



## GÜRBÜZ YÜZ TANIMA İÇİN ÇOK-KİPLİ ÖZİNİTELİK FÜZYONU

Cihan TOPAL<sup>1\*</sup>, Cevdet CIVIR<sup>2</sup>

<sup>1</sup> Eskişehir Teknik Üniversitesi Üniversitesi, Mühendislik Fakültesi, Elektrik Elektronik Mühendisliği Bölümü, Eskişehir, Türkiye

<sup>2</sup> Visea İnovatif Bilgi Teknolojileri, Eskişehir, Türkiye

Anahtar Kelimeler	Öz
<i>Yüz Tanıma, Öznelik Çıkartma, Öznelik Birleştirme, Spektral Öznelikler, Uzamsal Öznelikler.</i>	Yüz tanıma çok sayıda uygulama alanı olan popüler bir bilgisayarla görü problemidir. Farklı ışık koşulları ve değişen yüz ifadeleri yüz tanıma problemi zorlaştıran etkenlerdir. Yüz tanıma işlemi için çeşitli yöntemlerle elde edilen öznelikler yüze ait farklı karakteristik özellikleri yansıtır. Bu karakteristik özelliklerden faydalanılarak yüz tanıma işlemi gerçekleştirilir. Bu çalışmada, örüntü ve doku tanıma sıklıkla kullanılan Yerel İkili Örüntü ve Felzenszwalb Yönelimli Gradyan Histogram özneliklerinin birleştirilmesi ile yüz tanıma problemine çok kipli bir çözüm sunulmuştur. Yüz imgesi bölgelere ayrılarak, her iki yöntem ile bölgelerden öznelik vektörleri elde edilmiştir. Bununla birlikte elde edilen vektörlere öznelik seçim yöntemleri uygulanarak hem vektör boyutu azaltılmış hem de başarımlar artırılmıştır. Öznelik seçimi sonucu her iki yöntem için seçilen öznelik alt kümeleri birleştirilerek uzamsal ve spektral öznelikleri içeren tek bir öznelik vektörü haline getirilmiştir. Seçilen öznelikler Ki-kare sınıflandırıcısı kullanılarak sınıflandırılmıştır. Önerilen yöntemin başarımlarını FERET veri setinde ölçülmüş, %89.45 yüz doğrulama ve %94.55 yüz tanıma başarımlarını elde edilmiştir.

## FUSION OF SELECTED MULTI-MODAL FEATURES FOR ACCURATE FACE RECOGNITION

Keywords	Abstract
<i>Face Recognition, Feature Extraction, Feature Fusion, Spectral Features, Spatial Features.</i>	Face recognition is a popular computer vision problem with many areas of application. Different lighting conditions and changing facial expressions are factors that make the face recognition problem difficult. The features extracted by different methods from the face image reflect the different characteristics of the face image. Face recognition process is applied by using these features. In this study, a multi-modal solution to the face recognition problem is presented by fusing the Local Binary Pattern and Felzenszwalb Histogram of Oriented Gradients features, which are frequently used in pattern and texture recognition. Face image is divided into regions and feature vectors are obtained from the regions through both methods. However, by applying feature selection methods to the obtained vectors, both the vector size is reduced and the performance is increased. As a result of the feature selection, the feature subsets selected for both methods are combined into a single feature vector containing spatial and spectral features. Selected features are classified using the Chi-square classifier. The success of the proposed method was measured in the FERET dataset, 89.45% verification success and 94.55% identification success were obtained.

### Alıntı / Cite

Topal, C., Cıvır, C., (2021). Türkçe Makaleler İçin Türkçe Başlık Olmalı ve Kelimelerin İlk Harfi Büyük Olmalıdır, Mühendislik Bilimleri ve Tasarım Dergisi, 9(1), 301-311.

### Yazar Kimliği / Author ID (ORCID Number)

C. Topal, 0000-0002-6329-5251  
C. Cıvır, 0000-0003-4607-0170

### Makale Süreci / Article Process

<b>Başvuru Tarihi / Submission Date</b>	10.10.2020
<b>Revizyon Tarihi / Revision Date</b>	09.02.2021
<b>Kabul Tarihi / Accepted Date</b>	21.02.2021
<b>Yayın Tarihi / Published Date</b>	30.03.2021

\* İlgili yazar / Corresponding author: cihant@eskisehir.edu.tr, +90-222-321-3550

## 1. Giriş (Introduction)

Sosyal ilişkilerde ilk izlenimin oluşmasında odak bölge olan yüz, kimlik ve duygu durumu hakkında önemli bilgiler taşımaktadır. İnsanlar bu bilgilerden faydalanarak, kişinin yaşı, ifadesi, gözlük kullanması vb. değişen koşullara rağmen yüz tanıma konusunda oldukça başarılıdır. İnsanların tanımakta bu denli başarılı oldukları yüzlerin görsel olarak işlenmesi uzun yıllar boyunca üzerine çalışmaların yapıldığı bir araştırma konusu olmuştur.

Yüz, üzerinde biyometrik bilgiler barındırmakla birlikte kişiden kişiye değişen yapısıyla da öznelik oluşturmaktadır. Yüzün sahip olduğu biyometrik bilgilerden faydalanılarak yüz tanıma, yüz ifadesi tanıma, yapay yüz örneklerinin oluşturulması vb. çalışmalar gerçekleştirilmektedir (Topal ve Erdem, 2018; Topal ve Gacav, 2017; Topal ve Özbey, 2018; Gacav ve Benligiray, 2016; Yavuz vd., 2016). Yapılan araştırmalar yüzün güvenilirliği yüksek etkin bir biyometrik belirleyici olduğunu göstermektedir. Bankalar, havaalanları, pasaport kontrol noktaları, gümrük kapıları, karakollar, mobese ve güvenlik sistemleri vb. mekanlarda biyometrik güvenlik yöntemlerine başvurulmaktadır. Geçtiğimiz yıllarda bu kurumlarda iris tanıma, parmak izi tanıma gibi teknolojiler birincil biyometrik güvenlik yöntemleri iken, günümüzde yüz tanıma daha sıklıkla başvuru alan biyometrik güvenlik yöntemi haline gelmiştir.

Yüz tanıma probleminin çözümünde temel olarak mevcut yüz imgelerinden öznelik vektörleri elde edilir. Elde edilen öznelik vektörlerinin, karşılaştırılacak olan yüze ait öznelik vektörüne olan uzaklığı hesaplanarak tanıma işlemi gerçekleştirilir. Faydalı öznelik vektörlerinin elde edilmesi yüz tanıma için büyük önem taşımaktadır. Öznelik vektörleri elde edilirken kullanılan yöntemlere HOG (histogram of gradient - yönelimli gradyan histogramları), LBP (local binary pattern - yerel ikili örüntü) gibi yöntemler örnek olarak verilebilir (Dalal ve Triggs, 2005; Ojala vd., 1996).

