

**KALİTE AĞIRLIKLANDIRILMIŞ ÖZDÜZENLEYİCİ HARİTALAR İLE
YÜZ SINIFLANDIRMA**

Mesut ÇEVİKER

**YÜKSEK LİSANS TEZİ
BİLGİSAYAR MÜHENDİSLİĞİ**

**GAZİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**OCAK 2011
ANKARA**

Mesut ÇEVİKER tarafından hazırlanan “KALİTE AĞIRLIKLANDIRILMIŞ ÖZDÜZENLEYİCİ HARİTALAR İLE YÜZ SINIFLANDIRMA” adlı bu tezin Yüksek Lisans olarak uygun olduğunu onaylarım.

Yrd.Doç.Dr. Hasan Şakir BİLGE

Tez Danışmanı, Bilgisayar Mühendisliği Anabilim Dalı

Bu çalışma, jürimiz tarafından oy birliği ile Bilgisayar Mühendisliği Anabilim Dalında Yüksek Lisans olarak kabul edilmiştir.

Doç.Dr. Ferda Nur ALPASLAN

Bilgisayar Mühendisliği Anabilim Dalı, O.D.T.Ü.

Yrd.Doç.Dr. Hasan Şakir BİLGE

Bilgisayar Mühendisliği Anabilim Dalı, G.Ü.

Prof.Dr. Şeref SAĞIROĞLU

Bilgisayar Mühendisliği Anabilim Dalı, G.Ü.

Tarih: 19 /01/2011

Bu tez ile G.Ü. Fen Bilimleri Enstitüsü Yönetim Kurulu Yüksek Lisans derecesini onamıştır.

Prof. Dr. Bilal TOKLU

Fen Bilimleri Enstitüsü Müdürü

TEZ BİLDİRİMİ

Tez içindeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edilerek sunulduğunu, ayrıca tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını bildiririm.

Mesut ÇEVİKER

**KALİTE AĞIRLIKLANDIRILMIŞ ÖZDÜZENLEYİCİ HARİTALAR İLE
YÜZ SINIFLANDIRMA
(Yüksek Lisans Tezi)**

Mesut ÇEVİKER

**GAZİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
Ocak 2011**

ÖZET

Kimlik doğrulamada neyi bildiğimize ya da neye sahip olduğumuza dayalı yöntemlerin zafiyetleri nedeniyle son yıllarda gerçekten kim olduğumuzu araştıran, biyometriklerimize dayalı yöntemler üzerinde çalışmalar yoğunlaşmıştır. Bu amaçla kullanılan biyometriklerden en fazla tercih edileni parmak izi ile birlikte yüz olmuştur. Daha önce belirli (deterministic) ya da belirsiz (nondeterministic) yöntemleri uygulayarak çalışan pek çok yüz tanıma sistemi geliştirilmiştir. Yüz tanıma sistemlerinin amacı hareketsiz bir görüntü ya da video görüntüsündeki bir kişiyi, var olan bir yüz veritabanını kullanarak buradaki kişilerden birisi ile eşleştirmektir. Bu tanımdan yüz görüntülerini sınıflandırmanın, yüz tanıma işleminde çekirdek konumundaki alt bir işlem olduğu anlaşılmaktadır. Gözlemler arası ilişkilerin doğrusal olmadığı durumlarda sınıflandırma probleminin çözümü için Yapay Sinir Ağı (YSA) türleri yaygın olarak kullanılmaktadır. Boyut indirgeme ve ilişkilerin soyutlanmasını başarıyla yapabilen Özdüzenleyici Harita (ÖDH), örüntü tanıma ve sınıflandırma işlemlerinde kullanılan bir YSA türü olmuştur. Bu çalışmada, ÖDH kullanılarak geliştirilen yeni bir yöntem ile yüzler sınıflandırılmakta ve elde edilen sonuçlara göre önerilen yöntemin başarısı diğer yöntemlerle karşılaştırılarak ortaya konmaktadır. Sonuçların elde edilmesi için Matlab'da bir uygulama geliştirilmiş, testler Yale B ve ORL yüz

veritabanları kullanılarak gerçekleştirilmiştir. Uygulama öncelikle kişilere ait veritabanındaki yüzlerin belirli bir kısmı ile ÖDH eğitimini gerçekleştirmekte ardından kişilere ait kalan yüzleri teste tabi tutmaktadır. Yüzler, boyutu kullanıcı tarafından belirlenmiş eşit büyüklükteki bloklara bölünmüş halde işleme tabi tutulmakta ve yüz bölgelerini içeren önemli bloklar sınıflandırmada daha fazla etkili olmaktadır. Yüz üzerinde aynı konumdaki bloklar kendileri arasında sınıflandırmaya tabi tutulurken, sınıf tayininde komşularının sınıfları da hesaba katılarak poz değişimi, kısmi kusurlar gibi durumları ele alan güvenli ve tutarlı bir sınıflandırma amaçlanmıştır. Başarım, test görüntüsünün ya da görüntü bloğunun ÖDH üzerinde en iyi eşlenen nörona yerleştirilmesi ardından bu nöronun eğitimde yerleştirilmiş sınıflara Öklid uzaklığı ile belirlenen sınıfının doğruluğuna göre değerlendirilmiştir. ORL yüz veritabanında %91,67 ve Yale B yüz veritabanında %86,10 oranlarında sınıflandırma başarısı sistemin 100 epok çalıştırılması sonucu elde edilmiştir, bu değerler önerilen yöntemin verimliliğini ortaya koymaktadır. Ayrıca testlerde harita boyutlarının, blok boyutlarının, öğrenmedeki epok sayısının ve komşu etki katsayısının başarıma etkisi araştırılmış, bu faktörler ile başarımlar arasında doğrusal bir ilişki olmadığı ancak maksimum başarı için en uygun değerlerinin var olduğu gözlemlenmiştir.

Bilim Kodu : 912.1.067
Anahtar Kelimeler : Özdüzenleyici haritalar, yüz sınıflandırma
Sayfa Adedi : 77
Tez Yöneticisi : Yrd. Doç. Dr. Hasan Şakir BİLGE

**FACE CLASSIFICATION USING QUALITY WEIGHTED
SELF ORGANIZING MAPS**

(M.Sc. Thesis)

Mesut ÇEVİKER

**GAZİ UNIVERSITY
INSTITUTE OF SCIENCE AND TECHNOLOGY**

January 2011

ABSTRACT

Due to the weakness of the methods based on what we know or what we have, in recent years studies for identification have concentrated on the methods researching really who we are based on our biometrics. The fingerprint and the face have been the biometrics mostly used for this purpose. Previously, many face recognition systems were developed implementing deterministic or nondeterministic methods. The goal of the face recognition systems is, to identify the person on a still image or video using an existing database of faces. From this definition it is understood that face classification is a sub process located on the core of the face recognition process. For the cases in which the relations among observations are nonlinear, problem solving using the variations of Artificial Neural Networks (ANN) have been frequently utilized. The Self Organizing Map (SOM) which can successfully do the dimension reduction and build abstraction on relationships among observations, is a type of ANN used for pattern recognition and classification. In this study face classification is performed by a newly developed method using the SOM and according to the results obtained, the success of the proposed method is demonstrated by comparing with other methods. In the study, an application on Matlab was developed to obtain the results, the Yale B and the ORL face databases were used for tests. The application firstly performs the education of SOM using

a specific percent of images then put the remaining faces to the test. Faces are processed after they are divided into user-defined and equal-sized blocks and the more important blocks picturing the face regions are more effective on classification result. The blocks at the same location on the face are classified among themselves and during determination of the best matching class, the class information of the neighboring blocks is taken into account and so that a safe, consistent classification handling cases like pose change, partial occlusions is aimed. Accuracy was evaluated according to the correctness of the class determined by the Euclidean distance between the best matching neuron position and positions of the class centers determined at training after the accommodating the face image to the best matching neuron. Classification successes of 91.67% for ORL face database and 86.10% for Yale B face database were obtained as a result of system run for 100 epochs , these values put forward the efficiency of the proposed method. In addition by the tests, the effects of dimensions of SOM, dimensions of the blocks, epoch count and neighbor effect coefficient on success were investigated and it is observed that there are no linear relationships between these factors and performance but there are optimum values of the factors for maximizing the performance.

Science Code : 912.1.067

Key Words : Self organizing maps, face classification

Page Number: 77

Advisor : Assist. Prof. Dr. Hasan Şakir BİLGE

TEŐEKKÜR

Çalıőmalarım boyunca deęerli yardım ve katkılarıyla ben yönlendiren Hocam Yrd. Doç. Dr. Hasan Őakir BİLGE'ye, yüksek lisans eęitimim süresince yardımlarını esirgemeyen hocalarım Prof. Dr. Őeref SAĐIROĐLU'na ve Doç. Dr. M. Ali AKCAYOL'a, manevi destekleriyle beni hiçbir zaman yalnız bırakmayan canım eőim Elife'ye ve çok deęerli aileme teőekkürü bir borç bilirim.

İÇİNDEKİLER

	Sayfa
ÖZET.....	iv
ABSTRACT	vi
TEŞEKKÜR.....	viii
İÇİNDEKİLER	ix
ÇİZELGELERİN LİSTESİ.....	xii
ŞEKİLLERİN LİSTESİ	xiii
RESİMLERİN LİSTESİ	xvi
SİMGELER VE KISALTMALAR.....	xvii
1. GİRİŞ	1
2. ÖZDÜZENLEYİCİ HARİTA (ÖDH)	14
2.1. ÖDH Yapısal Özellikleri.....	14
2.2. ÖDH Öğrenme Kuralı (Kohonen Öğrenme Kuralı).....	16
2.3. ÖDH Öğrenme Algoritmaları	17
2.3.1 ÖDH artırılmış öğrenme algoritması.....	17
2.3.2 ÖDH grup öğrenme algoritması.....	20
2.4. ÖDH Model Vektör Ağırlıkları İlk Değer Ataması	20
3. TEMEL BİLEŞEN ANALİZİ (TBA)	22
3.1. Ortalamaların Çıkartılması.....	23
3.2. Kovaryans Matrisinin Hesaplanması	24
3.3. Kovaryans Matrisine Ait Öz Vektör ve Öz Değerlerin Hesaplanması	25
3.4. Temel Bileşenlerin Seçilmesi ve Öznitelik Vektörlerinin Oluşturulması	26

Sayfa

3.5. Temel Bileşenlere Göre Yeni Veri Setinin Verilmesi	27
4. ÖZDÜZENLEYİCİ HARİTALAR İLE YÜZ SINIFLANDIRMA (ÖDHYS) ...	28
4.1. ÖDHYS Çalışmalarının Sınıflandırılması	28
4.1.1. ÖDH'ye yapısal değişiklikler uygulayan çalışmalar.....	28
4.1.2. ÖDH ile görüntüyü yeniden düzenleyen çalışmalar	29
4.1.3. Her bir sınıfa için ayrı bir ÖDH kullanan çalışmalar.....	29
4.2. ÖDH ile Geleneksel Yüz Sınıflandırma.....	29
5. KALİTE AĞIRLIKLANDIRILMIŞ ÖZDÜZENLEYİCİ HARİTALAR İLE YÜZ SINIFLANDIRMA (KAÖDHYS)	32
5.1. Yeni Önerilen Sistemde Uygulanan Yöntem.....	33
5.1.1. Görüntülerin okunması ve histogram hesitleme	33
5.1.2. Temel Bileşen Analizi (TBA) ve blokların eğitimi.....	33
5.1.3. Nöronların ön etiketlendirilmesi	37
5.1.4. Sınıf içi ve sınıflar arası harita yayılım indekslerinin hesaplanması....	37
5.1.5. Test görüntülerine ait blokların sınıflandırılması (ön sınıflandırılma).....	42
5.1.6. Blok sınıflandırma güvenilirlik puanlarının hesaplanması	43
5.1.7. Görüntü sınıflandırma sonucunun elde edilmesi.....	47
5.2. Geliştirilen Uygulamanın Çalışması	49
5.2.1. Sistem özelliklerin belirlenmesi ve görüntülerin okunması.....	49
5.2.2. Sınıflandırma adımları	51
5.2.3. Sonuçların raporlanması	52
6. GÖRSEL VE SAYISAL TEST SONUÇLARI	54
7. SONUÇ VE ÖNERİLER	70

	Sayfa
KAYNAKLAR	73
ÖZGEÇMİŞ.....	77

ÇİZELGELERİN LİSTESİ

Çizelge	Sayfa
Çizelge 1.1. İncelenilen yöntemlerin sınıflandırma başarıları	13
Çizelge 5.1. 16 Bloğa ayrılmış görüntüler için bir kişiye ait 4 test görüntüsünün ön sınıflandırma sonuçları.....	43
Çizelge 5.2. Görüntülerin 16 bloğa ayrıldığı bir test senaryosunda blok sınıflandırma güvenilirlik puanları.....	45
Çizelge 5.3. Veritabanından 20 kişi kullanan bir test senaryosunda 2.kişinin (sınıfın) görüntülerinin güvenilirlik puanları toplamı	47
Çizelge 5.4. Veritabanından 20 kişi kullanan bir test senaryosunda 2.kişinin test görüntülerinin normalize edilmiş güvenilirlik puanları toplamı	48
Çizelge 6.1. Blok boyutlarına göre görüntünün bölündüğü toplam blok sayısı.....	54
Çizelge 6.2. Literatürde ORL ve Yale B yüz veritabanlarında sınıflandırma başarıları	68

ŞEKİLLERİN LİSTESİ

Şekil	Sayfa
Şekil 1.1. ÖDH ile boyut indirgenmesi.....	4
Şekil 1.2. Şekil çıkarımı için sırt ve çukur operatörlerinin kullanılması	4
Şekil 1.3. Ağaç yapısında tasarlanmış ÖDH.....	5
Şekil 1.4. SOM-Face oluşturulması	6
Şekil 1.5. SOM-Face yaklaşımlarının birleştirilmesi.....	8
Şekil 1.6. LMSOM modelinde blokların eğitimi	9
Şekil 2.1. ÖDH temsili yapısı	15
Şekil 2.2. 6X6 ızgara topolojiye örnek.....	16
Şekil 2.3. 6X6 altıgensel topolojiye örnek	17
Şekil 2.4. Nöronlar arası Öklid bağıntısına göre belirlenmiş komşuluk kümesi örnekleri	18
Şekil 2.5. Nöronlar arası Manhattan bağıntısına göre belirlenmiş komşuluk kümesi örnekleri	19
Şekil 3.1. z ve t değişkenlerinin koordinat düzleminde gösterimi	24
Şekil 3.2. z ve t değişkenleri ve öz vektörler eğimindeki doğruların koordinat düzleminde gösterimi	26
Şekil 4.1. Geleneksel ÖDH ile yüz sınıflandırma aşamaları.....	30
Şekil 5.1. Kalite Ağırlıklandırılmış ÖDH'ler ile yüz sınıflandırma aşamaları	34
Şekil 5.2. Önerilen metotta blokların eğitimi.....	36
Şekil 5.3. Eğitilmiş ÖDH örnekleri.....	38
Şekil 5.4. Gözlemlerin orijine doğru taşınması.....	41
Şekil 5.5. Hesaplanmış örnek harita yayılım indeksleri.....	41

Şekil	Sayfa
Şekil 5.6. Sınıflandırma Güvenilirlikleri oranında ağırlıklandırılmış gri seviyeli yüz haritaları.....	46
Şekil 5.7. Kullanılan yazılım kütüphanesinin dosya sistemindeki yerinin belirlenmesi	49
Şekil 5.8. Yüz veritabanının dosya sistemindeki yerinin belirlenmesi	50
Şekil 5.9. Sistem değişkenleri giriş ekranı	51
Şekil 5.10. İşlemlerle ilgili bilgi verilmesi.....	52
Şekil 5.11. Sınıflandırma sonucu ekran görüntüsü	53
Şekil 6.1. ORL yüz veritabanı farklı blok boyutlarında sınıflandırma başarısı	55
Şekil 6.2. ORL yüz veritabanı farklı blok boyutlarında toplam işlem süresi.....	56
Şekil 6.3. ORL yüz veritabanı farklı epok sayılarında sınıflandırma başarısı	57
Şekil 6.4. ORL yüz veritabanı farklı epok sayıları için toplam işlem süresi	57
Şekil 6.5. ORL yüz veritabanı farklı ÖDH boyutlarında sınıflandırma başarısı.....	58
Şekil 6.6. ORL yüz veritabanı farklı ÖDH boyutlarında toplam işlem süresi	59
Şekil 6.7. ORL yüz veritabanı, farklı komşu etki katsayılarında sınıflandırma başarısı	60
Şekil 6.8. Yale B yüz veritabanı farklı blok boyutlarında sınıflandırma başarısı.....	61
Şekil 6.9. Yale B yüz veritabanı farklı blok boyutlarında işlem süresi.....	61
Şekil 6.10. Yale B yüz veritabanı farklı epok sayılarında sınıflandırma başarısı	62
Şekil 6.11. Yale B yüz veritabanı farklı epok sayılarında işlem süresi.....	63
Şekil 6.12. ORL Yale B yüz veritabanı farklı ÖDH boyutlarında sınıflandırma başarısı	64
Şekil 6.13. Yale B yüz veritabanı farklı ÖDH boyutlarında işlem süresi	64
Şekil 6.14. Yale B yüz veritabanı farklı komşu etki katsayılarında sınıflandırma başarısı	65

Şekil	Sayfa
Şekil 6.15. Yale B yüz veritabanında bir kişiye ait farklı pozlardaki yüz görüntülerinin eğitim sonrası harita üzerinde dağılımı	66
Şekil 6.16. ORL yüz veritabanındaki yüz görüntülerinin eğitim sonrası harita dağılımı	67

RESİMLERİN LİSTESİ

Resim	Sayfa
Resim 5.1. Yüz görüntülerine Histogram Eşitleme uygulanması	35
Resim 5.2. Yüz görüntüsünün bloklara ayrılması	35

SİMGELER VE KISALTMALAR

Bu çalışmada kullanılmış bazı kısaltmalar, açıklamaları ile birlikte aşağıda sunulmuştur.

Kısaltmalar	Açıklama
TBA	Temel Bileşen Analizi
ÇKP	Çok Katmanlı Perseptron
RTS	Radyal Tabanlı Sinir Ağı
KAÖDHYS	Kalite Ağırlıklandırılmış Özdüzenleyici Haritalar İle Yüz Sınıflandırma
KSA	Katmanlı Sinir Ağı
KOK	K-Ortalama Kümeleme
ÖDH	Özdüzenleyici Harita
ÖDHYS	Özdüzenleyici Haritalar İle Yüz Sınıflandırma
YS	Yüz sınıflandırma
YSA	Yapay Sinir Ağı
HE	Histogram Eşitleme
ST-SOM	Shape + Texture SOM
S-SOM	Shape-SOM
AHD	Average Hausdorff Distance
TS-SOM	Tree Structured SOM
ESOM	Ensemble of Self-organizing Maps
HSV	Hue-Saturation-Value
HLISSOM	Hierarchical Laterally Interconnected Synergetic SOM
S-LISSOM	Shape-LISSOM
LDA	Linear Discriminant Analysis
MSOM-Face	Multiple SOM-Face
k-NN	K Nearest Neighbors

Kısaltmalar**Açıklama****LMSOM**

Lateral Multiple SOM

LMSOM-Face

Lateral Multiple SOM-Face

FSOM

Fast SOM

CPN

Counter Propagation Network

MÖDH

Mahalanobis Özdüzenleyici Harita

ViSOM

Visualization-Induced SOM

gViSOM

Groving Visualization-Induced SOM

BMU

Best Matching Unit

1. GİRİŞ

Neyi bildiğimize ya da neye sahip olduğumuza göre kimlik doğrulaması yapan sistemlerin zafiyetlerine binaen gerçekten kim olduğumuza göre ya da farklı bir ifadeyle beden ve davranış karakteristiklerimiz olan biyometriklerimize göre kimlik doğrulaması yapan sistemler üzerindeki çalışmalar son yıllarda yoğunlaşmıştır. Yüz tanıma dayalı sistemler, güvenilirlik, sosyal kabul görme ve sistem maliyetinin ucuzluğu gibi faktörler göz önünde bulundurulduğunda parmak izi tanıma sistemleri ile birlikte diğer biyometriklere dayalı tanıma sistemlerine oranla daha fazla tercih edilmektedir [Abate ve ark., 2007].

Yüz tanıma işleminin amacı, hareketsiz bir görüntü ya da video görüntüsündeki bir kişiyi; var olan bir yüz veritabanına bakarak buradaki kişilerden birisi ile eşleştirmektir. Yüz sınıflandırma (YS) ise, bir yüz veritabanındaki yüz görüntülerinin ait oldukları kişiye göre sınıflara ayrılması işlemidir ve yüz tanıma işlemi için çekirdek konumdaki alt bir işlemidir. Literatürde yüz tanıma ve yüz sınıflandırma kavramlarının birbirinin yerine kullanımları mevcuttur [Tan ve ark., 2006].

Hesaplama yetisi olan birçok küçük işleme biriminden oluşan YSA, insan beyninin ve özellikle biyolojik sinir ağlarının çalışma prensiplerini (anlaşılabilirliği kadarıyla) örnek alarak geliştirilmiş hesaplayıcı bir yapıdır. YSA klasik sistemlere göre doğrusal olmama, öğrenme, genelleme yapma, adaptasyon, hata ve gürültüye karşı duyarlılık ve tolerans gibi önemli üstünlükler sunmaktadır. Bu üstünlükleri ile pek çok mühendislik dalında kullanılan YSA genellikle tahmin, sınıflandırma, veri yorumlama, veri filtreleme ve ilişkilendirme uygulamalarında kullanılmaktadır [Sağiroğlu ve ark., 2003]. Bir sinir ağı çeşidi olan Özdüzenleyici Harita (ÖDH) çok boyutlu ifade edilen gözlemlerin sınıflandırılması problemlerinde başarıyla uygulanabilmektedir ve bunlara yüz sınıflandırma işlemi de dahildir [Kohonen ve ark., 2002].

Gözlemlerin sınıflandırılması işlemi için pek çok sayıda teknik önerilmiş ve uygulanmıştır [Bowyer ve ark., 2006]. Bunlardan gözlemlerin çok sayıda ve doğrusal

olmayan özellikleri ile ifade edildiği sistemlerde, YSA ve çeşitlerini kullananlar gibi belirsiz (non-deterministic) sistemlerin; paralel işleme tabi tutma (uygun donanım sağlanması şartıyla), veri setinin beklenen özelliklerini göstermede karşılaşılan farklılık ve kusurlara olan yüksek tolerans, öğrenme ve genelleme gibi yönleri ile belirli (deterministic) sistemlere göre üstünlükleri görülmektedir [Liao ve Wen, 2007].

YS işlemi ile ilgili yapılan bir araştırmada bu konudaki yöntemler beş başlık altında toplanmıştır [Abate ve ark., 2007]: (a) doğrusal/doğrusal olmayan izdüşüm yöntemleri, (b) sinir ağları, (c) Gabor filtreleri ve dalgacıkları, (d) fraktallar ve tekrarlayan fonksiyon sistemleri, (e) termal ve hiperspektral analiz yöntemleri. Aynı konuda yapılan farklı bir araştırmada ise YS için kullanılan yöntemler görüntüden elde edilen bilginin kullanım şekline göre üç başlıkta toplanmıştır [Zhao ve ark., 2003]: (a) yüzün tamamını kullanan yöntemler, (b) yüze ait öznitelikleri kullanan yöntemler, (c) ilk iki yöntemin melezleri.

Kohonen tarafından 1982' de önerilen Özdüzenleyici Haritalar (ÖDH), çok boyutlu, karmaşık ve doğrusal olmayan istatistikî ilişkiler içeren veri kümelerinin daha az boyutta görüntülenmesini sağlayan sinir ağı modelleridir [Kohonen, 1998]. Kısa süre içerisinde yaygınlaşan ÖDH ve varyasyonları, sınıflandırma ve kümeleme işlemleri için çok farklı uygulama alanlarında kullanılmışlardır. Örüntü tanımda ve sınıflandırmada da ÖDH sıklıkla denenmiş ve bu alan ÖDH'nin temel kullanım alanlarından biri haline gelmiştir [Kaski ve ark., 1998].

Bu çalışmada, Özdüzenleyici Haritalar İle Yüz Sınıflandırma (ÖDHYS) işlemi için önerilmiş yeni bir yöntem anlatılmaktadır. Daha önce bu konuda yapılmış çalışmalar incelenmiş ve bu çalışmalarda etkili bulunan yaklaşımlar geliştirilerek daha başarılı, yeni bir yaklaşım önerilmiş ve bu sonuçlar doğrultusunda ortaya konmuştur.

ÖDH kullanılarak yapılmış YS çalışmalarındaki genel adımlar dikkate alındığında YS işlemi üç alt adıma bölünebilecektir;

Ön işleme (Boyut İndirgeme): Kullanılan yüz görüntülerinin vektörel hale getirilip bunlardan öznitelik vektörleri elde edilmesi işlemleri görüntü boyutlarının büyük

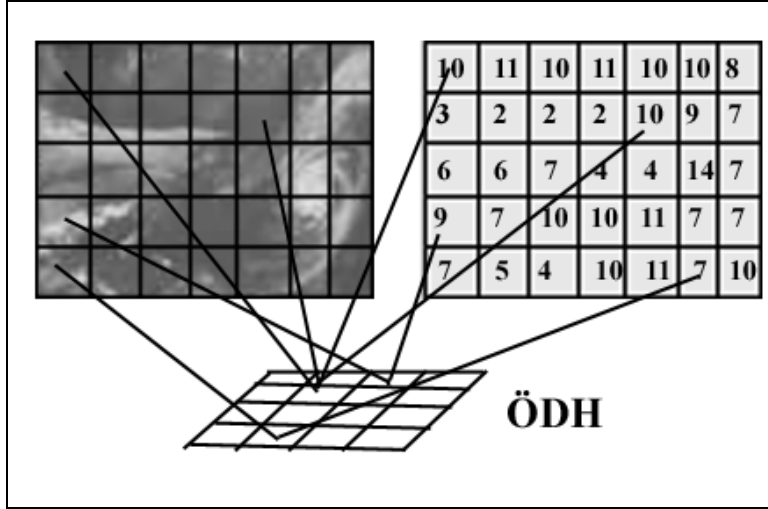
olduğu durumlarda oldukça maliyetlidir. Bu nedenle görüntülerin boyutlarının düşürülmesi, işlemlerin daha az zaman alması ve kaynak tüketmesi açısından ihtiyaç duyulan bir adımdır. Literatürde bu amaçla Temel Bileşen Analizi (TBA, Principal Component Analysis), ÖDH ve Çok Katmanlı Perseptron (ÇKP, Multi Layer Perceptron) kullanımı sıklıkla görülmektedir [Zhao ve ark., 2003].

