelge 6.5: TYİÖ yönteminde blok sayısının başarıma etkisi	28
Çizelge 6.6: TYİÖ ve $\sqrt{TYIO}$ yöntemlerinin başarımları	29
Çizelge 6.7: YZM vektörlerinin TBA ile boyut indirgeme başarımları	30
Çizelge 6.8: TYİÖ vektörlerinin TBA ile boyut indirgeme başarımları [11]	30
Çizelge 6.9: L2ML uzayında k parametresinin başarıma etkisi	32
Çizelge 6.10: Farklı YZM vektörleri ile elde edilen başarımlar	33
Çizelge 6.11: Kosinüs ve L2 uzaklık ölçütlerinin başarımlara etkisi	33
Çizelge 6.12: YTIÖ ve hibrit yöntemin başarımları	34
Çizelge 6.13: Elde edilen L2ML başarımların literatürdeki sonuçlarla karşılaştırılması	34
Çizelge 6.14: Farklı YZM vektörleri ile elde edilen LSML başarımları	36
Çizelge 6.15: Elde edilen LSML başarımların literatürdeki sonuçlarla karşılaştırılması	37

ŞEKİL LİSTESİ

	<u>Sayfa</u>
Şekil 2.1 : YZM çekirdeklerin imge üzerinde kaydırılması.....	7
Şekil 2.2 : $k = 9$ için elde edilen çekirdeklerinden ilk 8 tanesinin a) gerçel bileşenleri b) sanal bileşenleri [1]	8
Şekil 2.3 : YZM yönteminin giriş görüntüsüne uygulanması [1]	9
Şekil 2.4 : Temel YİÖ operatörü.....	10
Şekil 2.5 : (8,2) gösterimi için çembersel komşuluk [5].....	11
Şekil 5.1 : $k = 3$ için k-En Yakın Komşuluk yönteminin gösterimi	21
Şekil 6.1 : LFW veritabanındaki örnek yüz imgelerinden a) eş olanlar b) eş olmayanlar.....	24
Şekil 6.2 : Kesilmiş ve hizalanmış yüz imgeleri	25

YEREL ZERNİKE MOMENTLERİ VE METRİK ÖĞRENME YÖNTEMLERİYLE YÜZ ÇİFTİ EŞLEME

ÖZET

Tarihin ilk zamanlarından beri insanlar iletişim ve etkileşim halinde bulundukları diğer insanları birbirlerinden ayırt edebilmek ve kimliklerini tespit edebilmek için yüzlerini tanımakta ve bu bilgiyi hafızalarında tutmaktadır. İnsan vücudunda kendisinin başkalarından ayırt edilebilmesini sağlayan parmak izi vb. pek çok biyometrik ölçüt bulunmaktadır. Ancak bu ölçütlerin hiçbirisi yüz bilgisi gibi günlük hayatta kolaylıkla kullanılabilecek nitelikte değildir. Günümüzde bilgisayar teknolojisinin gelişmesi ve yaygınlaşması ile dünyadaki ilk insanlardan beri her zaman popüler olan yüz tanıma problemi, akademik ve ticari olarak da önemli araştırma geliştirme konularından birisi haline gelmiştir. Günümüzde ulusal ve özel güvenlikten, hizmet kalitesini arttırmak amaçlı müşteri sadakati sistemlerine kadar pek çok alanda yüz tanıma uygulamaları aktif olarak kullanılmaktadır.

Yüz çifti eşleme (YÇE) problemi, yüz tanıma araştırma alanının önemli alt başlıklarından birisidir. Yüz çifti eşlemenin amacı imgelerdeki kişilerin kimlik tespiti (ing. *identification*) değil, imgelerdeki yüzlerin aynı kişiye mi yoksa farklı kişilere mi ait olduğu bilgisini elde etmektir. İki ayrı yüz imgesi, eğer aynı kişiye ait ise eşleşmiş (ing. *match*), eğer farklı kişilere ait ise eşleşmemiş (ing. *mismatch*) olarak nitelendirilir. Bu değerli bilgi kısıtlandırılmış bölgelere giriş/çıkış kontrolü, kriminal vakalardaki kamera kayıtlarının analiz edilmesi gibi pek çok alanda kullanılmaktadır.

YÇE alanındaki çalışmalar genellikle üç ana aşamadan oluşmaktadır. İlk adımda imgelerdeki yüzlerin yerleri bulunmakta, bulunan yüzler hizalanmakta ve kesilmektedir. Böylelikle yüzler sonraki işlemlere hazır hale getirilmektedir. İkinci adımda kesilen bu yüzlerin farklı yöntemlerle öznitelik vektörleri çıkartılmaktadır. Son olarak da çıkartılan bu öznitelik vektörleri çeşitli şekillerde yorumlanarak amaca uygun şekilde sınıflandırılmaktadır. Bu çalışmada problemin ikinci ve üçüncü aşaması üzerinde çalışmalar yapılmıştır.

Tez çalışmasında öznitelik çıkartma yöntemi olarak Yerel Zernike Momentleri (YZM) kullanılmıştır. Zernike Momentleri(ZM) imgenin bütününde hesaplanmakta ve karakter tanıma gibi konularda başarılı sonuçlar vermektedir. Ancak, ZM yüz tanıma gibi imgenin şekilden çok desen bilgisinin önemli olduğu konularda aynı oranda başarılı değildir. Bu nedenle momentlerin bütün imge üzerinde hesaplanması yerine her gözek ve komşuları etrafında yerel olarak hesaplanması prensibine dayalı yeni bir yüz gösterimi olan YZM yöntemi kullanılmıştır. Daha önce yüz imgelerinden kimlik tespiti alanında Yerel İkili Örüntü (ing. *Local Binary Patterns*) ve Gabor gibi yöntemlerden daha başarılı sonuçlar veren YZM yönteminin, yüz çifti eşleme probleminde de başarıyla kullanılabileceğini göstermek tezin amaçlarından birisidir.

YZM yönteminde giriş imgesinden moment derecesi parametresine göre farklı sayılarda gerçel ve sanal kısımlardan oluşan (karmaşık) imgeler oluşturulur, öznitelik

çıkartma işlemi sırasında da bu imgeler kullanılır. Seçilen parametrelere göre öznitelik vektörünün uzunluğu değişebilmekte ve yüksek boyutlara ulaşabilmektedir. İşlem kolaylığı ve gerçek zamanlı uygulamalarda kullanılabilirliği sağlamak için YZM öznitelikleri boyut indirgeme işlemine tabii tutulmaktadır. Temel Bileşenler Analizi (TBA)(ing. *PCA*) yöntemi sayesinde vektörler veri çeşitliliğini çok fazla kaybetmeden daha düşük boyutlara indirgenmektedir.

Tez çalışmasında boyutları indirgenen YZM vektörleri sınıflandırma işlemi öncesinde daha ayırıcı hale gelebilmeleri için metrik öğrenme yöntemleri kullanılarak yeni bir uzaya taşınmaktadır. Bu yöntemde öncelikle eğitim aşamasında eş ve eş olmayan şeklinde iki ayrı sınıfta etiketlenmiş olan YZM vektör çiftleri kullanılarak istatistiksel çıkarımlar sonucunda dönüşüm matrisleri hesaplanmaktadır. Yöntem sonucunda öğrenilen bu dönüşüm matrisleri test aşamasında YZM vektör çiftleri ile çarpılmakta ve vektörler boyut değiştirmekte ve daha ayırıcı hale gelmektedir. Yapılan çalışmalara göre öznitelik vektörleri metrik öğrenme yöntemleri ile birlikte kullanıldıklarında ortalama %6 – 8 başarımlar artışı sağlanmaktadır. Çalışmada metrik öğrenme yöntemi olarak L2-Norm Metrik öğrenme ve Eşitlik Kısıtları ile Geniş Ölçekte Metrik öğrenme yöntemleri kullanılmaktadır.

Tez kapsamında yapılan çalışmaların ve geliştirilen yöntemlerin test edilebilmesi için internetteki haber görüntüleri kullanılarak oluşturulmuş Labeled Faces in the Wild (LFW) veritabanı kullanılmıştır. 5749 farklı kişiye ait toplam 13233 adet görüntüden oluşan bu veritabanı kontrolsüz ortamlardan toplanmış imgelerden oluşmakta ve farklı poz, açı, yaş ve aydınlatma gibi değişimler içermektedir. LFW veritabanının yüz çifti eşleme problemi için belirlediği bir başarımlar ölçme protokolü bulunmaktadır. Eş ve eş olmayan 6000 adet yüz çifti belirlenmiş, bunlar 10 grupta (ing. *fold*) toplanmıştır. Çapraz doğrulama (ing. *cross validation*) yöntemi ile bu 10 grup kullanılarak başarımlar hesaplanmaktadır.

LFW veritabanının YÇE problemlerinde yaygın olarak kullanılması ve başarımlar hesaplarının sabit bir protokol üzerinden gerçekleştirilmesi, testler sırasında bu veritabanının seçilmesini sağlamıştır. Bu sayede çalışma sonucunda elde edilen başarımlar aynı giriş imgeleri üzerinde ve aynı protokol ile elde edildiğinden karşılaştırma sonuçları daha anlamlı hale gelmektedir.

Hesaplanan, boyutları indirgenen ve metrik öğrenme yöntemleri ile dönüştürülen vektörlerin, LFW veritabanının başarımlar protokolüne uygun şekilde sınıflandırılmasında k-en yakın komşuluk yöntemi kullanılmaktadır. Eş ve eş olmayan şeklinde iki adet sınıf barındıran bu işlemde eğitim aşamasında sabit bir eşik değeri hesaplanmaktadır. Test aşamasında ise birbirlerine bu değerden daha yakın olan yüz çiftleri eş, diğerleri ise eş olmayan şeklinde sınıflandırılmaktadır. Vektörlerin birbirleri ile arasındaki uzaklığın hesabında L1 Norm, L2 Norm, Mahalanobis ve Kosinüs gibi farklı uzaklık ölçüm metrikleri kullanılmıştır.

FACE PAIR MATCHING WITH LOCAL ZERNIKE MOMENTS AND METRIC LEARNING METHODS

SUMMARY

Since ancient times, human face is used to be one of the most widely used biometrics of human's identity. People have been labeling each other, who are interacted with, by facial appearance. We are still storing other people's faces in our minds to recognize them. There are several biometric identities in human body such as finger print, eyes etc. , but most of them is not suitable to recognize other people in daily lives, except face. With the development of computer technologies and increase in power of microprocessors, applications of face recognition are becoming widespread day by day. There are lots of computer scientist who are interested in face recognition phenomenon. Governments and companies are investing huge amount of money on researching and development of face recognition applications in wide areas such as national security, customer loyalty systems.

Face recognition is an application area for automatically identifying or verifying a person from a digital image or a video frame from a video source. Some conditions where face recognition does not work well include poor lighting, sunglasses, long hair, or other objects partially covering the subject's face, and low resolution images. Algorithms about face recognition problems must prove their durability to these negative conditions.

Face pair matching is one the most important subtopics in face recognition problem. It is a binary classification problem which is deciding whether or not two face images belong to the same person. Two face images are labeled as match if they belong to same person, otherwise labeled as mismatch. Results of a pair matching algorithm provide very useful information to specific applications like verification access control of restricted areas or grouping the unknown people's faces in an image gallery.

There are many studies about face pair matching problem and they generally consist of three main steps.

First step is detecting the faces and important face features such as eyes, mouth, nose etc. These face landmark points provide very important preprocessing on faces called alignment. Face alignment tries to align faces such that they are closed to a common or specified pose of face as much as possible. Aligned faces are then cropped from whole image rectangular shape and become face images. By the help of these preprocessing phases on face images, faces become ready to next stages.

Second step is feature extraction of these cropped face images. There are lots of feature extraction method successfully give solid performance on face recognition step. Local Binary Patterns (LBP), Gabor Wavelets and Scale Invariant Feature Transform (SIFT) methods are the most commonly used algorithms. Any of these algorithms generate some numeric values from face images and they called as feature vectors.

Feature vectors represent the face image in mathematical space, so faces are become comparable with each other.

Finally, third step is classification process. The classifier is trained on the match and mismatch example face images so that it learns the decision boundary between these two classes. After that it uses what it learn to make a decision on the given face images. Faces are labeled as match or mismatch. There is a variety of ways in classification step, such as; Nearest Neighborhood, Support Vector Machines etc.

In this project, main contribution is focused on second and mostly third stages. Faces are aligned and cropped in rectangular shape by using landmarks from annotation file of image database. After these preprocessing, cropped faces are applied to masking with an ellipse shape mask just like human faces. By the help of this masking, effects of the information on image background are completely eliminated. There is a final operation on face images, called light normalization which is a process that changes the range of pixel intensity values. It increases the contrast of images and decrease the effect of luminance, so images become visually more clear.

In this thesis, Local Zernike Moments (LZM) method is used as feature extraction method. Zernike Moments (ZM) is a feature extraction method that computes complex moments coefficients from all around of image. ZM has a solid performance while using in shape based problems like fingerprint or character recognition, but not inadequate for much more texture based problems like face recognition. Therefore, LZM, a novel face representation method is purposed to use. LZM calculates complex coefficients locally, around the neighborhood of each pixel on image, not globally.

Previous works show that LZM is as successful as famous rival methods such as Local Binary Patterns or Gabor Wavelets on face identification problem. Showing that whether or not LZM may be successful in face pair matching problem similar to face recognition is one of the main goals in thesis.

In LZM method, each moment component produces new complex face images, including real and imaginary parts, from input image. These images are separated into overlapping blocks because of keeping the spatial information. Final feature vector is obtained by concentration of each complex image's phase/magnitude histograms for each block. To sum up, length of the feature vector depends on how many moment component is generated and how many block is chosen. So, feature vector may have high dimensions in case of setting these parameters high. It is a fact that processing these high dimension vectors is hard ,so in order to reducing the processing time, dimension reduction of feature vectors process is necessary. Principal Component Analysis (PCA) is used for this purpose.

