

Araştırma Makalesi - Research Article

Makine Öğrenimi Yaklaşımları Kullanarak El Hareketi Tabanlı Biyometrik Kimlik Doğrulama

Hand Gesture Based Biometric Authentication Using Machine Learning Approaches

Zekeriya Katılmış^{1*}

Geliş / Received: 24/09/2024

Revize / Revised: 17/10/2024

Kabul / Accepted: 18/10/2024

ÖZ

Kimlik doğrulama, modern teknoloji alanında önemli bir görev haline gelmektedir. Bu, bir cihazın bir sistem varlığıyla etkileşimde bulunan bir kullanıcıyı tanıdığını onaylamasına olanak tanıyan bir süreçtir. Bu çalışmada, Leap Motion (LM) cihazı kullanılarak tek elle gerçekleştirilen hareket bazlı kullanıcı kimlik doğrulama üzerine çalışılmıştır. Çalışma el hareketi takip, görüntü karelerinin elde edilmesi, ön işleme, öznelik çıkarımı ve seçimi, boyut indirgeme, sınıflandırma ve doğrulama adımlarından oluşmaktadır. El biyometrisinin benzerlik ve farklılıkları dikkate alınarak hazırlanan 85 özellik belirlenerek 40 kullanıcı tarafından veri kümesi oluşturulmuştur. Bu veri kümesine Pearson Korelasyon Katsayısı (PCC) özellik seçim algoritması ile Doğrusal Ayırım Analizi (LDA) ve Temel Bileşenler Analizi (PCA) boyut indirgeme yöntemleri uygulanarak karşılaştırma analizleri yapılmıştır. Doğrulama başarımı farklı makine öğrenimi algoritma yöntemleri ile test edilmiştir. Önerilen bu sistemin geçerliliği ve elde edilen sonuçların doğruluğunu test etmek için 5 katlamalı çapraz doğrulama yöntemi kullanılmıştır. Biyometrik kimlik doğrulama, en iyi sonuç %96,50 oranı ile çekirdek tabanlı aşırı öğrenme makinesi (K-ELM) yaklaşımı ile elde edilmiştir. Tüm aşamalarda uygulamalara bakıldığında, K-ELM sınıflandırıcının başarımlarını koruduğunu ve en yüksek başarımların verildiği gözlemlenmiştir. Aynı zamanda K-ELM sınıflandırıcının kararlı bir yapıda olduğu görülmüştür.

Anahtar Kelimeler- Biyometrik, Kimlik Doğrulama, El Hareketi, Makine Öğrenimi, Özellik Çıkarımı

ABSTRACT

Authentication is becoming an important task in the field of modern technology. It is a process that allows a device to confirm that it recognizes a user interacting with a system entity. In this study, a single-handed gesture-based user authentication using the Leap Motion (LM) device has been investigated. The study consists of hand gesture tracking, acquisition of image frames, preprocessing, feature extraction and selection, dimension reduction, classification, and validation steps. A dataset was collected by 40 users by determining 85 features prepared by considering the similarities and differences of hand biometrics. Comparison analyses were performed by applying the Pearson Correlation Coefficient (PCC) feature selection algorithm and Linear Discriminant Analysis (LDA) and Principal Component Analysis (PCA) dimensionality reduction methods to this dataset. The verification performance was tested with different machine learning algorithm methods. A 5-fold cross-validation method was used to test the validity of this proposed system and the accuracy of the obtained results. In biometric authentication, the best result was obtained with the kernel-based extreme learning machine (K-ELM) approach

^{1*}Sorumlu yazar iletişim: zekeriya.katilmis@ksbu.edu.tr (<https://orcid.org/0000-0002-2095-5483>)

Bilgisayar Mühendisliği Bölümü, Kütahya Sağlık Bilimleri Üniversitesi, Kütahya, Türkiye

with a rate of 96.50%. When the applications were examined in all stages, it was observed that the K-ELM classifier maintained its performance rates and gave the highest performance rate. At the same time, it was seen that the K-ELM classifier has a stable structure.

Keywords- Biometrics, Authentication, Hand Gesture, Machine Learning, Feature Extraction

I. GİRİŞ

Teknolojinin ilerlemesiyle birlikte, bilgisayar da dahil olmak üzere dijital cihazların kullanımı büyük ölçüde artmıştır. Bu artış nedeniyle, önemli bilgi ve belgelerin büyük bir kısmı bilgisayarda saklanmaktadır. Sonuç olarak, bilgisayar güvenliği ve kimlik doğrulama artık çok önemlidir. Güvenlik veya kişiselleştirme amacıyla kullanıcı kimlik doğrulamasını geliştirmeye artan bir ihtiyaç vardır. Çeşitli güvenlik türleri bulunmaktadır; bunlar arasında bilgiye dayalı, biyometrik temelli güvenlik sistemleri yer almaktadır.

Son zamanlarda giderek artan bir şekilde karşılaştığımız biyometrik sistemler, sunduğu avantajlar ve kullanım alanlarıyla ön plana çıkmaktadır. Biyometrik sistemler, bireylerin fiziksel ve davranışsal özelliklerini tanımlayarak kimliklendirme yapan sistemlerdir. En yaygın kullanılanları ise parmak izi [1], el geometrisi [2], ses [3], retina [4], yüz [5], imza [6] vb. biyometrik sistemlerdir. Bu sistemler günümüzde hava alanları, bankalar ve sağlık sektörü gibi kritik alanlarda, giriş çıkış işlemleri ve kimlik doğrulama gibi süreçlerde kullanılmaktadır. Her bir sistemin kendi içerisinde avantajları ve dezavantajları bulunmaktadır. Günümüzde bu teknolojiler sayesinde güçlü parolalara ve uzun şifrelere ihtiyaç gittikçe azalmaktadır. Biyometrik güvenlik sistemlerinde kişilerin kimlik ispatı için taşımak zorunda oldukları kart, anahtar ya da şifre gibi araçların yerine, bireyin unutulması, kaybetmesi, kopyalanması daha zor olan fiziksel ya da davranışsal özelliklerine dayalı bir analiz sistemi sunulmaktadır.

Dokunmatik olmayan insan-bilgisayar etkileşimine ve gelişmiş kullanıcı kimlik doğrulamasına artan bir ilgi vardır. El duruşu ve hareketi temelli temassız etkileşimlerin daha yaygın olarak kullanılacağını ve bu tür etkileşimlerde yeniden kimlik doğrulamanın giderek daha fazla talep edileceği düşünülmektedir. LM cihazı, ellerin, parmakların ve eklemlerin 3D hareketlerini temassız olarak tanıyabilen bir cihazdır. LM cihazının benzer sensör ve kameralara kıyasla daha uygun fiyatlı, hafif ve taşınabilir olması ile günümüzdeki çeşitli teknolojik cihazlara kolayca entegre edilebilmesi, bu çalışmada tercih edilmesinin nedenidir. Literatürde LM tabanlı kullanıcı kimlik doğrulama çalışması az sayıda bulunmaktadır. Bu çalışmada, dijital bir sensör sistemine dayanan LM sensörü kullanılarak sağ elle gerçekleştirilen biyometrik kullanıcı kimlik doğrulama üzerine çalışılmıştır.


