

Iris Biyometrik Tanıma Performansının Makine Öğrenmesi Yöntemleriyle Değerlendirilmesi

Sabit Gölçük

Yıldız Teknik Üniversitesi, Elektrik Elektronik Fakültesi, Elektronik ve Haberleşme Mühendisliği, İstanbul, Türkiye
(sabit.golcuk@std.yildiz.edu.tr) (ORCID: 0009-0001-7078-7238)

Türkçe Özet – Biyometrik tanıma sistemleri, güvenlik ve kişiye özel kimlik doğrulama gereksinimlerinin artmasıyla birlikte günümüzde yaygın şekilde kullanılmaktadır. Bu çalışmada, iris görüntülerine dayalı biyometrik tanıma sistemlerinin performansı, farklı makine öğrenmesi ve derin öğrenme yöntemleri kullanılarak kapsamlı bir şekilde analiz edilmiştir. Araştırmanın ilk aşamasında, açık kaynaklı bir iris veri seti üzerinde kişi tanıma algoritmalarına uygun olacak şekilde çeşitli ön işleme ve veri artırma teknikleri uygulanmıştır. Bu adımlar, sistemin tanıma başarımını optimize etmeyi ve sınıflandırma algoritmalarının genel doğruluğunu artırmayı hedeflemiştir. Ardından, geleneksel makine öğrenmesi yaklaşımlarından biri olan destek vektör makineleri (Support Vector Machine - SVM) ile derin öğrenme tabanlı VGG16 sinir ağı modeli kullanılarak sınıflandırma işlemleri gerçekleştirilmiştir. Modellerin performansı doğruluk (accuracy) ve sahte red oranı (False Rejection Rate - FRR) metrikleri üzerinden değerlendirilmiştir. VGG16 modeli gauss filtre kullanılarak artırılmış veri seti ile %99 doğruluk ve %1 FRR değeri ile en iyi performansı gösterirken, SVM ile aynı veri seti ve HOG+PCA öznelik çıkarımı kullanılarak %96.5 doğruluk ve %3.5 FRR oranlarına ulaşmıştır. Çalışma kapsamında geliştirilen model dosyaları ve kodlar, açık erişimli olarak paylaşılmaktadır.

Anahtar Kelimeler – IRIS Tanıma, Makina Öğrenmesi, Destek Vektör Makinaları, VGG16, Biyometrik Tanıma

Atf: Gölçük, S. (2025). Iris Biyometrik Tanıma Performansının Makine Öğrenmesi Yöntemleriyle Değerlendirilmesi. International Journal of Multidisciplinary Studies and Innovative Technologies, 9(2): 233-239.

Evaluation of Iris Biometric Recognition Performance Using Machine Learning Methods

Extended Abstract

Research Problem/Questions – Biometric recognition systems have gained increasing importance due to the growing demand for secure and reliable identity authentication. Among various biometric traits, the iris provides highly unique and stable patterns that remain unchanged throughout an individual's lifetime. The main research question of this study is: *How can machine learning and deep learning approaches improve the accuracy and reliability of iris-based biometric recognition systems?*

Short Literature Review – Previous studies have demonstrated that traditional machine learning methods such as Support Vector Machines (SVM) combined with statistical or texture-based feature extraction can achieve competitive accuracy in iris recognition. However, recent advances in deep learning, particularly convolutional neural networks (CNNs) such as VGG16 and DenseNet, have shown superior performance by automatically extracting complex features. While earlier works primarily focused on limited datasets and handcrafted features, current research emphasizes data augmentation and transfer learning techniques to address scalability and robustness challenges.

Methodology – In this study, the CASIA-Iris-Thousand dataset, consisting of 20,000 near-infrared iris images from 1,000 individuals, was used. For traditional machine learning, SVM classifiers were trained using feature extraction methods including Histogram of Oriented Gradients (HOG), Local Binary Patterns (LBP), and Principal Component Analysis (PCA) for dimensionality reduction. In parallel, the VGG16 deep learning architecture was applied for classification tasks. Data augmentation techniques, such as Gaussian blur and Gaussian noise, were employed to increase sample diversity and improve generalization. Performance evaluation was conducted using accuracy, F1-score, False Acceptance Rate (FAR), and False Rejection Rate (FRR).

Results and Conclusions – The results show that SVM with HOG+PCA features achieved 96.5% accuracy with a 3.5% FRR, while the VGG16 model, combined with Gaussian blur augmentation, reached 99% accuracy and 1% FRR, demonstrating superior performance. The low FAR values indicate high security, while the low FRR values highlight user-friendliness. Compared with previous works, the proposed augmentation strategies significantly improved recognition performance, particularly for larger class sizes. The findings confirm that deep learning models, when combined with data augmentation, outperform traditional machine learning approaches in iris biometric recognition. This study highlights the potential of deep learning for real-world biometric security systems and suggests that future work should focus on optimizing models for deployment in resource-constrained environments.

Keywords – IRIS recognition, Machine Learning, Support Vector Machine, VGG16, Biometric authentication

Citation: Golcuk, S. (2025). Evaluation of Iris Biometric Recognition Performance Using Machine Learning Methods. International Journal of Multidisciplinary Studies and Innovative Technologies, 9(2): 233-239.