Principal Component Analysis is a statistical analytical method that is used to explore, sort and group data. What PCA does is take a large number of correlated (interrelated) variables and transform this data into a smaller number of uncorrelated variables (principal components) while retaining maximal amount of variation, thus making it easier to operate the data and make predictions. By the help of PCA, dimension of vectors is decreasing without losing any data variety.

After dimension reduction process, there is another step called metric learning which is used for increasing the discrimination power of feature vectors. In metric learning algorithms, generally a transform matrix is calculated in training stage using vector couples dubbed as match/mismatch by solving a minimizing problem of matching and

a maximizing problem of mismatching class distances. In order to apply the metric learning algorithm, transform matrix generated in training stage is multiplied to feature vectors. According to tests, using these statistic based metric learning algorithms on feature vector increase the matching performance by 6 – 8%.

In this thesis, there are two metric learning algorithm is used for increasing the discrimination of feature vectors . First algorithm is L2-Norm Metric Learning. This method differs from other similar approaches by giving an efficient closedform solution to a relatively simple optimization objective. It aims to find a transformation matrix that minimizing the distances of matching vectors while maximizing the mismatching pairs distances. The second metric learning algorithm, used in thesis, is Large Scale Metric Learning from Equivalence Constraints algorithm. This method introduces a simple though effective strategy to learn a distance metric from equivalence constraints, based on a statistical inference perspective. In contrast to existing methods it does not rely on complex optimization problems requiring computationally expensive iterations.

Showing that whether or not using LZM feature vectors in these two metric learning spaces has better recognition performance than using them in normal space is another main goal in thesis.

Labeled Faces in the Wild (LFW) image data set is used for benchmarking tests in this work. LFW is a database of face photographs designed for studying the problem of unconstrained face recognition. The data set contains more than 13233 images from 5749 person. Face images of LFW are collected from the Yahoo News website, so images have all of the pose, illumination, angle and aging varieties due to be taken from uncontrolled environment.

LFW has two benchmark principles which are restricted and unrestricted settings. In unrestricted setting, people may generate another face pairs from given pairs by transitive relation rule. But in restricted setting, it is not allowed to change given face pairs, on the contrary unrestricted setting. In these thesis restricted setting paradigm is used because in restricted setting, all tests must run according to same benchmarking rule. 6000 face image pairs are chosen and they are divided into ten folds in restricted settings of LFW. Each fold has 300 match and 300 mismatch face pairs. Therefore, success rate of workings are calculated by using cross validation method as suggested.

For classification step, k-Nearest Neighborhood method is used in thesis. L1, L2, Mahalanobis and Cosine distance metrics are used for calculating distances of feature vectors belongs to images. In training stage, a threshold that classifies the face pairs is learning. After applying all algorithms to the input image pairs, according to comparison between threshold and distances of the feature vectors decide whether they are match or mismatch images.

1. GİRİŞ

Yüz tanıma konusu, uzun yıllardır bilgisayarla görü alanında çalışan bilim insanlarının ilgisini çeken, popüler bir araştırma alanıdır. Özellikle son yıllarda teknolojinin gelişmesi, MOBESE gibi kapalı devre kameraları ile izleme sistemlerinin ülke genelinde yaygınlaşması sayesinde pek çok yüz tanıma uygulama alanı ortaya çıkmıştır. Yüz tanıma uygulamaları ulusal ve özel güvenlik, giriş çıkış kontrolleri ve kriminal analizler gibi pek çok alanda aktif olarak kullanılmaktadır. Bilgisayarlar daha yüksek hesaplama gücüne eriştikçe, daha karmaşık ve yüksek başarımlı yüz tanıma sistemleri geliştirilmeye devam edecektir.

Yüz çifti eşleme (YÇE) konusu, yüz tanıma alanının önemli alt başlıklarından bir tanesidir [4]. Problemin amacı iki ayrı yüz imgesi verildiğinde, bu iki imgenin aynı kişiye mi yoksa farklı kişilere mi ait olduğu kararının verilmesidir. Kişinin kimliğinin belirlenmesi işleminin uygulanamadığı durumlara çözüm arayan bu konunun, kontrollü alanlara yetkili giriş/çıkış vb. pek çok uygulama alanı bulunmaktadır.

Diğer yüz tanıma problemlerinde olduğu gibi YÇE konusunda da çevre şartları, kamera görüntüsü gibi dış etkenlerden kaynaklanan zorluklar bulunmaktadır. Bu zorlukların başlıcaları şu şekilde sıralanabilir.

- Düşük görüntü kalitesi, düşük çözünürlük,
- Farklı kamera açısı ve poz değişimleri,
- Işıklandırma değişimleri ve gölgeler

Geliştirilmiş yüz tanıma yöntemleri incelendiğinde çalışmaların genel olarak üç ana aşamadan meydana geldiği görülmektedir. İlk aşamada imgelerdeki yüzler tespit edilmekte, bulunan yüzler hizalanmakta ve kesilmektedir. İkinci aşamada kesilen bu yüzlerin farklı yöntemlerle öznitelik vektörleri çıkartılmaktadır. Son olarak üçüncü aşamada çıkartılan bu öznitelik vektörleri amaca uygun şekilde sınıflandırılmaktadır.

1.1 Tezin Amacı

Tez çalışması, bir yüz imge çiftinin aynı kişiye mi (ing. *match*) yoksa farklı kişiye mi (ing. *mismatch*) ait olduğu bilgisini veren yüz çifti eşleme (YÇE) problemi için Yerel Zernike Momentleri (YZM) yönteminin kullanılmasını önermektedir. Daha önceki çalışmalarda yüz imgeleri kullanarak kişinin kimliğinin tespit edilmesi konusunda başarılı sonuçlar veren YZM yönteminin, YÇE probleminde de kullanılabileceğinin gösterilmesi amaçlanmıştır.

İkinci olarak, YZM yöntemi kullanılarak elde edilen öznitelik vektörlerinin doğrudan sınıflandırma işlemlerinde kullanılması yerine, metrik öğrenme yöntemleri ile ayıricılığının artırılabilceğinin gösterilmesi de tez çalışmasındaki amaçlardan birisidir.

1.2 Literatür Araştırması

Yüz çifti eşleme (YÇE) alanı halen popülerliği devam eden, pek çok araştırmacının ilgisini çeken bir konudur, bu nedenle konu hakkında çok sayıda çalışma bulunmaktadır. Literatürdeki çalışmalarda Yerel İkili Örüntüler (YİÖ) [5], Gabor [6] ve Scale Invariant Feature Transform (SIFT) [7] gibi farklı öznitelik çıkartma yöntemleri, farklı sınıflandırıcılar kullanılmış, farklı veritabanlarında ve farklı başarımlar ölçme yöntemleri kullanılarak elde edilen başarımlar raporlanmıştır.

Simonyan ve diğerleri [8] çalışmasında Ölçekten Bağımsız Öznitelik Dönüşümü (ing. *Scale Invariant Feature Transform, SIFT*) yöntemini her gözek ve komşulukları etrafında yerel ve yoğun (ing. *dense*) olarak kullanarak Gauss modelleri (ing. *Gaussian Mixture Model, GMM*) hesaplaması ve Fisher vektörlerinin oluşturulması prensibine dayalı yeni bir yöntem önermiştir. Önerilen yöntem LFW testlerinde %87.47 başarımlar elde etmiştir. Her ne kadar oldukça yüksek boyutlu öznitelik vektör hesapları ve yüksek işlemci yükü gerektirse de, YÇE alanındaki en yüksek başarıma ulaşılmıştır.

[9] çalışmasında Seo ve Milanfar, yerel uyumlu regresyon çekirdekleri (ing. *Locally Adapted Regression Kernels, LARK*) isminde yeni bir yüz gösterimi önermiştir.

Yöntem, yüz imgesi üzerindeki her gözek için komşu gözeklerle jeodezik uzaklık olarak isimlendirdikleri yeni bir ölçüt ile yerel uzaklıkların belirlenmesi prensibine

dayanmaktadır. Bu işlem sonucu elde edilen LARK tanımlayıcıları mantıksal bir fonksiyona tabii tutulmaktadır ve ikili kodlanmış bir vektör elde edilmektedir. Bu yöntem ile LFW veritabanında %85,1 başarımla elde edilmiştir.

Taigman ve diğerleri [10] çalışmasında öznelik çıkarma yöntemi olarak tek bir yöntem yerine YİÖ ve SIFT yöntemlerini beraber kullanmıştır. Sınıflandırma işleminde yüz imgelerinin poz değişimlerinin etkisini ölçmek için benzer pozdaki resimlerin kendi aralarında gruplanması önerisinde bulunulmuştur. Bu sayede farklı pozların biriktiği yüz grupları çoklu tek-atış benzerlik (ing. *multiple one-shot similarity*) yöntemiyle başarılı şekilde sınıflandırılmıştır.

YÇE alanındaki çalışmaların önemli bir kısmı eğitim kümelerindeki verileri kullanarak çeşitli yöntemlerle dönüşüm matrisleri öğrenip, bu sayede test verilerini daha ayırıcı olabilecekleri bir uzaya taşıyan metrik öğrenme tabanlı yöntemlerden oluşmaktadır. [11] çalışmasında Barreto ve diğerleri, YİÖ ve ham gözet değerlerinin (ing. *intensity*) beraber kullanılması yöntemiyle hesapladıkları vektörlerin uzaklıkları hesabında L2-norm kullanılarak bir metrik öğrenme yöntemi geliştirmiştir. Yöntem, eş olarak etiketlenmiş çiftlerin toplam L2-norm uzaklıklarının en küçüklendiği, eş olmayan çiftlerin toplam L2-norm uzaklıklarının ise en büyüklendiği bir eniyileme probleminin çözülmesinin sonucunda dönüşüm matrisi elde edilmesi prensibine dayanmaktadır.

Nguyen ve Bai [12] çalışmasında kosinüs uzaklıklarını istatistiksel olarak yorumlama mantığına dayanan yeni bir metrik öğrenme yöntemi önermiştir. YİÖ, Gabor ve ham gözet değerlerinin beraber kullanıldığı hibrit vektörler arası uzaklık ölçümünde L2-norm yerine kosinüs uzaklığı kullanmanın daha iyi sonuçlar verdiği ve kosinüs uzaklıkları tabanlı bu yöntemin benzer problemler için daha iyi genelleştirilebildiği gösterilmektedir.

Metrik öğrenme tabanlı YÇE çözümlerinde mahalanobis uzaklığı sıklıkla kullanılmaktadır. Weinberger ve diğerlerinin yaptığı [13] çalışmada hesaplanan vektörlerin sınıflandırma öncesi ağırlıklandırılması ile k-en yakın komşuluk sınıflandırıcısının performansını arttırmaya dayalı yeni bir metrik öğrenme yöntemi geliştirilmiştir. Yöntemde k-en yakın komşuluk işlemindeki aynı etiketi kapsayan örnekleri kapsayan çemberler çizilmekte olup, bu çemberlerin içerisinde kalan farklı

etiketteki örnekler ise ceza katsayıları ile çarpılmaktadır. Bu şekilde hedef veriler arasındaki mahalanobis uzaklıkları güçlendirilirken, amaç dışı olan veriler arası uzaklıklar zayıflatılmaktadır.

[14] çalışmasında Davis ve diğerleri Mahalanobis uzaklığının enküçüklemesi tabanlı yeni bir metrik öğrenme yöntemi önermiştir. Yöntem, uzaklık fonksiyonundaki iki çok değişkenli Gauss formülü arasındaki ilişkinin enküçükleme problemi şeklinde özetlenmektedir.

Guillaumin ve diğerleri [15] Mahalanobis uzaklıklarının lojistik ayrıştırma (ing. *discriminant*) tabanlı şekilde kullanıldığı yeni bir metrik öğrenme yöntemi önermiştir. Yüz imge çiftlerinin YİÖ ve SIFT kullanılarak çıkartılan vektörleri arasındaki uzaklık, eğitim kümesindeki çiftler ile geliştirilen model kullanılarak aynı kişiye ait olma olasılığı şeklinde formülleştirilmiştir.

[2] çalışmasında Köstinger ve diğerleri, Mahalanobis uzaklığı tabanlı dönüşüm matrisleri kullanan Large Margin Nearest Neighbor Learning (LMMN) [13], Information Theoretic Metric Learning (ITML) [14] ve Logistic Discriminant Metric Learning (LDML) [15] gibi yöntemlerin vektör uzaylarındaki ön işlemlerindeki işlem yükü önemli derecede azaltılmış ve Mahalanobis uzaklığının ayırıcılığı artırılmıştır. Yöntem, vektör uzayındaki verilerin ayırıcılık bakımından önemli kısımlarının ağırlıklarını arttırmakta, önemsiz kısımlarını ise dışarıda bırakmakta ve böylece hızlı ve etkin bir çözüm sunmaktadır.

1.3 Tezin Organizasyonu

Bölüm 2’de kullanılan özniteilk çıkarma yöntemi olan Yerel Zernike Momentlerinden (YZM) bahsedilmektedir. Bölüm 3’te YZM vektörlerinin boyutlarının indirgenmesi ve bu amaçla kullanılan Temel Bileşen Analizi (TBA) yöntemi açıklanmıştır. Bölüm 4’te dönüşüm matrislerinin hesaplanması için kullanılan metrik öğrenme yöntemleri sıralanmıştır. Bölüm 5’te sınıflandırma yöntemlerinden bahsedilmektedir. Bölüm 6’da önerilen algoritmaların kullanımı, seçilen parametreler ve başarımları sonuçları gösterilmiştir.

2. ÖZNİTELİK ÇIKARMA YÖNTEMLERİ

Bu bölümde, çalışmada öznitelik çıkartma yöntemi olarak kullanılan Yerel Zernike Momentleri(YZM) açıklanmaktadır.

2.1 Yerel Zernike Momentleri

Moment tanımlayıcıları, imgeler üzerindeki şekil ve desen karakteristiğinin çıkartılmasında kullanılan çokterimlilerdir. Bu moment tanımlayıcılarından birisi olan Zernike momentleri ise bir imgenin Zernike dik çokterimlileri üzerindeki iz düşümü kullanılarak hesaplanmaktadır [16].

