

# Yüz Nirengi Noktalarının Zamansal Öz-benzerliğine ve Kelime Çantasına Dayalı Yüz İfadesi ve Kafa Hareketi Tanıma

## Facial Expression and Head Gesture Recognition Using Temporal Self-similarity and Bag of Words of Facial Landmarks

İsmail Arı<sup>1</sup>, Hua Gao<sup>2</sup>, Hazım K. Ekenel<sup>2</sup>, Lale Akarun<sup>1</sup>

1. Bilgisayar Mühendisliği Bölümü  
Boğaziçi Üniversitesi, İstanbul, Türkiye  
{ismailar,akarun}@boun.edu.tr

2. Bilgisayar Bilimleri Bölümü  
Karlsruhe Teknoloji Enstitüsü, Karlsruhe, Almanya  
{hua.gao, ekenel}@ira.uka.de

### Özetçe

Yüz ifadeleri ve kafa hareketleriyle yapılan jestlerin otomatik tanınması, işaret dili tanıma ve insan bilgisayar etkileşimi gibi birçok alanda önemli bir değere sahiptir. Bu çalışmada, hareket tanımda başarısı gösterilen, takip noktalarının öz-benzerliğine dayalı yöntem, yüz ifadesi ve kafa hareketi jestlerini sınıflandırmak için adapte edilmiştir. Ayrıca, takip edilen yüz nirengi noktalarının histogramına dayalı, daha başarılı yeni bir yöntem önerilmiştir. Sunulan yöntemler Saklı Markov Modeli tabanlı çalışmamızla [1] birleştirilmiş ve sınıflandırma başarısında %15 artış sağlanmıştır.

### Abstract

Automatic recognition of facial expressions and head gestures plays an important role in a wide range of research area including sign language recognition and human-computer interaction. In this work, we adopt the well-performing self-similarity based action recognition method to classify facial expressions and head gestures. Additionally, we propose a novel approach for facial gesture recognition based on the histogram of tracked facial landmarks. We fuse the presented techniques with our previous Hidden Markov Model based approach [1] and get 15% increase in classification results.

### 1. Giriş

Yüz ifadesi ve kafa hareketlerinden oluşan jestlerin otomatik tanınması, bu jestlerin önemli rol oynadığı işaret dillerini tanıma [2] ve insan bilgisayar etkileşimi gibi birçok alanda merak edilen bir araştırma konusudur. Bu konuyu farklı açılardan irdeleyen birçok çalışma yürütülmüştür. Morency ve diğerleri, sağa-sola ve aşağı-yukarı kafa sallama hareketlerini tanıyan bir sistem geliştirmişlerdir [3]. Kafa pozunu takibiyle bulunan kafa rotasyon hızının frekans bilgilerini çıkarmışlar ve Destek Vektör Makineleri (DVM) ile sınıflandırma yapmışlardır. Zelinsky ve Heinzmann, özel donanım ve Kalman süzgeci yardımıyla 9 yüz noktasını takip etmiş, olasılıksal bir yöntemle kafanın belli yön hareketlerini, göz kırpmayı ve ağız kapama/açmayı tanımlamışlardır [4]. Kişinin konuşup konuşmadığını ayırt etmeyi amaçlayan Pantic ve

Rothkrantz ise yüzlerden 22 adet hareket birimi çıkararak yapay sinir ağları ile sınıflandırma yapmışlardır [5]. Fakat ilgili çalışmalar, yalnızca belli kafa hareketlerini kapsamakta, yüz ifadelerini hesaba katmamakta ve daha karmaşık jestleri içermemektedir. Öte yandan, yürütülen birçok yüz ifadesi tanıma araştırması ise kafa hareketi algılamayı içermemekte, özellikle duygusal ifadeleri tanımaya yoğunlaşmaktadır [6].