Çalışmanın amacı, kullanıcıları ellerinin iskelet duruşlarındaki bireysel özelliklere dayanarak tanımlamak ve doğrulamaktır. El ve parmakları doğru bir şekilde tanımak ve birden fazla ölçümde kullanıcılar arası değişkenliği azaltmak için, kullanıcıların sağ ellerini LM cihazının üzerinde, avuç içi aşağı bakacak ve parmaklar birbirine bitişik şekilde düz uzatılmış olarak tutmaları istenmiştir. Kullanıcı kimlik doğrulama yöntemi, her kullanıcının el pozisyonunu aldığı sırada parmaklarının ve eklemlerinin göreceli konumsal ilişkisine dayanmaktadır.

Bu çalışma için oluşturulan veri kümesi ilk olarak PCC özellik seçimi yöntemi uygulanarak özellik sayısı oransal ve kademeli olarak düşürülmüştür. İkinci aşamada ise boyut indirgeme yöntemleri kullanılarak boyut küçültülmüştür. Makine öğrenimi yöntemleri kullanılarak orijinal veri kümesi ile özellik seçimi ve boyutu indirgenmiş veri kümelerinin sınıflandırma başarımları karşılaştırılmıştır. Önerilen bu sistemin geçerliliği ve elde edilen sonuçların doğruluğunu test etmek için 5 katlamalı çapraz doğrulama yöntemi kullanılmıştır. Ayrıca yeni bir sağ el tabanlı biyometrik kullanıcı kimlik doğrulama veri kümesi ile topluluğa katkıda bulunulmuştur. Bu çalışma ile elde edilen özgün veri kümesi <https://sites.google.com/view/trdataset/> linkinden elde edilebilir.

Makine öğrenimi yöntemlerinden ELM sınıflandırıcılar hızlı eğitim, yüksek performans, genelleme yeteneği gibi avantajlı yönleri ile öne çıkmaktadır. ELM algoritması, diğer sınıflandırma algoritmalarına kıyasla daha hızlı öğrenme süresi sunar ve yüksek bir doğruluk düzeyi sağlamaktadır. ELM, katmanlı sinir ağları gibi yapılara benzer ancak, ağırlık ve eşik parametrelerinde rastgele seçilen değerler kullanılır ve değiştirilmez. Bu durum başarımların doğruluğunda dalgalanmalara yol açmaktadır. Bunun yerine K-ELM algoritmasında çekirdek fonksiyonu kullanılmıştır. Kernel-ELM'de, önce giriş verileri, bir çekirdek fonksiyonu ile dönüştürülür, yüksek boyutlu bir uzaya aktarılır. Bu dönüşüm, doğrusal olmayan ilişkileri yakalamaya yardımcı olur. Kernel-ELM, yüksek boyutlu verilerde etkili sonuçlar verir. Bu süreç, verinin karmaşıklığını daha iyi yakalayarak, kararlı bir yapı sunar ve modelin performansını artırır. Bu sebeple çalışmada K-ELM algoritması tercih edilmiştir. Temel ELM ve diğer farklı türlerden seçilen algoritmalar kullanılarak çalışma süresi ve performans karşılaştırmaları sunulmuştur.

PCC özellik seçimi yöntemi büyük veri kümeleri üzerinde hızlı bir şekilde çalışması ve özellik seçimi sürecinde güçlü bir teknik olmasından dolayı tercih edilmiştir. PCA ve LDA, veri analizi ve makine öğrenimi alanında en önemli boyut indirgeme yöntemlerindendir. Her ikisi de yüksek boyutlu verileri daha yönetilebilir bir

forma indirgeyebilmekle birlikte, veri analiz ve modelleme süreçlerini kolaylaştırır. PCA, fazla boyutlu verilerdeki genel özellikleri bularak boyut sayısının azaltılmasını, verinin sıkıştırılmasını sağlamaktadır. Bu yöntem, yüksek korelasyonlu değişkenleri bir araya getirerek verilerdeki en çok varyasyonu oluşturarak daha az sayıda yapay değişken kümesi oluşturur. PCA verideki gerekli bilgileri ortaya çıkarmada etkili bir yöntemdir. LDA ise sınıflar arasındaki ayrımı en iyi şekilde maksimize etmeye çalışır. Bu, daha iyi sınıflandırma sonuçları elde edilmesine daha etkin rol oynamaktadır. Aynı zamanda yüksek boyutlu verilerde, LDA boyut indirgeme gereksiz özelliklerin etkisini azaltarak modelin performansını arttırmaktadır. PCA, genel bir boyut indirgeme yöntemi iken, LDA, sınıflandırma ve ayırt etme üzerinde yoğunlaşan bir tekniktir. LDA, sınıflandırma problemlerinde daha yaygın olarak kullanılır. Özellikle etiketli verilerle çalışır. Çalışmada LDA boyut indirgeme yöntemi tercih edilmiş ve PCA ile karşılaştırma imkanı sunulmuştur.



Şekil 1. Kullanıcı kimlik doğrulama için kullanılan öbek yapı

Önerilen doğrulama modelin genel öbek yapısı, Şekil 1'de gösterildiği gibi 3 aşama ve 10 adımdan oluşmaktadır. LM aşaması hareket, izleme ve görüntü karelerinin toplanması adımlarından oluşmaktadır. Veri kümesi aşaması önilem, öznelilik çıkarımı ve seçimi ve boyut indirgeme adımlarından oluşmaktadır. Uygulama aşaması ise sınıflandırma, biyometrik kimlik doğrulama ve kabul, ret aşamalarından oluşmaktadır. İlk adım, el hareketinin yapılması ve LM hizmetinin başlatan adımdır. İkinci adım, izleme adımdır, bu adımda izleme katmanı, el ve parmak hareket izleme bilgilerini çıkararak verileri eşleştirir. Üçüncü adım, LM uygulama programlama arabirimi özelliklerini kullanarak eşleştirilen verilerden görüntü karelerinin toplanır. Dördüncü adım LM sensöründen toplanan verilerinden alınan özellikler çıkarılarak veri kümesi oluşturulur. Beşinci adımda, bu özelliklerden özellik seçim algoritması uygulanarak özellik seçimi yapılır. Altıncı adımda ise seçim yapılan özelliklerin indirgeme yöntemiyle boyutları orantısız kademeli azaltılır. Yedinci adım ise kimlik doğrulama için sınıflandırma eğitimin yapıldığı aşamadır. Son adımda eğitilmiş sınıflandırıcı bireylerin kimliğinin doğrulanması gerçekleştirilir. Bu çalışmanın literatüre katkıları aşağıdaki şekilde özetlenebilir:

- Biyometrik kimlik doğrulamada K-ELM ağ yapısı ve öğreniminin kullanıldığı ilk uygulama olması
- Biyometrik kimlik doğrulama için LM tabanlı bir veri kümesinin kullanıma sunulması
- Biyometrik kimlik doğrulama da PCC özellik seçimi, PCA ve LDA boyut indirgeme yöntemlerinin kullanılması
- İki aşamalı özellik seçme ve küçültme yaklaşımlarının bütünleştirilmesiyle oluşturulan farklı veri kümeleri ile doğrulama başarımları analizi sunulması
- El hareketlerinin kullanıcılar tarafından farklı sürede yapılmasının doğrulama başarımlarına etkisinin sunulması
- Özellik seçme ve boyut azaltma yöntemleri aşamasında orantılı ve kademeli olarak özellikler azaltılarak en iyi ve uygun özellik sayısı ile doğrulama başarımları analizi sunulması.