Önerilen yöntemde spektral ve uzamsal iki farklı öznelik olan LBP ve FHOG (Felzenszwalb histogram of gradient - Felzenszwalb yönelimli gradyan histogram) kullanılarak yüz tanıma problemine çok kipli bir çözüm sunulmuştur. Elde edilen öznelik vektör boyutunun azaltılması ve faydalı özneliklerin problemin çözümünde kullanılması amacıyla öznelik seçimi yapılmıştır. LBP öznelikleri için ardışık ileri öznelik seçimi, FHOG öznelikleri için ise en iyi bağımsız öznelik seçimi ile öznelik seçimi gerçekleştirilmiştir. LBP ve FHOG için seçilen öznelik altkümeleri birleştirilerek tek bir vektör haline getirilmiştir.

Bu çalışmanın ikinci bölümünde konu ile ilgili kaynak araştırması yapılmış, üçüncü bölümde spektral ve uzamsal farklı iki öznelik olan FHOG ve LBP algoritmalarıyla çıkarılan öznelik vektörlerinin birleştirilmesi anlatılmıştır. Dördüncü bölümde yapılan deneyler hakkında ayrıntılı bilgiler verilmiştir. Beşinci bölümde ise sonuçlar yorumlanmış ve çıkarımlar yapılmıştır.

## 2. Kaynak Araştırması (Literature Survey)

Nesne ve örüntü tanıma uygulamalarında yüksek başarımla elde edilen HOG algoritması sıklıkla kullanılan bir yöntemdir. HOG öznelikleri ilk kez Dalal ve Triggs'in yaya tespiti problemine çözüm olarak önerilmiştir. Bu öznelikler imgelerin bölgelere bölünmesi sonrasında her bölgedeki piksel için gradyan hesabı yapılarak elde edilir. Bir başka öznelik vektörü elde etme yöntemi olan LBP ilk olarak Ojala vd. tarafından 1996 yılında önerilmiştir. Başlangıçta doku tanıma amacıyla geliştirilen LBP daha sonra yüz imgeleri üzerinde de denenmiştir. LBP komşu piksellerin birbirleri ile karşılaştırılması sonucu oluşturulan görünüm tabanlı bir özneliktir.

Holat vd. yaptıkları çalışmada PCA (principal component analysis - temel bileşen analizi), LDA (linear discriminant analysis - doğrusal ayraç analizi) ve LBP kullanarak Yale veri seti üzerinde yüz tanıma uygulaması yapmışlardır (Holat vd., 2014). Görüntünün poz ve ışık farklılıklarına göre sistemin en uygun yöntemi seçmesi için imge üzerinde çeşitli histogram eşitleme yöntemleri ve filtre uygulamaları gerçekleştirilmiştir.

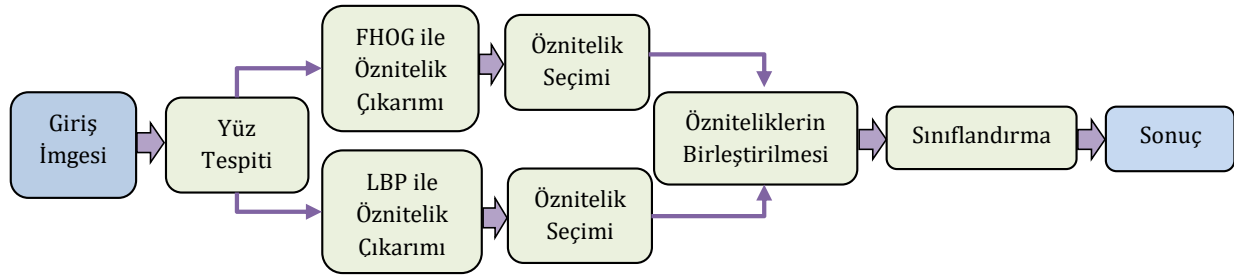
Memiş vd. yaptıkları çalışmada mobil ortamda elde edilen imgelerde görünüm tabanlı yöntemler kullanarak yüz tanıma çalışması gerçekleştirmişlerdir (Memiş vd., 2016). Mobil cihazın kamerasından çekilen görüntülerde Haar kaskat sınıflandırıcısını kullanarak yüz tespiti yaptıktan sonra tespit edilen yüzler üzerinde renk uzayı dönüşümü, boyutsal normalizasyon ve histogram eşleme işlemlerini yürütmüşlerdir. Yüzlere ait öznelikleri ise PCA, LDA ve LBP kullanarak elde etmişlerdir. Bu yöntemin başarımını ölçmek için K-en yakın komşu sınıflandırıcısını kullanarak sınıflandırma yapmışlardır.

Gusain vd. çalışmalarında bankaların güvenlik sistemleri için yüz tanıma, iris tarama ve avuç içi tarama yöntemlerini birleştirerek, çok aşamalı bir güvenlik yöntemi sunmuştur (Gusain vd., 2018). Yüz imgesini üst, orta ve alt seviye olarak 3 parçaya böldükten sonra veri tabanındaki imgeler ile karşılaştırarak erişim verilip verilemeyeceğini belirlemişlerdir.

Yüz tanıma işlemi için görünüm tabanlı yaklaşımların yanı sıra geometrik tabanlı yaklaşımlar da kullanılmaktadır. Huang vd. çalışmalarında geometrik tabanlı bir yaklaşım benimseyerek, LVP (local vector pattern – yerel vektör örüntüsü) kullanmışlardır (Huang vd., 2015). LVP bir girdi imgesi ile mevcut imgeler arasındaki uzaklığı hesaplayan bir yöntemdir. LVP ile elde edilen öznelik vektörleri yüz tanıma işleminde kullanmak üzere ağırlıklandırılmıştır.

Literatürde yapılan çalışmalarda farklı yöntemler ile öznelik vektörleri elde edilerek çeşitli veri setleri üzerinde başarımların ölçüldüğü çalışmaların mevcut olduğu görülmüştür. Derin öğrenme yöntemleri kullanılarak yüz tanımanın yapıldığı çalışmalara da sıklıkla rastlamak mümkündür (Yan vd., 2019; Taigman vd., 2014; Kowsari vd., 2018). Literatürde incelenen çalışmalar ile karşılaştırıldığında bu çalışma, problemin çözümü için geliştirilen spektral ve uzamsal iki farklı öznelik olan LBP ve FHOG özneliklerinin birleştirilmesi noktasında yenilikçi ve özgün olma özelliği taşımaktadır.