Kafa hareketi ve yüz ifadesi tanıma yöntemleri ile benzerlik gösterir. Her iki yöntem de, videolardan ilgili öznitelikleri çıkarıp problemi zaman serisi analizi problemine çevirmeyi amaçlar. Öz Benzerlik Haritası (ÖBH - Self Similarity Map), zaman serisindeki benzerlikleri gösteren bir matris olarak kullanılır ve ekonomi, psikoloji, sinirbilim, astrofizik ve mühendislik gibi birçok dalda yaygın kullanım alanlarına sahiptir [7]. Vücut hareketlerini sınıflandırmayı amaçlayan Junejo ve diğerleri de KLT takipçisi ve optik akış ile ayrı ayrı elde ettikleri bilgiden ÖBH elde etmişler ve farklı kişilerin yaptığı aynı sınıfa ait hareketlerin kamera açısı değişse dahi ÖBH'lerinin benzer olduğunu raporlamışlardır [8]. ÖBH'lerden betimleyiciler çıkarmışlar ve bu betimleyicilerin histogramı olarak elde ettikleri Kelime Çantalarını (KÇ - Bag of Words) en yakın komşu (EYK - Nearest Neighbour) veya çok sınıflı DVM ile sınıflandırmışlardır. Daha sonra bu yöntemi hareket eşleme için iyileştirmişlerdir [9]. Bir başka başarılı yöntem ise Saklı Markov Modellerine (SMM - Hidden Markov Models) dayalı jest tanımadır. SMM, gözlemlenen veriyi kullanarak bir Markov sisteminin parametrelerini bulmayı ve bu parametreleri sınıflandırmada kullanabilmeyi amaçlar [10]. Bu yaklaşımı Aktif Şekil Modeline dayalı takipçimizden elde ettiğimiz yüz nirengi noktalarının konumlarını modellemede kullanmış ve işaret dillerinde yaygın olarak kullanılan kafa hareketi ve yüz ifadesi jestlerinin sınıflandırılmasını sunmuştuk [1].

Bu çalışmada; ÖBH ve KÇ'ye dayalı yöntem [8,9] kafa hareketi ve yüz ifadesi sınıflandırmaya adapte edilmiş, SMM-tabanlı yöntemle karşılaştırılıp birleştirilmiştir. Ek olarak, takip edilen nirengi noktalarının histogramına dayalı yeni bir yöntem geliştirilmiş ve deneysel sonuçlarla başarısı gösterilmiştir. Hem ifade, hem de kafa hareketini içeren kapsamlı bir çalışma sunulmuştur.

## 2. Öznitelik Takibi ve Çıkarımı

Aktif Şekil Modelleri (AŞM), eğitim kümesindeki örneklerin nokta dağılımını modelleyip, bilinmeyen bir örneğe bu şekli oturturken, şeklin eğitilen modelin izin verdiği dağılımda kalmasını hedefler ve belli bir şablon şeklin resim içinde bulunmasında kullanılır [11]. Bu çalışmada, [1]'de sunduğumuz çok-çözünürlüklü ve çok-pozlu AŞM'ye dayalı takipçinin verdiği dudak, göz, kaş ve çene çevresi ile burun ucunu oluşturan noktalardan 52 tanesini kullanılmıştır.  $T$  kareden oluşan bir videonun her karesi için denklem (1)'deki vektör elde edilir. Bir videodaki tüm yüz şekilleri o videodaki birinci yüz şeklini sıfır merkezine taşıyıp birim boyuta ölçekleyen matrisle çarpılarak normalize edilir [1].

$$\mathbf{s}_i = (x_1, y_1, x_2, y_2, \dots, x_{52}, y_{52}), \quad i = 1, \dots, T \quad (1)$$

AŞM-tabanlı bir model, eğitim kümesine bağımlıdır ve eğitim kümesi genişledikçe hassasiyeti azalır. Alternatif olarak, [8]'de sunulan vücut bölgesinin optik akışını çıkarma yaklaşımı yüz için adapte edilmiştir. Video içinde yüzü çevreleyen en geniş kutu bulunur,  $64 \times 64$ 'lük bir pencereye ölçeklenir ve bu pencere dizisi için Lucas-Kanade optik akış denklem (2)'deki gibi  $x$  ve  $y$  eksenleri için elde edilir [12].

