

(Araştırma Makalesi)

Özellik Çıkarımları Kullanarak Dış Çift El Görüntülerine Dayalı Kişi Tanıma**Şevval KOÇ¹, Zekeriya KATILMIŞ^{*2}**¹Kütahya Sağlık Bilimleri Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi, Bilgisayar Mühendisliği Bölümü, 43100, Kütahya, ORCID No : <https://orcid.org/0009-0009-6169-0053>²Kütahya Sağlık Bilimleri Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi, Bilgisayar Mühendisliği Bölümü, 43100, Kütahya, ORCID No : <https://orcid.org/0000-0002-2095-5483>**Anahtar Kelimeler:**Biyometrik,
El görüntüsü,
Özellik çıkarımı,
GLCM,
ORB,
LBP

Özet: Bu çalışma, dış çift el görüntü tabanlı biyometrik özelliklerin kişi tanıma sistemlerinde kullanımını ve sınıflandırma performansına olan etkilerini incelemektedir. Farklı çözünürlük düzeylerinde elde edilen el görüntülerinden Gri-Seviye Eş Olasılık Matrisi (GLCM), Yönlendirilmiş Hızlı ve Döndürülmüş Yavaş (ORB) ve Yerel İkili Örüntü (LBP) yöntemleri ve birleşimleri kullanılarak özellik çıkarımı gerçekleştirilmiştir. Özgün oluşturulan veri kümesi, çözünürlük indirgeme aşamaları uygulanarak kişi tanıma başarımları birçok yönü ile ele alınmıştır. Çalışma ön işlem, resim boyutlandırma, öznelilik çıkarımı ve birleştirme, sınıflandırma ve kişi tanıma adımlarından oluşmaktadır. Deneysel çalışmalar, (4032 × 3024) piksel çözünürlüğe sahip orijinal görüntülerin dört farklı boyuta ölçeklendirilmesiyle oluşturulan veri kümeleri üzerinde yürütülmüştür. Özellik çıkarımı sonrasında elde edilen veri kümesi, çeşitli makine öğrenmesi algoritmaları ile eğitilerek sınıflandırma doğruluğu analiz edilmiştir. Aşırı öğrenme makinesi (ELM, Extreme Learning Machine) algoritmasının tüm çözünürlük seviyelerinde istikrarlı ve yüksek doğruluk oranları sağladığını göstermektedir. En iyi doğruluk %98 oranı ile ELM yaklaşımı kullanılarak kaydedilmiştir. En başarılı özellik çıkarım yöntemi olarak ise ORB+LBP'nin birleşimi öne çıkmıştır. Elde edilen bulgular, dış el görüntülerinin biyometrik kişi tanıma sistemlerinde etkili bir şekilde kullanılabileceğini ve düşük çözünürlüklü verilerle kabul edilebilir doğruluk oranları elde edilebileceğini göstermektedir. Çalışma, biyometrik sistemlerde kullanılabilecek en uygun çözünürlük ve özellik çıkarım yöntemi belirleyerek bu sistemlerin doğruluk başarımını artırmaktır. Ayrıca çalışma, el görüntülerine dayalı biyometrik sistemlerin, kişi tanımlama, doğrulama ve demografik analiz gibi uygulamalarda önemli bir potansiyele sahip olduğunu ortaya koymaktadır.

(ResearchArticle)

Human Recognition Based on Outer Double Hand Images Using Feature Extraction**Keywords:**Biometric,
Hand image,
Feature extraction,
GLCM,
ORB,
LBP

Abstract: This study examines the use of outer double hand image-based biometric features in human recognition systems and their effects on classification performance. Feature extraction was performed using Grey-Level Co-Probability Matrix (GLCM), Oriented FAST and Rotated BRIEF (ORB) and Local Binary Patterns (LBP) methods and their combinations on hand images obtained at different resolution levels. The original dataset was analyzed to resolution reduction stages and the performance of human recognition was analyzed in many aspects. The study consists of pre-processing, image resizing, feature extraction and fusion, classification, and human recognition steps. Experimental studies were carried out on datasets created by scaling the original images with a resolution of (4032 × 3024) pixels to four different dimensions. The dataset obtained after feature extraction was trained with various machine-learning algorithms and the classification accuracy was analyzed. The results show that the Extreme Learning Machine (ELM) algorithm provides stable and high accuracy rates at all resolution levels. The best accuracy was recorded using the ELM approach with a rate of 98%. The

combination of ORB+LBP was the most successful feature extraction method. The findings show that outer hand images can be used effectively in biometric human recognition systems and acceptable accuracy rates can be achieved with low resolution data. This study aims to improve the accuracy of biometric systems by determining the most appropriate resolution and feature extraction method that can be used in biometric systems. In addition, the study highlights that biometric systems based on hand images have significant potential in applications such as human identification, verification and demographic analysis.


1. GİRİŞ

Biyometrik tanıma sistemleri, bireylerin özelliklerini analiz ederek kimlik doğrulama işlemini gerçekleştiren yapılardır [1]. Biyometrik sistemler fiziksel ve davranışsal olmak üzere ikiye ayrılmaktadır [2,3]. Fiziksel biyometrikler; iris, yüz, parmak izi, retina, el tanıma vb. sistemleri ele alırken, bireyin davranışsal özelliklerini temel alan davranışsal biyometri ise; ses, el yazısı, ıslak imza vb. sistemleri ele almaktadır [4]. Geleneksel yöntemlerin (şifre, PIN vb.) unutulabilir, çalınabilir veya taklit edilebilir olması, biyometrik sistemlerin daha güvenilir bir alternatif olarak öne çıkmasını sağlamaktadır. Kişiye özgü ve değiştirilemez özelliklere dayanan bu sistemler, özellikle yüksek güvenlik gerektiren alanlarda giderek daha yaygın hale gelmektedir. Parmak izi, yüz tanıma ve iris tanıma gibi biyometrik yöntemler, bu teknolojilerin en bilinen uygulamaları arasında yer almaktadır. Parmak izi, iris, yüz tanıma ve avuç içi damar izi gibi biyometrik yöntemler, bireyin benzersiz özelliklerine dayandığından kimlik sahteciliğine karşı yüksek güvenlik sağlamaktadır [4]. Biyometrik sistemlerin kullanıcı deneyimini daha konforlu ve erişilebilir hale getirmek için çeşitli geliştirme çalışmaları devam etmektedir [5]. Özellikle yaşlılar ve sınırlı el becerisine sahip bireyler için ergonomik iyileştirmeler, bu teknolojilerin daha geniş bir kullanıcı kitlesi tarafından benimsenmesini sağlamaktadır. Ayrıca, hijyen standartlarının artırılması ve temassız biyometrik çözümlerin yaygınlaşması, kullanıcıların güvenliğini ve konforunu artırarak biyometrik sistemlerin günlük yaşamdaki entegrasyonunu kolaylaştırmaktadır [6]. Bu gelişmeler, biyometrik tanıma sistemlerinin güvenilirliğini ve kullanım kolaylığını daha da artırarak, farklı sektörlerde daha yaygın hale gelmesine katkı sağlamaktadır.