### 3. Materyal ve Yöntem (Material and Method)

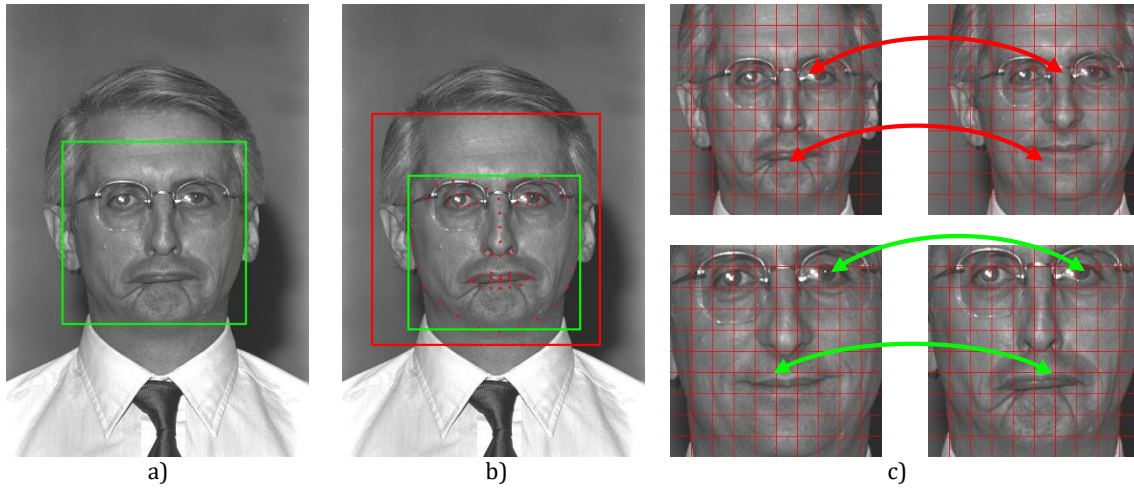


Şekil 1. Önerilen Yöntemin Akış Şeması (Flow Chart of The Proposed Method)

Yapmış olduğumuz bu çalışma için sırasıyla şu adımlar izlenmiştir: Veri setindeki ön yüzleri içeren imgeler üzerinde Haar kaskat sınıflandırıcısı kullanılarak yüz tespiti gerçekleştirilmiştir (Viola ve Jones, 2004). Haar kaskat sınıflandırıcısı çok ölçekli çalıştığı için tespit ettiği yüz bölgelerinin lokalizasyonu farklılık gösterebilmektedir. Bu nedenle tespit edilen yüzler üzerinde Kazami ve Sullivan'ın önerdiği yöntemin kullanılması ile nirengi noktaları tespit edilmiştir (Kazami ve Sullivan, 2014). Nirengi noktaları referans alınarak imgeler yüz sınır noktalarından kırılmıştır. Sonrasında imgeler aynı boyutta olacak şekilde yeniden boyutlandırılmıştır. Bu ön işlemlerden geçen imge eşit bölgelere ayrılmıştır. Ayrılan bölgelerin her imge için yüzün aynı bölgesine denk gelmesi amacıyla ön işlemler esnasında imgeler aynı boyuta getirilmiştir. Ayrılan bölgelerin her birinden uzamsal ve spektral iki farklı öznelik olan LBP ve FHOG öznelikleri elde edilmiştir. Elde edilen öznelik vektörlerinin boyutunun indirgenmesi amacıyla LBP için ardışık ileri öznelik seçimi uygulanırken FHOG için en iyi bağımsız öznelik seçimi ile öznelik seçimi gerçekleştirilmiştir. Öznelik seçimi sonucu elde edilen vektör alt kümeleri birleştirilerek uzamsal ve spektral olarak çok kipli bir öznelik vektörü elde edilmiştir. Şekil 1'de önerilen yöntemin akış şeması gösterilmiştir. Şekil 1'de gösterilen temel yapı alt bölümlerde ayrıntılı şekilde açıklanmıştır.

#### 3.1. Yüz Tespiti ve Hizalaması (Face Detection and Alignment)

İmgelerde yüzlerin bulunabilmesi için Haar kaskat sınıflandırıcısı kullanılmıştır. Haar kaskat, Paul Viola ve Micheal Jones tarafından 2001 yılında önerilen yüz tespit yöntemidir. Her insan yüzünün birbirine benzer özelliklerinden faydalanarak yüksek doğrulukta yüz tespiti yapmaktadır. Bir Haar özelliği, bir algılama penceresinde belirli bir konumdaki bitişik dikdörtgen bölgeleri dikkate alır. Her bölgedeki piksel yoğunluğunu toplar ve bu toplamlar arasındaki farkı hesaplar. Bir Haar özelliğine, yüzün göz bölgesinin burun kemerine göre daha koyu olması, örnek olarak verilebilir. Haar kaskat sınıflandırıcısı yüz tespiti yaparken yüz üzerinde farklı boyutlardaki çerçeveleri gezdirerek yüz aramaktadır. Bu sebeple Haar kaskat sınıflandırıcısı ile tespit edilen yüzlerin lokalizasyonu aynı olmamaktadır. Bu durum yüzlerin bulunduğu alandan çıkarılacak özneliklerde örtüşme sağlamadığı için performans düşüklüğüne sebep olmaktadır. Bu nedenle tespit edilen yüzler üzerinde Kazami ve Sullivan'ın önerdiği yöntem kullanılarak yüz üzerine 68 nokta yerleştirilmektedir. Yüzün sınır noktalarını ifade eden noktalar referans alınarak yüz imgesi kırılmıştır. Şekil 2'de gerçekleştirilen ön işlemler ve imgelerin aynı boyuta getirilmesinin önemini açıklayan görsel gösterilmiştir.