$$\text{ofx}_i = (\text{ofx}_{mn})_{64 \times 64}, \quad m, n = 1, \dots, 64, \quad i = 1, \dots, T - 1 \quad (2)$$

$$\text{ofy}_i = (\text{ofy}_{mn})_{64 \times 64}$$

### 2.1. Zamansal benzerlik hesabı

Art arda gelen yüzlerden oluşan bir jesti,  $\{\mathbf{s}_i\}_{i=1}^T$  serisi olarak gösterelim. Bu serinin  $i$  ve  $j$  anındaki elemanları arasındaki uzaklığı  $(i, j)$  hücrelerinde gösteren simetrik matris, bu seriyi ifade eden uzaklık matrisidir ve Öz Benzerlik Matrisi (ÖBH - Self Similarity Map) olarak da isimlendirilir. Bu matrisin elemanları (3) ve (4)'teki gibi hesaplanır:

$$D(\mathbf{s}) = (d_{ij}), \quad i, j = 1, \dots, T \quad (3)$$

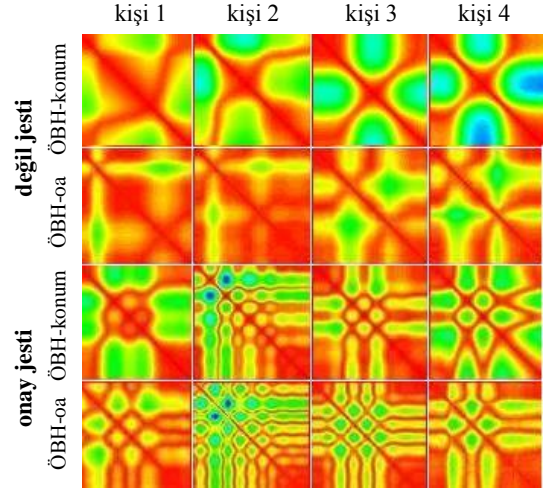
$$d_{ij} = \|\mathbf{s}_i - \mathbf{s}_j\|_2 \quad (4)$$

Takip edilen noktaların konum, hız ve ivmelerinden benzerlik matrisleri oluşturulmuş ve sırasıyla ÖBH-konum, ÖBH-hız ve ÖBH-ivme olarak isimlendirilmiştir. Optik akış serisinden ÖBH oluştururken, matrisler vektörize edilip iki vektör arasındaki Öklid uzaklığı kullanılmıştır.  $x$  eksen yönündeki akış,  $y$  eksen yönündeki akış ve bileşik akış kullanılarak elde edilen matrisler sırasıyla ÖBH-oax, ÖBH-oay ve ÖBH-oa olarak isimlendirilmiştir. İsimlendirmelerde [8]'deki isimlendirmeye sadık kalınmıştır.


Veritabanı kısmında anlatılacak olan "değil" ve "onay" jestleri için dört farklı kişiden (konum ve optik akış ile) elde edilen örnek ÖBH'ler, Şekil 1'de gösterilmiştir. Görüleceği üzere, farklı kişiler aynı hareketi yaptığında ÖBH'leri benzerlik göstermektedir.

### 2.2. Benzerlik matrisinden betimleyici çıkarımı

Benzerlik matrisinin köşegenindeki her nokta için, bu noktayı merkez alan yamadan çıkarılan bilgi, ilgili video karesini merkez alan zaman aralığı için bir betimleyici oluşturacaktır. [8]'de bu yama, log-kutupsal disk olarak seçilmiştir.



Şekil 1: Örnek öz-benzerlik matrisleri. (Gösterim için boyutları ortak boyuta ölçeklenmiştir.)



Şekil 2: ÖBH'den betimleyici çıkarmak için kullanılan örnek log-kutupsal disk.

Köşegenin her noktası için betimleyici vektör benzer şekilde çıkarılır. Diskin yarıçapının sabit tutulması yerine [9]'da anlatıldığı gibi, her nokta için en uygun (normalize Laplasyanı en yüksek olan) yarıçap hesaplanır. Disk, Şekil 2'deki gibi 11 parçaya bölünür, bölgeler içindeki eğimler (gradyanlar) hesaplanır ve 9 değere nicelenir (quantization). Bu değerlerin normalize histogramı elde edilir ve bu histogramlar 11 parça için art arda eklenerek  $11 \times 9 = 99$  boyuttan oluşan betimleyici vektör elde edilir.

