

**YÜKSEK BOYUTLU MODEL GÖSTERİLİMİ YÖNTEMİ İLE
BÜYÜK ÖLÇEKLİ VERİ TABANLARINDA GÖRÜNTÜ ERİŞİMİ**

YÜKSEK LİSANS TEZİ

Önder ÖZÜTEMİZ

Matematik Mühendisliği Anabilim Dalı

Matematik Mühendisliği Programı

ARALIK 2015

**YÜKSEK BOYUTLU MODEL GÖSTERİLİMİ YÖNTEMİ İLE
BÜYÜK ÖLÇEKLİ VERİ TABANLARINDA GÖRÜNTÜ ERİŞİMİ**

YÜKSEK LİSANS TEZİ

**Önder ÖZÜTEMİZ
(509121059)**

Matematik Mühendisliği Anabilim Dalı

Matematik Mühendisliği Programı

Tez Danışmanı: Yrd.Doç.Dr. Burcu TUNGA

ARALIK 2015

İTÜ, Fen Bilimleri Enstitüsü'nün 509121059 numaralı Yüksek Lisans Öğrencisi **Önder ÖZÜTEMİZ**, ilgili yönetmeliklerin belirlediği gerekli tüm şartları yerine getirdikten sonra hazırladığı **“YÜKSEK BOYUTLU MODEL GÖSTERİLİMİ YÖNTEMİ İLE BÜYÜK ÖLÇEKLİ VERİ TABANLARINDA GÖRÜNTÜ ERİŞİMİ”** başlıklı tezini aşağıdaki imzaları olan jüri önünde başarı ile sunmuştur.

Tez Danışmanı : **Yrd.Doç.Dr. Burcu TUNGA**
İstanbul Teknik Üniversitesi

Jüri Üyeleri : **Doç.Dr. Ahmet Kırış**
İstanbul Teknik Üniversitesi

Yrd.Doç.Dr. Rüştü Murat Demirer
Üsküdar Üniversitesi

.....

Teslim Tarihi : **27 Kasım 2015**

Savunma Tarihi : **25 Aralık 2015**



ÖNSÖZ

Bu çalışmanın kısa sürede ortaya çıkmasında gerek tez konusunun belirlenmesi gerekse araştırma ve kontrol aşamasındaki emeklerinden dolayı tez danışmanım Yrd.Doç.Dr. Burcu TUNGA'ya teşekkür ederim.

Aralık 2015

Önder ÖZÜTEMİZ





İÇİNDEKİLER

	<u>Sayfa</u>
ÖNSÖZ	v
İÇİNDEKİLER	vii
KISALTMALAR	ix
ÇİZELGE LİSTESİ	xi
ŞEKİL LİSTESİ	xiii
ÖZET	xv
SUMMARY	xvii
1. GİRİŞ	1
1.1 Boyut İndirgeme Yöntemleri.....	2
1.1.1 Gúdúmsüz (Unsupervised) Boyut İndirgeme Yöntemleri.....	2
1.1.1.1 PCA.....	2
1.1.1.2 MDS.....	3
1.1.1.3 Çekirdek PCA.....	3
1.1.1.4 ISOMAP	3
1.1.1.5 LLE.....	4
1.1.1.6 LPP	4
1.1.2 Gúdúmlü (Supervised) Boyut İndirgeme Yöntemleri	4
1.1.2.1 FLDA.....	4
1.1.2.2 LFDA.....	4
2. YÜKSEK BOYUTLU MODEL GÖSTERİLİMİ YÖNTEMİ	7
2.1 Yüksek Boyutlu Model Gösterilimi	7
3. YBMG YÖNTEMİ İLE VERİ TABANINDA GÖRÜNTÜ ERİŞİMİ	13
3.1 Görüntü Arama İşlemi için YBMG Denklemine Yeniden Düzenlenmesi	13
3.2 Hata Analizi.....	15
4. YBMG YÖNTEMİ İLE VERİ TABANINDA GÖRÜNTÜ ERİŞİMİ UYGULAMALARI	19
4.1 Algoritma.....	19
5. DENEYSEL ÇALIŞMALAR VE DİĞER YÖNTEMLERLE KARŞILAŞTIRMA	21
5.1 YBMG Yöntemi ile Birebir Eşleme	28
5.2 YBMG Yöntemi ile Benzer Görüntülere Erişim.....	32
6. SONUÇ VE ÖNERİLER	37
KAYNAKLAR	39
ÖZGEÇMİŞ	41



KISALTMALAR

CBIR	: Content Based Image Retrieval
FLDA	: Fisher Linear Discriminant Analysis
HDMR	: High Dimensional Model Representation
ISOMAP	: Isometric Mapping
İTGE	: İçerik Tabanlı Görüntü Erişimi
LFDA	: Local Fisher Discriminant Analysis
LPP	: Locality Preserving Projections
LLE	: Locally Linear Embedding
MSE	: Mean Square Error
MDS	: Multidimensional Scaling
PSNR	: Peak Signal-to-Noise
PCA	: Principal Component Analysis
YBMG	: Yüksek Boyutlu Model Gösterilimi

ÇİZELGE LİSTESİ

	<u>Sayfa</u>
Çizelge 3.1: Şekil 3.1, Şekil 3.2 ve Şekil 3.3'teki görüntülere ait bağıl hata değerleri.	16
Çizelge 3.2: Şekil 3.1, Şekil 3.2 ve Şekil 3.3'teki görüntülere ait PSNR değerleri.	16
Çizelge 5.1: YBMG yönteminin COIL, COREL ve LFW veri tabanlarındaki tüm görüntülere uygulanması sonucu elde edilen birebir erişim sonuçları.	29
Çizelge 5.2: YBMG yönteminin COIL, COREL ve LFW veri tabanlarındaki PCA yönteminin kullanıldığı görüntülere uygulanması sonucu elde edilen birebir erişim sonuçları.	29
Çizelge 5.3: PCA yönteminin $k=0.9$ değeri için COIL, COREL ve LFW veri tabanlarındaki bazı görüntülere uygulanması sonucu elde edilen birebir erişim sonuçları.	31
Çizelge 5.4: YBMG yönteminin COIL veri tabanında değişik açılımlar için uygulanması ile ulaşılan sonuçlar.	33



ŞEKİL LİSTESİ

	<u>Sayfa</u>
Şekil 3.1 : Orjinal görüntü ve YBMG yaklaşımı örneği: Einstein.....	16
Şekil 3.2 : Orjinal görüntü ve YBMG yaklaşımı örneği: Lena.	17
Şekil 3.3 : Orjinal görüntü ve YBMG yaklaşımı örneği: Baboon.....	18
Şekil 5.1 : COIL veri tabanında bulunan bir objeye ait görüntü örnekleri.	23
Şekil 5.2 : COIL veri tabanında bulunan bir objeye ait görüntü ve YBMG yaklaşımı.	24
Şekil 5.3 : COREL veri tabanında bulunan bazı görüntü örnekleri.	25
Şekil 5.4 : COREL veri tabanında bulunan bir görüntü ve YBMG yaklaşımı.	26
Şekil 5.5 : LFW veri tabanında bulunan bazı görüntü örnekleri.....	27
Şekil 5.6 : LFW veri tabanında bulunan bir görüntü ve YBMG yaklaşımı. ...	28
Şekil 5.7 : COIL veri tabanında bulunan bir objeye ait 5, 10 ve 15 derece aralıkla yapılan bazı arama sonuçları (1).	34
Şekil 5.8 : COIL veri tabanında bulunan bir objeye ait 5, 10 ve 15 derece aralıkla yapılan bazı arama sonuçları (2).	35
Şekil 5.9 : COIL veri tabanında bulunan bir objeye ait 5, 10 ve 15 derece aralıkla yapılan bazı arama sonuçları (3).	36



YÜKSEK BOYUTLU MODEL GÖSTERİLİMİ YÖNTEMİ İLE BÜYÜK ÖLÇEKLİ VERİ TABANLARINDA GÖRÜNTÜ ERİŞİMİ

ÖZET

Gelişen ve giderek yaygınlaşan teknoloji ile birlikte görüntüleme aygıtlarından elde edilen görüntülerin sayısında meydana gelen dikkate değer artış, ortaya analiz edilmesi ve işlenmesi gereken devasa büyüklükte veri tabanları çıkarmıştır. Görüntü işleme alanında, örnek bir görüntünün var olan bir veri tabanında bulunup bulunmadığının tespit edilmesi ve bu işlemin mümkün olan en kısa sürede ve yüksek doğruluk oranıyla yapılması önemli bir çalışma başlığıdır. Bu alanda öne çıkan ve üzerinde çalışılan veri tabanını daha kolay işlenebilir hale getirmeye çalışan araştırma başlıklarından bir tanesi de boyut indirgeme çalışmalarıdır. Bu çalışmada bir boyut indirgeme yöntemi olarak Yüksek Boyutlu Model Gösterilim Yöntemi'nin (YBMG) görüntü arama alanında nasıl kullanılabileceği ve ne gibi sonuçlar elde edilebileceği üzerinde durulmuştur. YBMG yönteminin özü, işlemesi görece daha zor olan çok değişkenli bir fonksiyonun ya da veri kümesinin böl ve yönet ilkesi temelinde işlemesi daha kolay olan daha az değişkenli fonksiyonların ya da verilerin toplamı şeklinde yeniden ifade edilmesi prensibine dayanır. YBMG yönteminin görüntülerin daha düşük boyutlu olarak yeniden ifade edilmesi konusunda başarılı olduğu daha önce bu konuda yapılan araştırmalar tarafından gösterilmiştir. Gerçekleştirilen deneysel çalışmalar göstermiştir ki YBMG yönteminin ele alınan örnek bir görüntünün üzerinde çalışılan bir veri tabanında bulunup bulunmadığının tespit edilmesi, yani birebir eşleme ve bu örnek görüntüye benzer görüntülerin veri tabanından çekilmesi problemlerine bir çözüm olarak uygulanması ele alınan yöntemin gerek doğruluk hassasiyeti gerekse de işlem süresi bakımından dikkate değer avantajlar sağladığını göstermiştir. Deneyler sırasında çeşitli kategorilerde sınıflandırılabilir ve görüntü işleme çalışmalarında sıkça başvurulan toplamda 30301 adet renkli görüntü içeren COIL, COREL ve LFW veri tabanları kullanılmıştır. Karşılaştırma amacıyla yöntem olarak boyut indirgemeyi kullanan, öne çıkan yöntemlerden biri olan PCA yöntemi ele alınmıştır. YBMG yöntemi, gerçekleştirilen deneysel çalışmalarda kullanılan bütün veri tabanlarında aranan bir görüntünün söz konusu veri tabanında yer alıp almadığını, karşılaştırılan diğer yöntemden 3-5 kat kadar daha kısa sürede ve % 100 doğruluk oranıyla bulurken, örnek görüntüye benzer görüntülerin veri tabanından çekilmesi probleminde de dikkate değer sonuçlar elde etmiştir. Ele alınan yöntemin büyük veri tabanlarında görüntü erişimi alanında göstermiş olduğu bu başarı görüntü işleme araştırmalarının diğer önemli çalışma başlıklarından olan sınıflandırma ve yüz tanıma gibi daha ileri çalışmalar için pozitif motivasyon kaynağı olmaktadır.



