



# Farklı Renk Kanallarında Üretilen Doku Özniteliklerinin Yüz Sahteciliği Tespiti Başarımına Etkisinin İncelenmesi

## Investigation of the Effect of Texture Features Extracted From Different Color Channels on Face Spoofing Detection Performance

Asuman GÜNAY YILMAZ

Karadeniz Teknik Üniversitesi  
Of Teknoloji Fakültesi, Yazılım  
Mühendisliği Bölümü  
Trabzon, Türkiye  
gunaya@ktu.edu.tr

ORCID:0000-0003-3960-5085

Uğur TURHAL

Bayburt Üniversitesi  
Teknik Bilimler MYO,  
Bilgisayar Teknolojileri Bölümü  
Bayburt, Türkiye  
Uturhal@bayburt.edu.tr

ORCID:0000-0002-5627-1833

Vasif NABIYEV

Karadeniz Teknik Üniversitesi  
Mühendislik Fakültesi,  
Bilgisayar Mühendisliği Bölümü  
Trabzon, Türkiye  
vasif@ktu.edu.tr

ORCID:0000-0003-0314-8134

### Öz

Yüz tanıma sistemleri temassız olmaları ve kullanım kolaylığından dolayı pek çok uygulamada kendine yer bulmaktadır. Fakat teknolojinin gelişimi ve bilgiye erişimin kolaylaşması nedeniyle bu sistemler, sahte yüzler kullanılarak yapılan saldırılara karşı dayanıksızdır. Bu çalışmada, farklı renk uzaylarındaki kanallardan çıkarılan doku özniteliklerinin yüz sahteciliği tespitindeki başarımı incelenmiştir. Bu amaçla HSV, YCbCr, ve daha önceden bu alanda kullanılmayan L\*a\*b\* renk uzaylarının kanallarından çıkarılan çok seviyeli yerel ikili örüntü özniteliklerinin ikili üçlü birleşimleri ile yüz sahtecilik tespiti gerçekleştirilmiştir. Öznitelik vektörleri temel bileşenler analizi ile küçültülüp, destek vektör makinesi sınıflayıcısının eğitiminde kullanılmıştır. CASIA ve Replay-Attack veri kümeleri üzerinde yapılan deneylerde farklı kanallardan çıkarılan öznitelik birleşimlerinin yüz sahteciliği tespitinde başarılı olduğu görülmüştür.

**Anahtar sözcükler:** Yüz sahteciliği tespiti, renkli doku analizi, yerel ikili örüntüler

### Abstract

Face recognition systems find their place in many applications because of their contactless nature and ease of use. However,

Gönderme, düzeltme ve kabul tarihi: 17.02.2022 -14.04.2022 - 26.04.2022

Makale türü: Araştırma

due to the development of technology and easier access to information, these systems are vulnerable to attacks using fake faces. In this study, the performance of texture features extracted from channels in different color spaces in detecting face spoofing was investigated. For this purpose, various combinations of multilevel local binary pattern features extracted from HSV, YCbCr, and L\*a\*b\* color space channels were used for face spoofing detection. The feature vectors were reduced by principal component analysis and used in training the support vector machine classifier. The experiments on CASIA and Replay-Attack datasets showed that feature combinations extracted from different channels are successful in detecting spoof faces.

**Keywords:** Face spoofing detection, color texture analysis, local binary patterns

### 1. Giriş

Günümüzde yüz tanıma sistemleri, özellikle temassız olmaları ve düşük kullanıcı iş birliğine ihtiyaç duymaları nedeniyle, biyometrik tabanlı doğrulama gerektiren birçok alanda yaygın olarak kullanılmaktadır. Ancak bu sistemler, uygulama kolaylığına rağmen saldırılara karşı savunmasızdır. Özellikle artan sosyal medya kullanımı, yüz tanıma sistemlerinin daha kolay kandırılmasına imkân sağlamaktadır. Bu nedenle yüz sahteciliği tespiti (YST) konusunda çeşitli çalışmalar yapılmaktadır. Özel donanım gerektirmeyen ve standart görüntüleme cihazlarını kullanarak YST gerçekleştiren

sistemler, ortam ışığı, görüntü kalitesi, gürültü, yüz görüntülerindeki tutarsızlık (gözleri kısma veya kapama, yüz ifadesini değiştirme) ve yaşlanmaya bağlı yüz değişiklikleri gibi çok sayıda değişkenden etkilenmektedir. Bu nedenle problemin çözümü zorlaşmaktadır.

Yüz sahteciliği yöntemleri genel olarak basılı fotoğraf saldırısı, video yeniden oynatma (video replay) saldırısı ve 3D maske saldırısı olarak üçe ayrılır. 3D modellerin oluşturulması daha zor ve pahalı olduğu için, saldırganlar ilk iki yöntemi daha kolay gerçekleştirebilir. Bunun dışında farklı çözünürlük, aydınlatma koşulları, giriş cihazı türü ve konumu gibi etkenler de saldırı senaryolarını çeşitlendirmektedir. Dolayısıyla, YST sisteminin gerçek zamanlı kullanımında ne tür bir senaryo ile karşılaşacağı tam olarak bilinememektedir. Literatürde yaygın kullanılan veri kümeleri birçok saldırı senaryosu içermektedir. Ancak bunları kullanan çoğu çalışmada genellikle tek bir saldırı senaryosu için (tüm saldırı türlerinin bir arada olduğu senaryo) sonuçlarının paylaşıldığı görülmektedir. Bu durum, önerilen modelin farklı senaryolar altındaki davranışını kestirmeyi ve genelleştirilmiş bir çözüm üretmeyi zorlaştırmaktadır.

Son yıllarda YST konusunda elle üretilen özneliklere dayalı [1-5] ve derin öğrenme ile üretilen özneliklere dayalı [6-8] çalışmalar yapılmaktadır. Bilindiği gibi Yerel İkili Örnekleme (YİÖ), doku tanımlamada sıklıkla kullanılan, oldukça güçlü bir yöntemdir. YST alanında yapılan birçok çalışmada bu yöntemden faydalanılmıştır [1, 9-10]. Önceki çalışmalarda gri seviye görüntülerden çıkarılan YİÖ doku öznelikleri yerini daha sonra renkli görüntülerden çıkarılan YİÖ özneliklerine bırakmıştır. Bu aşamada özellikle HSV (Hue-Saturation-Value), RGB ve  $YCbCr$  renk uzaylarında gerçekleştirilen çalışmalar, renk kanallarının YİÖ ile doku tanımlamada etkili olduğunu, bazı durumlarda ise bu kanalların birlikte kullanımının, YST başarımını arttırdığını ortaya koymuştur [2, 5, 11-12]. Fakat bu çalışmalarda genellikle renk uzaylarındaki tüm kanallardan çıkarılan özneliklerin birleşimi kullanılarak YST tespiti gerçekleştirilmiştir. Bu çalışmada literatürden farklı şekilde cihaza bağımlı renk uzayları HSV ve  $YCbCr$ 'ye ek olarak cihaza bağımsız ve insan görüş sistemine daha yakın olan  $L^*a^*b^*$  renk uzayında YST başarımını incelenmiştir. Bu renk uzaylarında çıkarılan YİÖ özneliklerinin ikili ve üçlü kanal birleşimlerinin (örneğin  $HS + a^*b^*$ ,  $HS + C_bC_r + a^*b^*$ ,  $HSV + YCbCr + L^*a^*b^*$  vb.) YST başarımına etkisi incelenmiştir. Bu amaçla, görüntülerden çıkarılan çok kanallı çok seviyeli YİÖ öznelikleri, öncelikle Temel Bileşenler Analizi (TBA) ile boyut indirgeme işleminden geçirilmiş, ardından Destek Vektör Makineleri (DVM) sınıflayıcısının eğitiminde kullanılmıştır. Deneyler, YST alanında sıklıkla kullanılan CASIA ve Replay-Attack veri kümeleri üzerinde gerçekleştirilmiştir. CASIA veri kümesinde 7, Replay-Attack veri kümesinde 6 olmak üzere toplamda 13 saldırı senaryosu için YST başarımını değerlendirilmiştir. Elde edilen sonuçlar farklı kanal birleşimlerinin daha iyi YST başarımını sağladığını göstermiştir. Sistemin genel yapısı Şekil 1'de verilmiştir.