I. GİRİŞ

Biyometrik doğrulama, bireylerin fizyolojik veya davranışsal özelliklerine dayalı olarak otomatik kimlik tanıma sürecini ifade eder. Parola veya kimlik kartı gibi geleneksel yöntemlerin aksine, biyometrik sistemler kişinin kendisine ait benzersiz verilerini kullanarak sahteciliğe karşı dayanıklı ve daha yüksek güvenliğin sistemlerin oluşmasına olanak tanır [1]. Günümüzde yaygın olarak kullanılan biyometrik özellikler arasında parmak izi, yüz, ses, retina ve iris dokusu yer almaktadır [1], [2]. Bu sistemler, sınır güvenliği ve bankacılık gibi yüksek güvenlik gerektiren alanların yanı sıra, mobil cihazların kilidinin açılması ve akıllı ev sistemleri gibi kişisel kullanım alanlarında da giderek artan bir şekilde kullanılmaktadır.

Biyometrik tanıma uygulamalarında sıklıkla kullanılan ve göz bebeğini çevreleyen renkli halka olarak tanımlanan iris, bireyin yaşamı boyunca büyük ölçüde sabit kalan karmaşık ve kişiye özgü desenler içerir. Bu özellikleri sayesinde güvenilir bir biyometrik tanımlayıcı olarak kabul edilmektedir [3]. Iris tanıma sistemleri; havaalanı geçiş kontrolleri, ulusal kimlik projeleri ve gelişmiş gözetim sistemleri gibi yüksek güvenlik gerektiren uygulamalarda başarıyla kullanılmaktadır [4].

Harrabi'nin çalışmasında [5], iris görüntülerinden elde edilen istatistiksel özelliklerin, Destek Vektör Makinesi (Support Vector Machine - SVM) ile birleşik bir şekilde kullanılarak tanıma doğruluğunun artırılması amaçlanmıştır. Fuzzy C-Means algoritması ile iris görüntüsü arka plandan ayrılmış ve PCA (Principal Component Analysis) ile sınıflandırıcıya verilmek üzere özellikler çıkartılmıştır. CASIA iris veri setinin kullanıldığı çalışmada 324 sınıf için %96.30 başarımlar raporlanmış ve sonuçlar literatürde yapılan benzer çalışmalarla karşılaştırılarak elde edilen iyileştirme gösterilmiştir. Moshli [6]'nin çalışmasında iris tanıma aşamasında yüksek doğruluk oranı elde etmek amacıyla önceden eğitilmiş DenseNet-201 modeli kullanılmıştır. Bu yöntem, çeşitli açık erişimli veri kümelerinde ulaştığı yüksek başarımlar nedeniyle iris tanıma açısından güçlü bir model olarak değerlendirilmektedir. Minaee ve Abdolrashidi [7], her sınıftan az sayıda örnek içeren bir veri seti kullanarak, ResNet-50 transfer öğrenme modeli ile kişi tanıma gerçekleştirmişlerdir. Tanıma aşamasında, iris bölgesindeki önemli bölgeleri belirlemek amacıyla bir görselleştirme yöntemi uygulanmıştır.

Bu çalışmada, iris görüntülerine dayalı biyometrik tanıma sistemlerinin başarımlarını, geleneksel makine öğrenmesi teknikleri ile derin öğrenme modelleri kullanılarak analiz

edilmiştir. Ayrıca, farklı veri artırımı ve öznetelik çıkartım yaklaşımları ve sınıf sayısının tanıma başarımı üzerindeki etkisi de incelenmektedir. Bu amaçla, Çin Bilimler Akademisi tarafından oluşturulan CASIA-Iris veri seti [12] kullanılarak, destek vektör makinesi (SVM) ve VGG16 algoritmaları kullanılmış, performans doğruluk, F1 ölçütü, FAR, FRR ve ROC eğrisi metrikleri kullanılarak raporlanmıştır. Elde edilen sonuçlar, farklı algoritmaların iris tanıma başarımı üzerindeki etkisini karşılaştırmalı olarak ortaya koymakta ve gelecekteki biyometrik güvenlik sistemleri için önemli çıkarımlar sunmaktadır.


Teknik yazının devamında, öncelikle kullanılan veri seti, veri artırımı ve öznetelik çıkartma yöntemleri ayrıntılandırılmakta sonrasında sınıflandırma algoritmaları açıklanmaktadır. Son bölümde yapılan testler, kullanılan metrikler ve performanslar karşılaştırmalı olarak sunulmaktadır.

II. YÖNTEM

Bu çalışmada, Çin Bilimler Akademisi Otomasyon Enstitüsü (CASIA-Chinese Academy of Sciences Institute of Automation) tarafından oluşturulan CASIA-Iris-Thousand veri kümesindeki iris görüntüleri kullanılmıştır. Veri kümesi, 1.000 farklı bireye ait toplam 20.000 kızılötesi (Near Infrared-NIR) iris görüntüsünden oluşmakta olup, her birey için 10 sol, 10 sağ olmak üzere 20 iris görüntüsü içermektedir. Şekil 1'de örnekleri gösterilen görüntüler, kontrollü aydınlatma koşulları altında ve sabit kamera mesafesi ile IKEMB-100 kamerası kullanılarak kaydedilmiştir. 640×480 piksel çözünürlüğe sahip bu görüntüler, özellikle büyük ölçekli iris tanıma algoritmalarının geliştirilmesi ve performanslarının değerlendirilmesi amacıyla tasarlanmıştır. Bu çalışmada, hesaplama maliyetini azaltarak farklı senaryolarda model performansını analiz edebilmek amacıyla, veri kümesinin tamamı yerine belirli bir alt kümesi kullanılmıştır. Verinin ayrıntıları, Bölüm III'de detaylandırılacaktır.