HDMR METHOD ON IMAGE RETRIEVAL FROM LARGE-SCALE DATABASES

SUMMARY

As a result of the rapid change in developing and widespreading of the technological devices, the number of images obtained from these devices generates large-scale image databases which are needed to be analyzed and handled. In image processing field, retrieving of a pattern image in a database and performing this process with high accuracy and in a short time is a significant study topic. An outstanding search topic in this area which aims to make a database easy to study on is dimension reduction methods. In image processing researches, a dimension reduction method seeks a way to reduce the dimension of the image to manage the retrieval process efficiently as much as possible. One of the prominent methods in dimension reduction studies is High Dimensional Model Representation (HDMR) method. HDMR method was mooted for the first time in 1990 by Sobol's article named "On sensitivity estimation for nonlinear mathematical models" and generalized in 1999 by Rabitz's article named "General foundations of high-dimensional model representations". This method based on the idea that an integrable multi-variable function can be represented as a sum of the low variable functions. In this way, a dimension reduction in the function can be obtained.

The expansion of a given $f(x_1, \dots, x_N)$ function with N independent variables is as following.

$$f(x_1, \dots, x_N) = f_0 + \sum_{i_1=1}^N f_{i_1}(x_{i_1}) + \sum_{\substack{i_1, i_2=1 \\ i_1 < i_2}}^N f_{i_1 i_2}(x_{i_1}, x_{i_2}) + \dots + f_{12\dots N}(x_1, \dots, x_N) \quad (1)$$

The resulted HDMR components of the representation of the original function consist of a f_0 constant term, f_i univariate terms, f_{ij} bivariate terms and so on. The constant term represents the average impact of the data (consisted in the original function) on the HDMR representation, univariate terms represent the independent impacts of variables and the other terms with two or more variables represent the co-operative impact of related independent variables on the resulted HDMR approximation. Structurally univariate terms are vectors and other terms with more than two variables are matrix. In HDMR approximation at most bivariate terms are enough to reach an efficient approximation of the original multivariate function.

In this study, since images are used and they have three dimension, the number of independent variables N is took as 3. As a result, the HDMR expansion become as following.

$$f(x_1, x_2, x_3) = f_0 + \sum_{i_1=1}^3 f_{i_1}(x_{i_1}) + \sum_{\substack{i_1, i_2=1 \\ i_1 < i_2}}^3 f_{i_1 i_2}(x_{i_1}, x_{i_2}) \quad (2)$$

When the required calculations are done f_0 constant term, f_i univariate terms, f_{ij} bivariate terms are obtained as following.

$$f_0 = \sum_{k_1=1}^{n_1} \sum_{k_2=1}^{n_2} \sum_{k_3=1}^{n_3} \alpha_{k_1}^{(1)} \alpha_{k_2}^{(2)} \alpha_{k_3}^{(3)} f(x_1^{(k_1)}, x_2^{(k_2)}, x_3^{(k_3)}) \quad (3)$$

$$f_1(x_1^{(k_1)}) = \sum_{k_2=1}^{n_2} \sum_{k_3=1}^{n_3} \alpha_{k_2}^{(2)} \alpha_{k_3}^{(3)} f(x_1^{(k_1)}, x_2^{(k_2)}, x_3^{(k_3)}) - f_0 \quad (4)$$

$$f_2(x_2^{(k_2)}) = \sum_{k_1=1}^{n_1} \sum_{k_3=1}^{n_3} \alpha_{k_1}^{(1)} \alpha_{k_3}^{(3)} f(x_1^{(k_1)}, x_2^{(k_2)}, x_3^{(k_3)}) - f_0 \quad (5)$$

$$f_3(x_3^{(k_3)}) = \sum_{k_1=1}^{n_1} \sum_{k_2=1}^{n_2} \alpha_{k_1}^{(1)} \alpha_{k_2}^{(2)} f(x_1^{(k_1)}, x_2^{(k_2)}, x_3^{(k_3)}) - f_0 \quad (6)$$

$$f_{12}(x_1^{(k_1)}, x_2^{(k_2)}) = \sum_{k_3=1}^{n_3} \alpha_{k_3}^{(3)} f(x_1^{(k_1)}, x_2^{(k_2)}, x_3^{(k_3)}) - f_1(x_1^{(k_1)}) - f_2(x_2^{(k_2)}) - f_0 \quad (7)$$

$$f_{13}(x_1^{(k_1)}, x_3^{(k_3)}) = \sum_{k_2=1}^{n_2} \alpha_{k_2}^{(2)} f(x_1^{(k_1)}, x_2^{(k_2)}, x_3^{(k_3)}) - f_1(x_1^{(k_1)}) - f_3(x_3^{(k_3)}) - f_0 \quad (8)$$

$$f_{23}(x_2^{(k_2)}, x_3^{(k_3)}) = \sum_{k_1=1}^{n_1} \alpha_{k_1}^{(1)} f(x_1^{(k_1)}, x_2^{(k_2)}, x_3^{(k_3)}) - f_2(x_2^{(k_2)}) - f_3(x_3^{(k_3)}) - f_0 \quad (9)$$

$$(10)$$

In the above expressions, $f(x_1^{(k_1)}, x_2^{(k_2)}, x_3^{(k_3)})$ means the pixel value of the image, $\alpha_{k_1}^{(1)}$, $\alpha_{k_2}^{(2)}$ and $\alpha_{k_3}^{(3)}$ parameters mean the weight factors and n_i means the dimensions of the image. In this study α parameters are chosen as following.

$$\alpha_{k_i}^{(i)} = 1/n_i, \quad 1 \leq i \leq 3 \quad (11)$$

This thesis study aims to apply the basic idea of dimension reduction of the HDMR method as a solution to image retrieval from a large-scale database problem. Previous researches on applying the HDMR method on image processing studies showed that this method is successful in representation of images. During the performed experimental studies the pattern image and all images in the database work on were subjected to HDMR method to get HDMR terms of images. Bivariate terms were omitted to decrease the complexity. Then by calculating and comparing the angles between f_i vectors of the pattern image and all images in the database the target image was tried to find. The algorithm was setted to retrieval the image of the smallest angle

with the pattern image. Experimental results showed that f_3 terms fails but both of the f_1 and f_2 terms are prospering in retrieving the same image with the pattern image for all images in all databases. The length of f_1 and f_2 vectors are the same with the dimensions of the images. Therefore to reduce the complexity again only f_1 or f_2 terms were decided to use for retrieval. Use of which of f_1 or f_2 terms depends on the corresponding dimensions of the images. The term which has the smallest dimension was decided to use.

The HDMR method was used for two purpose in this study. First aim is to retrieve the same images from large scale databases by using a pattern image to determine if the pattern image exists in databases. It is a exact matching. The other purpose is retrieval of the similar images with the pattern image. To that end, images are seeked with specific angle intervals such as 0-5, 0-10, 0-15, 0-20 and 0-25 degree.

During the experiments the common databases for image processing researches of COIL, COREL and LFW were used to test the performance of the HDMR method in image retrieval. COIL database consists of 7,200 images from 100 objects. All objects have 72 different images which are obtained by rotating of the objects by 5 degree. COREL database consists of 9,870 different kind of images which are real or produced by computer. LFW database consist of 13,231 face images of famous people from worldwide range. In total there are 30,301 color images from different categories. The exact matching was studied on all databases but retrieval of similar images was studied only on COIL database.

For comparison purpose, PCA which is one of the leading dimension reduction methods was used. Since PCA method works with very large matrices on large scale databases, it could not be executed on the databases mentioned above. To overcome this problem, new sub databases are setted from the main databases and for fair comparison the HDMR method was also applied on this new databases.

At the end of the experiments it came to sight that the HDMR method is 100% successful in accuracy for retrieving the same image with the pattern image (exact matching) for all images from all databases mentioned above. In spite of this, the PCA method reached its highest accuracy with $k=0.9$ as 100% in LFW face database, but its accuracy results for COIL and COREL databases are 86.67% and 86.36% respectively.

Moreover the propopsed method is faster than the PCA method as 3-5 times in terms of the avarage image retrieval time per image. PCA method retrieves images from COIL, COREL and LFW sub databases averagely in 13.83, 21.37 and 34.12 miliseconds respectively when $k=0.9$ in the case it reaches its highest retrieval accuracy. On the other hand, HDMR method retrieves images from the same databases in 4.33, 5.14 and 6.65 miliseconds respectively.

HDMR method reached also remarkable results in the problem of retriving the similar images with the pattern from large-scale databases. The ratios of similar images retrieved over all images retrieved are 99.52% and 90.66% when the angle interval is chosen as 0-5 and 0-10 in COIL database.

This study points up the fact that the HDMR method is a very efficient method in image retrieval from large-scale databases. For advanced researches it can be applied to classificaiton and face recognition problems.



1. GİRİŞ

Görüntüleme cihazlarının çeşidi, kullanım yaygınlığı ve teknolojilerindeki son dönemde kaydedilen hızlı gelişmelerin bir sonucu olarak analiz edilmesi ya da üzerinde işlem yapılması gereken devasa büyüklükte veri tabanları ortaya çıktı. Bu durumla birlikte görüntülerin buldukları veri tabanlarından bulunup geri çağrılmaları üzerine yapılan akademik çalışmalar ve önerilen yöntemlerin sayısında da önemli bir artış gerçekleşti. [1]

Bir resmin içinde bulunduğu veri tabanından geri çağırılması probleminde kullanılan yaklaşımlar genel olarak iki sınıfa ayrılır [2]: resmin metinsel üst verisini temel alanlar [3, 4] ve resmin içeriği ile ilgili bilgileri temel alanlar [5–7]. Metinsel üst veri tabanlı yaklaşımda daha önceden tanımlayıcı bir metin iliştilmiş görüntüler klasik anahtar kelime ile arama yöntemi yardımıyla veri tabanından çağrılmaya çalışılır. Söz konusu yaklaşım, görüntüye metin iliştilme işlemi bunu gerçekleştiren kullanıcıya çok fazla bağımlı olduğundan ortaya resmin sistematik bir şekilde ve doğru kelimelerle tanımlanmamış olması, farklı kullanıcıların aynı görüntü için birbirinden farklı tanımlamalar kullanması ya da görüntüye herhangi bir tanımlayıcı metin iliştilmemesi gibi sorunlar çıkarması ve görüntüyü tanımlama işleminin zahmetli ve çok zaman gerektiren bir işlem olması nedeniyle arama sonucunun doğruluk yüzdesi ve arama süresi bakımından yeteri kadar verimli sonuçlar verememektedir. Buna karşın görüntünün içeriği ile ilgili bilgileri temel alan İçerik Tabanlı Görüntü Erişim (İTGE - CBIR) sistemleri görüntünün tanımlanması işlemini kullanıcı müdahalesinden bağımsız olarak görüntünün kendi içinde barındırdığı renk, doku ve şekil gibi temel özellikleri kullandığından çok daha başarılı sonuçlar vermektedir. İTGE yaklaşımının diğer önemli avantajı da metin tabanlı yaklaşımın aksine otomatik aramayı mümkün hale getirmesidir.