Bununla birlikte, el tabanlı biyometrik sistemler, temas gerektirmemesi ve düşük çözünürlüklü görüntülerde dahi yüksek performans göstermesi nedeniyle giderek daha fazla tercih edilir hale gelmektedir. El tabanlı biyometrik sistemler, el veya parmak geometrisi ve avuç içi çizgileri gibi benzersiz fiziksel özelliklere dayanarak doğrulama sağlamaktadır. Ayrıca, bu sistemler yalnızca kimlik doğrulama süreçlerinde değil, aynı zamanda cinsiyetin belirlenmesinde de kullanılmaktadır. Birçok çalışmada, cinsiyet bilgisinin çıkarılmasında el boyutlarının kullanılabileceği göstermiştir [5]. Erkek ve kadınlar arasındaki biyolojik farklılıklar, el uzunluğu, genişliği ve parmak oranları gibi ölçümlerde belirgin hale gelmektedir. Erkeklerin ellerinin genellikle daha büyük ve geniş, kadınların ellerinin ise daha ince ve dar olması, bu tür ölçümlerin cinsiyet sınıflandırma modellerinde yüksek doğruluk oranlarıyla sonuçlanmasını

sağlamaktadır. Bu bağlamda, el tabanlı biyometrik sistemler, hem güvenlik hem de demografik analiz açısından önemli bir potansiyele sahiptir. Bu çalışmada biyometrik kişi tanıma sistemine katkıda bulunmak için oluşturduğumuz veri kümesi kullanılarak makine öğrenmesi yaklaşımlarından ELM, MLP-ELM, ML-ELM, CNN, DNN sınıflandırıcılar kullanılmıştır. Bu yaklaşımlarda görüntü özellik çıkarımı yöntemleri, Gri-Seviye Eş Olasılık Matrisi (Gray Level Cooccurrence Matrix, GLCM), Yönlendirilmiş HIZLI ve Döndürülmüş KISA (Oriented FAST and Rotated BRIEF, ORB) ve Yerel ikili Örüntüler (Local Binary Patterns, LBP) kullanılarak çıkarılan özneliliklerle eğitilerek sınıflandırılmıştır.

Bu çalışmada, dış çift el geometrisine dayalı biyometrik özelliklerin farklı çözünürlüklerdeki görüntülerin GLCM, ORB ve LBP özellik çıkarımı yöntemleri üzerindeki etkisini incelemek ve kişi tanıma ve sınıflandırma doğruluğuna olan katkılarını değerlendirmektir. Araştırma kapsamında GLCM, ORB ve LBP özellik çıkarım yöntemleri tekli, ikili ve üçlü birleştirilerek kullanılmıştır. El geometrisi tabanlı biyometrik sistemler, özellikle kimlik doğrulama ve cinsiyet tespiti gibi analizlerde etkin bir şekilde kullanılmaktadır. Bu bağlamda, çalışmada farklı çözünürlükteki görüntüler üzerinden çıkarılan özelliklerin performansını analiz ederek, biyometrik sistemlerde kullanılabilecek en uygun boyut ve yöntem birleşimini belirlemek hedeflenmiştir. Böylelikle, biyometrik sistemlerin doğruluk oranlarını artırmak ve düşük çözünürlüklü görüntülerle yüksek performans elde edilebileceğini göstermek amaçlanmaktadır. Çalışma, veri toplama ve ön işleme, boyut dönüştürme, özellik çıkarımı, özellik birleştirme, sınıflandırma ve tanıma olmak üzere altı adımdan oluşmaktadır. Önerilen biyometrik kişi tanıma modelin genel akış şeması, Şekil 1'de gösterildiği gibi üç aşama ve altı adımdan oluşmaktadır.



Şekil 1. El görüntülerine dayalı biyometrik kişi tanıma için kullanılan akış şeması.

Çalışma, yaşları 20 ile 40 arasında değişen toplam 60 bireyden elde edilen el görüntüleri üzerinde gerçekleştirilmiştir. Katılımcıların 30 kadın ve 30 erkekten oluşmaktadır. Her bireyden 10 el görüntüsü

örneği alınmış ve toplamda 600 görüntü elde edilmiştir. Çalışmada kullanılan görüntüler, homojen bir veri kümesi oluşturulması amacıyla farklı zamanlarda, benzer aydınlatma ve aynı açı doğrultusu ve arka plan koşullarında çekilmiştir. Veri toplama sırasında, katılımcılardan yüzük, saat veya diğer aksesuarları çıkarmaları ve doğal bir pozda ellerini düz bir yüzeye yerleştirmeleri istenmiştir. Orijinal görüntüler (4032×3024) boyutlarından oluşmaktadır. Tüm görüntüler (240×180), (160×120), (128×96) ve (80×60) piksel olmak üzere dört farklı çözünürlüğe göre yeniden boyutlandırılmıştır. Bu boyutlar, düşük çözünürlükteki görüntülerin tanıma ve sınıflandırma performansına etkisini incelemek için orijinal görüntülerin oranını bozmadan seçilmiştir.

Önerilen sistem Intel(R) Core(TM) i7- 12700H işlemci 2.3 GHZ hız ve 16 GB RAM kullanılarak gerçekleştirilmiştir. Veri kümesi, temassız bir şekilde mobil cihaz ile elde edilen görüntülerden oluşmaktadır. Bu görüntüler USB üzerinden bilgisayar ortamına aktarılmıştır. Görüntülerin alınma sürecinde aydınlatma koşulları değiştirilmeden gün ışığı aydınlatması ve doğal ortamlar kullanılmıştır. Görüntü dosyalarının ön işlem, boyut dönüştürülmesi, normalizasyon, özellik çıkarımı, sınıflandırma ve tanıma adımları Python programlama dili kullanılarak gerçekleştirilmiştir.

2. LİTERATÜR ÇALIŞMALARI

Literatürde biyometrik kişi tanıma üzerine birçok çalışma bulunmaktadır. Bu çalışmalar arasında, bu çalışmanın konusu ve kapsamı bağlamında, GLCM, ORB ve LBP özellik çıkarım yöntemi tabanlı çalışmalar incelenmiştir. Bu bağlamdaki çalışmalar aşağıdaki gibidir.

Afifi, el tabanlı biyometrik tanıma ve cinsiyet sınıflandırma üzerine gerçekleştirdiği çalışmada, 11.000'in üzerinde el görüntüsünden oluşan kapsamlı bir veri kümesi olan "11K Hands"i çalışmasını sunmuştur. Çalışmada, farklı yaş ve cinsiyet gruplarından bireylere ait sağ ve sol el görüntüleri kullanılarak, derin öğrenme temelli yöntemlerle hem kimlik tespiti hem de cinsiyet sınıflandırması gerçekleştirilmiştir. Cinsiyet tanıma için kullanılan iki akışlı derin sinir ağı (two-stream CNN) ve biyometrik kimlik doğrulama için kullanılan destek vektör makineleri (SVM) makine öğrenimi teknikleri kullanılmıştır. CNN ile birlikte yerel ikili örüntü (LBP) özellik çıkarımı yöntemi uygulanmıştır. En yüksek doğruluk oranı, el görüntülerinden çıkarılan derin özelliklerin SVM ile elde edilmiştir. Bu yöntemle cinsiyet tanıma için %97.3, biyometrik kimlik tanıma için ise %96.0 doğruluk oranına ulaşılmıştır [1].

Özbay çalışmasında, cinsiyet tespiti amacıyla iç (palmar) el görüntülerini kullanarak bir sınıflandırma yöntemi önermiştir. 5396 el görüntüsü kullanmıştır. Çalışmada, el görüntülerinden elde edilen özellikler yerel ikili Örüntüler (LBP) ve Zernike momentleri ile çıkarılmış, bu özellikler sınıflandırma algoritmalarına girdi olarak verilmiştir. Makine öğrenmesi sınıflandırıcısı olarak SVM (Support Vektör Machine), KNN (K-Nearest Neighbors) ve NB (Naive Bayes) kullanmıştır. Bu çalışmada SVM

kullanılarak %93 oranında en iyi doğruluk elde etmiştir [5].