Bu çalışmada sınıflandırıcı olarak klasik makine öğrenmesi yöntemlerinden olan Destek Vektör Makinası (Support Vector Machine-SVM) ve özellikle görsel verileri işlemek için tasarlanmış özel bir derin öğrenme modeli olan evrişimli sinir ağları (Convolutional Neural Network-CNN) tabanlı VGG16 [8] kullanılmıştır. VGG16, 2014 yılında Oxford Üniversitesi'nin Visual Geometry Group tarafından tasarlanmıştır, görsel sınıflandırma problemleri için evrişimli sinir ağlarını kullanan ilk yöntemlerdendir. Model, 13 evrişim katmanı ve 3 tam bağlı katman olmak üzere toplam 16 katmandan oluşur. VGG16, 3x3 lük evrişim filtreleri kullanarak, daha derin bir ağ yapısında yüksek seviyede

özellik çıkarımı yapabilme kapasitesine sahiptir. Bu küçük filtre boyutu, ağırlık katmanlarında daha fazla ağırlık ve öğrenilebilir parametre içermesine olanak tanır, bu da modelin daha detaylı ve incelikli özellikleri öğrenmesine yardımcı olur.




Şekil 1: CASIA-Iris-Thousand veri seti farklı kişilere ait veri örnekleri

SVM, özellikle sınıflandırma ve regresyon problemlerinde yüksek genel performans sergileyen denetimli bir makine öğrenme yöntemidir. SVM'in temel prensibi, veriyi en iyi şekilde ayıran hiper düzlemi (decision boundary) belirlemektir. Lineer olarak ayrılabilir verilerde doğrudan uygulanabilirken, lineer olmayan durumlar için çekirdek (kernel) fonksiyonları kullanılarak veri daha yüksek boyutlu özellik uzaylarına dönüştürülür ve burada ayrılabilir hale getirilir. Yaygın olarak kullanılan çekirdek fonksiyonlar arasında doğrusal (linear), polinomsal (polynomial), radyal tabanlı fonksiyon (RBF – Radial Basis Function) ve sigmoid yer almaktadır. Çalışma kapsamında kullanılan SVM sınıflandırıcısı RBF fonksiyonu kullanılmaktadır.

SVM tabanlı sınıflandırma sistemlerinde başarıyı doğrudan etkileyen en kritik adımlardan biri, etkili özellik çıkarımıdır. Bu kapsamda çalışmada Temel Bileşenler Analizi (Principal Component Analysis-PCA) [9], Yerel İkili Desenler (Local Binary Patterns-LBP) [10] ve Yönlendirilmiş Gradyanların Histogramı (Histogram of Oriented Gradient-HOG) [11] olmak üzere üç farklı özellik çıkarma algoritması kullanılmış ve SVM sınıflandırıcısı ile birlikte performansları karşılaştırılmıştır. PCA, yüksek boyutlu verilerdeki korelasyonları analiz ederek, veriyi daha düşük boyutlu ve anlamlı bileşenlere indirger. PCA, sınıflandırma sürecinde gürültüyü azaltarak bilgi yoğun alt uzaylarda daha güçlü temsil yeteneği sunar. Öte yandan LBP yöntemi, özellikle doku tabanlı özelliklerin çıkarımında yaygın olarak kullanılan istatistiksel bir tekniktir. Her pikselin komşuluk ilişkilerine göre ikili kodlar oluşturur ve bu kodlar, görüntünün mikro desenlerini etkili biçimde temsil eder. Bir diğer özellik çıkarma yöntemi olan HOG'un temel prensibi, görüntüdeki kenar yapılarını ve yerel gradyan yönelimlerini analiz ederek, bu bilgileri istatistiksel bir temsil olan histogramlar şeklinde özetlemektir. Yöntem, öncelikle görüntünün gradyan büyüklüklerini ve yönelimlerini hesaplar, ardından görüntü, sabit boyutlu hücrelere bölünerek her hücre için yönelim histogramları oluşturulur. Bu histogramlar, kenarların belirli yönlerde yoğunlaştığı bölgeleri tanımlar ve nesne yapısına özgü bilgileri içerir. Komşu hücrelerin birleştirilmesiyle oluşturulan bloklar üzerinden normalizasyon işlemi gerçekleştirilerek,

aydınlatma ve kontrast değişimlerine karşı daha kararlı bir öznelik kümesi elde edilir.

Makine öğrenmesi tabanlı sınıflandırma problemlerinde modelin doğruluğunu ve genelleme yeteneğini değerlendirebilmek için veri kümesi eğitim seti ve test seti olmak üzere iki ana gruba ayrılır. Bu ayrım, modelin yalnızca eğitim verisine uyum sağlamasını değil, aynı zamanda yeni veriler üzerinde de doğru tahminlerde bulunabilmesini sağlamak için kritik öneme sahiptir. Başarımı etkileyen en önemli faktörlerden biride eğitim kümesindeki örnekler ve bu örneklerin sayısıdır. Eğitim kümesindeki örneklerin kalitesi ve çeşitliliği daha başarılı bir model oluşturulmasına olanak tanır. Bu kapsamda veri setinde her bireyin tek gözü için sunulan 10 iris görüntüsü veri artırımı yöntemi ile ayrı ayrı artırılarak 20'ye çıkarılmıştır. Bu amaçla iki farklı yaklaşım kullanılmış ve bu yöntemlerin performansları karşılaştırmalı olarak analiz edilmiştir. İlk olarak standart sapması 1 olan Gauss Blur 5x5'lik filtreleme ile uygulanmıştır. Bu filtre her pikselin yeni değerini belirlerken, komşu piksellerin katkısını iki boyutlu Gauss dağılımı temelinde ağırlıklandırır. Bu dağılımın merkezine yakın piksellere daha yüksek ağırlık verilirken, uzak piksellerin etkisi azaltılır. Böylece, görüntü yumuşatılırken kenar yapıları korunmaya çalışılır. Veri artırımı için kullanılan diğer yöntem ise ortalaması sıfır, varyansı 0.005 olan normal dağılım gürültüsü (Gauss Noise) eklemektir. Şekil 2'de her iki veri artırma metodu ile elde edilen örnek görüntüler yer almaktadır.