Öz nitelik Vektörlerinin Sınıflandırılması: Çalışmalarda uygulanan temel algoritma bu adımda kullanılmakta olup öz nitelik vektörlerinin alınıp sonuç olarak test edilen görüntüye belirli bir sınıf tayin edilmesi aşamasıdır. İncelenen çalışmalarda bu adımda ÖDH veya yapısal olarak değişimlere uğratarak elde edilmiş yeni ÖDH türleri kullanılmıştır.

Son İşleme (Kümeleme): İncelenen tüm çalışmalarda benzer bir adım görülmemekle birlikte, yüz görüntülerinin ÖDH üzerine dağıtıldıktan sonra K-ortalama Kümeleme (KOK) ve benzeri kümeleme algoritmaları kullanılarak sınıflandırma sonuçlarının iyileştirilmesi başarı oranının artırılması için uygulanan bir adımdır [Haddadnia ve Ahmadi, 2004].

Son on yılda ÖDH ile yapılmış olan yüz sınıflandırma çalışmaları incelenmiş ve çalışmalarda izlenen yöntem ve teknikler çalışmaların yayınlanma tarihine (kronolojik sırasına) göre bölümün devamında aktarılmıştır.

İlk olarak, bir yüz sınıflandırma çalışması olmasa da yüz sınıflandırma çalışmaları öncesinde ÖDH'nin boyut indirgedeki kullanımını görmek için Honda ve arkadaşlarının çalışmasına değinmek yerinde olacaktır [Honda ve ark., 2000]. Çalışmada ardışık olarak çekilmiş olan uydu görüntülerini, çekildikleri andaki hava olaylarına göre sınıflandırmak için yaptıkları bir çalışmada öncelikle tüm görüntüleri $M \times N$ adet eşit büyüklükteki bloğa bölmüş ve her bir bloğu farklı bir görüntü gibi ele alıp gri seviyelerine göre bir ÖDH üzerine yansıtmışlardır. Bu sayede görüntüler içerdikleri blokların konumlarına karşılık gelen konumlarda kazanan nöron indekslerini tutan $M \times N$ boyutlarındaki matrisler ile ifade edilebilir hale gelmiş ve önemli bir boyut indirgeme söz konusu olmuştur. Anlatılan işlem Şekil 1.1'de gösterilmiştir.




Şekil 1.1. ÖDH ile boyut indirgenmesi

2001 yılında Alba ve arkadaşları ise ST-SOM (Shape + Texture SOM) adında yeni bir ÖDH tanımlamışlardır [Alba ve ark., 2001]. Bu çalışmada asıl olarak gülme, kızma gibi toplamda beş farklı durumu algılayıp hesaba dâhil ederek sınıflandırma yapılması amaçlanmıştır. Öncelikle şekil çıkarımı için sırt ve çukur operatörleri kullanılmış, Şekil 1.2.'de gösterildiği şekilde elde edilen yeni görüntüler ise S-SOM (Shape-SOM) adını verdikleri geçici bir ÖDH üzerine yansıtılmıştır. S-SOM'un normal ÖDH'den farkı vektörler arası uzaklık ölçümü için Öklid uzaklığı yerine AHD (Average Hausdorff Distance) kullanılmış olmasıdır. Şekil bilgisine ek olarak doku bilgisinin de sınıflandırmaya dahil edilmesi için görüntülere TBA uygulanmış ve S-SOM ile TBA sonuçlarını birleştirerek ST-SOM elde edilmiştir.



Şekil 1.2. Şekil çıkarımı için sırt ve çukur operatörlerinin kullanılması [Alba ve ark., 2001]

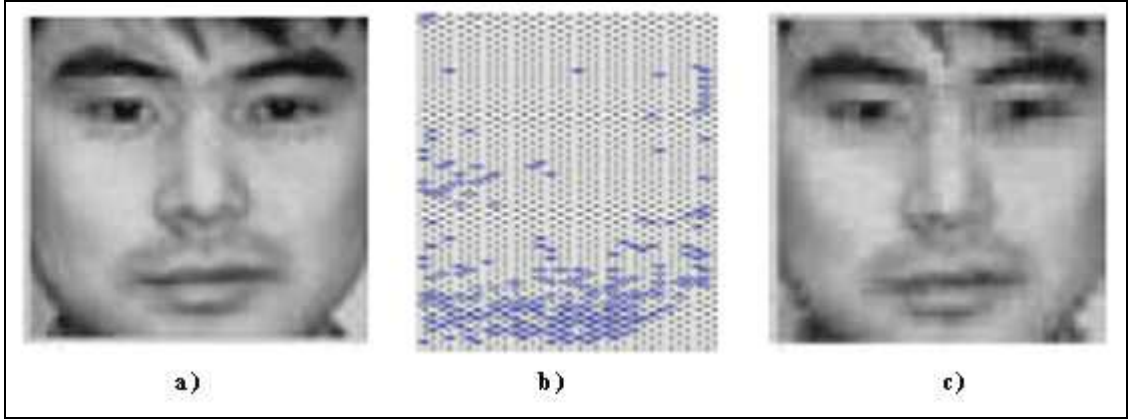
Daha önceki çalışmalarda farklı mimarilerde ÖDH tasarlanarak sınıflandırma çalışmaları da görülmektedir. Örneğin Ruiz-del-Solar ve Navarrete'nin yapmış oldukları bir çalışmada TS-SOM (Tree Structured SOM) adı altında ağaç (piramit) yapıda bir ÖDH önerilmiştir. Şekil 1.3'te görülebilen ÖDH şu şekilde çalışmaktadır; öncelikle yüz veritabanındaki görüntüler TBA ile boyut indirgemeye tabi tutulup en alt katmandaki ÖDH ile sınıflandırılmışlardır. Üst seviyelerdeki her nöron ise altındaki dört nörona bağlıdır ve bu dört nöronun ağırlıklarının TBA ile boyutlarının indirgenmesi ardından oluşan yeni ağırlıklarla eğitilmektedirler. Bu çalışmada önerilen sınıflandırma işleminde renk, doku gibi bilgisayarca algılanabilen özelliklerden faydalanmak yanında kullanıcı etkileşiminden de faydalanılmıştır ve TS-SOM'dan aramaların veriminin artırılmasında başarı ile kullanılmıştır [Ruiz-del-Solar ve Navarrete, 2002].



Şekil 1.3. Ağaç yapısında tasarlanmış ÖDH

Yüz tanıma sistemlerinde her zaman bir kişiye ya da sınıfa ait birden fazla yüz görüntüsü bulunamamakta ya da hafıza gereksinimleri nedeniyle sadece bir adet yüz görüntüsü saklanmaktadır. Literatürde bu durum üzerinde çalışmalar olmuştur. Tan ve arkadaşlarının yaptığı bir çalışmada veritabanındaki her bir kişi için bir adet yüz görüntüsünü kullanan Kernel-based SOM-Face yöntemi ile sınıflandırma önerilmiştir

[Tan ve ark., 2004]. Çalışmada öncelikle yüz görüntüleri eşit boyutlardaki $M \times N$ adet küçük bloğa ayrılmakta, ardından bu küçük blokların her biri farklı bir görüntü gibi ele alınıp ÖDH ile sınıflandırmaya tabi tutulmaktadır. Bloklara ait kazanan nöron indeksleri yeni oluşacak matriste blokların konumlarına yazılacak değerler olacak şekilde yüz görüntüleri artık $M \times N$ boyutlarındaki matrislerle ifade edilmektedirler. Yüzlerin ifade edilen bu yeni matrise SOM-Face adı verilmektedir [Tan ve ark., 2004]. SOM-Face oluşumu Şekil 1.4'de görülmektedir. Bu aşamadan sonra SOM-Face'ler Kernel-SOM ile sınıflandırılmaktadır. Kernel-SOM'da bilinen ÖDH'den farklı olarak eğitimden sonra ağırlıklar üzerinde bazı iyileştirmelerin yapıyor olmasıdır.



Şekil 1.4. SOM-Face oluşturulması a) Orijinal Yüz Görüntüsü b)Alt blokların harita üzerinde dağılımı c) Oluşturulan SOM-Face [Tan ve ark., 2004]

YS işleminde toplamda tek bir ÖDH kullanması halinde; yüz veritabanına yeni bir sınıf (kişi) eklendiğinde TBA gibi ön işleme adımlarının revize edilmesi gerekmektedir ve bu sistem için önemli bir dezavantajdır. Bu ekstra maliyetin üstesinden gelmek için her bir sınıf için adanmış ayrı bir ÖDH kullanılması iyi bir stratejidir. Cielniak and Duckett 2003 yılında yaptıkları çalışmalarında, bu stratejiden faydalanan ESOM (Ensemble of Self-organizing Maps) adını verdikleri bir ÖDH kümesi kullanmışlardır. Tüm beden görüntüsünü kullanarak sınıflandırma yapan sistemleri, kişinin baş, gövde ve ayaklarının HSV (Hue-Saturation-Value) renk uzayındaki koordinatlarının ortalama ve varyans değerlerinden oluşan 18 elamanlı öznitelik vektörlerini kullanmıştır [Cielniak ve Duckett, 2003].

Zhi ve Ming tarafından yapılan bir başka çalışmada ise ÖDH ve Dalgacık ağı kullanılarak, (özellikle dalgacık ağı yardımı ile) aynı sınıftaki görüntülere ait topolojik dağılımlar yanında onların genel benzerliklerini de hesaba katan bir yöntem önerilmiştir [Zhi ve Ming, 2005]. Çalışmada daha önce bebeklerin kişileri tanıma sistemlerini örnek alarak geliştirilmiş olan HLISSOM (Hierarchical Laterally Interconnected Synergetic SOM) yapısını temel alan S-LISSOM (Shape-LISSOM) adında yeni bir ÖDH tanımlamışlardır [Bednar ve Miikkulainen, 2003]. Dalgacık ağı ve ÖDH aracılığı ile elde edilen temsili yüzler ile öznitelik vektörü oluşturulmuş ve Mahalanobis uzaklığı esas alınarak sınıflandırma işlemi yapılmıştır.

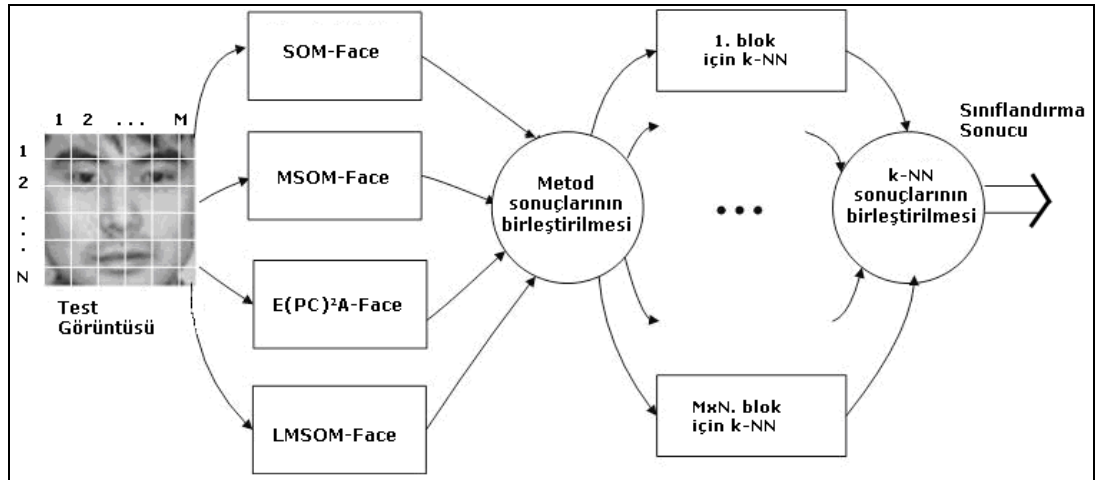
2005 yılında Santos ve Gonzaga tarafından yapılan bir çalışmada ise yüzlere öncelikle TBA ve ardından LDA (Linear Discriminant Analysis) uygulanarak öznitelik vektörleri oluşturulmuş ve ardından her bir sınıf için farklı bir ÖDH eğitilmiştir. Test işleminde yüzler tüm ÖDH'lerde test edilmiş ve ilgili yüze en yakın olan BMU (Best Matching Unit) bu tarama neticesinde bulunmuştur [Santos ve Gonzaga, 2005].

Tan ve arkadaşları 2005 yılında yaptıkları bir çalışmada MSOM-Face (Multiple SOM-Face) modeli olarak adlandırdıkları, SOM-Face modelini çoklu ÖDH ile uygulayarak yüz sınıflandırma işlemini yapmışlardır. Yüz görüntülerinin ÖDH üzerine yansıtıldıktan sonra bir sınıflandırma algoritması ile sınıflandırılarak sonuçların değerlendirilmesi örnekleri literatürde mevcuttur [Zhao ve ark., 2005]. Bu çalışmada da anlatılanlara ek olarak sınıflandırma işleminde sonuçlar K en yakın komşuluk(k-NN) ilişkisine göre elde edilmiştir [Tan ve ark., 2005].

Bazı tanıma sistemlerinde birden fazla sınıflandırıcının sisteme dahil olması da söz konusu olabilmektedir. Monteiro ve arkadaşları, ÖDH tabanlı dört sınıflandırıcıyı test eden bir çalışma yapmışlardır [Monteiro ve ark., 2006]. Çalışmadaki ilk sınıflandırıcıda eğitim esnasında ÖDH ağırlık güncellemesi yapılmadan kazanan nöronlar belirlenmiş ve bir nöron, kendisini BMU seçen sınıfların dağılımına göre etiketleme yapılmıştır (Örneğin x nöronu 2 defa 1.sınıf, 3 defa 2.sınıf bir görüntü için BMU olmuşsa 2.sınıf etiketi atanmaktadır). Test esnasında yüz görüntüsünün sınıfı doğrudan kazanan nöronun etiketlendiği sınıf olarak alınmıştır. İkinci sınıflandırıcıda

ise eğitim esnasında sınıflar harita üzerine dağıldıktan sonra KOK'a benzer bir yaklaşımla sınıf merkezlerine göre nöronlar etiketlenmiştir. Üçüncü sınıflandırıcıda öznitelik vektörüne sınıf bilgisi de dâhil edilerek eğitim yapılmış, test işleminde içinde sınıf bilgisi olmayan öznitelik vektörleri kullanılmıştır. Dördüncü sınıflandırıcıda ise her bir sınıf için ayrı bir ÖDH eğitilmiş ve test aşamasında BMU tüm ÖDH'ler gezilerek araştırılmıştır.


Birden fazla sınıflayıcının aynı anda sisteme dahil edildiği bir başka çalışma da, Tan ve arkadaşlarınınca 2006 yılında yapılmıştır. SOM-Face, MSOM-Face, $E(PC)^2A$ -Face ve yeni tanımlanmış oldukları LMSOM-Face (Lateral Multiple SOM-Face) modellerini birleştiren bir yaklaşım önermişlerdir. Çalışmada sınıflayıcıların sonuçları derlenmiş ve her bir blok için k-NN algoritması uygulanarak sonuçlar birleştirilmiştir. Sistemin blok diyagramı Şekil 1.5'te görülmektedir [Tan ve ark., 2006].



Şekil 1.5. SOM-Face yaklaşımlarının birleştirilmesi

LMSOM yapısında Şekil 1.6'da görüldüğü gibi yüz görüntüleri $M \times N$ adet alt bloğa ayrılmakta ve görüntülerin eğitilmesi için $M \times N$ adet farklı ÖDH kullanılmaktadır. Görüntü üzerinde aynı konumda yer alan tüm bloklar aynı ÖDH'de eğitilmektedirler. Test işleminde ise her blok için kendisiyle ilgili ÖDH'de BMU araştırılmakta ve yüz görüntüsü için tüm bloklarının en fazla atanan sınıfı sınıflandırma sonucu olarak alınmaktadır [Tan ve ark., 2006].

2006 yılında, Sagheer ve arkadaşlarınınca, ÖDH sınıflandırma performansının artırılmasını amaçlayan bir çalışma yapılmıştır. Bunu başarmak için FSOM (Fast SOM) adında yeni bir tür önermişlerdir. Çalışmalarındaki temel ilke daha önemli olan temel bileşenin sınıflandırmadaki etkinliğinin artırılmasıdır. Öncelikle yüz görüntülerine TBA uygulamışlar, temel bileşenleri sıralamışlar ve güncelleme esnasında, sıralamada daha önde gelen temel bileşenlere karşılık gelen ağırlıkları daha fazla değişikliğe uğratmışlardır. Sonuç olarak, tanıma başarısındaki küçük bir artışla birlikte işlem süresinde önemli bir kazanım elde ettiklerini ortaya koymuşlardır [Sagheer ve ark., 2006].



Şekil 1.6. LMSOM modelinde blokların eğitimi

Yüz sınıflandırmada pek çok farklı metodun yalın olarak veya birlikte kullanıldığı bir çalışma da Oravec ve Pavlovicova tarafından yapılmıştır [Oravec ve Pavlovicova, 2007]. Makaledeki ilk sınıflandırıcıda görüntü gri seviyelerine dayalı olarak ÇKP ve Radyal Tabanlı Sinir Ağı (RTS) ile sınıflandırma yapılmıştır. İkinci sınıflandırıcıda ise TBA uygulanması ardından eğitilen ve test edilen görüntüler arasındaki öklid uzaklığına dayanan bir sınıflandırma yapılmıştır. Üçüncü sınıflandırıcıda öncelikle yüz görüntüleri 16 adet eşit büyüklükteki alt bloğa bölünmüş ve ÇKP blok sıkıştırması uygulanmıştır. Sıkıştırma özete; alt bloklar ÇKP ile sınıflandırılmışlar ve ÇKP ile blokların almış oldukları sınıf etiketlerine göre yüz görüntüleri yeniden

oluşturulmuştur. SOM-Face yönteminde alt blokların sınıflandırılmasında ÖDH kullanılırken burada ÇKP kullanılmıştır. Bu sayede önemli ölçüde boyut indirgenmesi sağlanmıştır. Ardından bu yeniden oluşturulan görüntülerin sınıflandırılması TBA uygulanması ardından öklid uzaklığına bakılarak yapılmıştır. Dördüncü sınıflandırma yöntemi ise yine öncelikle ÇKP blok sıkıştırma ve ardından ÇKP ve RTS uygulanması adımlarından oluşmaktadır. Beşinci sınıflandırıcıda ise 64x60 boyutlarındaki giriş görüntüleri 64x60 – 48 – 64x60 boyutlarında bir ÇKP ile yeniden oluşturulmuş ve ardından ÇKP ve RTS ile sınıflandırma yapılmıştır. Altıncı sınıflandırmada ise önce SOM-Face oluşturulmuş ÇKP ve RTS ile sınıflandırma yapılmıştır.

Yüz sınıflandırma çalışmalarında karşılaşılan zorluklardan birisi de kişilerin hal ve duygularının farklılaşması ile birlikte yüz desenlerinin de farklılaşmasıdır. Bunun için kişilerin öfkeli, üzüntülü, uykulu olmak gibi farklı hallerdeki ifadelerinin sınıflandırılması üzerine çalışmalar yapılmıştır [Abate ve ark., 2007, Alba ve ark., 2001, Zhao ve ark., 2003]. Ishii ve arkadaşlarınca yapılan benzer bir çalışmada bir kişiye ait yüz görüntüleri öncelikle buldukları hallere göre ÖDH kullanılarak sınıflandırılmıştır [Ishii ve ark., 2008]. Bu sınıflandırma sonucu oluşan temsili yüz bilgisi ve belirttiği ifade bilgisi kullanılarak CPN (Counter Propagation Network) ile ifade haritası oluşturulmuştur. CPN'e kısaca değinilecek olursa, üç katmanlı bir yapıdır, ilk katmanda girdiler bulunmaktadır, ikinci katman ise girdilere karşılık gelen BMU'ların tutulduğu bir ÖDH'dir. Üçüncü katman Grossberg katmanıdır. Grossberg katmanında ÖDH üzerindeki nöronların sınıflara (duygulara) göre sınıflandırılması yapılmaktadır.

ÖDH'de yapısal bir değişiklik uygulayarak yeni bir ÖDH türü önermeye Aly ve arkadaşlarının yapmış olduğu bir çalışmada da rastlayabiliriz [Aly ve ark., 2008]. İlgili çalışmada öklid uzaklığı yerine Mahalanobis uzaklığı kullanılmış ve bu türe Mahalanobis Özdüzenleyici Harita (MÖDH) adı verilmiştir [Aly ve ark., 2008]. Bu çalışmada öncelikle TBA ile boyut indirgenmiş ardından MÖDH ile sınıflandırma tamamlanmıştır.

2009 yılında Huang ve Yin, 2002 yılında Yin tarafından önerilen Visualization-Induced SOM (ViSOM) türünü geliştirerek Genişleyen ViSOM (gViSOM) adında yeni bir tür önermişlerdir [Huang ve Yin, 2009]. Boyut indirgeme ve öznitelik vektörü çıkarımı adımlarında gViSOM'u kullanmış ve orijinal görüntü bilgisini korumada ve genel sınıflandırma başarısında yalın ÖDH'ye göre ViSOM ve gViSOM'un daha iyi olduklarını ortaya koymuşlardır. ViSOM bilinen ÖDH'den ağırlık güncellenmesi aşamasındaki farklılıklarla ayrılmaktadır. Kısaca değinmek gerekirse kazanan nöron ağırlıkları aşağıda verilmiş eşitliğe göre yapılmaktadır:

$$w_i(t+1) = w_i(t) + \alpha(t)[x(t) - w_i(t)] \quad (1.1)$$

Eş. 1.1'de $w_i(t)$ ağırlık vektörünün o artırımdaki değerini, $w_i(t+1)$ sonraki artırımdaki değerini, α komşuluk fonksiyonunu ve $x(t)$ kazanan nörona ait ağırlık vektörünü temsil etmektedir. Yenilikçi olan kısım, komşuluk kümesindeki nöronların ağırlık güncellemesi ise aşağıdaki eşitliklere göre yapılmaktadır:

$$w_l(t+1) = w_l(t) + \alpha(t)\mu(\varphi, l, t)[x(t) - w_l(t)] + \beta[w_l(t) - w_l(t)] \quad (1.2)$$

$$\beta = \frac{d_{vl}}{\delta\Delta_{vl}} - 1 \quad (1.3)$$

Burada $w_l(t)$ komşu nörona ait ağırlık vektörünün o artırımdaki değerini, $w_l(t+1)$ sonraki artırımdaki değerini, d_{vl} kazanan ve komşusu olan nöronlar arası veri uzayındaki uzaklığı, Δ_{vl} harita üzerindeki uzaklıklarını ve δ istenilen veri uzayı nöronlar arası uzaklığı belirleyen çözünürlük katsayısını ifade etmektedir. μ ise ÖDH'dekine benzer bir komşuluk fonksiyonudur. Güncellemedeki bu değişikliklerle ViSOM nöronlar arası uzaklığı düzenlemeyi ve niceme gürültüsünü (quantization error) en aza indirmeye çalışmaktadır. gViSOM için yapılan katkı ise güncelleme ardından harita boyutunun, istenilen nöronlar arası mesafeyi korumak için yeterli olmadığı durumlarda haritanın genişletilmesidir [Yin, 2002].

Çalışma kapsamında, Matlab ile Yale B ve ORL yüz veritabanları kullanılarak sonuçların test edildiği bir uygulama gerçekleştirilmiştir. ÖDH ile ilgili işlemler için

Helsinki Teknoloji Üniversitesi, Bilgi ve Bilgisayar Laboratuvarı tarafından geliştirilmiş olan SOM Toolbox 2.0 kütüphanesinden faydalanılmıştır [Vesanto ve ark., 2000]. Çalışmada ana hedef olarak yeni önerilen yaklaşımın başarısı, verimi ve kullanılabilirliği araştırılmış, bunun yanında eğitimde kullanılan gözlem oranının, harita boyutlarının, öğrenmedeki epok sayısının, öğrenme oranının ve harita komşuluk yarıçapının başarıma etkileri irdelenmiştir.

Çalışmada izlenen yöntem kısaca özetlenecek olursa; öncelikle dosyadan okunan yüz görüntülerinin boyutları çift doğrusal ara değer kestirim yöntemi ile küçültülmüş, Histogram Eşitleme ile kontrast iyileştirilmiş ve bu görüntüler boyutları sistem kullanıcısı tarafından belirlenen büyüklükteki bloklara ayrılmıştır. Ardından bu blokları ifade eden matrisler doğrusallaştırılarak elde edilen vektörler, TBA ile boyut indirgeme işlemine tabi tutulmuştur. Bloklara ait düşük boyutlu giriş vektörleri ile ÖDH'ler eğitilmiş ve eğitim sonrasında farklı sınıfların ÖDH üzerinde ne kadar yayıldığını ifade eden bir nevi sınıflandırma kalitesi olarak öngörölmüş *ÖDH dağılım dereceleri* hesaplanarak kaydedilmiştir. Bu çalışmanın özgün katkılarından biridir. Kişilere ait kalan yüzler de gerekli işlemlere tabi tutularak bloklara ayrılmış bir şekilde ÖDH'ler üzerine yansıtılarak blokların sınıflandırması yapılmış ve daha önceki adımlarda bulunan dağılım dereceleri ve komşu blokların sınıflandırma sonuçlarını dikkate alan bir yaklaşımla *blokların sınıflandırma doğruluk puanları* hesaplanmış ve kaydedilmiştir. Sınıflandırmada komşu blokların sınıflandırma sonuçlarının dikkate alınması çalışmanın diğer bir özgün yönüdür. Son olarak bir görüntünün tüm bloklarının sınıflandırma sonucuna bakılarak görüntünün sınıf tayini işlemi yapılmıştır.