<b>Giriş Görüntüsünün Alınması</b>	• Videodan çerçevelerin ayrıştırılması
<b>Görüntü Önileme</b>	• Yüz Tespiti • Yüzün Hizalanması ve Normalizasyonu
<b>Renk Uzaylarına Dönüştürme</b>	• HSV • $YCbCr$ • $L^*a^*b^*$
<b>Öznitelik Çıkarma</b>	• Çok seviyeli YİÖ
<b>Farklı Renk Kanallarındaki Öznitelikleri Birleştirme</b>	• $HSV+YCbCr$ • $HSV+L^*a^*b^*$ • $YCbCr+L^*a^*b^*$ • $HSV+YCbCr+L^*a^*b^*$ • $HS+C_bC_r$ • $HS+a^*b^*$ • $C_bC_r+a^*b^*$ • $HS+C_bC_r+a^*b^*$
<b>Boyut Küçültme</b>	• TBA
<b>Sınıflandırma</b>	• DVM
<b>Karar</b>	• Gerçek • Sahte

Şekil-1: Sistemin genel yapısı

Bu çalışmanın katkıları;

- Cihaza bağımlı ( $HSV$ ,  $YCbCr$ ) ve cihazdan bağımsız ( $L^*a^*b^*$ ) renk uzaylarından çıkarılan doku özneliklerinin YST başarımını incelenmiştir.
- Renk uzaylarının kanallarından çıkarılan öznelik vektörleri ikili üçlü olarak birleştirilerek YST başarımına etkisi incelenmiştir.
- Renk uzaylarındaki parlaklık bileşenleri ( $V$ ,  $Y$ ,  $L$ ) haricinde sadece kromatik bileşenlerin kullanımı ile YST başarımını değerlendirilmiştir.
- CASIA ve Replay-Attack veri kümelerinde toplam 13 farklı senaryo için testler gerçekleştirilmiş ve sonuçlar değerlendirilmiştir.

Yazının devamı şu şekilde planlanmıştır: YST ile ilgili yapılan çalışmalar 2. bölümde özetlenmiştir. Çalışmada kullanılan YST sistemi 3. bölümde açıklanmıştır. 4. bölümde elde edilen Bulgular verilmiş, 5. bölümde sonuçlar tartışılmıştır.

## 2. Literatür Özeti

Mevcut YST sistemleri: a) hareket analizine dayalı b) canlılık tespitine dayalı c) görüntü kalite analizine dayalı ve d) doku analizine dayalı yöntemler olarak 4 sınıfa ayrılabilir.

Hareket analizine dayalı yöntemlerin amacı, video dizilerindeki fizyolojik özellikleri ve dinamik doku bilgilerini incelemektir [13]. Canlılığın tespitine dayalı yöntemler, videoları göz kırpması ve yüz ifadeleri gibi yaşam göstergelerini belirlemek için analiz eder [14]. Gerçek erişimler ve yasa dışı saldırılar, farklı resim kalitesi özelliklerine sahiptir. Bu nedenle, görüntü kalitesi analizine dayalı yöntemler, renk çeşitliliği, bulanıklık, kenar bilgisi, kromatik moment özellikleri

vb. gibi gerçek ve sahte yüzlerin görüntü kalitesini değerlendirir [15-16].

Doku analizine dayalı yöntemler, sahtecilik saldırılarını tespit etmek için gerçek ve sahte yüzlerin doku desenleri (baskı hataları, görüntü bulanıklığı vb.) arasındaki farkları kullanır. Bu yaklaşımların uygulanması kolaydır ve kullanıcı iş birliğine ihtiyaç duymazlar. Ancak gerçek ve sahte yüzleri ayırt etmek için iyi öznelik vektörlerine ihtiyaçları vardır. Ayrıca, düşük doku bilgisi oluşturan düşük kaliteli görüntüler veya videolar iyi algılama sonuçları vermeyebilir.

YST'de doku tabanlı yaklaşımlar ilk olarak gri renk uzayında uygulanmıştır [9, 17-18]. Ancak sonraki yıllarda yapılan çalışmalar çok kanallı renk uzaylarına, hatta bu uzayların hibrit bir şekilde kullanılmasına odaklanmıştır [5]. Boulkenafet vd., çalışmalarında, HSV ve  $YCbCr$  renk uzaylarının YST başarımına etkisini incelemiştir. Renk uzaylarının her kanalından elde edilen YİÖ öznelikleri uç uca eklenmiş ve SVM ile sınıflandırma yapılmıştır. Çalışmada, HSV ve  $YCbCr$  renk uzaylarından elde edilen YİÖ özneliklerinin, YST başarımını arttırdığı belirtilmiştir [2]. Diğer bir çalışmada ise HSV ve  $YCbCr$  renk uzaylarının parlaklık ve kromatik kanallarından doku özelliklerini hesaplamak için çeşitli doku tanımlayıcıları kullanılmıştır [11].

Patel vd., mobil cihazlarda YST üzerine yaptıkları çalışmada, mobil cihazın kamerasından elde edilen giriş görüntüsünden yüz bölgesini tespit etmiş ve normalizasyon işlemi gerçekleştirilmiştir [19]. Ardından, renk bilgisini maksimize etmek için yüz görüntüsü HSV renk uzayına dönüştürülmüş ve tüm kanallardan ortalama, standart sapma ve asimetri gibi renk bilgileri elde edilmiştir. Yüz dokusu, üst üste binen bloklara uygulanan YİÖ ile üretilmiştir. YİÖ histogramı ve renk bilgilerinin birleştirilmesiyle giriş vektörü oluşturulmuş ve örnekler DVM ile sınıflandırılmıştır. Bunun yanında, RGB kanallarının bireysel olarak kullanımının YST başarımına etkisi de araştırılmıştır. Gri görüntünün yanı sıra her kanaldan elde edilen YİÖ histogramları DVM ile sınıflandırılmış ve sonuç olarak, kullanılan veri kümesi üzerinde kırmızı renk kanalının, diğer kanallara göre daha etkili olduğu belirtilmiştir [19].

Boulkenafet vd., HSV ve  $YCbCr$  renk uzaylarından SURF (Speeded-Up Robust Features) özneliklerini çıkarmış ve öznelik vektörlerini lineer sınıflandırma için daha uygun olan yüksek boyutlu bir uzaya gömmek için Fisher vektör kodlamasını kullanmıştır. Bir önceki çalışmada olduğu gibi, HSV ve  $YCbCr$  renk uzaylarının birleşimlerinin YST performansını arttırdığı ifade edilmiştir [20]. Peng vd., Gauss ölçek uzayının kenar koruma filtreleme yeteneğini geliştirmek için kılavuzlu ölçek uzayını (Gaussian Scale) önermiştir. Bu uzayda yüz kenarları korunurken, görüntü bileşenleri yumuşatılır ve gerçek yüz ile yapay doku arasındaki farkın büyütülmesi hedeflenir. Giriş görüntüsünün bloklara ayrıştırılması ve her blokta elde edilen YİÖ histogramları ile bu blokların kılavuzlu ölçek uzayından elde edilen GS-YİÖ histogramlarının birleştirilmesi sonucunda öznelik vektörü üretilmiştir. Bu işlemler farklı renk uzayları ile tekrar edilmiş ve en iyi sonuçların HSV +  $YCbCr$  renk uzayında elde edildiği görülmüştür [21]. Boulkenafet vd., normalize edilmiş yüz bölgeleri içeren RGB görüntülerini HSV ve  $YCbCr$  renk

uzaylarına dönüştürerek, her kanaldan ayrı ayrı bütünsel doku öznelikleri çıkarmıştır. Elde edilen tüm öznelikler uç uca eklenerek, giriş görüntüsü için öznelik vektörünü oluşturmuştur. Son olarak, elde edilen öznelik vektörleri bir Softmax sınıflandırıcısının eğitiminde kullanılmıştır. Önerilen yöntemin, özellikle çapraz veri kümesi senaryolarında başarımı arttırdığı görülmüştür [5].

Zhang vd., giriş görüntüsünden tespit edilen ve normalize edilen yüz bölgelerine renk uzayı dönüşümleri uygulamıştır. Üretilen renk kanallarından ve bu kanallar arası farklardan Markov özellikleri çıkarıldıktan sonra öznelik kümesi boyutu küçültülmüştür. Son olarak DVM sınıflandırıcısı yardımıyla YST yapılmıştır. Farklı renk uzaylarında yapılan araştırmalar neticesinde en iyi sonuçların nRGB renk uzayında elde edildiği belirtilmiştir [4]. Khurshid vd., doku özneliklerinden gerçek zamanlı YST yapan bir yöntem geliştirmiştir. RGB görüntüler önce gri seviye ve  $YCbCr$  renk uzayına dönüştürülmüştür. Bunu takiben, bu görüntülerden YİÖ öznelikleri ve yalnızca gri seviyeli görüntülerden CoA (Co-occurrence of Adjacent) YİÖ öznelikleri üretilmiştir. Son olarak, özellik seti bir DVM kullanılarak sınıflandırılmıştır [22].