Şekil 2: Veri Artırımı Örnekleri: a) Orijinal görüntü, b) Gauss Blur Filtre uygulanmış görüntü, c) Gauss dağılım gürültüsü uygulanmış görüntü

Çalışmada, eğitim – test veri seti oluşturulurken, veriler rastgele olarak ayrılmıştır. Ancak, performans analizinin doğru bir şekilde yapılabilmesi, eğitim-test veri setinde sınıflardaki örnek dengesizliklerinin azaltılabilmesi ve aynı kişiye ait görüntülerin hem eğitim hem de test setlerinde yer alabilmesi için veri kimlikleri bazında kontrollü bir ayırma stratejisi uygulanmıştır. Rastgele ayırım yapılması, modelin yalnızca belirli bir veri düzenine bağımlı kalmadan, farklı örnek dağılımlarında da benzer başarı gösterebilme (genelleme) yeteneğini test etme olanağı sağlamaktadır. Böylece, modelin performansı belirli bir veri diziliminden kaynaklanan etkilerinden arındırılmış, daha güvenilir bir değerlendirme yapılmıştır.

III. PERFORMANS TESTLERİ

Bu çalışmada kimlik tanıma bir sınıflandırma problemi olarak ele alınmış ve verinin düzenlenmesi, eğitim/test kümelerine ayrılması ve veri artırımı için MATLAB, öznelik çıkarımı ve sınıflandırma algoritmaları için Google Colab ortamı (T4-GPU) kullanılmıştır.

Model performansları, CASIA-Iris-Thousand veri setinde yer alan görüntülerden oluşturulmuş yeni bir veri seti kullanılarak raporlanmıştır. Öncelikle, verisetindeki ilk 100 ve 300 kişiye ait iris görüntülerinden yeni bir veri kümesi (sırasıyla OV100 ve OV300) oluşturulmuştur. Çalışmada her bireyin sağ ve sol iris görüntüleri ayrı sınıflar olarak değerlendirilmiş, dolayısıyla sınıf sayısı kişi sayısının iki katı olacak şekilde belirlenmiştir. Bunun nedeni, bireylere ait sağ ve sol iris örneklerinin farklı öznelik dağılımlarına sahip olabilesidir. Aynı sınıf olarak etiketlenmeleri durumu, sınıf içi varyansın artmasına ve modelin ayırt edici performansının düşmesine yol açabilmektedir. Her iki veri kümesi, hem orijinal görüntüler (OV) hem de veri artırma yöntemleriyle zenginleştirilmiş versiyonları olmak üzere üç farklı biçimde değerlendirilmiştir. Bu kapsamda Gauss Blur (GB) ve Gauss Noise (GN) yöntemleri uygulanarak her birey için mevcut örnek sayısı iki katına çıkarılmış (OV+GB ve OV+GN), böylece modelin farklı veri artırma yöntemleri ile göre performansı analiz edilmiştir. Tablo 1'de kullanılan veri setlerinin kişi sayısı, sınıf sayısı, sınıf başına örnek sayısı (ÖS) ve toplam örnek sayısı özetlenmektedir.

Tablo 1: Çalışma kapsamında kullanılan veriseti detayları.

Veriseti	Kişi Sayısı	Sınıf Sayısı	Sınıf Başına ÖS	Toplam ÖS
OV ₁₀₀	100	200	10	2000
OV ₃₀₀	300	600	10	6000
OV+GB ₁₀₀	100	200	20	4000
OV+GB ₃₀₀	300	600	20	12000
OV+GN ₁₀₀	100	200	20	4000
OV+GN ₃₀₀	300	600	20	12000

Tüm yöntemlerde başarımlar, karmaşıklık matrisi üzerinden analiz edilmiştir. Bu matris, her sınıf için modelin yaptığı tahminleri aşağıdaki gibi dört temel kategoriye ayırır:

- Doğru Pozitif (True Positive - TP): İlgili kişiye ait olan ve ilgili kişiye atanan örnek sayısı
- Yanlış Pozitif (False Positive - FP): İlgili kişiye ait olmayan ancak ilgili kişiye atanan örnek sayısı
- Yanlış Negatif (False Negative - FN): İlgili kişiye ait olan ancak farklı bir kişiye atanan örnek sayısı
- Doğru Negatif (True Negative - TN): İlgili kişiye ait olmayan ve farklı bir kişiye atanan örnek sayısı

Bu temel kavramlar üzerinden performansı değerlendirmek amacıyla doğruluk (accuracy-Acc), F1-skoru, Yanlış Kabul Oranı (False Acceptance Rate - FAR) ve Yanlış Red Oranı (False Rejection Rate - FRR) performans ölçütleri hesaplanmıştır. Doğruluk, doğru kimlik tanıma yapılan örneklerin toplam örnek sayısına oranı olup genel başarı

düzeyini yansıtan temel bir ölçüttür ve N ve K sırasıyla toplam örnek sayısı ve sınıf (tespit edilecek kişi) sayısı, TP_i i sınıf için TP değeri olmak üzere denklem 1 ile hesaplanır.