II. LİTERATÜR ÇALIŞMALARI

Literatürde biyometrik kullanıcı kimlik doğrulama üzerine birçok çalışma mevcuttur. LM tabanlı biyometrik kullanıcı kimlik doğrulama üzerine çok az çalışmaya rastlanmıştır. Bu çalışmalardan bu çalışmanın konusu ve kapsamı bağlamında LM tabanlı çalışmalar incelenmiş ve aşağıda özetlenmiştir.

Wong ve arkadaşları [7] da LM tabanlı bir sensör kullanarak biyometrik bir kimlik doğrulama yaklaşımı geliştirmişlerdir. Kollar, bilekler, ellerle birlikte kollar ve parmaklar gibi sabit el hareketlerini kullanmışlardır. Önerdikleri kimlik doğrulama sisteminin ortalama %0,10'luk bir eşit hata oranı ve %90'lık bir doğruluk elde ettiğini göstermişlerdir. Imura ve arkadaşları [8] LM aracılığıyla bir el hareketi tabanlı biyometrik kimlik doğrulama yöntemi sunmuştur. Biyometrik veriler kullanılarak, üç kategoriye ayrılmış yedi 3D hareket önermiştir.

Her katılımcı 75 özellik içeren 7 el hareketinin her birini 10 kez gerçekleştirmiş ve 630 örnek elde edilmiştir. Deney dokuz katılımcı ile gerçekleştirilmiş ve %90'ın üzerinde bir doğru kabul oranı (TAR) elde etmişlerdir. Eşit hata oranı (EER) yaklaşık %4 olarak ölçülmüştür. DP doğru pozitif sayısı, DN doğru negatif sayısı, YP yanlış pozitif sayısı ve YN yanlış negatif sayısıdır. EER metrik hesaplaması, yanlış kabul oranı (FAR) ve yanlış ret oranı (FRR) metriklerinin ortalaması ile bulunur. TAR, FAR, FRR ve EER metrik eşitlikleri sırasıyla (1)(2)(3)(4)'de sunulmuştur.

$$\text{TAR (True Accept Rate)} = DP / (DP + YN) \quad (1)$$

$$\text{FAR (False Acceptance Rate)} = YP / (YP + DN) \quad (2)$$

$$\text{FRR (False Rejection Rate)} = YN / (YN + DP) \quad (3)$$

$$\text{EER (Equal Error Rate)} = (FAR + FRR) / 2 \quad (4)$$

Ayrıca, Maruyama ve arkadaşları [9] LM sensörüyle parmak eklemlerinin konumlarını kullanarak kullanıcı kimlik doğrulama tanıtmışlardır. Kullanıcı kimlik doğrulama yöntemimiz temel olarak, her kullanıcı el duruşunu aldığı parmaklarının eklemlerinin göreceli konumsal ilişkisine dayanmaktadır. Bu çalışmada, aynı ve farklı parmaklar arası eklemleri arasındaki ilişki özellik setleri karşılaştırılarak kullanıcı analiz edilmiş ve doğrulanmıştır. Deneye yaklaşık yirmi katılımcı katılmış ve her kullanıcı için el 30 kez ölçülmüştür. Sonuçlar, parmak içi eklemler arasındaki ayrımlara dayalı %84,65'lik bir tanımlama oranı göstermiştir.

Elin geometrik özelliklerini kaydetmeye yönelik LM tabanlı bir kullanıcı kimlik doğrulama sistemi [10] çalışmasında sunulmuştur. Veri kümesi 21 kişiden toplanmıştır. Her kullanıcı için parmakların uzunluğu ve genişliği, parmaklar arasındaki mesafe, elin ve bileğin merkezi kaydedilmiştir. LM kullanarak el anlık görüntülerinden oluşan bir veri kümesi toplanmıştır. Her kullanıcı için çift elli 40 anlık görüntüsü için 52 el özelliği toplanmıştır. k-NN, SVM, çok katmanlı algılayıcı (MLP) ve lojistik regresyon gibi sınıflandırıcılar kullanılmıştır. Sınıflandırma %90 üzeri bir başarı sağlamıştır. Bu çalışmalar yanı sıra, Manabe ve arkadaşları [11] sayısal tuş takımı ve elin biyometrik kimlik doğrulamasını birleştiren iki faktörlü bir kullanıcı kimlik doğrulama sistemi önermiştir. El geometrisi ve el hareketi verileri LM cihazı tarafından ölçülmüştür. Ardından, kullanıcı kimlik doğrulaması için kullanılan ham özelliklerden 40 özellik çıkarmışlardır. Daha sonra, kullanıcıların gerçek olup olmadıklarını için rastgele orman (RF) tabanlı bir sınıflandırıcı uygulanmıştır. Aynı zamanda, önerdikleri kimlik doğrulama sistemi 21 katılımcı kullanıcı tarafından değerlendirilmiş ve %94,98'lik bir kimlik doğrulama doğruluğu elde edilmiştir. Bunların dışında, hava el yazısı [12-14], daire çizme [15], imza çizme [16,17], alfabe dizeleri [18] gibi farklı el hareketleri kullanılarak kullanıcı veya kişi tanımlama üzerine farklı çalışmalarda yapılmıştır. Örneğin, Saritha ve diğerleri [15] daire çizme, kaydırma, ekrana dokunma ve tuşa dokunma tabanlı hareketlere dayanan LM tabanlı bir kimlik doğrulama sistemi önermiştir. Bu çalışmalara benzer farklı cihazlar, sensörler kullanılarak yapılan çalışmalarda mevcuttur. Shin ve arkadaşları [19] ivme, jiroskop ve EMG sensörlerine dayalı bir kullanıcı kimlik doğrulama yaklaşımı geliştirmiştir. 20 denekten 400 örnek toplamışlardır. Her bir denek 20 kez hareket gerçekleştirmiş ve ardından çok sınıflı bir SVM'yi eğiterek %98,70'lik bir kimlik doğrulama oranı elde etmişlerdir. Wu ve arkadaşları [20], Lai ve arkadaşlarının [21] yaklaşımını, beden silüeti yerine Kinect iskelet modelini benimseyerek genişletmiş ve yöntemi yalnızca kimlik tespiti yerine kullanıcı kimlik doğrulaması yapmak üzere geliştirmiştir. Dinamik zaman eğriltme (DTW) algoritması, hareketlerin karşılaştırmak için kullanılmıştır.

