

**T.C.
ERCIYES ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI**

**GÖRÜNÜŞ TABANLI YÜZ TANIMA YÖNTEMLERİNDE
ÖZNİTELİK SEÇİMİ**

**Hazırlayan
Derya ALTINTOP**

**Danışman
Yrd. Doç. Dr. Celal ÖZTÜRK**

Yüksek Lisans Tezi

**Ocak 2017
KAYSERİ**

**T.C.
ERCIYES ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI**

**GÖRÜNÜŞ TABANLI YÜZ TANIMA YÖNTEMLERİNDE
VERİMLİLİĞİ ARTIRMAK İÇİN ÖZNİTELİK SEÇİMİ
(Yüksek Lisans Tezi)**

**Hazırlayan
Derya ALTINTOP**


**Danışman
Yrd. Doç. Dr. Celal ÖZTÜRK**

**Ocak 2017
KAYSERİ**

BİLİMSEL ETİĞE UYGUNLUK

Bu çalışmadaki tüm bilgilerin, akademik ve etik kurallara uygun bir şekilde elde edildiğini beyan ederim. Aynı zamanda bu kural ve davranışların gerektirdiği gibi, bu çalışmanın özünde olmayan tüm materyal ve sonuçları tam olarak aktardığımı ve referans gösterdiğimi belirtirim.

Derya ALTINTOP



YÖNERGEYE UYGUNLUK

“Görünüş Tabanlı Yüz Tanıma Yöntemlerinde Verimliliği Artırmak İçin Öznitelik Seçimi” adlı Yüksek Lisans tezi, Erciyes Üniversitesi Lisansüstü Tez Önerisi ve Tez Yazma Yönergesi ’ne uygun olarak hazırlanmıştır.

Tezi Hazırlayan

Derya ALTINTOP



Danışman

Yrd. Doç. Dr. Celal ÖZTÜRK



Bilgisayar Mühendisliği Anabilim Dalı Başkanı

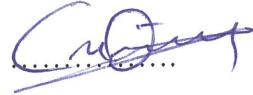
Prof. Dr. Derviş KARABOĞA

Yrd. Doç. Dr. Celal ÖZTÜRK danışmanlığında **Derya ALTINTOP** tarafından hazırlanan “**Görünüş Tabanlı Yüz Tanıma Yöntemlerinde Verimliliği Artırmak İçin Öznitelik Seçimi**” adlı bu çalışma, jürimiz tarafından Erciyes Üniversitesi Fen Bilimleri Enstitüsü Bilgisayar Mühendisliği Anabilim Dalında **Yüksek Lisans** tezi olarak kabul edilmiştir.

26 / 01 / 2017

JÜRİ:

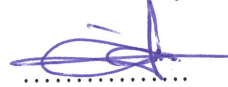
Danışman : Yrd. Doç. Dr. Celal ÖZTÜRK



Üye : Doç. Dr. Diyar AKAY



Üye : Doç. Dr. Duran TOKSARI



ONAY:

Bu tezin kabulü Enstitü Yönetim Kurulunun 07/02/2017 tarih ve 2017/06-08 sayılı kararı ile onaylanmıştır.



Prof. Dr. Mehmet AKKURT
Enstitü Müdürü



Y.

TEŐEKKÜR

Bu alıőmanın baőlamasında ve olgunlaőmasında bŸyŸk katkı sahibi olan ancak Ocak 2016 ‘da kaybettiėimiz sayın rahmetli hocam Yrd. Do. Dr. Necla ŐZKAYA’ ya ŐŸkranlarımı; alıőmanın kaldıėı yerden devam ettirilmesinde ve sonlandırılmasında birlikte alıőtıėımız saygıdeėer hocam Yrd. Do. Dr. Celal ŐZTŸRK’ e teőekkŸrlerimi sunarım.

Ayrıca; alıőmalarım sŸresince sabır gŸstererek beni daima destekleyen eőime ve beni bugŸnlere getiren deėerli aileme en iten teőekkŸrlerimi sunarım.

Derya ALTINTOP

Kayseri, Ocak 2017

GÖRÜNÜŞ TABANLI YÜZ TANIMA YÖNTEMLERİNDE VERİMLİLİĞİ ARTIRMAK İÇİN ÖZİNİTELİK SEÇİMİ

Derya ALTINTOP

Erciyes Üniversitesi, Fen Bilimleri Enstitüsü

Yüksek Lisans Tezi, Ocak 2017

Danışman: Yrd. Doç. Dr. Celal ÖZTÜRK

ÖZET

Yüz tanıma sistemlerinde gereksiz özneliklerin atılması hesaplama karmaşıklıklarının azaltılmasını ve işlenen verinin küçültülmesini sağlar. Daha etkili sınıflandırma performansını sağlayacak öznelik alt kümesini belirlemek zor bir konudur. Bu durum, yüz veri setinin örnek uzayında ayrıntılı araştırma yapmayı gerektirmektedir. Bu tez çalışmasında, görünüş tabanlı yüz tanıma sistemlerinde, ayırt edici ortak vektör yöntemi (DCV) ve sezgisel optimizasyon algoritmaları birlikte kullanılarak hibrit öznelik seçim yöntemleri geliştirilmiştir. Kullanılan sezgisel optimizasyon algoritmaları, genetik algoritma (GA) ve yapay arı kolonisi algoritması (ABC) temellidir. Çalışmanın temel amacı, yüz tanıma oranını artırmak ve hesaplama karmaşıklığını azaltmak için öznelik seçimi yapmaktır. Geliştirilen hibrit öznelik seçim yöntemleri, çeşitli yüz veri setleri üzerinde test edilmiş ve sonuçlar karşılaştırılmıştır. Geliştirilen yapay arı kolonisi algoritması temelli hibrit öznelik seçim yönteminin, yüz tanıma oranı ve verimlilik konularında yapılan diğer çalışmalara ve genetik algoritma temelli yöntemlere göre daha başarılı olduğu gözlemlenmiştir.

Anahtar Kelimeler: öznelik seçimi; yüz tanıma; ayırt edici ortak vektör;

yapay arı kolonisi algoritması; genetik algoritma.

**FEATURE SELECTION TO IMPROVE EFFICIENCY IN APPEARANCE
BASED FACE RECOGNITION METHOD**

Derya ALTINTOP

Erciyes University, Graduate School of Natural and Applied Sciences

M.Sc. Thesis, January 2017

Supervisor: Asst. Prof. Celal ÖZTÜRK

ABSTRACT

In face recognition systems, removing the redundant features reduces the size of the data and computation complexity. Identifying a good feature subset for effective classification is a hard task for face recognition. This requires an exhaustive search over the sample space of the face dataset. In this thesis, we designed a hybrid dynamic feature selection approach for face recognition based on modified discriminative common vector with metaheuristic optimization algorithms which are artificial bee colony algorithm and genetic algorithm. The main objective of the study is feature selection to improve recognition rate and reducing computation complexity. The designed hybrid systems are tested and compared on facial databases. The results show that artificial bee colony algorithm based hybrid feature selection approach is superior to other studies and genetic algorithm based method in terms of recognition rate, efficiency, and numerical stability.

Keywords: feature selection; face recognition; discriminative common vector;
artificial bee colony algorithm; genetic algorithm.

İÇİNDEKİLER

GÖRÜNÜŞ TABANLI YÜZ TANIMA YÖNTEMLERİNDE VERİMLİLİĞİ ARTIRMAK İÇİN ÖZİNİTELİK SEÇİMİ

	<u>Sayfa</u>
BİLİMSEL ETİĞE UYGUNLUK SAYFASI	ii
YÖNERGEYE UYGUNLUK SAYFASI	iii
KABUL VE ONAY SAYFASI	iv
TEŞEKKÜR.....	v
ÖZET.....	vi
ABSTRACT	vii
İÇİNDEKİLER	viii
TABLolar LİSTESİ.....	x
ŞEKİLLER LİSTESİ	xi
KISALTMALAR VE SİMGELER.....	xii
GİRİŞ.....	1

1. BÖLÜM

GENEL BİLGİLER

1.1. Yüz Tanıma ve Öz nitelik Seçimi.....	3
1.2. DCV Yönteminin Literatürdeki Kullanımı	5
1.3. Geliştirilen Sistemin Tanıtılması	6

2. BÖLÜM

GEREÇ VE YÖNTEMLER

2.1. Ayırt Edici Ortak Vektör (DCV) Yöntemi	7
--	----------

2.2. Yapay Arı Kolonisi (ABC) Algoritması	10
2.3. Genetik Algoritma (GA)	13
2.4. En Yakın Komşu (NN) Sınıflandırıcı	16
2.5. Kullanılan Yüz Veri Setleri	17
2.5.1. AR Yüz Veri Seti	18
2.5.2. ORL Yüz Veri Seti.....	19
2.5.3. YALE Yüz Veri Seti	20
2.6. Kullanılan Fiziki Makina	21

3. BÖLÜM

GELİŞTİRİLEN SİSTEM VE BULGULAR

3.1. Sistemin ABC Algoritması ile Modellenmesi.....	25
3.2. Sistemin GA ile Modellenmesi	26
3.3. ABC Algoritması ile Uygulanması.....	27
3.4. GA ile Uygulaması	30
3.5. ABC Algoritmasının Sistem İçin Kullanılan Parametreleri	33
3.6. GA nın Sistem İçin Kullanılan Parametreleri	34
3.7. Elde Edilen Deneysel Bulgular.....	34

4. BÖLÜM

TARTIŞMA, SONUÇ VE ÖNERİLER

4.1. Tartışma ve Sonuç.....	41
------------------------------------	-----------

KAYNAKLAR	45
------------------------	-----------

ÖZGEÇMİŞ.....	48
----------------------	-----------

TABLÖLAR LİSTESİ

Tablo 2.1. Kullanılan veri setleri hakkında özet gösterim.	17
Tablo 3.1. ABC algoritması ile geliştirilen sistem ile elde edilen deneysel bulgular.	35
Tablo 3.2. GA ile geliştirilen sistem ile elde edilen deneysel bulgular.....	36
Tablo 3.3. ABC algoritması ve GA ile geliştirilen sistemlerden elde edilen deneysel bulguların karşılaştırmalı gösterimi.	37
Tablo 3.4. Literatürdeki yapılan diğer çalışmalarda elde edilen deneysel bulgular.....	37

ŞEKİLLER LİSTESİ

Şekil 2.1. ABC algoritmasının arıların doğal dünyasından modellenmesi	11
Şekil 2.2. ABC algoritması kaba kodu	12
Şekil 2.3. Genetik algoritma kaba kodu	15
Şekil 2.4. NN sınıflandırıcı kaba kodu	16
Şekil 2.5. Kullanılan yüz veri setlerinden bazı örnek görüntüler	18
Şekil 2.6. AR yüz veri setinden bazı örnek görüntüler	19
Şekil 2.7. ORL yüz veri setinden bazı örnek görüntüler	20
Şekil 2.8. YALE yüz veri setinden bazı örnek görüntüler	21
Şekil 3.1. Geliştirilen sistemin genel diyagramı	24
Şekil 3.2. Öznitelik kümelerinin ABC algoritması ile modellenmesi	25
Şekil 3.3. Farklı boyutlardaki örnek nektar kaynaklarının gösterimi	25
Şekil 3.4. Öznitelik kümelerinin GA ile modellenmesi	26
Şekil 3.5. Sistem için geliştirilen ABC algoritmasının kaba kod tasarımı	28
Şekil 3.6. Geliştirilen ABC algoritmasının örnek komşuluk üretme mekanizması	29
Şekil 3.7. Sistem için geliştirilen GA kaba kod tasarımı	31
Şekil 3.8. Sistem için geliştirilen GA örnek çaprazlama mekanizması	32
Şekil 3.9. Sistem için geliştirilen GA örnek mutasyon mekanizması	32
Şekil 3.10. AR yüz veri seti için ABC algoritması ile geliştirilen sistemin, iterasyonlar boyunca gelişimi	38
Şekil 3.11. ORL yüz veri seti için ABC algoritması ile geliştirilen sistemin, iterasyonlar boyunca gelişimi	38
Şekil 3.12. YALE yüz veri seti için ABC algoritması ile geliştirilen sistemin, iterasyonlar boyunca gelişimi	39
Şekil 3.13. AR yüz veri seti için GA ile geliştirilen sistemin, nesiller boyunca gelişimi	39
Şekil 3.14. ORL yüz veri seti için GA ile geliştirilen sistemin, nesiller boyunca gelişimi	40
Şekil 3.15. YALE yüz veri seti için GA ile geliştirilen sistemin, nesiller boyunca gelişimi	40
Şekil 4.1. (a) ASM yüz modelleme, (b) AR yüz veri setinden kırpılmış eliptik ve T şekil öznitelik seçimi	42

KISALTMALAR VE SİMGELER

<u>Sembol</u>	<u>Anlamı</u>
DCV	Ayırt Edici Ortak Vektör
ABC	Yapay Arı Kolonisi Algoritması
GA	Genetik Algoritma
ACO	Karınca Koloni Algoritması
LDA	Lineer Diskriminant Analizi
FLDA	Fisher Lineer Diskriminant Analizi
PCA	Temel Bileşenler Analizi
SSSP	Small Sample Size Problem
FKP	Parmak Boğum Tanıma
SVM	Destek Vektör Makinası
K-DCV	Kernel Ayırt Edici Ortak Vektör
RBF	Radyal Temelli Fonksiyon
NN	En Yakın Komşu

GİRİŞ

Günümüzde oldukça yaygınlaşan yüz tanıma sistemlerinde, ham veriden öznitelik seçme ve boyut indirgeme gibi konular, hesaplama maliyetinin azaltılması ve verimliliğin artırılması adına oldukça önemlidir. Buna karşın öznitelik seçimi oldukça zor bir konudur. Çünkü veri setinin örnek uzayında çok kapsamlı araştırma ve analizler yapmak gerekmektedir. Bu tez çalışmasında görünüş tabanlı yüz tanıma sistemlerinde, modifiye edilmiş DCV yöntemi ve sezgisel optimizasyon algoritmaları birlikte kullanılarak öznitelik seçimi yaptırılmıştır. Kullanılan sezgisel optimizasyon algoritmaları, ABC ve GA' dır.