Zernike momentleri imgenin bütünündeki şekil karakteristiğinin önemli olduğu karakter tanıma vb. konularda başarılı sonuçlar vermektedir [17]. Ancak imgelerin ayrık şekil ve desen bilgileri yerine yerel istatistiksel bilgilerinin daha önemli olduğu yüz tanıma vb. konularda ise iyi sonuçlar verememektedir. Bu nedenle Zernike momentlerinin bütün imge üzerinde global olarak hesaplanması yerine, her gözek(ing. *pixel*) çevresinde yerel olarak hesaplanması mantığına dayanan yeni bir yüz gösterimi olarak Yerel Zernike momentleri yöntemi önerilmiştir [1]. YZM yöntemi yüz tanıma başarımlarında Çizelge 2.1’de gösterildiği gibi akademik FERET [18] veritabanının FaFb, FaFc, Dup1 ve Dup2 test protokollerinde Gabor [6] ve YİÖ [5] gibi betimleyicilere kıyasla daha başarılı sonuçlar elde etmektedir.

Çizelge 2.1: YZM’nin literatürdeki diğer yöntemlerle karşılaştırılması [1]

Yöntem	FaFb	FaFc	Dup I	Dup II
YİÖ	93.0	51.0	61.0	50.0
YİÖ (Ağırlıklı)	97.0	79.0	66.0	64.0
Gabor	97.6	98.9	77.7	76.1
Gabor (Ağırlıklı)	97.5	99.5	79.5	77.8
YZM	96.3	97.9	79.9	76.5
YZM (Ağırlıklı)	98.7	99.5	84.8	82.5

2.1.1 Yerel Zernike Momentleri dönüşümü

Bir imgenin Zernike dönüşümü, imgenin farklı radyal derecelerdeki Zernike çokterimlileri kümesi üzerindeki izdüşümü kullanılarak hesaplanmaktadır. Zernike çokterimlileri kümesinin genelleştirilmiş formülü,

$$V_{nm}(\rho, \theta) = R_{nm}(\rho)e^{jm\theta} \quad (2.1)$$

şeklinde gösterilmektedir. (2.1)'de moment derecesi n , yineleme sayısı m olmak üzere, $|m| \leq n$ ve $n - |m| = \text{çift sayı}$ olma koşulları sağlanmaktadır. R_{nm} şeklinde gösterilen radyal çokterimlileri,

$$R_{nm}(\rho) = \sum_{s=0}^{\frac{n-|m|}{2}} \frac{(-1)^s (-\rho)^{n-2s} (n-s)!}{s! (\frac{n+|m|}{2} - s)! (\frac{n-|m|}{2} - s)!} \quad (2.2)$$

şeklinde tanımlanmaktadır.

Boyutları $N \times N$ olan giriş imgesi $f(i, j)$ olarak gösterilir, x_i ve y_i değerleri $[-1, 1]$ aralığında birim çember üzerine getirilir. (x_i, y_i) noktası ile birim çemberin merkez noktası arası çizilen vektörün uzunluğu ρ , ve vektörün yatay eksenle saat yönünün tersine yaptığı açı θ olmak üzere $0 \leq \rho \leq 1$ ve $0 \leq \theta \leq 2\pi$ koşulları sağlanır. İlgili $f(i, j)$ için Zernike momentleri,

$$\Delta x_i = \Delta y_j = \frac{2}{N\sqrt{2}}, -1 \leq x_i, y_i \leq 1, \quad (2.3)$$

$$\theta_{ij} = \tan^{-1} \frac{y_i}{x_i}, \rho_{ij} = \sqrt{x_i^2 + y_i^2} \quad (2.4)$$

$$Z_{mn} = \frac{n+1}{\pi} \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} f(i, j) V_{nm}^*(\rho_{ij}, \theta_{ij}) \Delta x_i \Delta y_j \quad (2.5)$$

şeklinde hesaplanmaktadır.

Formülize edilen Zernike momentleri, YZM yönteminde her gözek ve çevresinde yerel olarak kullanılmaktadır. Bunun için gözeği ve komşularını kapsayacak şekilde


$k \times k$ boyutlu yerel filtre çekirdekleri V_{nm}^k şeklinde tanımlanmıştır. Bu çekirdeklerin dik radyal çokterimliler kümesi $V_{nm}(p_{ij}, \theta_{ij})$ olmak üzere,

$$V_{nm}^k(i, j) = V_{nm}(p_{ij}, \theta_{ij}) \quad (2.6)$$

eşitliği elde edilmektedir. Giriş imgesi olarak $f(i, j)$ kullanılırsa, her (i, j) gözet koordinat çifti için YZM dönüşümü,

$$Z_{nm}^k(i, j) = \sum_{p, q = -\frac{k-1}{2}}^{\frac{k-1}{2}} f(i-p, j-q) V_{nm}^k(p, q) \quad (2.7)$$


şeklinde elde edilmektedir [1]. YZM dönüşümü (2.7)'de görüleceği üzere her (i, j) gözet koordinatları etrafında $k \times k$ boyutlu çekirdeklerin konvolüsyon benzeri bir şekilde imgenin üzerine kaydırılması ile hesaplanmaktadır. İmge üzerinde filtre çekirdeklerinin kaydırılması Şekil 2.1'de gösterilmiştir.



Şekil 2.1: YZM çekirdeklerinin imge üzerinde kaydırılması

YZM yönteminde kullanılan moment derecesi n ile gösterilir ve derecesi n e bağlı olarak farklı sayılarda V_{nm}^k çekirdekleri elde edilir. Bu çekirdeklerin yarısı sanal, yarısı ise gerçel çekirdeklerdir. (2.7)'de gösterildiği gibi her sanal ve gerçel V_{nm}^k çekirdeği için giriş imgesinin sonucu olan bir imge üretilmektedir. $k = 9$ filtre boyu için elde edilen çekirdeklerden ilk 8 tanesinin gerçel ve sanal bileşenleri Şekil 2.2'de gösterilmektedir.

YZM dönüşümündeki moment derecesi n ile üretilen karmaşık değerli filtre çekirdekleri ve çıkış imgeleri sayısı ise şu şekilde hesaplanmaktadır.



Şekil 2.2: $k = 9$ için elde edilen çekirdeklerinden ilk 8 tanesinin a) gerçel bileşenleri
b) sanal bileşenleri [1]

$$K(n) = \begin{cases} \frac{n(n+2)}{4}, & n \text{ tek ise} \\ \frac{(n+1)^2}{4}, & n \text{ çift ise} \end{cases} \quad (2.8)$$

2.1.2 Yerel Zernike Momentleri öznitelik vektörü oluşturulması


YZM dönüşümünün giriş imgesine uygulanması ve karmaşık değerli çıkış imgelerinin oluşturulmasından sonraki adım öznitelik vektörünün oluşturulmasıdır.

Giriş imgesinin farklı sayıda alt alanlara ayrılması ve her ayrı alt alan için öznitelik vektörü çıkarma işleminin yapılması özellikle yüz tanıma alanında yapılan çalışmalarda sık kullanılan bir yöntemdir. YZM yönteminde de giriş imgesi öncelikle birbiri ile kesişmeyen $N \times N$ adet bloğa ayrılır. Ek olarak imge üzerinde yatay ve dikey olarak yarım bloklu bir kaymanın ardından $(N-1) \times (N-1)$ adet olmak üzere ikinci bir bloklara ayırma işlemi daha uygulanır ve toplamda $N^2 + (N-1)^2$ adet alt alan oluşturulur. İki katmanlı bu bloklara ayırma işleminin yüz tanıma başarısını arttırdığı YZM ile ilgili önceki çalışmalarda gösterilmiştir [1].

Şekil 2.3'te gösterildiği gibi bloklara ayırma işleminin ardından giriş imgesinin YZM tarafından üretilen sonuç imgelerinin, belirlenen her alt alanda faz genlik histogramları (FGH) çıkartılmaktadır.

Histogramların çıkartılması işleminde $[0, 2\pi]$ aralığı öncelikle b adet açı aralığına ayrılmaktadır. Ardından her gözeğin $|Z_{nm}^k(i, j)|$ şeklinde gösterilen genlik değeri, $\angle Z_{nm}^k(i, j)$ şeklinde gösterilen faz değerine karşılık gelen açı aralığına eklenmektedir. Bu işlem YZM yönteminin ürettiği bütün karmaşık imgelerin ilgili alt bölgede tekrarlanarak yerel histogramlar oluşturulmaktadır. Bütün yerel histogramların normalize edilmesinin ardından alt alta eklenmesi ile de sonuç öznitelik vektörü meydana gelmektedir.

α bir YZM vektörü olmak üzere seçilen parametrelere göre vektörün boyutu,



Şekil 2.3: YZM yönteminin giriş görüntüsüne uygulanması [1]

$$||\alpha|| = (N^2 + (N - 1)^2) \times b \times K_1 \times K_2 \times 2 \quad (2.9)$$

şeklinde hesaplanmaktadır. (2.9)'da N blok sayısı, b açılı aralığı sayısı, K_1 ve K_2 ise (2.8)'de hesaplama yöntemi gösterilen moment sayısıdır. YZM yönteminde oluşturulan karmaşık imgelerin sanal ve gerçel kısımları bulunduğu için hesaplanan bu sayı 2 ile çarpılmakta ve toplam vektör boyutu elde edilmektedir.

2.2 Yerel İkili Örüntüler


Yerel İkili Örüntüler (YİÖ) yöntemi, Ojala ve arkadaşları tarafından kullanılması önerilmiş etkin bir desen tanımlayıcı operatördür [3]. Bu yöntemin en önemli özelliği basit ve etkili bir yöntem olmasının yanı sıra, ışıklandırma değişimlerine oldukça dayanıklı olmasıdır.

YİÖ yönteminde, her gözet 3x3 komşuluğundaki diğer gözetleri kendi değeri ile eşikleyerek etiketler ve eşikleme sonucunu ikili bir sayı olarak değerlendirir.

Belirlenen bu ikili değerlere YİÖ kodları ismi verilmektedir.


YİÖ kodları üretirken merkez gözet değeri karşılaştırılan komşu gözetin değerinden büyük ise 1, aksi takdirde 0 olarak kodlanır. Bu işlem 3x3 komşuluktaki 8 adet komşu gözet için tekrarlanır ve böylelikle her gözet için 8 bitlik kod elde edilir. Temel YİÖ operatörünün gösterimi Şekil 2.4'te gösterilmiştir.

Önerilen bu yöntem, 3x3 gibi düşük bir komşuluk değerine sahip olması nedeniyle özellikle büyük çözünürlükteki görüntülerdeki desen bilgisinin ortaya çıkarılmasında yetersiz kalmaktadır. Bu nedenle YİÖ yöntemine 2 adet ilave özellik getirilmiş ve yöntem bugünkü halini almıştır.



Şekil 2.4: Temel YİÖ operatörü

YİÖ yöntemine getirilen güncellemelerden ilki örnekleme noktalarını ve komşuluk yarıçapını limitsiz hale getiren Genişletilmiş Yerel İkili Örüntüler (GYİÖ) yöntemidir. Bu yöntemde (P,R) gösterimi (ing. *notation*) adı verilen bir gösterim kullanılır. Gösterimdeki P değeri komşu gözet sayısını, R değeri ise komşuluk yarıçapını ifade etmektedir.



Şekil 2.5: (8,2) gösterimi için çembersel komşuluk [5]

Şekil 2.5'te (8,2) değerli çembersel komşuluk örneği verilmiştir.

YİÖ yöntemine getirilen güncellemelerden ikincisi ise düzgün örüntülerdir [5]. İlgili çalışmada elde edilen sonuçlara göre bazı örüntülerin diğerlerine göre çok daha fazla ayrıştırıcı bilgi taşıdıkları ortaya çıkmaktadır. Bu da imgenin sadece bu özel örüntüler kullanılarak betimlenebileceğini göstermektedir. Belirlenen bu özel örüntülere tekdüze (ing. *uniform*) örüntüler ismi verilmiştir.

Bir örüntünün tekdüze olarak adlandırılabilmesi için içerisinde en fazla 2 adet 0-1 ya da 1-0 bit geçişi olmalıdır. 00000001 (1 geçiş) ve 11110001 (2 geçiş) tekdüze örüntüler olarak adlandırılırken, 10100010 (5 geçiş) ve 01010110 (6 geçiş) tekdüze örüntü değillerdir.

Ojala ve arkadaşları doku görüntülerinde yaptıkları testler sırasında (8,1) komşuluk değeri için tüm örüntülerin yaklaşık %90'ının, (16,2) komşuluk değeri için tüm örüntülerin yaklaşık %70'inin tekdüze örüntü olduğunu görmüşlerdir [3].

8 adet komşuluk için hesaplanabilecek 256 farklı örüntü bulunmasına rağmen bunların sadece 59 tanesi tekdüze örüntü olarak kullanılmaktadır. Böylelikle sadece belirlenen 59 örüntü ile bütün imgeler betimlenebilmekte ve YİÖ vektörlerinin boyutları da azalmaktadır.

YİÖ yöntemine getirilen güncellemelerle birlikte imgelerden örüntülerin çıkartılması işlemi yukarıda anlatılmıştı. Bu örüntülerden öznitelik vektörlerinin oluşturulması sırasında uzamsal bilginin de kullanılabilmesi için Ahonen ve arkadaşları YİÖ görüntüsünü $m \times n$ adet alt bölgeye bölüp, bu bölgelerden birer histogram hesaplanmasını önermiştir [5]. Elde edilen histogramların ardarda eklenmesi sonucunda öznitelik vektörü oluşturulmaktadır.

3. BOYUT İNDİRGEME YÖNTEMLERİ

YZM yöntemi kullanılarak elde edilen öznitelik vektörleri yüksek boyutlu vektörlerdir ve çalışmanın diğer adımları için işlem yükünü ve çalışma zamanını arttırmaktadır. Bu problemi çözmek için Temel Bileşenler Analizi (TBA) yöntemi kullanılarak öznitelik vektörlerinin boyutlarının indirgenmesi önerilmiştir.

3.1 Temel Bileşenler Analizi

Temel Bileşenler Analizi, çok sayıda değişkenden oluşan ve değişkenleri birbiri ile bağlantılı olan bir veri kümesinin boyutlarının düşürülmesinde kullanılan bir yöntemdir.

