



## **Yüz İfadesi Tanıma için Mesafe Oranlarına Dayalı Öznitelik Çıkarımı ve Genetik Algoritmalar ile Seçimi**

Ensar Arif SAĞBAŞ<sup>1\*</sup>, Osman GÖKALP<sup>2</sup>, Aybars UĞUR<sup>2</sup>

<sup>1</sup>Muğla Sıtkı Koçman Üniversitesi, Bilişim Sistemleri Mühendisliği Bölümü, Muğla

<sup>2</sup>Ege Üniversitesi, Bilgisayar Mühendisliği Bölümü, İzmir

### **Özet**

Yüz ifadeleri, insanların duyguları hakkında bilgi vermesi nedeniyle sözsüz iletişimde önemli bir rol oynamaktadır ve başta eğitim, sağlık, hukuk, eğlence olmak üzere çok çeşitli alanlarda kullanılmaktadır. Bu çalışmada yüz ifadelerine dayalı duygu tespiti sistemi geliştirilmiştir. Bu kapsamda yedi temel duygu ifadesi için (mutlu, kızgın, üzgün, iğrenme, korku, şaşırma ve nötr) toplam 9296 adet görüntü 4 erkek 3 kadın katılımcıdan alınmıştır. Elde edilen görüntüler kullanılarak öncelikle yüz işaretçilerinin konumu tespit edilmiştir. Sonrasında yüz işaretçileri arasındaki mesafe oranlarına dayalı yeni bir öznitelik çıkarma yaklaşımı ile toplamda 120 adet öznitelik çıkarılmıştır. Öznitelik seçiminde Genetik Algoritmalar kullanılmıştır. Buna ek olarak ReliefF, Information Gain ve Gain Ratio öznitelik seçimi algoritmalarının başarımları Genetik Algoritmaların sonucu ile karşılaştırılmıştır. Seçilen özniteliklerin sınıflandırma performansları; kNN, Bayes Ağları ve Rastgele Orman yöntemleri ile test edilmiştir. Sonuç olarak, bu çalışmada önerilen öznitelik çıkarma yöntemi ile elde edilen özniteliklerin Genetik Algoritmalar kullanılarak seçilmesi ve Rastgele Orman ile sınıflandırılmasının ardından başarılı sonuçlar üretebildiği gözlemlenmiştir.

**Anahtar Kelimeler:** Yüz ifadesi tanıma, makine öğrenmesi, öznitelik seçimi, genetik algoritmalar, öznitelik çıkarımı

### **Makale Bilgisi**

*Başvuru:*

12/02/2019

*Kabul:*

26/06/2019

## **Feature Extraction Based on Distance Ratio and Selection with Genetic Algorithms for Facial Expression Recognition**

### **Abstract**

Facial expressions play an important role in nonverbal communication because they inform people about their feelings and they are used in a wide range of fields, especially education, health, law, entertainment. In this study, the emotion detection system based on facial expression has been developed. In this context, a total of 9296 images were taken from 4 male and 3 female participants for seven basic emotions (happy, angry, sad, disgust, fear, surprise and neutral). Using the obtained images, the positions of the facial landmarks were determined first. Subsequently, a total of 120 features were extracted with a novel feature extraction approach based on the distance between facial landmarks. Genetic Algorithms are used in feature selection. In addition, the performance of ReliefF, Information Gain and Gain Ratio feature selection algorithms is compared with the result of Genetic Algorithms. The classification performances of the selected features were tested with kNN, Bayesian Networks and Random Forest methods. As a result, it has been observed that the features extracted by

\* İletişim e-posta: arifsagbas@mu.edu.tr

the feature extraction method proposed in this study can produce successful results after selecting with Generic Algorithms and classifying with Random Forest.

**Keywords:** Facial expression recognition, machine learning, feature selection, genetic algorithms, feature extraction

## 1 Giriş

Yüz ifadesi tanıma, insan-makine etkileşimi, yüz animasyonu ve robotik gibi çeşitli alanlarda aktif bir araştırma alanıdır [1]. Otomatik yüz ifadesi tanıma ile ilgili araştırmalar bu modern teknolojik çağda çok önemlidir. Son yıllarda yüz ifadesi tanıma, özellikle sanal gerçeklik, akıllı ders sistemi, sağlık hizmetleri ve veri odaklı animasyonlar gibi çeşitli alanlarda yaşamsal uygulamalarına bağlı olarak yoğun bir yatırım altındadır [2]. Yüz ifadesinin tanınmasının ana hedefi, verilen yüz görüntülerine dayanarak insanların duygusal durumunu tanımlamaktır. Bu ifadeler öfke, aşağılama, iğrenme, korku, mutluluk, üzülmeye ve şaşkınlık olarak tanımlanmaktadır [3].

Yüz ifadelerini otomatik olarak tanımak için çeşitli yaklaşımlar önerilmekte olup bunlar; öznitelik tabanlı ve şablon tabanlı olmak üzere iki sınıfa ayrılmaktadır [2]. Bir dizi öznitelik kullanarak, herhangi bir makine öğrenme algoritması sınıflandırma yapabilmektedir. Alakasız ve gereksiz değişkenleri azaltma problemini çözmek için çeşitli teknikler geliştirilmiştir. Öznitelik seçimi, veriyi anlamada, hesaplama gereksinimini azaltmada, boyutsallık sorununun etkisini azaltmada ve tahmin edicinin performansını geliştirmede yardımcı olmaktadır [4].

Bu çalışmada öznitelik-tabanlı yüz ifadesi tanıma üzerinde durulmuştur. Yedi (7) farklı duygunun (mutlu, kızgın, üzgün, iğrenme, korku, şaşırma ve nötr) yüz ifadeleri üzerinden sınıflandırılması gerçekleştirilmiştir. Yüz işaretçileri kullanılarak yüz ifadesi için önem arz eden mesafeler hesaplanmış ve bu mesafeler birbirine oranlanarak 120 adet öznitelik elde edilmiştir. Yüz ifadelerinin sınıflandırılması ve öznitelik seçimi için Genetik Algoritma tabanlı melez bir yapı oluşturulmuştur. Oluşturulan Rastgele Orman, kNN ve Bayes Ağları yapılarının performansları kendi aralarında karşılaştırılmıştır. Ek olarak öznitelik seçiminde Genetik Algoritmanın başarısı klasik öznitelik seçimi algoritmalarından olan ReliefF, Information Gain ve Gain Ratio ile kıyaslanmıştır.

Çalışmanın 2. kısmında literatürde yer alan yüz ifadesi tanıma çalışmaları özetlenmiştir. Kullanılan

makine öğrenmesi yöntemleri, klasik öznitelik seçimi algoritmaları ve Genetik Algoritmalar 3. kısımda kısaca anlatılmıştır. Çalışma kapsamında oluşturulan veri kümesi ve yüz ifadesi tanıma aşamaları 4. başlık altında açıklanmıştır. Elde edilen deneysel sonuçlar 5. kısımda tartışılmıştır. Son olarak 6. kısımda çalışma sonuçlandırılmıştır.