Zhou vd., doku tabanlı bir tanımlayıcı ile hareket bilgilerini de elde edebilmek için LDN-TOP (local directional number pattern from three orthogonal planes) özneliklerini kullanmıştır. Renkli görüntülerin tüm kanallarından elde edilen LDN-TOP histogramları uç uca eklenerek, öznelik vektörleri üretilmiştir. Elde edilen sonuçlar, HSV ve  $YCbCr$  renk uzaylarının bir arada kullanılmasında YST performansını arttırdığını göstermiştir [12].

### 3. Materyal ve Metot

Bu bölümde giriş görüntülerinin ön işlenmesi, renk kanalları, öznelik çıkarma ve sınıflandırma ile ilgili bilgiler verilmektedir.

#### 3.1 Görüntü Önleme

Gerçek ortamda bir YST'nin nasıl gerçekleştirileceği tam olarak bilinmediğinden, giriş görüntüsünden yüz bölgesinin tespit edilmesi, hizalanması ve yeniden boyutlandırılması, tam otomatik bir YST sisteminin performansını önemli ölçüde etkiler. Bu çalışmada, Dlib kütüphanesinin [23] önceden eğitilmiş 5 noktalı yüz işaretçisi kullanılarak giriş görüntülerinden yüz bölgeleri tespit edilmiş ve göz konumlarına göre normalize edilmiştir. Örnek bir giriş görüntüsü için belirlenen yüz bölgesi Şekil 2'de verilmiştir.



Şekil-2: Giriş görüntüsünün hizalanması

#### 3.2 Renk Uzayları

Renk uzayları genel olarak cihaza bağımlı ve cihazdan bağımsız olmak üzere iki gruba ayrılabilir [24]. Cihaza bağlı bir renk uzayında üretilen renkler hem kullanılan parametrelere hem de görüntüleme için kullanılan cihaza bağlıdır. RGB, CMYK ve

HSV bu renk uzayının en yaygın örnekleridir. Cihazdan bağımsız bir renk uzayında ise, bir dizi parametre hangi donanım kullanılırsa kullanılsın aynı rengi üretmektedir.  $L^*a^*b^*$  bu renk uzaylarına bir örnektir. RGB, renk algılama, temsil ve görüntüleme için en sık kullanılan renk uzayıdır. Bununla birlikte, üç renk bileşeni (kırmızı, yeşil ve mavi) arasındaki yüksek korelasyon ve parlaklık ve kromatik bilginin tam ayrıştırılamaması nedeniyle, görüntü analizindeki uygulaması oldukça sınırlıdır [2]. Bu çalışmada HSV,  $YCbCr$  ve  $L^*a^*b^*$  renk uzayları kullanılmış ve bu renk uzayları aşağıdaki alt bölümlerde açıklanmıştır.

### 3.2.1 HSV Renk Uzayı

HSV renk uzayının üç boyutlu temsili, merkezi dikey eksenin yoğunluğu temsil ettiği bir heksatondur. Ton (hue), kırmızı eksene göre 0 açısında kırmızı,  $2\pi/3$ 'te yeşil,  $4\pi/3$ 'te mavi ve yine  $2\pi$ 'de kırmızı olan  $[0, 2\pi]$  aralığında bir açı olarak tanımlanır. Doygunluk (saturation), rengin derinliği veya saflığıdır ve merkezde 0 ile dış yüzeyde 1 arasındaki bir değerle merkezi eksenden radyal mesafe olarak ölçülür.  $S=0$  için, yoğunluk eksenini boyunca daha yükseğe çıkıldıkça, çeşitli gri tonlarında siyahtan beyaza gidilmektedir [25]. RGB renk uzayından HSV renk uzayına dönüşüm için Denklem (1) kullanılmaktadır.

$$H = \begin{cases} 2 - \cos^{-1} \left\{ \frac{[(R - G) + (R - B)]}{2\sqrt{(R - G)^2 + (R - B)(G - B)}} \right\}, B > G \\ \cos^{-1} \left\{ \frac{[(R - G) + (R - B)]}{2\sqrt{(R - G)^2 + (R - G)(G - B)}} \right\}, \text{aksi halde} \end{cases} \quad (1)$$

$$S = \frac{V - \min(R, G, B)}{V}; \quad V = \max(R, G, B)$$

### 3.2.2 $YCbCr$ Renk Uzayı

$YCbCr$  renk uzayı, video bilgilerinin işlenmesinde dijital algoritmalara yönelik artan taleplere yanıt olarak tanımlanmış ve dijital videolarda yaygın olarak kullanılan bir model haline gelmiştir. Parlaklığı temsil eden Y bileşeni RGB değerlerinin ağırlıklı toplamı olarak elde edilir.  $C_b$  ve  $C_r$  ise sırasıyla mavi ve kırmızı renk bileşenlerinin parlaklık bileşeni ile farkını ifade etmektedir [26]. RGB renk uzayından  $YCbCr$  renk uzayına dönüşüm için Denklem (2) kullanılmaktadır.

$$\begin{aligned} Y &= 0.299R + 0.587G + 0.114B \\ C_b &= 128 - 0.168736R - 0.331264G + 0.5B \\ C_r &= 128 + 0.5R - 0.418688G - 0.081312B \end{aligned} \quad (2)$$

### 3.2.3 $L^*a^*b^*$ Renk Uzayı

$L^*a^*b^*$  renk uzayındaki  $L^*$  kanalı parlaklığı temsil etmekte ve gri tonlarına karşılık gelen ve 0-100 arasında değişen değerler içermektedir.  $a^*$  ve  $b^*$  kanalları ise, -128 ile +127 arasında değerlere sahip olup sırasıyla kırmızı-yeşil oranını ve sarı-mavi oranını temsil etmektedir. Bu nedenle,  $a^*$  veya  $b^*$  kanalındaki yüksek bir değer, daha yüksek oranda kırmızı veya sarı olan bir rengi gösterirken, düşük bir değer, daha yüksek oranda yeşil veya mavi olan bir tonu belirtir [27].

$L^*a^*b^*$  renk uzayı, algılanabilir tüm renkleri içerir. Modelin en önemli özelliklerinden biri cihaz bağımsızlığıdır. Bu, renklerin yaratılışlarından veya üzerinde görüntülendikleri cihazdan bağımsız olarak tanımlandığı anlamına gelir. Ayrıca, cihaz bağımsızlığı açısından farklı cihazlar arasında bir değişim

formatı olarak kullanılır.  $L^*a^*b^*$  renk uzayı, insan görüş sistemine göre tasarlanmıştır.  $a^*$  ve  $b^*$  bileşenlerindeki çıktı eğrileri değiştirilerek renk dengelemek, L bileşenini kullanarak kontrastı ayarlamak mümkündür. İnsan görsel algısından ziyade fiziksel cihazların çıktısını modelleyen RGB veya CMYK uzaylarında bu dönüşümler ancak bir görüntü düzenleme uygulamasındaki uygun karışım seçenekleri yardımıyla yapılabilir [28].

Giriş olarak alınan görüntüler yukarıda detayları verilen renk uzaylarındaki renk kanallarına ayrıldıktan sonra her bir renk kanalından doku öznelikleri çıkarılıp ikili üçlü birleştirilerek YST başarımı incelenmiştir. Öznelik çıkarma işleminde kullanılan çok seviyeli YİÖ histogramları bir sonraki bölümde açıklanmıştır.