Yöntemin amacı yüksek boyutlu veriyi değişkenlerinin özelliklerini olabildiğince koruyacak şekilde daha az sayıda değişken ile ifade edilen bir alt uzaya izdüşürmektir. İz düşüm yapılan doğrusal alt uzaydaki vektörler temel bileşenler olarak tanımlanır.

3.1.1 Temel Bileşenlerin Hesaplanması

Temel bileşenlerin elde edilebilmesi için veri kümesinin kovaryans matrisi hesaplanmakta ve bu matrisin öz değerleri ve öz vektörleri elde edilmektedir. Bunun için giriş verisi öncelikle $M \times N$ boyutlu bir matris (X) formatına getirilir.

$$X = \begin{bmatrix} x_1^1 & x_1^2 & \dots & x_1^M \\ x_2^1 & x_2^2 & \dots & x_2^M \\ \dots & \dots & \dots & \dots \\ x_N^1 & x_N^2 & \dots & x_N^M \end{bmatrix} \quad (3.1)$$

(3.1)'de gösterildiği gibi X matrisinin satırları M örnek sayısı, sütunları N ise her bir veri örneğinin boyutudur.

TBA dönüşümünün ilk adımında denklemdeki gibi veri kümesindeki tüm örneklerin ortalaması alınmakta ve μ ile ifade edilen ortalama vektörü (3.2)'te gösterildiği gibi oluşturulmaktadır.

$$\mu = \frac{1}{M} \sum_{i=0}^M X^i = \begin{bmatrix} \mu_1 \\ \mu_2 \\ \dots \\ \mu_M \end{bmatrix} \quad (3.2)$$

Elde edilen μ ortalama vektörü (3.3)'te ifade edildiği gibi X matrisindeki her veriden çıkartılmaktadır. Bu sayede sıfır ortalamalı bir veri matrisi olan $\hat{X}$ elde edilmektedir.

$$\hat{X} = \begin{bmatrix} x_1^1 - \mu_1 & x_1^2 - \mu_1 & \dots & x_1^M - \mu_1 \\ x_2^1 - \mu_2 & x_2^2 - \mu_2 & \dots & x_2^M - \mu_2 \\ \dots & \dots & \dots & \dots \\ x_N^1 - \mu_M & x_N^2 - \mu_M & \dots & x_N^M - \mu_M \end{bmatrix} \quad (3.3)$$

Ortalanmış $\hat{X}$ matrisi (3.4)'te gösterildiği gibi kendi tranpozesi ile çarpılarak C kovaryans matrisi hesaplanmaktadır.

$$C = \hat{X} \hat{X}^T \quad (3.4)$$

Hesaplanan kovaryans matrisine ait özdeğerler ve bu özdeğerlere karşılık gelen özvektörler şu şekilde elde edilmiştir.

$$Cv = \lambda v \quad (3.5)$$

(3.5)'te λ özdeğerleri, v ise temel bileşenler olarak adlandırılan özvektörleri temsil etmektedir. Hesaplanan öz değerlerin sayısal değeri, ilgili özvektörün giriş veri kümesindeki örnekleri ne kadar iyi temsil ettiğine bağlıdır. Bu yüzden hesaplanan öz vektörler kendilerine karşılık gelen öz değerlere göre büyükten küçüğe doğru sıralandıktan sonra en büyük k adet değere ($k < N$) karşılık düşen öz vektörler kullanılarak sütunlarını bu özvektörlerin oluşturduğu ω dönüşüm matrisi elde edilmektedir.

Elde edilen ω dönüşüm matrisi ile giriş verisinin boyutları (3.6)'da gösterildiği gibi indirgenmekte ve boyutları indirgenmiş y matrisi elde edilmektedir.

$$y^i = \omega(X^i - \mu) \quad (3.6)$$

4. METRİK ÖĞRENME YÖNTEMLERİ

Yüz Çifti Eşleme (YÇE) problemi ile ilgili yapılan çalışmalarda sıklıkla kullanılan metrik öğrenme yöntemleri, eş ve eş olmayan şeklinde etiketlenmiş eğitim yüz çiftlerinin istatistiksel olarak yorumlanması prensibine dayanmaktadır. Metrik öğrenme yöntemlerinde eğitim verilerinin farklı uzaklık ölçütleri ve analiz yöntemleri kullanılarak bir dönüşüm matrisi hesaplanmaktadır. Hesaplanan bu dönüşüm matrisi, test için kullanılan yüz çiftlerine ait öznitelik vektörleri ile çarpılarak, ilgili vektörlerin ayırıcılığını arttırmaktadır.

Tez çalışmasında 2 farklı metrik öğrenme yöntemi ile YZM öznitelik vektörlerinin ayırıcılıkları artırılmıştır.

4.1 L2-Norm Metrik Öğrenme

Barreto ve diğerleri [11] tarafından geliştirilen L2-Norm Metrik Öğrenme (ing. *L2-Norm Metric Learning, L2ML*) yöntemi, öznitelik vektör çiftlerinin mevcut uzaydan, daha ayırıcı olabilecekleri başka bir uzaya taşınmalarını sağlayacak bir dönüşüm bulma temeline dayanmaktadır. Bu dönüşüm, eş vektörlerin kendi aralarındaki toplam uzaklıklarının sıfıra yaklaşacak şekilde en küçüklenmesi esasına göre hesaplanmaktadır.

Dönüşümün eğitim aşamasında eş ($l_i = 1$) ve eş olmayan ($l_i = 0$) şeklinde etiketlenmiş, her biri n boyutlu olan toplam N adet vektör çifti kullanılmaktadır. i indisli bir vektör çifti olan a_i ve b_i arası fark $d_i = a_i - b_i$ olarak belirtilmiştir. Bulunması hedeflenen dönüşüm matrisi T ile gösterilmektedir ve vektörlerin ayırıcılığı arttırabilmesi için (4.1)'deki denkliği sağlamalıdır:

$$\sum_{\forall i|l_i=1} \|Td_i\|_2 \ll \sum_{\forall i|l_i=0} \|Td_i\|_2 \quad (4.1)$$

(4.1)'deki T matrisi, fark matrisleri ile çarpım işleminde boyutlarının uyum göstermesi için $k \times n$ boyutlarındadır ve ortogonal özelliğindedir. ($TT^T = I$)

T matrisini yalnız bırakırsak çözülmesi gereken denklem (4.2) haline gelmektedir:

$$T^* = \arg \max_T \frac{\sum_{\forall i|l_i=0} \|T d_i\|_2^2}{\sum_{\forall i|l_i=1} \|T d_i\|_2^2} \quad (4.2)$$

(4.2), eş olmayan çiftlerin öklit uzaklıklarını enbüyüklerken, eş çiftlerin öklit uzaklıklarını ise enküçüklemeaktadır.

$$\|T d_i\|_2^2 = (T d_i)^T (T d_i) = \text{Tr}(T d_i d_i^T T^T) \quad (4.3)$$

özelliliği kullanılarak,

$$\sum_i \|T d_i\|_2^2 = \text{Tr}[T(\sum_i d_i d_i^T)T^T] \quad (4.4)$$

elde edilmektedir.

$S_- = \sum_{\forall i|l_i=0} d_i d_i^T$ ve $S_+ = \sum_{\forall i|l_i=1} d_i d_i^T$ şeklinde bir gösterimle birlikte (4.2)' şü şekilde tekrar yazılabilmektedir:

$$T^* = \arg \max_T \frac{\text{Tr}(T S_- T^T)}{\text{Tr}(T S_+ T^T)} \quad (4.5)$$

(4.5)'te $S_+ = I$ olarak bir giriş uygularsak T 'nin ortogonal olması nedeniyle $\text{Tr}(T S_+ T^T) = \text{Tr}(I)$ haline gelir ve (4.5),

$$T^* = \arg \max_T \text{Tr}(T S_- T^T) \quad (4.6)$$

şekline indirgenmiş olur.

(4.6)'daki problem eş olmayan vektörlere Temel Bileşenler Analizi uygulayarak elde çözülmektedir. Tek problem $S_+ = I$ olacak şekilde bir girişin nasıl hesaplanacağı sorusuna cevap bulmaktır. Burada da eş olan vektör çiftleri üzerinde Beyazlatılmış (ing. *Whitened*) Temel Bileşenler Analizi kullanarak $S_+ = I$ eşitliğini sağlayan giriş bulunabilmektedir.

Matematiksel olarak ifade edilen L2ML yönteminin gerçekleşmesi için aşağıdaki adımlar uygulanmaktadır.

Algorithm 1 L2ML Metrik Öğrenme Algoritması [11]

Giriş: $S_- = \sum_{\forall i|l_i=0} d_i d_i^T$

Giriş: $S_+ = \sum_{\forall i|l_i=1} d_i d_i^T$

Giriş: L2ML uzayındaki yeni boyut sayısı k

Çıkış: $k \times n$ boyutlu T dönüşüm matrisi

1 : $\lambda, U = \text{eigs}(S_+, k)$

2 : $U' = U \lambda^{-\frac{1}{2}}$

3 : $S'_- = U' S_- U'^T$

(4.6)'nın çözümü

4 : $\lambda, V = \text{eigs}(S'_-, k)$

5 : $T = V U'$

Verilen eğitim algoritmasının giriş verilerinden ilki, n boyutlu vektörlerin taşınacağı L2ML uzayındaki yeni vektör boyutu anlamına gelen ve $k < n$ eşitsizliğini sağlayan k değeridir. İkinci giriş verisi ise S_+ şeklinde ifade edilen $n \times n$ boyutlu bir kare matristir. Bu matris $1 \times n$ boyutlarındaki eş olarak etiketlenmiş yüz çiftlerine ait vektörlerin farklarının kendi transpozeleri ile çarpımlarından oluşan bir kare matristir. Benzer şekilde algoritmanın diğer bir giriş verisi olan S_- kare matrisi ise eş olmayan olarak etiketlenmiş vektör farklarından elde edilmektedir.

Örnek bir L2ML dönüşümü eğitimini bir örnek senaryoda açıklamak gerekirse, bütün adımların sonunda $n = 1000$ olmak üzere 1×1000 boyutundaki vektörlerden $k = 200$ boyutundaki bir L2ML uzayına dönüştürme için 1000×200 boyutunda bir T dönüşüm matrisi elde etmeye çalışılmaktadır. Eğitim aşamasında öğrenilen bu 1000×200 boyutlu T matrisi, test aşamasındaki 1×1000 boyutlarındaki vektörler ile çarpılacak ve ortaya 1×200 boyutundaki L2ML uzayına taşınmış yeni vektörler çıkacaktır.

Eğitim kümesinde $N = 3000$ adet eş ve eş olmayan vektör çifti olduğunu varsayalım. Algoritmanın giriş değerleri olan S_+ ve S_- matrislerini oluşturmak için öncelikle 3000 adet eş vektör çiftininin tek tek 1×1000 boyutlarındaki L2 normundaki fark vektörlerinin oluşturulması ve kendi transpozeleri ile çarpılarak $n \times n$ yani 1000×1000 boyutlu bir kare matris oluşturulması gerekmektedir. $N = 3000$ adet eş vektör çifti olduğu için bu işlem 3000 kere tekrarlanmalıdır ve her elde edilen kare matris üstüste toplanarak 1000×1000 boyutlarındaki nihai S_+ matrisi elde edilmektedir. Benzer işlemler eş olmayan vektörler için de yapıldığında aynı boyutlu S_- kare matrisi de ortaya çıkmaktadır.

Algoritmanın ilk adımında TBA yöntemi kullanılarak önceden elde edilen S_+ matrisinin en yüksek değere sahip k adet özdeğerine ait özvektörleri elde edilmektedir. İkinci adımda özvektörlere beyazlatılmış TBA işlemi olarak da adlandırılan özdeğerlerin kareköküne bölme işlemi uygulanmaktadır. Üçüncü adımda ise ikinci adımda elde edilen matris ve transpozisi, daha önceden elde edilen S_- ile çarpılmaktadır. Üçüncü adımın sonunda elde edilen matrise tekrar TBA işlemi uygulandığında elde edilen özvektörler ise ikinci adımın sonunda elde edilen beyazlatılmış vektör ile çarpılarak T matrisi elde edilmektedir.

4.2 Eşitlik Kısıtları ile Geniş Ölçekte Metrik Öğrenme

Eşitlik Kısıtları ile Geniş Ölçekte Metrik Öğrenme (ing. *Large Scale Learning from Equivalence Constraints, LSML*) yöntemi, Köstinger ve diğerleri tarafından önerilmiş bir metrik öğrenme yöntemidir [2]. Yöntemin amacı Mahalanobis uzaklığı kullanılarak geliştirilen Large Margin Nearest Neighbor Learning (LMMN) [13], Information Theoretic Metric Learning (ITML) [14] ve Logistic Discriminant Metric Learning (LDML) [15] gibi diğer metrik öğrenme yöntemlerinin, büyük veritabanlarında ölçeklenebilirliğini arttırmaktır.

Bir veri kümesindeki x ve y olarak gösterilen iki nokta arasındaki Mahalanobis uzaklığı,

$$d = \sqrt{(x - y)^T C^{-1} (x - y)} \quad (4.7)$$

şeklinde gösterilmektedir. (4.7)'de görülebileceği gibi öklid ve kosinüs gibi ölçütlerden farklı olarak bir veri kümesindeki iki verinin arasındaki uzaklığı hesaplarken (4.7)'de C terimi ile gösterilen mevcut verinin kovaryans bilgisi kullanılmaktadır. Bu sayede diğer verilerin davranışları da hesaba katılmaktadır.

