

## Öznitelik Füzyonu Kullanarak Derin Öğrenme Tabanlı Yüz Tanıma

Halit Türbedar<sup>1\*</sup>, Fatih Bayram<sup>2</sup>

<sup>1</sup>Mekatronik Mühendisliği, Fen Bilimleri Enstitüsü, Afyon Kocatepe Üniversitesi, Afyonkarahisar, Türkiye

<sup>2</sup>Mekatronik Mühendisliği, Teknoloji Fakültesi, Afyon Kocatepe Üniversitesi, Afyonkarahisar, Türkiye  
[\\*halitturbedar@hotmail.com](mailto:halitturbedar@hotmail.com)

(Received: 17 February 2026, Accepted: 25 February 2026)

(3rd International Conference on Pioneer and Academic Research ICPAR 2026, February 16-17, 2026)

**ATIF/REFERENCE:** Türbedar, H. & Bayram, F. (2026). Öznitelik Füzyonu Kullanarak Derin Öğrenme Tabanlı Yüz Tanıma, *International Journal of Advanced Natural Sciences and Engineering Researches*, 10(2), 227-234.

**Özet** – Yüz tanıma sistemleri güvenlik, kimlik doğrulama, kişiselleştirilmiş uygulamalar, sürücü yorgunluk takibi gibi birçok farklı alanda giderek daha yaygın bir şekilde kullanılmaktadır. Bu çalışmada, geleneksel öznitelik çıkarım yöntemlerinin (Histogram of Oriented Gradients, HOG; Local Binary Patterns, LBP; Grayscale) derin öğrenme tabanlı bir sınıflandırma mimarisiyle entegre edilmesiyle geliştirilen hibrit bir model sunulmaktadır. Geleneksel yöntemlerin sınırlı genelleme kapasitesini aşmak amacıyla, elde edilen ayırt edici öznitelikler birleştirilerek derin öğrenme modeline girdi olarak sunulmuştur. Geliştirilen modelin performansı, Or1, Put, Feret, Yale ve Georgia Tech olmak üzere 5 farklı yüz tanıma veri seti üzerinde test edilmiştir. Deney sonuçlarına göre hibrit model test verileri üzerinde Or1'de %99.00, Put'da %97.80, Feret'te %97.37, Yale'de %95.76 ve Georgia Tech'te %95.33 doğruluk oranına ulaşmıştır. Bu sonuçlar, önerilen hibrit sistemin geleneksel yaklaşımlara kıyasla daha başarılı performans sergilediğini ortaya koymuştur.

**Anahtar Kelimeler** – Yüz Tanıma, Derin Öğrenme, Öznitelik Çıkarma, Öznitelik Füzyonu, Hibrit Model,

### I. GİRİŞ

Yüz tanıma teknolojileri, kullanıcının fiziksel etkileşimine gerek duymaması, hızlı ve gizli bir şekilde çalışabilmesi gibi avantajlarıyla öne çıkmaktadır. Özellikle artan güvenlik ihtiyaçları, dijital kimlik doğrulama sistemleri, akıllı gözetim uygulamaları ve insan-bilgisayar etkileşimi gibi pek çok alanda yüz tanıma sistemlerinin uygulanabilirliğini ve önemini artırmıştır.

Yüz tanıma sürecinin başarısı, genel olarak dört temel adımdan oluşur: yüzün tespiti, öznitelik çıkarımı, özelliklerin seçimi ve sınıflandırma. Bu süreçte başarıyı etkileyen en kritik adım, görüntüden anlamlı ve ayırt edici özniteliklerin çıkarılmasıdır. Bu nedenle, öznitelik çıkarımı üzerine yapılan araştırmalar, yüz tanıma performansını artırmaya yönelik çalışmaların odak noktası hâline gelmiştir. Özellikle Yönlendirilmiş Gradyan Histogramları (HOG), Yerel İkili Örüntüler (LBP) ve Gri Tonlama (Grayscale) gibi geleneksel yöntemler, düşük karmaşıklıkları ve güçlü ayırt edicilik yetenekleri nedeniyle yaygın şekilde tercih edilmektedir. Ancak, geleneksel öznitelik çıkarım yöntemlerinin sınırlı örnek sayısı, değişken aydınlatma koşulları, poz varyasyonları, yaşlanma ve kısmi kapanma gibi zorlu koşullar karşısında genelleme kapasiteleri sınırlı kalabilmektedir. Bu noktada derin öğrenme mimarileri, yüksek düzeyde özellik çıkarma ve öğrenme kapasitesi sayesinde önem kazanmıştır.