### 3.3 Çok Seviyeli YİÖ Histogramları ile Öznelik Çıkarma

Ojala vd. tarafından önerilen YİÖ, bir görüntünün her pikselini, komşu pikselleriyle eşikleyerek etiketleyen ve sonucu ikili bir sayı olarak üreten basit ve verimli bir doku operatörüdür [29]. YİÖ kodlarının üretilmesi Denklem (3)'te verilmiştir.

$$YİÖ_{P,R}(x, y) = \sum_{n=1}^P \delta(r_n - r_c) \times 2^{n-1} \quad (3)$$

Denklemde  $\delta$  basamak fonksiyonudur ve  $x \geq 1$  ise  $\delta(x)=1$ , aksi halde  $\delta(x)=0$ 'dır.  $r_c$  ve  $r_n$  ( $n=1, \dots, P$ ) sırasıyla merkez pikselini ve  $R$  ( $R>0$ ) yarıçaplı dairesel  $P$  komşusunun parlaklık değerlerini ifade etmektedir. Görüntü doku bilgisini temsil etmek için, ikili kodların görüntüde meydana gelme sayıları bir histogramla gösterilir. Ojala vd.'ne göre, düzgün YİÖ'ler, yerel görüntü dokusunun temel özellikleridir ve bunların histogramı çok güçlü bir doku özelliğidir. Düzgün örüntüler görüntüdeki, kenarlar, köşeler ve noktalar gibi mikro özelliklere karşılık geldiği için doku bilgisini daha çok taşımaktadır [30].  $I(x,y)$  görüntüsü için  $R$  piksel uzaklıktaki  $P$  komşu için YİÖ histogramı Denklem (4) ile üretilir.

$$H = \sum f\{YİÖ_{P,R}(I_{x,y}) = U(i)\} \quad (4)$$

$$f(y) = \begin{cases} 1, & \text{eğer } y \text{ doğru ise} \\ 0, & \text{eğer } y \text{ yanlış ise} \end{cases}$$

Denklemde  $U(i)$ ,  $R$  piksel uzaklıktaki  $P$  komşuluk için düzgün örüntüleri içeren dizidir. YİÖ histogramlarının üretilmesinde her bir düzgün örüntü için ayrı bir bölme oluşturulur, düzgün olmayan tüm örüntüler ise tek bir bölmede tutulur. Örneğin (8,1) komşuluk için 256 farklı YİÖ kodu oluşurken bunlardan sadece 58 tanesi düzgündür. Bu nedenle (8,1) komşuluk için üretilen YİÖ histogramının boyutu 59 olur.

YİÖ operatörü, güçlü doku tanımlama yeteneğinin yanında basit ve hızlı hesaplanması sebebiyle tercih edilmektedir. Ancak bazı problemlerde daha detaylı özneliklere ihtiyaç duyulmaktadır. Bu durumda, Çoklu-Bloklu YİÖ ( $\text{ÇB\_YİÖ}$ ) operatörü kullanılır.  $\text{ÇB\_YİÖ}$ , giriş görüntüsünün  $n \times m$  alt bölgeye ayrılması ve her bölgeden elde edilen düzgün YİÖ histogramlarının uç uca eklenmesi (concatenate) esasına dayanır. Sonuç olarak tüm bloklardan üretilen YİÖ öznelik

histogramları yan yana eklenerek  $n \times m \times 59$  elemanlı  $\text{ÇB\_YİÖ}$  öznitelik vektörü elde edilir (Şekil 3).

Çoklu-Seviyeli YİÖ ( $\text{ÇS\_YİÖ}$ ) öznitelikleri ise, bir giriş görüntüsünden farklı seviyelerde  $\text{ÇB\_YİÖ}$  özniteliklerinin üretilmesi ve birleştirilmesi ile elde edilen daha detaylı bir doku tanımlama yöntemidir. Burada görüntüden 59 elemanlı bir düzgün YİÖ histogramı üretilir. Daha sonra görüntü sırasıyla  $n_i \times m_j$  ( $i = 1, \dots, N, j = 1, \dots, M$ ) farklı bölgeye ayrılıp  $\text{ÇB\_YİÖ}$  öznitelikleri çıkarılarak uç uca eklenir. Sonuç olarak tüm seviyelerdeki tüm bloklara karşılık gelen YİÖ histogramları yan yana getirilerek  $(1 + n_1 \times m_1 + n_2 \times m_2 + \dots) \times 59$  elemanlı  $\text{ÇS\_YİÖ}$  öznitelik vektörü elde edilir (Şekil 3).

Yapılan araştırmalar, farklı renk kanallarının, YST'de daha fazla bilgi taşıdığını ortaya koymuştur. Bu amaçla, çalışmada giriş görüntüleri renk kanallarına ayrılmış, her kanaldan elde edilen  $\text{ÇS\_YİÖ}$  öznitelikleri uç uca eklenerek, giriş görüntüsünü temsil edecek öznitelik vektörü elde edilmiştir. Bu işlem birden fazla renk uzayındaki kanallara uygulanıp uç uca eklenerek çok kanallı  $\text{ÇS\_YİÖ}$  öznitelik vektörü üretilmiştir.

Çalışmada giriş görüntüsü HSV,  $\text{YCbCr}$  ve  $\text{L}^*a^*b^*$  renk uzaylarının kanallarına ayrıştırılmıştır. Tüm kanallardan, yukarıda anlatılan şekilde  $\text{ÇS\_YİÖ}$  öznitelikleri ( $\text{ÇS\_YİÖ}_H$ ,  $\text{ÇS\_YİÖ}_S$ ,  $\text{ÇS\_YİÖ}_V$ ,  $\text{ÇS\_YİÖ}_Y$ ,  $\text{ÇS\_YİÖ}_{Cb}$ ,  $\text{ÇS\_YİÖ}_{Cr}$ ,  $\text{ÇS\_YİÖ}_{L^*}$ ,  $\text{ÇS\_YİÖ}_{a^*}$ ,  $\text{ÇS\_YİÖ}_{b^*}$ ) çıkarılıp ikili üçlü yan yana eklenmiş bu kanal birleşimlerinden elde edilen çok kanallı  $\text{ÇS\_YİÖ}$  özniteliklerinin YST başarımı incelenmiştir. Burada örneğin  $\text{ÇS\_YİÖ}_H$  görüntünün H kanalından çıkarılan  $\text{ÇS\_YİÖ}$  histogramını ifade etmektedir. Hesaplama ve depolama maliyetlerinin yanı sıra sınıflandırma sürelerini azaltmak için, TBA kullanılarak özellik vektörü boyutları küçültülmüştür. Son olarak, giriş görüntüsünü gerçek veya sahte olarak sınıflandırmak için bir DVM sınıflandırıcısı eğitilmiştir.

## 4. Deneyle ve Bulgular

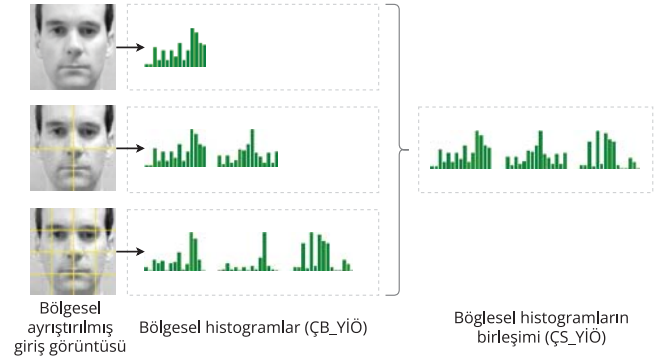
Bu bölümde çalışmada kullanılan veri kümeleri, sistem başarımı değerlendirme ölçütleri ve elde edilen bulgular açıklanmıştır.

### 4.1 Veri kümeleri

Önerilen yöntemin başarımı, daha önceki çalışmalarda sıklıkla kullanılan CASIA ve Replay-Attack veri kümeleri üzerinde değerlendirilmiştir. Sonraki alt bölümlerde bu veri kümeleri detaylı bir şekilde açıklanmaktadır.

#### 4.1.1 CASIA (CASIA-FASD) Veri kümesi

CASIA-FASD [31] basılı fotoğraf (photo) ve video yeniden oynatma (video replay) saldırılarını içeren bir YST veri kümesidir. Veri kümesi 3 saldırı türünden oluşmaktadır. Bunlar; bükülmüş fotoğraf saldırısı (warped photo), göz bölgesi kesilmiş basılı fotoğraf saldırısı (cut photo) ve video




Şekil-3:  $\text{ÇB\_YİÖ}$  ve  $\text{ÇS\_YİÖ}$  öznitelik vektörünün üretilmesi

yeniden oynatma (video replay) saldırısıdır. Veriler tüm saldırı türleri için üç farklı görüntüleme kalitesi kullanılarak elde edilmiştir. Yüksek kalite verileri (high quality)  $1280 \times 720$  piksel çözünürlüğe, orta kalite (normal quality) ve düşük kalite (low quality) veriler ise  $640 \times 480$  piksel çözünürlüğe sahiptir. Veri kümesi eğitim ve test kümelerine ayrılmıştır. Eğitim kümesi 20 kişiden (subject) alınan gerçek ve sahte görüntüleri içerirken, test kümesi 30 kişinin gerçek ve sahte görüntülerinden oluşmaktadır. Çalışmada, bu veri kümesi üzerinde yüz bölgeleri tespit edilebilen tüm çerçeveler kullanılmıştır. Veri kümesinde bulunan saldırı türleri, toplam video ve çalışmada kullanılan toplam çerçeve sayıları Çizelge 1'de, bu saldırı türlerinde kullanılan detaylı örnek sayıları ise Çizelge 2'de verilmiştir. CASIA-FASD veri kümesinden örnek görüntüler ise Şekil 4'te görülmektedir.