Tezin Amacı ve Önemi

Yapılan tez çalışmasının en temel amacı, görünüş tabanlı yüz tanıma sistemlerinde, hesaplama maliyetini azaltırken tanıma oranının artırılmasıdır. Bu amaç, ilerleyen bölümlerde daha detaylı bir şekilde açıklanacaktır. Günümüzde oldukça yaygınlaşmış olan yüz tanıma sistemleri için bu çalışmanın yapılması, enerji sarfiyatından zaman faktörüne kadar birçok konuda oldukça önemlidir.

Tezin birinci bölümünde, bu sistemin ihtiyaç duyulmasına neden olan etkenler tanıtılmış, literatürde bu konu üzerine yapılan çalışmalar irdelenmiş ve geliştirilen sistemin genel tanımları yapılmıştır.

İkinci bölümde, geliştirilen sistem için kullanılan gereç ve yöntemler tanıtılmıştır.

Üçüncü bölümde, geliştirilen sistemin tüm aşamaları detaylı şekilde açıklanmış ve elde edilen deneysel bulgular sunulmuş ve ilişkili çalışmalardaki ve farklı hibrit kullanım yöntemiyle elde edilen sonuçlarla karşılaştırmalar yapılmıştır.

Dördüncü bölümde deneysel bulgular ve yapılan karşılaştırmalar neticesinde, tartışma ve önerilere değinilmiştir.

1. BÖLÜM

GENEL BİLGİLER

1.1. Yüz Tanıma ve Öznitelik Seçimi

Yüz tanıma teknolojisi, son elli yıldır çeşitli kullanım alanlarındaki sistemlerde tercih edilmekte olan popüler araştırma konularındandır [1, 2]. Tipik bir yüz tanıma işlemi, kişilerin yüz görüntülerinin sisteme kaydedilmesinin ardından kontrol edilmek istenen yüz görüntülerinin sistemdeki görüntülerle karşılaştırılmasıyla yapılır. Kullanılan yüz tanıma sistemlerindeki yüz verileri, oldukça devasa boyutlara ulaşmış ve çok fazla öznitelik barındırmaktadır. Bu durum yüz tanıma sistemlerindeki hesaplama maliyetini çok fazla artırmaktadır [3]. Bu sorunu çözebilmek için, yüz veri setleri üzerinde öznitelik seçimi veya boyut indirgeme yapılması neredeyse kaçınılmazdır [4].

Öznitelik seçimi, ham veri seti için bütün öznitelik kümesinden yüz tanıma oranını maksimum, hesaplama maliyetini ve süre parametrelerini minimum yapacak şekilde alt kümelerin seçilmesidir. Genel olarak iki türde öznitelik seçimi yapılmaktadır. Bunlar: filtre tipi öznitelik seçimi ve sarmal tipte öznitelik seçimidir [5]. Filtre tipi öznitelik seçim yönteminde, belirli hesaplama yöntemleri ile önceden çeşitli hesaplama ve istatistikler yapılarak öznitelik seçimi yapılmaktadır [6]. Sarmal tipte öznitelik seçim yönteminde ise, öncelikle öznitelik seçimi yapılmakta, daha sonra seçilen bu öznitelikler ile başarı oranı hesaplanarak iteratif bir döngü içerisinde geri besleme ile en uygun öznitelik kümesi belirlenmeye çalışılmaktadır. Filtre tipi öznitelik seçim yönteminden farkı şudur: filtre tipi öznitelik seçim yönteminde ön hesaplamalar yapılarak öznitelikler seçilmekte ve seçilen öznitelikler kullanılmaktadır; sarmal tipte öznitelik seçim

yönteminde ise önce öznitelikler seçilmekte daha sonra seçilen bu öznitelikler değerlendirilerek en uygun öznitelik kümesi tespit edilmeye çalışılmaktadır [7].

Yüz tanıma için filtre tipi öznitelik seçimi amacıyla yapılmış temel çalışmalara örnek olarak: Eigenface [8], Fisher Lineer Diskriminant Analizi (FLDA) [9, 10] ve DCV [11] verilebilir. Bu yöntemler, Temel Bileşenler Analizi (PCA)' ni kullanmakta ve yüz görüntülerini iki boyutlu nesnelere olarak işlemektedirler. Bir başka deyişle $w \times h$ boyutundaki görüntüler w -boyutlu örnek uzayındaki noktalar olarak ifade edilmektedirler [11]. Eigenface metodu, yüz tanıma veri setindeki görüntülerin en belirgin ayırt edici özelliklerini tespit etmeye çalışan PCA temelli bir yöntemdir [8]. FLDA metodu ise Eigenface metodunun bazı eksikliklerini gidermek amacıyla tasarlanan ve Fisher lineer diskriminant kriterini kullanan benzer PCA temelli bir yöntemdir. Fisher lineer diskriminant kriterini kullanmasından ötürü diğer bir ismi, Fisherfacedir. [9, 10]. FLDA yönteminin en büyük eksikliği, bu yöntemin eğitim setindeki örnek sayısının, örnek uzayının boyutundan küçük olduğu durumlarda uygulanamamasıdır [11]. Bu sorun, örüntü tanıma alanında "small sample size problem (SSSP)" olarak isimlendirilmiştir [12]. Bu problemin üstesinden gelmek için, DCV yöntemi önerilmiştir. DCV yönteminde, her bir farklı sınıfı temsil eden ayırt edici ortak vektörler, sınıflar içi saçılım matrisinin sıfır alt uzayından seçilen iz düşüm vektörleri kullanılarak elde edilmiş ve kişi yüzlerinin sınıflandırılması için kullanılmıştır [11].

Yüz tanıma için öznitelik seçimi konusunda popüler hale gelen diğer sarmal tipte öznitelik seçimi çalışmalarında GA, karınca koloni algoritması (ACO) ve ABC gibi optimizasyon algoritmaları kullanılmaktadır. Kaur tarafından 2013 yılında yapılan çalışmada, yüz tanıma için öznitelik seçimi amacıyla ABC ve ACO optimizasyon algoritmaları kullanılmıştır [13]. Vignolo ve arkadaşları tarafından 2013'te yüz tanıma için en etkin özniteliklerin seçimi amacıyla GA tabanlı çok amaçlı bir sistem geliştirilmiştir. Yapılan bu çalışmada deneysel sonuçlar için, Essex yüz veri seti tercih edilmiştir [14]. Kanan ve Faez tarafından 2008 yılında yapılan çalışmada, yüz tanıma için öznitelik seçimi amacıyla ACO tabanlı bir yapı geliştirilmiştir. Yapılan bu çalışmada deneysel sonuçlar için, ORL yüz veri seti tercih edilmiştir [15]. Harandi ve arkadaşları tarafından 2004 yılında yapılan çalışmada, yüz tanıma için öznitelik seçimi amacıyla, GA tabanlı bir model geliştirilmiştir. GA'nın kalite fonksiyonu olarak PCA sınıflandırıcı

tercih edilmiştir. Bu çalışmada da deneysel sonuçlar için, ORL yüz veri seti tercih edilmiştir [16]. Abegaz ve arkadaşları tarafından 2011 yılında yapılan çalışmada, yüz tanıma için genetik tabanlı öznitelik seçimi ve PCA tabanlı ağırlıkların değerlendirilmesi sistemi geliştirilmiş ve FRGC yüz veri seti kullanılmıştır [17].

Son yıllarda, yüz tanıma öznitelik seçimi amacıyla ABC algoritması da etkin olarak kullanılmaktadır. Subanya ve arkadaşları tarafından 2014 yılında yapılan çalışmada, kardiyovasküler hastalıkların görüntüleri üzerinden teşhisi konusunda, sınıflandırma başarısının artırılması amacıyla ABC tabanlı öznitelik seçim sistemi geliştirilmiştir. Geliştirilen bu sistemde ABC algoritmasının kalite fonksiyonu olarak destek vektör makinası (SVM) tercih edilmiştir [18]. Uzer ve arkadaşları tarafından 2013 yılında yapılan ve Syarifah Adilah ve Rosni Abdullah tarafından 2012 yılında yapılan çalışmalarda, medikal örüntü tanınmasında özniteliklerin seçiminde hibrit ABC+SVM yaklaşımı geliştirilmiştir [19, 20]. Schiezero ve Pedrini tarafından 2013 yılında yapılan çalışmada, çeşitli UCI veri setleri için ABC tabanlı öznitelik seçim yaklaşımı geliştirilmiştir [21].

1.2. DCV Yönteminin Literatürdeki Kullanımı

DCV yöntemi, parmak boğum tanıma (FKP) ve yüz tanıma gibi biometrik kimlik doğrulama sistemlerinde diğer örüntü tanıma sistemlerinde başarıyla kullanılmaktadır [11, 22]. Wen tarafından 2012 yılında, DCV ve SVM tabanlı yüz tanıma yaklaşımı tasarlanmıştır ve deneysel sonuçlar için ORL ve AR yüz veri setleri tercih edilmiştir [23]. Liu ve arkadaşları tarafından 2008 yılında yapılan çalışmada, AR, ORL ve COIL-20 yüz veri setleri üzerinde SSSP' nin üstesinden gelmek için, LDA tabanlı üç yöntem karşılaştırılmıştır. Bu yöntemler: düzenlenmiş diskriminant analizi (RDA), DCV ve maksimum marj kriteridir (MMC) [24]. Jing ve arkadaşları tarafından 2008 yılında, DCV tabanlı bir yöntem olan kernel DCV (K-DCV) yöntemi, radyal temelli fonksiyon ağları (RBF neural network) ile birlikte kullanılarak yüz tanıma için öznitelik seçimi yapılmıştır ve AR yüz veri seti tercih edilmiş ve diğer yüz tanıma için yapılan öznitelik seçim çalışmaları ile kıyaslamalar yapılmıştır [25]. Jing ve arkadaşları tarafından yüz ve avuç içi tanıma için geliştirdikleri sistemde K-DCV ve RBF sınıflandırıcı yöntemleri kullanılmıştır ve deneysel sonuçlar için, AR, FERET yüz veri setleri ve avuç içi veri seti

tercih edilmiştir [26]. Gülmezoğlu ve arkadaşlarının 2007 yılında yaptıkları çalışmada tanıma amacıyla ortak vektör yaklaşımı kullanılmıştır ve deneysel sonuçlar için, TI-digit veri seti tercih edilmiştir [27]. Lakshimi ve arkadaşları tarafından yüz tanıma amacıyla DCV tabanlı hiyerarşik sınıflandırıcı olarak isimlendirilen bir sistem geliştirilmiştir ve deneysel sonuçlar için YALE yüz veri seti tercih edilmiştir [28]. Koç ve Barkana tarafından 2011 yılında yapılan çalışmada, yüz tanıma için öznelik seçimi ve boyut indirgeme adına ortak vektör ve DCV yaklaşımları kullanılmış ve bu yöntemler kendi aralarında karşılaştırılmıştır. Yapılan bu çalışmada deneysel sonuçlar için AR ve FERET yüz veri setleri kullanılmış ve DCV nin ortak vektör yaklaşımına göre daha başarılı olduğu vurgulanmıştır [29]. Koç ve Barkana tarafından 2014 yılında yapılan diğer bir çalışmada, yüz tanıma için hesaplama maliyetlerinin azaltılması adına DCV tabanlı öznelik seçim algoritması geliştirilmiştir ve AR ve YALE yüz veri setleri tercih edilmiştir [30].

1.3. Geliştirilen Sistemin Tanıtılması

Bu tez çalışmasında, yüz tanıma için ABC+DCV tabanlı yeni hibrit bir öznelik seçim sistemi geliştirilmiştir. Tezin en önemli amacı, minimum öznelik alt kümesi ile maksimum tanıma oranını elde etmektir. Geliştirilen sistemin çalışması için iki aşama bulunmaktadır. Bunlar: ABC algoritması ile öznelik seçimi ve seçilen bu özneliklerin DCV tabanlı en yakın komşu (NN) sınıflandırıcı ile değerlendirilmesidir. Yapılan bu tez çalışmasında deneysel sonuçlar için, AR, ORL ve YALE yüz veri setleri kullanılmıştır. Ayrıca geliştirilen sistemin başarısının test edilebilmesi adına aynı sistem GA+DCV şeklinde de tasarlanmıştır. Bu iki sistem kendi arasında ve literatürdeki diğer çalışmalar ile kıyaslanmıştır.

2. BÖLÜM

GEREÇ VE YÖNTEMLER

Bu bölümde tez çalışmasında kullanılan gereç ve yöntemler detaylı bir şekilde tanıtılacaktır. Kullanılan yöntemler: DCV metodu, ABC ve GA algoritmaları ile NN sınıflandırıcıdır. Kullanılan gereçler ise: veri setleri, deneylerinin yapıldığı ve testlerinin gerçekleştirildiği, geliştirilen Matlab uygulamasıdır.