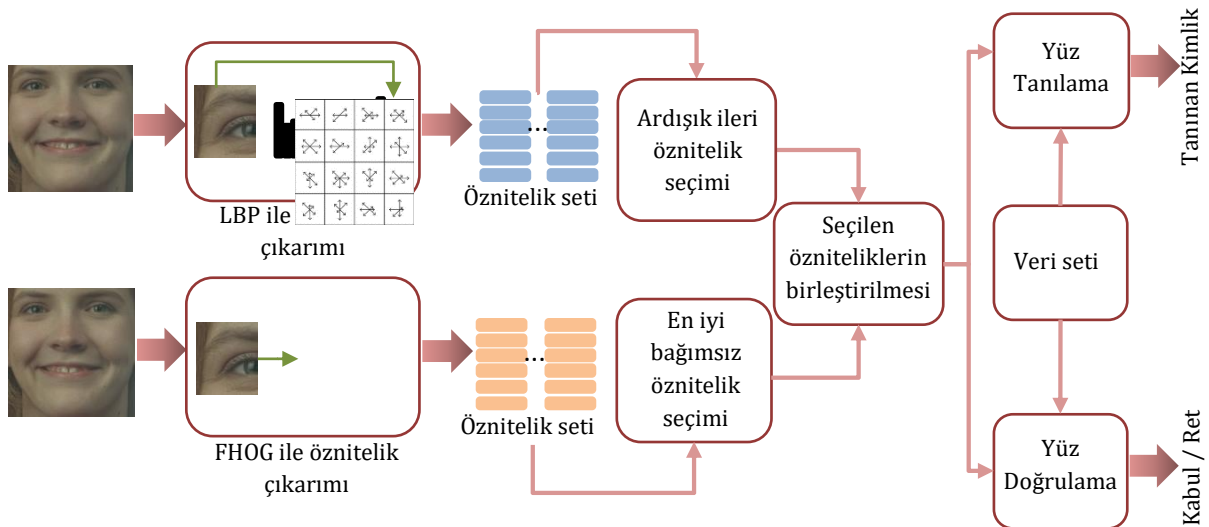


**Şekil 2.** Veri Seti Üzerinde Gerçekleştirilen Ön İşlemler; A) Haar Yüz Tespiti B) Nirengi Noktası Tespiti C) Hizalanarak Kırpılan Yüz İmgesi İle Hizalanmadan Kesilen Yüz İmgeleri (Preprocessing Steps in The Dataset; A) Haar Face Detection B) Landmark Detection C) Face Images Cropped Without Aligning With The Face Image Cropped By Alignment.)

### 3.2. FHOG Özniteliklerinin Elde Edilmesi (Extraction of FHOG Features)

HOG öznitelikleri görünüm tabanlı olup, girdi imgesi bölgelere bölündükten sonra bölgelerde bulunan her bir piksel için gradyan histogramı hesabının yapılmasıyla elde edilmektedir. Gradyan histogramında, girdi imgesindeki hücrelerin gradyan yönelimlerinin istatistikleri tutulur. HOG öznitelikleri  $36 \times 1$  boyutunda olmakla birlikte ışık koşulları ve diğer olumsuz şartlara karşı gürbüz olma özelliği taşımaktadır. HOG öznitelikleri ilk kez yaya tespit problemine uygulanmıştır (Dalal ve Triggs, 2005).

FHOG (Felzenszwalb vd., 2010), HOG'a kıyasla boyut olarak daha küçük öznitelik vektörü üretir. HOG'ta  $36 \times 1$  boyutunda olan vektör, FHOG'da  $31 \times 1$  boyutundadır.  $36 \times 1$  vektör boyutundaki HOG sadece kontrast duyarlı öznitelikleri içerirken,  $31 \times 1$  vektör boyutuna sahip olan FHOG kontrast duyarlı, kontrast duyarlı olmayan ve gradyan enerjisini yakalayan bilgiler içermektedir. Bu sebeple hem hız olarak hem de performans olarak HOG'a göre daha yüksek başarımlar sağladığı için, HOG yerine FHOG tercih edilmiştir. FHOG özniteliklerinden faydalanılarak yapılan çeşitli çalışmalar bulunmaktadır. Bunlardan yüz ile ilgili olan daha önce yapmış olduğumuz çalışmada FHOG öznitelikleri kullanarak yüz ifade tespit yöntemi geliştirilmiştir (Topal vd., 2018). Şekil 3'de öznitelik çıkarımı ve seçimini ifade eden görsele yer verilmiştir.




**Şekil 3.** Öznitelik Çıkarımı ve Seçimi (Flow Chart of The Proposed Method)

### 3.3. LBP Özniteliklerinin Elde Edilmesi (Extraction of LBP Features)

LBP ilk olarak 1996 yılında doku tanıma amacıyla geliştirilmiştir. Bu algoritma ilerleyen yıllarda yüz tespiti, yüz tanıma vb. uygulamalar için de kullanılmaya başlanmıştır. LBP bir merkez pikselin belirli bir yarıçaptaki komşu piksel değerleri ile karşılaştırılmasıyla ikili değerler oluşturur. LBP operatörü bir imgedeki her piksel için,

kendisini çevreleyen 3×3'lük komşu piksellerini merkez piksel değerine göre karşılaştırarak etiketler. Eğer merkez pikselin değeri komşu piksel değerinden büyük veya eşit ise 0, küçük ise 1 değerini alır. Bu sayede 3×3'lük bir komşuluk bölgesi için 8 bitlik LBP kodu oluşturulmuş olur. Oluşturulan ikili kodun onluk sistemdeki değeri, merkez pikseli içeren 3×3'lük bölgedeki yerel yapıyı ifade eder. Şekil 4.'de LBP operatörünün uygulanışı gösterilmiştir.



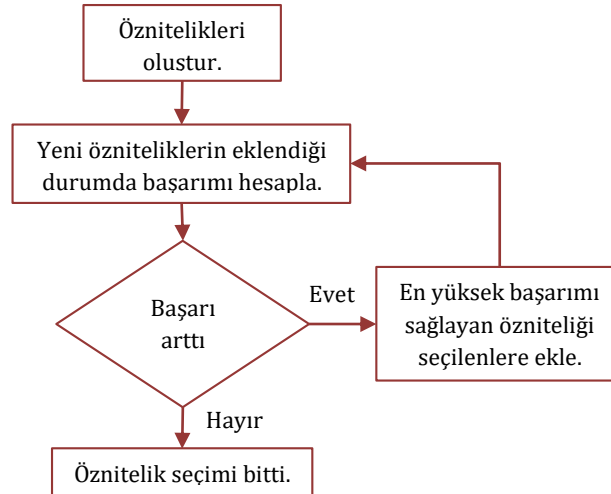
Şekil 4. LBP Operatörünün Uygulanışı (Implementing the LBP Operator) (Calculation of LBP)

R yarıçapına sahip bir komşuluk üzerinde varolan P adet komşu pikselin LBP kodu Eşitlik (1) ile hesaplanmaktadır. Kullanılan matematiksel eşitlikte  $g_c$ ; merkez pikselin gri-seviye değerini,  $g_p$  ise komşu piksellerin gri-seviye değerlerini ifade etmektedir. Deneysel çalışmalarda (P, R) değeri (8, 1) olarak kullanılmıştır.


$$LBP_{P,R} = \sum_{p=0}^{p-1} s(g_p - g_c)2^p, \quad s(x) = \begin{cases} 1, & x \geq 0 \\ 0, & x < 0 \end{cases} \quad (1)$$