İTGE sistemlerinde veri tabanındaki görüntülere ve kullanıcı tarafından veri tabanında arama için seçilen görüntülere ait olan içerik temelli uygun özellikler elde edilir ve bu

özellikler kullanılarak işletilen arama süreci ile seçili görüntüye benzeyen görüntülere ulaşılmaya çalışılır. [8]

İTGE sistemleri esas olarak öznitelik bulma, benzerlik ölçümü ve ilişki geribildirimine üzerine kuruludur. [9] Görüntülerden elde edilen öznitelikler genellikle yüksek boyutludur. Çok sayıda görüntü içeren büyük veri tabanları üzerinde çalışma yapıldığında ortaya çıkan yüksek boyut sorunu sürdürülen çalışmanın performansını olumsuz etkileyecek bir düzeye ulaşır. Bu sorunun üstesinden gelmek için çeşitli boyut indirgeme yöntemleri önerilmiştir. Boyut indirgeme yöntemleri ile yüksek boyutlu asıl veri daha düşük boyutlu yapılara dönüştürülerek sürecin daha hızlı ilerlemesi sağlanabilmektedir.

1.1 Boyut İndirgeme Yöntemleri

Ele alınan bir yüksek boyutlu veri ya da fonksiyon, veri kaybına neden olmayacak şekilde, daha düşük boyutlu fonksiyon ya da veriler yardımıyla ifade edilerek, bu veri ya da fonksiyon üzerinde yapılan çalışmaların daha hızlı ve daha az maliyetli olacak şekilde gerçekleşmesi sağlanabilir. Boyut indirgeme yöntemleri öğrenme şekillerine göre gödümlü (supervised) ve gödümsüz (unsupervised) olarak ikiye ayrılabilir. [9]

1.1.1 Gödümsüz (Unsupervised) Boyut İndirgeme Yöntemleri

Gödümsüz boyut indirgeme yöntemleri giriş verisinin işlenmesi mantığı üzerine kuruludur. Yaygın olarak kullanılan gödümsüz boyut indirgeme yöntemleri Temel Bileşen Analizi (Principal Component Analysis - PCA) [10], Çok-boyutlu Ölçeklendirme (Multidimensional Scaling - MDS) [11] ve çekirdek PCA (kernel PCA) [12] olarak sıralanabilir. Bunların yanında son zamanlarda kullanılmaya başlanılan manifold öğrenme yöntemleri olan Isometric Mapping (ISOMAP) [13, 14], Locally Linear Embedding (LLE) [15], ve Locality Preserving Projections (LPP) [16] yöntemleri de gödümsüz boyut indirgeme yöntemi olarak değerlendirilir.

1.1.1.1 PCA

PCA yöntemi verideki değişimi mümkün olduğunca iyi tanımlayabilecek şekilde orijinal veriyi daha düşük boyutlu olarak ifade etmeye çalışır. Bunu da ele alınan verinin düşük boyutlu ifadesine ait bir lineer bazı verideki değişim

miktarını maksimize edecek şekilde bulmaya çalışarak yapar. [17] PCA yöntemi boyutu düşürülecek veriyi yeni bir koordinat sisteminde ifade eden bir lineer transformasyon yöntemidir. Bu koordinat sisteminde temel bileşen olarak adlandırılan birbirinden bağımsız yeni veri kümeleri orjinal verinin fonksiyonlarıdır. Veriye ait projeksiyonlardan elde edilen varyanslar tüm veriye ait kovaryans matrislerinden elde edilen özdeğer ve özvektörlerin hesaplanıp azalan özdeğerlere göre büyükten küçüğe olacak şekilde sıralanmasının ardından birinci koordinattan başlayarak sırasıyla bahsedilen koordinat sistemine dizilirler. [10] Küçük özvektörlere karşılık gelen özdeğerler silinerek boyut indirgeme yapılır. Bu işlemdeki silme işlemi sonrası kalan özdeğerlerin başlangıçtaki özdeğer sayısına oranı test aşamasında k olarak ifade edilecek ve 0.9 olarak kullanılacaktır.

1.1.1.2 MDS

MDS yöntemi boyutu indirgenmiş çok boyutlu uzaydaki noktalar arasındaki uzaklık ölçüsünü kullanarak karşılaştırılan nesnelere arasındaki benzerliği ya da benzemezliği belirlemeye çalışır. [18] Çok boyutlu ölçeklendirme yönteminde amaç çok boyutlu bir veride bulunan noktalar arasındaki uzaklığı koruyacak şekilde daha düşük boyutlu bir yapının oluşturulmasıdır. Buradaki uzaklık Öklid uzaklığıdır.

1.1.1.3 Çekirdek PCA

Çekirdek PCA yöntemi verilen uygun bir çekirdek fonksiyonu aracılığı ile PCA'nın çekirdek uzayında yeniden kurulmasını sağlayarak lineer olmayan veri üzerine çalışmayı görece daha basit bir hale getirir. [9]

1.1.1.4 ISOMAP

Ana fikri MDS algoritmasıyla aynıdır. Çok boyutlu verideki noktalar arasındaki uzaklığı kullanır. Bu uzaklık bilgisi iç çarpımlar şeklinde ifade edilen bir uzaklık matrisidir. Bu matrisin ayrıklaştırılması ile daha düşük boyutlu bir yapı elde edilir. MDS'den farklı olarak noktalar arasındaki uzaklık Öklid anlamında uzaklık değil nokta grafiğindeki en kısa mesafenin ağırlığıdır. [14]

1.1.1.5 LLE

Çok boyutlu veride bulunan tüm noktaların yakın komşuluklarında bulunan noktaların lineer kombinasyonlarını kullanarak her bir noktayı betimlemek için bir ağırlık fonksiyonu oluşturur ve öz vektör tabanlı optimizasyon tekniği yardımıyla bu noktalara ait düşük boyutlu bir yapı kurar. [15]

1.1.1.6 LPP

Veri kümesinde bulunan noktalara ait komşuluk bilgilerini birleştirerek bir grafik oluşturur. Bu grafiğe ait Laplace bilgisini kullanarak veri noktalarını daha düşük boyutlu bir alt uzaya eşleyen transformasyon matrisini hesaplar. Bu lineer transformasyon noktalara ait lokal komşuluk bilgisini korur. [16]

1.1.2 GÜDÜMLÜ (SUPERVISED) BOYUT İNDİRGEME YÖNTEMLERİ

Güdümlü boyut indirgeme yönteminde amaç yüksek boyutlu veride bulunan sınıf etiketli bilgiyi yakalayan düşük boyutlu gösterilim benzeri bir öngörücü yapı oluşturmaktır.

1.1.2.1 FLDA

FLDA (Fisher Linear Discriminant Analysis) sınıf içi dağılım matrisini minimize ederken sınıflar arası dağılım matrisini maksimize ederek projeksiyon matrisini elde etmeye çalışan bir lineer boyut indirgeme yöntemidir. [19]

1.1.2.2 LFDA

LFDA (Fisher Linear Discriminant Analysis) yöntemi FLDA yönteminin genişletilmiş halidir. Projeksiyon matrisi lokal sınıflar arası dağılım matrisininin maksimize ve lokal sınıf içi dağılım matrisinin de minimize edilmesi ile elde edilir. [20]

Boyut indirgeme problemlerinde kullanılan ve bu çalışmamızda görüntü işleme alanındaki bir uygulamasını ele alacağımız Yüksek Boyutlu Model Gösterilim (YBMG) yöntemi ilk olarak Sobol tarafından 1993 yılında yayınlanan “On sensitivity estimation for nonlinear mathematical models” [21] isimli makale ile ortaya çıkmıştır. Sobol bu makalede karesi integrei edilebilen çok değişkenli bir fonksiyonun daha az değişkenli fonksiyonların toplamı şeklinde ifade edilebileceğini öne sürmüştü ve bunun

ispatını yapmıştır. Sobol'un yalın haliyle öne sürdüğü yöntem daha sonra Rabitz'in [22] çalışmalarıyla geliştirilmiştir. Aynı zamanlarda Demiralp [23] ve grubunun katkıları ile de YBMG tabanlı birçok yeni yöntem geliştirilmiş ve bu yöntemler farklı mühendislik alanlarına uygulanmıştır [24].

YBMG yöntemi temel olarak böl ve yönet algoritmasını kullanır. Bu algoritma ile ele alınan çok değişkenli integre edilebilir bir fonksiyon sabit terim, tek değişkenli terimler, iki değişkenli terimler, benzer şekilde artan derecede çok değişkenli terimler ve en son ana fonksiyonun derecesi kadar değişkene sahip terimin toplamı şeklinde ifade edilerek yeniden yazılır. Burada derecesi iki ve ikiden büyük olan terimlerdeki değişkenler algoritmanın çıktısı üzerindeki etkileri bakımından birbiri ile ilişki halindedir.

YBGM yönteminin boyut indirgeme problemlerine uygulanabilmesi için ele alınan çok değişkenli fonksiyonun her bir bağımsız değişkene karşılık gelen değer kümelerinin Kartezyen çarpımlarının elemanları olarak betimlenebilecek sonlu sayıda noktalar kullanılarak ifade edilebilmesi gerekmektedir [24]. Bunun yanında bir sonraki bölümde de göreceğimiz üzere YBMG denkleminin sağ tarafı toplamsal genişleme şeklinde ifade edildiğinden ele alınan çok değişkenli fonksiyonun toplamsal özelliği arttıkça söz konusu yöntem ana fonksiyonun daha az değişkenli fonksiyonlar tarafından yeniden ifade edilmesi bakımından daha başarılı sonuçlar vermektedir.