Yüz tanıma alanındaki çalışmaların temelleri, 1960'lı yıllarda Bledsoe tarafından atılmıştır [1]. 1990'lar itibarıyla bilgisayar bilimindeki gelişmelerle bu alandaki araştırmalar ivme kazanmıştır. Bu dönemin öne çıkan yöntemlerinden biri olan Temel Bileşen Analizi (PCA) tabanlı Eigenfaces, Turk ve Pentland tarafından boyut indirgeme ve örüntü tanıma tekniklerini birleştirerek yüz görüntülerini bir öznitelik uzayında temsil etmiştir [2]. Daha sonra, PCA'ya göre daha üstün performans sunan Fisherface, Belhumeur ve arkadaşları tarafından YALE veri seti üzerinde yapılan bir çalışmada, Eigenface'e göre daha düşük hata oranları elde etmiştir [3]. Geleneksel PCA'ya kıyasla daha yüksek ayırıştırma gücüne sahip olan Bağımsız Bileşenler Analizi (ICA) ise Bartlett tarafından yüz pikselleri arasındaki karmaşık ilişkileri modelleyerek tanıma performansını artırmıştır [4].

Bu çalışmanın temel amacı, geleneksel öznitelik çıkarım yöntemlerinin güçlü yönleri ile derin öğrenme modellerinin yüksek genelleme kapasitesini birleştirerek daha kararlı bir yüz tanıma sistemi oluşturmaktır. Çalışma kapsamında yüz görüntülerinden elde edilen gri tonlama, HOG ve LBP öznitelikleri geliştirilen derin öğrenme modeline girdi olarak verilmiştir. Hibrit modelin performansı, çeşitli veri setleri üzerinde değerlendirilmiştir. Makalenin devamında Bölüm 2'de kullanılan veri setleri ve önerilen metodoloji, Bölüm 3'te deneysel sonuçlar ve tartışma, Bölüm 4'te ise sonuç ve gelecek çalışmalar yer almaktadır.

## II. MATERYAL VE YÖNTEM

Bu çalışmada, Python programlama dili kullanılarak Google Colab geliştirme ortamında hibrit bir yüz tanıma sistemi geliştirilmiştir. Proje, veri analizi, model eğitimi ve değerlendirmesi için Keras, Scikit-learn, OpenCV, Pandas ve NumPy gibi farklı Python kütüphanelerini içermektedir. Çalışmada, farklı araştırmalarda yaygın olarak kullanılan beş hazır yüz tanıma veri seti kullanılmıştır [5]-[9]. Bu veri setleri, aydınlatma, pozisyon ve ifade varyasyonlarını barındırması nedeniyle modelin sağlamlığını test etmek için idealdir. Kullanılan veri setlerinden elde edilen sınıf, örnek sayıları ile koşullar ve öne çıkan özellikler Çizelge 1'de özetlenmiştir. Çizelgede yer alan bilgiler, çalışmada yararlanılan örnekler üzerinden elde edilmiştir.