### 3.4. Öznitelik Seçimi (Feature Selection)

Öznitelik seçimi, veri boyutunu azaltmak için yaygın olarak kullanılmaktadır. Bununla birlikte veri azaltma hız, doğruluk ve basitlik açısından sınıflandırma performansını ve örüntü tanıma sistemlerini geliştirir. Yerel aramadaki öznitelik sayısını azaltmak için kullanılan bir strateji sıralı arama algoritmalarıdır. Ardışık ileri öznitelik seçimi boş bir kümeden başlayarak öznitelik vektörlerinin teker teker eklenerek, minimum hata oranı veren öznitelikliğin, öznitelik kümesine eklenmesiyle devam eder. Belli bir iterasyondan sonra öznitelik kümesinde bulunan özniteliklerden hiç biri hata oranını etkilemiyor ise öznitelik seçimi sonlandırılır. Ardışık ileri öznitelik seçimi basitlik ve hız olarak sağladığı avantajdan dolayı yaygın olarak kullanılır. Ardışık ileri öznitelik seçimi için daha ayrıntılı bilginin bulunduğu çalışmalar literatürde mevcuttur (Last vd., 2001; Nakariyakul vd., 2009; Schenk vd., 2009). Şekil 5'de ardışık ileri öznitelik seçiminin şeması gösterilmiştir.



Şekil 5. Ardışık İleri Öznitelik Seçimi Şeması (Sequential Forward Selection Flow Diagram)



**Şekil 6.** FHOG ve LBP için Öznitelik Seçim Algoritması İle Seçilen Özniteliklerden Elde Edilen Doğruluk Değerleri (Accuracy Values Obtained From The Features Selected With The Feature Selection Algorithm for FHOG and LBP)

Gerçekleştirilen çalışmada bölgelere ayrılan yüz imgesi üzerinde LBP ve FHOG algoritmaları kullanılarak öznitelik vektörleri elde edilmiştir. Elde edilen LBP öznitelik vektörü her bir bölge için 256 boyutlu iken FHOG öznitelik vektörü 31 boyutludur. LBP öznitelik vektörünün yüz tanıma için faydalı olan öznitelik alt kümesinin bulunması için ardışık ileri öznitelik seçimi uygulanmıştır. FHOG öznitelik vektörünün, yüz tanıma için faydalı olan alt kümesi ise her bölgenin başarımı ölçüldükten sonra büyükten küçüğe sıralanmış özniteliklerin art arda eklenmesi ile bulunmuştur. Belli bir iterasyondan sonra LBP ve FHOG için doğruluk oranının artmadığı Şekil 6'da gösterilmiştir. Bu nedenle doğruluk oranının kayda değer bir değişim göstermediği anda öznitelik seçimi durdurulmuştur.

### 3.5. Özniteliklerin Birleştirilmesi (Feature Fusion)

Özniteliklerin birleştirilmesi örüntü tanıma problemlerinin çözümünde kullanılan popüler bir yöntemdir. Farklı özniteliklerin birleştirilmesi ile her birinin avantajlarından faydalanılarak probleme daha gürbüz ve doğru çözümler üretilmesine olanak sağlar. Aynı örüntü üzerinden elde edilen farklı öznitelik vektörleri daima örüntünün çeşitli karakteristik özelliklerini yansıtır. Bu sebeple veri setindeki imgelerden elde edilen FHOG ve LBP öznitelikleri öznitelik seçim aşamasından sonra uç uca eklenerek tek bir vektör haline getirilmektedir. Bu sayede uzamsal ve spektral özniteliklerin birleştirilmesi ile çok kipli öznitelik vektörü elde edilmiştir.

### 3.6. Kullanılan Sınıflandırma Yöntemleri (Employed Classification Methods)

#### 3.6.1. Ki-Kare Testi (Chi-Square Test)

Veri setindeki imgelerden elde edilen FHOG ve LBP histogramları karşılaştırma işleminde kullanılmıştır. Histogramların karşılaştırılması için Ki-kare metriği kullanılmıştır. Eşitlik (2)'de gösterilen formül kullanılarak Ki-kare metriği ile uzaklık hesaplanır.

$$d_{\chi^2}(S, T) = \sum_{i=1}^N \frac{(s_i - t_i)^2}{s_i + t_i} \quad (2)$$

Formülde karşılaştırılacak olan iki histogramı  $S$  ve  $T$  ifade etmektedir.  $N$ , histogramlardaki toplam eleman sayısını,  $s_i$  ve  $t_i$  ise  $S$  ve  $T$ 'nin  $i$ . Histogram elemanını göstermektedir.

#### 3.6.2 Öklid Uzaklık Metriği (Euclidean Distance Metric)

Veri setindeki imgelerden elde edilen FHOG ve LBP histogramlarının karşılaştırılması için Öklid uzaklık metriği kullanılmıştır. Ki-Kare Testi ve Öklid uzaklık metriği kullanılarak yapılan karşılaştırma işlemlerinde farklı metriklerin başarıma etkileri de irdelenmiştir. Eşitlik (3)'de gösterilen formül kullanılarak Öklid uzaklığı hesaplanmaktadır.

$$d(p, q) = \sqrt{\sum_{i=1}^n (p_i - q_i)^2} \quad (3)$$



Şekil 7. FERET Veri Kümesinden Örnek İmgeler (Sample Images From FERET Dataset)

#### 4. Deneysel Sonuçlar (Experimental Results)

Bu bölümde, önerilen yöntemin etkinliğini göstermek ve önceki bölümlerde ifade edilen anlatımları doğrulamak amacıyla, yüz tanıma için halka açık bir veri seti üzerinde yapılan deneyler sunulmuştur. Çalışmada deneyler The Facial Recognition Technology (FERET) veri setinde gerçekleştirilmiştir (Phillips vd., 1997). 512×768 çözünürlüğünde imgelerden oluşan veri setinin içinde yaş, etnik ve cinsiyet özellikleri bakımından farklı gruplar yer almaktadır. Bununla birlikte kişilerin nötral ve ifadeli yüzleri de veri kümesi içinde yer almaktadır. FERET veri kümesine ait örnek görüntüler ise Şekil 7'de verilmiştir.