Jestleri ifade etmek için Kelime Çantası (KÇ - Bag of Words) yöntemi kullanılmıştır [13,14]. Betimleyici vektörler,  $k$ -ortalama ( $k=1000$ ) algoritması ile öbeklenir. Öbek merkezleri, minimumdan başlanarak ve sırayla en yakındaki seçilerek indekslenir. Ardından jesti oluşturan betimleyici vektörlerin hangi öbek indekslerinden oluştuğu bulunur ve histogram çıkarılır.  $k$  kutulu olan bu histogram, o jesti oluşturan öbeklerin olasılık dağılım fonksiyonunun yaklaşımı olarak düşünülebilir.

Eğer birden fazla ÖBH hesaba katılacaksa, ilgili ÖBH'lerin tümü için betimleyici vektörler yan yana ekleyerek yeni bir betimleyici oluşturulur. Örneğin, konum, hız ve ivme ortak kullanılacaksa,  $99 \times 3 = 297$  boyutlu betimleyici vektör elde edilir ve kalan işlemlerde bu vektör kullanılır.

### 2.3. Şekil vektörlerinden histogram oluşturulması

Kullandığımız AŞM-tabanlı nokta takipçisi belli nirengi noktalarını tutarlı bir biçimde takip etmektedir. Takip edilen noktalardan uzaklık matrisini oluşturduğumuzda noktaların yalnızca birbirlerine olan uzaklıklarını hesaba katmış ve büyük bir bilgiyi kaybetmiş oluruz. Bu bilginin ışığında, benzerlik matrisi hesabına hiç girmeden, denklem (1)'de verilen yüz şekil vektörleri betimleyici olarak seçilmiş, kalan işlemler 104 boyutlu bu vektörler ile gerçekleştirilmiştir.

## 3. Sınıflandırma

### 3.1. SMM-tabanlı sınıflandırma

Denklem (1)'deki yüz şekil vektörleri Markov modelindeki gözlemlenen örnekler olarak seçilmiş, sürekli (continuous) çok-değişkenli SMM eğitilip, sınıflama yapılmıştır [1].

### 3.2. EYK/DVM-tabanlı sınıflandırma

Benzerlik matrisinden KÇ histogramının elde edilmesini kısım 2.1 ve 2.2'de açıklamıştık. Elde edilen histogramlar ilk olarak en yakın komşu (EYK) yöntemi ile sınıflandırılmıştır. Bu yöntemde,  $\chi^2$  uzaklığı kullanılmış [13] ve yeni bir örnek, eğitim kümesindeki en yakın örneğin sınıfına atanmıştır. Destek Vektör Makineleri (DVM) hareket sınıflandırmada başarılı sonuçlar veren diğer bir sınıflandırıcıdır [13, 15].  $\chi^2$  çekirdeği ile bire-karşı-bir (1vs1) DVM'ler eğitilmiş ve kazanım sayısına göre çok-sınıflı sınıflandırma yapılmıştır.


Ek olarak, kısım 2.3'te önerdiğimiz yüz şekil vektörü histogramları benzer şekilde EYK ve DVM ile sınıflanmıştır.

### 3.3. Sınıflandırıcıların birleştirilmesi

SMM-tabanlı sınıflandırıcı, olabilirlik bilgisini; EYK, yakınlık bilgisini; kullanılan çok-sınıflı DVM ise, bire-karşı-bir kazanım sayısını vermektedir. Üç yaklaşımın sonuçları, seçtikleri sınıfa göre çoğunluk oylaması (majority voting) ve Borda sayısı (Borda count) yöntemleriyle birleştirilmiştir.

## 4. Deneysel Sonuçlar

Deneyler için [16]'da sunulan BUHMAP veritabanı kullanılmıştır. BUHMAP, işaret dillerinde ve günlük yaşamda yaygın olarak kullanılan 7 farklı ifade ve baş hareketine ait videolardan oluşmaktadır. Her sınıf için, 11 farklı kişiden ortalama 1-2 saniye süren beşer tekrar alınmıştır. Şekil 3'te, ilk üç sınıftan örnek görüntüler verilmiştir.