#### 4.1.2 Replay-Attack Veri kümesi

Replay-Attack veri kümesi [9] 50 kişinin (subject) gerçek ve sahte erişim videolarından oluşmaktadır. Videolar Macbook Air 13" kamerası ile iki farklı aydınlatma koşulunda elde edilmiştir. Kontrollü ortamda (controlled) arka plan sabittir ve aydınlatma floresan lamba ile sağlanmıştır. Kontrolsüz ortamda (uncontrolled) ise gün ışığında ve sabit olmayan arka planda görüntüler çekilmiştir. Yüksek çözünürlüklü fotoğraf ve videolar iPhone 3GS ve Canon PowerShot SX150 IS cihazları ile elde edilmiştir. Bu kayıtlar, üç farklı saldırı türünün üretilmesinde kullanılmıştır. Basılı fotoğraf (printed photo) saldırısında A4 kağıdına basılmış yüksek çözünürlüklü fotoğraflar kamerasıya gösterilmiştir. Mobil (mobile) saldırılarda yüksek çözünürlüklü fotoğraflar (digital photo) ve videolar (video replay) iPhone 3GS ekranından kamerasıya çekilmiştir. Yüksek çözünürlük (high resolution) saldırısında ise fotoğraflar ve videolar iPad ekranı kullanılarak kamerasıya gösterilmiştir. Saldırı türleri görüntü/videoların kamerasıya gösterim şekline göre iki alt gruba ayrılmaktadır. Birinci grupta giriş cihazı elde tutulurken (hand), ikinci grupta cihaz bir yere sabitlenmiştir (fixed). Veri kümesi eğitim, geliştirme ve test olmak üzere üç gruptan oluşmaktadır. Çalışmada, 125ms aralıklarla elde edilen örneklerden, yüz bölgeleri tespit edilebilen çerçevelerin tümü kullanılmıştır. Veri kümesinde bulunan saldırı türleri, toplam video ve çalışmada kullanılan toplam çerçeve sayıları Çizelge 1'de, bu saldırı türlerinde kullanılan detaylı örnek sayıları ise Çizelge 2'de verilmiştir. Replay-Attack veri kümesinden örnek görüntüler ise Şekil 5'te görülmektedir.



**Şekil-4:** CASIA veri kümesinden yüksek kalite gerçek ve sahte görüntü örnekleri (soldan sağa: gerçek, bükülmüş fotoğraf, kesilmiş fotoğraf, video oynatma saldırısı)



**Şekil-5:** Replay-Attack veri kümesinden gerçek ve sahte görüntü örnekleri (soldan sağa: gerçek, yüksek çözünürlük, mobil, basılı fotoğraf saldırısı)

**Çizelge-1:** CASIA ve Replay-Attack veri kümeleri için içerik bilgisi

Veri kümesi	Kişi Sayısı	Aydınlatma Koşulları	Cihaz Konumu	Saldırı Türleri	Gerçek/Sahte Video Sayısı	Kullanılan Çerçeve (Toplam Çerçeve) %
CASIA-FASD	50	Kontrollü	Sabit	Düşük kalite Normal Kalite Yüksek Kalite Bükülmüş Fotoğraf Kesilmiş Fotoğraf Video Oynatma Tümü	150/450	110379 (111025) %99,418
Replay-Attack	50	Kontrollü KontROLSÜZ	Elde Sabit Tümü	Yüksek Çözünürlük Mobil Basılı Fotoğraf Dijital Fotoğraf Video Oynatma Tümü	200/1000	101201 (311207) %32,519

**Çizelge-2:** Deneyleerde kullanılan örnek sayıları

Veri kümesi	Saldırı Türü	Gerçek Örnek Sayıları			Sahte Örnek Sayıları		
		Eğitim	Geliştirme	Test	Eğitim	Geliştirme	Test
CASIA	Düşük kalite	3140	-	5297	11015	-	16088
	Normal Kalite	3197	-	4830	11231	-	16085
	Yüksek Kalite	4577	-	5782	11846	-	17291
	Bükülmüş Fotoğraf	10914	-	15909	12859	-	19165
	Kesilmiş Fotoğraf				9499		14731
	Video Oynatma				11734		15568
	Tümü				34092		49464
Replay-Attack	Yüksek Çözünürlük	7185	7197	9596	9518	9284	12279
	Mobil				9420	9168	11815
	Basılı Fotoğraf				4765	4738	6236
	Dijital Fotoğraf				14307	14031	18360
	Video Oynatma				9396	9159	11970
	Tümü				23703	23190	30330

#### 4.2 Değerlendirme Ölçütleri


Bir YST sistemi temelde iki tür hatayla karşı karşıyadır. Bunlar; gerçek erişim reddi (yanlış ret) ve bir saldırının kabulüdür (yanlış kabul). Bu sistemlerin performansı genellikle yarı toplam hata oranı (Half Total Error Rate- HTER) metriği ile ölçülür. HTER, Yanlış Kabul Oranı-(False Acceptance Rate-FAR) ve Yanlış Reddetme Oranı-(False Rejection Rate -FRR) toplamının yarısıdır ve aşağıdaki Denklem (5) ile hesaplanır.

$$HTER(\tau) = \frac{FAR(\tau) + FRR(\tau)}{2} \quad (5)$$

FAR ve FRR,  $\tau$  eşik değerine bağlı olduğundan, FAR'ın azalması FRR'nin artmasına neden olur. Bu nedenle, sonuçlar genellikle farklı  $\tau$  eşik değerleri için FAR'ın, FRR'ye göre değişimini

gösteren grafiklerle temsil edilir. YST'de kullanılan diğer bir ölçüt olan eşit hata oranı (Equal Error Rate- EER), bu grafik üzerinde FAR ve FRR'nin eşit olduğu noktadaki değerdir (Şekil 6). Bu değere karşılık gelen  $\tau$  eşik değeri geliştirme setinden elde edilir ve bu eşik değeri kullanılarak test setinden HTER hesaplanır.

Çalışmada sistem performansının değerlendirilmesinde EER ve HTER dışında AUC (Area Under Curve) ölçütü kullanılmıştır. AUC, ROC olasılık eğrisi altında kalan alanı ifade etmektedir. ROC eğrisi, hatalı pozitif oranının (False Positive Rate- FPR) gerçek pozitif oranına (True Positive Rate- TPR) göre değişimini göstermektedir (Denklem 6).



Şekil-6: EER değerinin elde edilmesi

$$TPR = \frac{TP}{TP + FN} \quad FPR = \frac{FP}{TN + FP} \quad (6)$$

Denklemden TP, doğru tahmin edilen pozitif örnekler, FP, yanlış tahmin edilen pozitif örnekler, TN, doğru tahmin edilen negatif örnekler ve FN yanlış tahmin edilen negatif örnekler temsil etmektedir. AUC ölçütü, modelin sınıflar arasında ne kadar ayırım yapabildiğini ifade eder. AUC ne kadar yüksekse, model tahmin etmede o kadar iyidir denebilir.