Mahalanobis uzaklık ölçütünü kullanan metrik öğrenme yöntemleri, dönüşüm matrislerini oluştururken LMMN için (4.8), ITML için (4.9) ve LDML için (4.10)'da gösterildiği gibi yinelemeli şekilde eniyileme çalışmaları yapmakta ve bu adımlar sırasında Mahalanobis uzaklık hesaplarını da defalarca tekrarlanacak şekilde kullanmaktadır. Bu da özellikle LFW gibi fazla sayıda yüz çifti içeren veritabanlarında eğitim zamanının oldukça uzamasına neden olmaktadır.

$$\frac{\partial_{\varepsilon}(M^t)}{\partial M^t} = \sum_{j=i} C_{ij} + \mu \sum_{(i,j,l)} (C_{ij} - C_{il}) \quad (4.8)$$

$$M_{t+1} = M_t + \beta M_t C_{ij} M_t \quad (4.9)$$

$$\frac{\partial L(M)}{\partial M} = \sum_{ij} (y_{ij} - p_{ij}) C_{ij} \quad (4.10)$$

Diğer metrik öğrenme yöntemlere ait (4.8),(4.9) ve (4.10) incelendiğinde eniyileme işlemlerinin eş etiketli vektör çiftleri için C_{ij} yönünde, eş olmayan şekilde etiketlenmiş çiftlerde ise C_{ij} 'nin ters yönünde gerçekleştirildiği görülmektedir. Geliştirilen yöntem de bu vektör çiftlerinin farklarının istatistik açısından analiz edilerek sonuç çıkartılmasına dayanılmaktadır.

i ve j iki ayrı öznitelik vektörü, (i, j) ise bir vektör çiftini göstermektedir. Vektör çiftinin aynı kişiye ait yani eş olma durumu H_1 , farklı kişilere ait olma durumu ise H_0 olmak üzere istatistiksel olarak (i, j) çiftinin eş olmamaya ne kadar yatkın olduğu,

$$\delta(x_i, x_j) = \log \left(\frac{p(x_i, x_j | H_0)}{p(x_i, x_j | H_1)} \right) \quad (4.11)$$

şeklinde gösterilebilir. (4.11)'deki $\delta(x_i, x_j)$ değeri ne kadar yüksekse (i, j) çiftinin eş olmama durumuna yakınsamaktadır, aynı şekilde ne kadar düşükse çiftin eş olma durumuna yakınsamaktadır. (4.11)'i fark uzayına taşımak için $x_{ij} = x_i - x_j$ dönüşümü yapılır sıfır ortalamaya sahip olacak şekilde indirgenirse,

$$\delta(x_{ij}) = \log \left(\frac{p(x_{ij} | H_0)}{p(x_{ij} | H_1)} \right) = \log \left(\frac{f(x_{ij} | \theta_0)}{f(x_{ij} | \theta_1)} \right) \quad (4.12)$$

elde edilir. (4.12)'deki $f(x_{ij} | \theta_1)$ terimi, vektör çiftinin eş olma ihtimalinin θ_1 parametresine bağlı olarak bir olasılık yoğunluk fonksiyonu (ing. *probability density function, pdf*) olarak gösterilebilir. Aynı denklik, $f(x_{ij} | \theta_0)$ terimi için de ters anlamda yazılabilir. Elde edilen (4.12) Gauss açılımına göre yeniden düzenlenirse,

$$\delta(x_{ij}) = \log \left(\frac{\frac{1}{\sqrt{2\pi|\Sigma_{y_{ij}=0}|}} \exp(-1/2x_{ij}^T \Sigma_{y_{ij}=0}^{-1} x_{ij})}{\frac{1}{\sqrt{2\pi|\Sigma_{y_{ij}=1}|}} \exp(-1/2x_{ij}^T \Sigma_{y_{ij}=1}^{-1} x_{ij})} \right) \quad (4.13)$$

haline gelmektedir. (4.13)'deki $\sum_{yij=0}$ ve $\sum_{yij=1}$ terimlerinin açılımı,

$$\sum_{yij=0} = \sum_{yij=0} (x_i - x_j)(x_i - x_j)^T \quad (4.14)$$

$$\sum_{yij=1} = \sum_{yij=1} (x_i - x_j)(x_i - x_j)^T \quad (4.15)$$

şeklindedir. x_{ij} ile gösterilen vektör farkı simetrik ve sıfır ortalamaya sahiptir. Bu durumda Gauss açılımlarının enbüyüklenme olasılığı, Mahalanobis uzaklığının en küçük kareler yöntemine göre en küçüklenmesi ile eşit hale gelmektedir. Bu sayede eş ve eş olmayan çiftlerin bulunduğu 2 bağımsız veri kümesi için bağımlı olasılık hesapları devam ettirilebilir. (4.13)'te gösterilen denklem, logaritma alınma işleminin ardından,

$$\delta(x_{ij}) = x_{ij}^T \sum_{yij=1}^{-1} x_{ij} + \log(|\sum_{yij=1}|) - x_{ij}^T \sum_{yij=0}^{-1} x_{ij} - \log(|\sum_{yij=0}|) \quad (4.16)$$

haline gelmektedir. (4.16) sabit değerlerin çıkartılması ile basitleştirilerek,

$$\delta(x_{ij}) = x_{ij}^T (\sum_{yij=1}^{-1} - \sum_{yij=0}^{-1}) x_{ij} \quad (4.17)$$

şeklinde yeniden yazılabilir. $\hat{M} = (\sum_{yij=1}^{-1} - \sum_{yij=0}^{-1})$ olmak üzere,

$$d_M^2(x_i, x_j) = (x - y)^T M (x - y) \quad (4.18)$$

elde edilir. (4.18), daha önce (4.7)'de verilen Mahalanobis uzaklık metriği formülü ile aynı yapıdadır. $\hat{M}$ ise hesaplanan uzaklık dönüşüm matrisidir. Bu sayede yinelemeli işlemlere gerek kalmadan hızlı ve etkin bir şekilde dönüşüm elde edilmiştir [2].

LSML yönteminin LFW veritabanı üzerindeki eğitim süresi ve diğer yöntemler ile işlem zamanı açısından karşılaştırılması Çizelge 4.1'de gösterilmiştir.

Çizelge 4.1: Karşılaştırılan yöntemlerin işlem zamanları [2]

Yöntem	LSML	SVM	ITML	LDML	LMMN
LFW(s)	0.05	12.78	24.81	307.23	1198.69


5. SINIFLANDIRMA YÖNTEMLERİ

YZM yöntemiyle elde edilen vektörlerin TBA ile boyut indirgemesinin ardından metrik öğrenme yöntemleriyle boyut deęiřtirmesinden sonra elde edilen vektör çiftlerinin sınıflandırılmasında k-En Yakın Komşuluk yöntemi kullanılmıştır.

5.1 k-En Yakın Komşuluk

Örnek tabanlı öğrenme yöntemlerinin en basiti olarak nitelendirilen k-en yakın komşuluk sınıflandırıcısı, test verisinin eğitim kümesindeki verilerden en yakın olanın sınıf etikeyle işaretilmesi prensibine dayanmaktadır. Bu sınıflandırıcıda her gelen veri için k adet komşuluktaki örnek verilerle belirli metriklere göre uzaklıkları hesaplanmaktadır. Eğer $k = 1$ seçilmişse, en yakın sınıfın sınıf bilgisi, test verisinin yeni sınıf bilgisi haline gelir.

$k = 3$ için örnek bir gösterim Şekil 5.1'deki gibidir.



Şekil 5.1: $k = 3$ için k-En Yakın Komşuluk yönteminin gösterimi

5.2 Uzaklık Ölçütleri

k-En Yakın Komşuluk yönteminde test verisi ile eğitim kümesindeki veriler arasındaki uzaklığın ölçülmesinde farklı ölçütler kullanılabilir.

Çalışmada kullanılan yöntemler şu şekildedir.

L1 uzaklığı,

$$L_1(x, y) = \sum_{i=1}^n |x_i - y_i| \quad (5.1)$$

L2 uzaklığı,

$$L_2(x, y) = \left(\sum_{i=1}^n |x_i - y_i|^2 \right)^2 \quad (5.2)$$

Kosinüs uzaklığı,

$$\cos(\theta) = \frac{XY}{|X||Y|} = \frac{\sum_{i=1}^n x_i y_i}{\sqrt{\sum_{i=1}^n x_i^2} \sqrt{\sum_{i=1}^n y_i^2}} \quad (5.3)$$

Mahalanobis uzaklığı,

$$d = \sqrt{(x - y)^T C^{-1} (x - y)} \quad (5.4)$$

6. DENEYSEL ÇALIŞMALAR

Bu bölümde, tez çalışmasında başarımların testleri hesaplanmasında kullanılan veritabanı ilgili açıklamalar yer almaktadır. Ayrıca veritabanındaki imgeler üzerindeki ön işlemlerden bahsedilmektedir. Öznitelik çıkarma, boyut indirgeme, metrik öğrenme ile boyut değiştirme ve sınıflandırma adımlarının gerçekleştirilmesinde kullanılan yöntemler, parametrelerin seçilmesi ve başarımların sonuçlarından bahsedilecektir.

6.1 Kullanılan Veritabanı

Bu çalışmada başarımların ölçmek amacıyla Labeled Faces in the Wild (LFW) veritabanı [19] kullanılmıştır. LFW, 5749 farklı kişiye ait toplam 13233 adet görüntüden oluşan ve yüz çifti eşleme (YÇE) problemine uygun şekilde oluşturulmuş bir veritabanıdır. İçerdiği görüntüler Yahoo isimli haber sitesi kaynaklarından derlendiği için kontrolsüz ortamlara ait görüntülerdir. Bu nedenle farklı açı, poz, ifade ve yaş gibi değişimler içermektedir.

LFW veritabanında YÇE başarımlarının hesaplanması için kısıtlandırılmış (ing. *restricted*) ve kısıtlandırılmamış (ing. *unrestricted*) protokoller altında 2 adet performans ölçüm prosedürü önerilmektedir. Kısıtlandırılmış prosedürde kullanılacak imge çiftlerinin isimleri sabittir, değiştirilemez. Diğer prosedürde ise mevcut çiftler kullanılarak yeni yüz çiftleri üretilebilmektedir.

Bu tez çalışmasında kısıtlandırılmış test protokolü kullanılmaktadır.

Kısıtlandırılmış testlerde kullanılmak üzere 2 ayrı veri kümesi belirlenmiştir. İlk küme (view1) parametrelerin eniyilenmesinde kullanılmaktadır. İkinci küme (view2) ise ilk kısımda öğrenilen en iyi parametre değerlerine göre performans ölçümü yapılacak giriş imge çiftlerinden ve etiketlerinden bahsetmektedir. Buna göre toplam 6000 adet yüz imgesi çifti, 10 ayrı gruba (ing. *fold*) ayrılmıştır. Her grupta 300 adet eş ve 300 adet eş olmayan imge çifti belirlenmiştir.

a)



Aaron Peirsol, 1

Aaron Peirsol, 2



Aaron Peirsol, 3

Aaron Peirsol, 4



Aaron Sorkin, 1

Aaron Sorkin, 2



Abdel Nasser
Assidi, 1

Abdel Nasser
Assidi, 2



Abdullah, 1

Abdullah, 3

b)



AJ Cook, 1

Marsha
Thomason, 1



Aaron Sorkin, 2

Frank Solich, 5



Abdel Nasser
Assidi, 2

Hilary McKay, 1



Abdoulaye Wade, 4

Linda Dano, 1



Abdul Rahman, 1

Magui Serna, 1

Şekil 6.1: LFW veritabanındaki örnek yüz imgelerinden a) eş olanlar b) eş olmayanlar

Karşılaştırılabilir test başarımlarının elde edilmesi için 10 adet gruptan oluşan veriler çapraz doğrulama (ing. *cross validation*) yöntemiyle işleme tabii tutulmaktadır. Örnek bir doğrulama adımımda 9 adet eğitim grubunda yer alan toplam 5400 adet yüz çifti eğitim amaçlı kullanılırken, test grubundaki 600 yüz çiftinin doğru etiketlenmesi yüzdesi hesaplanması ve bu işlemin 10 grup için de tekrar edilmesi ile başarımlar elde edilmektedir [19].

6.2 İmgeler Üzerinde Yapılan Ön İşlemler

LFW veritabanındaki imgeler 250x250 çözünürlüğe sahiptir. İmgelerdeki yüz ve yüzlere ait nirengi noktalarının koordinatları bulmak için [19]'te önerilen etiket dosyası kullanılmıştır. Etiketlenmiş koordinatlara göre yüzler gözlerin orta noktaları aynı hizaya gelecek şekilde düzgelenmiştir.

Yüzlerin haricinde kalan arka plan bölgelerinin tanıma başarımlarını etkilememesi için [20]'da önerilen betikler kullanılarak yüzler kesilmiş, yüz bölgeleri dışarısında kalan arka plan bölümleri maskelenmiş ve yüzler 130x150 çözünürlüğe sahip olacak şekilde yeniden boyutlandırılmıştır. Şekil 6.2'de kesilmiş yüzlerin örnek görüntüleri gösterilmiştir.



Şekil 6.2: Kesilmiş ve hizalanmış yüz imgeleri

Aynı hizaya gelecek Şekil 6.2'de gösterildiği gibi kesilen ve hizalanan yüzlerin görüntü karşıtlığının (ing. *contrast*) artırılması için kesilmiş imgeler ayırıştırma (ing. *normalization*) işlemine tabii tutulmuşlardır. İmgelerin üzerindeki gözetik değerleri,

0-255 gözetk aralığına daha homojen bir şekilde dağıtılarak imgelerin gözle görülebilir şekilde ayırıcılık ve karşıtlıkları yükseltilmiştir.

Çizelge 6.1’de giriş imgelerinin ayrıştırma işleminin başarıma etkisi görölmektedir. Öznitelik çıkartma yöntemlerinin parametreleri sabit tutularak sadece giriş imgeleri değıştirilmiş ve LFW veritabanının 10-grup çapraz doğrulama sonuçları elde edilmiştir.

Çizelge 6.1: İmgelerin ayrıştırmasının başarıma etkisi

Yöntem	Ayrıştırılmamış İmgelerle Başarım (%)	Ayrıştırılmış İmgelerle Başarım (%)
YZM	75.64	75.92
YİÖ	68.90	69.33

Giriş imgelerine yapılan bu ön işlemlerin farklı öznitelik çıkarma yöntemleri kullanıldığında da başarımları arttırdığı görölmektedir.