Şekil 3: [16]'dan alınan üç örnek sınıf. Satırlar içinde zaman soldan sağa ilerlemektedir.

Sınıflar özetle şöyledir (jest adları anlaşılabilirlik için eklenmiştir):

1. *Sağa sola baş sallama*: 'Hayır' jesti.
  2. *Yukarı doğru başı bir kez kaldırma*: 'Değil' jesti.
  3. *Öne doğru başı uzatma*: 'Soru' jesti.
  4. *Büzülmüş Dudaklar*: 'Üzgün' jesti.
  5. *Yukarı aşağı baş sallama*: 'Onay' jesti.
  6. *Gülümseme*: 'Mutlu' jesti.
  7. *Onaylama ve gülümseme*: 'Mutlu onay' jesti
5. sınıf yüz ifadesi, 4. ve 6. sınıflar ise kafa hareketi içermez; kalanlar ikisini de içerir. Son sınıf, 5. ve 6. sınıfın bileşimidir.

### 4.1. Deney kurulumları

Karşılaştırma yapabilmek için, bu çalışmada da [1]'de kullandığımız dört öznenin videoları kullanılmıştır. Alınan küme 4 özne, 7 sınıf, 5 tekrar olmak üzere 140 videodan oluşmaktadır. Deney I için üç tekrar (84 örnek) eğitim kümesine, kalan iki tekrar (56 örnek) test kümesine konulmuştur. Bu deney, kişinin eğitim kümesinde bulunduğu durumdaki tanıma başarısını görmek için tasarlanmıştır. Deney II için ise, kişiden bağımsız başarı performansını görmek amacıyla, üç kişi (105 örnek) eğitim kümesi olarak seçilip, kalan kişide test edilmiştir (35 örnek). Her iki deney için de capraz geçişleme yapıp ortalama alınmıştır.

SMM deneyleri Gauss dağılımı ve saklı durum sayısı sırasıyla 2 ve 6 olarak seçilerek SMM-araçkütüsü [17] ile; DVM deneyleri ise  $\chi^2$  çekirdeği matrisi hesaplanarak (genişlik = 0.5) LIBSVM ile gerçekleştirilmiştir [18].

Kullanılan ÖBH matrisleri konum, konum+hız+ivme, oa, oa+oax+oay olarak [8]'e benzer şekilde seçilmiştir. Ek olarak tümü birleştirilmiştir. Elde edilen KÇ vektörleri hem EYK hem de DVM ile sınıflandırılmıştır. Önerdiğimiz şekil vektörü histogramları (şvh) EYK/DVM ile sınıflandırılmıştır. Sınıflandırıcıları (SMM, EYK-tümü, DVM-tümü, EYK-şvh, DVM-şvh) birleştirirken çoğunluk oyu ve Borda sayısı kullanılmıştır. Borda sayısı için, birleştirilen her yöntemin döndürdüğü en olası sınıfa 6 puan, olabilirliği en düşük sınıfa ise 0 puan verilir ve kalan puanlar aradakilere sırayla dağıtılır; toplamda en çok sayıyı alan sınıf kazanır.

Sınıflandırma başarıları Tablo 1'de görülmektedir. Beklenildiği üzere, öz-benzerlik bilgilerinin birleştirilmesine dayalı modeller (EYK-tümü ve ÖBH-tümü), tek bir benzerlik matrisi kullanmaktan daha başarılı sonuçlar vermektedir ve bu başarı SMM-tabanlı sınıflandırmaya yakındır. Kişiden bağımsız durumda (Deney II) SMM'nin daha iyi sonuç vermesi, görülmeyen örnekleri üretilemedeki üstünlüğünden kaynaklanmaktadır. Eğitim kümesindeki örnek sayısının azlığından öngörüleceği üzere, DVM yerine EYK kullanmak genel olarak başarıyı az miktarda artırmıştır, öte yandan çok daha basit bir sınıflandırmadır. Zaman ve model karmaşıklığı yönünden iki yaklaşımdan da oldukça basit olan önerdiğimiz yeni yöntem (EYK-şvh/DVM-şvh), kişinin örnekleri eğitim kümesinde bulunduğu (Deney I) diğer yaklaşımları önemli derecede geride bırakmıştır (%97.5). Kişi sayısının artması ve eğitim kümesindeki jestleri gerçekleştiren kişilerde çeşitliliğin sağlanmasıyla Deney II sonuçlarının daha yüksek olacağı düşünülmektedir. Sonuçların birleştirilmesiyle Deney I için %98.21, Deney II için ise % 81.93 başarı elde edilmiş, [1]'deki sonuçlara göre %15 kadar artış yakalanmıştır.