### 4.3 Bulgular

Deneylerde renkli görüntüler HSV,  $YCbCr$  ve  $L^*a^*b^*$  renk uzaylarına dönüştürülmüş ve her kanaldan  $\mathcal{C}_S\_YiÖ$  öznelikleri ( $\mathcal{C}_S\_YiÖ_H$ ,  $\mathcal{C}_S\_YiÖ_S$ ,  $\mathcal{C}_S\_YiÖ_V$ ,  $\mathcal{C}_S\_YiÖ_Y$ ,  $\mathcal{C}_S\_YiÖ_{Cb}$ ,  $\mathcal{C}_S\_YiÖ_{Cr}$ ,  $\mathcal{C}_S\_YiÖ_{L^*}$ ,  $\mathcal{C}_S\_YiÖ_{a^*}$ ,  $\mathcal{C}_S\_YiÖ_{b^*}$ ) üretilmiştir. Çıkarılan  $\mathcal{C}_S\_YiÖ$  öznelikleri,  $LBP_{8,1} (1 \times 1)$ ,  $LBP_{8,1} (2 \times 2)$  ve  $LBP_{8,1} (4 \times 4)$   $\mathcal{C}_B\_YiÖ$  öznelik vektörlerinin birleşiminden meydana gelmektedir. Kanallardan çıkarılan öznelıklar öncelikle renk uzayı bazında birleştirilerek ( $\mathcal{C}_S\_YiÖ_{HSV}$ ,  $\mathcal{C}_S\_YiÖ_{YCbCr}$ ,  $\mathcal{C}_S\_YiÖ_{L^*a^*b^*}$ ) YST tespiti başarımı incelenmiştir. Veri kümelerinin eğitim kümelerindeki görüntülerden üretilen öznelik vektörleri SVM sınıflayıcısının eğitiminde kullanılmıştır. Çalışmada SVM sınıflayıcısında RBF (Radial Basis Function) çekirdek fonksiyonu kullanılmıştır. Diğer parametreler ise  $C=1.0$ ,  $\Gamma=1/(\text{öznelik sayısı} \times \text{varyans})$  şeklindedir.

CASIA veri kümesindeki 7 farklı saldırı senaryosu ve Replay-Attack veri kümesindeki 6 farklı saldırı senaryosu için elde edilen EER ve HTER değerleri Çizelge 3'te verilmiştir.

Çizelgeden görüldüğü gibi genel olarak saldırı senaryolarında, HSV renk uzayının kanallarından çıkarılan  $\mathcal{C}_S\_YiÖ$  histogramlarının birleşiminden meydana gelen öznelik vektörleri daha başarılıdır, fakat  $YCbCr$  ve  $L^*a^*b^*$  renk uzaylarından çıkarılan özneliklerin de başarılı olduğu senaryolar mevcuttur. Bu nedenle bu renk uzaylarının kanallarının çeşitli birleşimlerinde üretilen öznelik vektörleri ile YST başarımının artırılması hedeflenmiştir. Kanalların ikili ve üçlü birleşimlerinden üretilen öznelik vektörleri ile elde edilen YST başarımları CASIA veri kümesi için Çizelge 4'te, Replay-Attack veri kümesi için Çizelge 5'te verilmiştir.

Çizelge 4, CASIA veri kümesinde genel olarak HSV ve  $YCbCr$  renk uzaylarının kanallarından üretilen öznelik birleşimlerinin daha iyi bir YST başarımı sağladığını göstermektedir. Yüksek kalite saldırı senaryosunda HSV ve  $L^*a^*b^*$  renk uzaylarından üretilen öznelik vektörleri daha yüksek bir başarımla YST gerçekleştirmektedir. Düşük kalite saldırı senaryosunda ise renk uzaylarının H, S,  $C_b$  ve  $C_r$  kanallarından üretilen öznelik vektörlerinin birleşiminin YST başarımı daha yüksektir. Bu veri kümesinde en iyi YST başarımı %0,11 EER ile Normal kalite saldırı senaryosunda elde edilmiştir. CASIA veri kümesi için tüm saldırı türlerinin birlikte değerlendirildiği test senaryosunda ise  $\mathcal{C}_S\_YiÖ_{HSV} + \mathcal{C}_S\_YiÖ_{YCbCr}$  öznelikleri ile %2,22 EER YST başarımı elde edilmiştir. Bu sonuç için elde edilen AUC değeri ise %97,10'dur. Replay-Attack veri kümesi için elde edilen YST başarımları incelendiğinde ise çeşitli kanal birleşimleriyle daha iyi sonuçlar elde edildiği görülmektedir (Çizelge 5). Yüksek çözünürlük saldırısında H, S, V,  $L^*$ ,  $a^*$  ve  $b^*$  kanal özneliklerinin birleşimi, mobil ve video oynatma saldırılarında H, S,  $C_b$  ve  $C_r$  kanal özneliklerinin birleşimi, basılı fotoğraf saldırısında H, S,  $a^*$  ve  $b^*$  kanal özneliklerinin birleşimi, sayısal fotoğraf saldırısında ise H, S,  $a^*$ ,  $b^*$ ,  $C_b$  ve  $C_r$  kanal özneliklerinin birleşimi daha iyi YST başarımı sağlamıştır. Replay-Attack veri kümesi için tüm saldırı türlerinin birlikte değerlendirildiği test senaryosunda  $\mathcal{C}_S\_YiÖ_H + \mathcal{C}_S\_YiÖ_{a^*b^*} + \mathcal{C}_S\_YiÖ_{CbCr}$  öznelikleri ile %0,03 HTER YST başarımı elde edilmiştir. Bu sonuç için elde edilen AUC değeri ise %99,97'dir.

Çizelge-3:  $\mathcal{C}_S\_YiÖ_{HSV}$ ,  $\mathcal{C}_S\_YiÖ_{YCbCr}$ ,  $\mathcal{C}_S\_YiÖ_{L^*a^*b^*}$  özneliklerinin CASIA ve Replay-Attack veri kümesindeki YST başarımları

Veri kümesi	Saldırı Türü	Öznelik Türü					
		$\mathcal{C}_S\_YiÖ_{HSV}$		$\mathcal{C}_S\_YiÖ_{YCbCr}$		$\mathcal{C}_S\_YiÖ_{L^*a^*b^*}$	
		EER	AUC	EER	AUC	EER	AUC
CASIA	Düşük kalite	5,10	96,22	<b>4,40</b>	94,81	6,53	94,71
	Normal Kalite	<b>0,11</b>	99,58	2,00	98,22	2,35	97,73
	Yüksek Kalite	<b>5,15</b>	90,10	6,89	90,60	5,92	92,49
	Eğrilmiş Fotoğraf	<b>3,75</b>	96,25	6,06	94,17	4,41	94,84
	Kesilmiş Fotoğraf	<b>2,96</b>	96,01	4,87	94,33	3,01	95,82
	Video Oynatma	<b>1,38</b>	99,02	2,78	97,43	2,68	97,31
	Tümü	<b>2,46</b>	96,38	6,83	92,93	4,49	95,43
	<b>HTER</b>	<b>AUC</b>	<b>HTER</b>	<b>AUC</b>	<b>HTER</b>	<b>AUC</b>	
Replay-Attack	Yüksek Çözünürlük	<b>0,84</b>	99,16	1,90	98,10	1,17	98,84
	Mobil	<b>0,00</b>	100,00	1,12	98,88	3,11	96,90
	Basılı Fotoğraf	1,81	98,19	<b>0,56</b>	99,44	1,11	98,89
	Dijital Fotoğraf	<b>0,80</b>	99,20	1,49	98,51	0,85	99,15
	Video Oynatma	<b>0,62</b>	99,38	2,37	97,63	3,31	96,69
	Tümü	0,71	99,29	1,28	98,72	<b>0,70</b>	99,30

Çizelge-4: Farklı renk kanallarının birleşimi ile üretilen özneliklerin CASIA veri kümesindeki YST başarımları (EER)

Öznelik Vektörünün Üretilmesinde Kullanılan Renk Kanalları	Düşük Kalite	Normal Kalite	Yüksek Kalite	Bükülmüş Fotoğraf	Kesilmiş Fotoğraf	Video Oynatma	Tümü
HSV + L*a*b*	5,70	<b>0,12</b>	<b>4,97</b>	2,92	2,09	1,50	2,43
HSV + YCbCr	5,09	<b>0,12</b>	5,60	<b>2,45</b>	<b>2,04</b>	<b>1,31</b>	<b>2,22</b>
L*a*b* + YCbCr	5,25	2,29	6,30	4,44	2,82	2,60	4,89
HS + a*b*	4,43	0,90	5,40	3,76	2,53	2,55	2,97
HS + CbCr	<b>4,27</b>	0,89	6,77	3,84	2,93	2,37	3,24
a*b* + CbCr	6,21	3,91	10,81	5,84	5,17	4,97	6,05
HS + a*b* + CbCr	4,71	1,07	7,14	3,75	2,76	2,73	3,03
HSV + L*a*b* + YCbCr	5,93	0,29	5,55	2,75	2,07	1,53	2,55