$$Acc = \sum_{i=1..K} \frac{TP_i}{N_i} \quad (1)$$

F1-skoru ise, her bir sınıf için denklem 2 ile hesaplanan kesinlik (precision) ve duyarlılık (recall) değerlerinin harmonik ortalamasıdır ve denklem 3 ile hesaplanır. Kesinlik, belirli bir kişiye ait olarak tahmin edilen örneklerin ne kadarının doğru olduğunu; duyarlılık ise gerçekten o kişiye ait olan örneklerin ne kadarının doğru tahmin edildiğini ifade eder. Çok sınıflı sınıflandırma problemlerinde, F1-skoru sınıf bazında hesaplanmakta ve ortalama alınmaktadır.

$$Precision = \frac{TP}{TP + FP}, Recall = \frac{TP}{TP + FN} \quad (2)$$

$$F1 = \frac{2 \times Precision \times Recall}{Precision + Recall} \quad (3)$$

Yanlış Kabul Oranı (FAR), modelin ilgili sınıf olarak sınıflandırdığı yanlış örneklerin (FP), farklı kişi olarak sınıflandırılan toplam örnek sayısına oranı olarak tanımlanır. Bu metrik, modelin genel hata yapma eğilimini yansıtmaktadır. Yanlış Red Oranı (FRR) ise modelin, ilgili kişiye ait veriyi sınıflandırmada başarısız olduğu durumların oranını belirtir. Başka bir ifadeyle, sistemin doğru sınıfa ait örnekleri reddetme eğilimidir. FAR ve FRR denklem 4 ile hesaplanır. Bu metriklerin bir arada kullanılması, algoritmalarının yalnızca genel doğruluk düzeyini değil, aynı zamanda yanlış sınıflandırma yapma eğilimini ve hataya karşı duyarlılığı da kapsamlı biçimde değerlendirmeye olanak sağlamaktadır.

$$FAR = \frac{FP}{FP + TN}, FRR = \frac{FN}{FN + TP} \quad (4)$$

Bu çalışmada öncelikli olarak SVM modelinin performansı incelenmiştir. Görüntülerin yüksek boyutlu ve yoğun korelasyon içeren yapısı nedeniyle sınıflandırma öncesinde anlamlı ve düşük boyutlu özneliklerin çıkarılması gereklidir. Bu amaçla, LBP ve HOG yöntemleri kullanılarak öznelik çıkarımı yapılmış (sırasıyla 65536 ve 20736 boyutlu öznelikler) ve elde edilen vektörler, sınıflandırma için SVM modeline girdi olarak verilmiştir. Öznelik boyutunu azaltmak amacıyla PCA kullanılmıştır ve boyut HOG öznelikleri için 100, LBP öznelikleri için 200'e düşürülmüştür. Farklı öznelik çıkarım yaklaşımlarının SVM performansına etkisi 0.8/0.2 test oranı kullanılarak test edilmiş ve Tablo 2'de sunulmuştur.


Tablo 2'de görüldüğü üzere, orijinal veri kullanılarak 100 kişi için yapılan testlerde (200 sınıflı - sağ ve sol iris) en yüksek performansa HOG+PCA ile ulaşılmıştır. PCA kullanılarak, sadece yüksek korelasyonlu verilerin sınıflandırmaya sokulması sağlanmış ve SVM-HOG modeline göre doğruluk (Acc) %6.5 oranında artırılmıştır. LBP kullanılması durumunda PCA ile performans benzer kalmış ve her iki durumda da HOG öznelik çıkarımına göre çok düşük başarımlarına ulaşılmıştır. Bu durum öznelik seçiminin

önemini ve LBP öznelilik çıkarım yaklaşımının bu veri seti için uygun olmadığını göstermektedir. Veri artırım tekniklerinin etkisini gözlemlemek amacıyla, orijinal veri setinde en yüksek performansa sahip $SVM_{HOG+PCA}$ yöntemi gauss filtre ile çoğaltılmış veri seti (OV+GB) ve gürültü eklenmiş veri seti (OV+GN) ile eğitilmiş ve testler yapılmıştır. Gerçek dünya problemlerini modelleyen bu filtreleme teknikleri ile doğruluğun orijinal veri setine kıyasla, OV+GB ile %21 oranında artırıldığı görülmektedir. OV+GN ile yapılan test incelendiğinde performansın orijinal veri seti ile yapılan test göre büyük oranda düştüğü raporlanmış, gürültü ekleme ile veri setinin sınıf için varyansının artması nedeni ile SVM ile uygun bir sınıflandırıcı yapılamadığı sonucuna varılmıştır. Son olarak sınıf sayısının etkisini incelemek amacıyla, 300 kişi (600 sınıflı - sağ ve sol iris) için testler yapılmış ve OV ve OV+GB veri setlerine doğruluk %73.25 ve %95.79 olarak raporlanmıştır. 100 kişi testleri ile benzer sonuçlar elde edilmesi SVM yönteminin kişi sayısının artmasına karşı gürbüz bir performans sergilediğini göstermektedir.