Adedeji ve arkadaşlarının çalışmasında, el geometrisi tabanlı tanıma sistemlerinde yapay sinir ağı (ANN) eğitim algoritmalarının performansı incelenmiştir. Dört farklı eğitim algoritması, Levenberg-Marquardt (LMA), BFGS Quasi-Newton (BFGS-QN), esnek geri yayılım (RBP) ve ölçekli eşlenik gradyan (SCG) karşılaştırılmıştır. Görüntü üzerinde Sobel filtresi kullanılmıştır. Bu çalışmada LMA ile %99 en iyi doğruluk oranı elde edilmiştir [7].

Mohamed ve arkadaşlarının çalışması, el biyometrik doğrulama sistemlerinin doğruluğunu artırmak için derin öğrenme tekniklerini incelemektedir. Çalışmada, el geometrisi özelliklerinin tanımlanmasında kullanılan derin öğrenme yöntemlerinin etkinliği değerlendirilmiştir. Kimlik doğrulamayı geliştirmek için avuç içi damarı ve avuç içi izi özelliklerinin çok modlu biyometrik bütünleştirilmesine yönelik bir çalışma sunmuştur. Özellik çıkarımı yöntemlerinden Doğrusal Ayırıcı Analiz (LDA), Temel Bileşenler Analizi (PCA), Gabor filtreleri, Yerel İkili Örüntü (LBP), SIFT ve SURF kullanılmıştır. Sınıflandırma yöntemi olarak LSTM, CNN, SVM, Deep Belief Network (DBN) kullanmıştır. Doğruluk oranları sırasıyla %98, %96, %96, %95 elde edilmiştir [8].

Klonowski ve arkadaşlarının [9] çalışmasında, el geometrisi verileriyle geometrisi ve eğrilik tanımlama algoritması (HG CIA) ile kullanıcı yetkilendirme algoritması geliştirilmiştir. Bu algoritma, ofis ortamlarında yaygın olarak bulunan standart tarayıcılarla elde edilen verileri kullanarak, elin parmak eğrilikleri gibi geleneksel yöntemlerle ölçülmeyen özellikleri de içermektedir. Sonuçlar, bu yaklaşımın mevcut gelişmiş algoritmalarla karşılaştırıldığında benzer doğruluk oranları sağladığını göstermektedir. Aynı zamanda, biyometrik doğrulama sistemlerinin daha erişilebilir sağlamaktadır.

Shakil ve arkadaşlarının [10] çalışması, el tabanlı biyometrik tanıma özellik çıkarımı ve sınıflandırma için bir topluluk (ensemble) öğrenme yaklaşımı sunmaktadır. Çalışmada, her iki eldeki parmak bölütlemeleri ile birlikte gabor filtresi kullanılarak 94 özellik çıkarılmış ve bu özellikler farklı sınıflandırma teknikleriyle değerlendirilmiştir. Elde edilen sonuçlar, önerilen sistemin mevcut sistemlere kıyasla daha yüksek doğruluk sağladığını göstermektedir. Özellikle, destek vektör makineleri (SVM) kullanılarak elde edilen doğruluk oranları oldukça yüksektir.

Bu çalışmaların yanı sıra el üzerine yapılan benzer çalışmalarda bulunmaktadır. Bunlar parmak izi [11-13], avuç içi [14-16] ve avuç içi damar [17-19] tanıma ile ilgili çalışmalardır. Bunların dışında farklı cihaz kullanılarak da el tabanlı biyometrik kişi tanıma mevcuttur [20].

3. MATERYAL VE METOT

Makine öğrenimi (ML), bilgisayarların verilerden öğrenerek belirli görevleri müdahale olmadan yerine getirmesini sağlayan bir teknolojidir. Makine öğreniminde sistem, örnek veriler üzerinden kurallar ve ilişkiler öğrenir. Bu yaklaşım, algoritmaların büyük veri

bulunmasına olanak tanır. Bu sayede sınıflandırma, tahmin, tanıma gibi işlemler otomatik olarak yapılabilir. Günümüzde sağlık, biyometrik, görüntü işleme ve daha birçok alanda etkili çözümler sunarak, hızlı ve doğru sonuçlar elde etmeyi mümkün hale getirmiştir. Bu çalışmada, farklı makine öğrenimi yöntemleri kullanılarak modeller oluşturulmuş ve performansları karşılaştırılmıştır. Çalışmada farklı makine öğrenimi algoritmaları kullanılmıştır. Temel aşırı öğrenme makinesi (ELM), çok katmanlı algılayıcı ELM (MLP-ELM), çok katmanlı ELM (ML-ELM), derin sinir ağları (DNN) ve evrimsel sinir ağları (CNN) kullanılmıştır. Bu yöntemlere bağlı olarak el görüntülerinin başarımları ve çalışma süreleri karşılaştırma imkânı sağlanmıştır.

Aşırı öğrenme makineleri (Extreme Learning Machine, ELM), tek katmanlı ileri beslemeli yapay sinir ağlarına (SLFN – Single Layer Feed forward Network) dayalı, eğitim süresi oldukça hızlı olan bir öğrenme yöntemidir. ELM'in temel özelliği, gizli katmandaki ağırlıkların ve bias değerlerinin rastgele atanması, yalnızca çıkış ağırlıklarının analitik olarak hesaplanmasıdır. Bu yapı, eğitim süresini önemli ölçüde kısaltırken, yeterli doğruluk düzeyiyle sınıflandırma ve regresyon problemlerine etkili çözümler sunar [21]. Bir ELM modeli matematiksel olarak şu şekilde ifade edilir:

$$\sum_{i=1}^L \beta_i g(w_i \cdot x_j + b_i) = y \quad (1)$$

Burada x giriş vektörü, w_i gizli katmandaki i . nöronun ağırlık vektörü, b_i gizli katmandaki i . nöronun bias değeri, $g(\cdot)$ aktivasyon fonksiyonu, β_i çıkış katmanındaki ağırlıklar, L gizli katmandaki nöron sayısı ve y modelin çıktısıdır. Modelin eğitimi sırasında, w_i ve b_i rastgele belirlenir. Ardından, gizli katmanın çıktıları bir H matrisi olarak ifade edilir:

$$H = g(W \cdot X + B) \quad (2)$$

Son adımda çıkış ağırlıkları β , şu şekilde hesaplanır:

$$\beta = H^+ T \quad (3)$$

Burada H^+ matrisi, H matrisinin Moore-Penrose sözde tersini ifade eder. T ise gerçek hedef değerler matrisidir. Bu işlem sayesinde, ağırlık güncellemesi gerektiren tekrarlayan süreçlere ihtiyaç duyulmadan doğrudan çözüme ulaşılır. Bu da ELM'in klasik yapay sinir ağlarına kıyasla çok daha hızlı çalışmasını sağlar.

MLP-ELM (Multi-Layer Perceptron, MLP), ELM algoritmasının çok katmanlı algılayıcı yapısı ile birleştirilmiş halidir. Bu yaklaşımda, ELM'in hızlı öğrenme avantajı korunurken, MLP'nin çok katmanlı yapısı sayesinde daha karmaşık örüntülerin öğrenilmesi mümkün hale gelir. Bu yapı, doğrusal olmayan verilerde daha yüksek doğruluk sağlamayı hedefler [22]. Çok katmanlı ELM (Multi-Layer ELM, ML-ELM), ELM yapısının çok katmanlı bir yapay sinir ağına genişletilmesidir. Bu model, ELM'in hız avantajını korurken, derin öğrenmeye benzer şekilde katmanlar arasında daha güçlü özellik öğrenimi sağlar. Her katman, ELM prensiplerine göre eğitilir ve bu sayede hem öğrenme hızı yüksek tutulur hem de modelin temsil kapasitesi artırılır [23]. Temel ELM, MLP-ELM ve ML-

ELM sınıflandırıcılarda hücre sayısı 100 ve sigmoid aktivasyon fonksiyonu kullanılmıştır. Çok katmanlı MLP-ELM ve ML-ELM sınıflandırıcılarda katman sayısı 3 olarak belirlenmiştir.