Çalışmanın 2. bölümünde ÖDH ile ilgili açıklamalar ve matematiksel tanımlamalar yapılmakta, ayrıca önemli olduğu düşünülen konularla ilgili kısaca değerlendirmeler verilmiştir. 3. bölümde TBA ilgili tanımlamalar ve aşamaları hakkında detaylı bilgiler verilmiştir. 4. bölüm ÖDH ile yüz sınıflandırma işlemi için ayrılmış, bu işlem ile ilgili gerekli açıklayıcı bilgiler verilmiştir. 5. bölümde önerilen yöntemin uygulanmasının detaylı anlatımı verilmiş ve 6. bölümde ise yapılan çalışmanın görsel

ve sayısal sonuçları verilmiş, son bölümde sonuçlar ile ilgili değerlendirmeler yapılmakta ve öneriler sunulmuştur.

Çizelge 1.1. İncelenilen yöntemlerin sınıflandırma başarıları

Yöntem	Görüntü Kullanımı	Yüz Veritabanı	Başarı Oranı
Mahalanobis SOM [Aly ve ark., 2008]	Tüm yüz	CMU PIE	%95,00
FSOM [Sagheer ve ark., 2006]	Tüm yüz	CMU PIE	%63,90
SOM [Sagheer ve ark., 2006]	Tüm yüz	CMU PIE	%51,00
SOM [Aly ve ark., 2008]	Tüm yüz	CMU PIE	%46,00
MSOM-face [Tan ve ark., 2005]	Tüm yüz	FERET	%96,50
MSOM-faces fusion [Tan ve ark., 2006]	Tüm yüz	FERET	%90,50
LOG-kernel-SOM-face [Tan ve ark., 2004]	Tüm yüz	FERET	%89,50
LMSOM-face [Tan ve ark., 2006]	Yüz Bölümleri	FERET	%89,00
RBF-kernel-SOM-face [Tan ve ark., 2004]	Tüm yüz	FERET	%88,50
SOM-face [Tan ve ark., 2004]	Tüm yüz	FERET	%87,50
ST-SOM [Alba ve ark., 2001]	Tüm yüz	FERET	%80,00
blockSOM-RBF [Oravec ve Pavlovicova, 2007]	Tüm yüz	MIT	%80,23
blockSOM-MLP [Oravec ve Pavlovicova, 2007]	Tüm yüz	MIT	%79,95
ViSOM [Huang ve Yin, 2009]	Tüm yüz	ORL	%97,20
SOM [Huang ve Yin, 2009]	Tüm yüz	ORL	%96,80
KA ÖDH	Yüz Bölümleri	ORL	%91,67
SOM [Kumar ve ark., 2008]	Tüm yüz	ORL	%90,83
S-LISSOM+WN [Zhi ve Ming, 2005]	Tüm yüz	ORL	%90,80
LDA+SOM [Santos ve Gonzaga, 2005]	Tüm yüz	ORL	%90,80
RBF-SOM [Zhi ve Ming, 2005]	Tüm yüz	ORL	%84,10
SOM [Zhi ve Ming, 2005]	Tüm yüz	ORL	%83,30
SOM+PCA [Kumar ve ark., 2008]	Tüm yüz	ORL	%63,08
SOM-C2 [Monteiro ve ark., 2006]	Tüm yüz	YALE	%88,80
SOM-C4 [Monteiro ve ark., 2006]	Tüm yüz	YALE	%87,40
SOM-C1 [Monteiro ve ark., 2006]	Tüm yüz	YALE	%82,60
SOM-C3 [18 Monteiro ve ark., 2006]	Tüm yüz	YALE	%82,00
KA ÖDH	Yüz Bölümleri	YALE B	%86,10
SOM [Aly ve ark., 2008]	Tüm yüz	YALE B	%36,00

2. ÖZDÜZENLEYİCİ HARİTA (ÖDH)

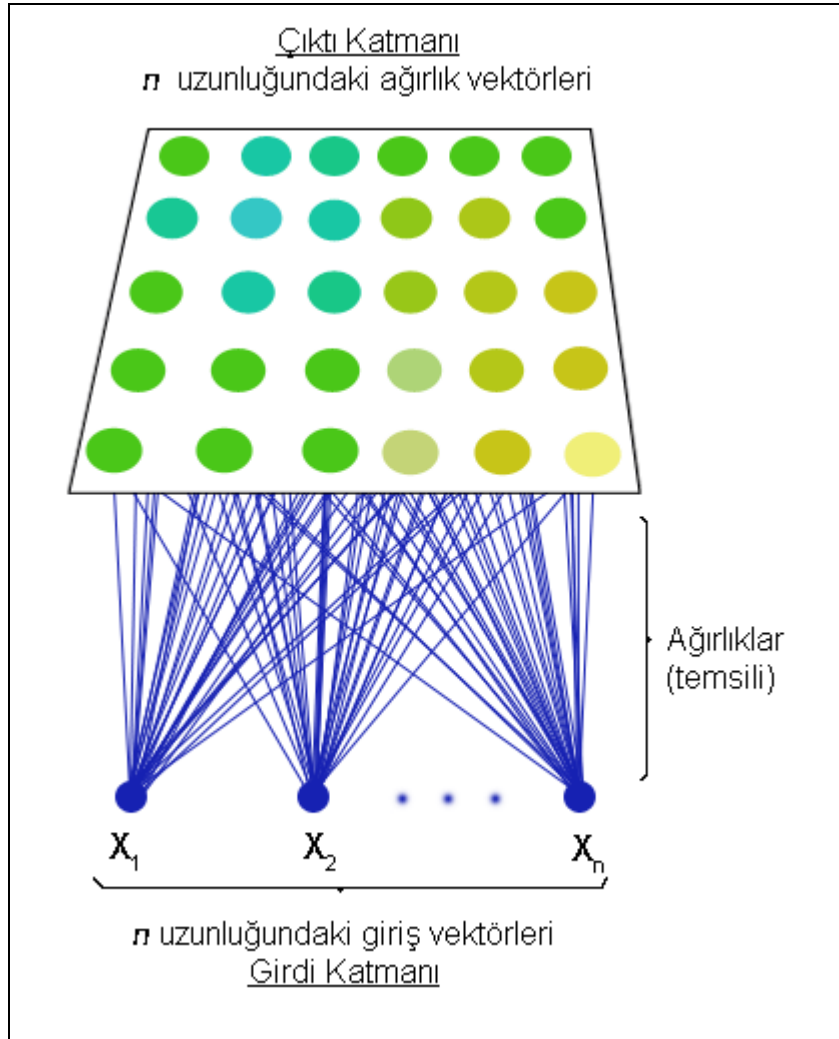
Özdüzenleyici harita (Kohonen ağı), Tuevo Kohonen tarafından 1982 yılında tanımlanmış ve daha sonra sunmuş olduğu makale ve kitaplarında farklı uygulama alanlarıyla birlikte açıklamış olduğu, öğrenim sırasında çıktı veya farklı bir türde geri besleme ile denetime ihtiyaç duymayan sinir ağı çeşididir [Penn, 2005]. ÖDH, çok boyutlu verilerin kolay anlaşılabilir şekilde görselleştirmesini sağlayan yazılım aracı olarak da karşımıza çıkmaktadır. Genellikle bir giriş ve bir çıkış tabakasından oluşur ve giriş tabakasından tek boyutlu, çıkış tabakasından genellikle 2 boyutlu ve çeşitli geometrilere konuşlanmış işlemci elemanlar yer almaktadır. Giriş tabakasındaki her işlemci elemanla çıkış tabakasındaki işlemci elemanlar arasında bağ bulunmakta ve bu bağ çıkış işlemci elemanına ait referans vektöründe tutulmaktadır [Sağiroğlu ve ark., 2003]. Verilerin daha çok boyutlu yapılarda sınıflandırılması mümkün olmakla birlikte bu takdirde ilişkilerin anlaşılması güçleşmekte ve esasen bu ÖDH'nin önerilme amacıyla da çelişmektedir. ÖDH, çok boyutlu temsil edilen girdi verilerinin karmaşık ve doğrusal olmayan istatistiksel ilişkilerini daha az boyutlu ve kolayca anlaşılabilir geometrik yapılar üzerine izdüşümünü alarak oldukça etkili bir görselleştirme ve sanallaştırma sağlamaktadır [Kohonen, 1982, 1990, 1995].

ÖDH, günümüzde öznitelik çıkartımı, işlem ve sistem analizi, istatistiksel örüntü tanıma, telekomünikasyon ve robot tasarımı gibi konular altında pek çok farklı uygulama alanına sahiptir [Kohonen ve ark., 2002]. Ülkemizde de ÖDH kullanılarak ders içeriklerinin sınıflandırılması [Alpdoğan ve Bilge, 2009] ve balıklarda görülen bir hastalığın değerlendirilmesi [Oral ve Genç, 2008] gibi çok farklı konularda özgün çalışmalar gerçekleştirilmiştir.

2.1. ÖDH Yapısal Özellikleri

ÖDH'de, $x = [x_1, x_2, \dots, x_n]^T \in \mathbb{R}^n$ şeklinde verilen n boyutlu giriş vektörleri için, ÖDH'ye ait nöronlarda giriş vektöründeki her bir satır ya da ağırlığa paralel bir ağırlık içeren $w_i = [w_{i1}, w_{i2}, \dots, w_{in}]^T \in \mathbb{R}^n$ ağırlık vektörleri tutulmaktadır. Şekil 2.1'de giriş vektörleri ile ÖDH nöronları arasındaki ilişki temsili olarak verilmiştir. Literatürde ağırlık vektörleri ya da başka bir deyişle model vektörleri için ilk değer

atamasında rastgele ya da girişlere benzer şekillerde gibi farklı yaklaşımlar gözlenmektedir. Bu ağlarda öğrenme, diğer bir deyişle ağırlık vektörlerinin güncellenmesi ÖDH öğrenme kuralına göre yapılmaktadır. Ağırlık vektörlerinin güncellenmesi eğitim sırasında giriş vektörlerine göre zamanla yapılmaktadır.

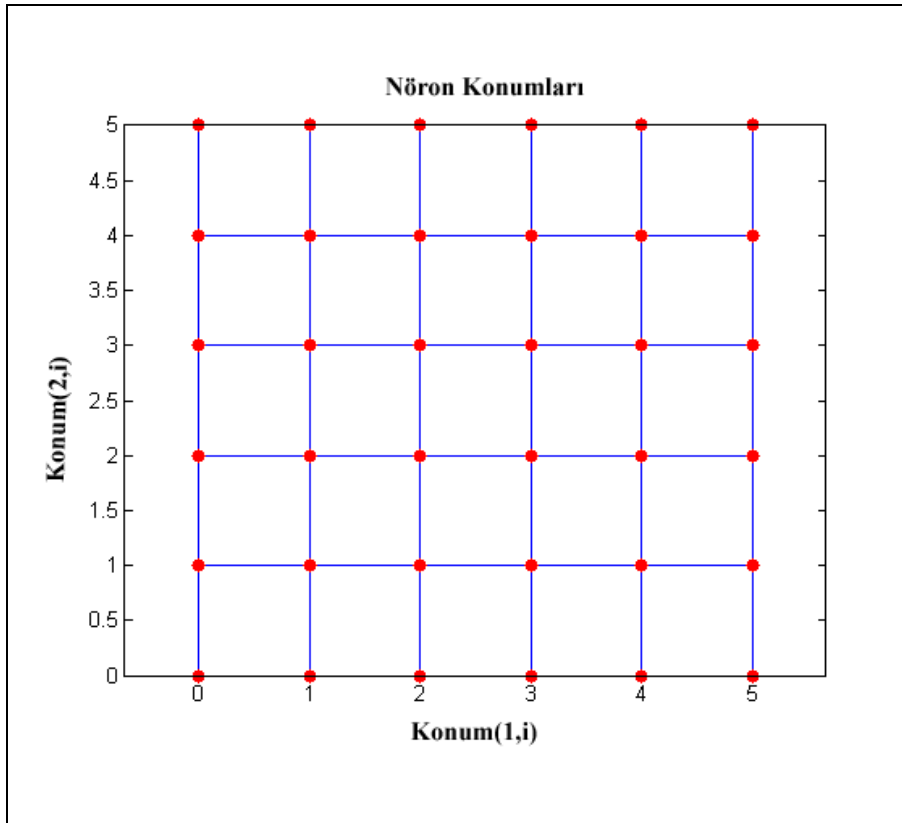


Şekil 2.1. ÖDH temsili yapısı

ÖDH ile yapılan çalışmalarda genellikle 2 boyutlu düzlemler üzerine izdüşüm yapılması, yani nöronların 2 boyutta görselleştirilmesi yaygındır. Bu düzlem yapısının oluşturulmasında ise 2 topoloji üzerinde durulmuştur: (a) ızgara topoloji. (b) altıgensel topoloji. 6X6 boyutlarında olması istenilen bir ÖDH için ızgara şeklinde ve altıgensel olan topolojilere Matlab `gridtop(x,y)` ve `hextop(x,y)` fonksiyonları ile oluşturulmuş örnekler Şekil 2.2 ve Şekil 2.3'te verilmiştir.

2.2. ÖDH Öğrenme Kuralı (Kohonen Öğrenme Kuralı)


Kohonen tarafından geliştirilen bu kuralda nöronlar çıkış olarak seçilmek için yarıştırlırlar ve kazanan nöron “kazanan tamamını alır (winner takes all)” prensibine göre gerekli ağırlık güncellemelerinden en fazla etkilenir ve sadece ağ tasarımındaki seçime göre belirli uzaklıktaki komşuları bu güncellemeden planlanan oranda faydalanabilirler. Giriş vektörünün her bir ağırlığı işleme tabi tutulmakta ve ağırlık vektörlerinin güncellenmesine katılmaktadır. Bu öğrenme kuralı danışmansız öğrenmeye bir örnektir. Ağın öğrenmesinin ardından yakın giriş verileri için yakın çıkışlar üretilmiş olduğundan giriş verilerinin sınıflandırması yapılmış olur [Sağiroğlu ve ark., 2003].



Şekil 2.2. 6X6 ızgara topolojiye örnek

2.3. ÖDH Öğrenme Algoritmaları

ÖDH'de yarışmacı öğrenme esastır. Verilen bir giriş vektörüne göre nöronlar birbirleri ile yarışmakta ve en uygun nöron kazanan nöron olarak belirlenmekte, öğrenmenin adımları bundan sonra devam etmektedir. Literatürde kazanan nöron genellikle BMU olarak adlandırılmıştır [Koikkalainen ve Oja, 1990]. ÖDH öğrenmesi için kullanılan, artırılmış ve grup (batch) öğrenme algoritmaları aşağıda anlatılmaktadır.



Şekil 2.3. 6X6 altıgensel topolojiye örnek

2.3.1 ÖDH artırılmış öğrenme algoritması


Artırılmış öğrenme algoritmasına göre $w_i \in R^n$ olan model vektörlerinin ağırlık güncellemeleri $x \in R^n$ olan giriş vektörlerine göre aşağıda verilen eşitliklerdeki gibi yapılmaktadır [Kohonen, 1998].

$$w_i(t+1) = w_i(t) + h_{c(x),i} (x(t) - w_i(t)) \quad (2.1)$$

Eş. 2.1'de t artırım indeksini, $h_{c(x),i}$ eğitimin etkilerini diğer nöronlara dağıtan komşuluk fonksiyonunu ifade etmektedir. Komşuluk fonksiyonunun alt indisi olarak verilmiş $c = c(x)$ yani kazanan nöronun indeksi aşağıdaki eşitsizlik koşuluna uymaktadır.

$$\forall i, \|x(t) - w_c(t)\| \leq \|x(t) - w_i(t)\| \quad (2.2)$$

Eş. 2.2'de uzaklık ölçüsü genellikle Öklid bağıntısına göre hesaplanmaktadır. Eş. 2.1 ve Eş. 2.2'ye göre belirlenmiş olan kazanan nöron w_c merkez kabul edilerek $h_{c(x),i}$ fonksiyonuna göre komşuluk kümesi, N_c belirlenmektedir. Komşuluk kümesinin belirlenmesinde nöronlar arası uzaklık esas alınmaktadır ve uzaklık Öklid, Manhattan gibi uzaklık bağıntılarıyla hesaplanmaktadır.



Şekil 2.4. Nöronlar arası Öklid bağıntısına göre belirlenmiş komşuluk kümesi örnekleri

Şekil 2.4'te Öklid uzaklığına göre kazanan 9. ve 22. nörona ait 1 ve 2 birim uzaklıklar için komşuluk kümelerine örnek verilmiştir. Şekil 2.5'te ise Manhattan uzaklığına göre aynı nöronun 1 ve 2 birim uzaklıklar için komşuluk kümelerine örnek verilmiştir.

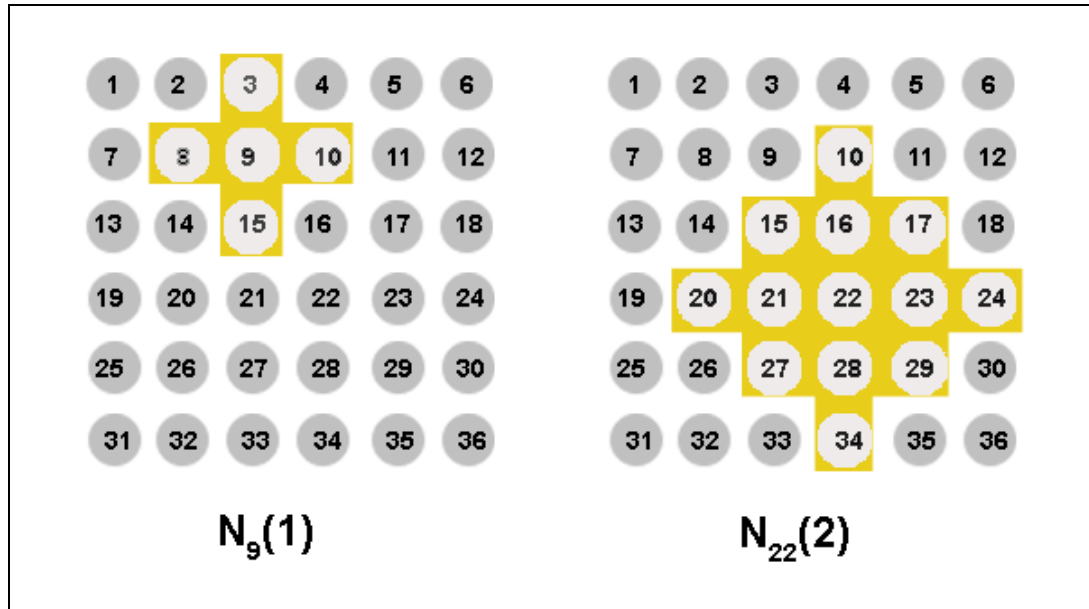
Komşuluk fonksiyonu ise genellikle aşağıdaki gibi bir Gauss fonksiyonu şeklinde tanımlanmaktadır.

$$h_{c(x),i} = \alpha(t) e^{\left(-\frac{\|r_i - r_c\|^2}{2\gamma^2(t)}\right)} \quad (2.3)$$

$$0 < \alpha(t) < 1 \quad (2.4)$$

Eş. 2.3'de verilen $\alpha(t)$ artırım indeksine ters orantılı olarak değişen öğrenme oranı katsayısıdır. r_c ve r_i ise sırasıyla kazanan nöronun ve komşuluk kümesi içinde kalan herhangi bir nöronun haritadaki vektörel konumlarıdır. $\gamma(t)$ ise komşuluk kümesinin genişliğini veren ve artırım indeksine ters orantılı olarak değişen uzaklık katsayısını vermektedir. Daha sade bir ifadeyle ise komşuluk kümesi genişliğinin k olduğu anda, komşuluk fonksiyonu Eş. 2.5'teki gibi tanımlanabilecektir.

$$\begin{aligned} \|r_i - r_c\| \leq k \text{ ise } h_{c(x),i} &= \alpha(t) \\ \|r_i - r_c\| > k \text{ ise } h_{c(x),i} &= 0 \end{aligned} \quad (2.5)$$



Şekil 2.5. Nöronlar arası Manhattan bağıntısına göre belirlenmiş komşuluk kümesi örnekleri

2.3.2 ÖDH grup öğrenme algoritması

ÖDH öğrenme algoritmasının daha hızlı çalışması için Eş. 2.1'de ve Eş. 2.2'de verilen eşitlikler yerine yığın halinde bir hesaplama yolu önerilmiştir [Kohonen, 1998]. Bu algoritma daha hızlı çalışmasının yanında öğrenme katsayısına ihtiyaç duymama avantajına da sahiptir.

$$\lim_{t \rightarrow \infty} w_i(t+1) = w_i(t) \quad (2.6)$$

Artırım indeksinin yeterince büyük olduğu bir değerde ÖDH istikrarlı bir konuma geleceği ve model vektörlerinin ağırlıklarının değişmeyeceğini varsayarsak Eş. 2.6 kabul edilebilecektir. Bu durumda istikrarlı halde aşağıdaki koşulun sağlanacağını söyleyebiliriz.

$$\forall i, E_t \left\{ h_{c(x),i} (x - w_i^*) \right\} = 0 \quad (2.7)$$

Eş. 2.7'de ilgili model vektörü w_i^* 'ın bulunması için denklemi aşağıdaki şekilde yazabiliriz.

$$w_i^* = \frac{\sum_t h_{c(x),i} x(t)}{\sum_t h_{c(x),i}} \quad (2.8)$$

Burada w_i^* değerinin hala $x(t)$ ve w_i^* değerine dayanıyor olması nedeniyle w_i^* için, doğrusal olmayan denklem çözümlerinde kullanılan bir yöntemin uygulanması ile kabaca tahmini bir değer atanır. Ardından Eş. 2.2'ye göre tüm $x(t)$ değerleri hesaplanarak Eş. 2.8'de yerine konulması ile w_i^* için daha doğru bir tahmin yapılabilir. Bu şekilde w_i^* değerindeki değişimin belirli bir değerin altına düşene kadar bu işlemin tekrarlanması ile istenilen sonuca ulaşılabilmektedir.

2.4. ÖDH Model Vektör Ağırlıkları İlk Değer Ataması

ÖDH model vektörlerine ait ağırlıklara ilk değerlerinin atanmasında literatürde farklı yaklaşımlar görülmüştür. Çoğunlukla rastgele verilen değerlerde de birkaç yüz yineleme sonrasında istenilen sonuçlara gelinmekle birlikte bazı araştırmacılarca giriş verilerinin dağılımına göre ilk değerlerin atanması faydalı bulunmuş ve girdi

vektörlerinden rastgele seçilen bazıları ile başlangıçta ÖDH ağırlık vektörleri düzenlenmiştir [Ong ve ark., 2002]. ÖDH tanımını yapan Kohonen de benzer şekilde ilgili ilk değer atamasının girdilere göre tahmini değerlerden seçilerek yapılmasının en iyi sonucu vereceğini önermiştir [Kohonen ve Somervuo, 1998].

3. TEMEL BİLEŞEN ANALİZİ (TBA)

Veri analizlerinde yaşanan temel sorunlarından biri çok değişkenle tanımlanmış olan verilerin görselleştirilmesidir. Bu tip veriler üzerinde yapılan çalışmalarda da yine döngülerin çoğalması, hafızada daha fazla yer ayrılması gibi nedenlerden sistem veriminin düşmesi söz konusu olmaktadır. Ancak istatistiksel olarak yaklaşırsak, gözlemler üzerinde yapılan incelemede gözlemlere ait değişkenlerin korelasyon gösterdikleri yani birbiri ile ilişkili olduğu, değişkenlerin gruplar halinde belirli bir bileşeni ölçtükleri gözlenmektedir. Bu ise değişkenlerin gruplanmasına ve veri setinin daha az değişkenle analiz edilebilmesine olanak sağlamaktadır [Korhonen ve Siljamaki, 1998]. Bu işlem literatürde boyut indirgeme olarak da tanımlanmıştır. TBA yukarıda belirtilen indirgeme işlemini başarılı bir şekilde yapabilen, sıklıkla kullanılan bir metottur.

Matematiksel olarak ifade etmek gerekirse, varsayalım elimizde n tane rastsal değişkeni ifade eden bir \mathbf{v} vektörü olsun. Öyle bir lineer f_1 fonksiyonu bulalım ki Eşitlik 3.1'de gösterilen f_1^T 'in katsayıları mümkün olan maksimum varyansa sahip olsun:

$$f_1^T \mathbf{v} = f_{11}v_1 + f_{12}v_2 + \dots + f_{1n}v_n \quad (3.1)$$

Ardından da öyle bir f_2 fonksiyonu bulalım ki Eşitlik 3.2'de gösterilen f_2^T 'in katsayıları f_1 'in katsayıları ile ilişkili olmasın ve mümkün olan maksimum varyansa sahip olsun:

$$f_2^T \mathbf{v} = f_{21}v_1 + f_{22}v_2 + \dots + f_{2n}v_n \quad (3.2)$$

Bu şekilde n tane lineer fonksiyon bulalım. İşte bu şekilde elde edilen $f_m^T \mathbf{v}$ bu veri seti için m . temel bileşen olmaktadır. İlk olarak mümkün olan en büyük varyans $f_1^T \mathbf{v}$ için aranmış olduğundan veri setindeki değişimi en iyi gösteren temel bileşen o olacaktır. TBA sonucunda elimizde n tane temel bileşen olacaktır ancak bunlardan m ($m < n$) tanesi artık veri setimizi ifade edebilir nitelikte olabilir ve böylece boyut indirgeme işlemi gerçekleştirilmiş olur.

TBA çok sayıdaki rastsal değişkeni daha az sayıdaki ana bileşenler olarak adlandırılan yeni değişkenler kümesine dönüştürmektedir. Bu yeni değişkenler aslında başlangıçtaki değişkenlerin doğrusal kombinasyonlarıdır. TBA temel bileşenlerin birbirine dik olmasını (ortogonal olmasını), yani değişkenler arasında korelasyon olmamasını, dolayısı ile hiç gereksiz bilgi tutulmamasını amaçlamaktadır. Bu halde ana bileşenler ortogonal bir sistem oluşturmaktadırlar.

TBA sonucunda elde edilen temel bileşenler olarak adlandırılan yeni değişkenlerde varyansın maksimuma çıkartılmasına çalışılmaktadır. Sonuç olarak elde edilen gösterimde veri setindeki benzerlikler ve değişkenlikler ön plana çıkartılarak ayrışmanın netleşmesi sağlanmaktadır. Bu nedenle TBA örüntü tanıma gibi pek çok sınıflandırmaya dayalı çalışmada kullanılmaktadır.