2. YÜKSEK BOYUTLU MODEL GÖSTERİLİMİ YÖNTEMİ

YBMG yönteminin amacı iki ana bölümde incelenebilir: İlki analitik yapısı bilinen bir çok değişkenli fonksiyonu daha az değişken içeren fonksiyonların toplamı olarak yazmak; böylece verilen çok değişkenli fonksiyona yaklaştırım yapmaktır. İkincisi ise, analitik yapısı bilinen bir fonksiyon olmadığı durumda yani, bir veri kümesi verildiğinde ilgili veriye uygun bir analitik yapının ortaya çıkarılmasına yönelik bir yaklaştırım yapmaktır. YBMG yöntemi veri kümelerine uygulanırken [24] ilk olarak Kartezyen çarpım kümesinin noktaları şeklinde verilmiş olan çok değişkenli bir veri kümesi daha küçük değişkenli veri kümelerine ayrıştırılır. Daha sonra bu veri kümesinin her bir elemanı geçerli yöntemler yardımıyla interpolasyona tabi tutulur. Bu amaçla analitik yapıya dair yukarıda sözü edilen yaklaşımı elde etmek için YBMG açılımının sadece sabit, tek değişkenli ve iki değişkenli terimleri kullanılır. Burada tek değişkenli ve iki değişkenli terimlerle ifade edilmeye çalışılan, çok değişkenli fonksiyonun karşılık gelen bağımsız değişkenlere ait noktalardaki tek değişkenli ve iki değişkenli fonksiyon bileşenlerinin değerleridir. Ele alınan çok değişkenli verinin N boyutlu olduğu varsayılırsa, sadece sabit terim ve tek değişkenli terim kullanıldığında N tane bir boyutlu interpolasyon elde edilir. Eğer sabit ve tek değişkenli terimlere ek olarak iki değişkenli terim de kullanılırsa elde edilen interpolasyona $N(N-1)/2$ tane iki boyutlu eleman eklenecektir.

Bu çalışmada HDMR yönteminin veri üzerindeki bir uygulaması ele alınacaktır. İlerleyen bölümlerde ilk olarak HDMR yönteminin genel mantığı anlatılacak, sonrasında ise veri kümesine uygulanabilmesi için yöntemde gerçekleştirilen uyarlamalardan söz edilecektir.

2.1 Yüksek Boyutlu Model Gösterilimi

YBMG'nin verilen bir N bağımsız değişkene sahip $f(x_1, \dots, x_N)$ fonksiyona ait açılımı

$$f(x_1, \dots, x_N) = f_0 + \sum_{i_1=1}^N f_{i_1}(x_{i_1}) + \sum_{\substack{i_1, i_2=1 \\ i_1 < i_2}}^N f_{i_1 i_2}(x_{i_1}, x_{i_2}) + \dots + f_{12\dots N}(x_1, \dots, x_N) \quad (2.1)$$

şeklinde ifade edilir. Denklemde sağ tarafında bulunan f_0 terimi $f(x_1, \dots, x_N)$ fonksiyonunun ortalama değerini ifade eden sabit değişkeni, $f_{i_1}(x_{i_1})$ terimi her bir bağımsız x_{i_1} değişkeninin ortaya konmak istenen analitik yapı üzerindeki birbirinden bağımsız etkilerini ifade eden tek değişkenli, $f_{i_1 i_2}(x_{i_1}, x_{i_2})$ terimi x_{i_1} ve x_{i_2} değişkenlerinin birlikte yaptığı etkiyi ifade eden iki değişkenli ve benzer biçimde daha yüksek dereceye sahip terimler de artan sayıdaki bağımsız değişkenlerin yaklaşım istenen analitik yapı üzerindeki ortak etkilerini ifade eden çok değişkenli yapıları belirtirken son terim olan $f_{12\dots N}(x_1, \dots, x_N)$ ise tüm bağımsız değişkenlerin $f(x_1, \dots, x_N)$ fonksiyonu üzerindeki ortak etkisini ifade eden N değişkenli bileşeni temsil etmektedir. [25]

$f(x_1, \dots, x_N)$ fonksiyonu ve yukarıda sözü edilen terimlerin belirli bir $a_i \leq x_i \leq b_i$ aralığında karesi integrale edilebilen fonksiyonlar olduğu varsayılır ve bağımsız değişken sayısı bazında kendi aralarında iç çarpım anlamında birbirine diktirler ve dolayısıyla

$$(u, v) \equiv \int_{a_1}^{b_1} dx_1 \dots \int_{a_N}^{b_N} dx_N W(x_1, \dots, x_N) u(x_1, \dots, x_N) v(x_1, \dots, x_N) \quad (2.2)$$

koşulunu sağlarlar. Burada $u(x_1, \dots, x_N)$ ve $v(x_1, \dots, x_N)$ iki rastgele seçilmiş karesi integrale edilebilen çok değişkenli fonksiyonlardır ve ifadede görülen ağırlık fonksiyonu

$$W(x_1, \dots, x_N) \equiv \prod_{i=1}^N W_i(x_i), \quad x_i \in [a_i, b_i], \quad 1 \leq i \leq N \quad (2.3)$$

şeklinde tek değişkenli $W_i(x_i)$ ağırlık fonksiyonlarının çarpımı olarak ifade edilir ve bu fonksiyonlar YBMG yönteminde

$$\int_{a_i}^{b_i} dx_i W_i(x_i) = 1, \quad 1 \leq i \leq N \quad (2.4)$$

olarak tanımlanan ağırlık fonksiyonu üzerinde normalizasyon koşulunu sağlayacak şekilde seçilir. Bunun yanında YBMG denkleminin sağ tarafındaki bileşenlerin tek türlü belirlenebilmesi için gerekli olan integral altında yok etme koşulu da

$$\int_{a_{i_s}}^{b_{i_s}} dx_{i_s} W_{i_s}(x_{i_s}) f_{i_1 \dots i_k}(x_{i_1}, \dots, x_{i_k}) = 0, \quad i_1 \leq i_s \leq i_k \quad (2.5)$$

şeklinde ifade edilir. Söz konusu bileşenlerin belirlenebilmesi için bazı projeksiyonlar kullanılmaktadır. Sabit bileşen olan f_0 terimi

$$\mathcal{P}_0 g(x_1, \dots, x_N) \equiv \int_{a_1}^{b_1} dx_1 \dots \int_{a_N}^{b_N} dx_N W(x_1, \dots, x_N) g(x_1, \dots, x_N) \quad (2.6)$$

projeksiyon operatörü (2.1) denkleminin iki yanına yukarıda bahsedilen yok etme ve normalizasyon koşulları ile birlikte uygulandığında

$$f_0 = \mathcal{P}_0 f(x_1, \dots, x_N) \equiv \int_{a_1}^{b_1} dx_1 \dots \int_{a_N}^{b_N} dx_N W(x_1, \dots, x_N) f(x_1, \dots, x_N) \quad (2.7)$$

olarak elde edilir. Benzer yöntemle farklı $\mathcal{P}_{i_1, \dots, i_k}$ ($1 \leq i \leq N$) projeksiyon operatörleri kullanılarak (2.1) denklemindeki tek değişkenli ve iki değişkenli terimler de aşağıdaki şekilde elde edilir.

$$f_{i_1}(x_{i_1}) = \int_{a_1}^{b_1} \dots \int_{a_{i_1-1}}^{b_{i_1-1}} \int_{a_{i_1+1}}^{b_{i_1+1}} \dots \int_{a_N}^{b_N} dx_{i_1} W(x_1, \dots, x_N) f(x_1, \dots, x_N) - f_0 \quad (2.8)$$

$$f_{i_1 i_2}(x_{i_1}, x_{i_2}) = \int_{a_1}^{b_1} \dots \int_{a_{i_1-1}}^{b_{i_1-1}} \int_{a_{i_1+1}}^{b_{i_1+1}} \dots \int_{a_{i_2-1}}^{b_{i_2-1}} \int_{a_{i_2+1}}^{b_{i_2+1}} \dots \int_{a_N}^{b_N} dx_{i_1 i_2} W(x_1, \dots, x_N) f(x_1, \dots, x_N) - f_{i_1}(x_{i_1}) - f_{i_2}(x_{i_2}) - f_0 \quad (2.9)$$

(2.3)'te elde edilen ağırlık fonksiyonu bu denklemlerde yerine yazılarak

$$f_0 = \int_{a_1}^{b_1} dx_1 \dots \int_{a_N}^{b_N} dx_N \prod_{j=1}^N W_j(x_j) f(x_1, \dots, x_N) \quad (2.10)$$

$$f_{i_1}(x_{i_1}) = \int_{a_1}^{b_1} \dots \int_{a_{i_1-1}}^{b_{i_1-1}} \int_{a_{i_1+1}}^{b_{i_1+1}} \dots \int_{a_N}^{b_N} dx_{i_1} \prod_{\substack{i=1 \\ i \neq i_1}}^N W_i(x_i) f(x_1, \dots, x_N) - f_0 \quad (2.11)$$

$$f_{i_1 i_2}(x_{i_1}, x_{i_2}) = \int_{a_1}^{b_1} \dots \int_{a_{i_1-1}}^{b_{i_1-1}} \int_{a_{i_1+1}}^{b_{i_1+1}} \dots \int_{a_{i_2-1}}^{b_{i_2-1}} \int_{a_{i_2+1}}^{b_{i_2+1}} \dots \int_{a_N}^{b_N} dx_{i_1 i_2} \prod_{\substack{i=1 \\ i \neq i_1, i \neq i_2}}^N W_i(x_i) f(x_1, \dots, x_N) - f_{i_1}(x_{i_1}) - f_{i_2}(x_{i_2}) - f_0 \quad (2.12)$$

YBMG denkleminin sağ tarafındaki sabit, tek değişkenli ve iki değişkenli terimler bulunur. Daha fazla değişkene sahip terimler benzer şekilde tanımlanan operatörler yardımıyla bulunabilir. N boyutlu $f(x_1, \dots, x_N)$ fonksiyonuna ait yaklaşımdaki toplam terim sayısı $\binom{N}{0} + \binom{N}{1} + \binom{N}{2} + \dots + \binom{N}{N} = 2^N$ kadardır. Sonlu olan N sayısı arttıkça yöntemin hesaplaması gereken terim sayısı üstel olarak arttığından maliyet de üstel olarak artmaktadır. Ancak literatürde varolan çalışmalardan da rahatça görülebilir ki, YBMG açılımı en fazla ikili terimlerin içerildiği yaklaşım fonksiyonları ile oldukça başarılı yaklaşımlar yapabilmektedir. Demiralp [23] tarafından tanımlanan ve kesme yaklaşımları adı verilen yaklaşımlar aşağıda verilmektedir.