En iyi sonuçlar için Tablo 2'de verilen hata matrisleri, *mutlu/üzgün* ve *onay/mutlu-onay* jestlerinin birbirleriyle en çok karıştırılanlar olduğunu söylemektedir. Global kafa hareketinin, dudaklar gibi yerel yüz bölgelerinin hareketini örtbas etmesinden kaynaklanan bu sonuç ardıl bir ikilik sınıflandırıcı ile geliştirilebilir.

Tablo 1: Sınıflandırma başarıları (% olarak)

		Deney I	Deney II
<b>SMM</b>		<b>83.57</b>	<b>67.86</b>
<b>EYK</b>	konum	75.89	55.71
	konum+hız+ivme	73.75	55.00
	oa	66.79	45.71
	oa+oax+oay	74.64	54.29
	tümü	<b>83.39</b>	<b>60.71</b>
<b>DVM</b>	konum	78.39	52.86
	konum+hız+ivme	76.43	58.57
	oa	68.75	42.86
	oa+oax+oay	75.36	55.00
	tümü	<b>82.14</b>	<b>60.71</b>
<b>EYK-şvh</b>		<b>97.50</b>	<b>59.29</b>
<b>DVM-şvh</b>		<b>96.61</b>	<b>57.86</b>
<b>Çoğunluk oyu</b>		<b>96.79</b>	<b>74.29</b>
<b>Borda sayısı</b>		<b>98.21</b>	<b>81.43</b>

Tablo 2: Borda sayısı birleşimi ile elde edilen hata matrisleri (Deney I ve Deney II için)

		değil	hayır	soru	üzgün	onay	mutlu	mutlu
<b>Deney I</b>	değil	100	0	0	0	0	0	0
	hayır	0	100	0	0	0	0	0
	soru	0	0	100	0	0	0	0
	üzgün	0	0	0	92.5	1.25	6.25	0
	onay	0	0	0	0	100	0	0
	mutlu	0	0	0	0	0	100	0
	mutlu onay	0	0	0	0	5	0	95
<b>Deney II</b>	değil	100	0	0	0	0	0	0
	hayır	0	100	0	0	0	0	0
	soru	0	0	100	0	0	0	0
	üzgün	0	0	5	90	0	5	0
	onay	0	0	5	0	90	0	5
	mutlu	0	0	0	40	0	60	0
	mutlu onay	5	0	0	10	55	0	30

## 5. Sonuç

Bu bildiriye, hareket tanımada başarı ile uygulanan zamansal öz-benzerliğe dayalı yöntem, yüz ifadesi ve kafa hareketi tanıma adapte edilmiştir ve Saklı Markov Modeli tabanlı önceki çalışmayla karşılaştırılmıştır [1]. Ek olarak, yüz şekil vektörlerinin histogramına dayalı yeni bir yöntem önerilmiştir. Yöntemler, 7 farklı yüz ifadesi ve kafa hareketi sınıfı içeren BUHMAP veritabanında [16] test edilmiştir. Öz-benzerlik haritasına dayalı yöntem, SMM-tabanlı yöntemle yakın sonuçlar vermiştir. Kişiye ait videoların eğitim kümesinde bulunduğu durumda, yeni önerilen yöntem %97.5 başarı oranı ile diğer yöntemleri geride bırakmıştır. Elde edilen sonuçlar, güvenilirlikleri çerçevesinde birleştirilmiş, hem kişinin verilerinin eğitim kümesinde bulunduğu hem de bulunmadığı deneylerde %15 başarı artışı sağlanmıştır.