TBA aşağıdaki temel adımlarla açıklanabilir.

3.1. Ortalamaların Çıkartılması


Her bir değişkenin ortalaması hesaplanarak, tüm veri için değişkenden; ilgili değişkenin ortalaması çıkartılmaktadır. Örneğin elimizde aşağıdaki iki rastsal değişken x , y olsun.

$$\mathbf{x} = \begin{pmatrix} 1,5000 \\ 3,5000 \\ 4,8000 \\ 7,6000 \\ 2,0000 \\ 3,0000 \\ 3,0000 \\ 5,3000 \end{pmatrix} \quad \mathbf{y} = \begin{pmatrix} 1,4000 \\ 3,4000 \\ 4,6000 \\ 7,7000 \\ 2,1000 \\ 2,9000 \\ 3,0000 \\ 5,4000 \end{pmatrix} \quad (3.3)$$

Bu değişkenlerden kendi ortalamaları çıkartıldığında aşağıdaki yeni vektörler elde edilmektedir. z ve t olarak adlandıracağımız bu yeni değişkenler ise aşağıdadır:

$$z = \begin{pmatrix} -2,3375 \\ -0,375 \\ 0,9625 \\ 3,7625 \\ -1,8375 \\ -0,8375 \\ -0,8375 \\ 1,4625 \end{pmatrix} \quad t = \begin{pmatrix} -2,4125 \\ -0,4125 \\ 0,7875 \\ 3,8875 \\ -1,7125 \\ -0,9125 \\ -0,8125 \\ 1,5875 \end{pmatrix} \quad (3.4)$$

Bu yeni deęişkenler ařaęıdaki Őekil 3.1’de koordinat dűzleminde gűsterilmiřtir.



Őekil 3.1. z ve t deęişkenlerinin koordinat dűzleminde gűsterimi

Bu deęişimle, deęişkenlerin ortalaması sıfır olmaktadır. Bu iřlemden sonra bazı benzer boyut indirgeme metotlarında deęerler -1 ile 1 arasına daęıtılarak hesaplamaların daha kolaylařması saęlanabilmektedir.

3.2. Kovaryans Matrisinin Hesaplanması

İkinci adım olarak yeni deęişkenlerimiz iin kovaryans matrisi hesaplanmakta ve kaydedilmektedir. Örneęimizde ortalamaları ıkartılmıř deęişkenlerimiz iin bulunan kovaryans matrisi ařaęıdadır.

$$Kov.Matrisi = \begin{pmatrix} 3,9398 & 4,0109 \\ 4,0109 & 4,0955 \end{pmatrix} \quad (3.5)$$

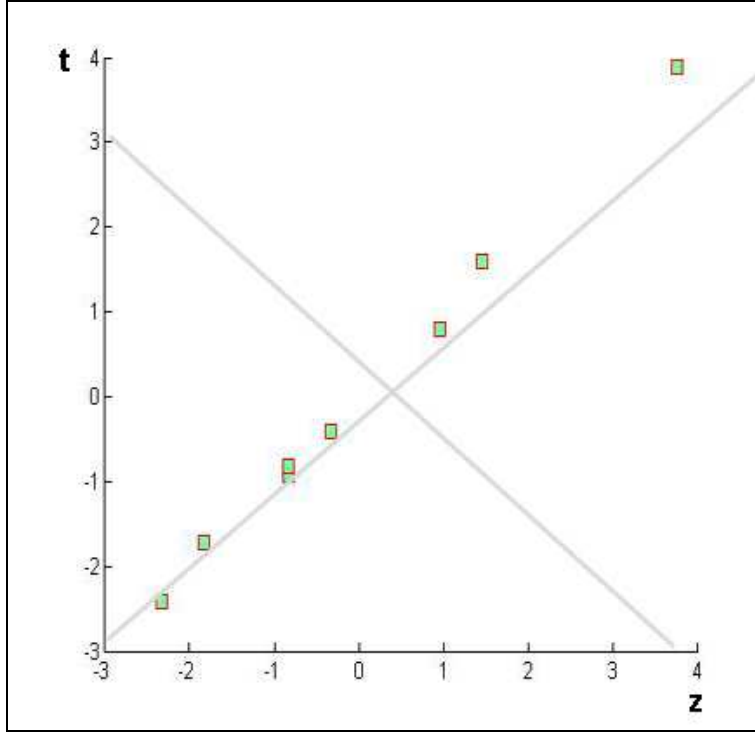
3.3. Kovaryans Matrisine Ait Öz Vektör ve Öz Değerlerin Hesaplanması

Kovaryans matrisi kare bir matristir ve dolayısı ile öz değer ve öz vektörleri hesaplanabilmektedir. Aşağıda bunların hesaplanmış halleri sırasıyla $\mathbf{\hat{d}}$ ve $\mathbf{\hat{v}}$ değişkenlerinde verilmiştir.

$$\mathbf{\hat{d}} = \begin{pmatrix} 0,0060 \\ 8,0293 \end{pmatrix} \quad (3.6)$$

$$\mathbf{\hat{v}} = \begin{pmatrix} -0,7139 & 0,7002 \\ 0,7002 & 0,7139 \end{pmatrix} \quad (3.7)$$

Şekil 3.2’de yukarıda verilmiş olan öz vektörlerle aynı eğime sahip doğrular ilk verilerimizin gösterilmiş olduğu sayı doğrusunda gösterilmiştir. Bu şeklin bize verdiği sonuç öz vektörlerin birbirlerine dik oldukları ve öz vektörlerden birinin veri setimizle benzer şekilde değişim gösterdiğidir, yani artık veri setinin değişimini tahmini olarak elde etmek için baştaki 2 değişken yerine 1 değişken kullanabilecektir. Buradan analizin istenilen sonuca yaklaştığı anlaşılabilir.



Şekil 3.2. z ve t değişkenleri ve öz vektörler eğimindeki doğruların koordinat düzleminde gösterimi

3.4. Temel Bileşenlerin Seçilmesi ve Öznitelik Vektörlerinin Oluşturulması

Bu aşamada daha önce de değinildiği gibi aslında elimizde oldukça faydalı bilgiler vardır. Örneğin kovaryans matrisinde öz değerlerin en büyük olanına karşılık gelen öz vektör ilk temel bileşen olarak alınabilir, çünkü bizim için en önemli en ayırt edici öz vektör budur. Elimizdeki verinin daha az boyutta incelenmesi için öz değerlerin büyükten küçüğe doğru sıralanması ve ardından çalışmak istediğimiz kadar boyuta karşılık gelen değişkenlerin değerlendirmeye alınması ile bu mümkün olacaktır. Bu anlatılan yöntem ile veri kaybı olacağı açıktır ancak bu kayıp değerlendirmeye aldığımız değişkenlere karşılık gelen öz değerler, değerlendirmeye alınmayanlarda ne oranda büyükse o oranda düşük bir kayıp olacaktır. Öz değerlere karşılık gelen öz vektörlerin de sıralanarak \hat{ov}_1 'in en büyük öz değere karşılık geldiğini var sayalım. Sıralanmış haldeki bu vektörler Öznitelik Vektörünü aşağıdaki gibi oluşturmaktadır.

$$\text{ÖznitelikVektörü} = (\hat{ov}_1 \hat{ov}_2 \dots \hat{ov}_n) \quad (3.8)$$

Bizim örneğimizde ikinci öz değer daha büyük olduğu için Öznitelik Vektörü aşağıdaki şekilde oluşacaktır.

$$\text{ÖznitelikVektörü} = \begin{pmatrix} 0,7002 & -0,7139 \\ 0,7139 & 0,7002 \end{pmatrix} \quad (3.9)$$

3.5. Temel Bileşenlere Göre Yeni Veri Setinin Verilmesi

Analizin son adımında ise elde edilen temel bileşenler yani değişkenlere göre veri setimizin ifade edilmesi işlemi yapılmaktadır. Bu işlem şimdiye kadar elde edilenlerle oldukça kolay bir şekilde yapılabilmektedir. Devrik öznitelik vektörü ile devrik haldeki orijinal veri setinin çarpılması ile elde edilen yeni veri setimiz Eş. 3.10'da görüldüğü gibi elde edilmektedir.

$$\text{YeniVeriSeti}^T = \text{ÖznitelikVektörü}^T * \text{IlkData}^T \quad (3.10)$$

Örneğimizde elde edilen yeni veri seti aşağıdadır. Bu veri setinde ilk vektör (ilk ana bileşen), baştaki verilerimize çok yakın bir değişim gösterdiği için artık veri setimizin boyutu bir miktar veri kaybıyla birlikte temsil edilebiliyor denilebilir.

$$\text{YeniVeriSeti} = \begin{pmatrix} 2,0498 & -0,0906 \\ 4,8780 & -0,1180 \\ 6,6449 & -0,2058 \\ 10,8186 & -0,0341 \\ 2,8996 & 0,0426 \\ 4,1709 & -0,1111 \\ 4,2423 & -0,0411 \\ 7,5661 & -0,0026 \end{pmatrix} \quad (3.11)$$

4. ÖZDÜZENLEYİCİ HARİTALAR İLE YÜZ SINIFLANDIRMA (ÖDHYS)

YS, yüz tanıma işleminde çekirdek konumundaki bir alt işlemdir. Yüz biyometriğini kullanan kimlik doğrulama sistemlerde en önemli görevi yerine getirmektedir. Sınıflandırma problemlerinde başarılı bir sinir ağı çeşidi olan ÖDH da YS için kullanılan yöntemler arasındadır [Abate ve ark., 2007].

ÖDH, YS işlemlerinde ilk olarak ana sınıflandırıcı olarak değil ÇKP gibi sınıflandırıcı sistemlerine yardımcı olarak son işleme bölümünde kullanılmaya başlanmıştır [Tolba ve Abu-Rezq, 2000]. Daha sonraları ise giriş bölümünde aktarılan çalışmalarda olduğu gibi YS işlemlerinde temel sınıflandırıcı olarak kullanımı da yaygınlık kazanmıştır [Kohonen ve ark., 2002]. Geleneksel ÖDH ile yapılan sınıflandırmada temel olarak öncelikle yüz görüntülerinden öznitelik vektörleri oluşturulmakta ve ÖDH ile doğrudan bu vektörlerin sınıflandırılması yapılmaktadır. Ancak araştırmacılar sınıflandırma verimini artırmak için bu temel yaklaşım üzerinde geliştirmelerde bulunmuş ve yeni uygulamalar önermişlerdir.

4.1. ÖDHYS Çalışmalarının Sınıflandırılması

ÖDH'yi yüz sınıflandırma işleminin herhangi bir adımında kullanan çalışmalar incelendiğinde araştırmacıların çalışmalarını üç kategoriye ayırabiliriz: a) ÖDH'ye yapısal değişiklikler uygulayan çalışmalar, b) ÖDH ile görüntüyü yeniden düzenleyen (image reconstruction) çalışmalar, c) her bir sınıfa için ayrı bir ÖDH kullanan çalışmalar.

4.1.1. ÖDH'ye yapısal değişiklikler uygulayan çalışmalar

ÖDH'ye yapısal değişiklikler uygulayan çalışmalarda, genellikle vektörler arası uzaklığın hesaplanmasında kullanılan uzaklık metriğinin değiştirilmesi, nöronların dağıtıldığı haritanın fiziksel yapısının (katmanlar eklenmesi gibi işlemlerle) değiştirilmesi ya da ağırlık güncellemelerindeki değişimler görülmektedir.

4.1.2. ÖDH ile görüntüyü yeniden düzenleyen çalışmalar

Daha başarılı bir sınıflandırma oranı ve çalışma süresi hedefleyen ikinci gruba giren araştırmalar ise düşük boyutlarda öznitelik vektörleri elde etmek ve bunun yanında bilgi kaybını da en aza indirebilmek için ÖDH ile görüntüleri yeniden düzenledikten sonra sınıflandırma yapmayı önermişlerdir.

4.1.3. Her bir sınıf için ayrı bir ÖDH kullanan çalışmalar

Yüz sınıflandırma işleminde öznitelik vektörlerini sınıflandırmak üzere tek bir ÖDH kullanılmasında yüz veritabanına yeni bir sınıf (kişi) eklenmesi durumunda TBA gibi ön işleme adımlarının tekrarlanması dezavantajı bulunmaktadır. Bunun üstesinden gelmek için üçüncü grupta değerlendirdiğimiz çalışmalarda her bir sınıfa yeni bir ÖDH atanması stratejisi izlenmiştir. BMU araştırılırken tüm ÖDH'ler gezilerek ilgili öznitelik vektörüne en yakın nöron aranmaktadır.

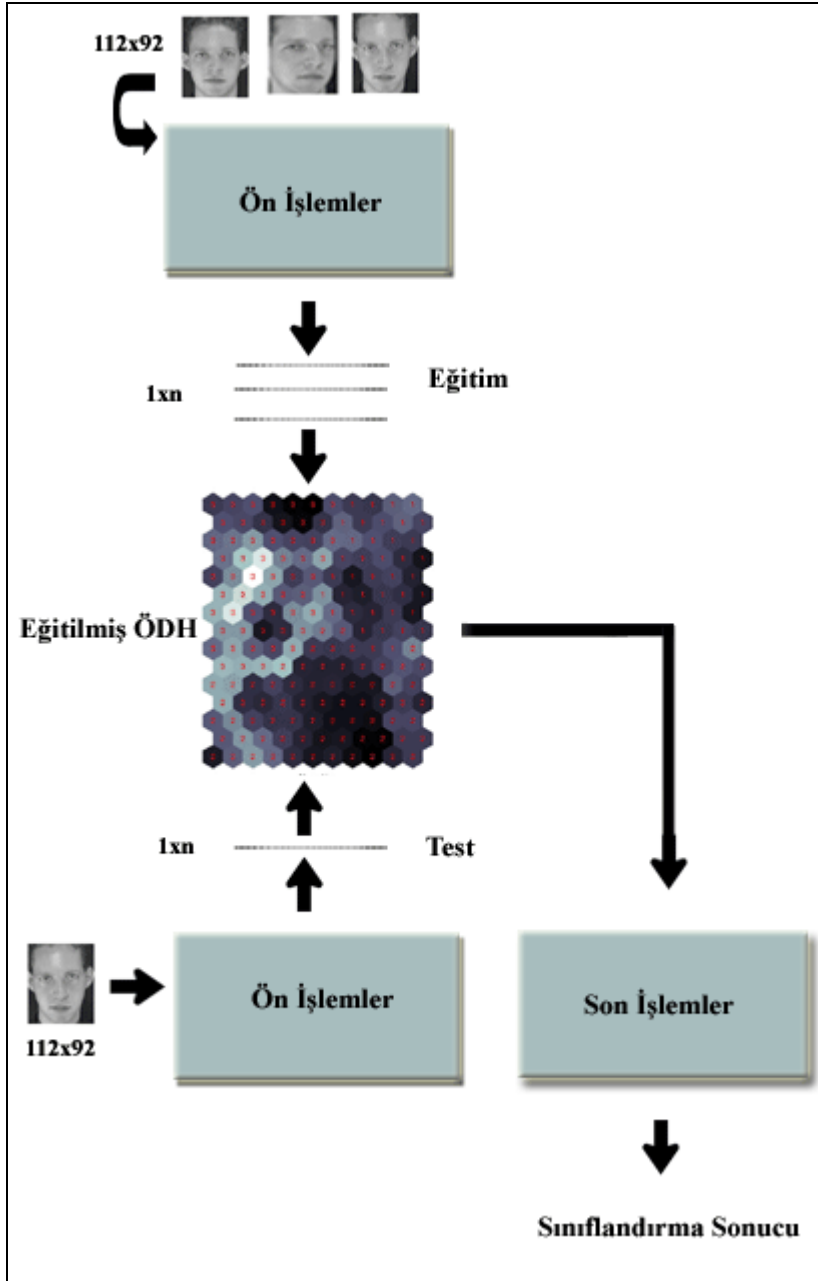
4.2. ÖDH ile Geleneksel Yüz Sınıflandırma

ÖDH ile vektörel olarak ifade edilebilen gözlemleri sınıflandırmak oldukça kolay bir işlemdir. Yüz görüntülerinin sınıflandırılması için yapılması gereken yüz görüntülerinden öznitelik vektörlerinin oluşturulması ve bunlarla uygun eğitim parametreleri değerlerinde ÖDH eğitiminin yapılmasıdır.

Şekil 4.1'de görülebileceği gibi ilk adım olarak görüntülerin okunması ve görüntü bilgilerinin matrisler olarak sisteme kaydedilmesi gerekmektedir. Genel olarak yüz veritabanlarındaki görüntülerden elde edilen matrisler büyük boyutlarda olduğundan, bu matrislerden elde edilen vektörlerle çalışmak verimli olmayacaktır, bu nedenle boyutlarının küçültülmesi gerekmektedir. Boyut indirgemedede bilgi kaybının mümkün olduğunca az olması için, vektörler TBA gibi alt adımların uygulandığı ön işlemlere tabi tutulmaktadırlar.

Ön işlemlerden sonra artık ilgili yüz görüntüsünü temsil eden bir vektör elde edilmiştir. Yüz görüntüsünün işlenmesi ile elde edilen ve ona ait istenen bilgileri saklayan bu vektöre öznitelik vektörü denilmektedir. Eğitim esnasında, ÖDH için eğitimde kullanılacak başlangıç öğrenme oranı, harita boyutları gibi değişkenler

belirlendikten sonra yüz veritabanından eğitim için seçilmiş olan yüzlere ait öznitelik vektörleri ile sistemin merkezinde olan ÖDH eğitilmektedir. Eğitimden sonra ÖDH test görüntülerini harita üzerinden konuşlandırmaya hazır hale gelmiştir.



Şekil 4.1. ÖDH ile geleneksel yüz sınıflandırma aşamaları

Yüz veritabanında test için seçilmiş görüntülerin harita üzerindeki konumlarını öğrenmek için test görüntülerinin de öznitelik vektörlerinin çıkartılması

gerekmektedir. Bunun için bu görüntüler ön işlemlere tabi tutulmaktadır. Elde edilen öznitelik vektörleri harita üzerine yansıtılarak ilgili BMU'lar bulunup kaydedilmektedir. Bu işlemden sonra elde, sınıfları belirli olan eğitim görüntülerinin BMU'larının harita üzerindeki konumları ve sınıfları belirli olmayan test görüntülerinin BMU'larının harita üzerindeki konumları bulunmaktadır. Bu aşamada son işlemler adında genel olarak verilmiş işlemler sonrasında test görüntülerinin sınıflandırma sonuçları belirlenmektedir. Son işlemler nöronların, eğitim görüntülerinin BMU'larının konumlarına göre etiketlenmesi ya da bu konumlara göre farklı sınıflandırma algoritmalarının uygulanması gibi alt işlemlerden oluşabilmektedir.

5. KALİTE AĞIRLIKLANDIRILMIŞ ÖZDÜZENLEYİCİ HARİTALAR İLE YÜZ SINIFLANDIRMA (KAÖDHYS)

Tez çalışmaları kapsamında ÖDH ve varyasyonları kullanılarak yapılan yüz sınıflandırma çalışmaları üzerine literatür taraması yapılmış, incelenen çalışmalarda sergilenen yaklaşımlar, parametrelerin seçimi gibi kriterlerin sınıflandırma başarısına ve çalışma performansına etkileri değerlendirilmiştir. Sınıflandırılacak görüntülerdeki farklı bölgelerin sınıflandırma açısından aynı derecede katkı sağlamayacağı ve bunun önerilecek yöntemde dikkate alınabilmesi için görüntülerin son yıllarda önerilmiş olan LMSOM [Tan ve ark., 2006] mimarisinde gösterilen yaklaşıma benzer şekilde bloklara ayrılması gerekli görülmüştür. Bunun yanında ÖDH'lerin sınıflandırma problemlerinde kullanımında özel olarak ÖDH sınıflandırma kalitelerinin ağırlıklandırılması ile yapılan eğitimden daha fazla faydalanılabileceği görülmüştür. Sonuç olarak bahsedilen yaklaşımları birleştiren, çok sayıda ÖDH kullanan yeni bölge temelli (region-based) bir yöntem önerilmiştir.

Sınıflandırma başarısı ve çalışma performansı açısından diğer yöntemlerle kıyaslandığında başarılı olan yöntem kısaca şu şekilde çalışmaktadır: öncelikle yüzler okunmakta ve istenilen sayıda eşit büyüklükteki alt bloğa ayrılmaktadır. Görüntünün bölündüğü blok sayısı adedince ÖDH yaratılmakta ve eğitim aşamasında bloklar diğer yüz görüntülerinde kendi konumlarında yer alan bloklar arasında sınıflandırılmaktadırlar. Eğitim ardından nöronlar, kendilerini kazanan olarak seçen ve sınıfları belirli olan eğitim görüntülerinin harita üzerindeki dağılımlarına göre etiketlenmektedirler. Eğitimdeki sınıflandırmanın ardından bloklarda sınıf içi ve sınıflar arası dağılımın derecesi hesaplanmakta ve ilerde bloğun sınıflandırma kalitesini bulmada kullanmak üzere kaydedilmektedir, bu adım tez çalışmasının özgün yönlerinden birisidir. Test aşamasında test görüntülerine ait bloklar sınıflandırılmakta ve sonuçlar kaydedilmektedir. Test edilen görüntünün sınıf tayini olan son aşamaya gelindiğinde blokların sınıflandırma doğruluk puanları; bloğun sınıflandırma kalitesi, bloğun 4-koşuluğundaki blokların sınıflandırma sonuçları ve sınıflandırma kaliteleri de dikkate alınarak hesaplanmaktadır, bu adım da tez çalışmasının özgün bir yönüdür. Bir test görüntüsüne ait sınıflandırma sonucu,

blokların sınıflar bazında tutulmuş sınıflandırma doğruluk puanlarının birikmiş toplamlarına göre duyurulmaktadır.

5.1. Yeni Önerilen Sistemde Uygulanan Yöntem

Yeni önerilen, temelinde çok sayıda ÖDH kullanan sistemin çalışmasında izlenen yöntemin adımları aşağıda anlatılmaktadır. Sistemin blok diyagramı Şekil 5.1’de verilmiştir.


5.1.1 Görüntülerin okunması ve histogram eşitleme

Öncelikle dosya sisteminde görüntü formatında kayıtlı bulunan yüz veritabanındaki yüzler okunmakta ve her bir yüzün gri seviye değerleri daha sonraki işlemlerde kullanılmak üzere kaydedilmektedir. Bu aşamada görüntülerin aydınlanma farklılıklarını ortadan kaldırmak ve önemli bölümlerinin belirginleşmesi için Histogram Eşitleme (HE) ile kontrastları artırılmıştır. Bu iyileştirme yöntemi ile tüm resimlerde birbirine benzeyen soluk görünümlü bölgeler yerine sınıflandırma açısından daha anlamlı farklı seviyelerdeki bölgeler elde edilmiş olmaktadır. Resim 5.1’de HE’nin etkisi görülmektedir. HE ardından elde edilen görüntüler istenilen sayıda eşit büyüklükteki bloğa ayrılarak kaydedilmektedir. Resim 5.2’de 16 bloğa ayrılmış bir yüz görüntüsü blok indeksleri içlerine yazılmış şekilde görülmektedir.

5.1.2 Temel Bileşen Analizi (TBA) ve blokların eğitimi

ÖDH’lere girdi olarak vektörel değişkenler verilmektedir. Bloklara ait okunan gri seviye değerleri ya da RGB değerleri ise matrisler halinde hafızada tutulmaktadır. Bu nedenle öncelikle bu matrisler boyut değişimi ile vektörler haline getirilmektedirler.


ÖDH’lerin eğitimi ve benzeri işlemlerde toplam işlem süresi ile ÖDH giriş vektörü boyutu doğrudan ilgilidir. Bu nedenle eldeki bloklara ait vektörlerin boyutlarının küçültülmesi önem arz etmektedir. Bahsedilen boyut indirgeme işleminde dikkat edilmesi gerekli en önemli konu ise boyut indirgemesi esnasında bilgi kaybının hiç olmaması ya da çok az olmasıdır, aksi takdirde sınıflandırma başarısında düşüşler gözlenecektir.



Şekil 5.1. Kalite Ağırlıklandırılmış ÖDH'ler ile yüz sınıflandırma aşamaları



Resim 5.1. Yüz görüntülerine Histogram Eşitleme uygulanması a) Orijinal yüz görüntüleri b) Histogram Eşitleme uygulanmış yüz görüntüleri




Resim 5.2. Yüz görüntüsünün bloklara ayrılması

Boyut indirgeme için literatürde pek çok metot önerilmiştir, TBA; ortalama karesel hata bakımından (mean square error) çok başarılı bir doğrusal boyut indirgeme yöntemidir [Fodor, 2002]. Belirtilen özelliği nedeniyle daha önce yapılmış olan

sınıflandırma çalışmalarında da sıklıkla kullanılmıştır. Diğer çalışmalarda kullanılmış olması önerdiğimiz yöntemin etkinliğinin kıyaslanmasını daha anlamlı kılmaktadır. Bu avantajlarının nedeniyle boyut indirgemede TBA kullanılmasına karar verilmiştir.

Bloklara ait vektörler görüntü üzerinde kendi konumlarında yer alan blokların vektörleri ile TBA'ya tabi tutulmaktadır. Sonuç olarak vektörler arası korelasyon azaltılmakta ve vektör boyutları düşürülmektedir.



Şekil 5.2. Önerilen metotta blokların eğitimi

Bu aşamadan sonra bloklara ait TBA uygulanmış vektörler eğitime hazırdır. Şekil 5.2'de görüldüğü gibi her bir blok için ayrı bir ÖDH yaratılmıştır. Bu ÖDH 'ler eğitim için seçilmiş olan yüz görüntülerinin kendileriyle ilgili olan blokların vektörleri ile eğitilmektedirler. Eğitim sonucunda her bir bloğun en iyi eşleşen nöronları yani BMU bilgileri daha sonraki adımlarda kullanılmak üzere kaydedilmektedir. Kayıt esnasında bu bilgiler bloğun ait olduğu yüz görüntüsünün sınıfına (hangi kişiye ait olduğuna) ve bloğa göre tasnif edilmektedir.

5.1.3. Nöronların ön etiketlenmesi

Eğitim ardından nöronlar, kendilerini BMU olarak seçmiş olan blokların sınıflarının (blokların ait oldukları görüntülerin sınıflarının) dağılımına göre etiketlenmektedirler. Bu amaçla yapılan işlemlere daha önceki çalışmalarda ön etiketleme (pre-labelling) adında rastlanabilmektedir. Bizim çalışmamızda etiket seçimi için çoğunluk seçim sistemi (plurality voting system) kullanılmıştır. Bu sadece bir kazananın olduğu bir seçim sistemidir [Lin ve ark., 2003]. Bir nöronu en fazla kazanan olarak seçen sınıf nörona etiketini vermektedir. Örneğin belirli bir ÖDH üzerindeki n. nöronu; 3.sınıftan olan bloklar 3 kez, 2.sınıftan olan bloklar 1 kez seçmiş ve başka bir blok kazanan olarak seçmemişse, ilgili nörona 3.sınıf etiketi verilmektedir [Monteiro ve ark., 2006]. İlgili nöron hiç seçilmemişse ya da farklı sınıflar tarafından aynı çoklukta seçilmişse ön etiketleme yapılmamakta, daha sonraki adımlarda nöronun sınıf merkezlerine uzaklıklarına göre belirlenmek üzere ilgili nöron etiketsiz bırakılmaktadır. Nöronun birden fazla sınıf tarafından eşit sayıda seçildiği durumda nöron bu sınıflardan hangisinin merkezine daha yakınsa onun etiketini alacaktır.

5.1.4. Sınıf içi ve sınıflar arası harita yayılım indekslerinin hesaplanması

Eğitim ardından ÖDH ağırlık vektörleri sabitlenmektedir. Bu durumdaki ÖDH, artık test vektörlerini, ağırlık vektörleri ile kıyaslayarak harita tasarımında belirlenen uzaklık metriğine göre harita üzerinde test vektörüne en yakın konuma yerleştirmektedir. Bu konumdaki nöron BMU olarak seçilmiş olmaktadır. Fakat bu ve diğer pek çok ÖDH ile yapılmış sınıflandırma çalışmasında merak edilen soru: “eğitilmiş bir ÖDH’nin kullandığımız görüntü veritabanı için sınıflandırma yeteneği ya da kalitesi nedir?” olmuştur. Bu sorunun cevabı bize, test vektörünün yerleştiği konumun doğruluğuna ne kadar güvенеbileceğimizi gösterecektir.

ÖDH ile sınıflandırma işlemi temelde, test görüntülerinin yerleştikleri konumların eğitim görüntüleri ve/veya test görüntülerinin yerleştikleri konumlara uzaklıklarına¹ göre yapılmaktadır. Normal şartlar altında test görüntülerinin dağılımlarının da eğitim görüntülerine paralellik göstermesi zorunluluğunu göz önüne aldığımızda, eğitim görüntülerinin dağılımının sınıflandırma için son derece önem arz ettiği ve sınıflandırma hakkında bilgi verdiği açıktır. Şekil 5.3'te iki ÖDH'ye ait eğitimden sonra sınıflara ait kazanan nöronlar boyanmış halde gösterilmiştir, gri renkteki nöronlar herhangi bir sınıf tarafından seçilmemişken, her farklı renkteki nöron farklı bir sınıf tarafından seçilmiştir. Aynı renkteki nöronlar aynı sınıf tarafından seçilmişlerdir. Bu bilgiler dahilinde şekile bakıldığında 1. haritada aynı sınıfa ait görüntülerin birbirlerine yakın konumlar aldığı, yani kümelenmeler oluşturduğu ve ayrıca sınıfların oluşturduğu bu kümelenmelerin birbirinden belirgin bir biçimde ayrıldığı görülmektedir. 2. haritada ise aynı sınıftan olan görüntülerin kümelenme yapmadığı ve sınıfların birbiri içersine girdiği görülmektedir.



Şekil 5.3. Eğitimden sonra kazanan nöronların harita üzerindeki dağılımları a) Kaliteli harita dağılımına örnek b) Kalitesiz harita dağılımına örnek

¹ Bu uzaklıklar, harita uzayı üzerindeki uzaklıklar da olabilir, gözlemlere ait vektör uzayındaki uzaklıklar da olabilir, çünkü ÖDH vektörel olarak çok boyutlu ifade edilen gözlemler arasındaki ilişkiyi harita düzlemine indirgeyerek anlaşılabilirliğini artırmaktadır.

Şekil 5.3'te belirtilen haritalar kullanılarak yapılacak olan bir test işlemlerinde, aynı test görüntüsünün her iki haritada da 20 numaralı nöronla eşleştiğini varsayalım. 1. haritaya bakıldığında bu görüntünün turkuaz renkli sınıftan bir görüntü olduğunu söylemek oldukça güvenilir bir tahmin olacaktır. Ancak 2. haritada 20 numaralı nöron çevresinde her üç sınıf tarafından da seçilmiş nöronlar bulunmaktadır. Bu, ilgili bölgedeki nöronların ağırlık vektörlerinin belirli bir sınıfa ait giriş vektörlerine yaklaşmadığı, aksine hepsine yakın uzaklıklarda olduğunu göstermektedir. Bu durumda bu test görüntüsü için yapılan sınıf tahmininin güvenilirliği oldukça düşüktür. Test görüntüsünde yer alan ve kendi sınıfından olan görüntülerde bulunmayan küçük bir farklılık görüntünün farklı bir sınıfta algılanmasına neden olacaktır. 2. haritaya tekrar bakıldığında diğer pek çok nöronun durumunun 20 numaralı nörona farksız olmadığı görülmektedir.

Bir ÖDH ile yapılan sınıflandırmaya ne kadar güvenebileceğimize eğitim esnasında, görüntülerin harita üzerinde hangi özelliklerde yayıldığına (yayılım, dispersiyon) bakarak karar verebiliriz. Eğitim ardından, eğitim görüntülerinin² harita üzerinde dağılımında; belirli bir sınıfa ait nöronların yayılımının (sınıf içi yayılımın) az, sınıfların oluşturduğu kümelenmelerin konumlarının yayılımları yani sınıflar arası yayılımın fazla olması sınıflandırma güvenilirliğini artıran önemli iki etmen olarak ortaya çıkmaktadır. Bir sınıfa ait görüntülerin harita üzerinde kümelenmediği, dağınık olarak konuşlandığı dağılımlarda kümelenmeden bahsedilemeyeceği için sınıflar arası yayılımdan bahsederken sınıflara ait görüntülerin orta noktalarının belirlenmesi ve sınıf orta noktası olarak isimlendirebileceğimiz bu noktaların yayılımının sınıflar arası yayılım ölçütü olarak düşünülmesi yerinde olacaktır.

Yayılım indeksi (index of dispersion) kabaca, bir olasılık dağılımının yayılımını veren katsayıdır ve varyansın ortalamaya bölünmesiyle hesaplanmaktadır [Upton ve Cook, 2008]. D ile ifade edilen yayılım indeksi Eş. 5.1'de verilmiştir. Eşitlikte σ^2 varyansı ve μ ortalamayı ifade etmektedir.

² "Eğitim görüntülerine ait BMU konumları" kısaca bu şekilde ifade edilmiştir.

$$D = \frac{\sigma^2}{\mu} \quad (5.1)$$


Ancak bu tanımda verilen yayılım sayı doğrusu üzerindeki tek boyutlu bir veri seti için geçerlidir. Çalışmamızda tercih ettiğimiz ÖDH düzlemleri ise 2 boyutludur ve yayılım, görüntülerin düşey ve yataydaki konumlarının beraber ele alınması durumunda anlamlı olabilecektir. Bu nedenle haritadaki yayılımın ölçülmesi için *harita yayılım indeksi* olarak isimlendirilen farklı bir oran kullanılmıştır. Harita yayılım indeksi, bir nöron setindeki nöronların orta noktalarına olan uzaklıklarının karelerinin toplamının, orta noktanın orijine uzaklığına oranıdır. Eş. 5.2'de n adet nöron içeren bir sette, konumları (x_i, y_i) olarak ifade edilen nöronların haritanın üzerindeki yayılımlarının hesaplanması verilmektedir.

$$D_H = \frac{\sum_{i=1}^n (x_i - x_{ort})^2 + (y_i - y_{ort})^2}{\sqrt{x_{ort}^2 + y_{ort}^2}} \quad (5.2)$$

Eşitlikte D_H harita yayılım indeksini, x_{ort} ve y_{ort} ise nöron setinin orta noktasının koordinatlarını vermektedir.

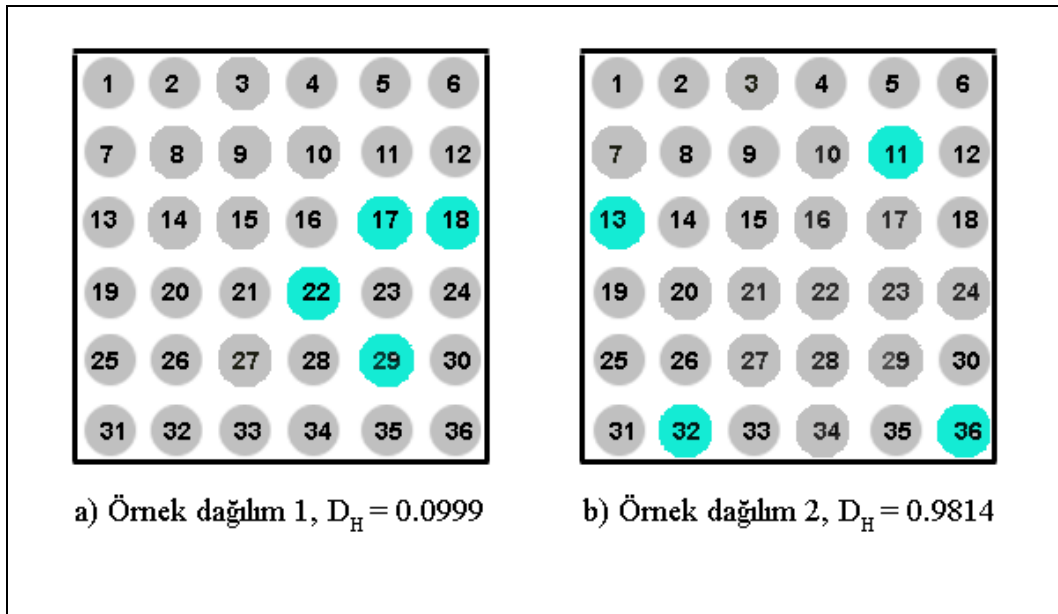
Harita yayılım indeksine bakılarak farklı nöron setlerinin yayılımları doğrudan kıyaslandığında, orta noktaya olan uzaklıklarının kareleri toplamı aynı olsa bile orta noktalarının koordinatları daha yüksek olan setler daha az yayılmış olarak algılanacaklardır. Bunun önüne geçmek için kıyaslama yapılan setlerin orta noktaları aynı olacak şekilde belirli bir yöne taşınmaları gerekmektedir. Bu nedenle nöron setlerinde x eksenine dikey olarak en yakın nöronun x koordinatı 1 olacak şekilde ve y eksenine dikey olarak en yakın nöronun y koordinatı 1 olacak şekilde taşınmaktadır. Taşıma işlemi Şekil 5.4'te örneklendirilmiştir. Harita yayılım indeksi bu geçici taşıma ardından hesaplanmaktadır. Taşıma işleminde orta noktaları aynı iki nöron setinden daha geniş bir alana yayılmış olan nöron setlerinin daha az kaydırılabileceği ve kaydırma sonundaki geçici orta noktasının orijine daha uzak olacağı açıktır. Ancak uzaklıkların kareleri toplamının ikinci dereceden olması

nedeniyle bu iki nöron setinden daha geniş alana yayılmış olanın harita yayılım indeksi beklendiği gibi daha fazla çıkacaktır ve kıyaslama sonucu doğru olacaktır.



Şekil 5.4. Gözlemlerin orijine doğru taşınması

Şekil 5.5'te iki nöron setinin harita üzerinde dağılımları ve hesaplanmış harita yayılım indeksleri verilmiştir.



Şekil 5.5. Hesaplanmış örnek harita yayılım indeksleri

Uygulanan yöntemin adımlarına geri dönecek olursak, blokların eğitiminden sonra elimizde eğitim setindeki görüntülerin bloklarına ait BMU indeksleri bulunmaktadır. Her bir blok konumu için yaratılmış olan ÖDH'lerin sınıflandırma sonuçlarına ne kadar güvenebileceğimizi anlamak için haritalardaki sınıf içi ve sınıflar arası harita yayılım indeksleri hesaplanmaktadır. Tüm görüntünün sınıflandırma sonucuna katkı sağlayacak olan blokların bu katkıyı ne oranda yapacağı ne kadar iyi sınıflandırıldıkları ile doğrudan ilgilidir, bu nedenle blokları sınıflandıran ÖDH'lerde sınıf içi ve sınıflar arası yayılımların bilinmesine ihtiyaç vardır. Bu amaçla öncelikle aynı sınıftaki bloklar için kazanan seçilmiş nöronların ÖDH üzerindeki konumlarına bakılarak sınıf içi harita yayılım indeksleri, ardından aynı sınıftaki bloklar için kazanan seçilmiş nöronların konumlarının orta noktalarını kullanılarak sınıflar arası harita yayılım indeksleri hesaplanıp kaydedilmektedir.

5.1.5. Test görüntülerine ait blokların sınıflandırılması (ön sınıflandırılma)

Yöntemin eğitim ve sonrasındaki yayılım analizi aşamalarından sonra artık test işlemine geçebilir durumdadır. Test görüntüsünün bloklara ayrılıp, her bloğa TBA uygulanmaktadır, sonra ÖDH'ler üzerine yansıtılarak bloklara ait kazanan nöron indeksleri kaydedilmektedir. Bu indekslere karşılık gelen nöronların etiketlerine göre ya da eğer etiketsiz bir nöron ise eğitim esnasında belirlenmiş sınıf orta noktalarına olan uzaklığına³ göre bloklara sınıf tayini yapılmakta ve bu sınıflandırma sonuçları kaydedilmektedir, bu görüntünün tamamını değil sadece blokların sınıf tayini olduğu için bu adıma *ön sınıflandırma* diyebiliriz.

Çizelge 5.1'de bir test senaryosuna ait 2. sınıftaki (kişiye ait) test görüntülerinin blok ön sınıflandırma sonuçları verilmiştir. İlgili testte görüntüler 16 bloğa ayrılmıştır ve bu blokların bazılarının 2. sınıftan farklı bir sınıf olarak sınıflandırıldığı görülmektedir.

³ Bu uzaklığın ölçümünde Öklid uzaklığı esas alınmaktadır.

5.1.6. Blok sınıflandırma güvenilirlik puanlarının hesaplanması

Blokların sınıflandırma sonuçlarının, genel sınıflandırma sonuçlarına katkısından önce her blok için aynı kalitede sınıflandırma yapılmamış olması, yani blokların sınıflandırma sonuçlarına aynı oranda güvenemeyeceğimiz gerçeğinden yola çıkarak üçüncü adımda hesaplamış olduğumuz yayılım indekslerini kullanarak blokların sınıflandırma güvenilirlikleri puanlanmaktadır. Nihai olan sınıflandırma işleminde bir ÖDH harita ne kadar güvenilir sınıflandırma yapmışsa o ÖDH’de sınıflandırılmış olan blokların konumu sınıflandırma sonucuna o kadar etki edecektir. Bu bazı çalışmalarda kullanılan kırılmış yüzlerden oluşan veritabanlarının kullanılması gerekliliğini de ortadan kaldıracaktır [Liu ve Wechsler, 2002, Lyons ve ark., 1999].

Çizelge 5.1. 16 Bloğa ayrılmış görüntüler için bir kişiye ait 4 test görüntüsünün ön sınıflandırma sonuçları

Test Görüntüsü Numarası →				
Blok Numarası ↓	1	2	3	4
1	13	2	1	13
2	2	2	2	2
3	2	2	1	2
4	2	2	2	2
5	1	2	2	2
6	2	2	8	2
7	16	2	2	2
8	1	2	2	6
9	12	2	2	2
10	4	2	2	4
11	2	2	2	2
12	2	2	2	2
13	15	2	2	2
14	2	2	2	2
15	13	13	14	11
16	14	14	14	14

Puanlamada ilgili bloğun kendi sınıf içi ve sınıflar arası harita yayılım indeksinin yanında 4-komşuluğundaki blokların da sınıflandırma sonuçları ve yayılım indeksleri

dikkate alınmaktadır. Çalışmadaki özgün bir özellik olan bu yaklaşımın nedeni, görüntü içersindeki bazı blokların komşularından ve genelleme yaparsak görüntü genelinden aykırı (outlying) bir sonuç sergilemesi ve bu aykırılığın göz ardı edilmek istenmesidir.

Puanlamayla ilgili açıklamalara geçmeden önce bazı tanımlamalar vermek yerinde olacaktır.

Blok_Sınıflar_Arası_Yayılm_İndeksleri: 5.1.4 bölümünde hesaplanan eğitim ardından oluşan sınıflar arası yayılım indekslerini tutan matrisi,

Blok_Sınıf_İçi_Yayılm_İndeksleri: 5.1.4 bölümünde hesaplanan eğitim ardından oluşan aynı sınıfa ait görüntülerin yayılım indekslerini tutan matrisi,

Komşu_etki_katsayısı: Blok sınıflandırma doğruluk puanlarının hesaplanmasında ilgili bloğun komşularının sınıflandırma sonuçlarının blok doğruluk puanına etkisini veren katsayıyı,

Etki_Yönü: Blok ile ilgili komşusu aynı ön sınıflandırma sonucuna sahipse +1, aksi takdirde -1 olan işaret katsayısını,

Komşu_etki_puanı: Bir bloğun komşuların blok doğruluk puanına toplam etkisini,

Blok_Ön_Sınıflandırma_Sonuçları: 5.1.5 bölümünde belirlenmiş olan blok ön sınıflandırma sonuçlarını tutan matrisi,

Blok_Sınıflandırma_Güvenilirlik_Puanları: Her bir blok için sınıflara ait sınıflandırma güvenilirlik puanlarını tutan Blok_sayısı X Sınıf_sayısı boyutlarındaki matrisi ifade etmektedir.

Aşağıdaki Eş. 5.3'te Komşu_Sayısı kadar komşusu olan bir bloğun sınıflandırma puanına komşularının toplam etkisi verilmiştir.

$$\text{Komşu_etki_puanı} = \frac{\sum_{i=1}^{\text{Komşu Sayısı}} \frac{\text{Etki_Yönü} * \text{Blok_Sınıflar_Arası_Yayılım_İndeksleri}_i}{\text{Blok_Sınıf_İçi_Yayılım_İndeksleri}_i}}{\text{Komşu_Sayısı}} \quad (5.3)$$

Eş. 5.3'te verilen blok sınıflar arası ve sınıf içi yayılım indeksleri 0 ile 10 arasında değerler almaktadırlar. Sınıflar arası yayılım indeksi kaliteyi artıran ve sınıf içi yayılım indeksi kaliteyi azaltan faktörler olduğundan, eşitlikte payda olan sınıflar arası yayılım indeksinin artması ile sınıflandırma kalitesi artmakta, paydada olan sınıf içi yayılım indeksinin artması ile ilgili bloğun sınıflandırma kalitesi azalmaktadır. Eşitlikte komşu etki puanı hesaplanan blok ile komşusunun sınıfları farklı ise bu bloğa ait etki negatif olmaktadır.

Çizelge 5.2. Görüntülerin 16 bloğa ayrıldığı bir test senaryosunda blok sınıflandırma güvenilirlik puanları

Blok Numarası	Sınıflandırma Güvenilirliği
1	9,04
2	9,79
3	8,23
4	8,66
5	9,25
6	8,57
7	7,56
8	6,78
9	9,43
10	8,20
11	6,27
12	4,83
13	10
14	7,69
15	5,84
16	6,96

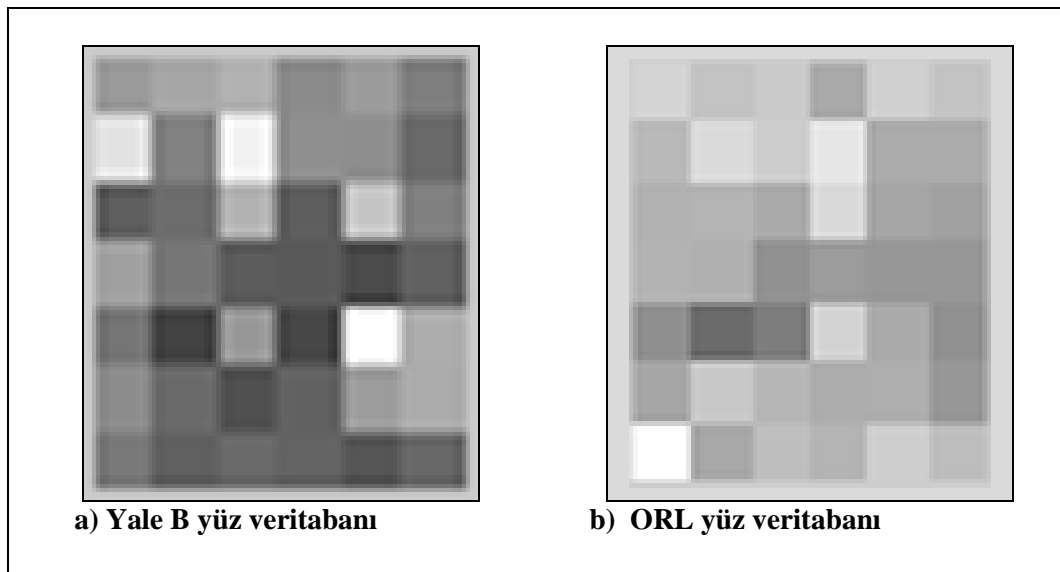
Aşağıda Eş. 5.4'te ise k. test görüntüsünün n.bloğuna ait ön sınıflandırmada belirlenen sınıfın güvenilirlik puanını hesaplanması verilmiştir. Blok sınıflandırma kalitesi olarak blok sınıflar arası yayılım indeksi doğrudan alınmıştır, çünkü haritanın sınırlı bir alana yayılmış olması nedeniyle sınıf içi yayılımların fazlalığı, sınıflar arası yayılımın azlığını göstermektedir. Bloğun kendisi için olan sınıflandırma

güvenilirliği sınıflandırmada daha etkili olduğu için, komşulardan gelecek etkiyi azaltan 0 ile 1 arasındaki Komşu_etki_katsayısı kullanılmaktadır. Böylece sınıflandırma kalitesi ile doğru orantılı olan blok sınıflar arası yayılım indeksi $1/\text{Komşu_etki_katsayısı}$ ile çarpılarak, blok sınıflandırma güvenilirlik puanına eklenmektedir.

$$\text{Blok_Sınıflandırma_Güvenilirlik_Puanları}_{(k,\text{Blok_Ön_Sınıflandırma_Sonuçları}_n)} = \left(\frac{\text{Blok_Sınıflar_Arası_Yayılım_İndeksleri}_n}{\text{Komşu_etki_katsayısı}} \right) \cdot \text{Komşu_etki_puanı}_k \quad (5.4)$$

Çizelge 5.2’de bir test senaryosuna ait Eş. 5.4’e göre hesaplanmış blok sınıflandırma güvenilirlik puanları verilmiştir. Puanlama 10 üzerinden yapılmıştır. Güvenilirliği en fazla olan 13.blok sınıflandırma sonucuna en fazla katkıyı sağlayacaktır.

Tezde önerilen yöntemde bloklar, görüntünün genel sınıflandırma sonucuna ilgili oldukları ÖDH’nin sınıflandırma güvenilirliği oranında etki edeceklerdir. Bu adımda belirlenmiş olan blok sınıflandırma güvenilirlik puanları ile birlikte hangi bloğun ne kadar katkı sağlayacağı Yale B ve ORL yüz veritabanları için Şekil 5.3’te gösterilmiştir.



Şekil 5.6. Sınıflandırma Güvenilirlikleri oranında ağırlıklandırılmış gri seviyeli yüz haritaları

5.1.7. Görüntü sınıflandırma sonucunun elde edilmesi

Bir önceki adımda kaydedilen blok sınıflandırma güvenilirlik puanları sınıflar bazında birikimli olarak toplanarak, her bir sınıfın o görüntüden toplam ne kadar puan aldığı hesaplanmaktadır. Bu işlem yapılırken Çizelge 5.1'den yola çıkılmaktadır. Bir test görüntüsünün bir sınıf için güvenilirlik puanının hesaplanması için öncelikle bloklarından en az bir tanesinin ön sınıflandırma sonucunun ilgili sınıf olarak belirlenmiş olması gerekmektedir. Çizelge 5.1'de örnek olarak verilen ön sınıflandırma sonuçları için, Çizelge 5.3'te blok sınıflandırma güvenilirlik puanları sınıflar bazında birikimli olarak verilmiştir.

Çizelge 5.3. Veritabanından 20 kişi kullanan bir test senaryosunda
2.kişinin (sınıfın) test görüntülerinin güvenilirlik puanları toplamı

		Test Görüntüleri			
		1	2	3	4
Veritabanında yer alan sınıfların (kişilerin) aldığı puanlar	1	116,59	0	-192,17	0
	2	829,20	2630,33	1599,37	1757,84
	3	0	0	0	0
	4	26,51	0	0	16,59
	5	0	0	0	0
	6	0	0	0	36,96
	7	0	0	0	0
	8	0	0	-190,11	0
	9	0	0	0	0
	10	0	0	0	0
	11	0	0	0	-43,54
	12	85,75	0	0	0
	13	-	-43,54	0	-95,64
	14	-77,30	-77,30	-69,91	-77,30
	15	3,70	0	0	0
	16	65,02	0	0	0
	17	0	0	0	0
	18	0	0	0	0
	19	0	0	0	0
	20	0	0	0	0

Çizelge 5.4'te ise sınıflandırma güvenilirlik puanları 100 üzerinden verilmiştir. Çizelge 5.1'e bakıldığından 1 numaralı test görüntüsünün bloklarının 1,2,4,12,13,14,15,16 numaralı sınıfları seçtiği görülmektedir. Çizelge 5.4'te sadece bu sınıflara ait blok sınıflandırma güvenilirlik puanı hesaplanmış, diğer sınıfların güvenilirlik puanı '-' olarak gösterilmiştir. Bu toplam tablosuna bakılarak sınıflandırma sonucu tayin edilmektedir. Bir görüntü için bloklarda en fazla puanı toplamış olan sınıf, kazanan sınıf olarak ilan edilmektedir. Çizelge 5.3'te verilen değerler 2. sınıfa ait test görüntüleri içindir ve bu sınıftaki tüm yüzler doğru sınıflandırılmıştır.

Çizelge 5.4. Veritabanından 20 kişi kullanan bir test senaryosunda
2.kişinin test görüntülerinin normalize edilmiş güvenilirlik puanları
toplamı

		Test Görüntüleri			
		1	2	3	4
Veritabanında yer alan sınıfların (kişilerin) aldığı puanlar	1	23,91	-	0,11	-
	2	100,00	100,00	100,00	100,00
	3	-	-	-	-
	4	14,29	-	-	6,10
	5	-	-	-	-
	6	-	-	-	7,20
	7	-	-	-	-
	8	-	-	0,22	-
	9	-	-	-	-
	10	-	-	-	-
	11	-	-	-	2,86
	12	20,62	-	-	-
	13	0,11	1,27	-	0,05
	14	3,21	0,03	6,92	1,04
	15	11,86	-	-	-
	16	18,40	-	-	-
	17	-	-	-	-
	18	-	-	-	-
	19	-	-	-	-
	20	-	-	-	-

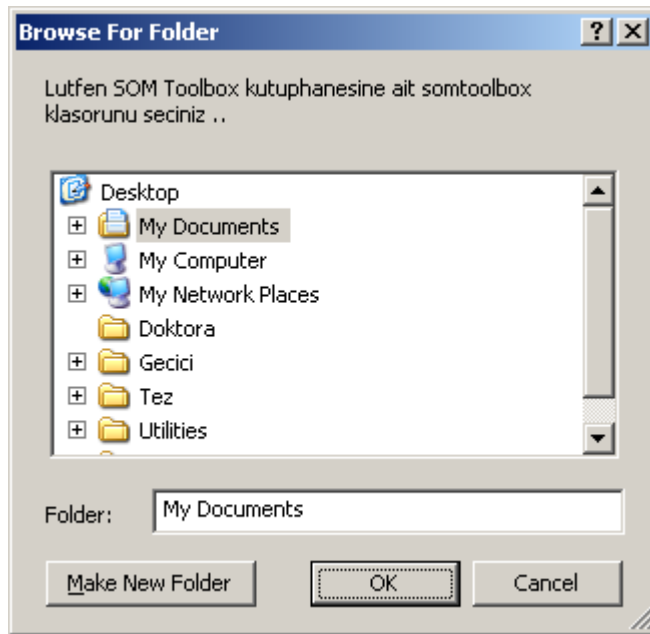
5.2. Geliştirilen Uygulamanın Çalışması

Önerilen yöntemin test edilmesi için Matlab ile bir uygulama geliştirilmiştir. Uygulamada önerilen yöntem, Olivetti Research Ltd (ORL) tarafından geliştirilmiş ORL yüz veritabanı [Samaria ve Harter, 1994] olarak tanınmış olan veritabanı ve Yale B yüz veritabanı [Georghiades ve ark., 2001] ile denenmiştir. Uygulamanın ORL yüz veritabanında çalışan sürümünün adımları aşağıda anlatılmıştır.

5.2.1 Sistem özelliklerin belirlenmesi ve görüntülerin okunması

Uygulama çalıştırıldığında ilk olarak kullanılan yazılım kütüphanesinin dosya sistemindeki yerini belirlenmektedir. Şekil 5.7’de gösterilen sorgulamanın ardından bu yer bilgisi Matlab yoluna (path) eklenmektedir.

Uygulamada sonraki adımda kullanılan yüz veritabanının dosya sistemi üzerindeki yeri belirlenerek bu yer bilgisi de Matlab yoluna eklenmektedir. Sorgu ekranı Şekil 5.8’de görülmektedir.



Şekil 5.7. Kullanılan yazılım kütüphanesinin dosya sistemindeki yerinin belirlenmesi



Şekil 5.8. Yüz veritabanının dosya sistemindeki yerinin belirlenmesi

Ardından Şekil 5.9’da gösterilmiş diyalog kutusu yardımı ile sisteme ait aşağıdaki özellikler girilmektedir:

- Eğitimde kullanılacak yüz adedi
- Oluşturulacak olan ÖDH’lerin yatay ve düşeydeki boyutları
- Eğitimlerdeki epok (yineleme) sayısı
- Görüntü bloklarının yatay ve düşeydeki boyutları
- Eğitim ve düzenleme (ince ayar) için öğrenme oranları
- Eğitim komşuluk yarıçapı (başlangıç için)
- Komşu etki katsayısı

Bu özelliklerin kaydedilmesi ardından görüntülerin okunmasına geçilmektedir. Okunan görüntüler Histogram Eşitleme yöntemi ile iyileştirilmekte ve ardından istenilen büyüklükteki bloklara ayrılmaktadırlar. Bloklara ait gri seviye değerleri işlemlerde kullanılmak üzere vektörleştirilerek kaydedilmektedir.

The image shows a Windows-style dialog box titled "Som Properties". It contains several input fields with the following labels and values:

- Veritabanındaki 40 kisten kaç kisiyi kullanmak istiyorsunuz ? : 40
- 10 yuzden kac tanesini egitim icin kullanacaksınız ? : 6
- Izgara X boyutunu giriniz: : 16
- Izgara Y boyutunu giriniz: : 16
- Epok Sayisi: : 250
- Alt Blok X boyutu(1,2,2,7 sayilarinin carpimi olabilir) : : 7
- Alt Blok Y Boyutu(1,2,2,2,3 sayilarinin carpimi olabilir) : : 6
- Egitim icin Ogrenme Orani: : 0.5
- Ince Ayar icin Ogrenme Orani: : 0.05
- Egitim icin Komsuluk İlk Capi : : Boyuta gore varsayılan hesaplanır
- Komsu etki katsayisi (0-1 arasında) : : 0.1

At the bottom of the dialog box, there are two buttons: "OK" and "Cancel".

Şekil 5.9. Sistem değişkenleri giriş ekranı

5.2.2 Sınıflandırma adımları

Yüz vektörleri oluşturduktan sonra bir önceki bölümde anlatılan yönteme ilişkin adımlar uygulanmakta ve sınıflandırma sonuçları kaydedilmektedir. Şekil 5.10'da görüldüğü gibi uygulama çalışırken devam etmekte olan işlemin ne olduğu hakkında bilgi verilmekte ve eğitim gibi uzun zaman işlemlerde bu bilgiye tahmini işlem süresi de eklenmektedir.

```

Yuz verilerine Temel Bilesen Analizi(TBA) uygulanıyor ...
TBA tamamlandi.
Etiketleme yapiliyor...
Etiketleme tamamlandi.
Oz duzenleyici harita icin veri yapilari hazirlaniyor..
Veri yapilari hazir.
Oz duzenleyici haritalar olusturuluyor ..
Oz duzenleyici haritalar hazir..
Egitim yapiliyor ..
1.blok egitiliyor...
Tahmini Islem Suresi: 1.575 sn

2.blok egitiliyor...
Tahmini Islem Suresi: 1.68 sn

```

Şekil 5.10. İşlemlerle ilgili bilgi verilmesi

Uygulamada ÖDH'ların eğitim işlemi (düzenleme adımı ile birlikte) tamamlanana kadarki kısım uygulamada toplam işlem süresinin çok büyük kısmını kullanmaktadır. Yöntemimize ilişkin güvenilirlik puanlaması ve sınıflandırma gibi özgün yönler ise bu adımdan sonra eğitilmiş ÖDH'ler üzerinde yapılmaktadır. Bu özgün yönlerde yapılan değişikliklerin baştaki uzun süren adımların tekrarlanmasına neden olmaması için eğitim ardından o anki Matlab çalışma alanı (workspace) kaydedilmektedir ve aynı parametrelerle sistem çalıştırıldığında bu çalışma alanı yüklenerek hazır görüntü vektörleri ve eğitilmiş ÖDH'ler kullanılmaktadır.

5.2.3 Sonuçların raporlanması

Uygulamanın sınıflandırma sonuçlarını üretmesinin ardından sonuçlar Şekil. 5.11'de verilen ekran görüntüsünde olduğu gibi ekrana basılmaktadır. Bu gösterilen sonuç, ilk adımda alınan sistem özelliklerinin tamamı ve testin gerçekleştiği zaman bilgilerini de içerecek bir metin dosyasına kaydedilmektedir.

```
42.blok icin duzenleme yapiliyor...
Tahmini Islem Suresi: 0.48 sn

Egitim tamamlandi.
Egitim ardindan en iyi eslesen nöronlar bulunuyor ...
En iyi eslesen noronlar bulundu.
Test görüntuleri icin en iyi eslesen nöronlar bulunuyor ..
Test görüntuleri icin en iyi eslesen noronlar bulundu.
Sinif tayinleri yapiliyor ...
Sinif tayinleri yapildi.
KA ODH Basari = ●●●
Calisma Suresi = 0 s 1 dk 0.041434 sn
```

Şekil 5.11. Sınıflandırma sonucu ekran görüntüsü

6. GÖRSEL VE SAYISAL TEST SONUÇLARI

Bu bölümde önerilen yöntemi test eden uygulamanın sonuçları kontrollü testlerle ortaya konulmuştur. Testlerde, etkisi ve optimum değerini araştırılan sistem parametresi değiştirilmiş, diğer parametrelerin değerleri sabit tutulmuştur. Testlerin sınıflandırma başarıları ve her bir testin ne kadar sürdüğünü bildiren sayısal sonuçlar grafiksel olarak verilmiştir. Sınıflandırma başarılarını veren grafiklerde karşılaştırmaya olanak sağlamak için tezde önerilen yöntemin esas aldığı yaklaşımı kullanan bir yöntem olan LMSOM yöntemine ait sonuçlar da verilmiştir. Sonuçlar öncelikle ORL yüz veritabanına ait olanları, sonra Yale B yüz veritabanına ait olanları vermektedir.

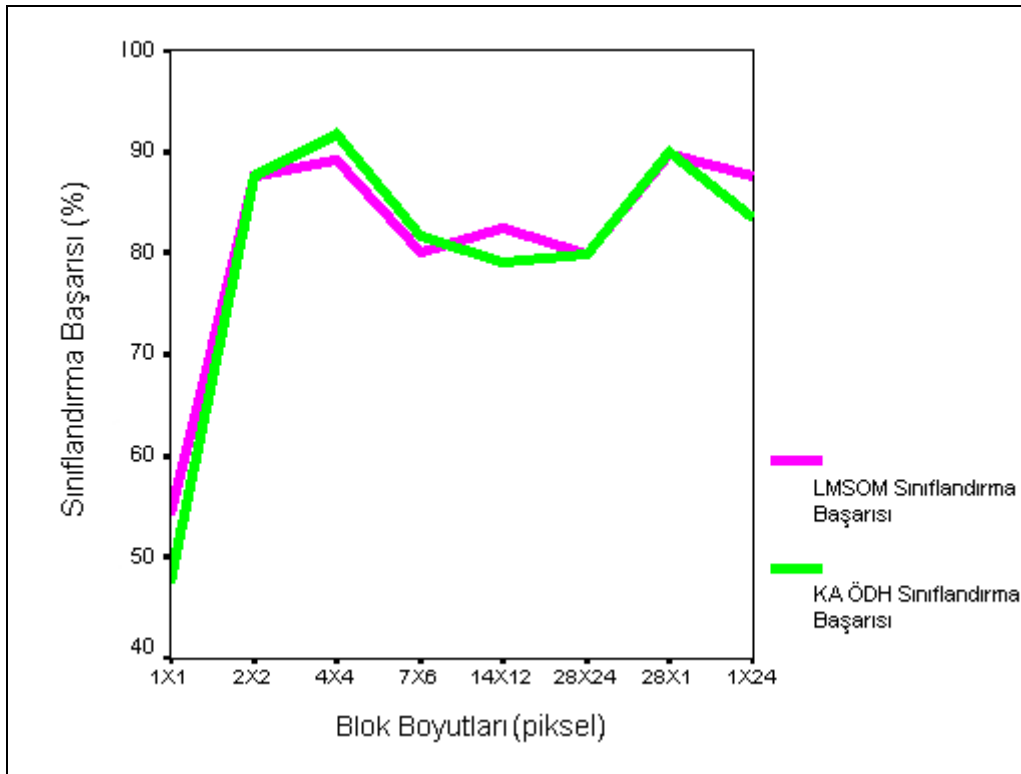
Testlerde kullanılan bilgisayar 2 X 2.26 GHz Intel Core2 Duo CPU P9300 işlemci, 1.98 GB RAM donanımına sahiptir ve işletim sistemi olarak Microsoft Windows XP SP3 kullanmaktadır.

Şekil 6.1’de ORL yüz veritabanı kullanılarak; ÖDH boyutları = 18X18, epok sayısı = 100, öğrenme oranı = 0,5, eğitim komşuluk yarıçapı= 2,25 ve komşu etki katsayısı = 0,01 değerleri olacak şekilde görüntüler farklı boyutlardaki bloklara bölünerek sınıflandırılmışlardır. Şekil 6.2’de de aynı değerler geçerlidir. Çizelge 6.1’de farklı blok sayılarında görüntünün toplamda kaç bloğa bölündüğü ile ilgili bilgi verilmiştir.

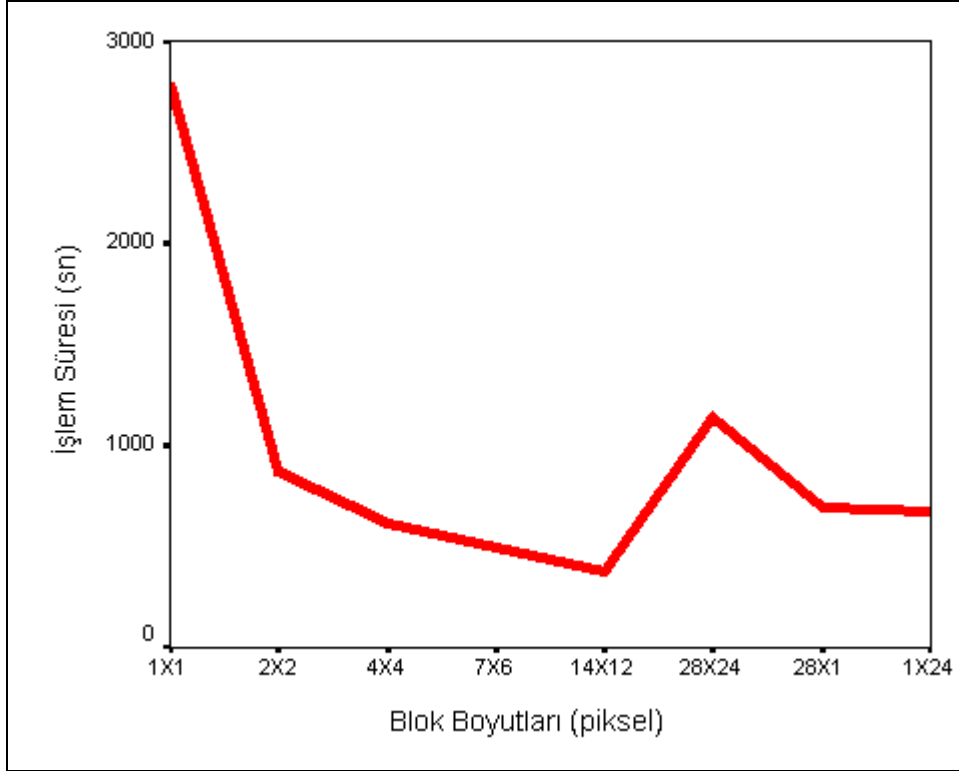
Çizelge 6.1. ORL ve Yale B yüz veritabanlarında sınıflandırma başarıları

Blok Yatay Boyutu (piksel)	Blok Düşey Boyutu (piksel)	Toplam Blok Sayısı
1	1	672
2	2	168
4	4	42
7	6	16
14	12	4
28	24	1
28	1	24
1	24	28

Şekil 6.1’de yatay ekseninde verilen değerler blokların yatay ve dikey boyutlarının piksel değerleridir. Bu şekillere bakıldığında en başarılı sınıflandırmanın 4X4 piksel boyutlarındaki bloklarda yapıldığı görülmektedir. Bunun anlamı seçilen boyutlardaki bloklar bu veritabanı için anlamlı küçük görüntüler oluşturmakta ve sınıflandırmaya etkisi olmayan görüntü kısımları başarıyla ayırt edilebilmektedir. Bazı blok büyüklükleri için LMSOM yönteminin daha başarılı sonuçlar verdiği gözlenirken 4X4 piksel boyutlarındaki bloklarda KA ÖDH yönteminin tüm sonuçlar içinde en iyi sonucu vermiştir. İşlem süresinde ise sistemde toplam kullanılan ÖDH sayısı ve haritaları eğitmekte kullanılan vektörlerin boyutları belirleyici olmaktadır. Eğitim vektörlerinin boyutları blok boyutlarından hesaplanmaktadır. Örneğin 4X4 piksel boyutlarındaki bloklarla çalıştırılmış sistemde eğitim vektörlerinin boyutları 16 olmaktadır. ÖDH sayısı ve eğitim vektörü boyutuna birlikte bakıldığında bu değerlerin yüksek olduğu 28X1 piksel boyutlarında bloklar kullanan senaryoda işlem süresi en uzundur.



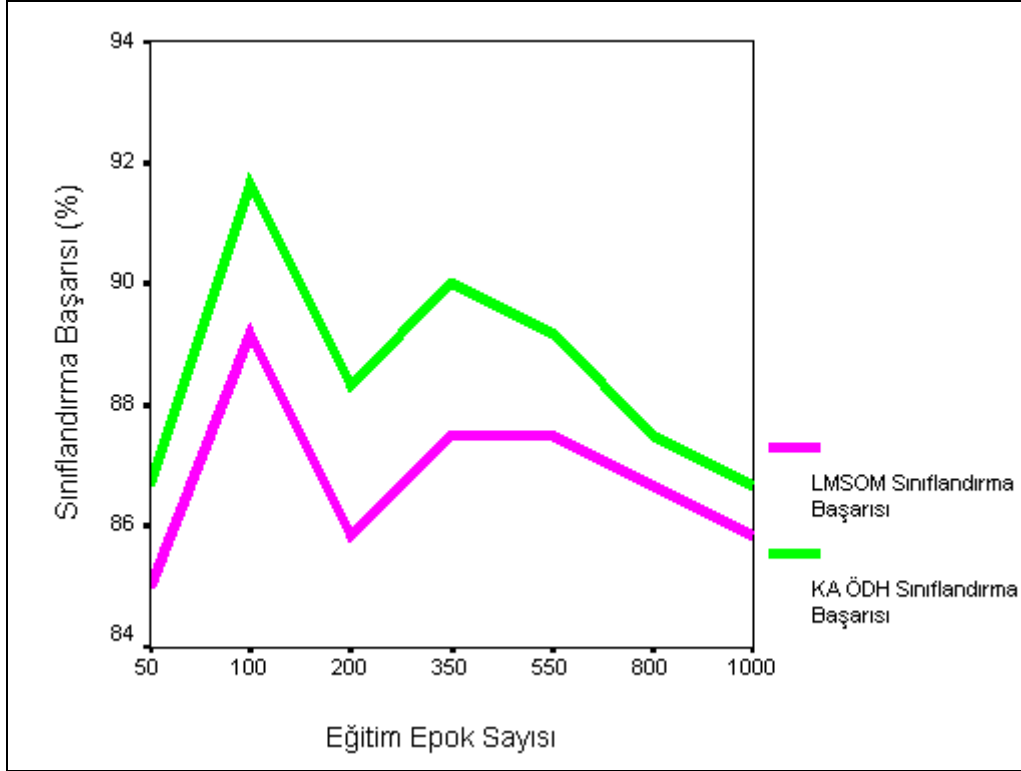
Şekil 6.1. ORL yüz veritabanı farklı blok boyutlarında sınıflandırma başarısı



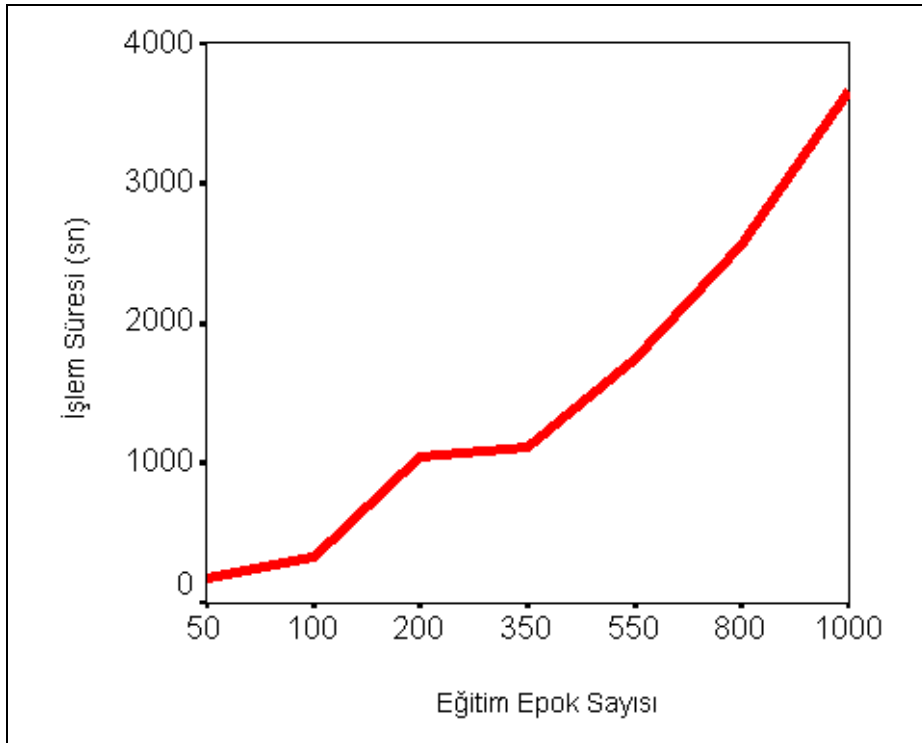
Şekil 6.2. ORL yüz veritabanı farklı blok boyutlarında toplam işlem süresi

Şekil 6.3 ve 6.4'te ORL yüz veritabanı kullanılarak; ÖDH boyutları = 18X18, blok boyutları 4X4 piksel, öğrenme oranı = 0,5, eğitim komşuluk yarıçapı= 2,25 ve komşu etki katsayısı = 0,01 değerleri olacak şekilde sistem farklı epok sayılarında çalıştırılmış ve sonuçlar üretilmiştir. Şekil 6.3'te eğitimin 100 epok ile yapıldığı test senaryosunda başarının en fazla olduğu gözlenmektedir. Bunu 4X4 piksel boyutlarındaki bloklar için uzunluğu 16 olan eğitim vektörleriyle eğitilen ÖDH'ler için 100 epok ile optimum öğrenim gerçekleşmekte, daha fazla eğitim ile ağırlık vektörleri istenilen değerlerden uzaklaşmaktadırlar. Şekilde LMSOM ile KA ÖDH kıyaslandığında tüm farklı epok sayıları için KA ÖDH yönteminin daha başarılı olduğu gözlenmektedir.

Düşük epok sayılarında iyi sonuçların alınmıyor olması önerilen yöntemin verimli olduğunu ortaya koymaktadır, zira şekil 6.4'e bakıldığında epok sayısı artıkça işlem süresinde de artış olmaktadır.



Şekil 6.3. ORL yüz veritabanı farklı epok sayılarında sınıflandırma başarısı

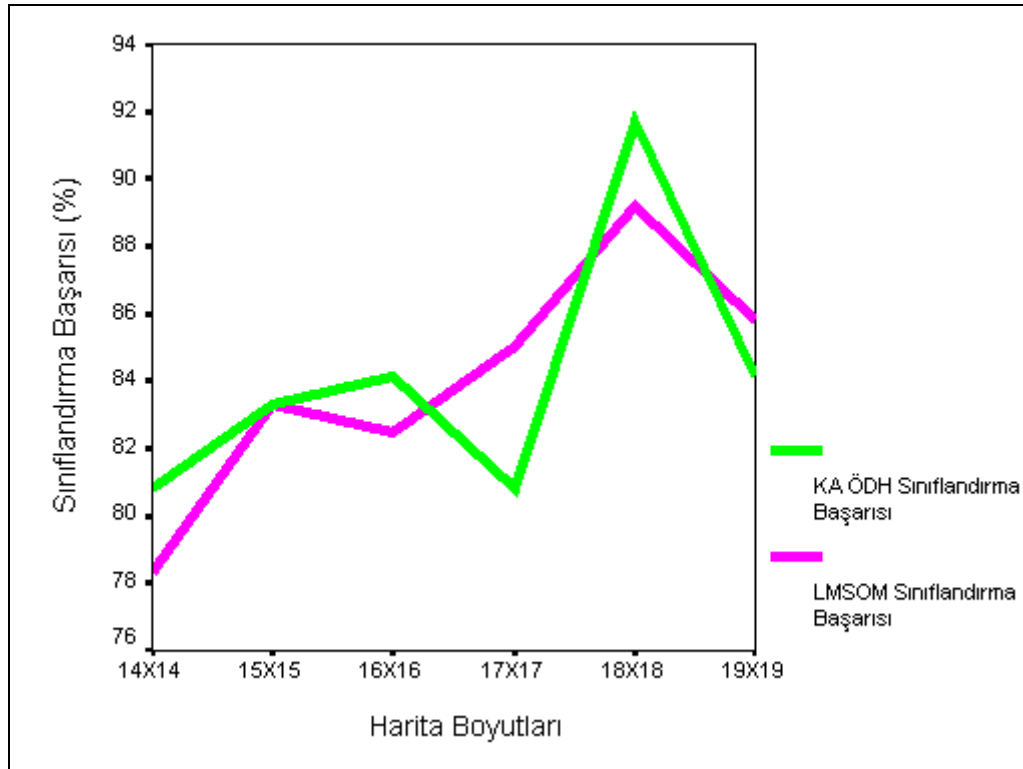


Şekil 6.4. ORL yüz veritabanı farklı epok sayıları için toplam işlem süresi

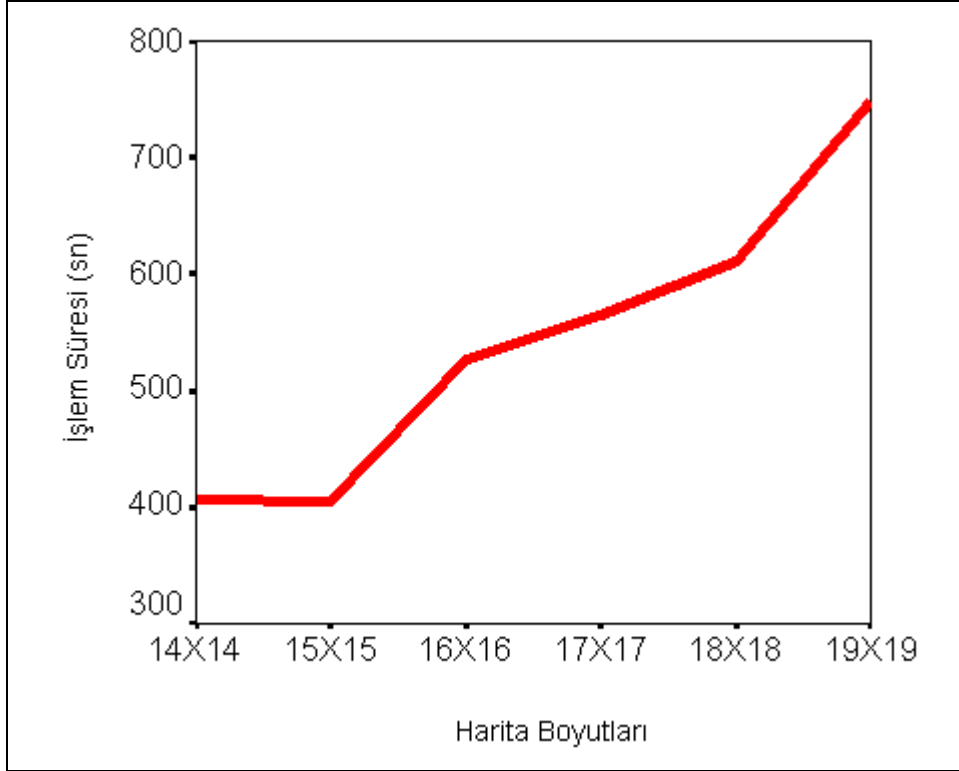
Şekil 6.5 ve 6.6'da ORL yüz veritabanı kullanılarak; epok sayısı = 100, blok boyutları 4X4 piksel, öğrenme oranı = 0,5 ve komşu etki katsayısı = 0,01 değerleri olacak şekilde, sistem farklı harita boyutlarında çalıştırılmış ve sonuçlar üretilmiştir. Eğitim komşuluk yarıçapı ise harita boyutuna bağlı olarak Eş. 6.1'de görüldüğü gibi hesaplanmıştır. Ağırlık vektörlerine ilk değer ataması doğrusal olduğunda, eğitim komşuluk yarıçapı için bu hesaplama ile değer atanması, kullanılan yazılım kütüphanesinde önerilmiş ve varsayılan olarak kullanılmıştır.

$$Komsuluk_Yaricapi = \max\left(1, \frac{\max(Harita_X_Boyutu, Harita_Y_Boyutu)}{8}\right) \quad (6.1)$$

Şekil 6.5'te görüldüğü üzere en başarılı sonuçlar 18X18 harita boyutlarında alınmıştır, bu harita boyutlarında elde edilen oran KA ÖDH ve LMSOM metotlarında görülen en yüksek başarı oranı olmuştur. İşlem süresinde ise harita boyutu artması sonucu gerçekleşen toplam nöron sayısı artışı ile birlikte işlem sürelerinin de arttığı Şekil 6.6'da gözlenmektedir.

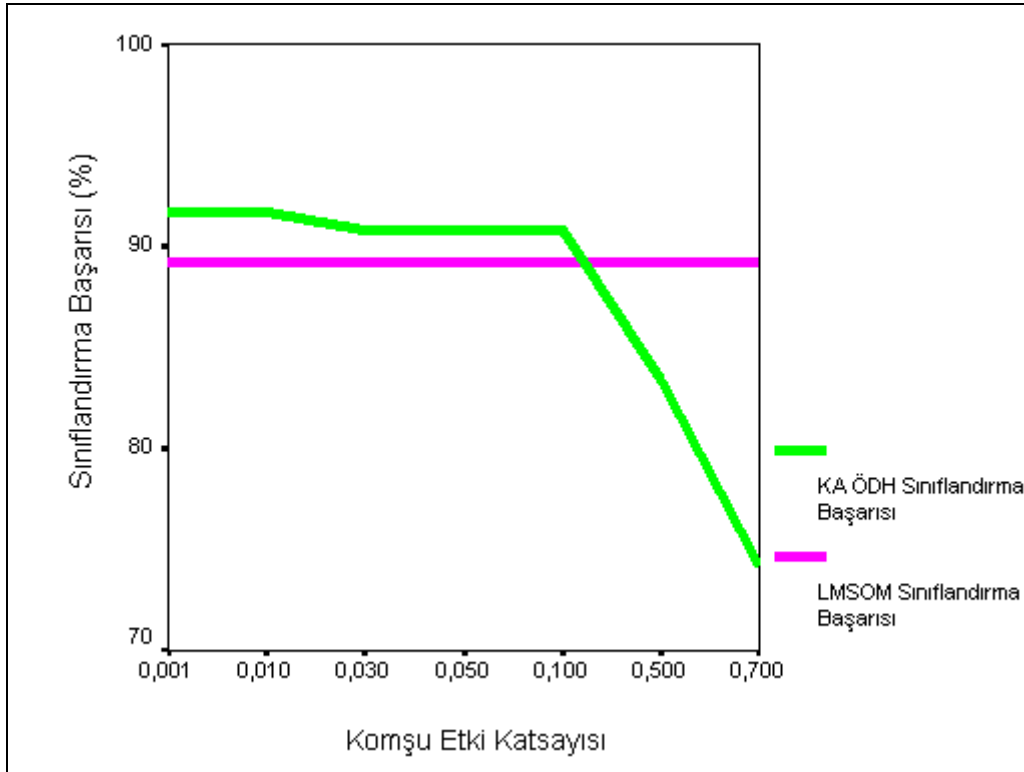


Şekil 6.5. ORL yüz veritabanı farklı ÖDH boyutlarında sınıflandırma başarısı



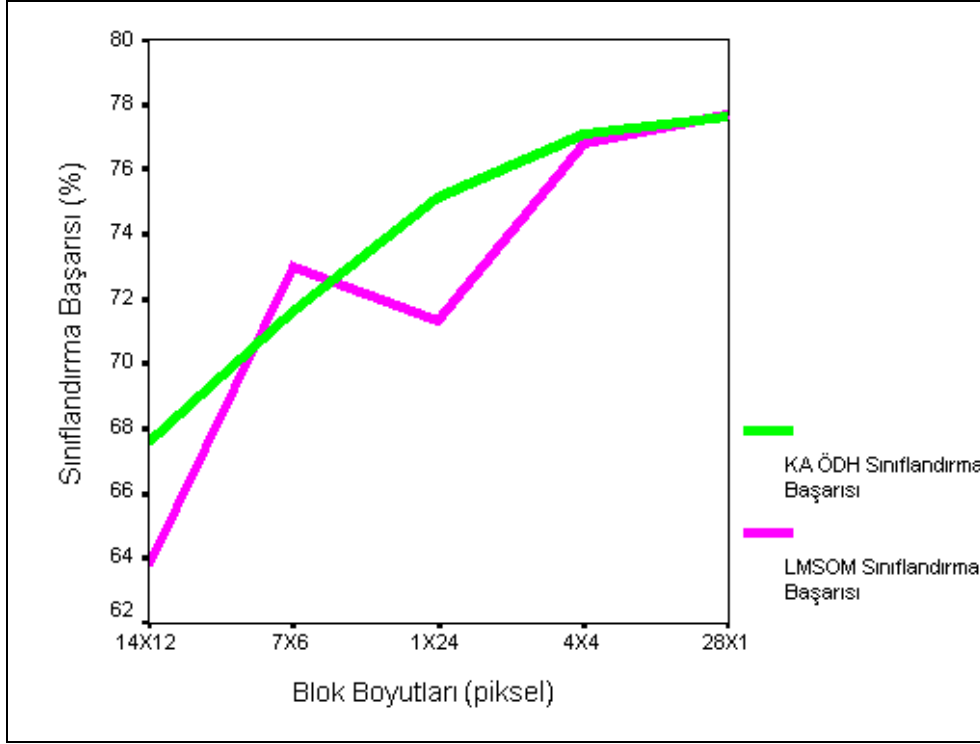
Şekil 6.6. ORL yüz veritabanı farklı ÖDH boyutlarında toplam işlem süresi

Şekil 6.7’de ise ORL yüz veritabanı kullanılarak; ÖDH boyutları= 18X18, blok boyutları 4X4 piksel, epok sayısı= 100, öğrenme oranı= 0,5 ve eğitim komşuluk yarıçapı= 2,25 değerleri olacak şekilde, sistem farklı komşu etki sayılarında çalıştırılmış ve sonuçlar üretilmiştir. Verilen grafikten en iyi sınıflandırma başarısının blokların kendi sınıflandırma sonuçlarına dayanılarak, komşu etkisinin azaltıldığı durumlarda elde edildiği durumda ortaya çıktığı gözlenmektedir. Zira blokların sınıflandırılma kalitelerini hesaba katan KA ÖDH metodunda komşu blokların etkilerinin azaltıldığında, başarının; blokların her birinin sınıflandırmaya eşit derecede etki ettiği LMSOM metodundan daha iyi olduğu görülmektedir.

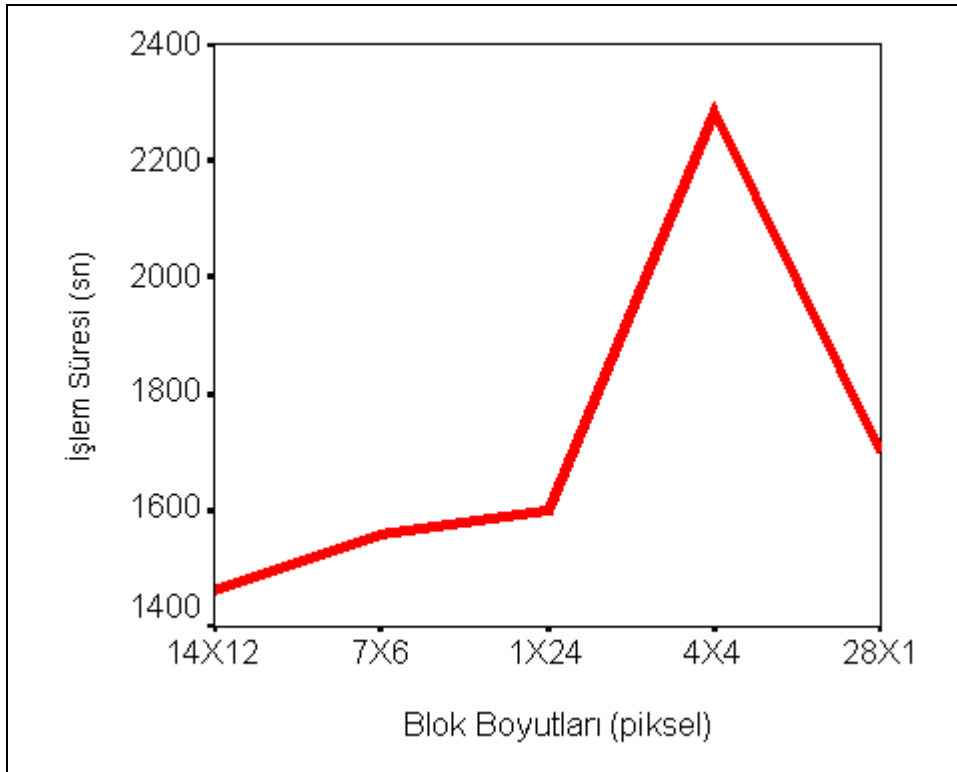


Şekil 6.7. ORL yüz veritabanı, farklı komşu etki katsayılarında sınıflandırma başarısı

Şekil 6.8 ve 6.9’da Yale B yüz veritabanı kullanılarak; ÖDH boyutları = 13X13, epok sayısı = 100, öğrenme oranı = 0,5, eğitim komşuluk yarıçapı= 1,63 ve komşu etki katsayısı = 0,01 değerleri olacak şekilde görüntüler farklı boyutlardaki bloklara bölünerek sınıflandırılmışlardır. Grafıklere bakıldığında en başarılı sınıflandırmanın 28X1 piksel boyutlarındaki bloklarda yapıldığı görülmektedir, bu Yale B yüz veritabanında 28X1 piksel boyutlarındaki bloklara ayrılması ile bloklar arasındaki farklılıkların en yüksek oranda ortaya çıktığı sonucunu ortaya koymaktadır. KA ÖDH metodu 7X6 piksel boyutlarındaki blokların kullanıldığı senaryo dışında LMSOM’a göre daha başarılı sonuçlar elde etmiştir. İşlem sürelerine bakılınca 4X4 piksel boyutlarındaki blokların kullanıldığı ve blok alanının küçüklüğü nedeniyle en fazla sayıda ÖDH kullanılmış olan test senaryosunun en fazla sürdüğü gözlenmektedir.

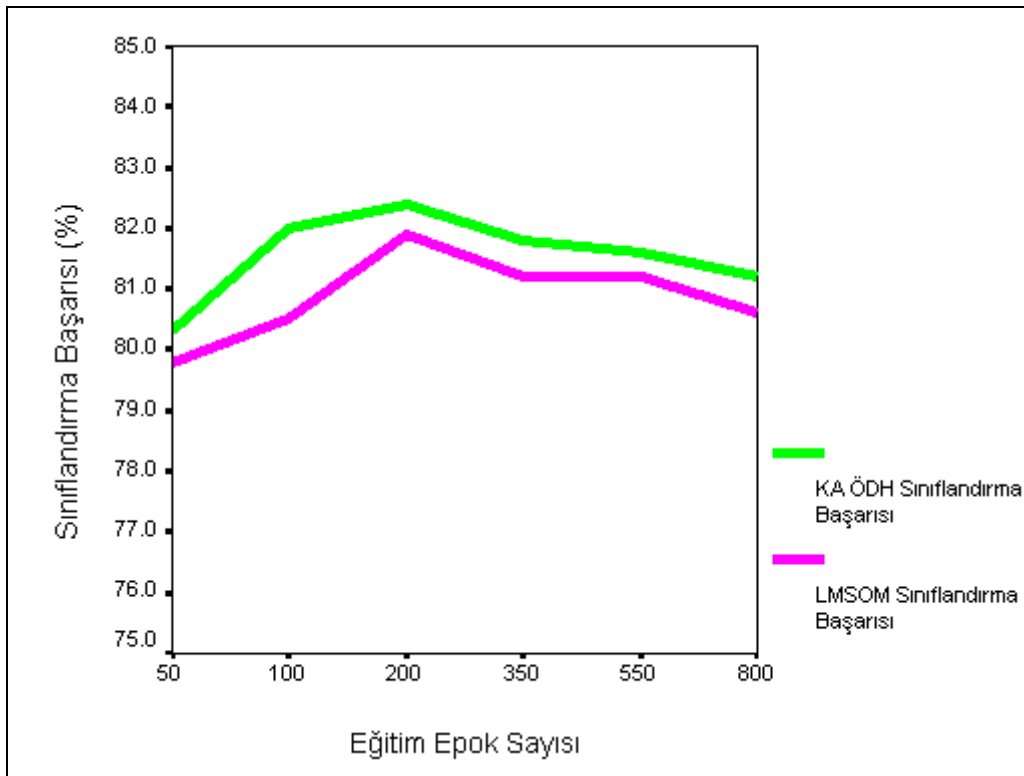


Şekil 6.8. Yale B yüz veritabanı farklı blok boyutlarında sınıflandırma başarısı

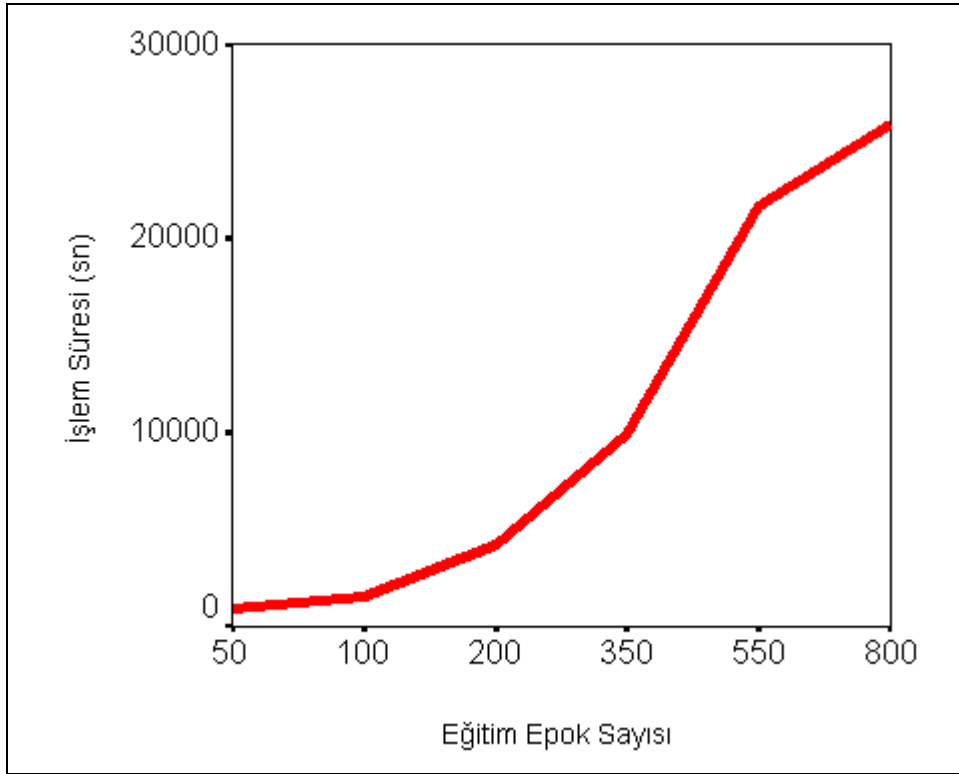


Şekil 6.9. Yale B yüz veritabanı farklı blok boyutlarında işlem süresi

Şekil 6.10 ve 6.11’de Yale B yüz veritabanı kullanılarak; ÖDH boyutları = 16X16, blok boyutları = 4X4 piksel, öğrenme oranı = 0,5, ilk eğitim komşuluk yarıçapı= 2,00 ve komşu etki katsayısı = 0,001 değerleri olacak şekilde sistem farklı epok sayılarında çalıştırılarak sınıflandırma yapılmıştır. Belirtilen değerler için en uygun epok sayısının 200 olduğu görülmektedir ve ayrıca 350’de yerel bir minimum olmakla birlikte 200’den az ve fazla değerlerde başarıda azalma görülebilmektedir. İşlem süresinde ise epok sayısındaki artışa paralel bir artış gözlenmektedir.

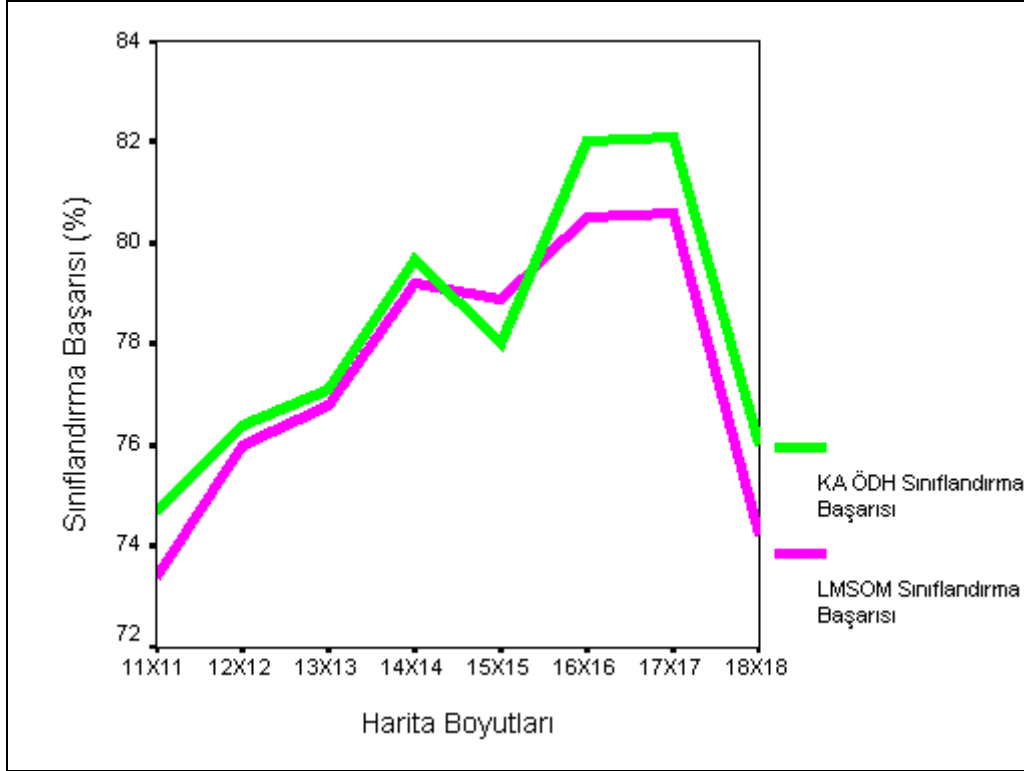


Şekil 6.10. Yale B yüz veritabanı farklı epok sayılarında sınıflandırma başarısı




Şekil 6.11. Yale B yüz veritabanı farklı epok sayılarında işlem süresi

Şekil 6.12 ve 6.13’de Yale B yüz veritabanı kullanılarak; blok boyutları = 4X4 piksel, epok sayısı = 100, öğrenme oranı = 0,5 ve komşu etki katsayısı = 0,01 değerleri olacak şekilde, sistem farklı ÖDH boyutlarında çalıştırılarak sınıflandırma yapılmıştır. Eğitim komşuluk yarıçapı ise harita boyutuna bağlı olarak Eş. 6.1’de görüldüğü gibi hesaplanmıştır. Sistem en iyi sonuçları 17X17 harita boyutlarında elde etmiştir. İşlem süresinde ise harita boyutlarındaki artışla birlikte daha fazla nöronun ağırlık güncellemesi yapılması gerektiğinden artış gözlenmektedir.

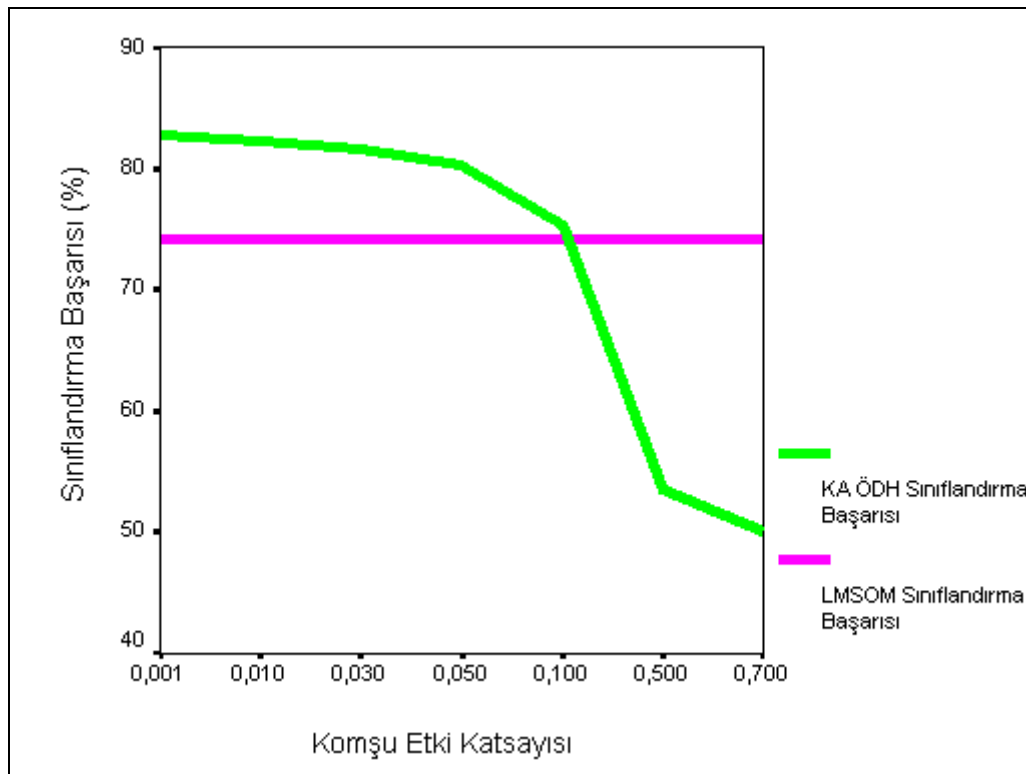


Şekil 6.12. Yale B yüz veritabanı farklı ÖDH boyutlarında sınıflandırma başarısı



Şekil 6.13. Yale B yüz veritabanı farklı ÖDH boyutlarında işlem süresi

Şekil 6.14'te ise Yale B yüz veritabanı kullanılarak; ÖDH boyutları = 18X18, blok boyutları 4X4 piksel, epok sayısı=100, öğrenme oranı = 0,5 ve eğitim komşuluk yarıçapı= 2,25 değerleri olacak şekilde, sistem farklı komşu etki sayılarında çalıştırılmış ve sonuçlar üretilmiştir. Verilen grafikten en iyi sınıflandırma başarısının blokların kendi sınıflandırma sonuçlarına dayanılarak, komşu etkisinin azaltıldığı durumlarda elde edildiğinde ortaya çıktığı gözlenmektedir.