2.1. Ayırt Edici Ortak Vektör (DCV) Yöntemi

DCV yöntemi [11] de, ilk defa yüz görüntülerinden öznitelik vektörlerini elde etmek için kullanılmıştır. Bu tez çalışmasında da DCV yöntemi aynı amaç çerçevesinde kullanılmıştır. Görüntüler, örnek uzay olarak isimlendirilen w_h boyutlu uzaydaki noktalar olan w_xh piksel gösteriminde iki boyutlu görüntüler olarak modellenmektedir. Yüz veri setlerindeki görüntüler de bu şekilde olduklarından dolayı, önemli özellikleri korunarak alt uzaylar şeklinde kullanılabilir. DCV metodu, yüz görüntülerindeki öznitelik vektörlerini elde etmek için, tüm sınıfların sınıf içi saçılım matrisini kullanmaktadır [11]. DCV'nin detaylı formülasyon gösterim ve açıklamalarda Çevikalp'in 2007 yılında yaptığı çalışma temel alınarak yapılmıştır.

Ortak vektör yönteminde, öznitelik vektörü, iki bileşenden oluşmaktadır. Bunlar: sınıfın ortak özelliklerinin olduğu bileşen ve ait olduğu sınıfın ortak özelliklerinden geriye kalan farklılıkların oluşturduğu ve her öznitelik vektörü için farklı olan bileşendir. DCV yönteminde, her sınıfa ait birbirinden farklı ortak vektörler, ait oldukları sınıftaki bütün örneklerin sıfır alt uzaya izdüşümleri ile elde edilmektedir. Eğitim setinin M adet örnekten oluştuğu, sınıf sayısının C olduğu ve her sınıftaki yüz görüntüleri örnek sayısının N olduğu varsayıldığında, elde edilecek eşitlik, $M=N*C$ dir [29].

S_w , sınıflar içi saçılım matrisidir. $d \times d$ boyutlu S_w matrisinin sıfır alt uzayını oluşturan birimdik vektörü setini bulmak, d 'nin büyük olduğu durumlarda oldukça güçtür. Buna karşın, S_w matrisinin erim alt uzayını oluşturan birimdik vektör seti çok daha küçük boyutlu olan $A^T A$ matrisi kullanılarak kolayca bulunabilmektedir. Buna göre ilgili ifadenin gösterimi, $S_w = AA^T$ şeklindedir. A matrisi $d \times M$ boyutlu olup, hesaplanması, denklem 2.1'de gösterilmiştir. A^T matrisi ise A matrisinin transpozudur.

$$A = \begin{bmatrix} x_1^1 - \mu_1 & \dots & x_N^1 - \mu_1 & x_1^2 - \mu_2 & \dots & x_N^2 - \mu_2 & \dots & x_1^C - \mu_C & \dots & x_N^C - \mu_C \end{bmatrix} \quad (2.1)$$

S_w matrisinin hesaplanması ise denklem 2.2'de gösterilmiştir.

$$S_w = \sum_{i=1}^C \sum_{m=1}^N (x_m^i - \mu_i)(x_m^i - \mu_i)^T \quad (2.2)$$

Denklem 2.2'de görülen x_m^i ifadesi, sınıf i olan m 'inci görüntü örneğini d -boyutlu uzayda ifade etmek içindir. Denklem 2.2'deki μ_i ifadesi, i 'inci sınıftaki ortalama vektörü; μ ifadesi ise, eğitim setindeki tüm örneklerin ortalama vektörünü göstermektedir.

v ve v^\perp değişkenlerinin sırasıyla S_w matrisinin erim alt uzayını ve sıfır alt uzayını temsil eden uzaylar olduğu varsayalım. v erim alt uzayının gösterimi denklem 2.3'deki şekilde; v^\perp sıfır alt uzayının gösterimi ise, denklem 2.4'deki şekildedir. Bu iki uzayın direkt toplamı, d boyutlu örnek uzayı vermektedir. Bu ifade ise, denklem 2.5'de gösterilmiştir.

$$v = \text{span}\{\alpha_k \mid S_w \alpha_k \neq 0, k = 1, \dots, r, \alpha_k \in R^d\} \quad (2.3)$$

$$v^\perp = \text{span}\{\alpha_k \mid S_w \alpha_k = 0, k = r + 1, \dots, d, \alpha_k \in R^d\} \quad (2.4)$$

$$v \oplus v^\perp = R^d \quad (2.5)$$

Denklem 2.3 ve Denklem 2.4’de görülen r ifadesi S_w matrisinin rankını göstermektedir. r değerinin olması gereken kıstas, $d \geq r$ dir. $\{\alpha_1 \dots \alpha_d\}$ ifadesi, S_w matrisine ait orta normal set; $\{\alpha_1 \dots \alpha_r\}$ ifadesi ise, S_w matrisinin sıfır olmayan öz değerlerinden oluşan orta normal öz vektörlerini göstermektedir.

Her sınıfı temsil eden ortak bir vektörü hesaplamak için denklem 2.6’dan yararlanılmaktadır.

$$x_{com}^i = x_m^i - QQ^T x_m^i = \bar{Q} \bar{Q}^T x_m^i, m = 1, \dots, N, i = 1, \dots, C \quad (2.6)$$

Veri setindeki her örnek yüz görüntüsü x_m^i şeklinde ifade edildiğinde, bunun anlamı i ’inci sınıftaki m ’inci örnektir. x_m^i ifadesi, d boyutlu bir sütun vektörüdür. Bu sütun vektörünün oluşturulması için yüz görüntüsündeki piksel değerleri sırasıyla alt alta yazılmaktadır. Bu ifade, denklem 2.7’de gösterilmiştir.

$$x_m^i = y_m^i + z_m^i \quad (2.7)$$

Denklem 2.7’deki y_m^i ve z_m^i ifadelerinin gösterimleri üzerinde durmak gerekirse:

$y_m^i = QQ^T x_m^i \in \mathcal{V}$ ve $z_m^i = \bar{Q} \bar{Q}^T x_m^i \in \mathcal{V}^\perp$ şeklindedir. Bu ifadelerde, $Q = [\alpha_1 \dots \alpha_r]$, $\bar{Q} = [\alpha_{r+1} \dots \alpha_d]$ ve r de S_w matrisinin rankıdır.

Bu noktada $S_{com} = A_{com} A_{com}^T$ ifadesinin doğruluğu varsayıldığında; S_{com} matrisinin w_k öz vektörleri, $A_{com}^T A_{com}$ matrisi yardımıyla denklem 2.8’deki şekilde hesaplanmaktadır.

$$A_{com} = [x_{com}^1 - \mu_{com} \dots x_{com}^C - \mu_{com}] \quad (2.8)$$

Sıfırdan farklı öz değerlerden oluşan öz vektörlerin maksimum sayısı, $C-1$ değerinde olmaktadır. Bu durumda, projeksiyon matrisi, $W = [w_1 \dots w_{C-1}]$ şeklinde modellenmektedir. Projeksiyon matrisi, öznitelik vektörlerinin elde edilmesi amacıyla kullanılmaktadır. Eğitim ve test veri setleri için öznitelik vektörleri sırasıyla denklem 2.9 ve denklem 2.10'da gösterilmektedir.

$$\Omega_i = W^T x_m^i \quad (m = 1, \dots, N; i = 1, \dots, C) \quad (2.9)$$

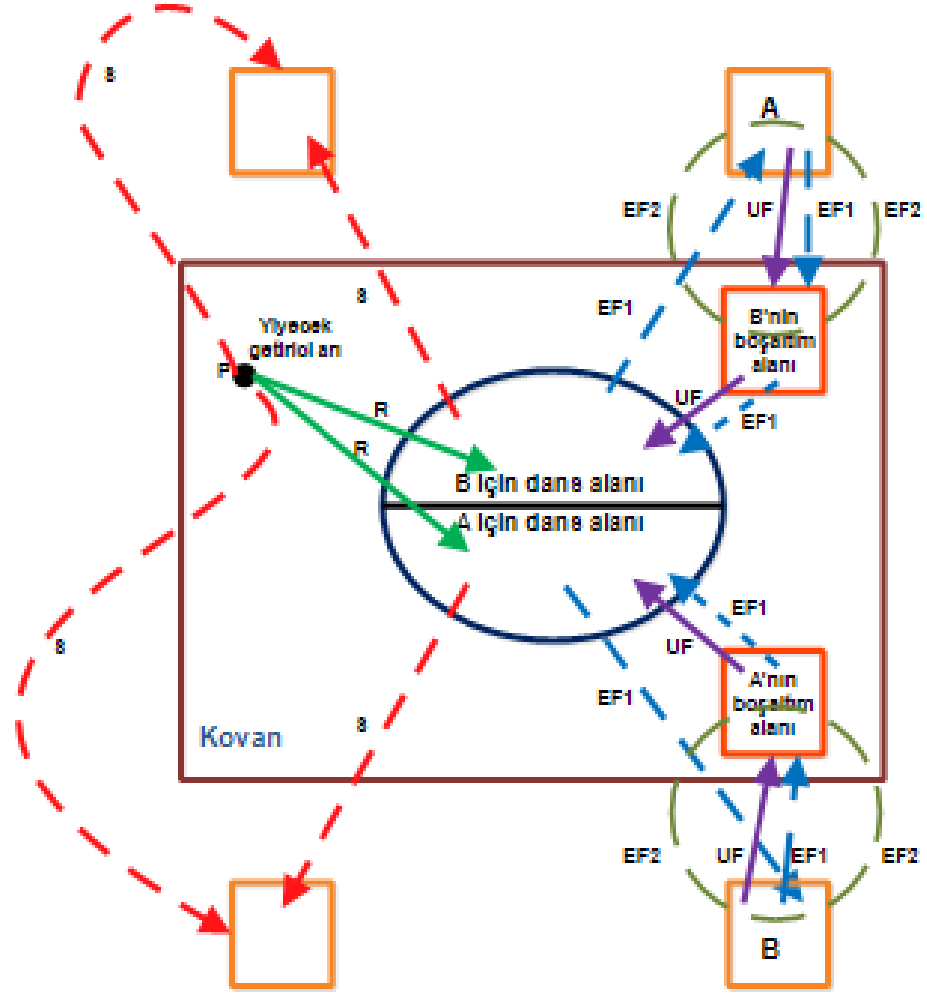
$$\Omega_{test} = W^T x_{test} \quad (2.10)$$

Denklem 2.9'daki eğitim veri setindeki her sınıf için sonuç öznitelik vektörü olan Ω_i ve denklem 2.10'daki test veri setindeki her sınıf için sonuç öznitelik vektörü olan Ω_{test} , yüz görüntülerinin çok yüksek doğrulukla ayırt edilmesini sağlayan vektörlerdir. Bir başka ifadeyle bu vektörler ayırt edici ortak vektörlerdir.

Eğitim ve test veri seti için her sınıfa ait ayırt edici ortak vektörler elde edildikten sonra bunların birbiriyle karşılaştırılması ile yüz görüntüleri sınıflandırılmış olmaktadır.

2.2. Yapay Arı Kolonisi (ABC) Algoritması

Yapay arı kolonisi algoritması (ABC) sürü zekası prensibin temel alındığı optimizasyon algoritmalarından bir tanesidir. İsminden de anlaşılacağı üzere esinlenen, arı sürüsüdür. Algoritmanın çıkış mantığı, arıların doğada yiyecek araması ve bulunan nektar kaynaklarının kovanda diğer arılarla paylaşılması sonucu en kaliteli nektar kaynaklarına ait bilgilerin tespit edilmesidir [31]. Arıların doğal dünyasındaki bu yaşam şeklinin ABC algoritması ile modellenmesi, Şekil 2.1'de gösterilmiştir. Şekilden de görüleceği üzere, arılar kovanın dışında nektar kaynaklarını araştırmakta ve bulunan bu nektar kaynaklarının lokasyon ve kaynak miktar bilgilerini kovandaki dans pistinde diğer arılara aktarmaktadır. Bu şekilde etkileşimler sağlanarak en kaliteli nektar kaynakları tespit edilmeye çalışılmaktadır.



Şekil 2.1. ABC algoritmasının arıların doğal dünyasından modellenmesi [31]

ABC algoritmasındaki popülasyonda üç çeşit arı bulunmaktadır. Bunlar: işçi arılar, gözcü arılar ve kâşif arılardır. İşçi ve gözcü arılar kovanın yakınlarında yiyecek kaynağı tespit etmekle görevliyken; kâşif arı tüm çözüm uzayında keşif yapmaktadır. ABC algoritmasında işçi arı sayısı ve gözcü arı sayısı birbirine eşittir. Nektarı tükenmiş kaynağın görevli arısı, kâşif arı olacak şekilde modellenmektedir [31]. Algoritmanın giriş parametreleri, işçi arı ve gözcü arı sayısına eşit olan nektar sayısı, durdurma kriteri ve nektar kaynaklarının en fazla şekilde ziyaret edilebileceği terkedilme limitidir. ABC algoritmasının durdurma kriteri parametresi, maksimum iterasyon sayısı veya kabul edilebilir başarı veya hata oranı değeri olabilmektedir. ABC algoritmasının fazlarının kaba kod tasarımı, Şekil 2.2'de gösterilmiştir [32].

```

P = başlangıç nektar kaynakları;
değerlendir (P) ;
while durdurma kriteri sağlanmadıkça
    işçiArıFazı (P) ;
    gözcüArıFazı (P) ;
    kaşifArıFazı (P) ;
    P = sırala (P) ;
end
enİyiDeğeriDöndür (P) ;

```

Şekil 2.2. ABC algoritması kaba kodu

Algoritmanın kaba kodu incelenecek olursa [33];

- Algoritma, başlangıç aşamasında, nektar kaynak sayısı parametresince rastgele nektar kaynakları üretilerek başlamakta ve üretilen her başlangıç nektar kaynağı için terk etme limitinin takip edilebilmesi adına birer geliştirelememe değişkeni tanımlanmaktadır.
- Değerlendirme aşamasında, üretilen bu nektar kaynaklarının kalite değerleri hesaplanmaktadır.
- Algoritmanın bundan sonraki kısmı, belirlenen durdurma kriteri sağlanana kadar çalışacak bloklar şeklinde işlemektedir. Her blok içerisinde, işçi arı fazı, gözcü arı fazı ve kaşif arı fazı yer almaktadır.
- İşçi arı fazında, her işçi arı yeni nektar kaynakları tespit etmektedir. Tespit edilen her yeni nektar kaynağının kalite değeri hesaplandıktan sonra, eldeki nektar kaynağının kalite değeri ile kıyaslanmaktadır. Hangi nektar kaynağının kalite değeri daha iyiye o nektar kaynağı ile devam edilmektedir. Bu yöntem, aç gözlü seçim olarak da adlandırılmaktadır. Kıyaslamalar yapılırken, değiştirilemeyen nektar kaynakları için geliştirelememe değişkenlerinin değerleri birer artırılmaktadır. Ayrıca bu aşamada, tüm nektar kaynaklarının toplam kalite değerlerinin saklandığı bir toplam kalite değeri hesaplanmaktadır.