## 2 Önceki çalışmalar

Yüz ifadelerinin tanınması ile ilgili literatürde çeşitli çalışmalar bulunmaktadır. Hariri vd. [1] tarafından yapılan çalışmada çok katmanlı (manifold) veriler ve çekirdek tabanlı yöntemler ile 3 boyutlu yüz ifadesi tanıma problemi ele alınmıştır. Geliştirilen yapının performansı BU-3DFE ve Bosphorus veri kümeleri üzerinde test edilmiştir. Soyel ve Demirel [5] tarafından gerçekleştirilen çalışmada yüz işaretçileri üç boyutlu düzlem üzerinde incelenerek öznitelikler çıkarılmıştır. Öznitelik çıkarımı için 83 adet yüz işaretçisinin konumu 3 boyutlu olarak tespit edilmiş ve her bir nokta çifti arasındaki mesafeler hesaplanmıştır. Toplamda 83 nokta için 3403 adet mesafe hesaplanmıştır. Bu noktaların en uygun alt kümelerinin bulunması amaçlanmıştır. Bunun için de Fisher Criterion tabanlı öznitelik seçimi yönteminden faydalanılmıştır. Literatürdeki çeşitli çalışmalar ile mevcut çalışma karşılaştırılmış ve %88.5 ile başarılı sonuçların elde edildiği gösterilmiştir. Yang ve Yin [6] BU-3DFE ve BU-4DFE veri kümeleri üzerinden yüz işaretçilerinden maskeler üretmek için yüz ifadelerini tespit etmişlerdir. Elde edilen maskeler Evrişimsel Sinir Ağları ile sınıflandırılmıştır.

Owusu vd. [7] yüz ifadesi tanıma probleminin çözümünde doğruluk oranını artırırken hesaplama zamanını azaltacak Gabor yöntemi tabanlı öznitelik çıkarımı ve Adaboost Algoritması tabanlı öznitelik seçimine dayalı bir yapı önermişlerdir. Sınıflandırma yöntemi olarak Çok Katmanlı İleri Beslemeli Sinir Ağları kullanılmıştır. Önerilen yapının performansı JAFEE ve Yale veri kümeleri üzerinde test edilmiştir. Ruiz vd. [8] tarafından geliştirilen algoritma veri kümesinden görüntüyü yakalamakta ve Temel Bileşen Analizi (TBA) ile boyut azaltmaktadır. Yüz ifadeleri, eğitilmiş veri kümesine göre Yapay Sinir Ağları (YSA) ile tespit

edilmektedir. İşlemlerin daha hızlı gerçekleştirilebilmesi için görüntüler gri tonlamalı hale çevrilmiş ve 256x256 piksel olarak yeniden boyutlandırılmıştır. Çalışma sonunda TBA+YSA yönteminin yüz ifadesi tespit problemini başarılı bir şekilde ele aldığı görülmüştür. Ayvaz ve Gürüler [9], 7 farklı duygu için 5 kadın 7 erkek katılımcı ile yüz ifadesi veri kümesi oluşturmuştur. Yüz tespiti için Viola Jones algoritması kullanılmıştır. Dlib kütüphanesi ile 68 adet yüz işaretçisinin konumu bulunmuştur. Destek Vektör Makineleri, kNN, Rastgele Orman ve Regresyon Ağacı yöntemlerinin performansları karşılaştırılmış ve en iyi sonuç %97 ile Destek Vektör Makinelerinden elde edilmiştir. Agrawal ve Khatri [10] tarafından yapılan çalışmada Viola Jones Algoritması ve Temel Bileşen Analizi kullanılan bir yüz ifadesi sınıflandırma yapısı önerilmiştir. Tivatansakul vd [11] geliştirdikleri yeni öznelik çıkarımı yaklaşımını JAFEE veri kümesi üzerinde test etmişlerdir. Sınıflandırma yöntemi olarak Destek Vektör Makineleri tercih edilmiş ve ortalamada %87 sınıflandırma başarısı elde edilmiştir. Lajevardi ve Hussain [12] yüz ifadesi tanıma probleminde sınıflandırma hatasının en aza indirilmesine dayanan bir alt öznelik kümesi seçmek için genel bir eniyileme algoritmasını uygulamıştır.

Ayvaz vd. [13] görsel ve etkileşimli e-öğrenme sistemleri için bilgisayarla görü ve makine öğrenimi teknolojilerini birleştiren bir melez bilgi sistemi önermişlerdir. Gacav vd. [14] Felzenszwalb'ın yönelimli gradyan histogramının yüz ifadesi tanımadaki başarısını test etmişlerdir. Engin ve Ekenel [15] yüz ifadesi tanıma konusunu bir görüntü çifti eşleştirme problemi olarak ele almışlardır. Gacav vd. [16] tarafından gerçekleştirilen çalışmada ardışık ileri öznelik seçimi uygulanarak yüz imgesinden elde edilen nirengi noktaları kullanılarak elde edilen özneliklerden en verimli altküme belirlenmiştir. Özbey ve Topal [17] aktif şekil modelleri kullanılarak bulunan nirengi noktalarının çevresinden elde edilen yerel ikili örüntü (YİÖ) öznelikleri kullanarak yüz ifadelerinin tanınmasını sağlamışlardır. Aksoy ve Sert [18] yüz eylem birimlerinin sezimi için, ikili öğrenme yöntemlerinin kestirim aşamasında değişken karar eşikleri kullanan yeni ve etkili bir yöntem önermişlerdir. Akkoca ve Gökmen [19] yüz görüntüleri üzerinden otomatik olarak gülümsemelerin tanınmasını sağlayacak bir çalışma gerçekleştirmişlerdir. Akyol ve Şahin [20] KDEF

verisetini kullanarak görüntü tabanlı yüz ifadesi tespiti gerçekleştirmişlerdir. Bayrakdar vd. [21] video dosyalarının hızlandırılmış yüz ifade analizi için bir yaklaşım önermiştir. Ayvaz ve Gürüler [22] bilgisayar kullanıcısının yüz ifadelerine dayalı anlık duygu tespiti gerçekleştiren prototip bir sistem geliştirmişlerdir.

Zeng vd. [2] yüz bölgelerinin konumlarından faydalanılan geometrik özneliklerin çıkarıldığı bir yaklaşım üzerinde durmuştur. Çalışma kapsamında yüz ifadeleri için yüksek boyutlu öznelikler açıklanmıştır. Deep Sparse Auto Encoder (DSAE) tabanlı derin öğrenme yöntemi kurulmuştur. Önerilen DSAE yöntemi CK+ veri kümesine 7 ve 8 sınıflı bir şekilde uygulanmıştır. Li vd. [23] tarafından gerçekleştirilen çalışmada derin öğrenme yöntemlerinden Faster R-CNN tabanlı bir yöntem önerilmiştir. Veri kümesi Chinese Linguistic Data Consortium'dan sağlanmıştır. Faster R-CNN sayesinde bütün ağ yapısında orijinal görüntüler kullanılmıştır. Geleneksel öznelik çıkarma yöntemlerinin önüne geçilmiştir. Tümen vd. [24] FER2013 veri setinde bulunan yüz ifadelerini otomatik olarak sınıflandırmak üzere Evrimsel Sinir Ağları (CNN) tabanlı bir yüz ifadesi tanıma sistemi geliştirmişlerdir. Abanoz ve Çataltepe [25] duygu tanıma problemi için transfer öğrenme ve topluluk öğrenmesini birlikte kullanarak güçlü bir sınıflandırıcı elde etmişlerdir. Akay ve Arıca [26] yüz videolarında yüz eylem birimlerinin tespiti için derin sinir ağları tabanlı yeni bir yöntem önermişlerdir.