Tablo 1. Yüz tanıma veri setlerinden elde edilen temel özelliklerin karşılaştırılması

Veri Setinin Adı	Sınıf Sayısı	Örnek Sayısı	Toplam Görüntü	Koşullar	Öne Çıkan Özellikler
Feret	194	10	1940	Farklı poz, ifade, ışık	Savunma projeleri için geliştirilmiş, geniş varyasyon
Georgia Tech	50	15	750	Doğal ortam, çeşitli pozlar	Gerçekçi senaryolar, doğal arka plan
Orl	40	10	400	Sabit arka plan, kontrollü ortam	Temel algoritmalar için uygun, klasik veri seti
Put	100	10	1000	Çoklu kamera, kontrollü ışık	Yönelim, ifade ve ışık kontrolü
Yale	39	60-65	2452	Kontrollü ortam, farklı ifadeler	İfade ve ışık analizine uygun, yüksek örnek sayısı

Bu çalışmada her veri seti için eğitim, doğrulama ve test bölmeleri veri setinin büyüklüğüne ve örnek çeşitliliğine göre belirlenmiştir. Bölme işlemlerinde sınıf dağılımının korunmasına dikkat edilmiştir. Model tasarımı ve eğitimi Keras altyapısı ile gerçekleştirilmiştir. Eğitim sürecinde ModelCheckpoint, ReduceLROnPlateau ve EarlyStopping gibi geri çağırma (callback) yöntemleri kullanılarak aşırı öğrenme kontrol altına alınmış ve doğrulama başarımı iyileşmediğinde öğrenme hızı azaltılarak eğitim sonlandırılmıştır. Erken durdurma (EarlyStopping) sonucunda eğitim, veri setine bağlı olarak 28-34 epoch aralığında tamamlanmıştır.

Önerilen hibrit model, öznitelik çıkarma ve sınıflandırma olmak üzere iki ana bileşenden oluşmaktadır.

#### A. Öznitelik Çıkarma


Çalışmada, yüz tanıma sürecinin ilk adımı olarak, her bir yüz görüntüsünden Gri Tonlama, HOG ve LBP öznitelik vektörleri paralel olarak çıkarılır. Bu vektörler, yüzdeki yerel gradyan yönelimleri, doku desenleri ve genel yoğunluk bilgisi gibi kritik özelliklerin yakalanmasını sağlar. Bu sayede, modelin farklı yüz özelliklerini daha kapsamlı bir şekilde öğrenmesi amaçlanmıştır.

- HOG (Histogram of Oriented Gradients): HOG, kenar yönelimlerini ve nesne şekillerini temsil etmede etkili bir öznitelik çıkarım yöntemidir [10]. Bu yöntemde, görüntü küçük hücrelere ayrılır ve her hücredeki gradyan yönelimleri histogramlar şeklinde hesaplanır. HOG algoritması, özellikle aydınlatma değişimlerine karşı kısmen dayanıklılığı sayesinde yüz tanıma uygulamalarında önemli bir rol oynamaktadır. Şekil 1’de, orijinal görüntü ile HOG sonrasında elde edilen örnek yüz görüntüsü karşılaştırmalı olarak sunulmuştur.



Şekil 1. HOG yöntemi uygulandıktan sonra elde edilen örnek yüz görüntüsü

- LBP (Local Binary Patterns): LBP, görüntüdeki doku desenlerini tanımlayan güçlü bir yöntemdir [11]. Bu yöntem, özellikle yüzdeki kırışıklıklar, benler ve gölgeler gibi ince yüzey yapılarını tanımlamak için kullanılır. LBP, her bir pikseli, etrafındaki komşu piksellerle karşılaştırarak bir ikili kod oluşturur. Eğer bir komşu pikselin değeri, merkez pikselin değerinden büyük veya eşitse '1', küçükse '0' olarak atanır. Bu ikili değerler bir araya getirilerek o pikselin LBP kodunu oluşturur. Şekil 2’de, LBP uygulanmadan önceki orijinal görüntü ile uygulama sonrası elde edilen örnek yüz görüntüsü gösterilmiştir.



Şekil 2. LBP yöntemi uygulandıktan sonra elde edilen örnek yüz görüntüsü

- Gri Tonlama: En basit ama etkili özniteliklerden biri olan Gri Tonlama, bir görüntünün renk bilgilerini ortadan kaldırarak onu sadece parlaklık değerleriyle temsil eder. Bu çalışmada, görüntü direkt olarak piksel değerleri kullanılarak bir vektöre dönüştürülür. Gri tonlama, yüzün genel aydınlatma ve gölge yapısını basit bir şekilde temsil ederek, diğer daha karmaşık özniteliklerle birlikte modelin tanıma

performansını artırır. Şekil 3'te, Grayscale uygulanmadan önceki orijinal renkli görüntü ile işlem sonrası elde edilen örnek yüz görüntüsü karşılaştırmalı olarak sunulmuştur.