Derin sinir ağları (Deep Neural Network, DNN), birden fazla gizli katmandan oluşan derin öğrenme modellerini ifade eder. DNN'ler, giriş verilerinden karmaşık ve soyut özellikleri öğrenme kapasitesine sahiptir. Bu yapı, çok katmanlı yapısı sayesinde yüksek boyutlu verilerde güçlü öğrenme yetenekleri sunar ve birçok alanda, özellikle ses, görüntü ve metin işleme gibi karmaşık görevlerde yaygın olarak kullanılmaktadır [24]. Tek boyutlu DNN yapısında bir giriş katmanı, üç gizli katman ve bir çıkış katmanı kullanılmıştır. Katmanlarda sırasıyla 100, 50 ve 25 nöron yer almıştır. Gizli katmanlarda ReLU aktivasyon fonksiyonu, son katmanda softmax fonksiyonu, modelin optimizasyonu için Adam algoritması, eğitim süresi 70 epok, mini-yığın (batch) boyutu 50 ve öğrenme oranı 0.01 olarak alınmıştır.

Evrimsel Sinir Ağları (Convolutional Neural Network, CNN), özellikle görüntü işleme ve görsel veri analizinde oldukça başarılı sonuçlar sunan bir derin öğrenme mimarisidir. CNN, giriş verilerinden öznetelik çıkarımı yapabilen evrim katmanları ve havuzlama katmanları sayesinde otomatik öğrenme yeteneğine sahiptir. Görsel örüntülerin yerel ve mekansal ilişkilerini etkili şekilde modelleyerek yüksek doğrulukta sınıflandırma yapabilir [25-27]. Bu çalışmada, CNN modelinde sırasıyla bir giriş katmanı, bir evrimsel katman, bir ReLU aktivasyon katmanı, bir global maksimum havuzlama katmanı, bir tam bağlantılı katman, bir softmax katmanı ve bir sınıflandırma katmanı kullanılmıştır. Çıkış katmanında softmax fonksiyonu kullanılmıştır. Modelin eğitiminde Adam optimizasyon algoritması tercih edilmiş, eğitim süresi 70 epoch olarak belirlenmiş, mini-yığın (batch) boyutu 50 ve başlangıç öğrenme oranı 0.01 olarak ayarlanmıştır.

4. ÖZELLİK ÇIKARIM YÖNTEMLERİ

Özellik çıkarımı, biyometrik kişi tanıma ve sınıflandırma süreçlerinin temel bir bileşenidir. Bu çalışmada kullanılan yöntemler aşağıda açıklanmıştır.

4.1. Gri Seviye Eş Olasılık Matrisi (Gray Level Co-occurrence Matrix, GLCM)


Gri-Seviye Eş Olasılık Matrisi (GLCM), Haralick ve arkadaşları tarafından farklı doku türlerinin sınıflandırılmasına yönelik olarak geliştirilen, piksel tabanlı bir görüntü işleme yöntemidir [28]. Bu yöntem, görüntüdeki özneteliklerin çıkarımında pikseller arasındaki mekansal ilişkileri dikkate alarak çalışmaktadır [29]. GLCM matrisinin oluşturulmasında; pikseller arası uzaklık (D), yönelme açısı ve gri seviye sayısı gibi parametreler temel alınmaktadır [30,31].

Bu çalışmada kullanılan parametreler, pikseller arasındaki uzaklık (D) 3 piksel olarak belirlenmiş, yönelme açısı olarak ise (0° , 45° , 90° ve 135°) dört açı seçilmiştir. Haralick'in temel istatistiksel özellikler arasından kontrast (contrast), benzersizlik (dissimilarity), homojenlik (homogeneity), enerji (energy), korelasyon

(correlation) ve Açılal İkinci Moment (Angular Second Moment, ASM) olmak üzere 6 temel doku özelliği kullanılmıştır [29]. Kontrast, gri seviye yoğunluklarının farklılık derecesini ölçer. Benzersizlik kontrasta benzer ancak farkın karesi yerine mutlak değeri alınır, daha az ağırlık verir. Homojenlik, gri tonlarındaki benzerlikleri ölçer. Enerji, GLCM'nin toplam enerjisi yoğunluğunu temsil eder. Yüksek enerji, görüntünün daha düzenli olduğunu gösterir. Korelasyon, piksel çiftleri arasındaki doğrusal bağımlılığı ölçer. Yüksek korelasyon değerleri daha öngörülebilir bir dokuyu gösterir. ASM, gri-seviye eş olasılık matrisi elemanlarının karelerinin toplamıdır [32].

Bu 6 temel GLCM özelliğinden entropi (entropy), maksimum korelasyon katsayısı (Maximal Correlation Coefficient, MCC), küme gölgesi (Cluster Shade), küme önemliliği (cluster prominence), minimum gri seviye (Minimum Gray Level), maksimum gri seviye (maximum gray level), gri seviye ortalaması (mean gray level), gri seviye varyansı (variance of gray levels), gri seviyelerin standart sapması (standard deviation of gray levels) ve normalize edilmiş ters fark momenti (Inverse Difference Moment Normalized, IDMN) türetilerek 10 adet ek özellik çıkarılmıştır.

Ayrıca, pikseller arası uzaklık (distance) ve yönelme açısı (angle) da öznelik setine dahil edilerek analiz kapsamı genişletilmiştir. Böylece bu çalışmada 6 temel + 10 türetilmiş + 2 GLCM parametresi olmak üzere toplam 18 özellik kullanılmıştır. Bu 18 özellik, 3 farklı uzaklık ve 4 farklı yönelme açısına göre hesaplanarak, toplam 216 özellik ($18 \times 3 \times 4 = 216$) çıkarılmıştır. Veri kümesindeki orijinal el görüntüleri kullanılarak GLCM öznelik çıkarımı yöntemi uygulanmış el görüntüsü Şekil 2'de sunulmuştur. GLCM yöntemi ile çıkarılan temel özelliklere ait matematiksel formüller Tablo 2' de sunulmuştur. Burada $P(i,j)$, GLCM'nin i -sıra ve j -sütunundaki elemanı olup, ilgili gri seviye çiftinin birlikte görülme olasılığını ifade eder; μ piksel yoğunluklarının ortalamasını, σ ise bu yoğunlukların standart sapmasını temsil etmektedir.



Şekil 2. Orijinal resim ve GLCM özellik tablosu.

Tablo 1. GLCM yöntemi ile çıkarılan temel özelliklere ait matematiksel formüller.

Kontrast	$\sum_{i=1}^N \sum_{j=1}^N (i-j)^2 \cdot P(i,j)$
Benzersizlik	$\sum_{i=1}^N \sum_{j=1}^N i-j \cdot P(i,j)$
Homojenlik	$\sum_{i=1}^N \sum_{j=1}^N \frac{P(i,j)}{1 + (i-j)^2}$
Enerji	$\sum_{i,j=0}^{N-1} P_{i,j}^2$
Korelasyon	$\frac{\sum_{i=1}^N \sum_{j=1}^N (i - \mu_i)(j - \mu_j)P(i,j)}{\sigma_i \cdot \sigma_j}$
Açılal İkinci Moment	$\sum_{i=1}^N \sum_{j=1}^N P(i,j)^2$

4.2. Yönlendirilmiş Hızlı ve Sağlam Brief (Oriented FAST and Rotated BRIEF, ORB)

Yönlendirilmiş Hızlı ve Döndürülmüş Kısa (ORB, Oriented FAST and Rotated BRIEF) özellik çıkarımı yöntemi, Rublee ve arkadaşları tarafından OpenCV laboratuvarında geliştirilmiştir [33]. Bu yöntem, hem daha verimli hem de uygulanabilir bir özellik çıkarma algoritmasıdır ve SIFT ile SURF'e kıyasla çok daha hızlı bir alternatif sunar [34].