III. LEAP MOTION SENSÖRÜ

LM, el hareketleriyle yazılımlarla etkileşim sağlamaya olanak tanıyan, Şekil 2'de gösterilen bir cihazdır. Bu sensör, derinlik bilgisine sahip el görüntüsünü elde etmek için bir çift kamera ve kızılötesi LED'ler kullanmaktadır. LM, üç boyutlu uzayda gerçekleşen el ve parmak hareketlerini çok hassasiyetle, 290 fps gibi yüksek bir hızla algılayıp kaydedebilmektedir. LM saniyede 200 kareye kadar hareketleri yaklaşık 25 ile 600 mm arasında 150 derecelik etkin görüş alanı içerisinde izleyebilir [22]. Tespit edilen değerler milimetre cinsinden değerlerdir. LM uygulama programlama arayüzü (API), hareket izleme verilerine ait görüntü karesi (frame) adı verilen bir dizi anlık fotoğraf sunar. Bu cihaz görüş alanındaki el, parmak ve benzer nesneleri tarayarak sürekli olarak bir veri dizisi ve görüntü kareleri sağlar. Bu sensör, görüş alanına giren el, parmak hareketlerini tarayarak anlık bir veri dizisi ve görüntü kareleri üretir. Her bir görüntü karesi el, parmak ve nesne gibi temel tarama bilgilerini ve o anda tanınan hareket ve durum bilgilerini içerir. Tespit edilen bir el ve parmak hareketleri için cihaz benzersiz bir ID değeri üretir. Üretilen ID değeri tespit edilen hareketin sensörün görüş alanında kaldığı sürece korunur. LM işaret dili tanıma (SLR) [23,24], bilgisayar etkileşimi [25,26], robot kontrolü [27,28], tıbbi teşhis [29] ve rehabilitasyon [30,31] gibi araştırma alanlarında yaygın olarak kullanılmaktadır.



Şekil 2. LM cihazı ve uygulama programlama arayüzü [22]


IV. VERİ KÜMESİ

Bu çalışmada, sağ el ile yapılan hareketlerin kaydedilmesi amacıyla farklı yaş gruplarından 20 yetişkin erkek ve 20 yetişkin kadından oluşan toplam 40 denekle veri toplanmış ve özellik çıkarımları gerçekleştirilmiştir. Bu bağlamda el, parmak, eklem ve eklem noktalarının her biri için uzunluk, mesafe, genişlik ve açı olmak üzere 4 farklı türden oluşan ayırt edici 85 özellik belirlenmiştir. Bu özellikler arasında, sadece el ve parmak boyutlarıyla sınırlı kalmayıp el hareketinin tanınmasında belirleyici olacağı düşünülen açı bilgisi de bulunmaktadır. Her bir el hareketi için tek çerçevede (frame) 10 tekrar örnek barındıran 40 denekten toplam 400 kayıt içeren bir veri kümesi oluşturulmuştur. Veri kümesi, her bir el hareketi için farklı sürelerde alınan görüntü karelerinin birleşiminden oluşmuştur. Görüntü kareleri her 30 salisede bir alınmıştır. LM cihazı tarafından elin açık pozisyon duruşu sağlandıktan sonra kayıt başlatılmıştır. Kayıtlar bir ile dört saniye arası değişen süreler içinde alınmıştır. Denekler sağ eli kullanarak LM üstünde Şekil 3'te gösterildiği üzere el cihaza paralel duracak şekilde ve parmaklar bitişik bir konumda göstererek kayıtlar oluşturulmuştur. LM cihazının bağlantısı bilgisayar üzerinde yer alan USB 3.0 portu ile gerçekleştirilmiştir. Her bir deneğin her bir el hareketi için oluşturduğu kayıt ayrı bir dosya olarak kaydedilmiştir. Bir kullanıcıya ait el hareketi yakalama görüntüsü Şekil 3'de sunulmuştur.



Şekil 3. LM ile el geometrisini yakalama görseli.

Veri kümesinin oluşturulması amacıyla LM cihazı kullanılarak C# dilinde bir veri toplama sistemi tasarlanmıştır. Hareketlerin denekler tarafından yapılması sürecinde aydınlatma koşulları değiştirilmeden gün ışığı aydınlatması ve doğal ortamlar kullanılmıştır. Geliştirilen sistemle oluşturulan raw uzantılı veri kümesinin dönüştürme, normalizasyon, özellik seçimi, boyut indirgeme ve sınıflandırma süreçleri Matlab ile gerçekleştirilmiştir.




Şekil 4. El bileği ve kemikleri [32,33]

El anatomisi tarak (metakarp) kemikleri, parmak (falanks) kemikleri ve eklemlerden (joint) oluşur. Her parmak için 1 tane olmak üzere 5 adet tarak kemiği bulunur. Avuç içi bitişinden itibaren parmak eklemleri başlar. Bunlar falanks kemikleri olarak bilinir. Falankslar konumlarına göre isimlendirilir. Yerleşimlerine göre proksimal falanks (parmak kökünde, yakın), orta falanks ve distal falanks (parmak uç kemikleri) olarak 3 tanedir. Parmak eklemleri ise içeriden dışarıya doğru metakarpal falanks eklem (MCP), proksimal iç falanks eklem (PIP) ve distal iç falanks eklem (DIP) olarak 3 tanedir. Parmak kemikleri 14 tane falanks kemiği ve 14 tane eklemden oluşmaktadır [32,33]. El bileği ve kemiklerin anatomisi Şekil 4’de sunulmuştur.

El tabanlı biyometrik kullanıcı kimlik doğrulama için uygun özellik çıkarımları el anatomisine bağlı yapılmıştır. Özellikler sağ elin biyometrik yapılış durumu ve gereksinim görülen noktalar dikkate alınarak belirlenmiştir. Özellik setinde 2 farklı grup mesafe bilgisi kullanılmıştır. Birinci grupta parmak içi ve parmaklar arası mesafe bilgisi alınmıştır. Öncelikle parmak ucu (TipPosition) pozisyon noktaları arası mesafe bilgisine başvurulur. Benzer özellik grubu olarak 3 parmak eklem (DIP, PIP, MCP) (JointPosition) pozisyon noktaları arası mesafe bilgisi ve bunlar ile parmak ucu (TipPosition) ve avuç içi (PalmPosition) pozisyon noktaları arası mesafe bilgisine başvurulur. Söz konusu bu noktalar arasında toplam 39 özellik belirlenmiştir. İkinci grupta ise tarak ve bilek kemikleri arası mesafe bilgisi alınmıştır. Elin avuç içi noktası ve bilek (Arm) noktası arası mesafe bilgisine başvurulur. Bunlara ek olarak elin metakarpal falanks eklem (MCP) noktaları ile dirsek pozisyon (ElbowPosition), bilek pozisyon (WristPosition) ve bilek (Arm) merkez noktası arası mesafe bilgilerine başvurulur. Belirlenen bu noktalar arasında toplam 30 özellik belirlenmiştir. Diğer özellik seti olarak parmak kemik uzunluk ve genişlik bilgisine de başvurulmuştur. Bunlarla birlikte bilek (Arm) ve avuç içi genişlik bilgisine de özellik olarak ilaveten alınmıştır. Bu noktalar için toplam 12 özellik belirlenmiştir. Son olarak parmaklar arası yön (Direction) açısı bilgisine de kullanılmıştır. Her bir açı bilgisi için toplam 4 özellik eklenmiştir. Bu çalışma çerçevesinde, el tabanlı biyometrik kullanıcı kimlik doğrulama için tanımlanan özellikler daha önce belirtildiği gibi 4 kategoriye ayrılmış ve toplamda 85 özellik sınıflandırma aşamasında kullanılmak üzere belirlenmiştir.