Şekil 3. Grayscale yöntemi uygulandıktan sonra elde edilen örnek yüz görüntüsü

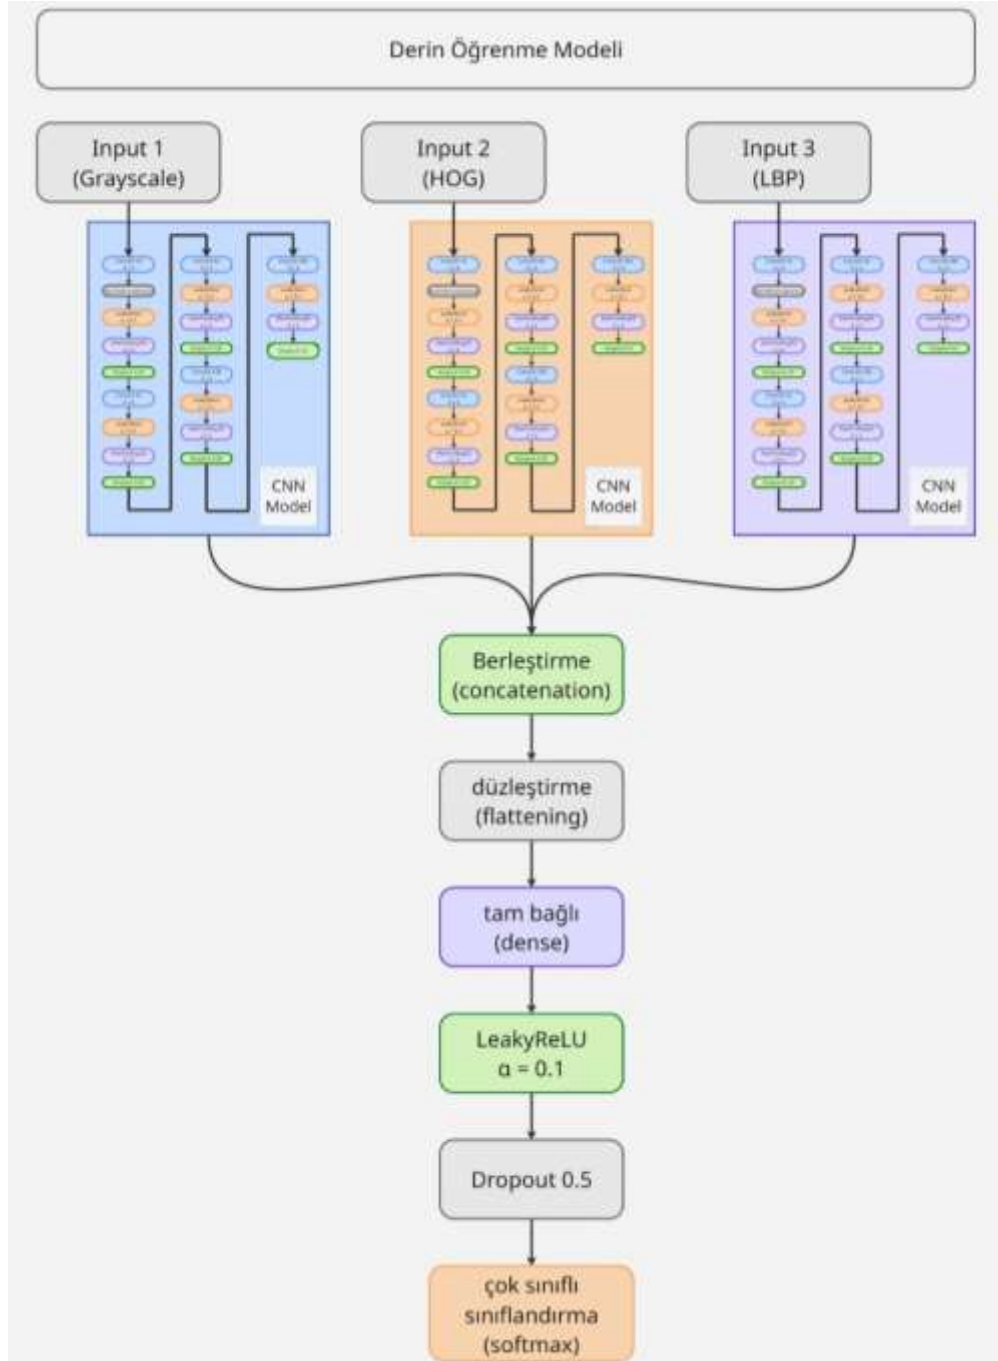
### B. Sınıflandırma

Bu çalışmada kullanılan CNN tabanlı derin öğrenme modeli, yüz görüntülerinden yüksek düzeyde özellikler çıkaracak şekilde tasarlanmıştır. Modelin ilk katmanı temel kenar ve şekil bilgilerini öğrenirken, sonraki katmanlar giderek daha karmaşık yapısal ve anlamsal özellikleri öğrenir. Filtre sayısı katmanlar boyunca artarak, yüz hatları, mimik detayları ve diğer ayırt edici özelliklerin öğrenilmesi sağlanır. Dropout ve MaxPooling gibi düzenleme teknikleri ile aşırı öğrenmenin önüne geçilmiş ve hesaplama yükü azaltılmıştır (Şekil-4).



Şekil 4. Geliştirilen CNN modelinin mimari şeması

Keras kütüphanesi kullanılarak geliştirilen derin öğrenme modeli, gri tonlamalı (Grayscale), HOG ve LBP öznitelikleri için üç ayrı giriş dalına sahiptir. Her bir giriş dalı, evrimsel katmanlar içerir. Bu dallar daha sonra birleştirilerek (concatenation), düzleştirme (flattening) işlemi uygulanır ve tam bağlı (dense) katmanlara aktarılır, ardından LeakyReLU aktivasyon fonksiyonu ve Dropout