ORB, geliştirilmiş FAST (Features from Accelerated Segment Test) algoritmasını kullanarak köşe algılama performansını artırır. Bu algoritma, bir görüntüdeki köşeleri tespit etmek için en iyi N noktayı seçer ve bu noktalar, daha tanımlı konum bilgisine sahiptir. Ayrıca FAST, çok ölçekli özellikler üretebilmesine rağmen döndürme değişmezliği sağlamaz. Bu eksikliği gidermek için ORB, köşe algılama işlemi sırasında, köşelerin bulunduğu yamanın yoğunluk ağırlıklı merkezini hesaplayarak yön bilgisi elde eder.

ORB aynı zamanda BRIEF (Binary Robust Independent Elementary Features) tanımlayıcısını kullanır. BRIEF, seçilen noktaları ikili bir özellik vektörüne dönüştürerek algoritmayı hızlandırır. Ancak BRIEF döndürme değişmezliği sağlamadığından, ORB'de FAST ile birlikte kullanılan tanımlayıcı rBRIEF (Rotasyona Duyarlı BRIEF) olarak geliştirilmiştir. Bu sayede, ORB döndürmeye karşı da dayanıklılık gösterir ve hızlı bir şekilde yüksek doğruluk oranları sunar [33]. Şekil 3'te bir kadın ve bir erkek bireye ait orijinal el görüntüsü ve bu görüntülere ORB yöntemi uygulanmış hali sunulmuştur.



Şekil 3. Orijinal ve ORB yöntemi uygulanmış el görüntüsü.

Bu çalışmada ORB algoritması ile elde edilen özellikler, iki ana grupta değerlendirilmektedir. Birincisi anahtar noktalara (keypoints) ilişkin mekânsal ve yapısal özellikler, ikincisi ise bu noktalara ait tanımlayıcı vektörleri (descriptors) içeren özelliklerdir. ORB algoritmasında anahtar noktalar, görüntüdeki ilginç ve tanımlayıcı bölgeleri belirlerken, tanımlayıcılar ise bu noktaların çevresindeki desenleri ikili vektörlerle temsil eder.

Bu çalışmada, ORB algoritması ile elde edilen öznelilikler temel alınarak toplamda 71 özellik çıkarılmıştır. Bunların 7 temel özelliği, anahtar noktalara ilişkin temel istatistiksel ölçümlerden oluşmaktadır. Bu ölçümler; anahtar nokta sayısı, anahtar noktaların ortalama boyutu, boyut varyansı, minimum ve maksimum boyut değerleri, boyutların standart sapması ve medyandır. Geriye kalan 64 özellik ise tanımlayıcı vektörlerine dayalıdır. Her bir tanımlayıcı vektörünün 32 boyutu için iki ayrı istatistiksel ölçüm (ortalama ve standart sapma) hesaplanarak tanımlayıcı vektörler tabanlı özellikler elde edilmiştir.


4.3. Yerel ikili desenler (Local Binary Patterns, LBP)

Yerel İkili Örüntüler (LBP), gri seviyedeki dokuları analiz etmek için etkili bir yöntemdir. Bu operatör, görüntüdeki her piksel için bir etiket oluşturur. Etiketleme işlemi, merkez pikselin komşularıyla karşılaştırılması sonucu elde edilen ikili bir sayıya dayanır. Bu sayede her piksel, komşularıyla olan farklara göre etiketlenir. LBP, özellikle dairesel komşuluk yapılarına dayalı olarak, çeşitli doku analizlerinde kullanılabilir. LBP, piksel komşularının ara değerlerini hesaplayarak, farklı komşuluk sayıları ve çaplarındaki dokuları analiz etmeye olanak tanır [35].

$$LBP_{p,R}(x_c) = \sum_{p=0}^{P-1} u(x_p - x_c) 2^p, u(y) = \begin{cases} 1, & y \geq 0 \text{ ise,} \\ 0, & y < 0 \text{ ise.} \end{cases} \quad (4)$$

Formülde yer alan x_c , LBP etiketinin üretildiği merkez pikseli temsil etmektedir. x_p , merkez pikselin komşularını, R , komşuların merkez piksele olan uzaklığını ve P , işlemeye alınan komşu sayısını ifade etmektedir. LBP operatörü, çeşitli dairesel komşuluk yapıları kullanılarak genişletilmiştir. Bu sayede farklı ölçeklerdeki dokuların analizi mümkün hale gelmiştir. Piksellerin ara değerlerinin bulunması (interpolasyon), her çapta ve sayıdaki komşuluğa imkan sağlamaktadır. Bu esneklik, LBP operatörünün çok çeşitli doku türlerini tanımda kullanılabilmesine olanak tanımaktadır.

Bu çalışmada, LBP algoritmasından elde edilen çıktılar üzerinden çeşitli histogram özellikleri çıkarılmaktadır. Çıkarılan temel özellikler arasında ortalama, standart sapma, maksimum ve minimum LBP değeri, çarpıklık, basıklık, enerji, entropi, harmonik ortalama ve varyans yer almaktadır. Ayrıca, medyan, ortalama mutlak sapma, 1. çeyrek (25. yüzdelik dilim) ve 3. çeyrek (75. yüzdelik dilim), korelasyon ve Shannon entropisi gibi ek istatistiksel ölçütler de hesaplanmaktadır. Bu doğrultuda, toplamda 27 farklı LBP özelliği elde edilmiştir. Şekil 4'te bir kadın ve bir erkek bireye ait orijinal iki el görüntüsü ve LBP yöntemi uygulanmış hali verilmiştir.



Şekil 4. Orijinal ve LBP yöntemi uygulanmış el görüntüsü.


5. DENEYSEL SONUÇLAR

Deneysel çalışmalar, (4032 × 3024) piksel çözünürlüğe sahip orijinal görüntülerin farklı çözünürlüklere indirgenerek oluşturulan veri kümeleri üzerinde gerçekleştirilmiştir. İlk olarak, orijinal görüntülerin en uygun en-boy oranı olan 4:3 oranı dikkate alınarak, görüntüler sırasıyla (240 × 180), (160 × 120), (128 × 96) ve (80 × 60) piksel çözünürlüklerde boyutlandırılmıştır. Bu boyutlandırma süreci, görüntülerin boyutlarının düşürülerek özellik çıkarımı için daha uygun hale getirilmesini sağlamıştır. Özellik çıkarımı aşamasında, GLCM, ORB ve LBP yöntemleri kullanılmıştır. Ayrıca, bu yöntemlerin çeşitli kombinasyonları da dahil edilmiştir. Bu kapsamda beş özellik çıkarımı belirlenmiştir. Bunlar ikili birleşim GLCM+ORB, GLCM+LBP, ORB+LBP ve üçlü birleşim olan GLCM+ORB+LBP kullanılarak elde edilen özellik çıkarımları incelenmiştir. Tablolardaki sonuçlar test sürecindeki başarımların oranlarıdır. Model eğitimi ve değerlendirme aşamasında veri kümesi, %70 eğitim ve %30 test olarak belirlenmiştir. Çalışma süreleri ise eğitim ve test aşamasında geçen toplam süre alınmıştır. Çalışmada beş makine öğrenimi algoritması kullanılmıştır. Başarımların incelenmesinde, deneysel sonuçlar dört aşama ve her aşamada beş uygulamadan oluşmaktadır.