## 6. Teşekkür

Bu çalışma, DAAD ve 108E161 numaralı proje kapsamında TÜBİTAK tarafından desteklenmiştir. Ayrıca, katkılarından dolayı M. Fischer, Y. E. Kara ve N. Alyüz'e teşekkür ederiz.

## 7. Kaynakça

- [1] İ. Arı ve L. Akarun, "Yüz öznetelikleri takibi ve işaret dili için ifade tanıma". *IEEE Sinyal İşleme ve İletişim Uygulamaları Konferansı*, Antalya, 2009.
- [2] U. Zeshan, "Aspects of Türk İşaret Dili (Turkish Sign Language)," *Sign Language & Linguistics*, 6:43-75, 2003
- [3] L. Morency, C. Sidner, C. Lee, ve T. Darrell, "Head gestures for perceptual interfaces: The role of context in improving recognition," *Artificial Intelligence*, 171:568-585, 2007.
- [4] A. Zelinsky ve J. Heinzmann, "Real-time visual recognition of facial gestures for human-computer interaction," *Proceedings of the Second International Conference on Automatic Face and Gesture Recognition*, 351-356, 1996.
- [5] M. Pantic ve L. Rothkrantz, "Facial gesture recognition in face image sequences: A study on facial gestures typical for speech articulation," *IEEE International Conference on Systems, Man and Cybernetics*, 2002.
- [6] B. Fasel ve J. Luetin, "Automatic facial expression analysis: a survey," *Pattern Recognition*, 36:259-275, 2003.
- [7] N. Marwan, M. Carmenromano, M. Thiel, ve J. Kurths, "Recurrence plots for the analysis of complex systems", *Physics Reports*, 438:237-329, 2007.
- [8] I. Junejo, E. Dexter, I. Laptev, ve P. Pérez, "Cross-view action recognition from temporal self-similarities," *European Conference on Computer Vision*, 2008.
- [9] E. Dexter, P. Pérez, ve I. Laptev, "Multi-view synchronization of human actions and dynamic scenes," *British Machine Vision Conference*, 2009.
- [10] L. Rabiner, "A tutorial on hidden Markov models and selected applications in speech recognition," *Proceedings of the IEEE*, 77:257-286, 1989.
- [11] T. F. Cootes, C. J. Taylor, D. H. Cooper, ve J. Graham, "Active shape models-their training and application," *Computer Vision and Image Understanding*, 61:38-59, 1995
- [12] B. Lucas ve T. Kanade, "An iterative image registration technique with an application to stereo vision," *Image Understanding Workshop*, 121-130, 1981.
- [13] I. Laptev, B. Caputo, C. Schuldt, ve T. Lindeberg, "Local velocity-adapted motion events for spatio-temporal recognition," *Computer Vision and Image Understanding*, 108: 207-229, 2007.
- [14] J. C. Niebles, H. Wang, ve L. Fei-Fei, "Unsupervised learning of human action categories using spatial-temporal words," *International Journal of Computer Vision*, 79: 299-318, 2008.
- [15] M. Marszałek, C. Schmid, H. Harzallah, and J. Van De Weijer, "Learning object representations for visual object class recognition," *The PASCAL Visual Recognition Challenge*, 2007.
- [16] O. Aran, İ. Arı, A. Güvensan, H. Haberdar, Z. Kurt, İ. Türkmen, A. Uyar, ve L. Akarun, "Türk işaret dili yüz ifadesi ve baş hareketi veritabanı," *IEEE Sinyal İşleme ve İletişim Uygulamaları Konferansı*, 2007.
- [17] K. Murphy, "Hidden markov model (hmm) toolbox for MATLAB," <http://people.cs.ubc.ca/~murphyk/Software/HMM/hmm.html>, erişim tarihi: 30.01.2010.
- [18] C. Chang ve C. Lin, "LIBSVM: a library for support vector machines," <http://www.csie.ntu.edu.tw/~cjlin/libsvm>, erişim tarihi: 30.01.10.