işlemleri uygulanır. Çıkış katmanı olarak, çok sınıflı sınıflandırma için (softmax) aktivasyon fonksiyonunu kullanır. Şekil 5'te geliştirilen derin öğrenme modelinin akış şeması gösterilmiştir.



Şekil 5. Derin öğrenme modelinin akış şeması

### III. BULGULAR VE TARTIŞMA

Bu bölümde, geliştirilen hibrit yüz tanıma modelinin performansına ilişkin detaylı sonuçlar sunulmuştur. Feret, Or1, Put, Yale ve Georgia veri setleri üzerinde yapılan deneylerde, önerilen sistemin

geleneksel yaklaşımlara göre daha üstün bir başarı sergilediği gözlemlenmiştir. Özellikle, farklı veri setlerindeki değişken koşullar (aydınlatma, poz, ifade) altında modelin kararlılığı ve genelleme yeteneği analiz edilmiştir. Modelin test görüntülerindeki doğruluk, kesinlik, duyarlılık ve F1 skoru gibi metriklerle değerlendirilen performansı Çizelge 2’de verilmiştir.

Çizelge 2. Modelin test görüntülerindeki performansı

Veri Seti	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	F1-score (%)
Orl	99.00	99.17	99.00	98.99
Put	97.80	98.26	97.80	97.78
Feret	97.37	97.89	97.21	97.06
Yale	95.76	96.10	95.74	95.77
Georgia Tech	95.33	96.50	95.33	95.00