Birinci aşamada (240 × 180) piksel çözünürlük içeren veri kümesi üzerinde özellik çıkarımları uygulanmıştır. Özellik çıkarımı sonucunda elde edilen veri kümesi, dış el görüntüsü tabanlı biyometrik kişi tanıma ve sınıflandırma modeli için kullanılmıştır. Makine öğrenimi algoritmalarının ilk aşama için başarımları ve çalışma süreleri Tablo 2'de sunulmuştur. Başarımların oranlarına ait grafikler ise Şekil 5'de verilmiştir.

Tablo 2. (240 × 180) çözünürlük içeren veri kümesi başarımlar oranları ve çalışma süreleri


Algoritmalar	GLCM (216 özellik)		ORB+LBP (98 özellik)		GLCM+LBP (243 özellik)		GLCM+ORB (287 özellik)		GLCM+ORB+LBP (314 özellik)	
	Doğruluk (%)	Çalışma süresi (sn)	Doğruluk (%)	Çalışma süresi (sn)	Doğruluk (%)	Çalışma süresi (sn)	Doğruluk (%)	Çalışma süresi (sn)	Doğruluk (%)	Çalışma süresi (sn)
ELM	98.70	0.0138	98.20	0.0136	97.80	0.015	98.50	0.0149	98.50	0.0149
MLP-ELM	98.20	0.0139	96.20	0.0137	96.50	0.0164	96.80	0.0157	97.80	0.0154
ML-ELM	98.20	0.0463	98.50	0.0496	96.50	0.0534	98.00	0.0176	97.30	0.0486
CNN	87.33	81.24	96.33	82.36	90.17	86.93	94.00	80.63	92.50	78.15
DNN	92.83	64.65	98.17	66.01	89.67	70.35	98.50	64.77	97.83	69.05

**Şekil 5.** (240x180) çözünürlük veri kümesi başarımlar oranları

Bu aşamada oluşturulan beş özellik çıkarımına bakıldığında kişi tanıma için en iyi sınıflandırma başarımlar oranı ELM algoritması ile elde edilmiştir. Çalışma süreleri açısından ise en hızlı algoritma ELM olmuştur. Deneyel sonuçlara göre, ELM algoritması ilk uygulamadaki tüm özellik çıkarımı süreçlerinde yakın başarımlar sonuçları gözlemlenmiştir. Özellik çıkarımları incelendiğinde ilk aşama için en iyi başarımlar oranı GLCM yöntemi ile elde edilmiştir.

İkinci aşamada (160 × 120) piksel çözünürlük içeren veri kümesi üzerinde özellik çıkarımları uygulanmıştır. Özellik çıkarımı sonucunda elde edilen veri kümesi, dış el görüntüsü tabanlı biyometrik kişi tanıma ve sınıflandırma modeli için kullanılmıştır. Makine öğrenimi algoritmalarının ikinci aşama için başarımlar oranları ve çalışma süreleri Tablo 3'de sunulmuştur. Başarımlar oranlarına ait grafikler ise Şekil 6'da verilmiştir. Bu aşamada oluşturulan beş özellik çıkarımına bakıldığında kişi tanıma için en iyi sınıflandırma başarımlar oranı ELM algoritması ile elde edilmiştir. Çalışma süreleri açısından ise en hızlı algoritma ELM olmuştur. Deneyel sonuçlara

göre, ELM algoritması ilk uygulamadaki tüm özellik çıkarımı süreçlerinde yakın başarımlar sonuçları gözlemlenmiştir. Özellik çıkarımları incelendiğinde en iyi başarımlar oranı ORB+LBP yöntemi ile elde edilmiştir.

**Şekil 6.** (160 x120) çözünürlük veri kümesi başarımlar oranları.



Üçüncü aşamada (128 × 96) piksel çözünürlük içeren veri kümesi üzerinde özellik çıkarımları uygulanmıştır. Özellik çıkarımı sonucunda elde edilen veri kümesi, dış el görüntüsü tabanlı biyometrik kişi tanıma ve sınıflandırma modeli için kullanılmıştır. Makine öğrenimi algoritmalarının üçüncü aşama için başarımlar oranları ve çalışma süreleri Tablo 4'de sunulmuştur. Başarımlar oranlarına ait grafikler ise Şekil 7'de verilmiştir. Bu aşamada oluşturulan beş özellik çıkarımına bakıldığında kişi tanıma için en iyi sınıflandırma başarımlar oranı ELM algoritması ile elde edilmiştir. Çalışma süreleri açısından ise en hızlı algoritma ELM olmuştur. Deneyel sonuçlara göre, ELM algoritması ilk uygulamadaki tüm özellik çıkarımı süreçlerinde yakın başarımlar sonuçları gözlemlenmiştir. Özellik çıkarımları incelendiğinde en iyi başarımlar oranı GLCM+ORB yöntemi ile elde edilmiştir.

Tablo 3. (160 × 120) çözünürlük içeren veri kümesi başarımlar oranları ve çalışma süreleri.

Algoritmalar	GLCM (216 özellik)		ORB+LBP (98 özellik)		GLCM+LBP (243 özellik)		GLCM+ORB (287 özellik)		GLCM+ORB+LBP (314 özellik)	
	Doğruluk (%)	Çalışma süresi (sn)	Doğruluk (%)	Çalışma süresi (sn)	Doğruluk (%)	Çalışma süresi (sn)	Doğruluk (%)	Çalışma süresi (sn)	Doğruluk (%)	Çalışma süresi (sn)
ELM	97.70	0.0138	98.80	0.0142	95.90	0.0149	98.70	0.0137	98.30	0.0151
MLP-ELM	94.50	0.0144	97.30	0.0142	93.30	0.0153	96.70	0.0148	96.70	0.0158
ML-ELM	95.80	0.0436	98.50	0.0505	96.20	0.051	97.20	0.0452	95.30	0.0521
CNN	88.17	80.51	92.50	82.59	89.33	85.31	91.00	80.83	90.17	78.32
DNN	92.00	65.44	98.50	66.25	92.67	69.79	98.00	63.51	98.00	67.57

Tablo 4. (128 × 96) çözünürlük içeren veri kümesi başarımları ve çalışma süreleri.