6.3 Öznitelik Vektörlerinin Hazırlanması

Çalışmada kesilen imgelerin öznitelik vektörlerinin çıkartılması işleminde ağırlıkla YZM yöntemi kullanılmaktadır. Geliştirilen YÇE yöntemlerinin, literatürdeki diğer yöntemlerle karşılaştırılması ve başarımlarını eniyilemesi sırasında kullanılmak üzere YİÖ yöntemi de gerçekenmiş ve kullanılmıştır. Bu bölümde öznitelik vektörü çıkarma için kullanılan yöntemler, yöntemlerin seçilen parametreleri ve ilgili özniteliklerin yorumlanması açıklanmaktadır.

6.3.1 Yerel Zernike Momentleri

Tez çalışmasında öznitelik çıkarma yöntemi olarak kullanılan yöntemlerden ilki olan YZM yöntemi, kesilen yüz görüntülerine Bölüm 2.1’de anlatıldığı gibi uygulanmaktadır. Yüz imgelerine arka arkaya iki kere uygulanan YZM yöntemi farklı moment dereceleri n , farklı boyutlardaki filtre çekirdekleri k , farklı blok sayıları N ve farklı açısı değeri b kullanılarak farklı vektörler elde edilmektedir.

Çalışmada kullanılacak YZM yönteminin en iyi parametrelerinin belirlenmesi için LFW veritabanının 10-grup çapraz doğrulama sonuçları hesaplanmıştır.

Çizelge 6.2’de moment derecelerinin ve filtre çekirdek boylarının başarıma etkisi görülmektedir. Yapılan testlere göre özellikle daha fazla sayıda moment bileşeni n kullanıldığında başarının arttığı gözlenmiştir ancak moment sayısının artırılması vektörün uzunluğunun da artmasına neden olmaktadır. Yüksek boyutlu öznitelik vektörlerinin çalışmanın geri kalanında işlemci/bellek gereksinimlerini ve işlem süresini çok yükseltmemesi için $n1 = 2$, $n2 = 2$, $k1 = 5$ ve $k2 = 7$ parametreleri seçilmiştir.

Çizelge 6.2: YZM dönüşümünde k ve n değerlerinin başarıma etkisi

N1	N2	K1	K2	Başarım (%)
2	2	5	5	75.64
2	2	5	7	75.92
3	3	5	5	75.81
3	3	5	7	76.02
4	4	5	5	76.14
4	4	5	7	76.32

Çizelge 6.3’te blok ızgara sayısı N değerinin başarıma etkisi gösterilmektedir. Bölüm 2.1’de anlatıldığı üzere iki katmanlı ızgara kullanılmış ve başarıma buna göre hesaplanmıştır. İlk ızgara katmanı giriş imgesini $N \times N$ adet bloğa, ikinci ızgara katmanı ise $(N - 1) \times (N - 1)$ bloğa ayırmaktadır ve toplam $N^2 + (N - 1)^2$ adet blok elde edilmektedir.

Çizelge 6.3: YZM dönüşümünde blok sayısının başarıma etkisi

İzgara Sayısı	3	5	7	9
Toplam Blok Sayısı	13	41	85	145
Başarım (%)	73.21	75.92	75.92	76.13

Testler sonucunda elde edilen başarımlar ve toplam blok sayıları incelendiğinde, blok sayısının artmasının başarıma olumlu etkilediği görülmektedir. Ancak öznitelik boyutlarının çok yüksek olmaması nedeniyle $N = 5$ seçilmiştir.

YZM dönüşümünün anlatıldığı Bölüm 2.1’deki seçilen parametrelere göre vektör uzunluğunun formülü olan Denklem 2.9 kullanılarak ve açısı $b = 18$ seçilerek, YZM öznitelik vektörünün uzunluğu 2952 olarak hesaplanmaktadır. Bu vektör boyutu literatürdeki önceki çalışmalarda kullanılan YİÖ ve SIFT yöntemlerinde elde edilen vektörlerle yakın boyutlardadır ve bu sayede adil bir karşılaştırma yapılabilmesini sağlamaktadır.

YZM dönüşümü ile elde edilen öznitelik vektörünün her bir değerinin karekökünün alınmasıyla elde edilen aynı boyutlu $\sqrt{YZM}$ vektörleri de çalışmada kullanılmaktadır. Çizelge 6.4'te YZM ve $\sqrt{YZM}$ yöntemlerinin başarımları karşılaştırılmıştır.

Çizelge 6.4: YZM ve $\sqrt{YZM}$ yöntemlerinin başarımları

Yöntem	YZM	$\sqrt{YZM}$
Başarım (%)	75.92	74.89

6.3.2 Yerel İkili Örüntüler

Çalışmada öznitelik çıkarma yöntemi olarak kullanılan yöntemlerden biri de YİÖ histogramları yöntemidir. YÇE problemi ile ilgili yapılan pek çok çalışmada YİÖ dönüşümü ve histogramları kullanılmaktadır. Bu çalışmada da Bölüm 2.2'de anlatıldığı gibi temel YİÖ operatörüne ek olarak geliştirilen Tekdüze Yerel İkili Örüntüler (TYİÖ) yöntemi kullanılmaktadır.

TYİÖ yöntemi [11] ve [12] gibi YÇE problemi ile ilgili çalışmalarda sıklıkla kullanılmış ve başarılı sonuçlar elde edilmesini sağlamıştır. İlgili yöntemler incelendiğinde, öznitelik vektörü olarak kullanılan örüntü histogram değerlerinin boyutlarını ve dolayısıyla başarımlarını etkileyen en önemli faktör olarak imgelerin bloklara bölünmesi gözlenmiştir. Çizelge 6.5'te çalışmada kullanılan TYİÖ yönteminin farklı blok sayıları kullanıldığında elde edilen vektör uzunlukları ve LFW veritabanında 10-grup çapraz doğrulama başarımları gösterilmiştir.

Çizelge 6.5: TYİÖ yönteminde blok sayısının başarıma etkisi

Blok sayısı	1x1	3x5	6x7
Başarım (%)	62.45	68.14	70.27

Yapılan testlerden çıkan sonuçlardan da görülebileceği gibi daha TYİÖ yöntemi 6x7 adet kesişmeyen bloğa bölündüğünde elde edilen başarımlar ve mevcut vektör boyutlarının kullanılmasına karar verilmiştir. Elde edilen TYİÖ vektörünün boyutu Bölüm 2.2'de anlatıldığı üzere $6 \times 7 \times 59 = 2478$ olarak belirlenmiştir ve YZM yöntemi kullanılarak elde edilen öznitelik vektörünün boyutu ile yakın değerlere sahiptir.

TYİÖ dönüşümü ile elde edilen vektörünün her bir değerinin karekökünün alınmasıyla elde edilen aynı boyutlu $\sqrt{TYIO}$ vektörleri de tez çalışmasında yapılan

testlerde kullanılmaktadır. Çizelge 6.6'da TYİÖ ve $\sqrt{TYIO}$ yöntemlerinin başarımları karşılaştırılmıştır.

Çizelge 6.6: TYİÖ ve $\sqrt{TYIO}$ yöntemlerinin başarımları

Yöntem	TYİÖ	$\sqrt{TYIO}$
Başarım (%)	70.27	69.77

6.4 Öznitelik Vektörlerinin Boyutlarının İndirgenmesi

Tez çalışmasında öznitelik çıkarma yöntemi kullanılan Yerel Zernike Momentleri ve Tekdüze Yerel İkili Örüntüleri dönüşümlerinin seçilen parametrelere göre vektör boyutları önceki bölümlerde açıklanmıştı. Elde edilen vektörlerin yüksek boyutları metrik öğrenme algoritmalarına uyarlanmalarını zorlaştırmaktadır. Özellikle eğitim aşamasındaki bellek/işlemci kullanımını azaltmak için vektörlerin boyut indirgeme işleminin yapılması gerekmektedir.

Bölüm 3'te anlatıldığı gibi öznitelik vektörlerinin ayıricılıklarını kaybetmeden boyutlarının indirgenmesi için Temel Bileşenler Analizi (TBA) yöntemi kullanılmıştır.

Eğitim amaçlı kullanılmak üzere belirlenen yüz çiftlerine ait öznitelik vektörleri TBA yöntemi ile daha düşük boyutlara indirgenmiş ve başarımları test edilmiştir. Bu testlerde LFW veritabanının 10-grup çapraz doğrulama protokolü kullanılmış ve başarımlar raporlanmıştır.

YZM yöntemi ile elde edilmiş 2952 boyutlu vektörlere uygulanan TBA dönüşümündeki seçilen yeni boyut k parametresinin başarıma olan etkisi Çizelge 6.7'de gösterilmiştir.

TYİÖ yöntemiyle elde edilmiş 2478 boyutlu vektörlere uygulanacak TBA dönüşümündeki seçilen yeni boyut n parametresi ise [11] çalışmasında gösterildiği gibi seçilmiştir. Barreto ve arkadaşlarının yaptığı testlerde eniyilediği parametrelere [11] göre TYİÖ ve $\sqrt{TYIO}$ vektörlerinin TBA ile boyutları indirgenmiş başarımları Çizelge 6.8'de gösterilmiştir.

Çizelgeler incelendiğinde TBA dönüşümünde seçilen ve boyutları indirgenen vektörlerin boyutunu veren k parametresinin başarımları çok etkilemediği görülmüştür.

Çizelge 6.7: YZM vektörlerinin TBA ile boyut indirgeme başarımları

Yöntem	k	Başarım (%)
YZM-TBA	100	74.25
YZM-TBA	200	75.42
YZM-TBA	300	75.90
YZM-TBA	340	76.01
YZM-TBA	400	75.87
$\sqrt{YZM}$ -TBA	100	75.21
$\sqrt{YZM}$ -TBA	200	75.49
$\sqrt{YZM}$ -TBA	300	75.98
$\sqrt{YZM}$ -TBA	340	76.23
$\sqrt{YZM}$ -TBA	400	76.36

Çizelge 6.8: TYİÖ vektörlerinin TBA ile boyut indirgeme başarımları [11]

Yöntem	k	Başarım (%)
TYİÖ-TBA	204	72.33
$\sqrt{TYIO}$ -TBA	267	72.80

Literatürdeki incelenen çalışmalarda [11] [12] [2] da benzer şekilde başarımlar üzerinde çok kritik bir etkisi olmayan k değerinin kullanılacağı algoritmaya göre rahatlıkla seçilebileceği gözlenmiştir.

L2-Norm Metrik Öğrenme (L2ML) yönteminde için kullanılmak üzere hazırlanan YZM-TBA ve $\sqrt{YZM}$ -TBA vektörleri için k değeri 340 olarak seçilmiştir. Bu parametrelerin seçiminde L2ML yöntemi için [11], LSML yöntemi için ise [2] çalışmalarındaki seçilmiş parametrelere yakın değerlerin kullanılması amaçlanmıştır.

6.5 Metrik Öğrenme

Önceki bölümlerde anlatıldığı gibi yüz çiftlerine ait imgelerden elde edilen boyutları indirgenmiş öznitelik vektörlerinin en yakın komşuluk sınıflandırma işlemi öncesi ayıricılıklarının arttırılacağı dönüşüm metrik öğrenme olarak adlandırılmıştır.

Tez çalışmasında L2-Norm Metrik Öğrenme (L2ML) ve Eşitlik Kısıtları ile Geniş Ölçekte Metrik Öğrenme (LSML) algoritmaları kullanılmış ve başarımları eniyilemek adına en uygun parametreler bulunmaya çalışılmış ve bulunan başarımlar raporlanmıştır.

6.5.1 L2-Norm Metrik Öğrenme

Tez çalışmasında kullanılan metrik öğrenme algoritmalarından ilki olan L2ML, Barreto ve arkadaşları [11] tarafından geliştirilmiş bir yöntemdir. Öznitelik çıkarma yöntemi olarak YİÖ kullanılan bu yöntem, eş olarak etiketlenmiş yüz çiftlerine arası L2-Norm uzaklığın enküçüklenmesi, eş olmayan şeklinde etiketlenmiş vektörler arası L2-Norm uzaklıkların ise enbüyüklenmesi prensibine dayanmaktadır.

TBA ile boyutları indirgenmiş n boyutlu vektör çiftlerinin farklarının, eğitim aşamasında öğrenilen $k < n$ olmak üzere $k \times n$ boyutlu bir T dönüşüm matrisi kullanılarak ayırıcılığının arttırılması şeklinde uygulamaktadır. İlgili çalışmada LFW 10-grup çapraz doğrulama yöntemi kısıtlı protokolde kullanılarak YİÖ vektörleri ile %82.75 oranında başarımlar elde edilmiştir. Birden çok öznitelik vektörü ve farklı sınıflandırıcıların harmanlanması ile bu başarımlar %84,97 başarımlar elde edilmiştir [11].

Bu çalışmada ise YZM öznitelik vektörlerinin L2ML yönteminde kullanılması gerçekleştirilmiş ve aynı veritabanı ve test protokolleri kullanılarak benzer yüksek başarımlar elde edilmeye çalışılmıştır.

Önceki bölümlerde anlatıldığı gibi belirlenen YZM ve $\sqrt{YZM}$ vektörlerinin boyutları $n_{YZM} = 2952$ olarak seçilmişti. Yöntemin daha hızlı çalışması için yapılan testlerin ardından TBA yöntemi ile indirgenen YZM-TBA vektörlerinin boyutları ise $n_{YZM-TBA} = 340$ olarak seçilmişti. LFW kısıtlandırılmış eğitim/test protokolü ve Bölüm 4.1'deki Algoritma 1'de gösterildiği gibi yüz çiftlerine ait YZM-TBA vektör çiftlerinin farkları kullanılarak L2ML dönüşüm matrisi olan T hesaplanmaktadır. Eğitim aşamasında elde edilen bu $k \times n$ boyutlu T matrisi, test aşamasındaki n boyutlu vektör çiftleri ile çarpılmakta ve böylece hem vektörleri L2ML uzayına taşımakta hem de giriş vektörlerinin boyutlarını k değerine düşürmektedir. Görülebileceği gibi vektörlerin taşındığı L2ML uzayının boyutlarını oluşturan k değerinin seçilmesi, başarımlar hesabını etkileyen en önemli faktördür.