V. ÖZELLİK ÇIKARIMI

Biyometrik kullanıcı kimlik doğrulama hareket tabanlı olduğu için, farklı ve benzer el hareketlerini ayırt edilebilmesini sağlayan bir süreç işletilir. Oluşturulan farklı uzunluklara sahip veri kümesinde sinyal işleme özellik çıkarım yöntemi kullanılmıştır. Bu özellik çıkarımı için çeşitli ölçütler mevcuttur. Bunlar içerisinde standart sapma (STD), ortalama (AVG), ortanca (medyan), varyans ve en sık tekrar eden değer (mod) olmak üzere 5 adet ölçüt kullanılmıştır [34-36]. İlk aşamada, her bir hareket örneğine ait özellikler için bu ölçütler tek tek uygulanmış ve her biri için birer değer elde edilmiştir. Elde edilen toplam 5 değer, her bir örnek özelliği için ayrı ayrı hesaplandıktan sonra birleştirilerek yeni bir veri kümesi oluşturulmuştur. Her biri farklı uzunlukta olan kimlik doğrulama örneklerinin her bir özelliği için anılan ölçütler hesaplanarak örnek bu ölçütler ile temsil edilir hale getirilmiştir. Bu işlem sonucunda, farklı uzunluk ve sürelerle sahip veri kümesinin boyutunun eşitlenmesi gerçekleştirilmiştir. Her bir orijinal özellik için beş farklı istatistiksel ölçüt (ortalama, standart sapma, ortanca, varyans, mod) hesaplanarak, 85 orijinal özellik 425 özelliğe genişletilmiştir ($85 \times 5 = 425$). Ayrıca, 40 denekten her biri için 10 tekrar alınarak toplam 400 örnek elde edilmiştir ($40 \times 10 = 400$). Böylece, veri kümesi (400×425) boyutuna dönüştürülmüştür. Bir kullanıcının bir örneklem içinden 4 özellik bilgisi içeren orijinal veriler ve özellik çıkarımı sonrası oluşan verilere ait grafik Şekil 5’te sunulmuştur. Kullanılan bu 4 özellik parmak ucu (TipPosition) pozisyon noktaları arası mesafe bilgisidir.



Şekil 5. Bir kullanıcının bir örneklem içinden seçilen beş özelliğe (a) ve özellik çıkarımı sonrası veriler (b)

VI. ÖZELLİK SEÇİMİ

Özellik seçimi orijinal veri kümesinden en iyi, etkin ve nitelikli özelliklerin seçimi olarak tanımlanmaktadır. Büyük boyutlu ve özellik sayısı fazla olan veri kümelerinde kullanılması kaynak optimizasyonu, sonuç doğruluğu, çalışma süresi, etkin kullanım gibi avantajlar sunmaktadır. Bu çalışmada, PCC yöntemi kullanılmıştır. PCC, iki değişken ya da özellik arasındaki ilişkiyi ortaya çıkarmak için önemli yöntemlerden birisidir. Veri analizi süreçlerinde, özellikler arasındaki doğrusal bağlantıyı değerlendirerek karar verme süreçlerinde, ilişkilerin güçlülüğünü ve yönünü belirlemede ve sonuçların genellenebilirliğini sağlamada önemli bir rol oynamaktadır.

PCC tekniği, özellikler arasındaki ilişkinin gücünü ve yönünü istatistiksel olarak ölçme amacı ile kullanılan bir yöntemdir. Kovaryans yöntemine dayanmaktadır. İki özellik kovaryansının standart sapmasına bölünmesiyle belirlenir. Bu teknik ile veri kümesindeki her bir özellik için korelasyon katsayısı bulunarak, özellikler arasında bulunan doğrusal bağımlılık ilişkisi ortaya çıkarılır [37,38]. Korelasyon katsayısı $[-1,1]$ arasında bir değer almaktadır. Özelliklere ait elde edilen değerler mutlak değeri alındıktan sonra sıralanarak en yüksek değere sahip olanlar seçilir. P, özellikler arasındaki Pearson korelasyonun katsayısını gösterir ve eşitlik (5)'teki gibi tanımlanır. Eşitlikte x ve y veri kümesi içindeki iki özellik değeri ve σ_x ile σ_y sırasıyla x ve y özelliklerinin standart sapmalarını temsil etmektedir.

$$P = \frac{cov(x,y)}{\sigma_x \sigma_y} \quad (5)$$

VII. BOYUT İNDİRGEME YÖNTEMLERİ

Boyut indirgeme yöntemleri, yüksek boyutlu veri kümesinden gereksiz ve bağımlı özellikleri çıkararak daha düşük boyutlu bir veri kümesi elde etmek için kullanılır. Bu çalışmada, makine öğrenimi uygulamaları için önileme aşamasında boyut azaltmak amacıyla PCA ve LDA yöntemleri tercih edilmiştir.

A. Temel Bileşenler Analizi (PCA, Principal Component Analysis)

PCA, makine öğrenimi, veri madenciliği ve istatistik gibi birçok alanda yaygın olarak kullanılan bir doğrusal boyut azaltma tekniğidir. PCA, veri kümesindeki olası bağımlı değişkenleri, temel bileşenler adı verilen doğrusal bağımsız değişkenlere dönüştürmek için ortogonal dönüşüm yöntemini kullanır. Eşitlikte n veri kümesi toplam boyutu, $\bar{x}$ veri kümesi ortalaması, T transpoz ve x_i i . özellik değerini temsil etmektedir. PCA yönteminde, d boyutlu n örneklili bir veri kümesi $X = \{x_1, x_2, \dots, x_n\}$ için, kovaryans matrisi eşitlik(6) ile ifade edilir:

$$cov_{ij} = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})(x_i - \bar{x})^T \quad (6)$$

Bu hesaplama sürecinde, ilk olarak verinin ortalama değeri her bir elemandan çıkarılarak merkezleme işlemi gerçekleştirilir. Ardından, kovaryans matrisi, iki veya daha fazla rastgele değişken kümesi arasındaki korelasyon gücünü ölçmek için hesaplanır. Sonraki adımda, öz değer-öz vektör ayrıştırma yöntemi kullanılarak kovaryans matrisinin öz değerleri ve öz vektörleri elde edilir. Devamında, bileşenler seçilerek bir özellik vektörü oluşturulur; burada en yüksek özdeğere sahip özvektör, veri kümesinin temel bileşeni olarak belirlenir. Son aşamada ise boyutu değiştirilmiş yeni bir veri kümesi elde edilmiş olur [39,40].