Algoritmalar	GLCM (216 özellik)		ORB+LBP (98 özellik)		GLCM+LBP (243 özellik)		GLCM+ORB (287 özellik)		GLCM+ORB+LBP (314 özellik)	
	Doğruluk (%)	Çalışma süresi (sn)	Doğruluk (%)	Çalışma süresi (sn)	Doğruluk (%)	Çalışma süresi (sn)	Doğruluk (%)	Çalışma süresi (sn)	Doğruluk (%)	Çalışma süresi (sn)
ELM	97.50	0.013	98.50	0.031	97.00	0.0148	98.70	0.0132	97.80	0.0151
MLP-ELM	96.50	0.0138	96.80	0.0135	95.30	0.0158	97.20	0.0136	96.70	0.0151
ML-ELM	95.80	0.0441	98.50	0.0473	95.70	0.052	96.50	0.0464	96.50	0.0549
CNN	90.00	78.42	92.20	82.374	88.68	88.61	93.33	80.93	88.00	78.11
DNN	87.83	65.22	98.00	66.143	91.00	70.85	98.83	62.39	98.00	63.55

**Şekil 7.** (128 × 96) çözünürlük veri kümesi başarımları.**Şekil 8.** (80 × 60) çözünürlük veri kümesi başarımları.

Son aşamada (80 × 60) piksel çözünürlük içeren veri kümesi üzerinde özellik çıkarımları uygulanmıştır. Özellik çıkarımı sonucunda elde edilen veri kümesi, dış el görüntüsü tabanlı biyometrik kişi tanıma ve sınıflandırma modeli için kullanılmıştır. Makine öğrenimi algoritmalarının dördüncü aşama için başarımları ve çalışma süreleri Tablo 5'te sunulmuştur. Başarımlarına ait grafikler ise Şekil 8'de verilmiştir. Bu aşamada oluşturulan beş özellik çıkarımına bakıldığında kişi tanıma için en iyi sınıflandırma başarımları ELM algoritması ile elde edilmiştir. Çalışma süreleri açısından ise en hızlı algoritma ELM olmuştur. Deneysel sonuçlara göre, ELM algoritması ilk uygulamadaki tüm özellik çıkarımı süreçlerinde yakın başarımları gözlemlenmiştir. Özellik çıkarımları incelendiğinde en iyi başarımları ORB+LBP yöntemi ile elde edilmiştir.

Tüm aşamalarda uygulamalar incelendiğinde, farklı çözünürlüklere indirgenmiş veri kümeleri üzerinde ELM algoritmasının genel olarak diğer algoritmalarla göre başarımlarını koruduğu ve en iyi başarımları sağladığı gözlemlenmiştir. Tüm aşamalardaki süreçlerde ELM algoritması en iyi ortalama başarımları %97.60 olarak belirlenmiştir. Ayrıca, ELM'nin kararlı bir yapıya sahip olduğu söylenebilir. Algoritmaların farklı yapıları nedeniyle çalışma sürelerinde de farklılıklar ortaya çıkmaktadır. En hızlı sınıflandırıcı temel ELM algoritmasıdır. Özellik çıkarımları incelendiğinde tüm aşamalar için en iyi ORB+LBP yöntemi olmuştur. ORB+LBP özellik çıkarımı yöntemi tüm aşama ve uygulama süreçlerinde en iyi ortalama başarımları %96.78 olarak elde edilmiştir. Tüm aşamalardaki uygulamalarda algoritmalar içerisinde çalışma süresi en yavaş ve başarımları en düşük CNN olmuştur.

Tablo 5. (80 × 60) çözünürlük içeren veri kümesi başarımları ve çalışma süreleri.

Algoritmalar	GLCM (216 özellik)		ORB+LBP (98 özellik)		GLCM+LBP (243 özellik)		GLCM+ORB (287 özellik)		GLCM+ORB+LBP (314 özellik)	
	Doğruluk (%)	Çalışma süresi (sn)	Doğruluk (%)	Çalışma süresi (sn)	Doğruluk (%)	Çalışma süresi (sn)	Doğruluk (%)	Çalışma süresi (sn)	Doğruluk (%)	Çalışma süresi (sn)
ELM	95.30	0.0121	98.20	0.0113	94.30	0.0287	97.30	0.012	96.20	0.0136
MLP-ELM	94.30	0.012	94.80	0.0112	90.50	0.0164	93.50	0.0129	94.50	0.0148
ML-ELM	93.70	0.0386	98.50	0.0446	90.50	0.0557	94.30	0.0406	93.50	0.0485
CNN	87.67	75.38	87.00	89.826	89.20	84.09	92.67	75.60	93.66	76.57
DNN	89.50	57.45	98.10	66.795	91.00	68.88	97.90	57.48	97.95	60.88

6. TARTIŞMA VE SONUÇ

Bu çalışmanın bulguları, dış el görüntüsü tabanlı biyometrik kişi tanıma ve sınıflandırma süreçlerinde yüksek doğrulukla çalışabildiğini göstermektedir. Düşük çözünürlüklü görüntülerde kabul edilebilir doğruluk oranlarına ulaşabilmesi, bu yöntemlerin pratik uygulamalarda da kullanılabilirliğini artırmaktadır. GLCM, ORB ve LBP özellik çıkarımı yöntemleri ve birleşimleri ile oluşturulan özellik kümelerinin sınıflandırma doğruluğuna olan etkileri incelenmiş ve her üç özellik çıkarımı yönteminin de farklı çözünürlüklerde başarılı sonuçlar verdiği görülmüştür. Deneysel sonuçlar, ELM algoritmasının tüm çözünürlük seviyelerinde tutarlı ve yüksek başarımlar sağladığını; buna karşın CNN algoritmasının gerek doğruluk oranı gerekse işlem süresi açısından daha düşük performans sergilediğini ortaya koymuştur. Bu durum, ELM algoritmasının dış el tabanlı biyometrik sistemler için özellikle sınırlı işlem gücüne sahip uygulamalarda tercih edilebilir olduğunu göstermektedir. Özellik çıkarım yöntemleri açısından değerlendirildiğinde, ORB+LBP birleşiminin tüm çözünürlük düzeylerinde en yüksek ortalama doğruluk oranına ulaştığı görülmektedir. Ayrıca, GLCM yönteminin daha yüksek çözünürlüklerde etkili olduğu, ancak çözünürlük azaldıkça performansının düştüğü gözlemlenmiştir. Bu bulgular, özellikle düşük kaliteli görüntülerle çalışan biyometrik sistemlerde özellik çıkarım yöntemi seçiminin kritik olduğunu ortaya koymaktadır.

Gelecekte yapılacak çalışmalar kapsamında, sistemin farklı ışık koşulları, pozlama varyasyonları ve kullanıcı davranışlarına karşı dayanıklılığı planlanmaktadır. Ayrıca, derin öğrenme tabanlı yöntemlerle klasik makine öğrenmesi yöntemlerinin başarımları karşılaştırılarak daha kapsamlı analizler düşünülmektedir. Bu doğrultuda farklı biyometrik özelliklerin ve daha büyük veri kümelerinin kullanılması hedeflenmektedir.

Etik Hususlar

Finansman

Yazarlar, araştırmalarının kamu, ticari veya kar amacı gütmeyen sektörlerdeki fon kuruluşlarından özel bir hibe almamıştır.

Çıkar çatışması

Yazarlar arasında herhangi bir çıkar çatışması yoktur.

KAYNAKÇA

[1] Afifi, M. 2019. 11K Hands: Gender recognition and biometric identification using a large dataset of hand images. *Multimedia Tools and Applications*, 78, 20835–20854. DOI: 10.1007/s11042-018-6915-2

[2] Elumalai, K., Kannan, M. 2011. Multimodal authentication for high end security. *International Journal on Computer Science and Engineering*, 3(2), 687–692.

[3] Ngugi, B., Kamis, A., Tremaine, M. 2011. Intention to use biometric systems. *e-Service Journal*, 7(3), 20–46. DOI: 10.2979/eservicej.7.3.20

[4] Yalçın, N., Gürbüz, F. 2015. Biyometrik güvenlik sistemlerinin incelenmesi. *Düzce Üniversitesi Bilim ve Teknoloji Dergisi*, 3(2), 398–413.

[5] Özbay, E. 2022. Cinsiyet Tespiti için Palmar El Görüntülerinin Yerel İkili Desen ve Zernike Momentlenerek Kullanılarak Sınıflandırılması.

[6] Jain, A. K., Ross, A., Prabhakar, S. 2004. An introduction to biometric recognition. *IEEE Transactions on Circuits and Systems for Video Technology*, 14(1), 4–20. DOI: 10.1109/TCSVT.2003.818349

[7] Adedeji, K. B. 2024. Analysis of ANN Training Algorithms for Hand Geometry-based Access Control. *System*, 12(43).