### 3 Materyal ve yöntem

Bu çalışmada öznelik seçimi için ReliefF, Information Gain, Gain Ratio ve Genetik Algoritmalar yöntemleri kullanılmıştır. Seçilen özneliklerin sınıflandırma başarısı ise kNN, Bayes Ağları ve Rastgele Orman yöntemleri test edilmiştir. Bu yöntemler aşağıdaki alt başlıklarda açıklanacaktır.

#### 3.1 Öznelik seçimi yöntemleri

##### 3.1.1 ReliefF

ReliefF algoritmasında öznelikler, hedef fonksiyonuna uygunluğuna göre seçilmektedir. ReliefF algoritmasının ana fikri, k-en yakın komşu algoritmasının temel kurallarına benzemektedir. Bir öznelik yararlıysa, aynı sınıfın en yakın mesafelerinin, bu öznelik boyunca verilen tüm diğer sınıfların en yakın mesafelerinden daha yakın olması beklenmektedir [27, 28]. Böylece, belirli bir

özniteliğin  $W$  ağırlığı Denklem (1)'de gösterildiği gibi hesaplanmaktadır.

$$W = (W - \text{diff}(x_{ij}, \text{near\_hit}_{ij})^2 + \text{diff}(x_{ij}, \text{near\_miss}_{ij})^2) / m \quad (1)$$

Burada,  $m$ , örneklem büyüklüğünü (eğitim kümesinin bir alt kümesinden rastgele seçilen),  $\text{diff}(x_{ij}, \text{near\_hit}_{ij})$ , rastgele seçilen  $j$  mesafesi içindeki öznitelik değerleri ile aynı sınıftaki en yakın eğitim verisi içindeki özniteliğin ( $\text{near\_hit}_{ij}$ ) değeri arasındaki farkını tanımlamaktadır. Paralel olarak,  $(x_{ij}, \text{near\_miss}_{ij})$ , farklı sınıftan en yakın eğitim örneğinin değeri olarak tanımlanır. Yararlı bir öznitelik için  $x_{ij}$  ve  $\text{near\_hit}_{ij}$  değerlerinin birbirine çok yakın olması beklenmektedir. Bir öznitelik yararlı değilse, her iki farkın da neredeyse aynı dağılımı alması beklenmektedir [27, 28].

### 3.1.2 Information gain (Bilgi kazancı)

Information Gain, makine öğrenmesi alanında yaygın olarak kullanılan entropiye dayalı bir öznitelik değerlendirme yöntemidir. Bu yöntem, öznitelik seçiminde kullanılmaktadır ve öznitelikler tarafından sağlanan bilgi miktarı olarak tanımlanmaktadır [29].  $t$  özniteliğinin bilgi kazanımı Denklem (2)'de tanımlanmaktadır [30].

$$IG(t) = - \sum_{i=1}^{|C|} P(C_i) \log P(C_i) + P(t) \sum_{i=1}^{|C|} P(C_i|t) \log P(C_i|t) + P(\bar{t}) \sum_{i=1}^{|C|} P(C_i|\bar{t}) \log P(C_i|\bar{t}) \quad (2)$$

Burada,  $C_i$ ,  $i$  kategoriyi temsil etmektedir.  $P(C_i)$ ,  $i$  kategorinin olasılığıdır.  $P(t)$  ve  $P(\bar{t})$  sırasıyla,  $t$  ifadesinin görülme ve görülme olasılığı,  $P(C_i|t)$   $i$  kategoride  $t$  teriminin görülme koşullu olasılığı,  $P(C_i|\bar{t})$  ise  $i$  kategoride  $t$  teriminin görülme koşullu olasılığıdır [30].

### 3.1.3 Gain ratio (Kazanç oranı)

Bir karar ağacı, uçsal (terminal) olmayan düğümlerin bir veya daha fazla öznitelik üzerinde testleri temsil ettiği ve uçsal düğümlerinin karar sonuçlarını yansıttığı basit bir yapıdır. Bilgi kazancı ölçümü, karar ağacının her düğümündeki test öznitelikliğini seçmek için kullanılmaktadır ve çok sayıda değere sahip öznitelikleri seçmeyi tercih etmektedir. Karar ağacı, yanlılığın üstesinden

gelmek amacıyla, kazanç oranı olarak bilinen bilgi kazanımını kullanmaktadır [31]. Karar ağacı, aşağıdaki gibi tanımlanan bir değeri kullanarak bilgi kazanımı için normalizasyon uygulayan kazanç oranını kullanmaktadır (Denklem (3)).

$$\text{SplitInfo}_A(S) = - \sum_{i=1}^v (|S_i|/|S|) \log_2(|S_i|/|S|) \quad (3)$$

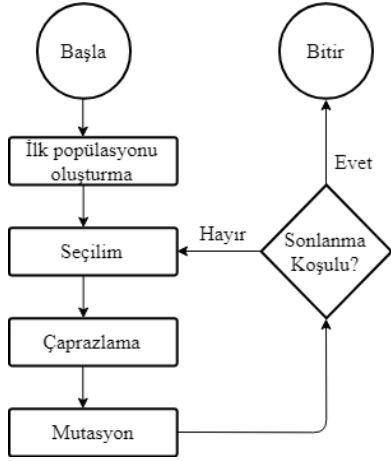
Gain ratio, bilgi kazancı değerlerini, bölünme bilgisine oranlayarak bir çeşit normalizasyona tabi tutmaktadır [32]. Kazanç oranı ise Denklem (4)'te gösterildiği şekilde tanımlanmaktadır.

$$\text{Gain Ratio}(A) = \text{Gain}(A) / \text{SplitInfo}_A(S) \quad (4)$$

### 3.1.4 Genetik algoritmalar

Genetik Algoritmalar (GA) [33], evrimsel algoritmalar ailesinin bir üyesi olarak eniyileme problemlerinin çözümü için sıklıkla tercih edilmektedir. Bu yöntemde kromozom, gen, uygunluk, seçim, çaprazlama ve mutasyon gibi biyolojik kavramlar eniyileme problemlerinin tasarım ve çözüm bileşenlerine eşlenmekte ve evrensel en iyi çözümün aranmasında kullanılmaktadır. Bir metasezgisel olarak GA, problemten bağımsız bir yapıya sahiptir. Bir başka deyişle, GA için tanımlanmış prosedürler herhangi bir eniyileme probleminin çözümüne uyarlanıp kullanılabilir.

GA'da her bir çözüm bileşeni bir gen olarak temsil edilmektedir. Genlerin birleştirilmesi ile oluşturulan kromozomlar ise birer çözüm adayına karşılık gelmektedir. Kromozomların kalitesine, bir başka deyişle istenen en iyi çözüme yakınlığına, uygunluk fonksiyonu ile karar verilmektedir [34]. Genel anlamda bir GA'nın akış şeması Şekil 1'deki gibidir. Başlangıçta ilk popülasyon belirli sayıda kromozom içerecek şekilde oluşturulmaktadır. Ardından, sonlanma koşulu sağlanıncaya kadar uygunluk değerine göre ebeveyn kromozomlar seçilip çaprazlanmakta ve yeni yavru kromozomlar oluşturulmaktadır. Çaprazlamanın hemen ardından mutasyon ile belirli oranda yavru kromozom genleri üzerinde rastgele değişiklikler yapılmaktadır. Ardından, oluşturulan yavru kromozomlar yeni popülasyona aktarılmaktadır. Yeni popülasyon, önceki popülasyonun büyüklüğüne ulaştığı zaman onun yerine geçmektedir. Sonlanma koşulu sağlanması durumunda ise mevcut en iyi çözüm döndürülerek algoritma sonlandırılmaktadır.