$$\begin{aligned}
s_0(x_1, \dots, x_N) &= f_0 \\
s_1(x_1, \dots, x_N) &= s_0(x_1, \dots, x_N) + \sum_{i=1}^N f_i(x_i) \\
s_2(x_1, \dots, x_N) &= s_1(x_1, \dots, x_N) + \sum_{\substack{i_1, i_2=1 \\ i_1 < i_2}}^N f_{i_1 i_2}(x_{i_1}, x_{i_2}) \\
&\vdots \\
s_k(x_1, \dots, x_N) &= s_{k-1}(x_1, \dots, x_N) + \sum_{\substack{i_1, \dots, i_k=1 \\ i_1 < \dots < i_k}}^N f_{i_1 \dots i_k}(x_{i_1}, \dots, x_{i_k})
\end{aligned}
\tag{2.13}$$

$1 \leq k \leq N$

Burada s_0 değişmez yaklaşımları s_1 birinci basamaktan YBMG yaklaşımı en genel tanımı ile s_k ise k. basamaktan YGMG yaklaşımı olarak adlandırılır. Yapılan bu işlem sonrasında $f(x_1, \dots, x_N)$ fonksiyonunun k.dereceden yaklaşımı

$$f(x_1, \dots, x_N) \approx s_k(x_1, \dots, x_N) \tag{2.14}$$

şeklinde ifade edilebilir. Bu çalışmada görüntüler üzerinde çalışacağımızdan ve dolayısıyla üç bağımsız değişken kullanacağımızdan YBMG yönteminde ikinci dereceye kadar olan terimler ulaşılmak istenen yaklaşım için yeterli olacaktır.

$$f(x_1, \dots, x_N) \approx s_2(x_1, \dots, x_N) \tag{2.15}$$

(2.13)'teki s_0 , s_1 ve s_2 değerleri (2.15)'te yerine konduğunda ve bağımsız değişken sayısı olarak $N = 3$ olarak alındığında

$$f(x_1, x_2, x_3) = f_0 + \sum_{i_1=1}^3 f_{i_1}(x_{i_1}) + \sum_{\substack{i_1, i_2=1 \\ i_1 < i_2}}^3 f_{i_1 i_2}(x_{i_1}, x_{i_2}) \tag{2.16}$$

ile ifade edilen ve bu çalışmanın uygulama kısmında kullanacağımız YBMG yaklaşımına ulaşılır.





3. YBMG YÖNTEMİ İLE VERİ TABANINDA GÖRÜNTÜ ERİŞİMİ

Görüntü işleme araştırmalarında örnek bir görüntünün ele alınan bir veri tabanında aranması önemli çalışma başlıklarından biridir. YBMG yöntemi kullanarak seçilen bir görüntünün verilen bir veri tabanında bulunup bulunmadığını tespit etmek mümkündür ve boyut indirgeme yöntemini kullanan diğer yöntemlerle karşılaştırıldığında hem doğru sonuç getirme yüzdesi hem de işlem süresi bakımından YBMG yöntemi daha başarılı sonuçlar vermektedir. Bu çalışmada üzerinde çalışılacak veri tabanında bulunan yapı olan görüntülerin sahip olduğu bilgi piksellerde kayıtlı üç boyutlu sonlu veri kümesi olduğundan YBMG yönteminin buna uygun olacak şekilde yeniden düzenlenmesi gerekmektedir.

3.1 Görüntü Arama İşlemi için YBMG Denkleminin Yeniden Düzenlenmesi

YBMG denkleminin gerçekleştirilecek testlerde kullanılacak son biçimini belirlemek üzere (2.10), (2.11) ve (2.12) ifadeleri görüntünün yapısına uygun olacak şekilde yeniden yapılandırılmalıdır [26]. Görüntüler üç boyutlu sonlu veri kümelerinden oluştuğundan x_1 , x_2 ve x_3 şeklinde üç tane bağımsız değişkene sahiptirler ve bu değişkenler sırasıyla n_1 , n_2 ve n_3 tane farklı değer alırlar. Sonlu sayıdaki noktalarla çalışma yapıldığından YBMG denkleminin integral yerine toplam sembolleri kullanılarak ifade edilmesi gerekmektedir. Bunun için (2.3) ifadesinde bulunan $W_i(x_i)$ ağırlık fonksiyonları Dirac delta fonksiyonlarının lineer kombinasyonu şeklinde ifade edilerek aşağıdaki şekilde seçilebilir [24].

$$W_i(x_i) \equiv \sum_{k_i=1}^{n_i} \alpha_{k_i}^{(i)} \delta(x_i - \xi_i^{(k_i)}), \quad x_i \in [a_i, b_i], \quad 1 \leq i \leq N \quad (3.1)$$

Bu ifade denklemdeki yerine yazılarak (3.2) denklemi Delta fonksiyonunun özelliklerinin yardımı ile

$$\int_{a_i}^{b_i} dx_i \sum_{k_i=1}^{n_i} \alpha_{k_i}^{(i)} \delta(x_i - \xi_i^{(k_i)}) = \sum_{k_i=1}^{n_i} \alpha_{k_i}^{(i)} \quad (3.2)$$

olarak ifade edilebilir ve Dirac delta fonksiyonlarının katsayılarının lineer kombinasyonu üzerindeki bir koşul olarak aşağıdaki bağıntı elde edilir.

$$\sum_{k_i=1}^{n_i} \alpha_{k_i}^{(i)} = 1, \quad 1 \leq i \leq N \quad (3.3)$$

f_0 sabit değişkenini belirlemek için (2.10) denklemi (3.1) ifadesi denklemdeki yerine yazılarak yeniden yazılır.

$$f_0 = \int_{a_1}^{b_1} dx_1 \sum_{k_1=1}^{n_1} \alpha_{k_1}^{(1)} \delta(x_1 - \xi_1^{(k_1)}) \cdots \int_{a_N}^{b_N} dx_N \sum_{k_N=1}^{n_N} \alpha_{k_N}^{(N)} \delta(x_N - \xi_N^{(k_N)}) f(x_1, \dots, x_N) \quad (3.4)$$

Denklemdaki integral hesapları Dirac delta fonksiyonlarının özellikleri kullanılarak yapıldığında ve görüntülerimiz üç boyutlu olduğundan N değeri 3 olarak alındığında f_0 sabit değişken bileşeni

$$f_0 = \sum_{k_1=1}^{n_1} \sum_{k_2=1}^{n_2} \sum_{k_3=1}^{n_3} \alpha_{k_1}^{(1)} \alpha_{k_2}^{(2)} \alpha_{k_3}^{(3)} f(x_1^{(k_1)}, x_2^{(k_2)}, x_3^{(k_3)}) \quad (3.5)$$

olarak elde edilir. Benzer şekilde işlemler (2.11) denklemi üzerinde uygulandığına tek bağımsız değişkenli bileşenler

$$f_1(x_1^{(k_1)}) = \sum_{k_2=1}^{n_2} \sum_{k_3=1}^{n_3} \alpha_{k_2}^{(2)} \alpha_{k_3}^{(3)} f(x_1^{(k_1)}, x_2^{(k_2)}, x_3^{(k_3)}) - f_0 \quad (3.6)$$

$$f_2(x_2^{(k_2)}) = \sum_{k_1=1}^{n_1} \sum_{k_3=1}^{n_3} \alpha_{k_1}^{(1)} \alpha_{k_3}^{(3)} f(x_1^{(k_1)}, x_2^{(k_2)}, x_3^{(k_3)}) - f_0 \quad (3.7)$$

$$f_3(x_3^{(k_3)}) = \sum_{k_1=1}^{n_1} \sum_{k_2=1}^{n_2} \alpha_{k_1}^{(1)} \alpha_{k_2}^{(2)} f(x_1^{(k_1)}, x_2^{(k_2)}, x_3^{(k_3)}) - f_0 \quad (3.8)$$

ve (2.12) denklemi üzerinde uygulandığına iki bağımsız değişkenli bileşenler

$$f_{12}(x_1^{(k_1)}, x_2^{(k_2)}) = \sum_{k_3=1}^{n_3} \alpha_{k_3}^{(3)} f(x_1^{(k_1)}, x_2^{(k_2)}, x_3^{(k_3)}) - f_1(x_1^{(k_1)}) - f_2(x_2^{(k_2)}) - f_0 \quad (3.9)$$

$$f_{13}(x_1^{(k_1)}, x_3^{(k_3)}) = \sum_{k_2=1}^{n_2} \alpha_{k_2}^{(2)} f(x_1^{(k_1)}, x_2^{(k_2)}, x_3^{(k_3)}) - f_1(x_1^{(k_1)}) - f_3(x_3^{(k_3)}) - f_0 \quad (3.10)$$

$$f_{23}(x_2^{(k_2)}, x_3^{(k_3)}) = \sum_{k_1=1}^{n_1} \alpha_{k_1}^{(1)} f(x_1^{(k_1)}, x_2^{(k_2)}, x_3^{(k_3)}) - f_2(x_2^{(k_2)}) - f_3(x_3^{(k_3)}) - f_0 \quad (3.11)$$

$$(3.12)$$

olarak elde edilir. Bu denklemlerde yer alan $f(x_1^{(k_1)}, x_2^{(k_2)}, x_3^{(k_3)})$ ifadesi görüntünün ilgili pikseldeki değerini, $\alpha_{k_1}^{(1)}$, $\alpha_{k_2}^{(2)}$ ve $\alpha_{k_3}^{(3)}$ parametreleri bir önceki bölümde bahsedilen ağırlık faktörlerini ve n_i değerleri ele alınan görüntüye ait boyut bilgisini belirtmektedir. Bu çalışmada α parametreleri

$$\alpha_{k_i}^{(i)} = 1/n_i, \quad 1 \leq i \leq 3 \quad (3.13)$$

olacak şekilde seçilmiştir.

YBMG denkleminde bulunan f_0 sabit değişkeni ele alınan yöntemin uygulandığı görüntünün piksel bilgilerinin aritmetik ortalaması olarak bir sayı verirken f_1, f_2 ve f_3 terimleri her bir tek değişkenli bileşenin ulaşılmak istenen görüntünün HDMR yaklaşımına yaptığı bağımsız katkıları ifade eden vektörel yapıları, f_{12}, f_{13} ve f_{23} terimleri ise içerdikleri iki bağımsız değişkenin aynı yaklaşıma yaptıkları ortak katkıyı ifade eden matris yapılarını temsil eder. Burada f_i 'lerin toplanmasıyla tek değişkenli YBMG bileşenine ve f_{ij} 'lerin toplanmasıyla da iki değişkenli YBMG bileşenine ulaşılır. Sabit değişken ile birlikte bu tek ve iki değişkenli bileşenlerin toplamı bize ele alınan görüntünün ulaşılmak istenen HDMR yaklaşımını verir.