Elde edilen sonuçlar, modelin tüm veri setlerinde %95’in üzerinde doğruluk sağlayarak yüksek bir genelleme kapasitesine sahip olduğunu göstermektedir. Orl veri setinde %99’un üzerindeki performans, modelin özellikle homojen veri dağılımlarında oldukça başarılı olduğunu ortaya koyarken, Yale ve Georgia Tech veri setlerinde görece daha düşük sonuçlar çeşitlilik ve zorluk düzeyine işaret etmektedir. Çizelge 3’te önerilen modelin performansı, literatürde aynı veri setleri kullanılarak yapılan çalışmaların elde ettiği doğruluk değerleri ile karşılaştırmalı olarak verilmiştir. Çizelgede görüldüğü üzere, önerilen model bazı veri setlerinde literatürdeki yöntemlerle karşılaştırılabilir hatta daha yüksek doğruluklar elde etse de (özellikle Put ve Feret), bazı veri setlerinde (örneğin Yale ve Georgia Tech) mevcut çalışmalardan daha düşük performans göstermektedir. Bununla birlikte, önerilen modelin farklı veri kümelerinde genel olarak tutarlı sonuçlar verdiği ve belirli veri setlerinde literatürdeki yöntemlere yakın başarı sağladığı görülmektedir. Bu durum, modelin farklı yüz tanıma veri kümelerine uygulanabilirliğini ve rekabetçi performansını ortaya koymaktadır.

Çizelge 3. Önerilen modelin literatürdeki çalışmalar ile karşılaştırması

Veri Kümesi	Çalışma (Yazar/Yıl)	Doğruluk (%)
Orl	Alane ve ark., 2024 [12]	99.00
	Yuping ve ark., 2017 [13]	97.00
	Chaturvedi ve Vishwakarma, 2020 [14]	95.50
	Önerilen Model	<b>99.00</b>
Put	Eleyan, 2023 [15]	97.67
	Önerilen Model	<b>97.80</b>
Feret	Luaibi ve Mohammed, 2019 [16]	94.50
	Önerilen Model	<b>97.37</b>
Yale	Agarwal ve Bhanot, 2018 [17]	99.83
	Gupta ve ark., 2018 [18]	97.05
	Önerilen Model	<b>95.76</b>
Georgia Tech	Selitskaya ve ark., 2020 [19]	99.33
	Lu ve ark., 2018 [20]	98.92
	Önerilen Model	<b>95.33</b>

#### IV. SONUÇLAR

Bu çalışma, geleneksel öznetelik çıkarım yöntemleri (HOG, LBP ve gri tonlama) ile derin öğrenme tabanlı sınıflandırmayı bir araya getiren hibrit bir yüz tanıma yaklaşımı sunmaktadır. Üç farklı temsilin çok-girişli CNN yapısında işlenip ara katmanda birleştirilmesiyle, farklı veri setlerinde tutarlı bir performans elde edilmesi hedeflenmiştir.

Deneyler sonucunda önerilen model ORL (%99.00) ve PUT (%97.80) veri setlerinde yüksek doğruluk değerlerine ulaşmış; FERET (%97.37), Yale (%95.76) ve Georgia Tech (%95.33) veri setlerinde ise %95'in üzerinde doğruluk sağlamıştır. Ayrıca kesinlik, duyarlılık ve F1-skoru metriklerinin birlikte raporlanması, modelin davranışının daha şeffaf biçimde değerlendirilmesine katkı sağlamıştır. Literatür karşılaştırmaları, kullanılan eğitim/test protokolüne ve ön işleme adımlarına duyarlı olduğundan, bu çalışmada belirli veri setlerinde rekabetçi sonuç üretme ve çoklu veri setinde istikrarlı performans göstermiştir. Yale ve Georgia Tech veri setlerinde bazı çalışmaların daha yüksek doğruluk bildirdiği görülmektedir; bu farklar, protokol ve veri seti zorluk düzeyi farklılıklarıyla ilişkilidir.

Gelecekteki çalışmalarda, kişi-bazlı bölme ve çapraz doğrulama gibi protokoller ile daha kapsamlı temel karşılaştırmaların eklenmesi ve farklı veri setleri üzerinde modelin genelleme kapasitesinin daha ayrıntılı analiz edilmesi planlanmaktadır.

BEYAN: Bu çalışma Halit TÜRBEDAR'ın Yüksek Lisans tezinden üretilmiştir.