LFW kısıtlandırılmış protokolüne göre 10 adet gruba ayrılmış 6000 adet eş ve eş olmayan yüz çiftlerinden 8 adet grupta bulunan 4800 adet yüz çifti, eğitim aşamasında T dönüşüm matrisinin öğrenilmesinde kullanılmıştır. Kalan 2 gruptan ilkinde ait 600 adet yüz çifti ise öğrenilen T matrisi ile çarpılarak eş ya da eş olmayan

şeklinde sınıflandırma yapılabilmesi için parametre eniyilemesinde kullanılmaktadır. Bu gruptaki yüz çiftleri kullanılarak öğrenilen sabit bir theta eşik değeri sayesinde, başarımlar testi için ayrılan son gruptaki 600 adet çiftte ait vektör uzaklıklarının eş ya eş olmayan vektörlere ait olup olmadığının kararı verilmektedir.

Farklı k değerlerine göre öğrenilmiş T dönüşümleri ve bu dönüşümler ile L2ML uzayına taşınan YZM-TBA vektörleri, YZM-TBA-L2ML vektörleri olarak isimlendirilmiştir. Bu vektörlerle elde edilen 10-grup çapraz doğrulama başarımları Çizelge 6.9’da gösterilmiştir.

Çizelge 6.9: L2ML uzayında k parametresinin başarıma etkisi

Yöntem	k	Başarım (%)
YZM-TBA-L2ML	100	74.85
YZM-TBA-L2ML	150	76.14
YZM-TBA-L2ML	200	79.58
YZM-TBA-L2ML	250	80.89
YZM-TBA-L2ML	260	81.87
YZM-TBA-L2ML	270	80.74
YZM-TBA-L2ML	300	78.49
YZM-TBA-L2ML	339	77.43
$\sqrt{YZM}$ -TBA-L2ML	100	73.69
$\sqrt{YZM}$ -TBA-L2ML	150	79.71
$\sqrt{YZM}$ -TBA-L2ML	200	80.35
$\sqrt{YZM}$ -TBA-L2ML	300	80.19
$\sqrt{YZM}$-TBA-L2ML	310	82.93
$\sqrt{YZM}$ -TBA-L2ML	320	81.85
$\sqrt{YZM}$ -TBA-L2ML	339	76.27

Çizelge incelendiğinde k parametresinin seçilmesinin başarımda önemli bir etken olduğu gözlenmiştir. TBA dönüşümünün aksine L2ML uzayına taşınan vektörlerin yeni boyut değeri olan k parametresi hassas bir şekilde seçilmelidir. Elde edilen sonuçlara göre $k = 310$ seçilerek eğitilen T dönüşüm matrisi kullanılarak L2ML uzayına taşınan $\sqrt{YZM}$ -TBA vektörleri ile %82.93 başarıma ulaşılmıştır. Farklı YZM vektörlerinin L2ML uzayında elde ettiği en iyi başarımlar ise Çizelge 6.10’da özetlenmiştir.

Çizelge 6.10’da görüleceği gibi en iyi LFW 10-grup çapraz doğrulama başarımları $\sqrt{YZM}$ -TBA-L2ML yöntemi kullanılarak elde edilmiştir. $\sqrt{YZM}$ vektörleri tek başlarına YZM vektörlerinden daha yüksek başarıma ulaşamasa da, önce TBA, sonra

Çizelge 6.10: Farklı YZM vektörleri ile elde edilen başarımlar

Yöntem	Başarım (%)
YZM	75.92
YZM-TBA	76.01
YZM-TBA-L2ML	81.87
$\sqrt{YZM}$	74.89
$\sqrt{YZM-TBA}$	76.23
$\sqrt{YZM-TBA-L2ML}$	82.93

da L2ML dönüşümlerinin ardından YZM vektörlerinden daha yüksek başarıma erişmiştir.

Elde edilen başarımlarda, L2ML uzayına taşınan vektörlerin eş ya da eş olmayan şeklinde sınıflandırılmasında kosinüs uzaklığı ölçütünün kullanılmasının da payı bulunmaktadır. L2ML uzayındaki vektörlerinin, L2 ve kosinüs uzaklığı ölçütlerine göre sınıflandırılmasının etkisi ise Çizelge 6.11’de gösterilmiştir.

Çizelge 6.11: Kosinüs ve L2 uzaklık ölçütlerinin başarımlara etkisi

Yöntem	Uzaklık Ölçütü	Başarım (%)
YZM-TBA-L2ML	L2	79.41
YZM-TBA-L2ML	Kosinüs	81.87
$\sqrt{YZM-TBA-L2ML}$	L2	80.56
$\sqrt{YZM-TBA-L2ML}$	Kosinüs	82.93

Literatürdeki yapılan çalışmalar incelendiğinde [11] [12] [10] daha yüksek başarımlara ulaşabilmek için tek bir öznitelik çıkarma yöntemi ve tek bir uzaklık ölçütü kullanarak yapılan yöntemlerin yerini hibrit çözümlerin aldığı görülmektedir. Birden fazla öznitelik çıkarma yönteminin birleştirilmesi (ing. *fusion*) ve farklı uzaklık ölçütlerinin beraber kullanılmasının başarımları arttırabileceği öngörüsü üzerine tez çalışmasında da YZM vektörlerine ek olarak TYİÖ vektörlerinin de kullanılması kararlaştırılmıştır.

TYİÖ vektörlerinin TBA ve L2ML işlemlerinde kullanılan parametreleri [11] çalışmasında önerildiği gibi seçilmiştir. Böylelikle çalışmada önerilen değerler ile TYİÖ yöntemine özel bir T dönüşüm matrisi elde edilmiştir. Elde edilen L2ML uzayına taşınmış TYİÖ vektörleri ile daha önceden hesaplanan T dönüşüm matrisi ile L2ML uzayına taşınmış YZM vektörlerinin beraber kullanılması sonucunda hibrit bir yöntem geliştirilmiş ve başarımları Çizelge 6.12’de gösterilmiştir.

Çizelge 6.12: YTiÖ ve hibrit yöntemin başarımları

Yöntem	Başarım (%)
TYiÖ	70.27
TYiÖ-TBA	72.80
TYiÖ-TBA-L2ML	78.67
$\sqrt{TYiÖ}$ -TBA-L2ML	82.75
$\sqrt{YZM} + \sqrt{TYiÖ}$ -TBA-L2ML (Hibrit)	83.91

Çizelgede gösterildiği gibi YZM ve TYiÖ yöntemlerinin beraber kullanılmasının başarıyı arttırdığı görülmüştür. Tez çalışması sırasında elde edilen bu en iyi başarımın, LFW veritabanındaki aynı protokol kullanılarak raporlanmış literatürdeki diğer başarımlarla olan karşılaştırması ise Çizelge 6.13'te gösterilmiştir.

Çizelge 6.13: Elde edilen L2ML başarımların literatürdeki sonuçlarla karşılaştırılması

Yöntemler	Başarımlar
$\sqrt{YZM}$ -TBA-L2ML	%82,93
$\sqrt{YZM} + \sqrt{TYiÖ}$ -TBA-L2ML (Hibrit)	%83,91
Ham Gözek Değerleri-L2ML [11]	%79,8
YiÖ-L2ML [11]	%78,67
$\sqrt{YiÖ}$ -L2ML [11]	%82,75
Ham Gözek Değerleri + $\sqrt{YiÖ}$ – L2ML [11]	%84,97
OSS + Çoklu öznitelikler (10 farklı uzaklık ölçütü) [10]	%82,07
Hibrit öznitelikler (20 farklı uzaklık ölçütü) [10]	%83,98
LARK gösterimi + (14 farklı uzaklık ölçütü) [9]	%85,10
CMSL + $\sqrt{LBP}$ [12]	%85,57
Dense SIFT + Fisher Faces [8]	%87,47

Sonuçları yorumladığımızda YZM vektörlerinin direkt olarak sınıflandırma işleminde kullanılması yerine öncelikle L2ML uzayına taşınmaları ile birlikte başarımın %6-8 oranında arttığı gözlemlenebilir.

Testlerde çıkan başarımlardan yola çıkarak YZM vektörlerinin L2ML uzayında en az YiÖ vektörleri kadar yüksek başarımlara ulaşabildiği söylenebilir. Tezin amaçlarından birisi olan YZM vektörlerinin YÇE probleminde kullanılabileceğini ispatlama konusunda YZM vektörleri başarılı gözükmektedir.

Literatürdeki diğer metrik öğrenme yöntemleri ile karşılaştırıldığında tez çalışmasında elde edilen en yüksek başarımın, literatürdeki en yüksek metrik öğrenme algoritmasında elde edilen değerden %1.5 civarında [12] daha düşük olduğu görülmektedir. Mevcut sonuçların içerisindeki en yüksek değer olan [8] çalışmasında

ise SIFT öznitelikleri her gözek etrafında hesaplandığı için oldukça yüksek işlemci gücü gerekmektedir. Tez çalışmasında önerilen yöntem raporlanmış en iyi başarımlara ulaşamasa da işlem yükü/bellek gereksinimi açısından daha kabul edilebilir bir düzeydedir.

6.5.2 Eşitlik Kısıtları ile Geniş Ölçekte Metrik Öğrenme

Tez çalışmasında kullanılan metrik öğrenme yöntemlerinden diğeri ise Eşitlik Kısıtları ile Geniş Ölçekte Metrik Öğrenme (LSML) yöntemidir. Köstinger ve arkadaşları [2] tarafından geliştirilen LSML yöntemi, literatürdeki Mahalanobis uzaklığı temelli metrik öğrenme yöntemlerinin ölçeklenebilirliğini ve daha az bilgi ile sonuç elde edebilme başarısını artırma amacını taşımaktadır.

Mahalanobis uzaklığı ölçütü pek çok metrik öğrenme algoritmasının temelini oluşturmaktadır ancak literatürdeki [15] [13] gibi ilgili çalışmalar incelendiğinde bu yöntemlerin genellikle daha çok sayıda yüz çifti etiketine ihtiyacı olduğu gözlemlenmektedir. Bu nedenle bu uzaklık ölçütünü kullanan ilgili çalışmalar LFW veritabanının kısıtlanmış protokolündeki 6000 adet yüz çifti yerine kısıtlanmamış protokolünü kullanmayı tercih etmekte ve ilgili protokol gereğince daha fazla yüz çifti kullanma ihtiyaçlarını karşılamaktadırlar.

LSML yönteminde diğeri Mahalanobis uzaklığı temelli yöntemlerden farklı olarak karmaşık matematiksel hesaplamalar ve uzun işlem yükü getiren iterasyonlar yerine daha basit bir şekilde eşitlik kısıtları kullanılarak hızlı ve etkin bir öğrenme sağlanmaktadır. Yöntem 0.5 saniye gibi kısa bir sürede eğitim aşamasını tamamlamakta ve LFW veritabanında kısıtlandırılmış protokol ve 10-grup çapraz doğrulama testlerine göre %80.5 başarımla elde etmektedir [2].

İlgili çalışmada Köstinger ve arkadaşları öznitelik çıkarma yöntemi olarak SIFT kullanmaktadır. Yüz imgeleri üzerindeki gözler, ağzın köşeleri, burun gibi önceden etiketlenmiş 9 nokta etrafında hesaplanan SIFT vektörleri 3456 boyutlu olarak kullanılmaktadır. SIFT vektörleri TBA yöntemiyle 100 boyutlu bir alt uzaya indirgenmekte ve boyutları azaltılmaktadır. Ardından hesaplanan LSML dönüşümü ile 100 boyutlu LSML-SIFT vektörlerinin ayıricılıkları artırılmaktadır [2].

Bu tez çalışmasında LSML yönteminde SIFT vektörleri yerine YZM vektörlerinin kullanılması denenmiş ve başarımları raporlanmıştır. 3456 boyutlu SIFT vektörlerinin yerine kullanılacak YZM vektörünün parametrelerinin belirlenmesi için özel bir test yapılmamış, L2ML metodunda kullanılmak üzere LFW veritabanında gerçekleştirilen önceki testlerde iyi sonuçlar veren 2952 boyutlu YZM ve $\sqrt{YZM}$ vektörlerinin kullanılmasına karar verilmiştir.

Yüz imgelerine ait çıkartılan YZM tabanlı vektörlerin ayıricılıklarını yitirmeden daha küçük boyutlara sahip olarak temsil edilebilmesi için TBA yöntemi kullanılmıştır.

TBA ile boyut indirgeme adımındaki yeni vektör boyu n parametresinin belirlenmesinde [15] ve [2] gibi çalışmalarda belirlendiği gibi L2-Norm Metrik Öğrenme yönteminde seçilen k değerinden çok daha küçük değerler seçilmeye çalışılmıştır. Böylelikle yakın boyuttaki giriş vektörleri kullanılarak başarımlar karşılaştırmalarının daha kabul edilebilir olması hedeflenmiştir.

TBA ile indirgenmiş YZM-TBA ve $\sqrt{YZM}$ -TBA vektörleri kullanılarak öncelikle Mahalanobis uzaklık matrisi LSML algoritmasında belirtildiği gibi hesaplanmakta, YZM-TBA-LSML ve $\sqrt{YZM}$ -TBA-LSML vektörleri oluşturulmaktadır. Bu test işlemi sırasında yeni vektör boyu n parametresi için yapılan testler ve sonuçları 6.14'te gösterilmiştir.

Çizelge 6.14: Farklı YZM vektörleri ile elde edilen LSML başarımları

Yöntem	n	Başarım (%)
YZM-TBA-LSML	50	72.65
YZM-TBA-LSML	75	76.41
YZM-TBA-LSML	90	79.57
YZM-TBA-LSML	100	79.88
YZM-TBA-LSML	104	79.92
YZM-TBA-LSML	110	79.45
$\sqrt{YZM}$ -TBA-LSML	50	73.12
$\sqrt{YZM}$ -TBA-LSML	75	76.74
$\sqrt{YZM}$ -TBA-LSML	90	78.36
$\sqrt{YZM}$-TBA-LSML	97	80.67
$\sqrt{YZM}$ -TBA-LSML	105	79.97
$\sqrt{YZM}$ -TBA-LSML	110	78.28

Çizelgede görülebileceği gibi elde edilen sonuçlara göre $n = 104$ seçilerek boyutları indirgenen YZM-TBA-LSML vektörleri ile LSML algoritması kullanılarak %79.92

başarıma ulaşmıştır. $\sqrt{YZM}$ -TBA-LSML vektörleri ile ise $n = 97$ seçilerek %80.67'lik daha iyi bir sonuç elde edilmiştir.