Tablo 2: SVM ile kimlik tanıma performans analizi. OV: Orijinal veri seti, GB: Gauss blur ile oluşturulmuş veri seti, GN: Gauss gürültüsü ile oluşturulmuş veri seti. "100" 200 sınıflı, "300" 600 sınıflı veriyi ifade eder. **Kalın** ve *italik* hücreler sırasıyla en iyi ve en iyi ikinci sonuçları göstermektedir

Yöntem	Veri seti	Acc (%)	F1 (%)	FRR (%)	FAR (%)
SVM_{LBP}	OV ₁₀₀	39.25	33.48	60.75	0.31
$SVM_{LBP+PCA}$	OV ₁₀₀	39.00	33.16	61.00	0.31
SVM_{HOG}	OV ₁₀₀	69.00	68.81	31.00	0.16
$SVM_{HOG+PCA}$	OV ₁₀₀	75.50	74.90	24.50	0.12
$SVM_{HOG+PCA}$	OV+GB ₁₀₀	96.50	96.33	3.50	<i>0.02</i>
$SVM_{HOG+PCA}$	OV+GN ₁₀₀	47.46	47.15	52.54	0.09
$SVM_{HOG+PCA}$	OV ₃₀₀	73.25	71.78	26.75	0.04
$SVM_{HOG+PCA}$	OV+GB ₃₀₀	95.79	95.58	4.21	0.01

Şekil 3'de SVM ile HOG-PCA öznelilik çıkarımı kullanılarak 100 kişi için OV+GB veri setinde yapılan teste ait ROC eğrisi görülmektedir. ROC eğrisi, modelin farklı sınıflandırma skoru eşik değerlerinde doğru pozitif oranı ile yanlış pozitif oranı arasındaki dengeyi göstererek sınıfları ayırt etme yeteneğini görselleştirmek için kullanılır. Eğrinin altta kalan alanı (Area Under Curve) ne kadar büyükse (maksimum 1) modelin ayırt ediciliği o kadar yüksektir. Verilen ROC eğrisi için AUC değeri 0.997 olarak hesaplanmıştır.




Şekil 3: $SVM_{HOG+PCA}$ ile OV+GB₁₀₀ veri setinde ROC eğrisi

Tablo 3'de VGG16 derin öğrenme mimarisi eğitilerek yapılan testler raporlanmaktadır. Tablo incelendiğinde orijinal veri seti ile 100 kişi(200 Sınıf, 2000 örnek) ve 300 kişi(600 sınıf, 6000 örnek) ile yapılan testlerde eğitim/test için 0.8/0.2 oranı kullanıldığında %91.00 başarımlı oranı görülmektedir. Aynı veri seti ile eğitim/test oranı 0.7/0.3 olarak alındığında doğruluğun yaklaşık %7.5 oranda düştüğü raporlanmaktadır. Bu durum eğitim veri setinin azalması nedeni ile, modelin sınıfları tam olarak öğrenemediğinin açık bir göstergesidir. Veri setindeki örnek sayısı Gauss Blur ve Gauss Gürültüsü yöntemleri ile artırılarak eğitim/test oranı 0.8/0.2 olarak alındığında performansın arttığı görülmektedir. Orijinal veri seti ve Gauss Blur Filtresi ile 100 kişi(200 Sınıf, 4000 örnek) ve 300 kişi(600 sınıf, 12000 örnek) için yapılan testlerde 100 kişi için %99.00, 300 kişi için %98.17 gibi yüksek başarımlı oranlarına ulaşılmıştır. Aynı zamanda %0.003 ve %0.005 gibi düşük FAR oranları ile güvenliği yüksek bir model oluşturulduğu da gözlenmektedir. %1 ve %1.833 FRR oranları ise sistemin kullanıcı dostu olduğunu ortaya koymaktadır. Bir başka veri artırma yöntemi olarak orijinal verilere eklenen gauss gürültüsü ile yine 100 kişi(400 Sınıf) ve 300 kişi(1200 sınıf) için testler tekrarlandığında Gauss Blur'daki sonuçlara çok yakın başarımlı oranlarına ulaşılmıştır. Bu durum veri artırmanın model başarımlı konusunda asıl etken olduğunu ortaya koymaktadır. Yapılan testlerde, tüm yaklaşımlarda sınıf sayısının artmasıyla birlikte performansta belirgin bir düşüş gözlenmemesi, önerilen yöntemlerin daha fazla sayıda kişi ayırt etme konusundaki performansını ortaya koymaktadır. F1 skorunun da doğruluk ile benzer sonuçlar vermesi, elde edilen başarımlı tüm sınıflar için orantılı olduğunun bir göstergesidir.

Tablo 3: VGG16 modeli ile kimlik tanıma performans analizi. OV: Orijinal veri seti, GB: Gauss Blur ile oluşturulmuş veri seti, GN: Gauss gürültüsü ile oluşturulmuş veri seti.

Train/Test	Veri seti	Acc (%)	F1 (%)	FAR (%)	FRR (%)
0.7/0.3	OV ₁₀₀	83.67	83.04	0.082	16.33
0.7/0.3	OV ₃₀₀	83.50	82.76	0.027	16.50
0.8/0.2	OV ₁₀₀	91.00	90.04	0.045	9.00
0.8/0.2	OV ₃₀₀	90.83	90.30	0.017	9.54
0.8/0.2	OV+GB ₁₀₀	99.00	98.93	0.005	1.00
0.8/0.2	OV+GB ₃₀₀	<i>98.17</i>	<i>98.03</i>	0.003	<i>1.83</i>
0.8/0.2	OV+GN ₁₀₀	98.12	98.00	0.009	1.88
0.8/0.2	OV+GN ₃₀₀	97.54	97.40	<i>0.004</i>	2.46

Şekil 4 farklı veri setlerinin eğitim boyunca test performansının değişimi gösterilmiştir. Orijinal veri seti kullanılarak yapılan testlerde (ilk şekil), düşük epochlarda eğitimin yeterli miktarda gerçekleşmediği ve 40. epochtan sonra yüksek doğruluklara ulaşıldığı gözlemlenmektedir. Artırılmış veri setlerinde ise (ikinci şekil) düşük epochlarda bile yüksek doğruluk değerlerine ulaşılmış ve 20. epochtan sonra performans iyileşmiştir. Bu durum, veri artırım yöntemlerinin modelin genelleme yeteneğini artırarak, sınıflar arasındaki ayırım kriterlerini daha erken öğrenebilmesini sağladığının göstergesidir.