3.2 Hata Analizi

Boyut indirgeme yöntemi olarak YBMG yönteminin bir görüntüye yaklaşımda başarılı sonuçlar verdiği Şekil 3.1, Şekil 3.2 ve Şekil 3.3'e bakılarak anlaşılabilir. Bunun yanında hata analizi yapılarak da YBMG yönteminin performansı değerlendirilebilir. Bunun için kullanılacak verilerden biri orjinal görüntü ile YBMG yaklaşımına ait aşağıdaki bağıl hata hesabıdır.

$$N = \frac{\|f_{orjinal} - f_{YBMG}\|}{\|f_{orjinal}\|} \quad (3.14)$$

Bağıl hata hesabı daha ayrıntılı bir şekilde aşağıdaki şekilde yazılabilir.

$$N = \left[\frac{\sum_{k_1=1}^{n_1} \sum_{k_2=1}^{n_2} \sum_{k_3=1}^{n_3} \alpha_{k_1}^{(1)} \alpha_{k_2}^{(2)} \alpha_{k_3}^{(3)} [f_{orjinal}(x_1^{(k_1)}, x_2^{(k_2)}, x_3^{(k_3)}) - f_{YBMG}(x_1^{(k_1)}, x_2^{(k_2)}, x_3^{(k_3)})]^2}{\sum_{k_1=1}^{n_1} \sum_{k_2=1}^{n_2} \sum_{k_3=1}^{n_3} \alpha_{k_1}^{(1)} \alpha_{k_2}^{(2)} \alpha_{k_3}^{(3)} [f_{orjinal}(x_1^{(k_1)}, x_2^{(k_2)}, x_3^{(k_3)})]^2} \right]^{1/2} \quad (3.15)$$

Hata analizi için kullanılacak bir diğer yöntem de iki görüntünün kıyaslanmasında kullanılan PSNR (Peak Signal-to-Noise, Tepe Sinyal-Gürültü Oranı) yöntemidir.

$$PSNR = 10 \log_{10} \left[\frac{255^2}{MSE} \right] \quad (3.16)$$

Buradaki MSE (Mean Square Error - Karese Ortalama Hata) aşağıdaki gibi hesaplanır.

$$MSE = \frac{1}{n_1 n_2} \sum_{k_1=1}^{n_1} \sum_{k_2=1}^{n_2} [f_{orjinal} - f_{YBMG}]^2 \quad (3.17)$$


PSNR değeri ne kadar büyükse karşılaştırılan görüntüler birbirine o kadar benzerdir. Şekil 3.1, Şekil 3.2 ve Şekil 3.3'teki görüntülere ait bağıl hata ve PSNR değerleri Çizelge 3.1 ve Çizelge 3.2'de verilmiştir.

Çizelge 3.1: Şekil 3.1, Şekil 3.2 ve Şekil 3.3'teki görüntülere ait bağıl hata değerleri.

$N_{Einstein}$	N_{Lena}	N_{Baboon}
7.61e-14	1.28e-13	1.87e-14


Çizelge 3.2: Şekil 3.1, Şekil 3.2 ve Şekil 3.3'teki görüntülere ait PSNR değerleri.

$PSNR_{Einstein}$	$PSNR_{Lena}$	N_{Baboon}
286.77	278.28	285.56




Şekil 3.1: Orjinal görüntü ve YBMG yaklaşımı örneği: Einstein.

Çizelge 3.1'deki bağıl hata değerleri görüldüğü üzere çok küçüktür ve bu da YBMG yönteminin örnek görüntülerimiz olan Einstein ve görüntü işleme çalışmalarında çok kullanılan Lena ve Baboon görüntülerine yaklaşıtımda başarılı olduğunu gösterir. Aynı sonuca yine görüntü işleme alanında sıkça kullanılan başarıyı ölçmeyi amaçlayan Çizelge 3.2'deki PSNR değerlerinden de ulaşılabilir.



Şekil 3.2: Orjinal görüntü ve YBMG yaklaşırımı örneği: Lena.



Şekil 3.3: Orjinal görüntü ve YBMG yaklaşırımı örneği: Baboon.

Bölüm 4'te bu çalışmanın ana konusu olan YBMG yöntemi ile bir görüntünün belirli bir veri tabanında bulunup bulunmadığının tespit edilmesi ile ilgili uygulamalar ele alınacaktır.



4. YBMG YÖNTEMİ İLE VERİ TABANINDA GÖRÜNTÜ ERİŞİMİ UYGULAMALARI

Veri tabanlarında bir resmin var olup olmadığının belirlenmesi problemi görüntü işleme alanının önemli bir çalışma başlığıdır. Arama işlemi yapılırken gerek doğru sonuç getirmek gerekse de bu işlemi mümkün olan en kısa sürede yapmak suretiyle performansını arttırmak için kullanılan yöntemlerden bir tanesi boyut indirgeme yöntemidir. Bu yöntemle yüksek boyutlu veriler daha düşük boyutlu veriler şeklinde ifade edilerek işlem sayısı önemli oranda azaltılabilmektedir.

Bu bölümdeki uygulamalarda bir önceki bölümde bir resmin yeniden yapılandırılması için başarılı sonuçlar verdiği görülen ve bir boyut indirgeme yöntemi olan YBMG yöntemi kullanılacaktır.

4.1 Algoritma

İlk olarak veri tabanındaki resimler aynı boyutta değilse boyutlarının eşitlenmesi için yeniden boyutlandırma işlemine tabi tutularak YBMG yönteminin uygulanmasına hazır hale getirilir. Hesaplama karmaşıklığını azaltmak için denklemde yer alan iki değişkenli f_{ij} bileşenleri hesaplanmayacaktır. Görüntülere YBMG yöntemi uygulanarak sabit f_0 değişkeni ile bir değişkenli f_1, f_2 ve f_3 bileşenleri bulunur. Artık veri tabanındaki tüm görüntülere ait YBMG verileri elde edilmiştir. Veri tabanında var olup olmadığı bulunmak istenen örnek görüntü de aynı adımlardan geçirilerek ona ait YBMG verileri hesaplanır. f_1, f_2 ve f_3 bileşenleri vektörel yapıda olduğundan örnek görüntüye ait f_i vektörü ile veri tabanındaki her bir görüntüye ait f_i vektörü arasındaki açı hesaplanabilir. İki vektör arasındaki benzerliği ölçmek için kullanılan yöntemlerden biri de kosinüs benzerliği yöntemidir. Bu yöntem açılara karşılık gelen kosinüs değerlerini kullanırken, bu çalışmada yalnızca açı değerleri karşılaştırılmıştır. Burada i indisi 1,2 ve 3 değerlerini alacaktır ve açı hesabı yapılırken f_1 'ler, f_1 'ler ile, f_2 'ler, f_2 'ler ile ve f_3 'ler, f_3 'ler ile işleme sokulacaktır. Bu şekilde hesaplanan açılar her i değeri için görüntülerin veri tabanında buldukları yere ait indeks bilgileriyle

bağlantılı olacak şekilde ayrı bir diziye atılır. Birebir eşleme için her bir dizi içindeki en küçük açığa sahip indeks bulunarak bu indekse karşılık gelen görüntü ile örnek görüntünün aynı olup olmadığı kontrol edilir. Yapılan bu kontrol sonucunda eğer örnek görüntü ile veri tabanından getirilen görüntü aynı ise yöntemin o görüntü için başarılı farklı ise başarısız olduğu sonucuna ulaşılır. Veri tabanındaki örnek görüntüye benzer görüntülere ulaşmak için ise açı için bir eşik değeri belirlenir ve bu eşik değerinin altında kalan görüntüler veri tabanından çekilerek örnek görüntü ile karşılaştırılır. Bu karşılaştırma ile veri tabanından çekilen görüntülerin yüzde kaçının örnek görüntüye benzediği hesaplanır.

Benzer şekilde bir karşılaştırma işlemi örnek görüntünün ve veri tabanındaki görüntülerin f_0 sabit değişken değerleri arasında da yapılabilir. Yapılan deneysel çalışmalar her ne kadar f_0 değerlerinin karşılaştırılmasının çalışılan veri tabanlarında başarılı sonuçlar verdiğini gösterse de f_0 değerleri görüntüye ait piksel verilerinin aritmetik ortalamasını gösterdiğinden ve herhangi iki görüntüye ait bu aritmetik ortalamaların aynı olma ihtimali mümkün olduğundan güvenilir bir karşılaştırma ölçütü olarak değerlendirilmesi mümkün değildir.

Gerçekleştirilen deneysel çalışmalarda örnek görüntülere ve veri tabanlarındaki görüntülere ait f_3 vektörleri arasındaki açılar her zaman 0 ya da 180 derece olarak bulunmuştur. Yukarıda açıklanan algoritma en küçük açılı eşleşmenin tespiti üzerinden aranan görüntüye ulaşmaya çalıştığından ve büyük veri tabanlarında yapılan işlemlerde ilgili dizilerde pek çok 0 sonucu tespit edildiğinden sağlıklı bir arama işlemi için f_3 'lerin de kullanılmayacağı sonucuna varılmıştır.

YBMG denkleminin geriye kalan bileşenleri olan f_1 ve f_2 vektörleri ile yapılan çalışmalarda kullanılan tüm veri tabanlarında her iki vektörün de aranan görüntüyü bulmada % 100 başarılı olduğu görülmüştür. Ancak işlem sürelerinin kısaltılması için hangi bileşenin kullanılacağına karar verilmesi gerekmektedir. f_1 ve f_2 vektörlerinin uzunlukları ilgili görüntünün boyutlarıyla aynıdır. Bu nedenle algoritmayı daha hızlı çalışır duruma getirmek amacıyla hesaplama karmaşıklık düzeyini daha da düşürmek için bu iki vektörden boyutu küçük olanın kullanılmasına karar verilmiştir.

5. DENEYSEL ÇALIŞMALAR VE DİĞER YÖNTEMLERLE KARŞILAŞTIRMA

YBMG yönteminin örnek bir görüntünün ele alınan bir veri tabanında bulunup bulunmadığını tespit etme problemindeki performansını test etmek için çeşitli veri tabanları kullanıldı. Bunlardan COIL [27] veri tabanında 100 tane nesneye ait toplam 7200 adet 128x128 boyutunda renkli görüntü vardır. Her bir nesnenin kendi etrafında beşer derece döndürülmesiyle elde edilmiş toplam 72 tane birbirine benzeyen görüntüsü mevcuttur. COREL [28] veri tabanı gerçek ve bilgisayar yapımı çeşitli kategorilerdeki toplam 9870 renkli görüntüden oluşmaktadır. Buradaki görüntüler değişik boyutlardadırlar ve algoritma içerisinde boyutları 128x90 olacak şekilde ayarlanmıştır. Bu veri tabanına ait bir görüntünün ortalama bulunma süresine sözü edilen yeniden boyutlandırma da dahildir. LFW [29] veri tabanı çeşitli ülkelerdeki ünlü kişilere ait 250x250 boyutundaki 13231 adet renkli yüz görüntüsünden oluşmaktadır. Aşağıdaki şekillerde, kullanılan veri tabanlarında bulunan görüntü örnekleri ve bazı görüntülerin orjinalleri ile YBMG yaklaşımlarının karşılaştırılmasına dair örnekler bulunmaktadır.