B. Doğrusal Ayrım Analizi(LDA, Linear Discriminant Analysis)

LDA, veri nesnelerinin sınıf bilgisini dikkate alarak sınıfların en iyi şekilde ayrıldığı uzaydaki vektörleri bulmayı hedefleyen bir doğrusal boyut indirgeme tekniğidir [41]. PCA yöntemiyle birlikte en yaygın kullanılan teknikler arasındadır [40]. Bu teknik, veri kümesindeki farklı sınıflara ait grupların doğrusal ayrılabilirliğini en üst düzeye çıkararak boyut azaltma işlemi gerçekleştirir. S_B eşitliğinde c sınıfların sayısını, x_i i . sınıfın ortalamasını,

$\bar{x}$ tüm sınıfların ortalaması ve T transpozunu temsil eder. S_w eşitliğinde ise N_i i . sınıftaki örnek sayısını ve x_{ij} i . sınıftaki j . örneği temsil etmektedir. LDA yöntemi için, boyut indirgeme işleminde sınıflar arası saçılım matrisi S_B ve sınıf içi saçılım matrisi S_w aşağıdaki şekilde tanımlanır:

$$S_B = \sum_{i=1}^c (\bar{x}_i - \bar{x})(\bar{x}_i - \bar{x})^T \quad (7)$$

$$S_w = \sum_{i=1}^c \sum_{j=1}^{N_i} (x_{ij} - \bar{x})(x_{ij} - \bar{x})^T \quad (8)$$

İlk olarak, sınıflar arası saçılım matrisi olan S_B , farklı sınıfların ortalamaları arasındaki mesafeyi hesaplamak için kullanılır. Ardından, sınıf içi saçılım matrisi olarak bilinen S_w ise her sınıfın ortalaması ile örnekleri arasındaki mesafeyi belirler. Devamında, saçılım matrisleri için özvektörler ve bunlara karşılık gelen özdeğerler hesaplanır. Daha sonra, özdeğerler sıralanır ve en yüksek özdeğerlere sahip özvektörler seçilerek yeni bir matris oluşturulur. Son olarak, veri kümesi ile bu matrisin iç çarpımı alınarak yeni bir veri kümesi elde edilir.

VIII. MAKİNE ÖĞRENİMİ YÖNTEMLERİ

Makine öğrenimi, istatistiksel, olasılıksal ve optimizasyon modeller kullanarak bilgisayarların veriden öğrenmesini ve bu öğrenilen bilgiyi çeşitli görevlerde uygulamasını sağlar. Makine öğrenimi, hızla gelişen bir alan olup, veri bilimi, yapay zeka ve analitik teknolojilerle birleşerek daha akıllı ve etkili sistemler geliştirilmesini sağlar [42]. Makine öğrenmesinde sınıflandırıcılar, otomatik karar verme sistemlerinde kritik bir rol oynamaktadır. Gelen verinin hangi sınıfa ait olduğunu belirlememize yardımcı olurlar. Sınıflandırma işlemi için birçok algoritma mevcuttur ve bunlar farklı veri kümelerinde farklı sonuçlar elde edebilir. Bu nedenle, elimizdeki verilere en uygun sınıflandırıcıyı seçmek, doğru kararlar almak açısından büyük önem taşır. Çalışmada farklı makine öğrenmesi algoritmaları tercih edilmiştir. Destek vektör makinesi, ileri beslemeli yapay sinir ağı, derin sinir ağları, aşırı öğrenme makinesi ve çekirdek tabanlı aşırı öğrenme makinesi modeli kullanılmıştır. Sırasıyla geleneksel makine öğrenimi algoritması, tek katmanlı sinir ağı, çok katmanlı sinir ağı, temel ve çekirdek tabanlı aşırı öğrenme sinir ağı algoritmaları kullanılmıştır. Bu makine öğrenimi yöntemlerinin özellik seçimi ve boyut indirgemeye bağlı olarak başarımları ve çalışma süreleri karşılaştırma imkanı sağlanmıştır.

A. Aşırı Öğrenme Makinesi (ELM, Extreme Learning Machines)

Son dönemde, ELM makine öğrenimi alanında dikkat çeken bir öğrenme yöntemi haline gelmiştir. Huang ve arkadaşları [43], bu yöntemi ELM olarak adlandırılan bir çalışma gerçekleştirmişlerdir. ELM, rastgele belirlenen giriş ağırlıkları ile analitik olarak hesaplanan çıkış ağırlıklarına sahip tek gizli katmanlı ileri beslemeli (SLFN) bir yapay sinir ağı modelinin özelleştirilmiş halidir. Bu nedenle, aşırı öğrenme makinelerinin çalışma prensipleri, YSA'nın prensipleriyle belirli bir ölçüde benzerlik göstermektedir. Ancak, aşırı öğrenme makinelerinde gizli katmandaki ağırlıklar rastgele atanmakta ve eğitim sürecinin ilerleyen aşamalarında güncellenmemektedir. Gizli katman ile çıktı katmanı arasındaki ağırlıklar ise tek bir seferde, doğrusal bir model aracılığıyla analitik ve hızlı bir şekilde belirlenmektedir. Bu modelde, giriş katmanındaki nöronların ağırlıkları ve gizli katmandaki nöronların eşik değerleri rastgele üretilirken, gizli katmandaki çıkış ağırlıkları analitik olarak hesaplanmaktadır [44]. Modelin en önemli avantajı, öğrenme sürecinin çok hızlı gerçekleşmesidir. ELM'de gizli katmanda sigmoid, sinüs ve gaussian gibi aktivasyon fonksiyonları kullanılırken, çıkış katmanında doğrusal bir fonksiyon tercih edilmektedir [45]. Deneysel sonuçlar bu algoritmanın iyi bir genelleme başarımı sunduğunu göstermiştir. İleri beslemeli sinir ağları için bilinen algoritmalarından çok hızlı öğrenebildikleri ifade edilmiştir. N örnek ve m sınıftan oluşan bir $\{(x_j, t_j)\}_{j=1}^N$ eğitim örneği kümesi için, L gizli düğümlü ve $g(x)$ aktivasyon fonksiyonlu SLFN aşağıdaki eşitlik(9) ile ifade edilir.

$$\sum_{i=1}^L \beta_i g(w_i \cdot x_j + b_i) = O_j, j=1, \dots, N \quad (9)$$

Burada $x_j = [x_{j1}, x_{j2}, \dots, x_{jN}]^T$, $w_i = [w_{i1}, w_{i2}, \dots, w_{iN}]^T$, $t_j = [t_{j1}, t_{j2}, \dots, t_{jm}]^T$ ve b_i sırasıyla girdi parametreleridir. $w_i = [w_{i1}, w_{i2}, \dots, w_{iN}]^T$ i . gizli düğüm ile giriş düğümlerini birbirine bağlayan, $\beta_i = [\beta_{i1}, \beta_{i2}, \dots, \beta_{im}]^T$ ise i . gizli düğüm ile çıkış düğümlerini birbirine bağlayan ağırlık vektörüdür. b_i i . gizli düğüm eşiği ve O_j ise x_j girişine göre gerçek ağ çıkışıdır.