Şekil 1. Genetik algoritmanın akış şeması

## 3.2 Sınıflandırma yöntemleri

### 3.2.1 Bayes ağları

Bayes Ağları olasılıksal çizgesel modellerden biridir. Bayes Ağlarında, belirsiz bir konu hakkındaki bilgi, çizgesel yapılar olarak gösterilmektedir. Değişkenler çizgede düğümler olarak temsil edilirken değişkenler arasındaki olasılıksal bağımlılıklar kenarlar olarak temsil edilmektedir. Bir Bayes Ağında, her değişken kendi ebeveynlerinin durumu göz önüne alındığında, kendi soyundan bağımsızdır. Değişkenler arasındaki bağımsızlık açıkça tanımlandığından, Bayes sistemindeki tüm ortak olasılıkların hesaplanması gerekmemektedir. Bu, sonsal

### 3.2.3 Rastgele orman

Rastgele Orman, karar ağacı yapısını kullanan tahminleyicilerin birleşimidir. Rastgele Orman yönteminde, veri kümesinden Bootstrap yöntemi ile örnekler seçilmekte ve bu örneklerle dayalı olarak sınıflandırma ağaçları oluşturulmaktadır. Bu sınıflandırma ağaçları kullanılarak her bir ağaç için gözlemin sınıfı kestirilmekte ve sınıflandırmalar arasında en çok tekrar eden sınıf değeri seçilmektedir [39]. Rastgele Orman algoritmasının yapısı Şekil 2'de sunulmaktadır.

## 4 Uygulama

### 4.1 Veri kümesi

Çalışma kapsamında veri kümesi, standart bir dizüstü bilgisayarı dâhili kamerası kullanılarak

(posterior) olasılıkları hesaplamak için etkili bir yol sağlar. Bir Bayes Ağındaki değişken kümesinin  $\{A_1, A_2, \dots, A_n\}$  olduğu ve  $parents(A_i)$ ,  $A_i$  düğümündeki ebeveyn kümesini ifade ettiği varsayalım. Buna bağlı olarak  $\{A_1, A_2, \dots, A_n\}$  için ortak olasılık dağılımı, düğümlerin bireysel olasılıklarının çarpımı ile hesaplanabilmektedir (Denklem (5)) [35, 36].

$$P(A_1, \dots, A_n) = \prod_{i=1}^n P(A_i | parents(A_i)) \quad (5)$$

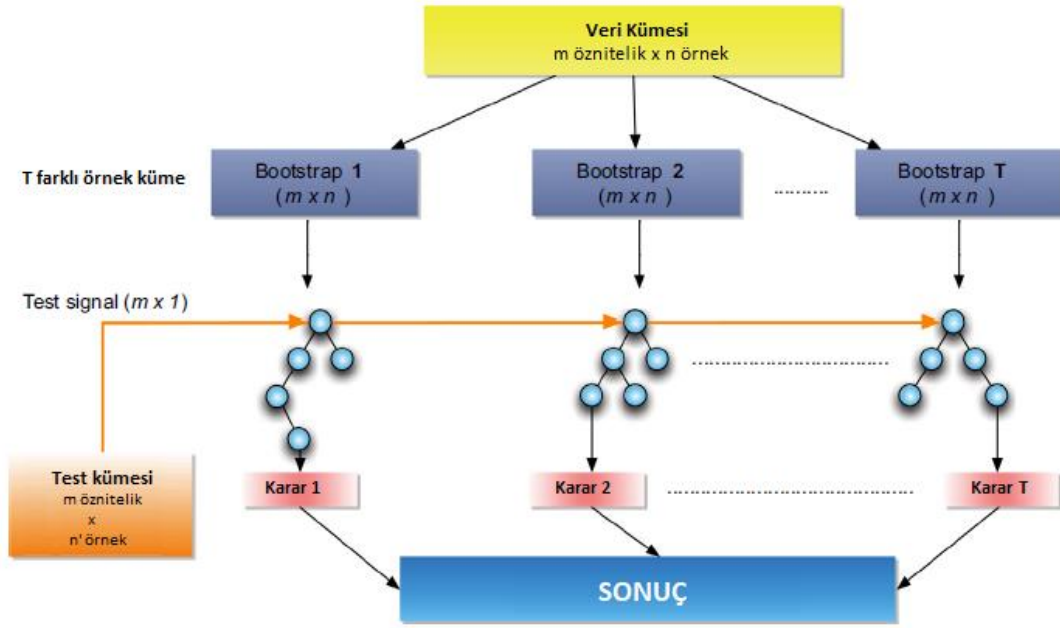
### 3.2.2 kNN

kNN, örnek veriler ve veri kümesi arasındaki benzerliğe dayanan sınıflandırma yöntemidir. Sınıflandırma şu şekilde gerçekleştirilir: Bir test seti nesnesi, aynı çok boyutlu hiperuzaya yerleştirilir. Yeni test seti nesnesi ile eğitim kümesindeki nesnelere arasındaki mesafe hesaplanır. Hesaplanan mesafeler küçükten büyüğe sıralanarak en yakın k nesnenin sınıf bilgisine bakılır [37,38]. Bu çalışmada p adet özneliğe sahip desenler arası uzaklığı hesaplamak için Denklem (6)'da bulunan Öklit mesafe formülü kullanılmıştır. Formülde  $X_i$  ve  $X_j$  farklı iki noktayı göstermektedir.

$$d(i, j) = \sqrt{|X_{i1} - X_{j1}|^2 + |X_{i2} - X_{j2}|^2 + \dots + |X_{ip} - X_{jp}|^2} \quad (6)$$

elde edilmiştir. Verilerin elde edilmesi için 24-50 yaş aralığında 4 erkek 3 kadın toplamda 7 katılımcıdan, mutlu, kızgın, üzgün, iğrenme, korku, şaşırma ve nötr duygu ifadelerini sergilemeleri istenmiştir. Yedi farklı duygu için toplamda 9296 adet görüntü elde edilmiş ve etiketlenmiştir. Kullanıcılardan elde edilen görüntüler; Python programlama dili, OpenCV ve dlib kütüphanelerini kullanan bir masaüstü uygulaması geliştirilerek incelenmiştir ve yüz işaretçilerinin otomatik tespiti gerçekleştirilmiştir. Yüzdeki 68 adet yüz işaretçisinin (Şekil 3) konumunun x ve y koordinatları dlib kütüphanesi kullanılarak elde edilmiştir. Her bir görüntü için elde edilen bu koordinatlar öznelik çıkarımı amacı ile CSV formatında saklanmıştır.<sup>1</sup>

<sup>1</sup> [https://github.com/arifsagbas/2019\\_fer\\_dataset](https://github.com/arifsagbas/2019_fer_dataset)




Şekil 2. Rastgele orman algoritmasının genel yapısı [40]

## 4.2 Öznitelik çıkarımı

İncelenen 68 yüz işaretçisinin koordinatları tespit edilmiştir ve belirlenen koordinatlar arasındaki Öklit uzaklıkları hesaplanmıştır. Belirlenen koordinatlar daha önceden yapılmış çalışmalarda seçilmiş yüz ifadesi tanımada önemli olacak mesafelerdir. Bunlar Tablo 1'de sunulmuştur.