- Gözcü arı fazında, her gözcü arı eldeki yeni nektar kaynaklarını bir olasılık çerçevesinde tespit etmektedir. Bu olasılık, rulet tekerleği prensibine göre ilgili nektar kaynağının kalite değerinin toplam kalite değeri değişkenine oranlanması ile tespit edilmektedir. Literatürde farklı olasılık hesaplama yöntemleri de kullanılmıştır. Tespit edilen her yeni nektar kaynağının kalite değeri hesaplandıktan sonra, eldeki nektar kaynağının kalite değeri ile kıyaslanmaktadır. Hangi nektar kaynağının kalite değeri daha iyiye o nektar kaynağı ile devam edilmektedir. Kıyaslamalar yapılırken, geliştirilemeyen nektar kaynakları için geliştirilememe değişkenlerinin değerleri birer artırılmaktadır.
- Kâşif arı fazında, işçi arı ve gözcü arı fazı sonucu nektar kaynaklarının geliştirilememe değişkenlerinin değerleri terk etme limiti parametresiyle karşılaştırılmaktadır. Terk etme limiti parametresine ulaşan nektar kaynakları terkedilerek, yerlerine mevcut nektar kaynaklarından farklı yeni rastgele nektar kaynakları üretilmektedir. Üretilen bu yeni nektar kaynakları için geliştirilememe değişken değeri sıfırlanmaktadır. Kâşif arılar sayesinde iterasyonlar boyunca algoritmanın belirli lokal en iyi değerlere takılması engellenmekte ve global en iyi değerlere ulaşmaya çalışılmaktadır. Eğer durdurma kriteri sağlandıysa en yüksek kalite değerine sahip nektar kaynakları kümesi, algoritmanın çözümü olarak sunulmaktadır.

ABC algoritmasında, kalite fonksiyonu, komşuluk üretim mekanizması ve algoritma giriş parametreleri problemden probleme farklılıklar göstermektedir. Bunun sebebi farklı problemleri ABC algoritması ile farklı farklı modellenmesidir [32]. Bizim problemimizin çözümü adına yapılan modelleme ve seçilen parametre değerleri hakkında detaylı bilgilendirme, geliştirilen sistem bölümünde yapılacaktır.

2.3. Genetik Algoritma (GA)

Genetik algoritma, doğada gözlemlenen gelişimine benzer bir şekilde çalışan arama ve eniyileme yöntemidir. Karmaşık çok boyutlu arama uzayında en iyinin hayatta kalması ilkesine göre bütünsel en iyi çözüm aranmaktadır. Genetik algoritma, problemlere tek bir çözüm üretmek yerine farklı çözümlerden oluşan bir çözüm kümesi üretmektedir.

Böylelikle, arama uzayında aynı anda birden çok nokta değerlendirilmekte ve sonuçta bütünsel çözüme ulaşma olasılığı yükseltilmektedir. Çözüm kümesindeki çözümler birbirinden tamamen bağımsızdır. Her biri çok boyutlu uzay üzerinde vektördür [34].

GA'da diğer eniyileme yöntemlerinde olduğu gibi çözüm için tek bir yapının geliştirilmesi yerine, böyle yapılardan meydana gelen bir küme oluştururlar. Problem için olası pek çok çözümü temsil eden bu küme genetik algoritma terminolojisinde popülasyon adını alır. Popülasyon, kromozom veya birey adı verilen sayı dizilerinden oluşmaktadır. Birey içindeki her bir elemana gen adı verilir. Popülasyondaki bireyler gelişim süreci içinde genetik algoritma operatörleri tarafından belirlenirler [35].

Genetik algoritmanın problemin çözümündeki başarısına etki eden en önemli faktör, problemin çözümünü temsil eden bireylerin gösterimidir. Popülasyon içindeki her bireyin problem için çözüm olup olmayacağına karar veren bir kalite fonksiyonu vardır. Kalite fonksiyonundan dönen değere göre yüksek değere sahip olan bireylere, popülasyondaki diğer bireyler ile etkileşimde bulunmaları için fırsat verilmektedir. Bu bireyler, çaprazlama işlemi sonunda yeni bireyler üretmektedirler. Yeni bireyler çaprazlama öncesindeki bireylerin genlerinden ortak özellikler taşımaktadır. Yeni bireyler üretilirken düşük kalite değerine sahip bireyler daha az seçileceğinden bu bireyler bir süre sonra popülasyon dışında bırakılırlar. Yeni popülasyon, bir önceki popülasyonda yer alan kalitesi yüksek bireylerin bir araya gelip çoğalmalarıyla oluşmaktadır. Böylelikle, nesiller boyunca kaliteli özellikler, popülasyon içerisinde yayılırlar ve genetik işlemler aracılığıyla da diğer iyi özelliklerle etkileşime geçmektedirler. Kalite değeri yüksek olan ne kadar çok birey bir araya gelip, yeni bireyler oluşturursa arama uzayı içerisinde o kadar iyi bir çalışma alanı elde edilir [36]. Probleme ait en iyi çözümün bulunabilmesi için;

- Problemin genetik modellemesinin yani bireylerin gösterimi doğru bir şekilde yapılmalı,
- Kalite fonksiyonu, problemin niteliğine uygun olarak belirlenmeli,
- Doğru genetik algoritma operatörleri ve parametreleri seçilmelidir.

Genetik algoritmanın kaba kod tasarımı, Şekil 2.3’de gösterilmiştir [36].

```
P = başlangıç popülasyonu;
değerlendir(P);
while durdurma kriteri sağlanmadıkça
    P' = iyiBireyleriSeç(P);
    P' = çaprazla(P');
    mutasyon(P');
    değerlendir(P');
    P = P';
end
enİyiBireyiDöndür(P);
```

Şekil 2.3. Genetik algoritma kaba kodu

Algoritmanın kaba kodu incelenecek olursa [36];

- Başlangıç popülasyonu aşamasında, modellenmesi yapılan bireyler rastgele ve birbirinden farklı bir şekilde oluşturulmaktadır. Popülasyondaki birey sayısı genetik algoritmanın parametrelerinden olup sisteme giriş olarak verilmektedir. Değerlendirme aşamasında ise, oluşturulan bu bireylerin kalite değerleri, problemin kalite fonksiyonu ile belirlenmektedir.
- Algoritmanın sonraki kısmı, belirlenen durdurma kriteri sağlanana kadar çalışacak bloklar şeklinde işlemektedir. Durdurma kriteri, iterasyon sayısı veya kabul edilebilir hata oranı olabilmektedir. Durdurma kriteri de genetik algoritmanın parametrelerinden olup sisteme giriş olarak verilmektedir. Her blok içerisinde, iyi bireylerin seçilmesi, çaprazlama ve mutasyon gibi işlemler ile yeni nesiller oluşturulmaktadır.
- İyi bireylerin seçilmesi aşamasında bir önceki nesildeki en kaliteli bireylerden belirli bir sayıda olanları yeni nesle aktarılmaktadır. Bu sayı da algoritmanın parametrelerin olup sisteme giriş olarak verilmektedir.

- Yeni neslin kalan bireyleri, çaprazlama ve mutasyon işlemlerinden geçirilmektedir. Çaprazlama aşamasında, popülasyon içindeki bireyler rastgele bir şekilde seçilerek birbirleriyle çaprazlanmaktadır. Literatürde çeşitli çaprazlama yöntemleri bulunmaktadır. Çaprazlama sonucunda iki yeni birey oluşmaktadır.
- Oluşan bu iki yeni birey belirli bir mutasyon oranı ihtimalince mutasyona uğratılmaktadır. Mutasyona uğratılma ihtimali de genetik algoritmanın parametrelerinden olup, sisteme giriş olarak verilmektedir. Mutasyon işlemi için literatürde çeşitli yöntemler önerilmiştir.
- Algoritma durdurma kriterinin sağlanmasının ardından, son nesildeki en kaliteli birey, problemin çözümü olarak sunulmaktadır.

2.4. En Yakın Komşu (NN) Sınıflandırıcı

En yakın komşu (NN) algoritması, araştırmacılar tarafından literatürde makine öğrenmesi ve örüntü tanıma alanlarındaki birçok çalışmada sıklıkla kullanılan oldukça basit bir sınıflandırma algoritmasıdır. Algoritmanın orijinal hali k-NN şeklindedir. Buradaki k değeri parametrik olup; örneğin k=3 olduğunda en yakın üç komşu çözüm olarak sunulmaktadır. Eğer k=1 olursa algoritma, en yakın komşu algoritması formuna dönüşmektedir. Algoritmanın sınıflandırma aşamasındaki en önemli operatörü mesafe ölçüm fonksiyonudur. Literatürde çeşitli problemler için çeşitli mesafe ölçüm fonksiyonları kullanılmaktadır. Bu mesafe ölçüm fonksiyonlarından en yaygın kullanılanı, Öklid fonksiyonudur. En yakın komşu sınıflandırma algoritmasının kaba kod tasarımı, Şekil 2.4'de gösterilmiştir [37].

```

for veri setindeki her veri için
    for eğitim veri setindeki her eğitim kaydı için
        Mesafeler.ekle(mesafe(veri, eğitim)); End
test.sınıf = minimum(Mesafeler).sınıf;
Mesafeler.temizle();end

```

Şekil 2.4. NN sınıflandırıcı kaba kodu

Algoritmanın kaba kodu incelenecek olursa [37];

- Algoritma test veri setindeki her test kaydı için eğitim veri setindeki her eğitim kaydının karşılaştırılması mantığına göre çalışmaktadır.
- Bu karşılaştırmalarda, döngü içerisinde her test kaydının bütün eğitim kayıtlarına olan mesafeleri hesaplanmakta ve saklanmaktadır.
- Eğitim kayıtlarına olan mesafeleri hesaplanan test kaydı için, en yakın mesafedeki eğitim kaydının sınıfı ilgili test kaydının sınıfı olarak belirlenmektedir.

2.5. Kullanılan Yüz Veri Setleri

Bu tez çalışmasında deneysel işlemler için, literatürde en çok tercih edilen setleri AR [38], ORL [39] ve YALE [9] veri setleri kullanılmıştır. Kullanılan veri setleri hakkında özet gösterim, Tablo 2.1’de ve bazı örnek yüz görüntüleri Şekil 2.5’de gösterilmiştir.

Tablo 2.1. Kullanılan veri setleri hakkında özet gösterim.

Veri Seti	Seçilen Görüntüler	Sınıf Sayısı	Eğitim Seti	Test Seti	Eğitim ve Test Seti için Örnek Sayısı	Orijinal Görüntü Boyutları (Piksel)	Normalizasyon Yapılmış Görüntü Boyutları (Piksel)	Öznitelik Sayısı
AR	300	30	150	150	5	768x576	115x85	9775
ORL	400	40	200	200	5	112x92	112x92	10304
YALE	150	15	75	75	5	320x243	64x64	4096



Şekil 2.5. Kullanılan yüz veri setlerinden bazı örnek görüntüler

2.5.1. AR Yüz Veri Seti

AR yüz veri seti Aleix Martinez ve Robert Benavente tarafından, Barcelona Üniversitesi, Bilgisayar Görüntü İşleme Merkezi laboratuvarlarında oluşturulmuştur [38]. Bu veri setinde 126 farklı kişiye (70 erkek 56 kadın) ait 4000den fazla renkli yüz resmi bulunmaktadır. Veri setindeki yüz görüntüleri farklı şartlar altında kaydedilmiştir. Bu şartlar: karşıdan görünüm, farklı duygusal şekillerde görünüm, farklı ışıklandırma koşulları altındaki görünüm ve farklı aksesuarlar ile olan görünümünden oluşmaktadır. Katılımcılara, hiçbir şekilde görünümünde değişiklik konusunda baskı yapılmadan kayıtlar yapılmıştır.

Bu tez çalışmasında AR yüz veri setinden, 30 kişiye ait rastgele 300 tane görüntü seçilmiştir. Bu 300 görüntü eğitim ve test işlemleri için 2 gruba bölünmüştür. Bir başka ifadeyle, her kişi için 5 tane eğitim verisi, 5 tane de test verisi alınmıştır. Orijinal görüntüler, 768x576 piksel çözünürlüğe sahiptir. Bu görüntüler, 115x85 piksel boyutuna normalize edilmiştir. Normalizasyonu yapılmış olan görüntülerdeki, öznitelik sayısı, 9775'dir. AR yüz veri setine ait bazı örnekler aşağıda Şekil 2.6'de gösterilmiştir.



Şekil 2.6. AR yüz veri setinden bazı örnek görüntüler

2.5.2. ORL Yüz Veri Seti

ORL yüz veri seti, Olivetti-Oracle araştırma laboratuvarı tarafından oluşturulmuştur [39]. Bu veri setinde 40 kişiye ait 400 görüntü bulunmaktadır. Veri setindeki yüz görüntüleri farklı şartlar altında kaydedilmiştir. Bu şartlar: karşıdan görünüm, farklı duygusal şekillerde görünüm, farklı ışıklandırma koşulları altındaki görünüm ve farklı aksesuarlar ile olan görünümüdür.