[8] Mohamed, A. S., Hassan, A. I., Salama, A. 2024. Deep Learning Techniques to enhance Biometric Authentication using Hand Features. *Alfarama Journal of Basic & Applied Sciences*, 5(2), 281–292. DOI: 10.21608/ajbas.2024.263079.1208

[9] Klonowski, M., Plata, M., Syga, P. 2018. User authorization based on hand geometry without special equipment. *Pattern Recognition*, 73, 189–201. DOI: 10.1016/j.patcog.2017.08.011

[10] Shakil, S., Arora, D., Zaidi, T. 2023. Feature identification and classification of hand based biometrics through ensemble learning approach. *Measurement: Sensors*, 25, 100593. DOI: 10.1016/j.measen.2023.100593

[11] Elihoş, A., Artan, Y. O., Sezer, E. S. 2022. Automatic Latent Fingerprint Pose Estimation. In *2022 30th Signal Processing and Communications Applications Conference (SIU)*, 1–4. IEEE. DOI: 10.1109/SIU55565.2022.9864715

[12] Artan, Y. 2024. MinNet Based Contactless Fingerprint Matching Method. In *2024 32nd Signal Processing and Communications Applications Conference (SIU)*, 1–4. IEEE.

[13] Genel, M., Can, Ö., Uğur, A. 2024. Comparison of Deep Learning and Machine Learning Methods for Fingerprint Verification and Forgery Detection. In *2024 8th International Artificial Intelligence and Data Processing Symposium (IDAP)*, 1–8. IEEE.

[14] Çalışkan, A., Ergen, B. Gabor Dalgacık Dönüşümü Kullanarak Avuç İçi Tanıma.

[15] Nabyev, V. V., Ekinci, M., Öztürk, Y. 2011. Avuç İçi Çizgilerine Göre Biyometrik Tanıma.

- [16] Çalışkan, A., Ergen, B. 2014. GRI seviye eş-oluşum matrisi tabanlı avuç içi tanıma sistemi. *Araştırma Merkezi Bilişim Dergisi*, 5(2), 18-29. <https://doi.org/10.53608/estudambilisim.1550680>
- [17] Babalola, F. O., Toygar, Ö., Bitirim, Y. 2021. A palm vein recognition approach by multiple convolutional neural network models. *Avrupa Bilim ve Teknoloji Dergisi*, (29), 237-242.
- [18] Jhong, S. Y., Tseng, P. Y., Siriphockpirom, N., Hsia, C. H., Huang, M. S., Hua, K. L., Chen, Y. Y. 2020. An automated biometric identification system using CNN-based palm vein recognition. In *2020 International Conference on Advanced Robotics and Intelligent Systems (ARIS)*, 1-6. IEEE.
- [19] Sun, S., Cong, X., Zhang, P., Sun, B., Guo, X. 2021. Palm vein recognition based on NPE and KELM. *IEEE Access*, 9, 71778-71783. DOI: 10.1109/ACCESS.2021.3078935
- [20] Katılmış, Z. 2025. Makine Öğrenimi Yaklaşımları Kullanarak El Hareketi Tabanlı Biyometrik Kimlik Doğrulama. *Bilecik Şeyh Edebali Üniversitesi Fen Bilimleri Dergisi*, 12(1), 274-289. <https://doi.org/10.35193/bseufbd.1555404>
- [21] Huang, G.-B., Zhu, Q.-Y., & Siew, C.-K. 2006. Extreme learning machine: Theory and applications. *Neurocomputing*, 70(1-3), 489-501. <https://doi.org/10.1016/j.neucom.2005.12.126>
- [22] Cai, D., He, X., & Han, J. 2012. Speed up kernel discriminant analysis. *The VLDB Journal*, 20(1), 21-33. <https://doi.org/10.1007/s00778-010-0200-4>
- [23] Kasun, L. L. C., Zhou, H., Huang, G.-B., & Vong, C. M. 2013. Representational Learning with ELMs for Big Data. *IEEE Intelligent Systems*, 28(6), 31-34. <https://doi.org/10.1109/MIS.2013.80>
- [24] LeCun, Y., Bengio, Y., & Hinton, G. 2015. Deep learning. *Nature*, 521(7553), 436-444. <https://doi.org/10.1038/nature14539>
- [25] [Arslan, N. N., & Ozdemir, D. 2024. Analysis of CNN models in classifying Alzheimer's stages: comparison and explainability examination of the proposed separable convolution-based neural network and transfer learning models. *Signal, Image and Video Processing*, 18(Suppl 1), 447-461. <https://doi.org/10.1007/s11760-024-03166-5>
- [26] Güçlü, S., Özdemir, D., & Saraoğlu, H. M. 2025. A new model for anomaly detection in elbow and finger X-Ray images: proposed parallel densenet. *Bulletin of the Polish Academy of Sciences. Technical Sciences*, 73(2). DOI 10.24425/bpasts.2025.153233
- [27] Güçlü, S., Özdemir, D., & Saraoğlu, H. M. 2024. Bilek ve Ön Kol X-Ray Görüntüleri Kullanılarak DenseNet Tabanlı Yeni Bir Anomali Tespiti Yöntemi. *Eskişehir Türk Dünyası Uygulama ve*
- [28] Serce, H., Bastanlar, Y., Temizel, A., Yardımcı, Y. 2008. On detection of edges and interest points for omnidirectional images in spherical domain. In *2008 IEEE 16th Signal Processing, Communication and Applications Conference*, 1-4. IEEE.
- [29] Şentürk, T., Latifoğlu, F., Bolat, D., Yay, A., Baran, M. 2021. Histopatolojik Görüntülerle Diyabetin Akciğer Dokusundaki Etkisinin Sınıflandırılması: LBP ve GLCM Özellikleri ile Bir Karşılaştırma Çalışması. *International Journal of Multidisciplinary Studies and Innovative Technologies*, 7(2), 84-89.
- [30] Hemalatha, C. S., Vaidehi, V., Lakshmi, R. 2015. Minimal Infrequent Pattern Based Approach for Mining Outliers in Data Streams. *Expert Systems with Applications*, 42(4), 1998-2012. DOI: 10.1016/j.eswa.2014.10.003
- [31] Ondimu, S. N., Murase, H. 2008. Effect of Probability-Distance Based Markovian Texture Extraction on Discrimination in Biological Imaging. *Computers and Electronics in Agriculture*, 63(1), 2-12. DOI: 10.1016/j.compag.2007.12.005
- [32] Haralick, R. M., Shanmugam, K., Dinstein, I. H. 1973. Textural Features for Image Classification. *IEEE Transactions on Systems, Man, and Cybernetics*, (6), 610-621. DOI: 10.1109/TSMC.1973.4309314
- [33] Rublee, E., Rabaud, V., Konolige, K., Bradski, G. 2011. ORB: An Efficient Alternative to SIFT or SURF. In *2011 International Conference on Computer Vision*, 2564-2571. IEEE. DOI: 10.1109/ICCV.2011.6126544
- [34] Kaur, A., Kumar, M., Jindal, M. K. 2023. Cattle Identification System: A Comparative Analysis of SIFT, SURF and ORB Feature Descriptors. *Multimedia Tools and Applications*, 82(18), 27391-27413. DOI: 10.1007/s11042-023-14715-3
- [35] Günay, A., Nabyev, V. V. 2011. LBP Yardımıyla Görüntüdeki Kişinin Yaşının Bulunması. *Çankaya University Journal of Science and Engineering*, 8(1), 27-41.