Önerilen yöntem ile farklı karakteristik özelliklere sahip olan iki öznitelik vektörü birleştirilmiştir. Bu sayede yüz tanıma probleminin çözümünde doğruluk oranı yüksek sonuçlar elde edilmiştir. FERET veri kümesi 1233 ifadeli ve 1229 ifadesiz yüz içeren imgelerden oluşmaktadır. Veri kümesindeki ifadesiz yüzler eğitim işlemi için kullanılırken, ifadeli yüzler ile test işlemi gerçekleştirilmiştir. Veri setinde bulunan ön yüz imgeleri 320×320 boyutunda yeniden boyutlandırılmıştır. Bu işlemin asıl sebebi yüz imgesi bölgelere ayrıldığında her bölgenin bir diğer imgede yüzün aynı bölgesine işaret etmesidir. Yeniden boyutlandırılan imge 32×32 boyutunda 100 bölgeye ayrılmıştır. Ayrılan 100 bölgeden her birinden 256×1 boyutlu LBP ve 31×1 boyutlu FHOG öznitelik vektörü elde edilmiştir. Öznitelik çıkarımında imgelerin 10×10'luk bloklara bölünmesinin sebebi bir yüze ait farklı detayların yeterince yüksek çözünürlükte elde edilmesinin sağlanmasıdır. Daha büyük bloklar seçildiğinde yüzün farklı bölgeleri (örn. göz, kaş, alın, vb.) aynı blok içine dahil edilmiş olacağından, yüzün hangi kısmının yüz tanımaya daha iyi etki sağladığının anlaşılması mümkün olmayacaktır. Daha yoğun bloklar kullanılmasıyla yüz bölgeleri birden fazla blokla temsil edilecek ve tanımaya katkı sağlaması durumunda öznitelik seçimi yöntemi bu blokların birkaçını ya da tamamını seçerek eniyileme yapacaktır.

Ayrılan bölgelerin başarımının ölçülmesi ile hangi yüz bölgelerinin yüz tanıma probleminin çözümünde faydalı olduğu gözlemlenmiştir. FERET veri seti örnek sayısı eşit iki alt gruba ayrılmıştır. İlk alt grup eğitim seti olarak adlandırılmış olup, veri setindeki nötral yüzlerden oluşmaktadır. İkinci alt grup ise test seti olarak adlandırılmış olup, veri setindeki ifadeli yüzlerden oluşmaktadır. Eğitim setindeki her imge 32×32 boyutunda olan 100 bölgeye sahiptir. Eğitim setindeki bir imgeye ait 100 bölgeden ilki, test setindeki tüm imgelerin ilk bölgesi ile karşılaştırılmıştır. Karşılaştırma işlemi bölgelerden elde edilen LBP ve FHOG öznitelikleri ayrı ayrı kullanılarak gerçekleştirilmiştir. Karşılaştırma sonucunda eşleşme doğru ise gerçek pozitif (true positive) değeri artırılmış, eğer yanlış ise yanlış pozitif (false positive) değeri artırılmıştır. Bu işlem her bölge için tek tek gerçekleştirilmiştir. Başarımın ölçülmesinde kullanılan formül Eşitlik (4)'de gösterilmektedir. LBP ve FHOG öznitelikleri için her bölgenin başarı grafiği ise Şekil 8'de gösterilmiştir. Eşitlik (4)'de GP; gerçek pozitif değerini, YP ise yanlış pozitif değerini ifade etmektedir.

$$\text{Doğruluk (\%)} = \frac{GP}{GP + YP} * 100 \quad (4)$$

Bölgelerin başarımı ölçüldükten sonra bölgeler başarım değerlerine göre büyükten küçüğe sıralanmıştır. FHOG öznitelikleri kullanılarak elde edilen başarım değerleri için, en yüksek başarımdan en düşük başarıma doğru her iterasyonda bir bölge eklenerek tekrar başarım ölçülmüştür. Belli bir iterasyondan sonra yeni bölge eklendiğinde başarımın artmadığı gözlemlenmiştir. Bu noktada öznitelik seçimi sonlandırılmıştır. FHOG için 21 bölge seçilmiştir. Her bölgeden elde edilen 31×1 boyutundaki FHOG vektörü, 21 bölge için 651 boyutlu bir öznitelik vektörü haline almıştır. LBP özniteliklerinin seçimi için ardışık ileri öznitelik seçimi kullanılmıştır. Belli bir iterasyondan sonra başarımın artmadığı gözlemlenmiştir. Bu noktada öznitelik seçimi sonlandırılmıştır. LBP için 28 bölge seçilmiştir. Sonuç öznitelik vektörünün uzamsal ve spektral özniteliklerden dengeli miktarlarda oluşması hedeflenmiştir. LBP öznitelikleri boyut olarak büyük olduklarından en faydalı grubu bulmak daha büyük öneme sahiptir. Bu nedenle farklı birçok kombinasyonun denendiği ardışık ileri öznitelik seçim (AİÖS) yöntemi uygulanmıştır. FHOG öznitelik vektörlerinin boyutları ise daha küçük olduğundan daha çok sayıda öznitelik seçimini mümkün kılan en iyi bağımsız öznitelik seçimi (EİBÖS) yöntemi kullanılmıştır. Sonuç olarak 7819 boyutlu

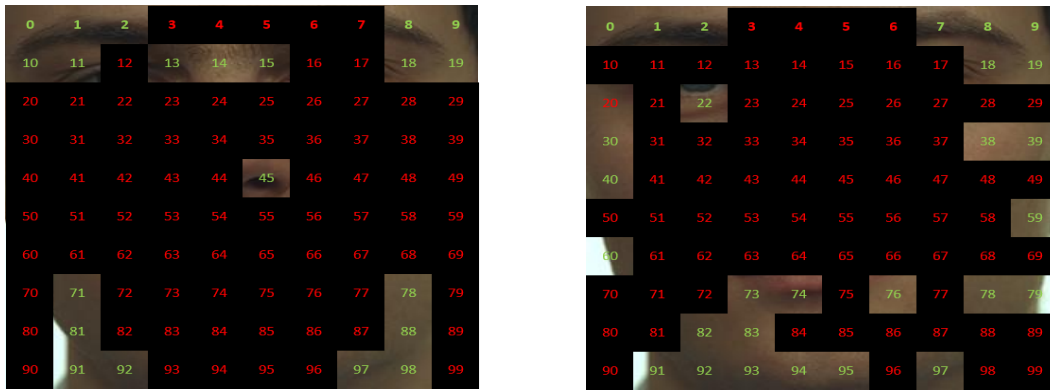
nihai öznitelik vektörünün 7168 boyutu LBP ve 651 boyutu FHOG vektörlerinden oluşmuştur. Veri kümesindeki bir imge üzerinde seçilen bölge aydınlatılmış görüntüsü Şekil 9'da verilmiştir.