Bu tez çalışmasında ORL yüz veri setindeki 40 kişiye ait her bir kişiye ait bu 400 görüntü, rastgele 200 tanesi eğitim; 200 tanesi de test işlemi için kullanılmak üzere seçilmiştir. Bir başka ifadeyle, her kişi için 5 tane eğitim verisi, 5 tane de test verisi alınmıştır. Orijinal görüntüler, 112x92 piksel çözünürlüğe sahiptir. Bir başka ifadeyle, görüntülerdeki öznitelik sayısı, 10304'dür. ORL yüz veri setine ait bazı örnekler aşağıda Şekil 2.7'de gösterilmiştir.



Şekil 2.7. ORL yüz veri setinden bazı örnek görüntüler

2.5.3. YALE Yüz Veri Seti

YALE yüz veri seti, YALE Üniversitesi tarafından oluşturulmuştur [39]. Bu veri setinde 15 kişiye ait 165 görüntü bulunmaktadır. Veri setindeki yüz görüntüleri farklı şartlar altında kaydedilmiştir. Bu şartlar: karşıdan görünüm, farklı duygusal şekillerde görünüm, farklı ışıklandırma koşulları altındaki görünüm ve farklı aksesuarlar ile olan görünümünden oluşmaktadır.

Bu tez çalışmasında YALE yüz veri setinden, 15 kişiye ait rastgele 150 tane görüntü seçilmiştir. Bu 150 görüntü eğitim ve test işlemleri için 2 gruba bölünmüştür. Bir başka ifadeyle, her kişi için 5 tane eğitim verisi, 5 tane de test verisi alınmıştır. Orijinal görüntüler, 320x243 piksel çözünürlüğe sahiptir. Bu görüntüler, 64x64 piksel boyutuna normalize edilmiştir. Normalizasyonu yapılmış olan görüntülerdeki, öznitelik sayısı, 4096'dır. YALE yüz veri setine ait bazı örnekler aşağıda Şekil 2.8'de gösterilmiştir.



Şekil 2.8. YALE yüz veri setinden bazı örnek görüntüler

2.6. Kullanılan Fiziki Makina

Bu tez çalışması kapsamında uygulamanın geliştirildiği, uygulamanın test edildiği ve sonuçların yorumlandığı bilgisayarın özellikleri aşağıdaki şekildedir:

- Intel® Core™ i7-840QM İşlemci,
 - İşlemci hızı 1.86 GHz., Intel® Turbo Boost Teknolojisi ile 3.20 GHz'e kadar, 8MB Intel® Akıllı Bellek,
 - Intel® HM55 Chipset,
 - Kablosuz Ağ Bağlantısı 802.11 b/g.
- Orijinal Windows® 7 Home Premium (64 Bit),
- 8 GB DDR3 1066 MHz Bellek,
- 640 GB SATA Harddisk,
- 15.6" WXGA (1366x768) HD LED Ekran,
- 2 GB DDR3 Nvidia Geforce GT335M Ekran Kartı (1GB Ayrılmış Bellek),
- 1.3MP Web Camera,

- DVD \pm RW DUAL,
- Bluetooth,
- PCI-e Mini Card,
- Multi Card reader,
- 3X USB 2.0 port, 1X eSATA Combo, 1X HDMI.

3. BÖLÜM

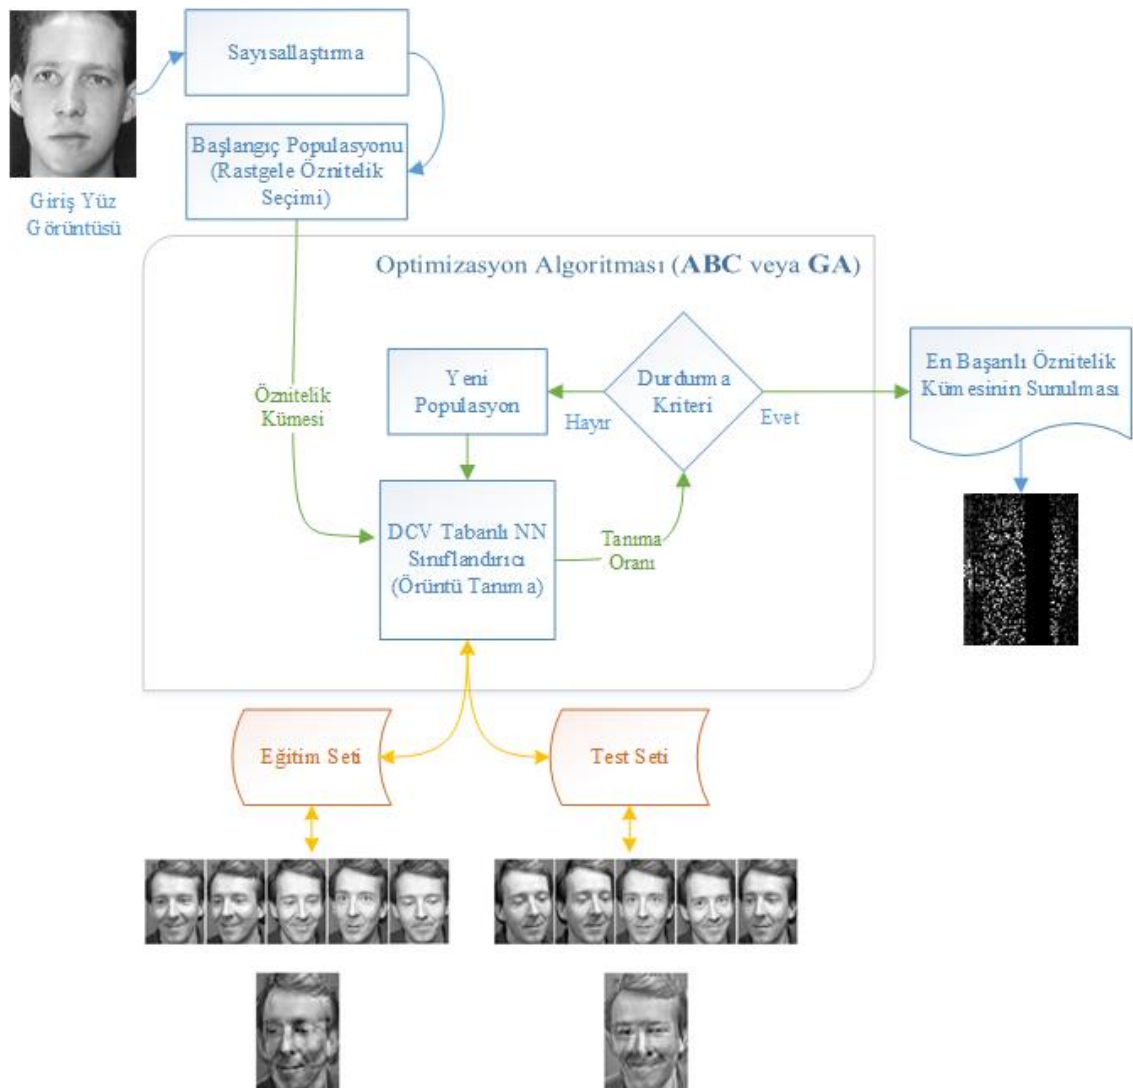
GELİŞTİRİLEN SİSTEM VE BULGULAR

Bu bölümde geliştirilen sistemin detaylı açıklaması yapılacaktır. Yapılacak olan bu detaylandırmada izlenecek olan yol, genel sistem diyagramının sunulması, tasarlanan sistemin GA ve ABC algoritmaları ile modellerinin sunulması, ABC algoritmasının adımlarının ve operatörlerinin sistem üzerinde uygulamasının açıklanması, GA'nın adımlarının ve operatörlerinin sistem üzerinde uygulamasının açıklanması, GA ve ABC algoritmalarının sistem için uygulanan giriş parametre değerlerine değinilmesi ve elde edilen bulguların paylaşılması şeklinde olacaktır.

Öncelikle geliştirilen sistemin blok diyagramı, Şekil 3.1'de sunulmuştur. Blok diyagram incelenecek olursa;

- Öncelikle giriş olarak alınan yüz görüntüsü sayısallaştırılarak vektörel forma dönüştürülmektedir. Matris form yerine vektörel form kullanılmasının sebebi, sonraki adımlarda yapılacak olan hesaplamaların maliyetlerinin minimize edilmesidir.
- Sayısallaştırılan yüz görüntülerinden eğitim ve test veri seti için rastgele öznitelikler seçilmektedir. Seçilen bu öznitelikler indirgenmiş vektörel formda saklanmaktadır.
- Seçilen bu özniteliklerle, DCV tabanlı NN sınıflandırıcı sayesinde test yüz görüntüleri için sınıflandırma başarı oranları hesaplanmaktadır. Bir başka ifadeyle DCV tabanlı NN sınıflandırıcı, kullanılacak olan optimizasyon algoritmasının kalite fonksiyonudur.


- Sınıflandırma başarı oranlarının elde edilmesinin ardından, sonuçlar durdurma kriteri parametresine bağlı olarak kullanılacak olan optimizasyon algoritmasına geri besleme olarak sunulmaktadır.
- Nihai olarak, en başarılı çözüm kümesi olan maksimum sınıflandırma başarı oranına ve minimum boyuta sahip öznitelik alt kümesi sistemin çözümü olarak sunulmaktadır.



Şekil 3.1. Geliştirilen sistemin genel diyagramı

3.1. Sistemin ABC Algoritması ile Modellenmesi

Görünüş tabanlı yüz görüntülerinin sınıflandırılmasında verimliliği artırmak için, ABC algoritması ve DCV tabanlı NN sınıflandırıcı sisteminin modellenmesi yapılmıştır. Bu modelleme kapsamında, rastgele seçilen ve sıralanan her öznelik indeks alt kümesi, ABC algoritmasının nektar kaynakları olarak modellenmiştir. Bundan sonraki bölümde, öznelik indeks alt kümesi, öznelik kümesi olarak adlandırılacaktır. Seçilen her öznelik kümesinin bir nektar kaynağı olarak modellenmesinin sebebi, ABC algoritmasının her iterasyonunda yeni öznelik kümeleri oluşturmak ve çeşitliliği artırmaktır. Seçilecek öznelik kümelerinin, ABC algoritması ile yapılan modellemesine ait örnek gösterim, Şekil 3.2’de görülmektedir.



Şekil 3.2. Öznelik kümelerinin ABC algoritması ile modellenmesi

Öznelik kümelerinin boyutları (içinde bulunduracakları öznelik indeks sayısı); bir başka ifadeyle, ABC algoritmasının nektar kaynaklarının boyutları, rastgele ve dinamik olarak belirlenmektedir. Bu belirleme işlemi, yüz görüntülerinden seçilebilecek maksimum öznelik sayısı kriteri altında yapılmaktadır. Bu kriter, kullanıcı tarafından sisteme giriş parametresi olarak verilmektedir. Farklı boyutlardaki nektar kaynaklarının örnek gösterimi, Şekil 3.3’de görülmektedir.

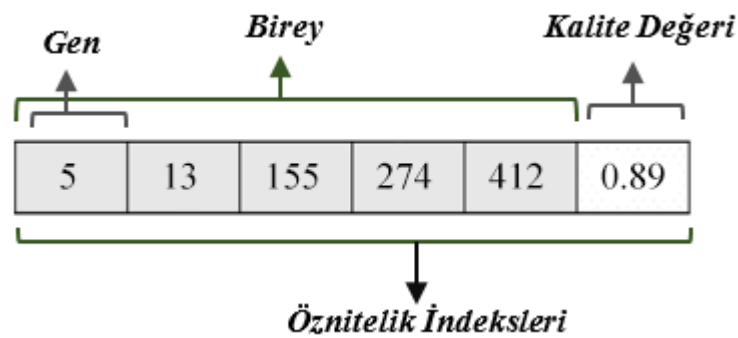
<i>Nektar Kaynağı-1</i>	3	8	121	235	393
<i>Nektar Kaynağı-2</i>	48	96	248	565	

Şekil 3.3. Farklı boyutlardaki örnek nektar kaynaklarının gösterimi

Nektar kaynaklarının kalitesinin hesaplanması adına ABC algoritmasının kalite fonksiyonu olarak, DCV tabanlı NN sınıflandırıcı kullanılmaktadır. Buna göre, seçilen öznitelik kümesi için, görünüş tabanlı test ve eğitim yüz görüntülerinin sınıfları DCV yöntemi ile indirgenmekte ve NN sınıflandırıcı ile sınıflandırılmaktadır. Sınıflandırma başarı oranı, nektar kaynağının kalite değerini ifade etmektedir. Kalite fonksiyonu yapısı, Şekil 3.1'deki DCV tabanlı öznitelik seçimi ve NN sınıflandırıcı ile örüntü tanıma kısmında gösterilmiştir.

3.2. Sistemin GA ile Modellenmesi

Görünüş tabanlı yüz görüntülerinin sınıflandırılmasında verimliliği artırmak için, GA ve DCV tabanlı NN sınıflandırıcı sisteminin modellenmesi yapılmıştır. Bu modelleme kapsamında, rastgele seçilen ve sıralanan her öznitelik indeks alt kümesi, GAnın bireyleri olarak modellenmiştir. Öznitelik indeks alt kümesindeki her indeks değeri ise, bireyin genleri olarak modellenmiştir. Bundan sonraki bölümde, öznitelik indeks alt kümesi, öznitelik kümesi olarak adlandırılacaktır. Seçilen her öznitelik kümesinin bir birey olarak modellenmesinin sebebi, GAnın her neslinde yeni öznitelik kümeleri oluşturmak ve genetik çeşitliliği artırmaktır. Seçilecek olarak öznitelik kümelerinin, GA ile yapılan modellenmesine ait örnek gösterim, Şekil 3.4'de görülmektedir.