Yüz işaretçilerine dayalı olarak çıkarılan öznitelikler, hesaplanan mesafelerin birbirine oranlanması ile elde edilmiştir. Bu bağlamda 16 mesafe birbiri ile oranlanarak toplamda 120 adet öznitelik elde edilmiştir. Bu öznitelikler F1-F120 olarak isimlendirilmiştir.



Şekil 3. 68 adet yüz işaretinin koordinatlarının görselleştirilmesi [41]

## 4.3 Öznitelik seçimi

### 4.3.1 Klasik öznitelik seçimi yöntemlerinin kullanımı

Belirlenen 120 adet öznitelikten hangilerinin verimli hangilerinin verimsiz olduğuna karar verilmesi amacı ile öznitelik seçimi algoritmaları uygulanmış ve elde edilen sonuçlar karşılaştırılmıştır. Bu aşamada Weka aracı [42] içerisinde bulunan ReliefF, Information Gain ve Gain Ratio öznitelik seçimi algoritmaları kullanılmıştır. Bu algoritmalar öznitelikleri derecelendirmektedir. Bu algoritmalarından elde edilen derecelendirmeler ile en iyi N elemanlı alt kümeler test edilmiştir. Örneğin öznitelik seçimi algoritması derecelendirmede büyükten küçüğe F20, F45, F51, F12, ..., F98 gibi bir sıralama geri döndürmüş olsun. Öncelikle F20, sonrasında F20 ve F45, devamında F20, F45 ve F51 olacak şekilde 120 elemanlı alt küme elde edilinceye dek sınıflandırma performansları değerlendirilmiştir.


Tablo 1. Öznitelikler için hesaplanan mesafeler

Sıra	Fiziksel anlamı	İlgili noktalar
D1	Ağız genişliği	49-55
D2	Ağız yüksekliği	52-58
D3	Göz genişliği	37-40
D4	Göz yüksekliği	38-41
D5	Kaş-göz arası mesafe	25-47
D6	Burun-ağız üstü arası mesafe	34-52
D7	Çene-ağız arası mesafe	9-58
D8	İki göz çukuru arası mesafe	40-43
D9	Burun-çene arası mesafe	9-34
D10	Yüz genişliği	6-12
D11	İki göz arası mesafe	37-46
D12	İki kaş arası mesafe	22-23
D13	Burun uzunluğu	28-34
D14	İki kaş uzunluğu	18-27
D15	Burun-ağız altı arası mesafe	34-58
D16	Çene-ağız üstü arası mesafe	9-52

#### 4.3.2 Genetik Algoritma tabanlı öznitelik seçimi

Bu çalışmada GA, yüz ifadesi tanımayaya yönelik öznitelik seçiminin eniyilenmesi amacı ile kullanılmıştır. Oluşturulan kromozom yapısı ikili kodlamaya sahip olup her bir gen bir adet özniteliğe eşlenmiştir (Şekil 4). Buna göre, ilgili genin 1 değerine sahip olması o genin seçildiği, 0 değerinde olması ile o genin kullanılmayacağı anlamına gelmektedir. Çalışmamızda 120 adet öznitelik kullanıldığından, oluşturulan kromozomların uzunluğu bu sayıya sabitlenmiştir.

Gerçekleştirilen GA tabanlı öznitelik eniyileme yönteminin amacı sınıflandırma doğruluk oranını maksimize etmektir. Bu nedenle uygunluk fonksiyonu, kendisine verilen kromozomun izin verdiği öznitelikler ile elde edilen doğruluk oranını uygunluk değeri olarak döndürmektedir. Çaprazlama için ebeveyn kromozomların seçiminde rulet tekerleği seçim yöntemi uygulanmıştır. Bu seçim yönteminde kromozomlar uygunluk değerleri oranında olasılık ile seçilebilmektedir. Yavru kromozomların elde edilmesi için tek noktalı çaprazlama operatörü kullanılmıştır. Buna göre, belirlenen rastgele bir noktadan itibaren iki kromozom gen parçalarını karşılıklı olarak değiştirmektedir. Mutasyon işleminde seçilen genin değeri 1 ise 0'a, 0 ise 1'e çevrilmektedir.



Şekil 4. Genetik algoritmanın kullanımı

Başlangıç popülasyonunun oluşturulması için kromozomların hangi oranda 1 içereceği, bir başka deyişle özniteliklerin kaç tanesinin seçili olacağı, [0,1] aralığında belirlenen bir ilk seçim olasılık değerine göre belirlenmektedir. Bu işlem Denklem (7)'ye göre yapılmakta olup bir kromozomun i. geninin 1 ya da 0 değeri alması [0,1] aralığında üretilen bir rastgele sayının belirlenen olasılık değeri sınırlarında olmasına bağlıdır. Dikkat edilecek olursa olasılık değeri ne kadar büyük olursa başlangıçta seçilen özniteliklerin sayısı o oranda büyük olmaktadır.

$$kromozom[i] = \begin{cases} 1, & \text{eğer } \text{rast}(0,1) \leq \text{olasılık değeri} \\ 0, & \text{eğer } \text{rast}(0,1) > \text{olasılık değeri} \end{cases} \quad (7)$$

## 5 Deneysel çalışmalar

Gerçekleştirilen deneysel çalışmada, bu makalede önerilen mesafe oranlarına dayalı öznitelik çıkarımı ve Genetik Algoritmalar ile seçiminin farklı sınıflandırıcılar üzerindeki başarısı ölçülmüştür. Ayrıca literatürde öznitelik seçimi için kullanılan klasik yaklaşımlardan olan Gain Ratio, Information Gain ve ReliefF yöntemleri ile karşılaştırma yapılmıştır.

### 5.1 Deneysel kurulum ve parametrelerin belirlenmesi

Genetik Algoritmalar olasılıklı bir yapıya sahip olup seçim, mutasyon vb. prosedürlerinde rastgelelik içermektedir. Bu nedenle, daha sağlıklı sonuçlar almak adına çalışmamızda önerilen GA tabanlı seçim yöntemi her bir durum için 25 defa çalıştırılmıştır. Her biri farklı rastgele çekirdek ile başlatılan bu çalıştırmalar sonucu elde edilen performans değerleri kaydedilerek bazı istatistikî değerler hesaplanmıştır. Gain Ratio, Information Gain ve ReliefF ise belirlenimci yapıda olduğundan her bir durum için birer kez çalıştırılmıştır.

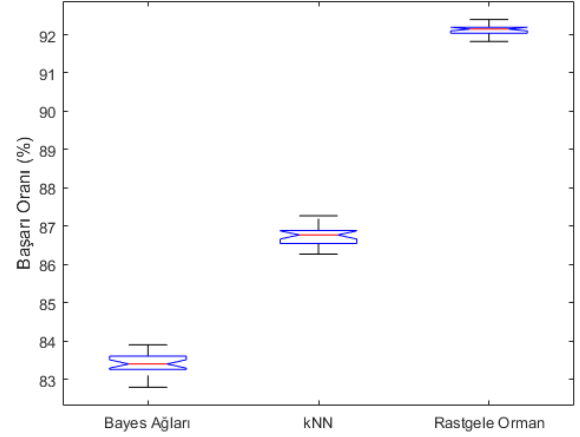
GA dışındaki tüm yöntemler için Weka'nın varsayılan değerleri seçilmiştir. Buna ek olarak



kNN'de  $k=5$  olacak şekilde ayarlanmıştır. GA için ise yapılan ön deneysel çalışma sonucunda elde edilen parametre değerleri ise Tablo 2'de sunulmuştur.

Tablo 2. GA parametre değerleri

Parametre	Değer
İterasyon sayısı	100
Popülasyon büyüklüğü	10
Mutasyon olasılığı	0.1
Çaprazlama olasılığı	1.0
Özneliklerin ilk seçim olasılık değeri	0.3



Şekil 5. GA öznelik seçimi sonuçlarına ait kutu grafiği

Tablo 3. Farklı sınıflandırıcılar için GA ile öznelik seçiminin 25'er kez tekrarlanması sonucu elde edilen başarı oranları

	Bayes Ağları		kNN		Rastgele Orman	
	Doğruluk oranı (ort.)	Öznelik Sayısı (ort.)	Doğruluk oranı (ort.)	Öznelik Sayısı (ort.)	Doğruluk oranı (ort.)	Öznelik Sayısı (ort.)
<b>Ortalama</b>	83.394	55.480	86.75	51.240	92.117	56.560
<b>Std.</b>	0.295	3.885	0.258	5.524	0.135	5.986
<b>En iyi</b>	83.901	46	87.271	39	92.398	42
<b>En kötü</b>	82.789	63	86.267	61	91.825	70

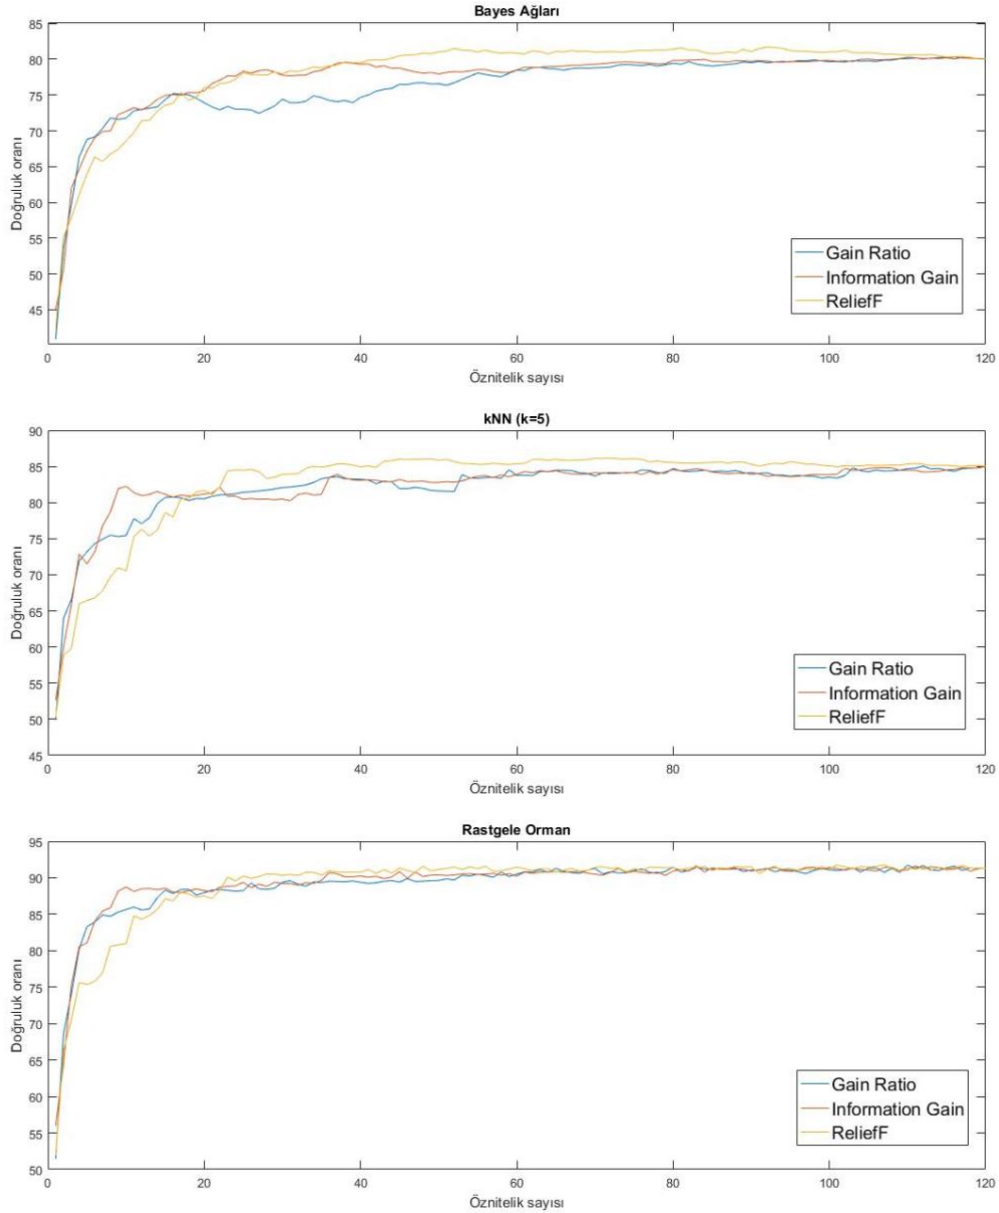
## 5.2 Deneysel sonuçlar

Belirlenen parametre değerleri ile GA tabanlı öznelik seçim yönteminin 25'er kez çalıştırılması sonucu elde edilen ortalama, standart sapma, en iyi ve en kötü değerleri, farklı sınıflandırıcılar için ayrı olarak Tablo 3'te sunulmuştur. Sonuçlar incelendiğinde, GA tabanlı öznelik seçiminin her üç sınıflandırıcı için de 120 olan öznelik sayısını ortalama 55 değerine yakın seviyelere indirebildiği görülmektedir. Böylece özneliklerin yarıdan fazlası elenmiş olmaktadır. Başarı oranlarının ise kullanılan sınıflandırıcıya bağlı olarak değişebildiği görülmüştür. Buna göre en yüksek sınıflandırma başarısını %92.1176 ile

Rastgele Orman yönteminin sergilediği görülmüştür.

Şekil 5'te ise GA öznelik seçimi sonuçlarına ait kutu grafiği gösterimi yer almaktadır. Tablo 3'te yer alan düşük standart sapma değerlerine paralel olarak kutu uzunluklarının sınırlı olduğu görülmektedir. Buna ek olarak, en yüksek sınıflandırma başarısına sahip Rastgele Orman yönteminin ayrıca en kısa uzunluklu grafiğe sahip olduğu göze çarpmaktadır. Grafikten çıkarılabilecek olan genel sonuç, GA tabanlı öznelik seçiminin her ne kadar olasılıklı bir yapıya sahip olsa da, yüksek tutarlılıkta sonuçlar üretebilmesidir.





Şekil 6. Klasik öznitelik seçimi yaklaşımlarının uygulanması sonucunda farklı sınıflandırıcılar için öznitelik sayısı/doğruluk oranı değişim grafikleri

GA tabanlı öznitelik seçiminin literatürde yer alan klasik algoritmalar karşısındaki performansını gözlemlemek amacıyla ek bir deneysel çalışma gerçekleştirilmiştir. Bu kapsamda ReliefF, Information Gain ve Gain Ratio algoritmaları yüz ifadesi tanımada 120 adet öznitelik seçimi için uygulanmıştır. Seçilen öznitelik sayısına göre değişen başarı oranlarına ait çizgi grafik Şekil 6'da yer almaktadır. Buna göre ReliefF algoritması daha ön planda olmak üzere her üç algoritma da birbirlerine yakın başarı oranları ortaya koymuştur. Ayrıca, her durumda en yüksek başarı oranları 120'den az öznitelik seçilmesi ile elde edilmektedir.

Bu durum bu veri seti için öznitelik seçiminin gerekliliğini ortaya koymaktadır. Klasik öznitelik seçimi algoritmalarından elde edilen sayısal sonuçlar GA tabanlı seçim sonuçları ile birleştirilerek Tablo 4'te özetlenmektedir. Buna göre, tüm sınıflandırıcılar için en yüksek başarı oranı ve en düşük öznitelik sayısının GA tabanlı öznitelik seçimi ile elde edildiği görülmektedir. Bu durum çalışmamızda kullanılan yöntemin başarısını ve anlamlılığını ortaya koymaktadır.

Tablo 4. GA tabanlı öznelik seçimi ile klasik öznelik seçimi algoritmalarına ait sayısal sonuçların karşılaştırılması

Sınıflandırıcı	Öznelik Seçimi Yöntemi	Başarı (%)	Öznelik Sayısı
Bayes Ağları	Gain Ratio	80.315	116
	Information Gain	80.279	110
	RelieFF	81.713	92
	<b>GA</b>	<b>83.394</b>	<b>55 (ort.)</b>
kNN	Gain Ratio	85.048	112
	Information Gain	85.048	120
	RelieFF	86.160	72
	<b>GA</b>	<b>86.750</b>	<b>51 (ort.)</b>
Rastgele Orman	Gain Ratio	91.753	110
	Information Gain	91.645	83
	RelieFF	91.787	107
	<b>GA</b>	<b>92.117</b>	<b>57 (ort.)</b>

## 6 Sonuç

Bu çalışmada yedi temel duygu için yüz ifadesi tanıma sistemi geliştirilmiştir. Yüz işaretçileri arasındaki mesafe oranlarına dayalı yeni bir öznelik çıkarımı yaklaşımı ile elde edilen 120 adet özneliğin seçimi için bir eniyileme yöntemi olan Genetik Algoritmalarından faydalanılmıştır. Sınıflandırma aşaması için kNN, Rastgele Orman ve Bayes Ağları olmak üzere 3 farklı algoritma denenmiştir.

Gerçekleştirilen deneysel çalışmalarda önerilen yöntemin başarımı sınanmıştır. Kullanılan üç farklı makine öğrenmesi yöntemi ve üç farklı öznelik seçimi yöntemi ele alındığında başarılı sonuçların Bayes Ağlarında 92, kNN'de 72 ve Rastgele Orman ise 107 öznelik alt kümesi ile yakalandığı görülmektedir. Üç sınıflandırma yöntemi için de RelieFF öznelik seçimi algoritması en başarılı alt kümeleri elde etmeyi sağlamıştır.

Elde edilen deneysel bulgulara göre, ele alınan veri kümesine, test edilen üç makine öğrenmesi yönteminden en uygununun Rastgele Orman olduğu sonucuna varılmaktadır. Öznelik seçiminde ise en iyi N alt küme yaklaşımı ile ele alınan üç farklı öznelik seçimi yöntemi Genetik Algoritmanın başarısının altında kalmıştır. Genetik Algoritma ile boyut azaltma işlemi daha başarılı bir şekilde gerçekleştirilmiştir. Genetik algoritma ile testleri daha farklı parametreler ile test edilerek daha başarılı sonuçların bulunması muhtemeldir.

Elde edilen test sonuçlarının çok yüksek olmamasının başlıca nedeni verilerin elde edilmesinde dizüstü bilgisayarın dâhili kamerasının kullanılmasıdır. Çok yüksek kalitede görüntü alınmasına imkân vermemesinden dolayı yüz işaretçileri belli noktalarda üst üste binmekte ifadenin karakterinin ortaya çıkması engellenmektedir. Buna rağmen Rastgele Orman yöntemi ile %92.4 sınıflandırma başarısı yakaladığı görülmektedir.

## Kaynaklar

- [1] Hariri W, Tabia H, Farah N, Benouareth A, Declercq D. "3D facial expression recognition using kernel methods on Riemannian manifold". Engineering Applications of Artificial Intelligence, 64, 25-32, 2017.
- [2] Zeng N, Zhang H, Song B, Liu W, Li Y, Dobaie AM. "Facial expression recognition via learning deep sparse autoencoders". Neurocomputing, 273, 643-649, 2018.
- [3] Ekman P, Friesen WV. "Constants across cultures in the face and emotion". Journal of personality and social psychology, 17(2), 124, 1971.
- [4] Chandrashekar G, Sahin F. "A survey on feature selection methods". Computers & Electrical Engineering, 40(1), 16-28, 2014.
- [5] Soyel H, Demirel H. "Optimal feature selection for 3D facial expression recognition using coarse-to-fine classification". Turkish Journal of Electrical Engineering & Computer Sciences, 18(6), 1031-1040, 2010.
- [6] Yang H, Yin L. "CNN based 3D facial expression recognition using masking and landmark features". In Affective Computing and Intelligent Interaction, San Antonio, Texas, 23-26 October 2017.
- [7] Owusu E, Zhan Y, Mao QR. "A neural-AdaBoost based facial expression recognition system". Expert Systems with Applications, 41(7), 3383-3390, 2014.
- [8] Ruiz LZ, Alomia RPV, Dantis ADQ, San Diego MJS, Tindugan CF, Serrano KKD. "Human emotion detection through facial expressions for commercial analysis". In Humanoid, Nanotechnology, Information Technology, Manila, Philippines, 1-3 December 2017.
- [9] Ayvaz U, Gürüler H. "Real-time detection of students' emotion states in the classroom". In Signal Processing and Communications Applications Conference, Antalya, Türkiye, 15-18 Mayıs 2017.
- [10] Agrawal, S., & Khatri, P. (2015, February). "Facial expression detection techniques: based on Viola and Jones algorithm and principal component analysis". In Advanced Computing & Communication Technologies, Rohtak, India, 21-22 February 2015.
- [11] Tivatansakul S, Ohkura M, Puangpontip S, Achalakul T. (2014, September). "Emotional healthcare system: Emotion detection by facial expressions using Japanese database". In Computer Science and Electronic Engineering Conference, Colchester, United Kingdom, 25-26 September 2014.
- [12] Lajevardi SM, Hussain ZM. "Feature selection for facial expression recognition based on optimization algorithm". In Nonlinear Dynamics and Synchronization, Klagenfurt, Austria, 20-21 July 2009.

- [13] Ayvaz, U., Gürüler, H., & Devrim, M. O. (2017). Use of Facial Emotion Recognition in e-learning Systems. *Information Technologies and Learning Tools*, 60(4), 95-104.
- [14] Gacav, C., Benligiray, B., Özkan, K., & Topal, C. (2018, May). Facial expression recognition with FHOG features. In 2018 26th Signal Processing and Communications Applications Conference (SIU) (pp. 1-4). IEEE.
- [15] Engin, D., & Ekenel, H. K. (2017, May). Facial expression pair matching. In *Signal Processing and Communications Applications Conference (SIU), 2017 25th* (pp. 1-4). IEEE.
- [16] Gacav, C., Benligiray, B., & Topal, C. (2016, May). Sequential forward feature selection for facial expression recognition. In *Signal Processing and Communication Application Conference (SIU), 2016 24th* (pp. 1481-1484). IEEE.
- [17] Özbey, N., & Topal, C. (2018, May). Expression recognition with appearance-based features of facial landmarks. In 2018 26th Signal Processing and Communications Applications Conference (SIU) (pp. 1-4). IEEE.
- [18] Aksoy, N., & Sert, M. (2016, May). Facial action unit detection using variable decision thresholds. In *Signal Processing and Communication Application Conference (SIU), 2016 24th* (pp. 2185-2188). IEEE.
- [19] Akkoca, B. S., & Gökmen, M. (2015, May). Automatic smile recognition from face images. In *Signal Processing and Communications Applications Conference (SIU), 2015 23th* (pp. 1985-1988). IEEE.
- [20] Akyol, F., & Şahin, P. D. (2016, May). Image-based facial expression detection. In *Signal Processing and Communication Application Conference (SIU), 2016 24th* (pp. 609-612). IEEE.
- [21] Bayraktar, S., Akgün, D., & Yücedağ, İ. (2017). Video dosyaları üzerinde yüz ifade analizi için hızlandırılmış bir yaklaşım. *Pamukkale University Journal of Engineering Sciences*, 23(5). pp. 602-613.
- [22] Ayvaz, U., & Gürüler, H. (2017). Bilgisayar Kullanıcılarına Yönelik Duygusal İfade Tespiti. *Bilişim Teknolojileri Dergisi*, 10(2), 231-239.
- [23] Li J, Zhang D, Zhang J, Zhang J, Li T, Xia Y, Xun L. "Facial Expression Recognition with Faster R-CNN". *Procedia Computer Science*, 107, 135-140, 2017.
- [24] Tümen, V., Söylemez, Ö. F., & Ergen, B. (2017, September). Facial emotion recognition on a dataset using convolutional neural network. In *Artificial Intelligence and Data Processing Symposium (IDAP), 2017 International* (pp. 1-5). IEEE.
- [25] Abanoz, H., & Çataltepe, Z. (2018, May). Emotion recognition on static images using deep transfer learning and ensembling. In 2018 26th Signal Processing and Communications Applications Conference (SIU) (pp. 1-4). IEEE.
- [26] Akay, S., & Arica, N. (2018, May). Facial action unit detection using deep neural networks in videos. In 2018 26th Signal Processing and Communications Applications Conference (SIU) (pp. 1-4). IEEE.
- [27] Kononenko, I. (1994). "Estimating attributes: analysis and extensions of RELIEF". In *European conference on machine learning*, Catania, Italy, 6-8 April 1994.
- [28] Peker M, Arslan A, Sen B, Celebi FV, But A. (2015, September). "A novel hybrid method for determining the depth of anesthesia level: Combining ReliefF feature selection and random forest algorithm (ReliefF+RF)". In *Innovations in Intelligent SysTems and Applications Madrid, Spain, 2-4 September 2015*.
- [29] S. Lei, "A feature selection method based on information gain and genetic algorithm", *International Conference on Computer Science and Electronics Engineering*, Hangzhou, China 23-25 March 2012.
- [30] Uğuz H. "A two-stage feature selection method for text categorization by using information gain, principal component analysis and genetic algorithm". *Knowledge-Based Systems*, 24(7), 1024-1032, 2011.
- [31] Karegowda AG, Manjunath AS, Jayaram MA. "Comparative study of attribute selection using gain ratio and correlation based feature selection". *International Journal of Information Technology and Knowledge Management*, 2(2), 271-277, 2010.
- [32] Yazıcı B, Yaslı F, Gürleyik HY, Yurgut UO., Aktas MS, Kalıpsız O. "Veri Madenciliğinde Özellik Seçim Tekniklerinin Bankacılık Verisine Uygulanması Üzerine Araştırma ve Karşılaştırmalı Uygulama". In *Proceedings of the 9th Turkish National Software Engineering Symposium*, Izmir, Turkey, 9-11 September 2015.
- [33] Holland, J. H., 1975, *Adaptation In Natural And Artificial Systems: an introductory analysis with applications to biology, control, and artificial intelligence*, University of Michigan Press, 1975.
- [34] Uslu, M. F., Uslu, S., & Bulut, F. (2018). An adaptive hybrid approach: Combining genetic algorithm and ant colony optimization for integrated process planning and scheduling. *Applied Computing and Informatics*.
- [35] Ben-Gal I. *Bayesian Networks*. Editors: Fabrizio Ruggeri, Ron Kenett and Frederick Faltin. *Encyclopedia of Statistics in Quality and Reliability*. Chichester, UK, Wiley; 2007.
- [36] Feng T, Timmermans HJ. "Transportation mode recognition using GPS and accelerometer data". *Transportation Research Part C: Emerging Technologies*, 37, 118-130, 2013.
- [37] Alsberg BK, Goodacre R, Rowland, JJ, Kell DB. "Classification of pyrolysis mass spectra by fuzzy multivariate rule induction-comparison with regression, K-nearest neighbour, neural and decision-tree methods". *Analytica Chimica Acta*, 348(1), 389-407, 1997.
- [38] Bulut, F., & Amasyali, M. F. (2017). Locally adaptive k parameter selection for nearest neighbor classifier: one nearest cluster. *Pattern Analysis and Applications*, 20(2), 415-425.
- [39] Özkan Y, Erol Ç. *Biyoenformatik DNA Mikrodizi Veri Madenciliği, İstanbul, Türkiye, Papatya Yayıncılık Eğitim*, 2015.
- [40] Morizet N, Godin N, Tang J, et al. Classification of acoustic emission signals using wavelets and random forests: application to localized corrosion. *Mech Syst Signal Pr* 2016; 70: 1026–1037.
- [41] Adrian Rosebrock. "Facial landmarks with dlib, OpenCV, and Python". <https://www.pyimagesearch.com/2017/04/03/facial-landmarks-dlib-opencv-python/> (12.07.2018)
- [42] Frank E, Hall MA, Witten IH. *The WEKA Workbench. Online Appendix for "Data Mining: Practical Machine Learning Tools and Techniques, Dördüncü baskı*, Cambridge, MA, United States, Morgan Kaufmann, 2016.