Şekil 8. Bölümlerin Elde Edilen Başarımları; Soldaki FHOG, Sağdaki LBP (Accuracy Of Each Area. Left; FHOG. Right; LBP)

Öznitelik seçimi tamamlandıktan sonra FHOG öznitelik vektörünün sonuna LBP öznitelik vektörü eklenerek tek bir öznitelik vektörü elde edilmiştir. FERET veri setindeki ilk imge veri setindeki diğer tüm imgeler ile Ki-kare sınıflandırma yöntemi kullanılarak karşılaştırılmıştır. Bunun sonucunda elde edilen uzaklık değeri belli bir eşik noktasının altında ise eşleşme sağlanır. Eğer eşleşme doğru ise gerçek pozitif (GP), eşleşme yanlış ise yanlış pozitif (YP) değeri artırılmaktadır. Eşleşmenin olmaması gereken kişi ile eşleşme gerçekleşmemiş ise gerçek negatif (GN) değeri artırılırken, eşleşmenin olması gerekirken eşleşme başarılı olamamış ise yanlış negatif (YN) değeri artırılmıştır. Bu değerlere bağlı kalınarak Eşitlik (5)'deki formül ile başarımlar hesaplanmıştır. Tablo 1'de yöntemlerin başarımları gösterilmiştir.

$$\text{Doğruluk}(\%) = \frac{GP + GN}{GP + GN + YP + YN} \quad (5)$$



Şekil 9. Seçilen Bölümlerin Gösterilmesi; Soldaki FHOG, Sağdaki LBP (Showing Selected Area . Left; FHOG. Right; LBP)




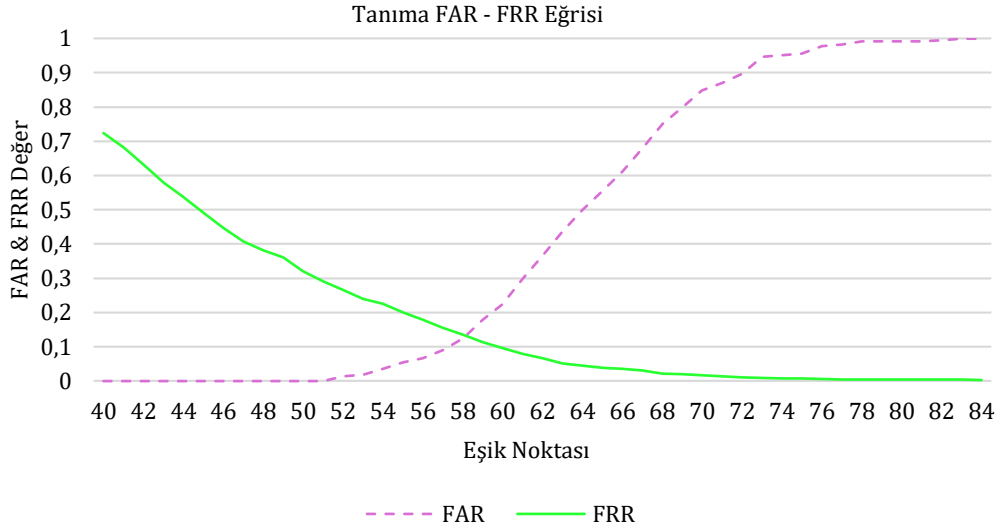
**Tablo 1.** Yöntem Başarımları (Methods Accuracy)

Yöntem	İmge Boyutu	Öznitelik Seçimi	Metrik	Vektör Boyutları	Doğruluk (%)
FHOG	280 × 280	Yok	Ki-Kare	3100	90.45
FHOG	280 × 280	Var	Ki-Kare	651	90.45
LBP	280 × 280	Yok	Ki-Kare	25600	89.18
LBP	280 × 280	Var	Ki-Kare	7168	93.51
LBP+FHOG	280 × 280	Yok	Ki-Kare	28700	90.38
LBP+FHOG	280 × 280	Var	Ki-Kare	7819	94.25
FHOG	280 × 280	Yok	Öklid	3100	89.70
FHOG	280 × 280	Var	Öklid	651	90.00
LBP	280 × 280	Yok	Öklid	25600	87.39
LBP	280 × 280	Var	Öklid	7168	90.60
LBP+FHOG	280 × 280	Yok	Öklid	28700	88.81
LBP+FHOG	280 × 280	Var	Öklid	7819	94.18
FHOG	320 × 320	Yok	Ki-Kare	3100	90.52
FHOG	320 × 320	Var	Ki-Kare	651	90.75
LBP	320 × 320	Yok	Ki-Kare	25600	89.38
LBP	320 × 320	Var	Ki-Kare	7168	94.10
LBP+FHOG	320 × 320	Yok	Ki-Kare	28700	90.60
<b>LBP+FHOG</b>	<b>320 × 320</b>	<b>Var</b>	<b>Ki-Kare</b>	<b>7819</b>	<b>94.55</b>
FHOG	320 × 320	Yok	Öklid	3100	89.56
FHOG	320 × 320	Var	Öklid	651	90.30
LBP	320 × 320	Yok	Öklid	25600	87.69
LBP	320 × 320	Var	Öklid	7168	91.64
LBP+FHOG	320 × 320	Yok	Öklid	28700	88.81
LBP+FHOG	320 × 320	Var	Öklid	7819	94.25

\*LBP için Ardışık İleri Öznitelik Seçimi, FHOG için En İyi Bağımsız Öznitelik Seçim yöntemi uygulanmıştır.

İki yüz imgesinin yakınlığının incelenmesi sonucu elde edilen uzaklık değerinin eşik noktası ile büyüklük ilişkisine göre eşleşme gerçekleşir. Değişen eşik noktalarında yöntemin başarımları da değişmektedir. Yüz tanıma sistemlerinde sistemin uygulama alanına göre eşleşmede yanlış kabul ve yanlış red ihtimali en aza indirmek istenebilmektedir. Doğrulama için yanlış kabul oranını (False Acceptance Rate - FAR) ifade eden ve yanlış ret oranını (False Rejection Rate - FRR) ifade eden eğri Şekil 9'da verilmiştir. FAR ve FRR değerlerinin eşit olduğu nokta ise eşit hata oranı (Equal Error Rate, EER) olarak adlandırılmaktadır. EER noktası da Şekil 10'da gösterilmiştir. Tanıma için farklı eşik noktalarında elde edilen FAR ve FRR değerlerini ifade eden eğriler Şekil 11'de gösterilmiştir. Uygulama alanına göre istenilen FAR ve FRR değerleri için eşik noktası seçimi bu eğriler referans alınarak seçilebilmektedir.

**Şekil 10.** Doğrulama İçin FAR & FRR Eğrisi (FAR & FRR Curve For Verification)



**Şekil 11.** Tanıma için FAR & FRR Eğrisi (FAR & FRR Curve for Identification)

Öznitelik seçimi uygulanarak, önerilen yöntem ile elde edilen öznitelik vektörünün boyutu azalmıştır. Vektör boyutunun bu yöndeki değişimi işlem süresinin azalmasına katkı sağlamıştır. Önerilen yöntemin işlem süresine olan etkisinin irdelenmesi için yöntemlerin öznitelik çıkarım süreleri ölçülmüştür. Bununla birlikte FHOG, LBP ve önerilen yöntemin sınıflandırma süreleri irdelenerek karşılaştırılmıştır. Deneyler 3.60 GHz Intel Core i7-7700 CPU donanımında gerçekleştirilmiştir. İşlem sürelerinin karşılaştırılması Tablo 2’de gösterilmiştir.