Çizelge-5. Farklı renk kanallarının birleşimi ile üretilen özneliklerin Replay-Attack veri kümesindeki YST başarımları (HTER)

Öznelik Vektörünün Üretilmesinde Kullanılan Renk Kanalları	Yüksek Çözünürlük	Mobil	Basılı Fotoğraf	Dijital Fotoğraf	Video Oynatma	Tümü
HSV + L*a*b*	<b>0,36</b>	0,93	0,23	0,28	0,50	0,20
HSV + YCbCr	0,75	0,00	0,91	0,63	0,26	0,54
L*a*b* + YCbCr	1,38	1,16	0,35	0,96	2,85	0,60
HS + a*b*	1,02	0,10	<b>0,10</b>	0,03	0,33	0,05
HS + CbCr	1,20	<b>0,00</b>	0,14	0,11	<b>0,04</b>	0,12
a*b* + CbCr	1,29	0,55	4,38	1,70	1,44	1,23
HS + a*b* + CbCr	1,21	0,00	0,65	<b>0,00</b>	0,22	<b>0,03</b>
HSV + L*a*b* + YCbCr	0,65	0,13	0,04	0,26	1,09	0,24

Çizelge-6. Önerilen YST yönteminin veri kümeleri için eğitim süreleri ve bir test görüntüsü için karar verme süresi

Veri Seti	Öznelik türü	Eğitim Görüntü Sayısı	Eğitim süresi	Geliştirme Görüntü Sayısı	Geliştirme süresi	Test süresi (1 görüntü)
CASIA	ÇS_YiÖ <sub>HSV</sub> + ÇS_YiÖ <sub>YCbCr</sub>	45006	6073,42 sn	-	-	0,01 sn
Replay-Attack	ÇS_YiÖ <sub>HS</sub> + ÇS_YiÖ <sub>a*b*</sub> + ÇS_YiÖ <sub>CbCr</sub>	30888	1973,96 sn	30387	220,38 sn	0,01 sn

Deneyler i7 7700k, 3.60 GHz işlemci ve 8GB DDR4 belleğe sahip bilgisayarda gerçekleştirilmiştir. Önerilen YST yönteminin veri kümeleri için eğitim süreleri ve bir test görüntüsü için karar verme süresi Çizelge 6'da verilmiştir. Çizelgeden görüldüğü gibi sistem eğitimi tamamlandıktan sonra bir görüntünün gerçek/sahte olarak değerlendirilmesi 0,01 sn gibi çok kısa bir sürede gerçekleştirilmektedir.

## 5. Tartışma

Çizelge 3, 4, 5 incelendiğinde CASIA veri kümesindeki yüksek kalite atağının normal ve düşük kalite ataklarına göre genel olarak daha düşük başarımlar gösterdiği görülmektedir. Aynı durum Replay-Attack veri kümesindeki yüksek çözünürlük atağı için de geçerlidir. Yüksek çözünürlüklü görüntülerin daha çok bilgi taşıması nedeniyle YST'de daha iyi sonuç verebileceği düşünülebilir. Fakat gerçek görüntülerle sahte görüntüleri birbirinden ayırt etmeyi sağlayan, gerçek görüntüdeki yüksek frekans bileşenlerinin, sahte görüntülerin elde edilmesi sırasında zayıflamasıdır. Fakat cihaz kalitesi yükseldikçe sahte görüntülerdeki yüksek frekans içeriği güçlendirildiği için bu görüntülerin gerçek görüntülerden ayırt edilmesi zorlaşır.

Önerilen YST yönteminin literatürde yapılan çalışmalarla karşılaştırılması Çizelge 7'de verilmiştir. Çizelgeden görüldüğü gibi önerilen yöntemle Replay-Attack veri kümesi için, renk uzaylarından doku bilgisi üretme konusunda HSV ve YCbCr

Çizelge-7: Önerilen yöntemin literatürdeki çalışmalarla karşılaştırılması

Yöntem	CASIA	Replay-Attack	
	EER	EER	HTER
Color LBP (YCbCr + HSV) [2]	6,20	0,40	2,90
CoALBP + LPQ (YCbCr + HSV) [11]	2,10	0,40	2,80
LBP + Color Moment [19]	5,88	-	14,60
Color SURF (YCbCr + HSV) [20]	2,80	0,10	2,20
LBP + GS-LBP [21]	3,05	0,69	3,31
LGBP [21]	7,06	7,08	8,29
Color Texture [5]	4,60	1,20	4,20
CTMF + SVM-RFE [4]	8,00	4,00	4,40
LDN-TOP [12]	<b>0,37</b>	-	3,13
Önerilen Yöntem	<b>2,22</b>	<b>0,01</b>	<b>0,03</b>

renk uzaylarının birleşiminden üretilen YiÖ özneliklerini kullanan çalışmalardan, daha iyi başarımlar elde edilmiştir. Literatürdeki çalışmalarda elde edilen sonuçlara paralel olarak, bu çalışmada da renk uzaylarının kromatik bileşenlerinden çıkarılan özneliklerin yüz sahteciliği tespitinde daha başarılı olduğu görülmüştür. Bu kromatik bileşenlerin, parlaklık bileşenlerine göre daha fazla doku bilgi taşımasının bir sonucudur.

Önerilen yöntem CASIA veri kümesi için LDN-TOP yönteminden daha düşük bir başarımlar göstermiştir. LDN-TOP yöntemi, peş peşe gelen çok sayıda (15, 25, ..., 55, 65, 75) çerçeveyi işleme sokarak öznelik çıkarmaktadır. Çerçeve



sayısının artışına bağlı olarak iyileşme sağlanmaktadır, fakat CASIA veri kümesinde bazı videolar LDN-TOP özneliklerini çıkarmak için yeterli sayıda çerçeveye sahip değildir [12]. Bu çalışmada önerilen yöntemde sadece bir çerçeve üzerinden gerçek/sahte kararı verilmektedir. Ayrıca LDN-TOP yöntemine göre hesaplama karmaşıklığı çok düşük, yorumlanabilir özelliği ise daha yüksektir. Diğer yandan CASIA veri kümesinde yüz bölgesinin belirlenebildiği tüm çerçeveler deneylerde kullanılmıştır. Elde edilen başarımlar literatürle kıyaslanabilir niteliktedir. Ek olarak çoğu çalışmada veri kümesindeki hangi çerçevelerin kullanıldığı bilgisi verilmemiştir. Bu durum sonuçların adil bir şekilde kıyaslanmasını doğrudan etkilemektedir.

Diğer yandan çoğu çalışmada saldırı senaryoları için ayrı sonuç verilmemektedir. Çalışmada, önerilen yöntemin farklı saldırı senaryolarındaki başarımlarını değerlendirilmiştir. Önerilen yöntem, renk uzaylarının problem çözümüne en uygun olan kanallarından öznelik çıkarıp birleştirilerek başarımlarını artırmıştır. Ayrıca önerilen yöntem daha iyi başarımlar raporlayan yöntemlere göre çok daha basittir ve düşük hesaplama karmaşıklığına sahiptir. Bu nedenle yöntemin YST konusunda başarılı olduğu söylenebilir.

## 6. Sonuçlar

Bu çalışmada gerçek ve sahte yüzleri birbirinden ayıran bir yöntem önerilmiştir. Yöntem cihaza bağımlı ve cihazdan bağımsız renk kanallarından çıkarılan çok seviyeli YİÖ özneliklerinin birleşimini kullanarak, saldırı türünden ve saldırıda kullanılan cihazdan bağımsız bir YST amaçlamaktadır. Çoklu renk özneliklerini çıkarmak için cihazdan bağımsız  $L^*a^*b^*$  ve cihaza bağımlı HSV,  $YCbCr$  renk uzayları kullanılmıştır. Bu renk uzaylarının kanallarından çıkarılan öznelik vektörleri ikili ve üçlü birleştirilerek etkin ve başarılı YST hedeflenmiştir. Deneyler önceki çalışmalarda sıklıkla kullanılan CASIA ve Replay-Attack yüz sahteciliği veri kümeleri üzerinde toplamda 13 farklı saldırı senaryosunda gerçekleştirilmiş, elde edilen sonuçlar yöntemin YST konusunda başarılı olduğunu göstermiştir. Gelecek çalışmalarda farklı renk kanallarından çeşitli öznelik çıkarma yöntemleri ile çıkarılan özneliklerin birlikte kullanılarak YST başarımlarının yükseltilmesi hedeflenmektedir. Ayrıca bu renk kanallarından derin öğrenme tabanlı öznelikler çıkarılarak YST gerçekleştirilebilir.