Bu bölümde YBMG yöntemi ilk önce örnek bir görüntünün birebir eşleme ile ele alınan veri tabanında var olup olmadığının tespit edilmesi problemine uygulanacak. Daha sonra seçilen bir görüntüye benzer görüntülerin veri tabanından bulunup getirilmesi problemindeki performansı ele alınacaktır.

YBMG yönteminin bu problemlerdeki performansını değerlendirmek için, ulaşılan sonuçlar PCA yönteminden elde edilen sonuçlarla karşılaştırılmıştır. Birebir eşleme problemi için PCA yöntemi uygulanırken, testlerin gerçekleştirildiği bilgisayar yukarıda bilgisi verilen veri tabanlarındaki tüm görüntülerin kullanıldığı durumlarda yetersiz hafıza uyarısı verdiği için, COIL veri tabanından 3,600, COREL veri tabanından 5,000 ve LFW veri tabanından 5,000 görüntü kullanılmıştır. Ayrıca LFW veri tabanındaki görüntüler 125x125 olacak şekilde yeniden boyutlandırılmıştır. Bu

nedenle sađlıklı bir karřılařtırma yapmak amacıyla bu yeni alt veri tabanlarına YBMG yöntemi de uygulanmıřtır.

Testlerin yapıldığı bilgisayarın özellikleri řu řekildedir: Intel® Core™ i5-3210M (3.10GHz, 3MB Cache) iřlemci, 3.6 GB kullanılabilir RAM, Matlab R2015b






Şekil 5.1: COIL veri tabanında bulunan bir objeye ait görüntü örnekleri.



Şekil 5.2: COIL veri tabanında bulunan bir objeye ait görüntü ve YBMG yaklaşırımı.



Şekil 5.3: COREL veri tabanında bulunan bazı görüntü örnekleri.


Orjinal Görüntü



YBMG Yaklaşırımı



Şekil 5.4: COREL veri tabanında bulunan bir görüntü ve YBMG yaklaşırımı.



Şekil 5.5: LFW veri tabanında bulunan bazı görüntü örnekleri.



Şekil 5.6: LFW veri tabanında bulunan bir görüntü ve YBMG yaklaşırımı.

5.1 YBMG Yöntemi ile Birebir Eşleme

Birebir eşleme için YBMG yönteminin yukarıda bahsedilen veri tabanlarında bulunan tüm görüntüleri teker teker araması işleminin sonuçları Çizelge 5.1’de gösterilmiştir. Bu çizelgede Boyut kolonu veri tabanında bulunan görüntülerin boyutunu, Doğruluk kolonu veri tabanındaki tüm görüntülerin teker teker aranması işlemi sonucu görüntülerin yüzde kaçının doğru bir şekilde bulunduğunu ve Süre kolonu bir görüntünün bulunması için gereken ortalama süreyi milisaniye cinsinden belirtmektedir.

Doğruluk oranı (DO)şu şekilde hesaplanmıştır:

$$DO = \frac{EBG}{EBG + EBOG} \quad (5.1)$$

Burada EBG, Erişilen Benzer Görüntüler ve EBOG, Erişilen Benzer Olmayan Görüntüler anlamına gelmektedir.

Çizelge 5.1 ve Çizelge 5.2’in Doğruluk kolonundaki sonuçlara bakıldığında YBMG yönteminin bütün veri tabanlarında aranan görüntüleri % 100 doğruluk oranıyla bulduğu görülür. Veri tabanlarındaki görüntülerin gerçek ya da yapay, insan yüzü, nesne ya da doku örneği olmasının yöntemin başarısı üzerinde hiçbir olumsuz etkisi

Çizelge 5.1: YBMG yönteminin COIL, COREL ve LFW veri tabanlarındaki tüm görüntülere uygulanması sonucu elde edilen birebir erişim sonuçları.

Veri Tabanı	Boyut	Görüntü Sayısı	Doğruluk (%)	Süre (ms)
COIL	128x128	7200	100	6.61
COREL	128x90	9870	100	8.60
LFW	250x250	13231	100	23.40

Çizelge 5.2: YBMG yönteminin COIL, COREL ve LFW veri tabanlarındaki PCA yönteminin kullanıldığı görüntülere uygulanması sonucu elde edilen birebir erişim sonuçları.

Veri Tabanı	Boyut	Görüntü Sayısı	Doğruluk (%)	Süre (ms)
COIL	128x128	3600	100	4.33
COREL	128x90	5000	100	5.14
LFW	125x125	5000	100	6.65

bulunmamaktadır. Ele alınan örnek bir görüntü, üzerinde çalışılan veri tabanında mevcut ise YBMG yöntemi onu kesin bir şekilde bulabilmektedir.

Çizelge 5.3'te PCA yönteminin $k=0.9$ değeri için COIL, COREL ve LFW veri tabanlarındaki bazı görüntülere uygulanması sonucu elde edilen sonuçlar bulunmaktadır. Burada 60/100, 70/100, 80/100 ve 90/100 ifadeleri test için kullanılan alt veri tabanındaki görüntü sayısının orjinal veri tabanındaki görüntü sayısına oranını belirtmektedir. Kullanılan veri tabanlarının boyutu büyüdükçe PCA yönteminin kullandığı matrislerin boyutu da büyümektedir. Örneğin LFW veri tabanında bulunan görüntülerin tamamı üzerinde çalışıldığında, test/orjinal görüntü oranının 90/100 olması halinde ortaya yaklaşık 13231x11908 boyutunda devasa matrisler çıkmaktadır. Testlerin gerçekleştirildiği bilgisayar bu durumda yetersiz hafıza uyarısı vererek işlem yapmayı durdurduğundan daha düşük boyutlu matrislerle karşı karşıya gelmek için PCA yöntemi COIL'den 3600, COREL ve LFW'den 5000'er görüntü içeren alt veri tabanları üzerinde uygulanmıştır. Ayrıca COREL veri tabanındaki orjinal boyutu 250x250 olan görüntüler 125x125 olacak şekilde yeniden boyutlandırılmıştır. YBMG ile PCA yöntemleri arasında sağlıklı bir karşılaştırma yapabilmek için YBMG yöntemi bu alt veri tabanlarına da uygulanmıştır.

Çizelge 5.3'ten de takip edilebileceği gibi test/orjinal görüntü sayısı oranı arttıkça PCA yönteminin başarı oranı artmaktadır. Ancak test/orjinal görüntü sayısı oranındaki bu artış daha büyük matrislerle çalışmayı beraberinde getirdiğinden erişim işlemi için harcanan sürede de artmaya neden olmaktadır.

İki yöntemin birebir eşleme problemindeki doğruluk performanlarını karşılaştırdığımızda YBMG yöntemi tüm veri tabanlarında % 100 başarı ile çalışırken PCA yönteminin LFW veri tabanında aynı şekilde % 100 başarı ile çalıştığı halde, test/orjinal görüntü oranının 90/100 olduğu durumlarda bile COIL ve COREL veri tabanlarında sırasıyla % 86.67 ve %86.36 başarı oranıyla çalıştığı görülür.



Çizelge 5.3: PCA yönteminin $k=0.9$ değeri için COIL, COREL ve LFW veri tabanlarındaki bazı görüntülere uygulanması sonucu elde edilen birebir erişim sonuçları.

Veri Tabanı	Boyut	Görüntü Sayısı	Doğruluk (%)						Süre (ms)		
			60/100	70/100	80/100	90/100	60/100	70/100	80/100	90/100	
COIL	128x128	3600	76.67	80	85	86.67	9.38	10.31	13.94	13.83	
COREL	128x90	5000	74.07	79.34	83.30	86.36	12.05	18.90	14.15	21.37	
LFW	125x125	5000	100	100	100	100	18.29	21.53	25.08	34.12	

Büyük veri tabanlarında görüntü arama probleminde kullanılan yöntemin doğruluk yüzdesinin yanında bu işlemi ne kadar sürede gerçekleştirdiği de önemlidir. Bu süreyi etkileyen faktörler olarak veri tabanındaki görüntülerin boyutu, yeniden boyutlandırmaya ihtiyaç duyup duymaması ve toplam görüntü sayısı sayılabilir. Bu bölümün başında belirtildiği gibi bu çalışmada değişik boyutlarda ve sayılarda görüntü içeren veri tabanları kullanılmıştır. COIL veri tabanı 7,200 adet standart 128x128 boyutlu, LFW yüz veri tabanı 13,231 adet standart 250x250 boyutlu ve COREL veri tabanı 9,870 adet başlangıçta farklı boyuta sahip olan ama algoritma içinde 128x90 olacak şekilde yeniden boyutlandırılan renkli görüntülerden oluşmaktadır. YBMG yöntemi bir görüntüyü COIL, COREL ve LFW veri tabanlarındaki tüm görüntüler kullanıldığında ortalama olarak sırasıyla 6.61, 8.60 ve 23.40 milisaniyede bulup getirmiştir. LFW veri tabanındaki görüntülerin boyutu ve sayısı daha büyük olduğundan ortalama görüntü erişim süresi diğerlerinden daha uzundur.

YBMG ve PCA yöntemlerinin işlem süresi bakımından performansları, PCA yönteminin en yüksek doğruluk oranlarına ulaştığı test/orjinal görüntü sayısı oranlarına karşılık gelen süreleri baz alarak karşılaştırıldığında, YBMG yönteminin PCA yönteminden COIL, COREL ve LFW veri tabanlarında sırasıyla 3.19, 4.16 ve 5.13 kat daha hızlı çalıştığı sonucuna ulaşılr. Üstelik %100 doğruluk oranı ile.

Sonuç olarak denilebilir ki birebir eşleme probleminde YBMG yöntemi hem doğruluk oranı hem de gerekli işlem süresi bakımından PCA yönteminden çok daha başarılı sonuçlar vermektedir.

5.2 YBMG Yöntemi ile Benzer Görüntülere Erişim

Veri tabanında örnek bir görüntüye benzer görüntülere erişmek için (4.1) bölümünde anlatıldığı gibi açı için bir eşik değeri belirlenir ve bu eşik değerinin altında kalan görüntülerden yüzde kaçının örnek görüntüye benzediği hesaplanır. Buradaki deneysel çalışmalarda her bir objenin kendi etrafında beşer derece döndürülmesiyle elde edilmiş birbirine çok benzeyen 72 adet görüntüye sahip olduğu, 100 objeye ait toplam 7,200 görüntü içeren COIL veri tabanı kullanılmıştır. COIL veri tabanında bulunan her bir görüntü sırasıyla örnek görüntü olarak seçildikten sonra değişik eşik açı değerleri için veri tabanındaki benzer görüntüler çekilmiş, doğruluk oranı bulunmuş ve tüm görüntülerin doğruluk oranlarının ortalaması hesaplanmıştır.