Şekil 4: VGG16 derin öğrenme mimarisi için doğruluğun eğitim boyunca değişim grafikleri eğrisi. a) OV-300-0.2/0.8 ve OV-300-0.3/0.7 için eğitim/test oranındaki değişimin karşılaştırması, b) OV+GN-300-0.2/0.8 ve OV+GB-300-0.2/0.8 için Gauss Gürültü ve Gauss Blur veri artırım yöntemlerinin karşılaştırması.

Verinin eğitim ve test ayrımının model performansı üzerindeki etkisini değerlendirebilmek ve başarımın belirli bir veri dağılımına bağlı olup olmadığını analiz etmek amacıyla, eğitim-test ayrımı OV+GB₁₀₀ ve OV+GB₃₀₀ verisi için rastgele olarak üç kere tekrarlanmış ve her bir senaryo altında model ayrı ayrı eğitilip test edilmiştir. Tablo 4, 0.8/0.2 eğitim/test oranında farklı veri dağılımlarını ile eğitilen model performanslarının benzer eğilimler gösterdiğini ortaya koymaktadır. Bu durum, modelin tutarlı bir performans sergilediğini ve genelleme kabiliyetinin veri bölünmesine karşı duyarlı olmadığını göstermektedir.


Tablo 4: VGG16 modeli ile farklı eğitim/test dağılımları ile gerçekleştirilen sınıflandırma performansları. 1. tekrar orijinal performans sonuçlarını göstermektedir.

Veri Seti	Tekrar No	Acc (%)	F1 (%)	FAR (%)	FRR (%)
OV+GB ₁₀₀	1	99.00	98.93	0.005	1.00
	2	98.00	97.88	0.010	2.00
	3	99.75	99.73	0.001	0.25
OV+GB ₃₀₀	1	98.17	98.03	0.003	1.83
	2	99.58	99.58	0.001	0.42
	3	97.38	97.23	0.004	0.63

Sonuçlar, modelin genel olarak yüksek bir sınıflandırma performansı sergilediğini göstermektedir. Bu performansın daha iyi anlaşılabilmesi ve görsel olarak yorumlanabilmesi amacıyla, doğru ve yanlış sınıflandırılmış örnekler ait iris görüntüleri sunulmuştur. Şekil 5a'da yer alan örnekler, model tarafından doğru sınıflandırılan iris görüntülerini göstermekte olup, model bu örneklerde sınıfa özgü öznelikleri başarıyla ayırt etmiştir. Şekil 5b'de verilen örnekler ise yanlış sınıflandırılmış olup, bu görüntüler gerçek sınıfları yerine (ID63 ve ID65) sırasıyla ID93 ve ID36 olarak sınıflandırılmıştır. Bu durum benzer öznelilik dağılımlarının model kararını etkileyebildiğini göstermektedir.

Kullanılan yöntemlerin etkinliğini gözlemlemek amacıyla, aynı veri setini kullanan benzer çalışmalar analiz edilmiştir. Maciej ve Piotr [13], Dougman [14] algoritması ile iris lokalizasyonunu çıkarmış ve bu görüntü üzerinden PCA ile elde edilen özellikleri kullanarak önerilen derin öğrenme sınıflandırıcısı ile %94.1 başarımlar raporumuşlardır. Farzaneh ve Roozbeh [13]'de önerilen CapsuleNet derin öğrenme mimarisi ile %96.3, VGG16 ile yapılan testlerde %95.63 başarımlarına ulaşılmıştır. Casia veri setinin kullanıldığı

bir başka çalışma olan [16]'de literatürdeki diğer çalışmalara benzer olarak Dougman [14] algoritması ile iris lokalizasyonunu sonrasında PCA ile özellikler çıkartılmıştır. Bu özellikler CNN tabanlı hibrit bir derin öğrenme mimarisi olan GSA-CNN kullanılarak sınıflandırılmış %95 başarımlar raporumuştur. Geçmiş çalışmalar ile karşılaştırıldığında önerilen veri artırım metotları olan gauss blur ve gauss gürültü ile elde edilen verilerle VGG16 derin öğrenme mimarisi ile yapılan sınıflandırma sonuçlarının belirgin iyileştirmeye sahip olduğu görülmektedir. Ayrıca düşük FAR oranları kullanılan derin öğrenme mimarisinin yüksek güvenlik seviyesine sahip olduğunu göstermektedir.



Şekil 5: VGG16 derin öğrenme mimarisi doğru ve yanlış sınıflamış veri örnekleri a) 65 nolu sol göz(065L) verisi yanlış sınıflandırılarak 36nolu sol göz(036L) veri sınıfında atanmış, b) 36 nolu sol göz(036L) verisine ait doğru sınıflanmış veriler.