Şekil 3.4. Öznitelik kümelerinin GA ile modellenmesi

Öznitelik kümelerinin boyutları (içinde bulunduracakları öznitelik indeks sayısı); bir başka deyişle, GA bireylerinin boyutları (içinde bulunduracakları gen sayısı), rastgele ve dinamik olarak belirlenmektedir. Bu belirleme işlemi, yüz görüntülerinden

seçilebilecek maksimum öznitelik sayısı kriteri altında yapılmaktadır. Bu kriter, kullanıcı tarafından sisteme giriş parametresi olarak verilmektedir.

Bireylerinin kalitesinin hesaplanması adına GA kalite fonksiyonu olarak, DCV tabanlı NN sınıflandırıcı kullanılmaktadır. Buna göre, seçilen öznitelik kümesi için, görünüş tabanlı test ve eğitim yüz görüntülerinin sınıfları DCV yöntemi ile indirgenmekte ve NN sınıflandırıcı ile sınıflandırılmaktadır. Sınıflandırma başarı oranı, bireyin kalite değerini ifade etmektedir. Kalite fonksiyonu yapısı, Şekil 3.1'deki DCV tabanlı öznitelik seçimi ve NN sınıflandırıcı ile örüntü tanıma kısmında gösterilmiştir.

3.3. ABC Algoritması ile Uygulanması

Sistem için geliştirilen ABC algoritması ile çözüm işleminin kaba kod tasarımı, Şekil 3.5'da verilmiştir. Kaba kod detaylandırılacak olursa, başlangıç nektar kaynaklarının üretilmesi aşamasında, sisteme giriş olarak verilen nektar kaynak sayısı parametresi değerince, birbirinden farklı rastgele nektar kaynakları üretilmektedir. Değerlendirme aşamasında, üretilen bu nektar kaynaklarının kalite değerleri DCV tabanlı NN sınıflandırıcı ile belirlenmektedir.

Başlangıç nektar kaynaklarının üretilmesi ve değerlendirilmesi aşamalarından sonra kullanıcı tarafından sisteme giriş olarak verilen durdurma kriteri parametresi sağlanıncaya kadar döngü içerisinde ABC algoritması operatörleri işlenmektedir. Durdurma kriteri sağlandığında ise son iterasyondaki en kaliteli nektar kaynağı çözüm olarak sunulmaktadır. Durdurma kriteri maksimum iterasyon sayısı olabileceği gibi kabul edilebilir bir başarı oranı da olabilmektedir.

```

P = başlangıçNektarKaynaklarınıÜret (nektarKaynakSayısı);
değerlendir (P);
while durdurma kriteri sağlanmadıkça
    % işçi arı fazı
    for k in nektarKaynakSayısı
        p = komşulukÜret (P(k));
        değerlendir (p);
        if p.kaliteDeğeri > P(k).kaliteDeğeri
            p.terkedilmeLimiti=0;
            P(k) = p;
        else
            P(k).terkedilmeLimiti ++;
        end if
    end;
    % gözcü arı fazı
    k=0
    While (k<nektarKaynakSayısı)
        if random() < olasılık of P(k)
            k++
            p = komşulukÜret (P(k));
            değerlendir (p);
            if p.kaliteDeğeri > P(k).kaliteDeğeri
                p.terkedilmeLimiti =0;
                P(k) = p;
            else
                P(k).terkedilmeLimiti ++;
            end if;
        end if;
    end;
    % kaşif arı fazı
    for k in nektarKaynakSayısı
        if P(k).terkedilmeLimiti == kaynakTerkedilmeLimiti
            P(k) = yeniNektarKaynağıÜret ();
        end if;
    end;
    enİyiyiKaydet (P);
end;
return enİyiNektarKaynağı (P);

```

Şekil 3.5. Sistem için geliştirilen ABC algoritmasının kaba kod tasarımı

ABC algoritmasının her iterasyonunda, sırasıyla işçi arı, gözcü arı ve kâşif arı fazları işlenmektedir. Komşuluk üretme mekanizması bu modelde aşağıdaki gibi uygulanmıştır.

İşçi arı ve gözcü arı fazlarındaki her nektar kaynağı için komşu nektar kaynağı üretimi özel bir yöntemle uygulanmaktadır. Bu yöntem, tez çalışmasındaki deneysel ve gözlemsel çalışmalar sonucu belirlenmiştir. Buna göre; komşuluk üretme mekanizması üç aşamadan oluşmaktadır. İlk aşamada nektar kaynağı boyutunun maksimum %20 si kadar olan kısmı rastgele başka öznitelik indeksleri ile değiştirilmektedir. Bu aşama kesin olarak işlenmektedir. İkinci aşamada, nektar kaynağı boyutunun maksimum %20 si kadar olan yeni rastgele seçilmiş öznitelik indeksleri nektar kaynağına eklenmektedir. Bu aşama, %50 oran kistası altında işlenmektedir. Üçüncü ve son aşamada ise, nektar kaynağı boyutunun maksimum %20 si kadar olan rastgele öznitelik indeksleri nektar kaynağından çıkarılmaktadır. Bu aşamada ikinci aşamada olduğu şekilde, %50 oran kistası altında işlenmektedir. Geliştirilen bu komşu nektar kaynağı üretme mekanizması ile ilgili örnek bir sunum, Şekil 3.6'de görülmektedir.

<i>Nektar Kaynağı</i>	3	8	121	235	393
<i>Adım-1 (Kesin İşlendi)</i>	3	13	121	235	393
<i>Adım-2 (%50 İhtimal Sonucu İşlenmedi)</i>	3	13	121	235	393
<i>Adım-3 (%50 İhtimal Sonucu İşlendi)</i>	3	13	121	235	X
<i>Komşu Nektar Kaynağı</i>	3	13	121	235	

Şekil 3.6. Geliştirilen ABC algoritmasının örnek komşuluk üretme mekanizması

İşçi arı fazında, her nektar kaynağı için yeni komşu bir nektar kaynağı, yukarıdaki komşuluk üretme mekanizması ile üretilmektedir. Üretilen bu komşu nektar kaynağının kalite değeri hesaplandıktan sonra, eski nektar kaynağının kalite değeri ile kıyaslama

yapılmaktadır. Eğer yeni üretilen komşu nektar kaynağı daha kaliteli ise eski nektar kaynağı terkedilmektedir. Eski nektar kaynağı daha kaliteli ise, onunla devam edilmekte ve nektar kaynağının geliştirilememe değişkeninin değeri bir artırılmaktadır.

Gözcü arı fazında, her nektar kaynağı için rulet tekerleği yöntemine göre bir olasılık değeri hesaplanmaktadır. Bu olasılık değeri kıstası altında, her nektar kaynağı için yeni komşu bir nektar kaynağı, işçi arı fazındaki aynı komşuluk üretme mekanizması ile üretilmektedir. Üretilen bu komşu nektar kaynağının kalite değeri hesaplandıktan sonra, eski nektar kaynağının kalite değeri ile kıyaslama yapılmaktadır. Eğer yeni üretilen komşu nektar kaynağı daha kaliteli ise eski nektar kaynağı terkedilmektedir. Eski nektar kaynağı daha kaliteli ise, onunla devam edilmekte ve nektar kaynağının geliştirilememe değişkeninin değeri bir artırılmaktadır.

Kâşif arı fazında, her nektar kaynağı için geliştirilememe değişkenlerinin değerleri ile sisteme giriş olarak verilen kaynak terk etme limiti parametresi karşılaştırılmaktadır. Limite ulaşan nektar kaynakları terkedilerek yerlerine rastgele yeni nektar kaynakları üretilmektedir.

3.4. GA ile Uygulanması

Sistem için geliştirilen GA ile çözüm işleminin kaba kod tasarımı, Şekil 3.7’de görülmektedir. Başlangıç popülasyonunun üretilmesi aşamasında, sisteme giriş olarak verilen birey sayısı parametresi değerince, birbirinden farklı rastgele bireyler üretilmektedir. Değerlendirme aşamasında, üretilen bu bireylerin kalite değerleri DCV tabanlı NN sınıflandırıcı ile belirlenmektedir.

Kullanıcı tarafından sisteme giriş olarak verilen durdurma kriteri parametresi sağlanıncaya kadar döngü içerisinde GA operatörleri işlenmektedir. Durdurma kriteri sağlandığında ise son iterasyondaki en kaliteli birey çözüm olarak sunulmaktadır. Durdurma kriteri maksimum nesil sayısı olabileceği gibi kabul edilebilir bir başarı oranı da olabilmektedir.

```

P = başlangıçPopülasyonuÜret (bireySayısı) ;
değerlendir (P) ;
while durdurma kriteri sağlanmadıkça
    P' = yeniBoşPopülasyonÜret () ;
    P'.add (enElitBireyleriSeç (P, elitizmKriteri)) ;
    while P' bireySayısı kadar dolmadıkça
        ebeveynler = rastgeleSeç (P) ;
        çocuklar = çaprazla (ebeveynler) ;
        mutasyon (çocuklar) ;
        genProblemleriniÇöz (çocuklar) ;
        değerlendir (çocuklar) ;
        P'.add (kaliteliÇocuk (çocuklar)) ;
    end ;
    kötüBireyleriTemizle (P') ;
    P = P' ;
end ;
return enKaliteliBirey (P) ;

```


Şekil 3.7. Sistem için geliştirilen GA kaba kod tasarımı

Algoritmanın her iterasyonunda, elit bireylerin yeni nesle aktarılması, çaprazlama işlemi sonucunda yeni bireylerin üretilmesi, yeni bireylerin mutasyona uğratılması, yeni bireylerde oluşabilecek muhtemelen gen hatalarının giderilmesi ve hangi bireylerin bir sonraki nesle aktarılacağına karar verilmesi işlemleri yapılmaktadır.

Elit bireylerin yeni nesle aktarılması aşamasında, kullanıcı tarafından sisteme giriş olarak verilen elitizm kriteri parametresi değerince popülasyondaki en kaliteli bireyler yeni nesle doğrudan aktarılmaktadır. Bu sayede yeni nesilde mutlaka bir önceki nesilden miras kalan kaliteli bireylerin bulundurulması sağlanmış olacaktır.


Çaprazlama aşamasında, popülasyondaki rastgele ve birbirinden farklı iki birey çaprazlanmak üzere seçilmektedir. Bu bireyler ebeveyn olarak adlandırılmaktadır. Çaprazlama işlemi tek noktali olarak yapılmaktadır. Her ebeveyn için rastgele çaprazlama noktaları belirlenmekte ve bu noktalardan bu iki birey çaprazlanarak yeni çocuk bireyler üretilmektedir. Bu çocuk bireyler, ebeveynlerden ve birbirinden

tamamen farklı fakat ebeveynlerin genlerini ihtiva etmektedirler. Örnek bir çaprazlama işlemi Şekil 3.8’de görülmektedir.



Şekil 3.8. Sistem için geliştirilen GA örnek çaprazlama mekanizması

Mutasyon aşamasında, üretilen yeni çocuk bireyler, kullanıcı tarafından sisteme giriş olarak verilen mutasyon oranı parametresi değeri olasılığınca ayrı ayrı mutasyona uğratılmaktadırlar. Mutasyon işlemi tek noktali olarak yapılmaktadır. Buna göre; mutasyona uğratılacak bireyden rastgele bir gen belirlenmekte ve bu gen, gen havuzu yani öznitelik indeksleri kümesinden rastgele bir gen ile değiştirilmektedir. Örnek bir mutasyon işlemi, Şekil 3.9’da görülmektedir.



Şekil 3.9. Sistem için geliştirilen GA örnek mutasyon mekanizması

Çaprazlama ve mutasyon aşamalarından sonra üretilen yeni çocuk bireylerde bir takım gen tekrarları oluşabilmektedir. Bu tekrarların oluşmasının sebebi, farklı problemlerin genetik algoritma ile farklı şekillerde modellenmesinden kaynaklanmaktadır [36]. Bu tarz gen hatalarını bünyesinde barındıran bireyler, doğal süreçlere benzer şekilde

öldürülmektedir yani silinmektedir. Öldürülen bu bireylerin yerlerine rastgele ve popülasyondaki diğer bireylerden farklı yeni bireyler üretilmektedir.

İterasyon içindeki çocuk bireylerle ilgili aşamaların tamamlanmasından sonra, bu çocuk bireylerin kalite değerleri hesaplanmaktadır. Kalite değeri yüksek olan çocuk birey, yeni nesle aktarılmaktadır. Bu aşamalar ile popülasyonun eksik kalan diğer bireyleri de aynı şekillerde üretilerek tamamlanmaktadır.

Yeni nesildeki popülasyonun üretilmesinin ardından, kalite değeri düşük olan bireylerinin yerlerine popülasyondaki diğer bireylerden farklı ve rastgele yeni bireylerin üretildiği temizlik operatörü tanımlanmıştır. Bu operatör genetik algoritmanın klasik operatörleri arasında yer almamasına karşın, tez çalışmasındaki deneysel çalışmalar ve bulgular sonucunda sisteme doping etkisi yaratması amacıyla tanımlanmıştır.

3.5. ABC Algoritmasının Sistem İçin Kullanılan Parametreleri

Sistem çözümü için geliştirilen ABC algoritmasının parametre değerleri, deneysel çalışmalar sonucu belirlenmiştir. Buna göre;

- Nektar kaynak sayısı (aynı zamanda işçi arı ve gözcü arı sayısı da bu değere eşittir) için, 100-300 arası değerlerin uygun olduğu,
- İterasyon sayısı için, 500-1000 arası değerlerin uygun olduğu,
- Nektar kaynaklarının terkedilme limiti için, 100-400 arası değerlerin uygun olduğu gözlemlenmiştir.

3.6. GA nın Sistem İçin Kullanılan Parametreleri

Sistem çözümü için geliştirilen GAnın parametre değerleri, deneysel çalışmalar sonucu belirlenmiştir. Buna göre;


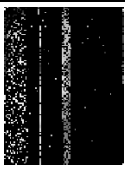




- Popülasyon büyüklüğü için, 100-300 arası değerlerin uygun olduğu,
- İterasyon sayısı için, 100-1000 arası değerlerin uygun olduğu,
- Mutasyon oranı için, 0.05-0.1 arası değerlerin uygun olduğu,
- Elitizm kriteri için, %5-%10 arası değerlerin uygun olduğu sonuçlarına varılmıştır.

3.7. Elde Edilen Deneysel Bulgular

Bölüm 2.5’de, tez çalışması için kullanılan görünüş tabanlı farklı yüz veri setlerindeki eğitim ve test yüz görüntülerinin nasıl belirlendiği, her sınıftaki örnek sayısı, öznitelik sayısı ve sınıf sayısı gibi konular hakkında bilgilendirme yapılmıştı. Bölüm 3.5 ve Bölüm 3.6’da ise ABC algoritması ve GA için kullanılan parametre değerlerinin belirlenmesi ve değerleri verilmiştir.


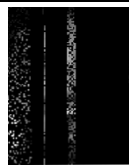




AR, ORL ve YALE yüz veri setleri için ABC algoritması ile geliştirilen sistemin deneysel bulguları, Tablo 3.1’de; GA ile geliştirilen sistemin deneysel bulguları ise, Tablo 3.2’de verilmiştir. İki yöntem ile geliştirilen sistemlerden elde edilen deneysel bulguların karşılaştırmalı gösterimi, Tablo 3.3’de; AR, ORL ve YALE yüz veri setleri için literatürdeki yapılan diğer çalışmalarda elde edilen deneysel bulgular ise, Tablo 3.4’de verilmiştir.

Tablo 3.1. ABC algoritması ile geliştirilen sistem ile elde edilen deneysel bulgular

Veri Seti	Öznitelik Sayısı (X)	Bütün Özniteliklere Sahip Örnek Yüz Görüntüsü	Bütün Özniteliklerle Yüz Tanıma Oranı	Seçilen Öznitelik Sayısı (Y)	Seçilen Özniteliklere Sahip Örnek Yüz Görüntüsü	Seçilen Özniteliklerle Yüz Tanıma Oranı	Öznitelik Seçim Oranı (Y/X)
AR	9775		0.780	902		0.940	0.092
ORL	10304		0.955	357		1.000	0.035
YALE	4096		0.867	148		0.960	0.036

Tablo 3.1 de görüldüğü üzere AR yüz veriseti için ABC algoritması ile geliştirilen sistem kullanılarak 9775 öznitelikten 902 tanesi seçilerek tanıma oranı 0.940 olarak bulunmasıyla hesaplanmıştır. Bütün öznitelikler kullanıldığında hesaplanan tanıma oranı, 0.780 dir. 0.092 lik bir öznitelik seçim oranı ile tanıma oranı 0.780 den 0.940 e çıkmıştır. ORL yüz veriseti için ABC algoritması ile geliştirilen sistem kullanılarak 10304 öznitelikten 357 tanesi seçilerek tanıma oranı 1.000 olarak hesaplanmıştır. Bütün öznitelikler kullanıldığında hesaplanan tanıma oranı, 0.955 dir. 0.035 lik bir öznitelik seçim oranı ile tanıma oranı 0.955 den 1.000 a çıkmıştır. YALE yüz veriseti için ABC algoritması ile geliştirilen sistem kullanılarak 4096 öznitelikten 148 tanesi seçilerek tanıma oranı 0.960 olarak hesaplanmıştır. Bütün öznitelikler kullanıldığında hesaplanan tanıma oranı, 0.867 dir. 0.036 lık bir öznitelik seçim oranı ile tanıma oranı 0.867 den 0.960 a çıkmıştır. Tablo 3.1 deki değerlerle ilgili kıyaslama ve sonuç çıkarımlarına Bölüm 4.1'deki Tartışma, Sonuç ve Öneriler başlığı altında yer verilmiştir.

Tablo 3.2. GA ile geliştirilen sistem ile elde edilen deneysel bulgular

Veri Seti	Öznitelik Sayısı (X)	Bütün Özniteliklere Sahip Örnek Yüz Görüntüsü	Bütün Özniteliklerle Yüz Tanıma Oranı	Seçilen Öznitelik Sayısı (Y)	Seçilen Özniteliklere Sahip Örnek Yüz Görüntüsü	Seçilen Özniteliklerle Yüz Tanıma Oranı	Öznitelik Seçim Oranı (Y/X)
AR	9775		0.780	902		0.920	0.092
ORL	10304		0.955	582		0.985	0.056
YALE	4096		0.867	395		0.960	0.096

Tablo 3.2 de AR yüz veriseti için GA algoritması ile 9775 öznitelik ile hesaplanan tanıma oranı 0.780 iken 902 tanesi seçilerek tanıma oranı 0.920'ye artırılmıştır. ORL yüz veriseti için 10304 ile tanıma oranı 0.955 den özniteliklerden 582 tanesi seçilerek tanıma oranı 0.985 e artırılmıştır. YALE yüz veriseti için 4096 öznitelik ile hesaplanan tanıma oranı 0.867 den özniteliklerden 395 tanesi seçilerek tanıma oranı 0.096 a artırılmıştır. Tablo 3.2 deki değerlerle ilgili kıyaslama ve sonuç çıkarımlarına Bölüm 4.1'deki Tartışma, Sonuç ve Öneriler başlığı altında yer verilmiştir.


Tablo 3.3. ABC algoritması ve GA ile geliştirilen sistemlerden elde edilen deneysel bulguların karşılaştırmalı gösterimi

Veri Seti	GA ile Seçilen Öznitelik Sayısı	GA ile Yüz Tanıma Oranı	ABC ile Seçilen Öznitelik Sayısı	ABC ile Yüz Tanıma Oranı
AR	902	0.920	902	0.940
ORL	582	0.985	357	1.000
YALE	395	0.960	148	0.960


Tablo 3.4. Literatürdeki yapılan diğer çalışmalarda elde edilen deneysel bulgular

Makale	Seçilen Öznitelik Sayısı	Not	AR Yüz Veri Seti Üzerinde Yüz Tanıma Oranı	ORL Yüz Veri Seti Üzerinde Yüz Tanıma Oranı	YALE Yüz Veri Seti Üzerinde Yüz Tanıma Oranı
Wen (2012) [23]	AR için 16384 öznitelik ORL için 10304 öznitelik	IDCV+SVM Yöntemi Her sınıf için 5 örnek	0.82	0.9775	-
Liu ve arkadaşları (2008) [24]	AR için 3168 öznitelik ORL için 10304 öznitelik	DCV Yöntemi (Sonuçlar ortalama değerlerdir)	0.8182	0.8834	-
Jing ve arkadaşları (2008) [25]	AR için 3600 öznitelik	KDCV+RBF Yöntemi (Sonuçlar ortalama değerlerdir)	0.8536	-	-
Koç ve Barkana (2014) [30]	AR için eliptik kesim 8000 ile 2000 arası öznitelik AR için T-Şekil kesim 4000 ile 2000 arası öznitelik YALE için eliptik kesim 3200 ile 11200 arası öznitelik YALE için T-Şekil kesim 3200 ile 9200 arası öznitelik	DCV Yöntemi (Farklı öznitelik seçim mekanizmaları için minimum ve maksimum yüz tanıma oranları alınmıştır)	Eliptik: 0.95-0.96 T-Şekil: 0.97-0.98	-	Eliptik: 0.93-0.95 T-Şekil: 0.90-0.91
Çevikalp ve arkadaşları (2005) [11]	AR için belirtilmemiş YALE için 19152 öznitelik	DCV Yöntemi (Sonuçlar ortalama değerlerdir)	0.99	-	0.973


AR, ORL ve YALE yüz veri setleri için ABC algoritması ile geliştirilen sistemin, iterasyonlar boyunca gelişimi sırasıyla: Şekil 3.10, Şekil 3.11 ve Şekil 3.12’de; GA ile geliştirilen sistemin nesiller boyunca gelişimi ise, sırasıyla: Şekil 3.13, Şekil 3.14 ve Şekil 3.15’de gösterilmiştir.




Şekil 3.10. AR yüz veri seti için ABC algoritması ile geliştirilen sistemin, iterasyonlar boyunca gelişimi: (a) iterasyonlar boyunca yüz tanıma oranı değişimi, (b) iterasyonlar boyunca seçilen öznelik sayısı değişimi




Şekil 3.11. ORL yüz veri seti için ABC algoritması ile geliştirilen sistemin, iterasyonlar boyunca gelişimi: (a) iterasyonlar boyunca yüz tanıma oranı değişimi, (b) iterasyonlar boyunca seçilen öznelik sayısı değişimi




Şekil 3.12. YALE yüz veri seti için ABC algoritması ile geliştirilen sistemin, iterasyonlar boyunca gelişimi: (a) iterasyonlar boyunca yüz tanıma oranı değişimi, (b) iterasyonlar boyunca seçilen öznelik sayısı değişimi



Şekil 3.13. AR yüz veri seti için GA ile geliştirilen sistemin, nesiller boyunca gelişimi: (a) nesiller boyunca yüz tanıma oranı değişimi, (b) nesiller boyunca seçilen öznelik sayısı değişimi



Şekil 3.14. ORL yüz veri seti için GA ile geliştirilen sistemin, nesiller boyunca gelişimi: (a) nesiller boyunca yüz tanıma oranı değişimi, (b) nesiller boyunca seçilen öznelik sayısı değişimi



Şekil 3.15. YALE yüz veri seti için GA ile geliştirilen sistemin, nesiller boyunca gelişimi: (a) nesiller boyunca yüz tanıma oranı değişimi, (b) nesiller boyunca seçilen öznelik sayısı değişimi

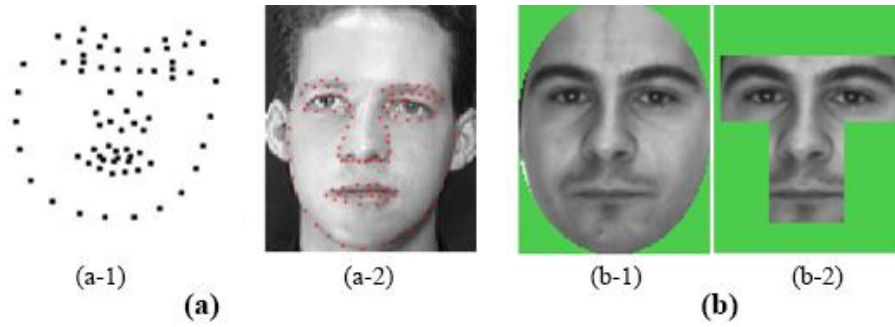
4. BÖLÜM

TARTIŞMA, SONUÇ VE ÖNERİLER

4.1. Tartışma, Sonuç ve Öneriler

Bu tez çalışmasında görünüş tabanlı yüz tanıma için hibrit öznitelik seçim sistemi geliştirilmiştir. Bu sistem, ABC algoritması + DCV tabanlı NN sınıflandırıcı ve GA + DCV tabanlı sınıflandırıcı şeklinde iki ayrı varyasyonda kurgulanmıştır. Geliştirilen sistemin en önemli amacı, maksimum yüz tanıma oranını minimum öznitelik sayısı ile elde etmektir. Geliştirilen sistemin aşamaları, optimizasyon algoritması ile öznitelik seçimi ve seçilen bu özniteliklerin DCV tabanlı NN sınıflandırıcı ile değerlendirilmesidir. Sistemin deneysel bulgularını elde etmek için, AR, ORL ve YALE yüz veri setleri kullanılmıştır. Geliştirilen sistem ile, 0.92-1.00 arasında oldukça yüksek yüz tanıma oranları 0.035-0.096 arasında oldukça düşük öznitelik seçim oranları ile elde edilmiştir. Bu sonuçlar, geliştirilen sistemin ilgili yüz veri setleri için ne kadar başarılı olduğunu göstermektedir.

Yüz tanıma sistemlerinde, yüzün karakteristik noktalarından oluşan şeklin yüze uydurulmasını amaçlayan aktif şekil modeli (AŞM), öznitelik seçimi için önceden tanımlanmış ve statik karakteristiğe sahip bir metottur (Şekil 4.1-a) [40]. Koç ve Barkana (2014) [30] AŞMyi temel alarak yapmış oldukları çalışmalarında, yüz resmini eliptik ve T şeklinde kırparak statik öznitelik seçimi yapmıştır. Seçmiş oldukları öznitelikleri, DCV tabanlı NN sınıflandırıcı ile test etmiştir (Şekil 4.1-b) [30]. AŞM yönteminin kullanıldığı çalışmaların aksine, bu tez çalışmasında optimizasyon algoritmaları kullanılarak dinamik öznitelik seçim mekanizması oluşturulmuştur.



Şekil 4.1. (a) ASM yüz modelleme, (b) AR yüz veri setinden kırılmış eliptik ve T şekil öznitelik seçimi

Geliştirilen ABC algoritması temelli sistemden elde edilen sonuçlar ile literatürdeki diğer çalışmalardan elde edilen sonuçlar, Tablo 3.1 ve Tablo 3.4’de verilmiştir.

AR yüz veri seti için, yüz tanıma oranı bazında ABC temelli elde edilen sonuç, Wen (2012) [23], Liu ve arkadaşları (2008) [24] ve Jing ve arkadaşları (2008) [25] tarafından elde edilen sonuçlara göre daha başarılıdır. Fakat yüz tanıma oranı bazında, Koç ve Barkana (2014) [30] ve Çevikalp ve arkadaşları (2005) [11]’nin çalışmalarına göre nispeten daha başarısız sonuçlar elde edilmiştir. Bu fark, 0.01-0.03 arasında değişen oldukça düşük bir orandır. Buna karşın tez çalışması kapsamında seçilen öznitelik sayısı 902 iken karşılaştırma yapılan bu çalışmalarda seçilen minimum öznitelik sayısı 2000’dir. Bu kapsamda, karşılaştırma yapılan diğer çalışmalara göre %50’den daha az öznitelik seçimi yapılarak, yalnızca 0.01-0.03 aralığında daha az yüz tanıma oranı değerlerinin elde edilmesi tarafımızca oldukça kabul edilebilir şekilde değerlendirilmektedir.

ORL yüz veri seti için, hem yüz tanıma oranı hemde öznitelik seçimi bazında ABC temelli elde edilen, Wen (2012) [23] ve Liu ve arkadaşları (2008) [24] tarafından elde edilen sonuçlara göre daha başarılı olmuştur. Öyle ki, yaklaşık 0.035 gibi oldukça düşük bir öznitelik seçim oranıyla 1.00 gibi olabilecek en yüksek yüz tanıma oranı elde edilmiştir.

YALE yüz veri seti için, yüz tanıma oranı bazında ABC temelli elde edilen sonuç Koç ve Barkana (2014) [30]’ya göre daha başarılı; Çevikalp ve arkadaşları (2005) [11] tarafından elde edilen sonuçlara göre nispeten daha başarısız sonuçlar üretmiştir.

Başarısız olarak değerlendirilen fark, yaklaşık 0.01 gibi oldukça düşük bir değerdir. Bu farkın oluşmasındaki değerlendirmemiz, ilgili çalışma ve bizim çalışmamızdaki test ve eğitim yüz veri setlerinin normalizasyon işlemindeki farklılıklar olabilir. Fakat yine de geliştirmiş olduğumuz ABC algoritması temelli sistem, 0.036 gibi oldukça düşük öznitelik seçim oranıyla 0.96 gibi oldukça yüksek bir yüz tanıma oranı elde etmiştir. Bu sonuç, tarafımızca oldukça başarılı olarak kabul edilmektedir.

GA temelli geliştirilen sistem ile ABC algoritması temelli geliştirilen sistem, Tablo 3.3'deki sonuçlar neticesinde karşılaştırıldığında genel olarak ABC algoritması temelli geliştirilen sistemin kullanılan tüm yüz veri setleri için daha başarılı olduğu görülmektedir.

AR yüz veri seti için GA temelli geliştirilen sistem ile ABC algoritması temelli geliştirilen sistem aynı sayıda öznitelik seçmiştir. Ama yüz tanıma oranı bazında ABC algoritması temelli geliştirilen sistemin daha başarılı olduğu görülmektedir. Bunun sebebi, ABC algoritması temelli geliştirilen sistemin Tablo 3.1'deki sonuçlarda da görüleceği üzere daha etkili öznitelikleri seçmesidir. Nihai değerlendirmede AR yüz veri seti için ABC algoritması temelli geliştirilen sistemin daha başarılı olduğu rahatlıkla söylenebilmektedir.

ORL yüz veri seti için ABC algoritması temelli geliştirilen sistem, GA temelli geliştirilen sisteme göre hem daha az sayıda öznitelik seçmiş hem de 1.00 yüz tanıma oranıyla olabilecek en başarılı sonucu elde etmiştir. Öyle ki öznitelik seçim oranı 0.035 gibi oldukça düşük bir değerdir. Nihai değerlendirmede ORL yüz veri seti için ABC algoritması temelli geliştirilen sistemin daha başarılı olduğu rahatlıkla söylenebilmektedir.

YALE yüz veri seti için GA temelli geliştirilen sistem ile ABC algoritması temelli geliştirilen sistem, 0.96 gibi oldukça yüksek bir değer olan aynı yüz tanıma oranını elde etmiştir. Ama seçilen öznitelik sayısı bazında ABC algoritması temelli geliştirilen sistemin daha başarılı olduğu görülmektedir. Seçilen özniteliklerin oranı Tablo 3.1'de de görüleceği üzere, 0.036 gibi oldukça düşük bir değerdir. Nihai değerlendirmede

YALE yüz veri seti için ABC algoritması temelli geliştirilen sistemin daha başarılı olduğu sonucuna varılabilir.

Tüm bu sonuç, tartışma ve karşılaştırma sonucu değerlendirmelerden sonra geliştirilen ABC algoritması temelli DCV tabanlı NN sınıflandırıcı sistem ile oldukça başarılı sonuçlar elde edilmiştir. Literatüre, bu yöntemle daha farklı yüz veri setleri ile daha detaylı deneysel çalışmalar yapılması önerilmektedir. Bu öneri çerçevesinde gelecekte farklı yüz veri setleri ile geliştirilen sistemin denenmesi de gelecekte yapılacak çalışmalar kapsamında planlanmaktadır.

KAYNAKLAR

1. Chellappa, R., C.L. Wilson, and S. Sirohey, *Human and machine recognition of faces: a survey*. Proceedings of the IEEE, 1995. **83**(5): p. 705 - 741.
2. Zhao, W., et al., *Face recognition: A literature survey*. ACM Computing Surveys (CSUR), 2003. **35**(4): p. 399-458
3. Koç, M., A. Barkana, and Ö.N. Gerek, *A fast method for the implementation of common vector approach*. Information Sciences, 2010. **180**(20): p. 4084-4098.
4. Bartlett, M.S., H.M. Lades, and T.J. Sejnowski, *Independent component representations for face recognition*, in *Human Vision and Electronic Imaging 3*. 1998: California. p. 528-539.
5. Kotu, V. and B. Deshpande, *Feature Selection*. Predictive Analytics and Data Mining 2015: p. 347-370.
6. Blum, A.L. and P. Langley, *Selection of relevant features and examples in machine learning*. Artificial Intelligence, 1997. **97**(1-2): p. 245–271.
7. Kohavi, R. and G.H. John, *Wrappers for feature subset selection*. Artificial Intelligence, 1997. **97**(1-2): p. 273–324.
8. Turk, M. and A. Pentland, *Eigenfaces for recognition*. Journal of Cognitive Neuroscience, 1991. **3**(1): p. 71-86.
9. Belhumeur, P.N., J.P. Hespanha, and D.J. Kriegman, *Eigenfaces vs. Fisherfaces: Recognition Using Class Specific Linear Projection*, in *IEEE Transactions on Pattern Analysis And Machine Intelligence*. 1997.
10. Swets, D.L. and J. Weng, *Using discriminant eigen features for image retrieval*, in *Pattern Analysis and Machine Intelligence, IEEE Transactions*. 1996, IEEE. p. 831 - 836.
11. Cevikalp, H. and M. Wilkes, *Discriminative Common Vectors for Face Recognition*, in *IEEE Transactions On Pattern Analysis And Machine Intelligence*. 2005. p. 4-13.
12. Fukunaga, K., *Introduction to Statistical Pattern Recognition*. 2 ed, ed. W. Rheinboldt. 1990, USA: Morgan Kaufmann.
13. Kaur, H., V.K. Panchal, and R. Kumar, *A Novel Approach Based on Nature Inspired Intelligence for Face Feature Extraction and Recognition*, in *Contemporary Computing (IC3), 2013 Sixth International Conference*. 2013, IEEE: Noida. p. 149-153.
14. Vignolo, L.D., D.H. Milone, and J. Scharcanski, *Feature selection for face recognition based on multi-objective evolutionary wrappers*. Expert Systems with Applications, 2013. **40**(13): p. 5077-5084.
15. Kanan, H.R. and K. Faez, *An improved feature selection method based on ant colony optimization (ACO) evaluated on face recognition system*. Applied Mathematics and Computation, 2008. **205**(2): p. 716-725.
16. Harandi, M.T., et al., *Feature selection using genetic algorithm and it's application to face recognition*, in *Cybernetics and Intelligent Systems, 2004 IEEE Conference*. 2004, IEEE: Singapore. p. 1368 - 1373.
17. Abegaz, T., et al., *Hybrid GAs for Eigen-based facial recognition*, in *Computational Intelligence in Biometrics and Identity Management (CIBIM), 2011 IEEE Workshop*. 2011, IEEE: Paris. p. 127 - 130.
18. B.Subanya, P.S. and R.R. Rajalaxmi, *Feature Selection using Artificial Bee Colony for Cardiovascular Disease Classification*, in *International Conference*

- on *Electronics and Communication System (ICECS -2014)*. 2014, IEEE: Coimbatore. p. 1-6.
19. Uzer, M.S., N. Yilmaz, and O. Inan, *Feature Selection Method Based on Artificial Bee Colony Algorithm and Support Vector Machines for Medical Datasets Classification*. The ScientificWorld Journal, 2013.
 20. M.Y., S., R. Abdullah, and İ. Venkat, *ABC Algorithm as Feature Selection for Biomarker Discovery in Mass Spectrometry Analysis*, in *4th Conference on Data Mining and Optimization (DMO)*. 2012, IEEE: Langkawi, Malaysia. p. 67-72.
 21. Schiezero, M. and H. Pedrini, *Data feature selection based on Artificial Bee Colony algorithm*. Schiezero and Pedrini EURASIP Journal on Image and Video Processing, 2013. **47**.
 22. Ozkaya, N. and N. Kurat, *Discriminative common vector based finger knuckle recognition*. Journal of Visual Communication and Image Representation, 2014. **25**(7): p. 1647-1675.
 23. Wen, Y., *An improved discriminative common vectors and support vector machine based face recognition approach*. Expert Systems with Applications, 2012. **39**(4): p. 4628-4632.
 24. Liu, J., S. Chen, and X. Tan, *A study on three linear discriminant analysis based methods in small sample size problem*. Pattern Recognition, 2008. **41**(1): p. 102-116.
 25. Jing, X.-Y., et al., *A novel face recognition approach based on kernel discriminative common vectors (KDCV) feature extraction and RBF neural network*. Neurocomputing, 2008. **71**(13-15): p. 3044-3048.
 26. Jing, X.-Y., et al., *Face and palmprint pixel level fusion and Kernel DCV-RBF classifier for small sample biometric recognition*. Pattern Recognition, 2007. **40**(11): p. 3209-3224.
 27. Gülmezoğlu, M.B., et al., *The common vector approach and its comparison with other subspace methods in case of sufficient data*. Computer Speech & Language, 2007. **21**(2): p. 266-281.
 28. Lakshmi, C., M. Sundararajan, and P. Manikandan, *Hierarchical Approach of Discriminative Common Vectors for Bio Metric Security*, in *Computer and Automation Engineering (ICCAE), 2010 The 2nd International Conference*. 2010, IEEE: Singapore. p. 784 - 790.
 29. Koc, M.B., Atalay, *Ortak Vektör ve Ayırt Edici Ortak Vektör Yaklaşımları ile Öznitelik Seçimi Yöntemi*, in *2011 IEEE 19th Signal Processing and Communications Applications Conference (SIU 2011)*. 2011.
 30. Koc, M. and A. Barkana, *Discriminative common vector approach based feature selection in face recognition*. Computers & Electrical Engineering, 2014. **40**(8): p. 37-50.
 31. Karaboga, D., *Yapay Zeka Optimizasyon Algoritmaları*. Vol. 2. 2011: Nobel Yayın Dağıtım. 205.
 32. Akay, B. and D. Karaboga, *A modified Artificial Bee Colony algorithm for real-parameter optimization*. Information Sciences, 2012. **192**: p. 120-142.
 33. Karaboga, D., *An Idea Based On Honey Bee Swarm for Numerical Optimization*. 2005, Engineering Faculty: Kayseri.
 34. Goldberg, D.E., *Genetic Algorithms in Search, Optimization and Machine Learning*. 1989: Addison-Wesley Longman Publishing Co., Inc. 372.
 35. Yang, X., *Genetic Algorithms*, in *Nature-Inspired Optimization Algorithms*, X.-S. Yang, Editor. 2004.

36. Melanie, M., *An Introduction to Genetic Algorithms*. Vol. 5. 1999, Cambridge, Massachusetts • London, England: A Bradford Book The MIT Press.
37. Fix, E. and J. Hodges, *Discriminatory analysis, nonparametric discrimination: Consistency properties*. USAF School of Aviation Medicine, 1951.
38. Martinez A, B.R., *The AR face database*. 1999, CVC technical report 24.
39. <http://www.cl.cam.ac.uk/research/dtg/attarchive/face/database.html>. 1994
40. Behaine, C.A.R. and J. Scharcanski, *Enhancing the Performance of Active Shape Models in Face Recognition Applications*. Instrumentation and Measurement, IEEE Transactions, 2012. **61**(8): p. 2330 - 2333.

ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı, Soyadı: Derya ALTINTOP

Uyruğu: Türkiye (TC)

Doğum Tarihi ve Yeri: 20 Temmuz 1988, Kayseri

Medeni Durumu: Evli

Tel: +90 536 924 30 39

E-Posta: derya_demirtas@yahoo.com

Yazışma Adresi: Yıldızevler Mah. 738 Sok. No: 3E/15 Çankaya/Ankara

EĞİTİM

Derece	Kurum	Mezuniyet Tarihi
Lisans	ERÜ Bilgisayar Mühendisliği	2012
Lise	Kayseri Sema Yazar Anadolu Lisesi	2006

İŞ DENEYİMLERİ

Yıl	Kurum	Görev
2014- Halen	PTT A.Ş. Genel Müdürlüğü	Bilgisayar Mühendisi
2012-2014	T.C. Sağlık Bakanlığı Türkiye Kamu Hastaneleri Kurumu	Yazılım Uzmanı

YABANCI DİL

İngilizce