Çizelge 5.4’de görüldüğü gibi COIL veri tabanındaki görüntüler için eşik değerleri 5, 10, 15, 20 ve 25 derece olarak belirlenmiştir.

Çizelge 5.4: YBMG yönteminin COIL veri tabanında değişik açı aralıkları için uygulanması ile ulaşılan sonuçlar.

Açı Aralığı	0-5	0-10	0-15	0-20	0-25
Doğruluk(%)	99.52	90.66	74.06	60.69	47.49
Süre (ms)	9.46	9.43	9.18	9.13	9.11






YBMG yöntemi benzer görüntülerin getirilmesinde en yüksek doğruluk oranına % 99.52 ile en küçük açı eşik değeri olan 5 derecede ulaşmıştır. Açı eşik değerleri arttıkça veri tabanından çekilen görüntüler içindeki örnek görüntüye benzemeyen görüntü sayısı arttığından bu oran giderek düşmektedir. Artan açı eşik değeri ile birlikte veri tabanından çekilen görüntülerdeki farklılaşmayı görmek için Şekil 5.7, Şekil 5.8 ve Şekil 5.9 incelenebilir. Bu şekillerde veri tabanından benzerleri getirilmek istenen örnek görüntü kırmızı çerçeve içine alınmıştır. Görüntüler satır boyunca örnek görüntü ile aralarındaki açı değeri artacak şekilde dizilmiştir.




0-5 Derece Aralığı




0-10 Derece Aralığı



Şekil 5.7: COIL veri tabanında bulunan bir objeye ait 5, 10 ve 15 derece aralıkla yapılan bazı arama sonuçları (1).



Şekil 5.8: COIL veri tabanında bulunan bir objeye ait 5, 10 ve 15 derece aralıkla yapılan bazı arama sonuçları (2).



Şekil 5.9: COIL veri tabanında bulunan bir objeye ait 5, 10 ve 15 derece aralıkla yapılan bazı arama sonuçları (3).

6. SONUÇ VE ÖNERİLER

Bu çalışmada çok büyük veri tabanlarında örnek olarak ele alınan bir görüntünün bulunup bulunmadığının tespit edilmesi ve bu görüntüye benzer görüntülerinin veri tabanından çekilmesi problemlerine yeni bir çözüm yolu olarak YBMG yöntemi önerilmiştir. Çok büyük veri tabanlarında yapılan işlemlerde üzerinde çalışılan nesnenin boyutunun yüksek olması performans üzerinde olumsuz bir etkiye sahip olduğundan boyut indirgeme yöntemleri öne çıkan önemli çalışma başlıklarındandır. Çok değişkenli fonksiyonların ya da veri kümelerinin daha az değişkenli fonksiyonların ya da veri kümelerinin toplamı şeklinde yeniden ifade edilmesi temeline dayanan YBMG yöntemi bir boyut indirgeme yöntemidir. Değişik boyutlardaki toplam 30,301 adet renkli görüntü içeren üç ayrı veri tabanında yapılan deneysel çalışmalar göstermiştir ki YBMG yöntemi, birebir eşleme probleminde, karşılaştırma için ele alınan diğer bir boyut indirgeme yöntemi olan PCA yönteminden çok daha başarılı bir şekilde çalışmaktadır. YBMG yöntemi, gerçekleştirilen deneysel çalışmalarda kullanılan bütün veri tabanlarında aranan bir görüntünün söz konusu veri tabanında yer alıp almadığını % 100 doğruluk oranıyla ve PCA yönteminden 3-5 kat kadar daha kısa sürede bulurken, örnek görüntüye benzer görüntülerin veri tabanından çekilmesi probleminde de dikkate değer sonuçlar elde etmiştir.

Bundan sonraki çalışmalarda görüntü işleme alanında öne çıkan diğer araştırma başlıkları olan benzer nesnelere sınıflandırılmaları ve yüz tanıma problemleri üzerinde durulacaktır. Bu çalışmada kullanılan veri tabanlarından biri olan ve insan yüzlerinden oluşan 13,231 renkli görüntü içeren LFW veri tabanında YBMG başarılı bir şekilde çalışarak tüm görüntüleri bulmuştur. Ancak bu uygulamanın yüz tanıma problemine bir çözüm olarak değerlendirilebilmesi için kullanılan yöntemin bir kişiye ait örnek görüntüleri kullanarak veri tabanında aynı kişiye ait diğer görüntüleri bulma becerisini gösterebilmesi gerekmektedir. Bu da gelecek araştırmaların konusu olacaktır.



KAYNAKLAR

- [1] **Foggia, P., Percannella, G. ve Vento, M.** (2014). Graph matching and learning in pattern recognition in the last 10 years, *International Journal of Pattern Recognition and Artificial Intelligence*, **28**(01), 1450001.
- [2] **Gupta, A. ve Jain, R.** (1997). Visual information retrieval, *Communications of the ACM*, **40**(5), 70–79.
- [3] **Ogle, V.E. ve Stonebraker, M.** (1995). Chabot: Retrieval from a relational database of images, *Computer*, **28**(9), 40–48.
- [4] **Lieberman, H., Rozenweig, E. ve Singh, P.** (2001). Aria: An agent for annotating and retrieving images, *Computer*, (7), 57–62.
- [5] **Flickner, M., Sawhney, H., Niblack, W., Ashley, J., Huang, Q., Dom, B., Gorkani, M., Hafner, J., Lee, D., Petkovic, D. ve diğerleri** (1995). Query by image and video content: The QBIC system, *Computer*, **28**(9), 23–32.
- [6] **Smeulders, A.W., Worring, M., Santini, S., Gupta, A. ve Jain, R.** (2000). Content-based image retrieval at the end of the early years, *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, **22**(12), 1349–1380.
- [7] **Rui, Y., Huang, T.S. ve Chang, S.F.** (1999). Image retrieval: Current techniques, promising directions, and open issues, *Journal of visual communication and image representation*, **10**(1), 39–62.
- [8] **da Silva Torres, R. ve Falcao, A.X.** (2006). Content-Based Image Retrieval: Theory and Applications., *RITA*, **13**(2), 161–185.
- [9] **Zhuo, L., Cheng, B. ve Zhang, J.** (2014). A comparative study of dimensionality reduction methods for large-scale image retrieval, *Neurocomputing*, **141**, 202–210.
- [10] **Hotelling, H.** (1933). Analysis of a complex of statistical variables into principal components., *Journal of educational psychology*, **24**(6), 417.
- [11] **Torgerson, W.S.** (1952). Multidimensional scaling: I. Theory and method, *Psychometrika*, **17**(4), 401–419.
- [12] **Schölkopf, B., Smola, A. ve Müller, K.R.** (1998). Nonlinear component analysis as a kernel eigenvalue problem, *Neural computation*, **10**(5), 1299–1319.
- [13] **Tenenbaum, J.B., De Silva, V. ve Langford, J.C.** (2000). A global geometric framework for nonlinear dimensionality reduction, *Science*, **290**(5500), 2319–2323.

- [14] **Balasubramanian, M. ve Schwartz, E.L.** (2002). The isomap algorithm and topological stability, *Science*, **295**(5552), 7–7.
- [15] **Roweis, S.T. ve Saul, L.K.** (2000). Nonlinear dimensionality reduction by locally linear embedding, *Science*, **290**(5500), 2323–2326.
- [16] **Niyogi, X.** (2004). Locality preserving projections, *Neural information processing systems*, cilt 16, MIT, s.153.
- [17] **van der Maaten, L.J., Postma, E.O. ve van den Herik, H.J.** (2009). Dimensionality reduction: A comparative review, *Journal of Machine Learning Research*, **10**(1-41), 66–71.
- [18] **Borg, I. ve Groenen, P.J.** (2005). *Modern multidimensional scaling: Theory and applications*, Springer Science & Business Media.
- [19] **Belhumeur, P.N., Hespanha, J.P. ve Kriegman, D.J.** (1997). Eigenfaces vs. fisherfaces: Recognition using class specific linear projection, *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, **19**(7), 711–720.
- [20] **Rahulamathavan, Y., Phan, R.C.W., Chambers, J., Parish, D.J. ve diğeri** (2013). Facial expression recognition in the encrypted domain based on local fisher discriminant analysis, *Affective Computing, IEEE Transactions on*, **4**(1), 83–92.
- [21] **Sobol', I.M.** (1990). On sensitivity estimation for nonlinear mathematical models, *Matematicheskoe Modelirovanie*, **2**(1), 112–118.
- [22] **Rabitz, H. ve Aliş, Ö.F.** (1999). General foundations of high-dimensional model representations, *Journal of Mathematical Chemistry*, **25**(2-3), 197–233.
- [23] **Demiralp, M.** (2003). High dimensional model representation and its application varieties, *Math. Res*, **9**, 146–159.
- [24] **Tunga, M.A. ve Demiralp, M.** (2008). A new approach for data partitioning through high dimensional model representation, *International Journal of Computer Mathematics*, **85**(12), 1779–1792.
- [25] **Li, G., Rosenthal, C. ve Rabitz, H.** (2001). High dimensional model representations, *The Journal of Physical Chemistry A*, **105**(33), 7765–7777.
- [26] **Altın, E.M. ve Tunga, B.** High Dimensional Model Representation in Image Processing.
- [27] **Columbia Object Image Library (COIL-100)**, <http://www1.cs.columbia.edu/CAVE/software/softlib/coil-100.php>, alındığı tarih: 23.11.2015.
- [28] **Wang, James**, <http://wang.ist.psu.edu/docs/related.shtml>, alındığı tarih: 23.11.2015.
- [29] **Huang, G.B., R.M.B.T. ve Miller, E.** (2007). Labeled Faces in the Wild: A Database for Studying Face Recognition in Unconstrained Environments, **Teknik Rapor07-49**, University of Massachusetts, Amherst.

ÖZGEÇMİŞ

Ad Soyad: Önder ÖZÜTEMİZ

Doğum Yeri ve Tarihi: Turhal 04.03.1982

Adres: Güzeltepe Mah. Yeni Okul Sok. No:10/1 Eyüp/İstanbul

E-Posta: ozutemizonder@gmail.com

Lisans: YTÜ Matematik Mühendisliği

Y. Lisans:

Mesleki Deneyim ve Ödüller:

Yayın ve Patent Listesi:

