

# YÜZ İFADE ANALİZİNDE ÖZİNİTELİK SEÇİMİ VE ÇOKLU SVM SINIFLANDIRICILARINA ETKİSİ

**Turan GÜNEŞ ve Ediz POLAT**

Elektrik-Elektronik Bölümü, Mühendislik Fakültesi, Kırıkkale Üniversitesi, 71450 Kırıkkale  
[turanguenes19@gmail.com](mailto:turanguenes19@gmail.com), [polat@kku.edu.tr](mailto:polat@kku.edu.tr)

(Geliş/Received: 17.08.2007 ; Kabul/Accepted: 02.02.2009)

## ÖZET

Yüz ifadeleri, insan ilişkilerinde anlam bütünlüğünün sağlanması için büyük rol oynayan, sözlü olmayan işaretlerdir. İnsanoğlu yüz ifadelerini kavramada herhangi bir zorluk çekmezken, bu durum makineler için geçerli olmayıp, halen güvenilir ifade tanıma sistemleri üzerinde araştırmalar yapılmaktadır. Bu çalışmada, insanın içinde bulunabileceği 7 ifade durumunun (öfke, iğrenme, korku, mutluluk, ifadesizlik, üzüntü ve şaşkınlık) analizi gerçekleştirilmiştir. Bu amaçla, her bir ifade için alınan sabit görüntülerin öznelikleri Gabor filtreleri kullanılarak çıkartılmış ve farklı öznelik seçme algoritmaları kullanılarak ifadeleri temsil eden en iyi öznelik kümeleri oluşturulmuştur. Seçilen öznelik kümelerinin çoklu SVM (Support Vector Machines-Destek Vektör Makineleri) sınıflandırıcıları üzerindeki etkileri incelenmiş ve sınıflandırma doğruluklarının kullanılan öznelik seçme algoritmalarına göre nasıl değiştiği karşılaştırmalı olarak değerlendirilmiştir. Çoklu sınıflandırma yapılması amacıyla SVM, One-Vs-One, One-Vs-Rest ve MC-SVM olmak üzere 3 farklı yaklaşım ile birlikte kullanılmıştır. Ayrıca öznelik seçimi yapılmadan alınan sınıflandırma başarımları sonuçları da incelendiğinde, öznelik seçiminin sınıflandırma doğruluğunun artması yönünde genel olarak büyük etkisinin olduğu görülmüştür.

**Anahtar Kelimeler:** Yüz ifade analizi, öznelik çıkartma, Gabor filtresi, öznelik seçme, SVM, sınıflandırma.

## FEATURE SELECTION IN FACIAL EXPRESSION ANALYSIS AND ITS EFFECT ON MULTI-SVM CLASSIFIERS

### ABSTRACT

Facial expressions are non-verbal signs that play important role to provide complete meaning in human communication. While humans can easily comprehend the facial expressions, it is not valid for the computers, thus the researchers are still working on developing reliable facial expression recognition systems. In this research, the analysis of 7 different human facial expressions (anger, disgust, fear, happiness, neutral, sadness and surprise) is performed from human facial images. For this purpose, the features for every facial expression are extracted using Gabor filters. The feature sets that best represent the facial expressions are obtained using different feature selection algorithms. The effects of selected feature sets on the multi-class Support Vector Machine (SVM) classifiers are investigated and a comparative evaluation for classification results is given for each algorithm. For the multi-class classification, the SVM classifier is used with three different approaches including One-Vs-One, One-Vs-Rest and Multi-class SVM. It is also shown that classification rates are increased when the selected features are used.

**Keywords:** Facial expression analysis, feature extraction, gabor filter, feature selection, support vector machines, classification.

### 1. GİRİŞ (INTRODUCTION)

Herhangi bir yüz ifadesi, bir insanın hissi durumunun, anlayış tavrının, karakterinin ve içinde bulunduğu

psikolojik durumunun görünen belirtileri [1] olup aynı zamanda insanlar arası ilişkilerde bir haberleşme aracı olma rolü vardır. Mehrabian [2], yüz ifadelerinin dinleyiciler üzerinde çok büyük etkisinin olduğunu

belirtmiştir ki, bu etkilerin yaklaşık %55'i konuşmacının açıklamalarındaki yüz ifadelerinden, %38'i konuşmadaki kelime tonlamalarından ve %7'si de konuşulan kelimelerden kaynaklanmaktadır.

1872'de Charles Darwin [3] insanlar ve hayvanlarda doğuştan gelen bazı duyguların bulunduğunu ve duyguların yüz ifadeleri şeklinde ortaya çıktığını belirtmiştir. Yüz ifade analizi üzerine yapılmış olan bu ilk çalışmadan sonra 1971'de, Ekman ve Friesen [4] 6 temel duygu olduğunu ve her bir duygunun da farklı bir yüz ifadesi taşıdığını ifade etmişlerdir. Farklı kültür ve milletler için geçerli kabul edilmiş olan bu duygular "öfke", "iğrenme", "korku", "mutluluk", "üzüntü" ve "şaşkınlık" olarak gösterilmiştir.

Sabit görüntülerin ve görüntü dizilerinin kullanılmasıyla birlikte yüz ifade analizi, sadece psikoloji alanında yapılan bir araştırma konusu olmaktan çıkmıştır. Bununla birlikte görüntülerde yüz bulma (face detection), yüz takip etme (face tracking) ve yüz tanıma (face recognition) alanındaki ilerlemeler, yüz ifade analizi üzerine yapılan çalışmaların artmasına sebep olmuştur.

Yüz ifadeleri biçimsel olarak yüzdeki belirli bölgelerin şekil değiştirmesi ile ortaya çıkmaktadır. Özellikle yüz kaslarının kasılarak göz kapakları, kaşlar, burun, dudaklar ve yüz derisi gibi yüz özniteliklerinde geçici değişimler oluşturması sonucu ortaya çıkan zamana bağımlı ve birkaç saniye süren bu değişimlerin yeri, yoğunluğu ve dinamiğinin ölçülmesi, yüz ifadelerinin tanınarak sınıflandırılması için önem taşıyan niteliklerdir. Bu değişimlerin kişiye, yaşa, ırka, cinsiyete göre miktar ve zaman olarak değişim göstermesi, problemi çok boyutlu hale getirip zorlaştırmaktadır [5].

Pantic ve Rothkrantz [6] yüz ifade analizi çalışmalarında karşılaşılan 3 temel problem tanımlamışlardır: bir görüntüdeki yüz kısmının belirlenmesi, yüz ifadelerine ait özniteliklerin çıkartılması ve yüz ifadelerinin sınıflandırılması. Literatürde yapılan çalışmalar da bu 3 temel problem için en iyi çözüm yollarının bulunması üzerine olmuştur. Kotsia ve Pitas [7] görüntü dizilerinden yüz ifade analizini destek vektör makineleri kullanarak gerçekleştirmiştir. Çalışmalarında, dizideki ilk görüntü üzerine yerleştirilen noktalar referans alınıyor ve sonraki görüntülerle olan yer değiştirmeye göre ifade sınıflandırması yapıyordu. Otsuka [8] 6 farklı yüz ifadesini sınıflandırmak amacıyla Hidden Markov Model (HMM) temelli sınıflandırıcılar kullanmıştır. Bartlett vd. [9], ifade analizi için Gabor özniteliklerini kullandıkları çalışmalarında yeni geliştirdikleri AdaSVM metodunu önermişler ve Cohn and Kanade yüz ifade veri seti için oldukça başarılı sonuçlar almışlardır.

Her ne kadar Pantic ve Rothkrantz [6] tarafından tanımlanmış 3 temel problemden "yüz ifadelerine ait özniteliklerin çıkartılması"nın bir parçası olsa da

"öznitelik seçilmesi", ifade sınıflandırması için üzerinde sürekli çalışmalar yapılan bir araştırma konusu olmuştur. Yapılan çalışmada da seçilen özniteliklerin ifade analizi için en fazla bilgi taşıyanların belirlenmesi amacıyla iki farklı öznitelik seçme yaklaşımı uygulanmıştır. Yaklaşımların ortak özelliği, çoklu sınıflandırma probleminin ikili sınıflandırma problemine dönüştürülerek öznitelik seçiminin uygulanması ve ardından seçilen özniteliklerin birleştirilerek sınıflandırma için kullanılmasıdır.

Çalışmanın izleyen kısımlarında yüze ait özniteliklerin çıkartılması ve özniteliklerin çıkartılmasında uygulanan yöntem Bölüm 2'de, öznitelik seçilmesi ve kullanılan öznitelik seçme algoritmaları üzerine bilgiler Bölüm 3'de verilmiştir. Deneysel çalışmaların anlatıldığı Bölüm 4'te ise yüz ifade veri seti, öznitelik seçme yaklaşımları ve alınan deneysel sonuçlara değinilmiştir. Son olarak Bölüm 5'te çalışma üzerine genel bir değerlendirme yapılmıştır.

## 2. YÜZ ÖZİNTELİKLERİNİN ÇIKARTILMASI (FACIAL FEATURE EXTRACTION)

Yüz görüntülerine ait öznitelikler, diğer yöntemlere göre daha üstün performans gösteren [1] Gabor filtreleri kullanılarak elde edilmiştir. Çünkü Gabor filtreleme sonucunda, görüntüde var olan ışık dağılımının homojen olmamasının oluşturduğu negatif etkiler yok olmaktadır. Ayrıca Gabor filtreleri, küçük miktardaki yer değiştirme ve deformasyonlara karşı az duyarlıdır.

### 2.1. Gabor Filtresi (Gabor Filter)

Gabor filtresi, görüntü işleme ve bilgisayarla görme alanında özellikle öznitelik çıkarımında (feature extraction) yaygın olarak kullanılan bir tekniktir [10]. Matematiksel olarak 2 boyutlu karmaşık Gabor fonksiyonu;

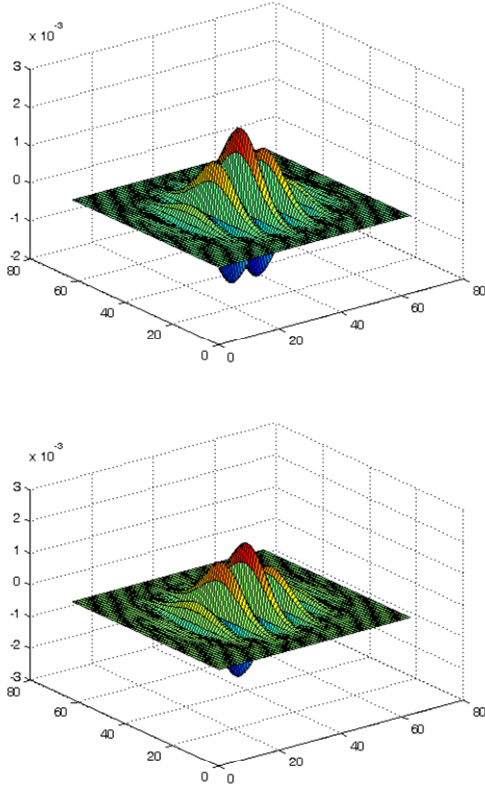
$$g(x, y) = \frac{1}{2\pi\sigma_x\sigma_y} \exp\left[-\frac{1}{2}\left(\frac{\tilde{x}^2}{\sigma_x^2} + \frac{\tilde{y}^2}{\sigma_y^2}\right)\right] \exp[j2\pi f \tilde{x}] \quad (1)$$

$$\tilde{x} = x \cos \theta + y \sin \theta$$

$$\tilde{y} = -x \sin \theta + y \cos \theta$$

biçiminde ifade edilir [10]. Burada  $\sigma_x$  ve  $\sigma_y$  sırasıyla  $x$  ve  $y$  eksenleri boyunca Gauss zarfının standart sapmalarıdır.  $\theta$  ( $\theta \in [0, \pi)$ ), Gabor filtresinin yönelimini belirtir ve  $f$  sinusoidal dalganın frekansıdır. Şekil 1'de uzay bölgesindeki karmaşık Gabor fonksiyonunun reel ve sanal kısımları görülmektedir.

Değişik açı ve frekanslar kullanılarak değişik niteliklere sahip özniteliklerin elde edilebilmesi amacıyla Gabor filtrelerinden oluşan bir filtre bankası oluşturulabilir.



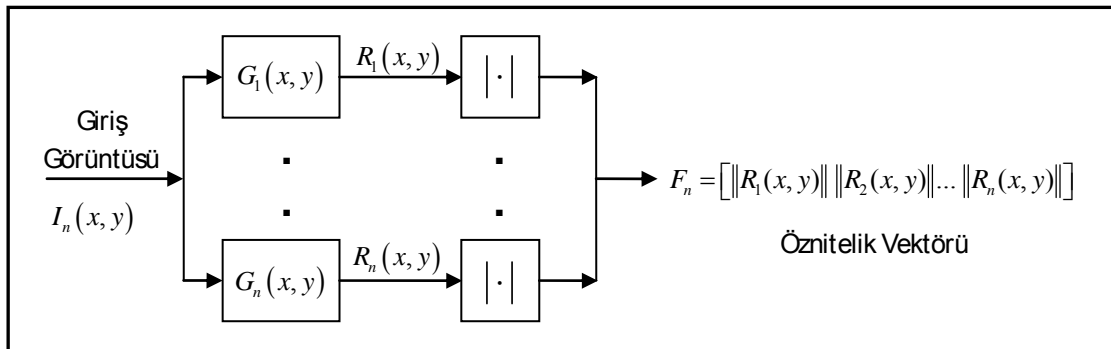
**Şekil 1.** Kompleks Gabor Fonksiyonunun Reel (Üst) ve Sanal (Alt) Kısımları (Real (top) and Imaginary (bottom) Part of the Complex Gabor Function)

Bu çalışmada  $30^\circ$  aralıklarla 6 açı ( $0^\circ$ ,  $30^\circ$ ,  $60^\circ$ ,  $90^\circ$ ,  $120^\circ$ ,  $150^\circ$ ) ve 1 oktav aralıklarla 3 frekans (4, 8, 16 piksel/cycle) için toplam 18 adet Gabor filtresinden oluşan Gabor filtre bankası oluşturulmuştur. Bir görüntü, Gabor filresiyle işleme tabi tutulduğunda, elde edilen çıkış, giriş görüntüsü  $I(x, y)$  ile Gabor fonksiyonu  $G_n(x, y)$  'nin;

$$R_n(x, y) = I_n(x, y) * G_n(x, y) \quad (2)$$

şeklindeki konvolüsyondur. Burada “\*” iki boyutlu konvolüsyonu belirtir.

Öznitelik vektörü Şekil-2’den görüleceği üzere filtrelenmiş görüntülerin genliğinden elde edilmiştir.



**Şekil 2.** Gabor Filtre Bankası Sistemi (Gabor Filter Bank System)

Herhangi bir giriş görüntüsü  $I_n(x, y)$  ile her karmaşık Gabor fonksiyonu  $G_n(x, y)$  'nin konvolüsyonundan elde edilen sonuç olan  $R_n(x, y)$ , reel ve sanal olmak üzere iki kısımdan oluşur. O halde öznitelik vektörünün elde edilmesi için bu sonucun genliği  $\|R_n(x, y)\|$ ;

$$\|R_n(x, y)\| = \sqrt{\Re^2\{R_n(x, y)\} + \Im^2\{R_n(x, y)\}} \quad (3)$$

olarak elde edilir.

### 3. ÖZİNTELİK SEÇME (FEATURE SELECTION)

Gabor filtreleme sonucu elde edilen özniteliklerin tamamı yüz ifade analizi için gerekli olmayıp ifade sınıflandırması için önemi ve yararı olmayan bilgiler içermektedirler. Dolayısıyla önemli özniteliklerin seçilmesi kullanılan sınıflandırma algoritmalarının hızlı çalışmasını, zaman kazancını ve belleğin gereksiz yere kullanılmamasını sağlayacaktır. Öznitelik seçilmesi sonucu boyutu azalan veri ideal olarak, yüksek ayırım gücü ve yüksek güvenilirliğe sahip esas bilgiyi korumalıdır. Bu boyut azalması literatürde “curse of dimensionality” [11] olarak bilinen “boyutun laneti” sorununu da hafifletebilir. Böylelikle iyi sınıflandırma performanslı daha basit ve anlaşılabilir sınıflandırma modellerinin oluşması sağlanır.

Denetimli öznitelik seçim metotları, Filtre Metotları (Filter Methods) ve Sarmalama Metotları (Wrapper Methods) [12] olmak üzere iki gruba ayrılırlar. Sarmalama metodu algoritmalarında, seçme metodu bir spesifik tahmin edicinin (algoritma) performansını doğrudan optimal yapma amacına yöneliktir. Bu, her bir adımda seçilen öznitelikler için tahmin edicinin genel performansının ölçülmesiyle yapılabilir. Filtre metodu algoritmalarında seçim, spesifik tahmin edicinin performansının doğrudan optimal yapılması hedeflenmeden, bir önışlem gibi yapılır. Filtre metodunda genel olarak öznitelikler hedefle güçlü bir ilişki içinde olmalıdır. Buradan hedefle en çok doğrusal ilişki içinde olan öznitelikler veya hedefle en yüksek ortak bilgili (Mutual Information) öznitelikler seçilir. Buna göre, bir özneliğin incelenen

problemdaki önemi belirlenir ve önemsiz olan öznitelikler atılarak öznitelik sayısı azaltılmış olur [13]. Çoğu örüntü tanıma (pattern recognition) uygulamalarında sarmalama metodu algoritmaları, filtre metodu algoritmalarına göre üstün performans göstermiştir. Fakat sarmalama metodu algoritmaları filtre metodu algoritmalarıyla karşılaştırıldığında hesaplama bakımından çok daha zahmetlidir.

Bu çalışmada, öznitelik seçimi için 2 adet sarmalama metodu algoritması (“Sıfırıncı Norm Öznitelik Seçimi” ve “Yinelemeli Öznitelik Eliminasyonu”) ile 1 adet filtre metodu algoritması (“Ortak Bilgi Temelli Öznitelik Seçimi”) kullanılmıştır. Bu algoritmalar SPIDER [14] paket programı kullanılarak MATLAB ortamında gerçekleştirilmiştir.

### 3.1. Sıfırıncı-Norm Öznitelik Seçimi (Zero Norm Feature Selection – L0)

Öznitelik seçimi, Weston vd. [15]'ye göre;

$$\min_{w \in \mathbb{R}^n} \|w\|_p \quad (4)$$

$$y_i (w \cdot x_i + b) \geq 1 \text{ ve } \|w\|_0 \leq r$$

biçiminde yapılabilir. Burada  $p = \{1, 2\}$  ve istenilen öznitelik sayısı  $r$ 'dir.  $\ell_2 - AROM$  veya  $\ell_1 - AROM$  metotları kullanılarak sıfırıncı-norm minimize edilerek ve  $\|w\|_0 \leq r$  kısıtı ile karşılaşıldığı zaman adım adım minimizasyon durdurulmak suretiyle, bu metot yaklaşık olarak yapılabilir [15]. Herhangi biri  $w$ 'nun sıfırdan farklı elemanları olan öznitelikler üzerindeki  $p$ -norm sınıflayıcısını eğitebilir. Bu durumda, sınıflayıcının kaç tane özniteliği kullanacağını dikte eden  $r$  parametreyi seçmekte kişi özgüdür.

### 3.2. Yinelemeli Öznitelik Elemesi (Recursive Feature Elimination - RFE)

RFE öznitelik seçim algoritması [16], sonuncu karar kuralında yalnızca  $r < n$  girdi boyutlarını sağlanması için, en iyi altküme  $r$ 'yi bulmaya çalışmaktadır. Algoritma, sınıf ayırımının en büyük sınırına (marjin) yol açan  $r$  özniteliği seçmeye çalışarak, bir SVM (Support Vector Machines-Destek Vektör Makineleri) sınıflayıcısının kullanımını işletmektedir. Bu tümleşik problem, marjini sadece  $r$  girdi boyutu kalıncaya kadar en düşüğe indiren girdi boyutunu çıkararak, eğitimin her iterasyonundaki Greedy Fashion'da çözülmektedir (Bu geriye dönük seçim olarak bilinir).

### 3.3. Ortak Bilgi Temelli Öznitelik Seçimi (Mutual Information Based - MUTINF)

Ortak bilgi ( $I$ ), ayrık rasgele değişkenlerin stokastik (olasılıksal) bağımlılık için kuramsal bilgi ölçümünde yaygın olarak kullanılmaktadır. Filtre yaklaşımı

çerçevesinde, küçük bir öznitelik alt kümesi bulmak amacıyla önemsiz özniteliklerin çıkarılması için ortak bilgi kullanılabilir.  $X$  ve  $Y$  gibi iki ayrık rastgele değişkenin ortak bilgisi;

$$I(X;Y) = \sum_{y \in Y} \sum_{x \in X} p(x,y) \log \frac{p(x,y)}{p(x)p(y)} \quad (5)$$

olarak tanımlanır. (5) denkleminde  $p(x,y)$ ,  $X$  ve  $Y$ 'nin birleşik olasılık dağılım fonksiyonu,  $p(x)$  ve  $p(y)$ 'de sırasıyla  $X$  ve  $Y$ 'nin marjinal olasılık dağılım fonksiyonlarıdır. Yukarıda verilen toplam, sürekli zamanda iki katlı belirli integral ile;

$$I(X;Y) = \int \int p(x,y) \log \frac{p(x,y)}{p(x)p(y)} dx dy \quad (6)$$

olarak tanımlanır. Bu ifadede olasılıklar veri setinden ve sınıf dağılımından hareketle bulunur. Yapılan çalışmada Zaffalon ve Hutter [17] tarafından gerçekleştirilen ortak bilgi temeli uygulaması öznitelik seçiminde kullanılmıştır.


## 4. DENEYSEL ÇALIŞMALAR

### 4.1. Yüz İfade Veri Seti (Facial Expressions Database)

Bu çalışmada yüz ifade analizi için Cohn and Kanade DFAT-504 [18] veri setinden alınan görüntüler kullanılmıştır. Bu veri seti, yaşları 18-30 arasında değişen 100 üniversite öğrencisinden oluşmaktadır. Öğrencilerin %65'i bayan, %15'i zenci ve %3'ü Uzak Doğu ve Latin kökenlidir. Görüntüler, analog S-video kamera ile kişilerin ön taraflarından kaydedilmiştir. Kişilerden 23 tane yüz ifadesi yapmaları istenmiştir. Görüntüler 640x480 veya 640x490 piksel boyutlarında ve 8-bit gri tona sahiptir.

Çalışmamızda bu veri setinden alınan görüntüler her biri farklı duygusal içerik taşıyan 7 temel yüz ifadesine (öfke – anger, iğrenme – disgust, korku – fear, mutluluk – happiness, ifadesizlik – neutral, üzüntü – sadness ve şaşkınlık – surprise) göre sınıflandırılmıştır. Veri setinde farklı kişilere ait görüntülerin bulunduğu klasörlerdeki ilk resim o kişiye ait ifadesizlik durumunu, son resim ise diğer 6 ifadeden herhangi birinin en çok belirgin olduğu durumu nitelemektedir. Yapılan çalışmada farklı kişilere ait görüntülerin ilk ve son resimleri alınmış ve toplam 322 tane görüntü kullanılmıştır.

Yüz ifade analizinde bir görüntünün sadece ifadeyi taşıyan kısmı yani yüz bölgesi önemlidir. Buna göre, daha önceden 7 adet ifade sınıfı klasörüne göre sınıflandırılan görüntülerin yüz kısımları el ile ayrıştırılmış ve elde edilen yeni yüz görüntüleri 24x24 piksel boyutlarına indirgenmiştir (Şekil 3). Bu



**Şekil 3.** Bir görüntü ve yüz kısmının ayrıştırılmış hali (An Image and Its Facial Section)

durumda, öznitelik çıkartılmasında 24x24 boyutundaki her bir görüntü için 6 farklı açı (0°, 30°, 60°, 90°, 120°, 150°) ve 3 farklı frekansta (4, 8, 16 piksel/cycle) Gabor filtreleri kullanıldığından toplam  $24 \times 24 \times 6 \times 3 = 10368$  tane öznitelik elde edilmiş olacaktır. Görüntülerin 24x24 piksel boyutlarına indirgenmesi ile işlem fazlalığı azaltılmış ve belleğin gereksiz yere kullanılmaması sağlanmıştır.

İfade tasviri, bir görüntünün baş kısmının konumunun yer değiştirmesi, ölçeklendirilmesi ve döndürülmesine karşı hassas olabilir. Bu tür istenmeyen durumların etkisini ortadan kaldırmak için gözler veya burun delikleri referans alınır [5]. Bu yüzden yüz görüntülerinin elde edilmesi esnasında eğik duran görüntüler düzeltilmiş ve tüm yüz görüntüleri olabildiğince göz hizalı olacak şekilde el ile ayarlanmıştır.

#### 4.2. Öznitelik Seçme Yaklaşımları (Feature Selection Approaches)

Öznitelik seçimi için kullanılacak veri dosyaları iki farklı yaklaşıma göre oluşturulmuştur. Bu yaklaşımlar çoklu sınıflandırma probleminin, One-Vs-Rest ve One-Vs-One biçiminde ifade edilen ikili sınıflandırma problemi olarak formüle edilmesine dayanmaktadır. One-Vs-Rest yaklaşımına göre, ikili sınıflandırma problemi, ifade sınıflarından birinin diğerlerinden ayrıştırılması biçiminde ifade edilir. Dolayısıyla  $k$  ifade sınıfı için oluşabilecek veri dosya sayısı da  $k$ 'nın birli kombinasyonu kadar ( $k$ ) olacaktır. Çalışmada 7 yüz ifadesinin analizi yapıldığından, sınıflandırma probleminin çözümü için gereken veri dosyaları Tablo 1'de gösterildiği üzere 7 adet ikili sınıflandırma problemi olarak ifade edilir.

One-Vs-One yaklaşımına göre ise, ikili sınıflandırma problemi yüz ifade sınıflarından birinin diğerinden ayrıştırılması biçiminde ifade edilir. Bu durumda yine

**Tablo 1.** One-Vs-Rest yaklaşımına göre oluşturulan veri dosyaları (Data Files for One-Vs-Rest Approach)

Öfke	–	Diğerleri
İğrenme	–	Diğerleri
Korku	–	Diğerleri
Mutluluk	–	Diğerleri
İfadesizlik	–	Diğerleri
Üzüntü	–	Diğerleri
Şaşkınlık	–	Diğerleri

$k$  ifade sınıf sayısını göstermek üzere, ikili sınıflandırma problemi sayısı  $k$ 'nın ikili kombinasyonu ( $k(k-1)/2$ ) kadar olacaktır. O halde, bu çalışmada  $k = 7$  olmak üzere toplam 21 tane ikili sınıflandırma problemi meydana gelir ve bunlara karşılık gelen veri dosyaları Tablo 2'de gösterilmiştir.

One-Vs-Rest için oluşturulan veri dosyalarından her bir öznitelik seçme algoritması için toplam 7 tane öznitelik alt kümesi elde edilir. Herhangi bir öznitelik seçme algoritması için seçilen öznitelik alt kümeleri;

$$S_i = \{j[i] \text{-Diğerleri veri dosyasından seçilen öznitelik alt kümesi}\};$$

$$i = 1, 2, \dots, 7$$

$$j[i] = \{\text{Öfke, İğrenme, Korku, Mutluluk, İfadesizlik, Üzüntü, Şaşkınlık}\}$$

biçiminde olacaktır. Bu öznitelik alt kümeleri 2 farklı biçimde birleştirilerek, sınıflandırılmak üzere kullanılacak öznitelik veri setleri oluşturulur.

SET1 olarak ifade edilen ilk veri seti, ( $S_1, S_2, S_3, S_4, S_5, S_6, S_7$ ) altkümelerinin en az ikisinde görülen öznitelikleri içermektedir ve tanımsal olarak bu alt kümelerinin kendi aralarındaki “tüm ikili kesişimlerinin birleşimi” olarak ifade edilir.

Matematiksel olarak;

$$SET1 = \bigcup_{\substack{i=1, \dots, T-1 \\ j=(i+1), \dots, T \\ i \neq j}} (S_i \cap S_j) \quad (7)$$

**Tablo 2.** One-Vs-One yaklaşımına göre oluşturulan veri dosyaları (Data Files for One-Vs-One Approach)

Öfke	–	İğrenme	İğrenme	–	Mutluluk	Korku	–	Şaşkınlık
Öfke	–	Korku	İğrenme	–	İfadesizlik	Mutluluk	–	İfadesizlik
Öfke	–	Mutluluk	İğrenme	–	Üzüntü	Mutluluk	–	Üzüntü
Öfke	–	İfadesizlik	İğrenme	–	Şaşkınlık	Mutluluk	–	Şaşkınlık
Öfke	–	Üzüntü	Korku	–	Mutluluk	İfadesizlik	–	Üzüntü
Öfke	–	Şaşkınlık	Korku	–	İfadesizlik	İfadesizlik	–	Şaşkınlık
İğrenme	–	Korku	Korku	–	Üzüntü	Üzüntü	–	Şaşkınlık

biçiminde gösterilir. Burada  $T$ , ikili sınıflandırma problemi sayısını temsil etmekte olup, bu çalışmada  $T$  değeri 7 olacaktır.

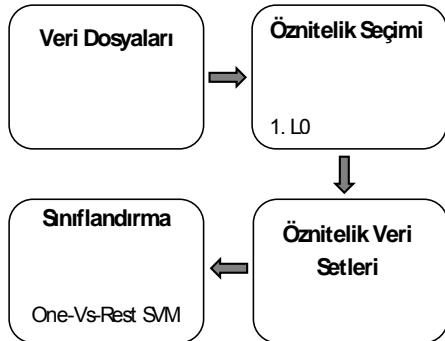
İkinci veri seti de,  $(S1, S2, S3, S4, S5, S6, S7)$  alt kümelerinin birleşimi olarak tanımlanır ve  $SET2$  biçiminde adlandırılır.  $SET2$  matematiksel olarak;

$$SET2 = \bigcup_{i=1}^T S_i ; T = 7 \quad (8)$$

biçiminde gösterilir.

One-Vs-Rest yaklaşımında olduğu gibi One-Vs-One yaklaşımında da, her bir öznitelik seçme algoritması için toplam 21 tane alt öznitelik kümesi elde edilir. Bu alt öznitelik kümeleri de yine iki farklı biçimde ( $SET1$  ve  $SET2$ ) birleştirilerek, sınıflandırılmak üzere kullanılacak öznitelik veri kümesi oluşturulur.

One-Vs-Rest için 7 ve One-vs-One için 21 adet veri dosyasının her birinden ayrı ayrı 500 adet öznitelik seçilmiş ve bunlar, One-Vs-Rest için  $SET1/SET2$  ve One-Vs-One için  $SET1/SET2$  ikilileri biçiminde oluşturulmuşlardır. One-Vs-Rest ve One-Vs-One yaklaşımları için ayrı ayrı elde edilen  $SET1$  ve  $SET2$  veri kümeleri yüz ifadelerinin SVM ile sınıflandırılmasında kullanılmıştır. Her iki yaklaşım için öznitelik seçiminden sınıflandırmaya kadar olan işlemler Şekil 4'deki blok diyagramla özetlenebilir.



**Şekil 4.** Öznitelik seçimi kullanıldığında yüz ifade analizi blok diyagramı (Block Diagram of the Facial Expression Analysis When Feature Selection is Used)

#### 4.3. Yüz İfade Sınıflandırması (Facial Expression Classification)

$SET1$  ve  $SET2$  öznitelik veri kümeleri oluşturulduktan sonra, çoklu ifade sınıflandırılması için SVM [19] kullanılmıştır. Bu amaçla SVM, hem çoklu sınıflandırma (Multi-Class SVM=MC-SVM) hem de çoklu sınıflandırma probleminin One-Vs-One (bir sınıfın diğer bir sınıftan ayrılması) ve One-Vs-Rest (bir sınıfın diğer sınıflardan ayrılması) ikili sınıflandırma problemi çözüm yaklaşımları biçiminde olmak üzere 3 şekilde kullanılmıştır. Ayrıca tüm

SVM sınıflandırıcıları RBF (Radial Basis Function) kernel [20] ile birlikte kullanılmıştır. RBF kernel parametreleri  $C$  ve  $\gamma$ 'nın veri seti için en uygun değerlerinin seçimi amacıyla, çapraz geçerlilik (cross-validation-CV) tekniği kullanılmıştır. Bu amaçla, çalışmada 5-fold için cross-validation tekniği kullanılarak, SVM sınıflandırıcısında en düşük sınıflandırma hatasını veren  $C$  ve  $\gamma$  parametrelerinin değerleri sırasıyla 10 ve 16 olarak bulunmuştur.

SVM sınıflandırıcıları herhangi bir öznitelik seçimi yapılmadan doğrudan 7 yüz ifadesinin sınıflandırılmasında kullanılmış ve elde edilen sınıflandırma başarımları cross-validation hata ve standart sapma cinsinden Tablo 3'de verilmiştir.

**Tablo 3.** Öznitelik seçimi yapılmadan elde edilen "Sınıflandırma Başarımları" (Classification Performances for No Feature Selection)

Sınıflandırma Algoritması	CV hata	Standart Sapma
One-Vs-One SVM	0.2143	0.0124
One-Vs-Rest SVM	0.1676	0.0128
Multi-Class SVM	0.2233	0.0203

Görüldüğü üzere en iyi sınıflandırıcı başarımları SVM'nin One-Vs-Rest yaklaşımı ile kullanıldığı durumda elde edilmiştir. Literatürde de, yapılan bu çalışmada elde edilen sonuçları destekleyecek yönde sonuçların alındığı görülebilir [21, 22, 23].

Öznitelik seçimi yapıldıktan sonra elde edilen sonuçlar; öznitelik seçimi için kullanılan veri dosyalarının oluşturulma yapılarının (One-Vs-Rest ve One-Vs-One), öznitelik veri kümelerinin ( $SET1$  ve  $SET2$ ) ve öznitelik seçme algoritmalarının (L0, RFE, MutInf) karşılaştırılması göz önüne alınarak değerlendirilmiştir. Değerlendirme, sınıflandırıcı başarımlarının ortalama CV hata ve standart sapma sonuçlarına göre yapılmıştır.

Tablo 4'de özniteliklerin seçtikleri veri dosya yapılarına göre elde edilen sınıflandırıcı başarımları, ortalama CV hata ve standart sapma cinsinden görülmektedir. Hata değerlerinden görüleceği üzere, ifade sınıflandırılmasında, One-Vs-Rest yaklaşımına göre oluşturulan veri dosyalarından seçilen öznitelikler, One-Vs-One yaklaşımına göre oluşturulan veri dosyalarından seçilen özniteliklere göre daha başarılıdır.

Tablo 5'de öznitelik oluşturma yapısına göre elde edilen  $SET1$  ve  $SET2$  veri kümelerinin sınıflandırma üzerindeki etkileri bulunmaktadır. Görüldüğü üzere, seçilen öznitelik alt kümelerinin birleşimi şeklinde oluşturulan  $SET2$  veri kümesi ile sınıflandırma başarımında çok daha doğru sonuçlar alınmıştır.

**Tablo 4.** Özniteliklerin seçildikleri dosya yapıları için ortalama SVM sınıflandırıcı başarımları (Average SVM classification performances for the file structures used for feature selection)

Özniteliklerin Seçildiği Dosya Yapısı	SINIFLANDIRICI BAŞARIMI					
	One-Vs-One SVM		One-Vs-Rest SVM		Multi-Class SVM	
	Ortalama CV Hata	Standart Sapma	Ortalama CV Hata	Standart Sapma	Ortalama CV Hata	Standart Sapma
One-Vs-Rest	0.1744	0.0125	0.1635	0.0170	0.1831	0.0161
One-Vs-One	0.1789	0.0135	0.1702	0.0157	0.1949	0.0164

**Tablo 5.** SET1 ve SET2 veri kümelerinin ortalama SVM sınıflandırıcı başarımları (Average SVM Classification Performances of the SET1 & SET2 Data Sets)

Öznitelik veri kümesi	SINIFLANDIRICI BAŞARIMI					
	One-Vs-One SVM		One-Vs-Rest SVM		Multi-Class SVM	
	Ortalama CV Hata	Standart Sapma	Ortalama CV Hata	Standart Sapma	Ortalama CV Hata	Standart Sapma
SET1	0.1847	0.0139	0.1718	0.0179	0.1904	0.0135
SET2	0.1686	0.0121	0.1619	0.0148	0.1877	0.0189

Kullanılan öznitelik seçme algoritmalarının sınıflandırıcı başarımları üzerindeki etkileri ise Tablo 6'da verilmiştir.

**Tablo 6.** Öznitelik seçme algoritmaları için SVM sınıflandırıcı başarımları (SVM Classification Performances for Feature Selection Algorithms)

Öznitelik Seçme Algoritması	Ortalama CV Hata	Standart Sapma
L0	0.1738	0.0156
RFE	0.1642	0.0152
MUTINF	0.1945	0.0148

Buradan yüz ifade sınıflandırılması probleminde RFE algoritması ile seçilen öznitelikler en düşük sınıflandırma hatasını verdiği için; RFE, kullanılan diğer öznitelik seçme algoritmaları içinde en etkili olanıdır. MutInf algoritması ise yapılan bu çalışma için tüm sonuçlar göz önüne alındığında sınıflandırma başarımları bakımından kötü performans göstermektedir.

## 5. SONUÇLAR (CONCLUSION)

Bu çalışmada yüz ifade sınıflandırmasında kullanılmak üzere seçilen özniteliklerden en fazla ayırt edici olanların belirlenmesi amacıyla 2 farklı yaklaşım uygulanmıştır. Alınan sınıflandırıcı başarımlarından ilk yaklaşıma göre (One-vs-Rest) oluşturulan veri dosyalarından seçilen özniteliklerin, ikinci yaklaşıma göre (One-Vs-One) oluşturulan veri dosyalarından seçilen özniteliklere nazaran sınıflandırma başarımlarında daha etkili olduğu gözlenmiştir. Bu durum, One-Vs-Rest veri dosyalarından, öznitelik seçiminde, her bir ifade sınıfını diğer sınıflardan ayıran özniteliklerin bulunabildiğinin göstergesidir. Seçilen öznitelik alt kümelerinin birleşimi şeklinde oluşturulan SET2 veri kümesi ile tüm çoklu SVM sınıflandırıcılar için çok daha doğru sonuçlar alınmıştır. Öznitelik seçme algoritmalarından en düşük CV hatanın alındığı RFE algoritması (Tablo 6)

kullanılan diğer algoritmalara göre daha başarılı olmuştur. Öznitelik seçimi yapılmadan elde edilen sonuçlarla (Tablo 3), öznitelik seçimi yapıldıktan sonra elde edilen sonuçlar (Tablo 4 ve 5) karşılaştırıldığında ise, öznitelik seçiminin sınıflandırma hatalarını azaltmada çok yararlı olduğu gözlenmiştir. Buradan, bu çalışmada olduğu gibi öznitelik sayısının çok fazla olduğu uygulamalarda öznitelik seçiminin ne kadar önemli ve gerekli olduğu sonucu çıkarılabilir. Ayrıca, gerek öznitelik seçimi yapılmadan, gerekse de öznitelik seçimi yapıldıktan sonra çoklu ifade sınıflandırılmasında en iyi sonuç, SVM'nin One-Vs-Rest yaklaşımı ile kullanıldığı durumda elde edilmiştir. SVM'nin çoklu sınıflandırma problemini çözmek amacıyla geliştirilmiş olan MC-SVM tipinin ise, çoklu sınıflandırma probleminin ikili sınıflandırma problemine dönüştürülmesi yoluyla çözülen One-Vs-One ve One-Vs-Rest yaklaşımlarına göre daha kötü sonuç verdiği görülmüştür. Dolayısıyla sınıflandırma problemlerinin SVM kullanılarak ikili sınıflandırma problemi biçiminde çözümlerinin daha doğru sonuçlar verdiği söylenebilir.

## TEŞEKKÜR (ACKNOWLEDGEMENT)

Bu çalışma, TÜBİTAK tarafından desteklenen 104E179 nolu proje kapsamında gerçekleştirilmiştir.

## KAYNAKLAR (REFERENCES)

1. Donato, G., Bartlett, M.S., Hager, J.C., Ekman, P. ve Sejnowski, T.J., "Classifying Facial Actions", **IEEE Trans. Pattern Analysis and Machine Intelligence**, Cilt 21, No 10, 974-989, 1999.
2. Mehrabian, A., "Communication without Words", **Psychology Today**, Cilt 2, No 4, 53-56, 1968.
3. Darwin, C., **The Expression of the Emotions in Man and Animals**, J. Murray, London, 1872.

4. Ekman, P. ve Friesen, W.V., “Constants Across Cultures in the Face and Emotion”, **Journal of Personality and Social Psychology**, Cilt 17, No 2, 124-129, 1971.
5. Chibulushi, C. C. ve Bourel, F., “Facial Expression Recognition: A Brief Tutorial Overview”, 2002.
6. Pantic, M. ve Rothkrantz, L.J.M., “Automatic Analysis of Facial Expressions: The State of Art”, **IEEE Trans. on PAMI**, Cilt 22, No 12, 1424-1445, 2000.
7. Kotsia, I. ve Pitas, I., “Real Time Facial Expression Recognition from Image Sequences using Support Vector Machines”, **Visual Communications and Image Processing**, China, 2005.
8. Otsuka, T. ve Ohya, J., “Spotting Segments Displaying Facial Expressions from Image Sequences Using HMM”, **IEEE Proc. International Conf. on FG**, Japan, 442-447, 1998.
9. Bartlett, M.S., Littlewort, G., Fasel, I., Susskind, J. ve Movellan, J., “Dynamics of Facial Expression Extracted Automatically from Video”, **Image and Vision Computing**, Cilt 24, No 6, 615-625, 2006.
10. [http://en.wikipedia.org/wiki/Gabor\\_filter](http://en.wikipedia.org/wiki/Gabor_filter)
11. Jain, A. K., Duin, R. P. W. Ve Mao, J., “Statistical Pattern Recognition : A Review”, **IEEE Trans. Pattern Analysis and Machine Intelligence**, Cilt 22, No 1, 4-37, 2000.
12. Kohavi, R. ve John, G., “Wrapper for feature subset selection”, **Artificial Intelligence**, Cilt 97, 273-324, 1997.
13. [http://www.idiap.ch/~bengio/lectures/old/text\\_feat\\_sel.pdf](http://www.idiap.ch/~bengio/lectures/old/text_feat_sel.pdf)
14. Weston, J., Elisseeff, A., Bakır, G. ve Sinz, F., “The Spider”, <http://www.kyb.tuebingen.mpg.de/bs/people/spider>, 2004.
15. Weston, J., Elisseeff, A., Schölkopf, B. ve Tipping, M., “Use of the Zero-Norm with Linear Models and Kernel Methods”, **Journal of Machine Learning Research**, 3, 1439-1461, 2003.
16. Guyon, I., Weston, J., Barnhill, S. ve Vapnik, V., “Gene selection for cancer classification using support vector machines”, **Machine Learning**, 2001.
17. Zaffalon, M. ve Hutter, M., “Robust Feature Selection by Mutual Information Distributions”, **Proceedings of the 18<sup>th</sup> International Conference on Uncertainty in Artificial Intelligence**, 2002.
18. Kanade, T., Cohn, J. F. ve Tian, Y., “Comprehensive Database for Facial Expression Analysis”, **4th Int. Conf. on Automatic Face and Gesture Recognition**, France, 46-53, 2000.
19. Burges, C. J. C., “A Tutorial on Support Vector Machines for Pattern Recognition”, **Data Mining and Knowledge Discovery**, 1998.
20. Hsu, C. W., Chang, C.C. ve Lin, C. J., “A practical guide to support vector classification”, **Department of Computer Science and Information Engineering**, National Taiwan University, 2003.
21. Ben-Hur, A. ve Brutlag, D., “Sequence motifs: highly predictive features of protein function”, 2004.
22. Yeang, C.H., Ramaswamy, S., Tamayo, P., Mukherjee, S., Rifkin, R., Angelo, M., Reich, M., Lander, E., Mesirov, J. ve Golub, T., “Molecular classification of multiple tumor types”, **In Proceedings, 11th international conference on intelligent systems for molecular biology**, Cilt 17, suppl 1 of Bioinformatics, 316-322, 2001.
23. Rifkin, R. ve Klautau, A., “In defense of one-vs-all classification”, **Journal of Machine Learning Research**, 5, 101-141, 2004.