## KAYNAKLAR

- [1] Bledsoe, W. W. (1964). The model method in facial recognition (Technical Report PRI 15). Panoramic Research, Inc.
- [2] Turk, M., & Pentland, A. (1991). Eigenfaces for recognition. *Journal of Cognitive Neuroscience*, 3(1), 71–86.
- [3] Belhumeur, P. N., Hespanha, J. P., & Kriegman, D. J. (1997). Eigenfaces vs. Fisherfaces: Recognition using class-specific linear projection. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 19(7), 711–720.
- [4] Bartlett, M. S. (1997). Independent components of face images: A representation for face recognition. In *Proceedings of the 4th Annual Joint Symposium on Neural Computation* (pp. 1–8). Pasadena, USA.
- [5] Samaria, F., & Harter, A. (1994). Parameterisation of a stochastic model for human face identification. In *Proceedings of the 2nd IEEE Workshop on Applications of Computer Vision* (pp. 138–144). Sarasota, USA.
- [6] Nefian, A. V. (1999). A hidden Markov model-based approach for face detection and recognition (Ph.D. thesis). Georgia Institute of Technology.
- [7] Georghiades, A., Belhumeur, P., & Kriegman, D. (2001). From few to many: Illumination cone models for face recognition under variable lighting and pose. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 23(6), 643–660.
- [8] Kasinski, A., Florek, A., & Schmidt, A. (2008). The PUT face database. *Image Processing and Communications*, 13(3–4), 59–64.
- [9] Phillips, P. J., Wechsler, H., Huang, J., & Rauss, P. J. (1998). The FERET database and evaluation procedure for face-recognition algorithms. *Image and Vision Computing*, 16(5), 295–306.
- [10] Dalal, N., & Triggs, B. (2005). Histograms of oriented gradients for human detection. In *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR)* (pp. 886–893). San Diego, USA.
- [11] Ojala, T., Pietikainen, M., & Harwood, D. (1996). A comparative study of texture measures with classification based on feature distributions. *Pattern Recognition*, 29(1), 51–59.
- [12] Alane, B., Terchi, Y., & Bouguezel, S. (2024). New face recognition system based on DCT pyramid and backpropagation neural network. *Elektronika ir Elektrotechnika*, 30(1), 68–76.
- [13] Yuping, F., An, X., & Liu, X. (2016). The application of scale invariant feature transform fused with shape model in human face recognition. In *Proceedings of the IEEE International Conference on Advanced Information Management, Communications, Electronic and Automation Control* (pp. 1716–1720). Xi'an, China.
- [14] Chaturvedi, K., & Vishwakarma, D. K. (2020). Face recognition in an unconstrained environment using ConvNet. In *Proceedings of the 2nd International Conference on Big Data Engineering and Technology* (pp. 67–71). Singapore.
- [15] Eleyan, A. (2023). Face recognition using ensemble statistical local descriptors. *Journal of King Saud University – Computer and Information Sciences*, 35(9), 101729.
- [16] Luaibi, M. K., & Mohammed, F. G. (2019). Facial recognition based on DWT–HOG–PCA features with MLP classifier. *Journal of Southwest Jiaotong University*, 54(6), 1–12.
- [17] Agarwal, V., & Bhanot, S. (2018). Radial basis function neural network-based face recognition using firefly algorithm. *Neural Computing and Applications*, 30(8), 2643–2660.
- [18] Gupta, P., Saxena, N., Sharma, M., & Tripathi, J. (2018). Deep neural network for human face recognition. *International Journal of Engineering and Manufacturing*, 8(1), 63–71.

- [19] Selitskaya, N., Sielicki, S., Jakaite, L., Schetinina, V., Evans, F., Conrad, M., & Sant, P. (2020). Deep learning for biometric face recognition: Experimental study on benchmark data sets. In *Deep biometrics* (pp. 71–97). Springer.
- [20] Lu, Z., Jiang, X., & Kot, A. (2018). Feature fusion with covariance matrix regularization in face recognition. *Signal Processing*, 144, 296–305.