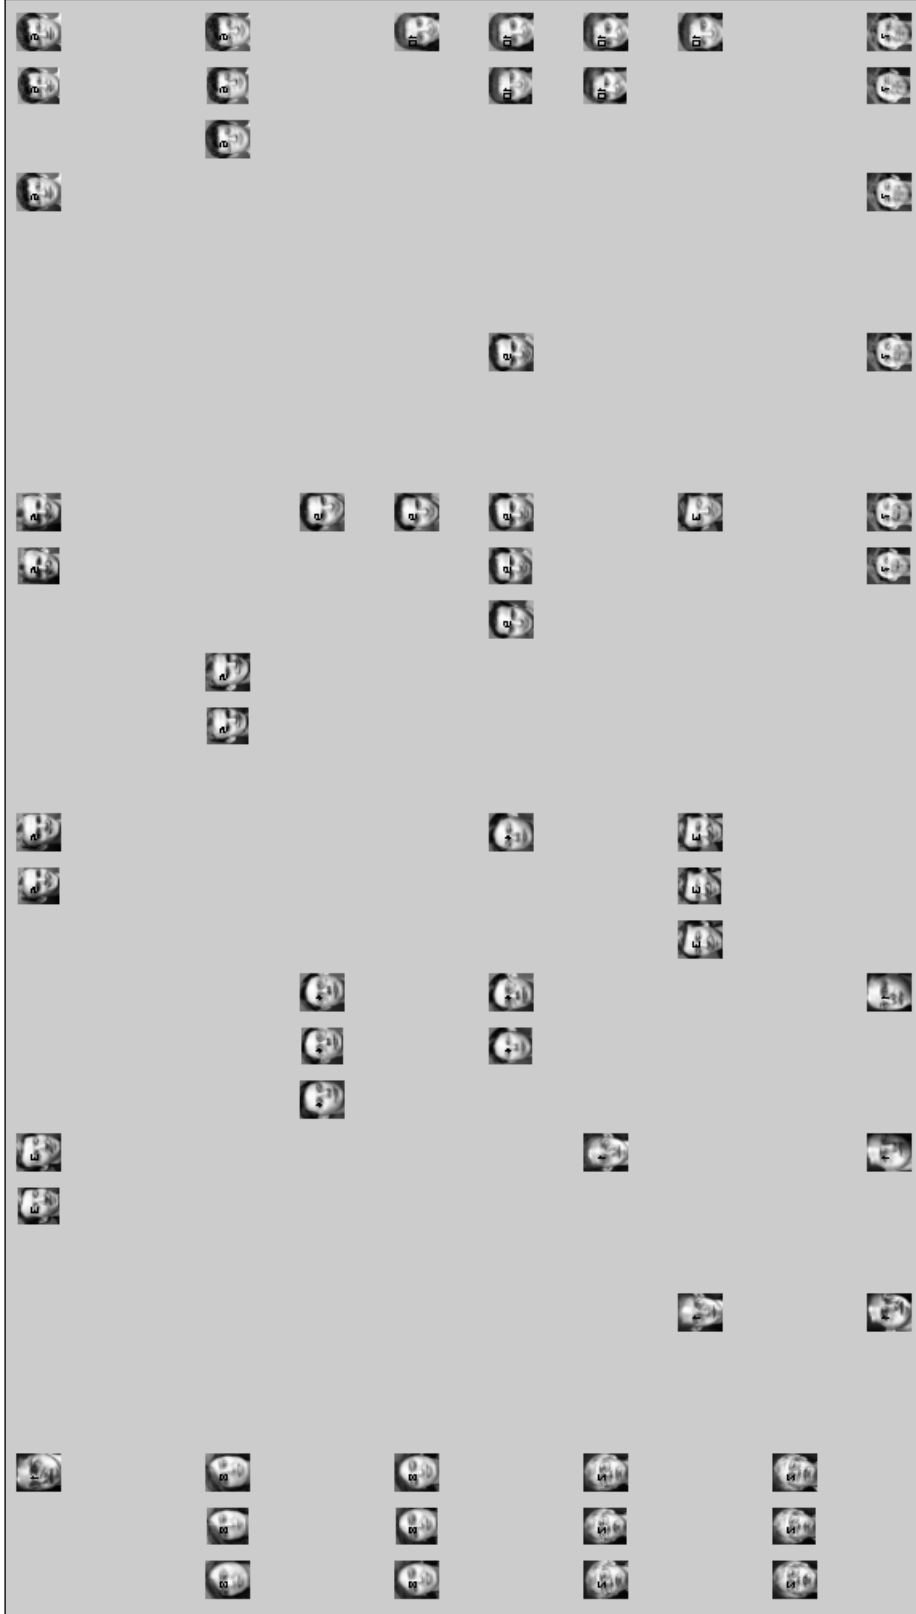
Şekil 6.14. Yale B yüz veritabanı farklı komşu etki katsayılarında sınıflandırma başarısı

Şekil 6.15'te Yale B yüz veritabanındaki bir kişiye ait farklı pozlardaki yüz görüntüleri öncelikle eğitime tabi tutulmuş ve eğitim sonrası harita üzerindeki dağılım gösterilmiştir. Her dikdörtgen karşılık geldiği konumdaki nöronu kazanan olarak seçen yüzleri göstermektedir. Şekilde benzer pozlardaki ve yakın açılardan ışıklandırılmış görüntülerin harita üzerinde yakın konumlar aldığı gözlenmektedir.



Şekil 6.15. Yale B yüz veritabanında bir kişiye ait farklı pozlardaki yüz görüntülerinin eğitim sonrası harita üzerinde dağılımı

Şekil 6.16'da ise ORL yüz veritabanındaki ilk 10 kişiye ait görüntülerle sistem eğitilmiş ve eğitim ardından yüzlerin harita üzerinde dağılımı gösterilmiştir. Aynı kişiye ait yüz görüntülerinin harita üzerinde benzer konumlara yerleştiği yani sınıflandırmanın başarılı olduğu şekilden anlaşılabilir, bu sınıflandırma için sistemin 250 epok gibi düşük bir epok sayısında çalıştırılmış olması da sistemin verimliliğini ortaya koymaktadır.



Şekil 6.16. ORL yüz veritabanındaki yüz görüntülerinin eğitim sonrası harita dağılımı

Çizelge 6.2. ORL ve Yale B yüz veritabanlarında sınıflandırma başarıları

Yöntem	Yüz Veritabanı	Sınıflandırma Başarısı
gViSOM [Huang ve Yin, 2009]	ORL	%97,45
ViSOM [Huang ve Yin, 2009]	ORL	%97,20
SOM [Huang ve Yin, 2009]	ORL	%96,80
KA ÖDH	ORL	%91,67
LM SOM	ORL	%90,20
SOM	ORL	%79,38
HMM [Zhi ve Ming, 2005]	ORL	%91,60
SOM [Kumar ve ark., 2008]	ORL	%90,83
S-LISSOM+WN [Zhi ve Ming, 2005]	ORL	%90,80
LDA+SOM [Santos ve Gonzaga, 2005]	ORL	%90,80
RBF-SOM [Zhi ve Ming, 2005]	ORL	%84,10
SOM [Zhi ve Ming, 2005]	ORL	%83,30
Fisher-Face [Zhi ve Ming, 2005]	ORL	%82,50
PCA [Zhi ve Ming, 2005]	ORL	%81,60
SOM+PCA [Kumar ve ark., 2008]	ORL	%63,08
KA ÖDH	YALE B	%86,10
LMSOM	YALE B	%85,70
Mahalanobis SOM [Aly ve ark., 2008]	YALE B	~%72,00
Fisherfaces [Aly ve ark., 2008]	YALE B	~%59,00
Eigenfaces [Aly ve ark., 2008]	YALE B	~%45,00
SOM [Aly ve ark., 2008]	YALE B	~%36,00

Çizelge 6.1’de literatürde yer alan ORL ve Yale B yüz veritabanlarını kullanarak sınıflandırma yapmış çalışmalar ve bunların başarıları listelenmiştir. Sonuçlar öncelikle veritabanı ardından başarı sırasına göre sıralanmıştır, çünkü her yüz veritabanı sınıflandırma açısından poz değişimi ve ışıklandırma şiddeti değişimi gibi farklı türde ve derecede zorluklar içermektedir. Tabloda kalın renkli olarak verilmiş satırlar bu tez çalışmasının sonuçlarını göstermektedir. Listede verilmiş olan ORL

yüz veritabanında yapılan sınıflandırmada, ÖDH boyutları= 18X18, blok boyutları= 4X4 piksel, epok sayısı= 100, öğrenme oranı= 0,5, eğitim komşuluk yarıçapı= 2,25 ve komşu etki katsayısı = 0,01 değerlerindedir. Listede verilmiş olan Yale B yüz veritabanında yapılan sınıflandırmada ise, ÖDH boyutları= 18X18 piksel, blok boyutları= 28X1, epok sayısı= 100, öğrenme oranı= 0,5, eğitim komşuluk yarıçapı= 2,25 ve komşu etki katsayısı = 0,01 değerlerindedir. Yöntemin sınıflandırma başarısı test edilirken eğitime katılmış olan yüzler test işleminde kullanılmamıştır.

7. SONUÇ VE ÖNERİLER

Yüz, kulaklarla birlikte alındığında duyu organlarımızdan çoğunu barındıran ve estetik açıdan insanları yansıtan en önemli bölge olması gibi kolaylıkla sıralanabilecek pek çok faktör göz önünde bulundurulduğunda bütün olarak korunmasına en fazla özen gösterilen vücut bölgemizdir. Bir biyometrik olarak bakıldığında ise, tekliği ve dolayısı ile ayırt ediciliği son derece yüksektir. Diğer biyometriklerimizle kıyaslandığında, yüz görüntüleri ile kimlik belirlemede poz değişimi, yaşlanma, yüz ifadesi değişimi gibi başarıyı düşüren ve çözümü oldukça zor sorunlarla karşılaşılmasına rağmen, yapılan bir araştırmada ticari olarak kullanılan sistemlerde en çok tercih edilen ikinci biyometrik olmasının başta anlatılan nedenlerden kaynaklandığı düşünülmektedir.

ÖDH ile sınıflandırma, önerilmesinden bugüne örüntü tanımada sıklıkla denenen bir metot haline gelmiştir. Bu amaçla ÖDH kullanımının, uydu görüntülerinin analizinden, medikal görüntülerden bulgular elde edilmesine kadar literatürde pek çok örneğine rastlamak mümkündür. Bunun ana nedeninin ÖDH'lerle çok başarılı bir şekilde soyutlama yapılması ve veri kümelerinin daha az boyuta indirgenerek görselleştirilmesi olduğu düşünülmektedir. Ayrıca ÖDH ile yapılan sınıflandırma sonucunda elde edilen sonuçları var olan farklı yöntemlerde kolaylıkla kullanmak mümkündür. Bu nedenle ÖDH, amaçlanan asıl işlemi yapabilmek yanında ön işleme ya da son işleme aşamalarında kullanılarak diğer metotlar için oldukça destekleyici bir araç olmuştur.

Bu çalışmada yüz görüntüleri eşit büyüklükteki bloklara bölünmüş, her bir blok konumu için ayrı ÖDH yaratılmış ve bloklar diğer görüntülerde kendileri ile aynı konumdaki bloklar ile kendilerine ait ÖDH'leri eğitmişlerdir. Kullanılan ÖDH'ler bu çalışmada özgün bir katkı olarak eğitim ardından kalite ağırlıklandırılmıştır. Test işlemlerinde ÖDH kalite ağırlıklarını dikkate alan bir yaklaşımla sınıflandırma sonucu elde edilmiştir. Blokların sınıflandırılmasında, komşu blokların da sınıflandırma sonuçlarının dikkate alınması yüz görüntüsü içerisinde aykırı özelliğe sahip bölgelerin göz ardı edilmesini sağlamıştır, bu da çalışmadaki özgün diğer bir

katkıdır. Önerilen yöntem ile yapılan yüz sınıflandırma işleminde alınan sayısal sonuçlar; literatürdeki diğer çalışmalar ve izlenilen yaklaşımı esas alınmış olan LMSOM yöntemiyle kıyaslandığında oldukça başarılıdır. Ayrıca istenilen sonuçlara düşük epok sayılarında ulaşıyor olması da sistemin oldukça verimli olduğunu göstermektedir. Sistemin çok sayıda ÖDH'den oluşuyor olması sonucu, ÖDH'lerin uygun donanıma sahip bilgisayarlarda paralel olarak çalıştırılmasına olanak vermesi ile elde edilecek ek verim sistemin önemli bir avantajı olarak ortaya çıkmaktadır.

Sistemin bahsedilen başarısında, temel etmenin öncelikle yüz görüntüsünün bloklara ayrılarak sınıflandırma açısından önemli bilgiler içeren görüntü kısımları ön plana çıkartılması yani bölge tabanlı bir yaklaşım izlenmesinin olduğu düşünülmektedir. Her bir blok için ayrı bir ÖDH kullanılması ve (bu çalışmanın özgün bir katkısı olan) ÖDH'lerin sınıflandırma kalitesinin hesaplanması stratejisi ise bölge temelliğin faydalarının elde etmede büyük oranda katkı sağlamıştır. ÖDH'lerin kalitesinin hesaplanması ve bunun nihai sınıflandırma sonucunda göz önünde bulundurulması, sınıflandırma problemlerinde ÖDH eğitiminden daha fazla faydalanabilmeye olanak tanımıştır ve bu ek fayda sınıflandırma sonuçlarındaki artışla gözlenmiştir.

Önerilen yöntemde izlenen yaklaşımın, yüz görüntüsü dışındaki görüntülerin sınıflandırılması ve herhangi türdeki çok değişkenle ifade edilen gözlemlerin sınıflandırılmasında izlenmesinin, sınıflandırma başarısını ve verimini artırması beklenmektedir. Bu yaklaşım birçok araştırmada yüz görüntülerinin ya da sınıflandırma yapılmak istenen görüntülerinin kırılması işlemine olan gerekliliği ortadan kaldıracak ya da görüntüler arasında sınıf içi ve sınıflar arası farklılık yaratan kısımların anlaşılması işleminde de yardımcı olacak ve sonuç olarak nerelerin kırılması konusunda araştırmacılara yardımcı olabilecektir.

Çalışmada yapılan testler sonucunda görüntülerin ayrıldığı blokların boyutlarının veritabanıyla ilişkili olduğu, farklı veritabanları için blok boyutlarının farklı olacağı kanısı oluşmuştur. Bloklara ayırma işlemi sonrasında, içersinde sınıflandırma açısından önemli bilgiler bulunduran bloklar ve içersinde sınıflandırma açısından değersiz bilgiler (sınıflar arasında farklılık yaratmayan bölümleri) bulunduran bloklar farklı konumlarda yer almalıdır. Çünkü her iki özellikteki blok da sınıflandırma

açısından önemlidir ve sınıflandırma yöntemi öncelikle bunları birbirinden ayırarak sonuç üretmektedir. Harita boyutlarının ve epok sayısının seçiminde ise gözlem sayısı ve blok boyutu etkili olmaktadır, veritabanı, gözlem sayısı, blok boyutları değişkenlerine göre harita boyutu ve epok sayılarının optimum değerleri vardır ve bu değerlerden uzaklaşılması durumunda başarı düşmektedir.

Sonuç olarak çalışmada kalite analizi yapılmış, çok sayıda ÖDH kullanan yüz sınıflandırma işleminde verimli bir yöntem önerilmiştir. Ayrıca çalışmada önerilen bölge temelli yaklaşımların örüntü sınıflandırma başta olmak üzere diğer sınıflandırma işlemlerinde kullanılması halinde verim artırılması söz konusu olacağından, ilgili yaklaşımlardan diğer sınıflandırma problemlerinde de faydalanılması önerilmektedir.

KAYNAKLAR

1. Abate, A. F., Nappi, M., Riccio, D., Sabatino, G., "2D and 3D face recognition: A survey", *Pattern Recognition Letters*, 28: 1885-1906 (2007).
2. Alba, J. L., Pujol, A., Villanueva, J. J., "Novel SOM-PCA network for face identification", *Applications and Science of Neural Networks, Fuzzy Systems, and Evolutionary Computation IV*, San Diego, 186-194 (2001).
3. Alpdoğan, Y., Bilge, H. Ş., "Kendinden düzenlenen haritalar ile ders içeriklerinin sınıflandırılması", *Gazi Üniv. Müh. Mim. Fak. Der.*, 24(2), 303-310 (2009)
4. Aly, S., Tsuruta, N., Taniguchi, R. I., "Face recognition under varying illumination using Mahalanobis self-organizing map", *Artificial Life and Robotics*, 12 (1): 298-301 (2008).
5. Astel, A., Tsakovski, S., Barbieri, P., Simeonov, V., "Comparison of self-organizing maps classification approach with cluster and principal components analysis for large environmental data sets", *Water Research*, 41: 4566-4578 (2007).
6. Bednar, J. A., Miikkulainen, R., "Learning innate face preferences", *Neural Computation*, 15 (7): 1525-1557 (2003).
7. Bowyer, K. W., Chang, K., Flynn, P., "A survey of approaches and challenges in 3D and multi-modal 3D+ 2D face recognition", *Computer Vision and Image Understanding*, 101 (1): 1-15 (2006).
8. Cielniak, G., Duckett, T., "Person identification by mobile robots in indoor environments", *1st Int. Workshop on Robotic Sensing*, Orebro, 1-5 (2003).
9. Fodor, I. K., "A survey of dimension reduction techniques", *Lawrence Livermore National Lab., UCRL-ID-148494, California*, 1-24 (2002).
10. Georghiadis, A. S., Belhumeur, P. N., Kriegman, D. J., "From few to many: Illumination cone models for face recognition under variable lighting and pose", *IEEE Trans. Pattern Anal. Mach. Intelligence*, 23 (6): 634-660 (2001).
11. Haddadnia, J., Ahmadi, M., "N-feature neural network human face recognition", *Image and Vision Computing*, 22 (12): 1071-1082 (2004).
12. Honda, R., Takimito, H., Konishi, O., "Semantic indexing and temporal rule discovery for time-series satellite images", *1st Int. Workshop on Multimedia Data Mining*, Boston, 82-90 (2000).
13. Huang, W., Yin, H., "ViSOM for dimensionality reduction in face recognition", *Advances in Self-Organizing Maps*, 5629: 107-115 (2009).

14. Ishii, M., Sato, K., Madokoro, H., Nishida, M., "Extraction of subject-specific facial expression categories and generation of facial expression feature space using self-mapping", *Journal of Multimedia*, 3 (2): 60-67 (2008).
15. Kaski, S., Kangas, J., Kohonen, T., "Bibliography of self-organizing map (SOM) Papers", *Neural Computing Surveys*, 1: 102-350 (1998).
16. Kohonen, T., "Median strings", *Pattern Recognition Letters*, 3: 309–313 (1985).
17. Kohonen, T., "The self-organizing map", *Proceedings of the IEEE*, 78: 1464–1480 (1990).
18. Kohonen, T., "Self-organized formation of topologically correct feature maps", *Biological Cybernetics*, 43 (1): 59-59 (1982).
19. Kohonen, T., Oja, E., Simula, O., Visa, A., Kangas, J., "Engineering applications of the self-organizing map", *Proceedings of the IEEE*, 84 (10): 1358-1384 (2002).
20. Kohonen, T., Somervuo, P., "Self-organizing maps of symbol strings", *Neurocomputing*, 21: 19-30 (1998).
21. Koikkalainen, P., Oja, E., "Self-organizing hierarchical feature maps", *IJCNN International Joint Conference on Neural Networks*, San Diego, 279-284 (1990).
22. Korhonen, P., Siljamäki, A., "Ordinal principal component analysis theory and an application", *Computational Statistics & Data Analysis*, 26 (4): 411-424 (1998).
23. Kumar, D., Rai, C. S., Kumar, S., "Dimensionality reduction using SOM based technique for face recognition", *Journal of Multimedia*, 3 (1): 1-6 (2008).
24. Liao, S., Wen, C., "Artificial neural networks classification and clustering of methodologies and applications – literature analysis from 1995 to 2005", *Expert Systems with Applications*, 32: 1-11 (2007).
25. Lin, X., Yacoub, S., Burns, J., Simske, S., "Performance analysis of pattern classifier combination by plurality voting", *Pattern Recognition Letters*, 24 (12): 1959-1969 (2003).
26. Liu, C., Wechsler, H., "Gabor feature based classification using the enhanced fisher linear discriminant model for face recognition", *IEEE Transactions on Image Processing*, 11 (4): 467-476 (2002).
27. Lyons, M. J., Budynek, J., Akamatsu, S., "Automatic classification of single facial images", *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 21 (12): 1357-1362 (1999).
28. Monteiro, I. Q., Queiroz, S. D., Carneiro, A. T., Souza, L. G., Barreto, G. A., "Face recognition independent of facial expression through SOM-based

- classifiers”, *2006 International Telecommunications Symposium*, Fortaleza, Ceara, 263-268 (2006).
29. Ong, S. H., Yeo, N. C., Lee, K. H., Venkatesh, Y. V., Cao, D. M., “Segmentation of color images using a two-stage self-organizing network”, *Image and Vision Computing*, 20: 279-289 (2002).
 30. Oral, M., Genç, E., “İskenderun Körfezinde yaşayan Orfoz balığı (*Ephinephelus marginatus* Lowe 1834)’ndaki parazitlenmenin öz örgütlenmeli haritalarla yeniden değerlendirilmesi” , *Journal of Fisheries Sciences* , 2 (3): 293-300 (2008).
 31. Oravec, M., Pavlovicova, J., "Face recognition methods based on feedforward neural networks, principal component analysis and self-organizing map", *Radioengineering*, 16 (1): 51-57 (2007).
 32. Penn, S. B., “Using self-organizing maps to visualize high-dimensional data”, *Computers & Geosciences*, 31 (5): 531-544 (2005).
 33. Ruiz-del-Solar, J., Navarrete, P., “FACERET: An interactive face retrieval system based on self-organizing maps”, *CIVR’02 Proceedings of the International Conference on Image and Video Retrieval*, Londra, 157-164 (2002).
 34. Sagheer, A., Tsuruta, N., Taniguchi, R., Arita, R. D., Maeda, S., “Fast feature extraction approach for multi-dimension feature space problems”, *18th International Conference on Pattern Recognition*, Hong Kong, 417-420 (2006).
 35. Sağiroğlu, Ş., Beşdok, E., Erler, M., “Mühendislikte yapay zeka uygulamaları - I: yapay sinir ağları”, *Ufuk Kitap Kirtasiye Yayıncılık*, Kayseri, 23-116 (2003).
 36. Samaria, F. S., Harter, A. C., “Parameterisation of a stochastic model for human face identification”, *Proceedings of the Second IEEE Workshop on Applications of Computer Vision*, Sarasota, Florida, 138-142 (1994).
 37. Santos, A. R. D., Gonzaga, A., “Face recognition based on LDA and SOM neural nets”, *I Workshop on Computer Vision - WVC '05*, Piracicaba, Brezilya, 21-23 (2005).
 38. Tan, X., Chen, S., Zhou, Z., Zhang, F., “Face recognition from a single image per person: A survey”, *Pattern Recognition*, 39: 1725-1745 (2006).
 39. Tan, X., Chen, S., Zhou, Z., Zhang, F., “Feature selection for high dimensional face image using self-organizing maps ”, *Advances in Knowledge Discovery and Data Mining*, 3518 : 500-504 (2005).
 40. Tan, X., Chen, S., Zhou, Z., Zhang, F., “Recognizing partially occluded, expression variant faces from single training image per person with SOM and

- soft kNN ensemble”, *IEEE Transactions on Neural Networks*, 16 (4): 875–886 (2005).
41. Tan, X., Chen, S., Zhou, Z., Zhang, F., “Robust face recognition from a single training image per person with Kernel-Based SOM-Face”, *Advances in Neural Networks*, 3173 : 858–863 (2004).
 42. Tan, X., Liu, J., Chen, S., “Recognition from a single sample per person with multiple SOM fusion”, *Advances in Neural Networks-ISNN 2006*, 3972: 128-133 (2006).
 43. Tolba, A. S., Abu-Rezq, A. N., “Combined classifiers for invariant face recognition”, *Pattern Analysis & Applications*, 3 (4): 289-302 (2000).
 44. Upton, G., Cook, I., “A dictionary of statistics”, *Oxford University Press*, New York , 186-187 (2008).
 45. Visani, M., Garcia, C., Laurent, C., “Comparing robustness of two-dimensional PCA and eigenfaces for face recognition”, *Image Analysis and Recognition*, 1, *Springer*, Berlin / Heidelberg, 717-724 (2004).
 46. Vesanto, J., Himberg, J., Alhoniemi, E., Parhankangas, J., ‘Som toolbox for matlab’, *HUT A57, Helsinki*, 7-59 (2000).
 47. Yin, H., “ViSOM-a novel method for multivariate data projection and structure visualization”, *IEEE Transactions on Neural Networks*, 13 (1): 237-243 (2002).
 48. Zhao, W., Chellappa, R., Phillips, P. J., Rosenfeld, A., “Face recognition: A literature survey”, *ACM Computing Surveys (CSUR)*, 35 (4): 399-458 (2003).
 49. Zhi, Y., Ming, G., “A SOM-wavelet networks for face identification”, *IEEE International Conference on Multimedia and Expo*, Amsterdam, 1-4 (2005).

ÖZGEÇMİŞ

Kişisel Bilgiler

Soyadı, adı : ÇEVİKER, Mesut
Uyruğu : T.C.
Doğum tarihi ve yeri : 06.07.1984 Niğde
Medeni hali : Evli
Telefon : 0 (312) 468 53 00
Faks : 0 (312) 427 43 05
E-posta : mesut.ceviker@tubitak.gov.tr

Eğitim

Derece	Eğitim Birimi	Mezuniyet tarihi
Lisans	ODTÜ / Bilgisayar Müh. Bölümü	2007
Lise	Aksaray Fen Lisesi	2002

İş Deneyimi

Yıl	Yer	Görev
2007-2011	TÜBİTAK	Yazılım Mühendisi
2006-2007	Oracle Bilgisayar Sistemleri A.Ş.	Veritabanı Analist Yrd.
2004-2006	ODTÜ Bilgi İşlem Daire Başkanlığı	Teknik Koordinatör

Yabancı Dil

İngilizce

Hobiler

Bilgisayar teknolojileri, Futbol, Sinema