IV.SONUÇ

Yapılan analizler sonucunda, iris tabanlı biyometrik tanıma sistemlerinde uygulanan ön işleme ve öznelilik çıkarım tekniklerinin sınıflandırma performansı üzerinde önemli etkileri olduğu gözlemlenmiştir. SVM sınıflandırıcısı ile LBP ve HOG tabanlı öznelilik çıkarımı sonrası elde edilen sonuçlarda, özellikle HOG+PCA yaklaşımı %96.5 doğruluk ve %3.5 FRR ile en yüksek başarıyı sağlamıştır. Derin öğrenme tabanlı VGG16 modeli ise, özellikle gauss filtre ile veri artırımı sonrası %99 doğruluk ve %1 FRR gibi yüksek başarı oranları ile en başarılı performansa ulaşmıştır. FAR oranında düşüklük sistemin aynı zamanda yüksek güvenlik seviyesini göstermektedir. Klasik öznelilik çıkarımı ile çalışan SVM modelleri ile yüksek doğruluklara ulaşılmış olsa da öznelilik çıkarım yöntemlerine bağlı olarak performansın yüksek oranlarda değiştiği gözlemlenmiştir. Bu durum kullanılan veriye uygun yaklaşımın belirlenmesinin zorunluluğunu açıkça göstermektedir. VGG16 derin öğrenme modelinde ise daha yüksek doğruluk ve daha düşük hata oranları elde edilmiş, bunun yanı sıra orijinal veri setinde bile kabul edilebilir sonuçlara ulaşıldığı gözlemlenmiştir. Sonuç olarak derin öğrenme yaklaşımlarının biyometrik güvenlik sistemleri için uygunluğu gösterilmiştir. İlerleyen çalışmalarda, geliştirilen mimarilerin uygun donanımlara entegre edilmesi ile gerçek dünya uygulamalarına uyarlanması mümkündür. Bu doğrultuda, düşük maliyet ve

yüksek performans kriterlerini karşılayacak şekilde, hız ve verimlilik odaklı optimizasyon çalışmaları yapılabilir.

TEŞEKKÜR

Çalışmaya katkılarından dolayı Doç. Dr. Nihan Kahraman'a teşekkür ederim.

Araştırma ve Yayın Etiği Beyanı

Yazar bu çalışmanın Araştırma ve Yayın Etiğine uygun olduğunu beyan etmektedir.

Modelin Erişilebilirlik Durumu

Çalışma kapsamında oluşturulan model dosyaları ve kodlar şu adreste mevcuttur: <https://github.com/sgolcuk/IRIS-Classification-With-VGG16>

KAYNAKÇA

- [1] Vivek kumar, K Nageshwara Rao. "Analysis of Biometric Authentication Techniques: A Review". Volume. 9 Issue.3, March – 2024 International Journal of Innovative Science and Research Technology (IJISRT), www.ijisrt.com. ISSN - 2456-2165, PP :1736-1746, doi:10.38124/ijisrt/IJISRT24MAR886
- [2] R. A. Hamaamin, "Biometric Systems: A Comprehensive Review," BASRA JOURNAL OF SCIENCE, vol. 42, no. 1, Jun. 2024, doi: 10.29072/basjs.20240110.
- [3] C. Raghavendra, A. Kumaravel and S. Sivasubramanian, "Iris technology: A review on iris based biometric systems for unique human identification," 2017 International Conference on Algorithms, Methodology, Models and Applications in Emerging Technologies (ICAMMAET), Chennai, India, 2017, pp. 1-6, doi: 10.1109/ICAMMAET.2017.8186679.
- [4] Suwardi, Y.N., Emami, M.S. (2024). "An Effective Iris Identification Software System for Hospitals' Emergency Unit". 2024 IEEE 12th Conference on Systems, Process and Control (ICSPC), 53-58.
- [5] R. Harrabi, "A Combined Support Vector Machine and Statistical Method for Iris Recognition," 2025 4th International Conference on Computing and Information Technology (ICIT), Tabuk, Saudi Arabia, 2025, pp. 738-745, doi: 10.1109/ICIT63348.2025.10989426.
- [6] O. M. Mosli, "New full iris recognition system and iris segmentation technique using image processing and deep convolutional neural network," vol. 6, pp. 20–27, 3 2020.
- [7] S. Minaee and A. Abdolrashidi, "Deepiris: Iris recognition using a deep learning approach," arXiv preprint arXiv:1907.09380, 2019.
- [8] K. Simonyan, A. Zisserman, "Very deep convolutional networks for large-scale image recognition," in 3rd International Conference on Learning Representations, 2015, pp. 1–14.
- [9] M. Turk and A. Pentland. Eigenfaces for recognition. J Cogn Neurosci, vol. 3, no. 1, pp. 71–86, 1991.
- [10] T. Ojala, M. Pietikäinen, and D. Harwood (1994), "Performance evaluation of texture measures with classification based on Kullback discrimination of distributions", Proceedings of the 12th IAPR International Conference on Pattern Recognition (ICPR 1994), vol. 1, pp. 582 - 585.
- [11] N. Dalal and B. Triggs, "Histograms of oriented gradients for human detection," 2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'05), San Diego, CA, USA, 2005, pp. 886-893 vol. 1, doi: 10.1109/CVPR.2005.177.
- [12] Institute of Automation, Chinese Academy of Sciences, "CASIA-Iris-Thousand," [Online]. Available: <http://www.cbsr.ia.ac.cn/english/IrisDatabase.asp>. [Accessed: Jun. 8, 2025].
- [13] Szymkowski, M., Jasinski, P. and Saeed, K. "Iris-based human identity recognition with machine learning methods and discrete fast Fourier transform". Innovations Syst Softw Eng 17, 309–317 (2021). doi:10.1007/s11334-021-00392-9
- [14] Daugman J (2004) How iris recognition works. IEEE Trans Circuits Syst Video Technol 14(1):21–30.
- [15] Kuhifayegh, F. and Rajabi, R. (2024). "Iris Recognition via Deep Learning Using Capsule Networks with Enhanced Routing Algorithm". Sustainable Energy and Artificial Intelligence, 1(2), 91-99. doi: 10.61186/seai.2410-1012
- [16] Adegboye Olujoba James and Awodoye Olufemi Olayanju. "An Iris Recognition System Using Enhanced Convolution Neural Network". Acta Scientific Computer Sciences 4.10 (2022): 24-29.