**Tablo 2.** İşlem Sürelerinin Karşılaştırılması (Comparison of Processing Times)

	FHOG (ms)		LBP (ms)		FHOG + LBP (ms)	
Öznitelik Çıkarımı	1.761		6.193		2.721	
Metrik (Ki-Kare Testi / Öklid Uzaklık)	0.011	0.005	0.112	0.083	0.036	0.016
Toplam Süre	1.772	1.766	6.305	6.276	2.757	2,737

## 5. Sonuç ve Tartışma (Result and Discussion)

Bu çalışmada literatürde birçok örüntü tanıma uygulamasında kullanılan LBP ve FHOG yöntemlerinin yüz tanıma problemindeki başarımının irdelenmesi amaçlanmıştır. Yöntemin sınıflandırma başarısını test etmek amacıyla FERET veri seti kullanılmıştır. Yapılan deneysel çalışmalarda yöntemin diğer yöntemlere göre başarımı irdelenmiştir. Bununla birlikte imgenin farklı karakteristik özelliklerini ortaya çıkaran öznitelik vektörlerinin birleştirilmesinin başarıma etkisi gözlemlenmiştir. Yöntemlerin birleştirilmesi ile LBP yöntemine göre %5.17, FHOG özniteliliğine göre %4.03 artış sağlanarak %94.55 tanıma başarımı elde edilmiştir.

Yapılan deneysel çalışmalarda sistemin farklı eşik noktalarında gösterdiği başarımlar ayrıntılı bir şekilde irdelenmiştir. Bu sayede farklı uygulama alanlarında, FAR ve FRR değerlerindeki değişim incelenerek uygun eşik noktasında daha gürbüz uygulamalar gerçekleştirilebilir. Doğrulama deneylerinde FAR ve FRR’nin eşit olduğu EER noktasında %89.45 başarımlar elde edilmiştir.

## Çıkar Çatışması (Conflict of Interest)

Yazarlar tarafından herhangi bir çıkar çatışması beyan edilmemiştir. No conflict of interest was declared by the authors.

## Kaynaklar (References)

- Dalal, Navneet, and Bill Triggs. "Histograms of oriented gradients for human detection." 2005 IEEE computer society conference on computer vision and pattern recognition (CVPR'05). Vol. 1. Ieee, 2005.
- Felzenszwalb, Pedro F., et al. "Object detection with discriminatively trained part-based models." IEEE transactions on pattern analysis and machine intelligence 32.9 (2009): 1627-1645.

- Gacav, C., Topal, C., Benligiray B. (2017). Greedy search for descriptive spatial face features. IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP).
- Gacav, Caner, Burak Benligiray, and Cihan Topal. "Greedy search for descriptive spatial face features." 2017 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). IEEE, 2017.
- Gacav, Caner, Burak Benligiray, and Cihan Topal. "Sequential forward feature selection for facial expression recognition." 2016 24th Signal Processing and Communication Application Conference (SIU). IEEE, 2016.
- Gacav, Caner, et al. "Facial expression recognition with FHOg features." 2018 26th Signal Processing and Communications Applications Conference (SIU). IEEE, 2018.
- Gusain, Raj, Hemant Jain, and Shivendra Pratap. "Enhancing bank security system using Face Recognition, Iris Scanner and Palm Vein Technology." 2018 3rd International Conference On Internet of Things: Smart Innovation and Usages (IoT-SIU). IEEE, 2018.
- Holat, Recep, and Selman Kulaç. "YÜZ BULMA VE TANIMA SİSTEMLERİ KULLANARAK KİMLİK TANIMA ID IDENTIFICATION BY USING FACE DETECTION AND RECOGNITION SYSTEMS."
- Huang, Y., Chen S. (2015). A Geometrical-Modal-Based Face Recognition. IEEE International Conference on Image Processing (ICIP).
- Kazemi, Vahid, and Josephine Sullivan. "One millisecond face alignment with an ensemble of regression trees." Proceedings of the IEEE conference on computer vision and pattern recognition. 2014.
- Kowsari, Kamran, et al. "Rmdl: Random multimodel deep learning for classification." Proceedings of the 2nd International Conference on Information System and Data Mining. 2018.
- Last, Mark, Abraham Kandel, and Oded Maimon. "Information-theoretic algorithm for feature selection." Pattern Recognition Letters 22.6-7 (2001): 799-811.
- Memiş, Abbas, and Fethullah Karabiber. "Face recognition on mobile environment images using appearance based methods." 2016 24th Signal Processing and Communication Application Conference (SIU). IEEE, 2016.
- Nakariyakul, Songyot, and David P. Casasent. "An improvement on floating search algorithms for feature subset selection." Pattern Recognition 42.9 (2009): 1932-1940.
- Ojala, Timo, Matti Pietikäinen, and David Harwood. "A comparative study of texture measures with classification based on featured distributions." Pattern recognition 29.1 (1996): 51-59.
- Özbey, Nuri, and Cihan Topal. "Expression recognition with appearance-based features of facial landmarks." 2018 26th Signal Processing and Communications Applications Conference (SIU). IEEE, 2018.
- Phillips, P. Jonathon, et al. "The FERET evaluation methodology for face-recognition algorithms." IEEE Transactions on pattern analysis and machine intelligence 22.10 (2000): 1090-1104.
- Schenk, Joachim, Moritz Kaiser, and Gerhard Rigoll. "Selecting features in on-line handwritten whiteboard note recognition: SFS or SFFS?." 2009 10th international conference on document analysis and recognition. IEEE, 2009.
- Taigman, Yaniv, et al. "Deepface: Closing the gap to human-level performance in face verification." Proceedings of the IEEE conference on computer vision and pattern recognition. 2014.
- Viola, Paul, and Michael J. Jones. "Robust real-time face detection." International journal of computer vision 57.2 (2004): 137-154.
- Yan, Mengjia, et al. "Vargfacenet: An efficient variable group convolutional neural network for lightweight face recognition." Proceedings of the IEEE/CVF International Conference on Computer Vision Workshops. 2019.
- Yavuz, Hasan Serhan, Hakan Cevikalp, and Rifat Edizkan. "A comprehensive comparison of features and embedding methods for face recognition." Turkish Journal of Electrical Engineering & Computer Sciences 24.1 (2016): 313-340.