Gizli katman çıkış matrisi H ve eşitlik sırasıyla (10)(11) ile ifade edilir:

$$H(w_1, \dots, w_L, x_1, \dots, x_N, b_1, \dots, b_L) = \begin{bmatrix} g(w_1 \cdot x_1 + b_1) & \dots & g(w_L \cdot x_1 + b_L) \\ \vdots & \ddots & \vdots \\ g(w_1 \cdot x_N + b_1) & \dots & g(w_L \cdot x_N + b_L) \end{bmatrix}_{L \times N} \quad (10)$$

$$\beta = \begin{bmatrix} \beta_1^T \\ \vdots \\ \beta_L^T \end{bmatrix}_{L \times m}, \quad T = \begin{bmatrix} t_1^T \\ \vdots \\ t_N^T \end{bmatrix}_{N \times m} \quad (11)$$

Çıkış ağırlık matrisi β ise eşitlik (12) ile ifade edilir. T ise istenen hedef çıktı matrisidir.

$$\beta = H^T T \quad (12)$$

B. Çekirdek Tabanlı Aşırı Öğrenme Makinesi (K-ELM, Kernel Extreme Learning Machines)

Huang ve arkadaşları [46-51], kernel çekirdek yöntemini aşırı öğrenme makinesi ile birleştirerek K-ELM geliştirmiştir. Girdi ağırlıkları ve bias değeri, eğitim kümesinden bağımsız olarak rastgele belirlenir. Gradyan tabanlı yöntemlerde ise en uygun parametreler iteratif bir süreçle bulunur ve bu süreç genellikle uzun sürer. Bu nedenle, aşırı öğrenme makinesinin öğrenme süreci, klasik geri yayılım algoritmalarına göre daha hızlı ve kolaydır. Ancak, gizli düğüm sayısı sabit tutulsa bile, girdi ağırlıkları ve bias değerlerinin her sınıflandırmada rastgele seçilmesi, sınıflandırma doğruluğunda dalgalanmalara yol açmaktadır. Bu durumu çözmek amacıyla, aşırı öğrenme makinesinin gizli katmanı yerine bir çekirdek fonksiyonu kullanılmasını önermişlerdir. Böylece, girdi ve gizli katmanlar arasındaki ağırlıkların rastgele belirlenmesine gerek kalmamaktadır. [52-54].

Kernel-ELM'de, $\phi_i(x)$ matrisinde her bir giriş verisi için çekirdek fonksiyonu uygulanır. Çalışmada gaussian (RBF) çekirdek fonksiyonu kullanıldığından eşitlik (13) ile ifade edilir:

$$\phi_i(x) = \phi(\mu_i, \sigma_i, x) = \exp\left(-\frac{\|x - \mu_i\|^2}{\sigma_i}\right) \quad (13)$$

$\mu_i = [\mu_{i1}, \mu_{i2}, \dots, \mu_{iN}]^T$ i . çekirdek fonksiyonunun merkezi, x ise giriş verisi, σ_i ise i . çekirdek genişliğini ve verilerin yayılımını kontrol eder. μ_i modelin öğrenme sürecinde, veriler arasındaki ilişkileri temsil eder. N örnek ve m sınıftan oluşan bir $\{(x_j, t_j)\}_{j=1}^N$ eğitim örneği kümesi için ve L gizli düğümlü RBF aşağıdaki eşitlik (14) ile tanımlanır.

$$\sum_{i=1}^L \beta_i \phi_i(x_j) = o_j, j=1, \dots, N, \quad (14)$$

H tahmin matrisini, $\phi_i(x)$ çekirdek fonksiyonu ile dönüştürülmüş giriş verilerini ve β ise çıktıları karşılık gelen ağırlıkları temsil eder. β ise en küçük kareler yöntemi ile hesaplanır. Gizli katman çıkış matrisi H eşitlik sırasıyla (15)(16)(17) ile ifade edilir:

$$H(\mu_1, \dots, \mu_N, \sigma_1, \dots, \sigma_N, x_1, \dots, x_N) = \begin{bmatrix} \phi(\mu_1, \sigma_1 + x_1) & \dots & \phi(\mu_L, \sigma_L + x_1) \\ \vdots & \ddots & \vdots \\ \phi(\mu_1, \sigma_1 + x_N) & \dots & \phi(\mu_L, \sigma_L + x_N) \end{bmatrix}_{L \times N} \quad (15)$$

$$\beta = \begin{bmatrix} \beta_1^T \\ \vdots \\ \beta_L^T \end{bmatrix}_{L \times m}, \quad T = \begin{bmatrix} t_1^T \\ \vdots \\ t_N^T \end{bmatrix}_{N \times m} \quad (16)$$

$$H = \phi_i(x) \cdot \beta \quad (17)$$

Temel ELM sınıflandırıcıda hücre sayısı 100 ve sigmoid aktivasyon fonksiyonu kullanılmıştır. Çekirdek tabanlı K-ELM sınıflandırıcıda *RBF_kernel* fonksiyonu tercih edilmiştir. K-ELM'de hücre sayısının kullanılmasına gerek yoktur. K-ELM algoritması için düzenleme katsayısı C (18)'deki eşitlik ile belirlenmiştir. Düzenleme katsayısı genellikle veri kümesine bağlı olarak değişmektedir. Burada X veri kümesini temsil etmektedir.

$$C = \max(\text{eig}(X^T X)) \quad (18)$$

C. Destek Vektör Makinesi (SVM, Support Vector Machine)

SVM, regresyon ve sınıflandırma analizlerinde yaygın olarak kullanılan esnek ve yüksek performanslı bir makine öğrenme algoritmasıdır. SVM, veri noktalarını yüksek boyutlu bir özellik uzayında en iyi şekilde ayırmak amacıyla hiper düzlemler kullanır. Amacı, sınıflandırma probleminde farklı sınıfları en iyi şekilde ayıran bir sınır bulmaktır. SVM'nin temel prensibi, iki sınıf arasındaki en geniş ayırma sınırını bulmaktır [55]. Bu ayırma sınırı, destek vektörleri olarak bilinen ve sınıflandırma kararını etkileyen en yakın veri noktaları tarafından belirlenir. SVM'nin temel hedefi, bu ayırma sınırını en geniş yapacak hiper düzlemi bulmaktır. Bu genişlik, iki sınıf arasındaki en yakın veri noktalarının arasındaki mesafeyi ifade eder. Bu mesafenin maksimize edilmesi, modelin genelleme yeteneğini artırarak daha iyi sınıflandırma performansı sağlar. SVM, yalnızca doğrusal olarak ayrılabilen veri kümeleriyle değil, aynı zamanda doğrusal olarak ayrılabilir olmayan veri kümeleriyle de etkili bir şekilde çalışabilir. Çalışmada yaygın olarak kullanılan doğrusal çekirdek fonksiyonu kullanılmıştır.

D. İleri Beslemeli Yapay Sinir Ağı (FFNN, A feed-forward Artificial Neural Network)

FFNN, yaygın olarak girdi verilerini önceden tanımlanmış sınıflara ayırmak üzere kullanılmaktadır. Her katmanın bir sonraki katmana tamamen bağlı olduğu düzenlenmiş sinir hücrelerinden oluşur. Bu model, özellikleri alan bir giriş katmanından, verileri işleyip dönüştüren bir veya daha fazla gizli katmandan ve sınıf olasılıklarını

üreten bir çıkış katmanından oluşmaktadır [56]. Her katman bir sonraki katmana tamamen bağlıdır, bu da ağıın veriler içindeki karmaşık desenleri ve ilişkileri öğrenmesine olanak tanır. İleri ve geri geçişlerden oluşan bir süreç sayesinde geriye yayılım, ağıın bağlantılarının ağırlıklarını yinelemeli olarak ayarlamasını sağlayarak tahmin edilen çıktılar ile gerçek hedefler arasındaki tutarsızlığı en aza indirir. Model daha çok yeni veriler geldikçe ağıın parametrelerini güncelleyerek kademeli öğrenmeyi sağlamaya odaklanmıştır. Ağ, giriş özelliklerinden çıkış sınıflarına olan eşleştirmeyi optimize etmek ve doğrusal dışı özellik katmak için ReLU gibi aktivasyon fonksiyonları kullanmaktadır. Çalışmada ReLU aktivasyon fonksiyonlu 100 nöron içeren tek gizli katmanlı, çıkış katmanında da Softmax aktivasyon kullanılan bir sinir ağı modeli oluşturulmuş ve kullanılmıştır.