## Kaynakça

- [1] De Freitas Pereira, T., Komulainen, J., Anjos, A., De Martino, J. M., Hadid, A., Pietikäinen, M., Marcel, S., *Face liveness detection using dynamic texture*, EURASIP Journal on Image and Video Processing, 2, 2014, <http://jivp.eurasipjournals.com/content/2014/1/2>
- [2] Boulkenafet, Z., Komulainen, J., Hadid, A., *Face anti-spoofing based on color texture analysis*, Proceedings - International Conference on Image Processing, ICIP, 2015, pp. 2636–2640. <https://doi.org/10.1109/ICIP.2015.7351280>
- [3] Parveen, S., Ahmad, S. M. S., Abbas, N. H., Adnan, W. A. W., Hanafi, M., Naeem, N., *Face liveness detection using dynamic local ternary pattern*, Computers, 5(2), 2016, pp. 1–15. <https://doi.org/10.3390/computers5020010>
- [4] Zhang, L. B., Peng, F., Qin, L., Long, M., *Face spoofing detection based on color texture Markov feature and support vector*

- machine recursive feature elimination*, Journal of Visual Communication and Image Representation, 51, 2018, pp. 56–69. <https://doi.org/10.1016/j.jvcir.2018.01.001>
- [5] Boulkenafet, Z., Komulainen, J., Hadid, A., *On the generalization of color texture-based face anti-spoofing*, Image and Vision Computing, 77, 2018, pp.1–9.
- [6] Li, L., Feng, X., Xia, Z., Jiang, X., Hadid, A., *Face spoofing detection with local binary pattern network*, Journal of Visual Communication and Image Representation, 54, 2018, pp.182–192. <https://doi.org/10.1016/j.jvcir.2018.05.009>
- [7] Li, L., Feng, X., Jiang, X., Xia, Z., Hadid, A., *Face anti-spoofing via deep local binary patterns*, Proceedings - International Conference on Image Processing, ICIP, 2018, pp.101–105. <https://doi.org/10.1109/ICIP.2017.8296251>
- [8] Li, H., He, P., Wang, S., Rocha, A., Jiang, X., Kot, A. C., *Learning Generalized Deep Feature Representation for Face Anti-Spoofing*, IEEE Transactions on Information Forensics and Security, 13(10), 2018, pp.2639–2652. <https://doi.org/10.1109/TIFS.2018.2825949>
- [9] Chingovska, I., Anjos, A., Marcel, S., *On the effectiveness of local binary patterns in face anti-spoofing*, Proceedings of the International Conference of the Biometrics Special Interest Group, BIOSIG 2012, 2012.
- [10] Määttä, J., Hadid, A., Pietikäinen, M., *Face spoofing detection from single images using micro-texture analysis*, International Joint Conference on Biometrics, IJCB, 2011. <https://doi.org/10.1109/IJCB.2011.6117510>
- [11] Boulkenafet, Z., Komulainen, J., Hadid, A., *Face Spoofing Detection Using Colour Texture Analysis*, IEEE Transactions on Information Forensics and Security, 11(8), 2016, pp. 1818–1830. <https://doi.org/10.1109/TIFS.2016.2555286>
- [12] Zhou, J., Shu, K., Liu, P., Xiang, J., Xiong, S., *Face anti-spoofing based on dynamic color texture analysis using local directional number pattern*, Proceedings - International Conference on Pattern Recognition, 2020, pp.4221–4228. <https://doi.org/10.1109/ICPR48806.2021.9412323>
- [13] Anjos, A., Chakka, M. M., Marcel, S., *Motion-based countermeasures to photo attacks in face recognition*, IET Biometrics, 3(3), 2014, pp.147–158. <https://doi.org/10.1049/iet-bmt.2012.0071>
- [14] Alotaibi, A., Mahmood, A., *Deep face liveness detection based on nonlinear diffusion using convolution neural network*, Signal, Image and Video Processing, 11(4), 2017, pp.713–720. <https://doi.org/10.1007/s11760-016-1014-2>
- [15] Galbally, J., Marcel, S., Fierrez, J., *Image quality assessment for fake biometric detection: Application to Iris, fingerprint, and face recognition*, IEEE Transactions on Image Processing, 23(2), 2014, pp.710–724. <https://doi.org/10.1109/TIP.2013.2292332>
- [16] Wen, D., Han, H., Jain, A. K., *Face spoof detection with image distortion analysis*, IEEE Transactions on Information Forensics and Security, 2015. <https://doi.org/10.1109/TIFS.2015.2400395>
- [17] Agarwal, A., Singh, R., Vatsa, M., *Face anti-spoofing using Haralick features*, IEEE 8th International Conference on Biometrics Theory, Applications and Systems, BTAS, 2016. <https://doi.org/10.1109/BTAS.2016.7791171>
- [18] Määttä, J., Hadid, A., Pietikäinen, M., *Face spoofing detection from single images using texture and local shape analysis*, IET Biometrics, 1(1), 2012, pp.3–10. <https://doi.org/10.1049/iet-bmt.2011.0009>
- [19] Patel, K., Han, H., Jain, A. K., *Secure Face Unlock: Spoof Detection on Smartphones*, IEEE Transactions on Information Forensics and Security, 11(10), 2016, pp.2268–2283. <https://doi.org/10.1109/TIFS.2016.2578288>
- [20] Boulkenafet, Z., Komulainen, J., Hadid, A., *Face antispoofing using speeded-up robust features and fisher vector encoding*,

- IEEE Signal Processing Letters, 24(2), 2017, pp.141–145.  
<https://doi.org/10.1109/LSP.2016.2630740>
- [21] Peng, F., Qin, L., Long, M., *Face presentation attack detection using guided scale texture*, Multimedia Tools and Applications 77(7), 2017 pp.8883–8909. <https://doi.org/10.1007/S11042-017-4780-0>
- [22] Khurshid, A., Tamayo, S. C., Fernandes, E., Gadelha, M. R., Teofilo, M., *A robust and real-time face anti-spoofing method based on texture feature analysis*, International Conference on Human-Computer Interaction, 2019, pp.484–496.
- [23] King, D. E., *Dlib-ml: A machine learning toolkit*. The Journal of Machine Learning Research, 10, 2009, pp.1755–1758.
- [24] Bora, D. J., Kumar Gupta, A., Khan, F. A., *Comparing the Performance of L\*A\*B\* and HSV Color Spaces with Respect to Color Image Segmentation*, International Journal of Emerging Technology and Advanced Engineering, 5 (2), 2015.
- [25] Huang, Z. K., Liu, D. H., *Segmentation of color image using EM algorithm in HSV color space*, Proceedings of the 2007 International Conference on Information Acquisition, 2007, pp.316–319. <https://doi.org/10.1109/ICIA.2007.4295749>
- [26] Vezhnevets, V., Sazonov, V., Andreeva, A., *A Survey on Pixel-Based Skin Color Detection Technique*, In Proceedings of the Graphi Conference, 2003, pp.85-92.
- [27] Murali, S., Govindan, V. K., *Shadow detection and removal from a single image: Using LAB color space*, Cybernetics and Information Technologies, 13(1), 2013, pp.95–103. <https://doi.org/10.2478/cait-2013-0009>
- [28] Baldevbhai, P. J., Anand, R. S., *Color Image Segmentation for Medical Images using L\*a\*b\*\* Color Space*, IOSR Journal of Electronics and Communication Engineering, 1(2), 2012, pp.24–45. <https://doi.org/10.9790/2834-0122445>
- [29] Ojala, T., Pietikäinen, M., Harwood, D., *Performance evaluation of texture measures with classification based on Kullback discrimination of distributions*, Proceedings - International Conference on Pattern Recognition, 3, 1994, pp.582–585. <https://doi.org/10.1109/ICPR.1994.576366>
- [30] Ojala, T., Pietikäinen, M., Mäenpää, T., *Multiresolution gray-scale and rotation invariant texture classification with local binary patterns*, IEEE Transactions on Pattern Analysis and Machine Intelligence, 2002. <https://doi.org/10.1109/TPAMI.2002.1017623>
- [31] Zhang, Z., Yan, J., Liu, S., Lei, Z., Yi, D., Li, S. Z., *A face antispoofing database with diverse attacks*, Proceedings - 2012 5th IAPR International Conference on Biometrics, 2012, pp.2–7. <https://doi.org/10.1109/ICB.2012.6199754>