Tez çalışması sırasında elde edilen bu en iyi başarımın, LFW veritabanındaki aynı protokol kullanılarak raporlanmış ve literatürdeki Mahalanobis uzaklığı tabanlı diğer başarımlarla olan karşılaştırması ise Çizelge 6.15'te gösterilmiştir.

Çizelge 6.15: Elde edilen LSML başarımların literatürdeki sonuçlarla karşılaştırılması

Yöntemler	Başarım (%)
$\sqrt{YZM}$ -TBA-LSML	80.67
SIFT-TBA-LSML [2]	80.5
SIFT-TBA-LDML [2]	79.6
SIFT-LDA-LDML [15]	79.4
SIFT-TBA-ITML [2]	78.9
SIFT-TBA-LMMN [2]	78.5
SIFT-TBA-SVM [2]	75.5
SIFT- Mahalanobis [2]	74.7

Literatürdeki halihazırda raporlanmış en iyi Mahalanobis uzaklığı tabanlı yöntemlerle karşılaştırıldığında YZM vektörlerinin en az diğer yöntemler kadar başarılı olduğu gözlenebilir. SIFT vektörleri ile yakın boyutlarda seçilen YZM vektörlerinin en az SIFT vektörleri kadar başarımlara ulaşması, tezin amaçlarından birisi olan YÇE probleminde YZM vektörlerinin kullanılabileceği tezini de doğrulamaktadır.

7. SONUÇ VE ÖNERİLER

Bu tez çalışmasında yüz çiftlerinin eşlenmesi problemi için Yerel Zernike Momentleri (YZM) vektörlerinin kullanıldığı yöntemler önerilmiştir. Önceki çalışmalarda yüz imgelerinden kişilerin kimlik tespitlerinde kullanılan ve yüksek sonuçlar veren YZM yönteminin, yüz çifti eşleme probleminde de başarıyla kullanılabileceği gösterilmiştir. Ayrıca YZM vektörlerinin direkt olarak kullanılması yerine metrik öğrenme yöntemleriyle birlikte kullanılarak ayırıcılıklarının da artırılabilceği gösterilmiştir.

Yüz çifti eşleme, yüz tanıma alanındaki popüler araştırma alanlarından birisidir. Problemin amacı eş ve eş olmayan şeklinde belirlenmiş etiketlere sahip yüz çiftlerinin ikili şekilde sınıflandırılması olarak açıklanmaktadır.

Tez çalışmasında bahsedilen yüz çifti eşleme problemine YZM vektörlerinin direkt olarak kullanılması yerine metrik öğrenme yöntemleri ile ayırıcılıklarının artırıldığı 2 ayrı yaklaşım önerilmiştir.

Tez çalışmasında önerilen yaklaşımlardan ilki L2-Norm Metrik Öğrenme (L2ML) yöntemidir. İlgili yöntem eş ve eş olmayan şeklinde etiketlenmiş yüz çiftlerine ait öznitelik vektörlerin ayırıcılıklarının artırıldığı yeni bir uzaya taşınmaları esasına dayanmaktadır. Yöntem eş olan vektör çiftlerin aralarındaki L2 norm uzaklığın en küçüklendiği, eş olmayan vektör çiftlerinin aralarındaki uzaklığını ise en büyüklendiği bir T dönüşüm matrisi bulmayı hedeflemektedir. Test için ayrılan yüz çiftlerine ait vektörler, eğitim aşamasında kullanılan imgelerden öğrenilen ilgili T matrisi ile çarpılmak suretiyle L2ML uzayına taşınmaktadır ve ayırıcılıkları artmaktadır. L2ML uzayına taşınan vektörlerin ikili sınıflandırılmasında L2 uzaklık ölçütünün yerine kosinüs uzaklığı kullanmanın da başarımı arttırdığı gözlenmiştir.

Çalışmada yüz çifti eşleme problemine getirilen ikinci yaklaşım ise Eşitlik Kısıtları ile Geniş Ölçekte Metrik Öğrenme (LSML) yöntemidir. İlgili yöntem eş ve eş olmayan vektörlerin aralarında hesaplanan ve konuyla ilgili çalışmalarda da sıkça kullanılan Mahalanobis uzaklıklarının eniyilenmesi prensibine dayanmaktadır. LSML yöntemi

literatürdeki diğer yöntemlerin aksine karmaşık matematiksel işlemler ya da defalarca tekrar eden iterasyonlar kullanmadan basit ve etkin bir şekilde vektörlerin ayırıcılığını arttırmaktadır. Yöntemin diğer yöntemlerden önemli bir farkı da daha az vektör çifti kullanarak eğitim aşamasını tamamlayabilmesidir, bu sayede Mahalanobis uzaklığı tabanlı diğer yöntemlerin aksine LFW veritabanının kısıtlandırılmış protokolünde iyi sonuçlar verebilmektedir. Yöntem eğitim aşamasında benzer yöntemlere kıyasla son derece hızlı bir şekilde dönüşüm matrisini oluşturmakta ve daha küçük boyutlardaki vektörler ile daha etkin bir şekilde sınıflandırma yapılmasına imkân tanımaktadır.

Önerilen bu çözümlerin çözümlere ait başarımlarının test edilmesi için tez çalışmasında Labeled Faces in the Wild (LFW) veritabanı kullanılmıştır. LFW'nin kısıtlandırılmış protokolünde 10-grup çapraz doğrulama yöntemi ile gerçekleştirilen testlerden elde edilen başarımlar, literatürdeki diğer yöntemlerle karşılaştırılmış ve sonuçlar raporlanmıştır. Kısıtlandırılmış protokolde eş ve eş olmayan çiftler tam olarak belirlenmiştir, yeni yüz çiftleri türetme ya da bazı zor yüz çiftlerini testlere dâhil etmeme imkanı yoktur. Kısıtlandırılmamış protokolde ise mevcut yüz çiftlerinin yeterli gelmediği yöntemlerin mevcut çiftlere ekleme yapmalarına izin verilmektedir. Tez çalışmasında kısıtlandırılmış protokol kullanılmaktadır. Bu sayede elde edilen başarımlar farklı yöntemlerle üretilen sonuçlar ile eşit şartlarda ve kolaylıkla karşılaştırılabilmektedir.

Çalışmada öncelikle veritabanındaki etiketlenmiş yüz imgeleri öncelikle uygun şekilde kesilmiş, hizalanmış, yüzlerin dışında kalan arka plan maskelenmiş ve son olarak normalize edilmek suretiyle imgelere yapılan ön işlemler tamamlanmıştır. Yapılan testlerde imgelere yapılan ön işlemlerin başarımları olumlu etkilediği gözlenmiştir. Ön işlemlerin ardından elde edilen kesilmiş yüz imgelerinden YZM ve YİÖ yöntemleri kullanılarak öznelik vektörleri çıkartılmıştır. Çıkartılan bu öznelik vektörlerinin ayırıcılıklarını kaybetmeden boyutlarının indirgenmesi TBA yöntemi sayesinde gerçekleştirilmiştir. L2ML ve LSML şeklinde belirtilen iki ayrı yaklaşımda kullanılmak üzere hazırlanan bu vektörler farklı algoritmalar için farklı parametreler kullanılarak oluşturulmuştur. Son olarak da ilgili vektörler bu iki metrik öğrenme yöntemine tabii tutulmuşlardır. Eğitim aşamasında öğrenilen dönüşüm matrisleri ile çarpılan YZM vektörleri hem L2ML hem de LSML uzayında daha ayırıcı bir hale getirilmiştir.

Yapılan çapraz doğrulama başarımlarına göre YZM vektörlerinin L2ML uzayına taşınmaları sayesinde %6-8 oranında başarımların artışı sağlanmıştır. L2ML uzayındaki YZM vektörleri, aynı uzaya taşınan YİÖ vektörlerinden biraz daha yüksek başarımlara ulaşmıştır. İncelenen çalışmalarda tek bir öznitelik çıkarma yöntemi ve tek bir sınıflandırıcı uzaklık ölçütünün yetersiz kaldığının görülmesi üzerine YZM ve YİÖ vektörlerinin hibrit olarak kullanılması test edilmiş ve elde edilen başarımlar %1 civarında yükselmiştir. Aynı L2ML uzayında olduğu gibi LSML uzayında da YZM vektörleri iyi sonuçlar elde etmiş, benzer çalışmalarda sıklıkla kullanılan SIFT vektörlerinden daha yüksek başarımlara ulaşılmıştır.

Gelecekte daha yüksek başarımlarına ulaşabilmek için ikiden fazla öznitelik çıkarma yönteminin, benzer şekilde iki veya daha fazla sınıflandırıcı ile birlikte harmanlanması planlanmaktadır. Daha yüksek işlem gücü ve bellek kaynaklarının mümkün olması durumunda, buna uygun seçilecek parametreler ile birlikte elde edilen başarımların da artacağı öngörülmektedir.

KAYNAKLAR

- [1] **Sariyanidi, E., Dagli, V., Tek, S.C., Tunc, B. ve Gokmen, M.** (2012). Local Zernike Moments: A new representation for face recognition, *ICIP*.
- [2] **Kostinger, M., Hirzer, M., Wohlhart, P., Roth, P.M. ve Bischof, H.** (2012). Large Scale Metric Learning from Equivalence Constraints, *CVPR*.
- [3] **Ojala, T., Pietikainen, M. ve Harwood, D.** (1996). A comparative study of texture measures with classification based on feature distributions, *Pattern Recognition*, 51–59.
- [4] **Jafri, R. ve Arabnia, H.R.** (2009). A Survey of Face Recognition Techniques, *Journal of Information Processing Systems*, 5(2), 41–68.
- [5] **Ahonen, T., Hadid, A. ve Pietikainen, M.** (2004). Face recognition with local binary patterns, *8th Eur. Conf. Computer Vision*.
- [6] **Zhang, B., Shan, S., Chen, X. ve Gao, W.** (2007). Histogram of Gabor Phase Patterns (HGPP) A Novel Object Representation Approach for Face Recognition, *IEEE Transactions on Image Processing*, 16(1), 57–68.
- [7] **Lowe, D.** (2004). Distinctive Image Features from Scale-Invariant Keypoints, *International Journal of Computer Vision*, 60(2), 91–110.
- [8] **Simonyan, K., Omkar, M.P., Vedaldi, A. ve Zisserman, A.** (2013). Fisher Vector Faces in the Wild, *British Machine Vision Conference*.
- [9] **Seo, H.J. ve Milanfar, P.** (2011). Face Verification Using the LARK Representation, *IEEE Transactions on Infor*, 6(4).
- [10] **Taigman, Y., Wolf, L. ve Hasner, T.** (2009). Multiple One-Shots for Utilizing Class Label Information, *BMVC*.
- [11] **Barreto, R.M., Ren, T.I. ve Cavalcanti, G.** (2013). L2-Norm Metric Learning Applied to Unconstrained Face Pair Matching, *ICIP*.
- [12] **Nguyen, H. ve Bai, L.** (2010). Cosine Similarity Metric Learning for Face Veri, *ACCV*.
- [13] **Weinberger, K., Blitzer, J. ve Saul, L.K.** (2006). Distance Metric Learning for Large Margin Nearest Neighbor Classification, *In Advances NIPS*.
- [14] **Davis, J.V., Kulis, B., Jain, P., Sra, S. ve Dhillon, I.S.** (2007). Information Theoretic Metric Learning, *IEEE International Conference of Machine Learning*.

- [15] **Guillaumin, M., Verbeck, J. ve Schmid, C.** (2009). Is that you? Metric Learning Approaches for Face Identification, *IEEE Intern. Conf. on Computer Vision*.
- [16] **Hu, M.K.** (1962). Visual Pattern Recognition by Moment Invariants, *IRE Transactions on Information Theory*, **8**(2), 469–481.
- [17] **Khontanzad, A. ve Hong, Y.H.** (1990). Rotation Invariant Image Recognition Using Features Selected via a Systematic Method, *Pattern Recognition*, **23**, 1089–1101.
- [18] **Phillips, P.J., Moon, H., Rauss, P.J. ve Rizvi, S.** (2000). The FERET evaluation methodology for face recognition algorithms, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, **22**(10).
- [19] **Huang, G.B., Ramesh, M., Berg, T. ve Miller, E.M.** (2007). Labeled Faces in the Wild: A Database for Studying Face Recognition in Unconstrained Environments, **Teknik Rapor**, University of Massachusetts.
- [20] **Beveridge, R., Bolme, D., Teixeira, M. ve Draper, B.** (2003). The CSU Face Identification Evaluation System, **Teknik Rapor**, Colorado State University Computer Science Department.

ÖZGEÇMİŞ

Ad Soyad: Şeref Emre Kahraman

Doğum Yeri ve Tarihi: İstanbul - 24 Mart 1989

E-Posta: kahramans@itu.edu.tr

Lisans: İstanbul Teknik Üniversitesi

Mesleki Deneyim ve Ödüller:

Temmuz 2011 - ...	Divit Dijital Video ve İmge Teknolojileri AR-GE Mühendisi
Haziran 2010-Temmuz 2011	Divit Dijital Video ve İmge Teknolojileri Yarı Zamanlı Yazılım Geliştiricisi
Temmuz 2009-Ağustos 2009	Türk Telekom Stajyer

TEZDEN TÜRETİLEN YAYINLAR/SUNUMLAR

- **Kahraman, S. E.**, Gökmen, M., Yerel Zernike Momentleri ve L2-Norm Metrik Öğrenmeyle Yüz Çifti Eşleme, 22. Sinyal İşleme ve Uygulamaları Kurultayı(SIU), 2014