E. Derin Sinir Ağları (DNN, Deep Neural Networks)

DNN, yapay zeka ve makine öğreniminde önemli bir rol oynayan, çok katmanlı yapay sinir ağı modelleridir. Genel olarak, bir girdi katmanı, bir veya daha fazla gizli katman ve bir çıktı katmanı bulunur. DNN, katmanlar halinde düzenlenmiş ve birbirine bağlı nöronlardan oluşur. DNN'nin derin sinir ağı olarak adlandırılmasının sebebi, mimarisinde birden fazla gizli katmanın yer almasıdır. Gizli katmanlardaki nöron sayısı, sınıflandırma doğruluğu açısından kritik bir öneme sahiptir. DNN mimarisini klasik yapay sinir ağlarından ayıran en belirgin özellik, çok katmanlı yapısı ve her katmanda barındırdığı yüksek sayıda nöronudur. [57-59]. Bu derinlik, ağıın karmaşık verileri daha iyi modelleyebilmesine ve yüksek düzeyde soyutlama gerçekleştirebilmesine olanak tanır. Bu farklılık, modelin karmaşıklığını ve öğrenme yeteneğini artırma potansiyelini gösterir. Ancak, katman sayısının artması, daha fazla parametre ve hesaplama kaynağı gereksinimini de beraberinde getirir. Her katman, ağıın öğrenme sürecine önemli bir katkı sağlar. Gizli katman sayısının artması, ağıın daha karmaşık ve özel özellikler öğrenmesine imkan tanırken, eğitim sürecini de zorlaştırabilir. Derin öğrenme modellerindeki katmanlar, bilgiyi bir önceki katmandan alıp bir sonraki katmana aktararak modelin temel yapı taşlarını oluşturur.

Bu çalışmada geliştirilen modelde bir giriş katmanı, üç gizli katman ve bir çıkış katmanı bulunmaktadır. İlk gizli katmanda 100, ikinci katmanda 50 ve üçüncü katmanda 25 nöron yer almıştır. Gizli katmanlarda ReLU aktivasyon fonksiyonu, son katmanda ise softmax kullanılmıştır. Modelin optimizasyonu için Adam algoritması tercih edilmiştir. Diğer parametreler, eğitim döngüsü sayısı 50, mini-yığın (batch) boyutu 128, öğrenme oranı 0.01, gradyan eşik değeri 1 olarak alınmıştır.


IX. DENEYSEL SONUÇLAR

Başarım oranlarının incelenmesinde, 40 denekten elde edilen 400 örnek içeren orijinal veri kümesi üzerinde iki aşamalı özellik seçimi ve boyut indirgeme işlemi gerçekleştirilmiştir. İlk aşama PCC özellik seçim algoritması kullanılarak kritik özelliklerin seçimi için alt veri kümeleri oluşturulmuştur. Kritik özelliklerin seçiminde oransal ve kademeli olarak özellik sayıları azaltılmıştır. Özellik seçimleri oransal ve kademeli olarak sırasıyla yüzde 75, 50, 25 ve 13'e düşürülmüştür. Bu aşamada 4 oransal yüzdeliğe göre kademeli düşürülerek en iyi özellik seti belirlenmek istenmiştir. İkinci aşamada orijinal ve özellik seçimi ile elde edilen veri kümeleri PCA ve LDA yöntemleri ile boyut indirgenerek yeni veri kümeleri oluşturulmuştur. Boyutu indirgenmiş veri kümeleri ile birlikte tüm veri kümeleri sınıflandırma sürecinde kullanılmıştır. Özellik seçimi ve boyut indirgeme yöntemleri ile elde edilen veri kümelerinin başarım oranlarının karşılaştırılması ve en yüksek başarım oranına sahip özellik alt kümelerin belirlenmesi hedeflenmiştir. Tablo ve şekillerdeki sonuçlar test sürecindeki başarım oranlarıdır. Çalışma süreleri ise eğitim ve test aşamasında geçen süre alınmıştır. ELM ve K-ELM sınıflandırıcılar için eğitim sürecindeki başarım oranları yazılmamıştır. PCA ve LDA süreçlerinde %98 oranında veriyi temsil eden özellik sayısı alınmıştır.

Makine öğrenimi sınıflandırıcıları kullanılarak ilk aşamada özellik çıkarımları ile dönüştürülen 425 özellik seti içeren orijinal veri kümesi ve 2 boyut indirgeme tekniği ile oluşturulan veri kümelerinin başarım oranlarına bakılmıştır. Bu aşamada boyut indirgeme yöntemleri sonucu 114 PCA ve 35 LDA özellik setine düşürülmüştür. Makine öğrenimi algoritmalarının birinci aşama için başarım oranları ve çalışma süreleri Tablo 1'de sunulmuştur. Tablo 1'deki başarım oranı grafikleri ise Şekil 6'da verilmiştir. Bu 3 veri kümesine bakıldığında kullanıcı kimlik doğrulama için en yüksek sınıflandırma başarım oranı K-ELM ile elde edilmiştir. Sınıflayıcılar arasında çalışma süresi en kısa olan K-ELM'dir. Deneysel sonuçlara göre, LDA boyut indirgemenin PCA'ya göre daha iyi başarım ile sonuçlandığı gözlenmiştir.

Tablo 1. Birinci aşama veri kümelerinin sınıflandırma başarımları ve çalışma süreleri

1. AŞAMA						
Sınıflandırıcı	Orijinal veri Kümesi (425)		PCA (114 özellik)		LDA (35 özellik)	
	Doğruluk (%)	Ç. Süresi (sn)	Doğruluk (%)	Ç. Süresi (sn)	Doğruluk (%)	Ç. Süresi (sn)
ELM	93,40	0,0335	80,05	0,0062	92,50	0,0067
K-ELM	95,93	0,0191	83,80	0,0056	95,40	0,0051
FFNN	94,55	1,0631	81,25	0,2304	94,35	0,2011
DNN	92,50	6,1189	76,00	2,8553	84,10	2,6278
SVM	95,30	9,0028	83,25	8,5663	93,75	8,2863




Şekil 6. Birinci aşama veri kümelerinin sınıflandırma başarımları


İkinci aşamada 425 özellik seti içeren orijinal veri kümesinin yüzde 75 (320 özellik) oranında en iyi özellik seti PCC özellik seçimi yöntemi uygulanarak belirlenmiştir. Bu aşamada ikinci işlem olarak yeni özellik setine boyut indirgeme yöntemleri uygulanarak 91 PCA ve 32 LDA özellik setine düşürülmüştür. Üçüncü aşamada da orijinal veri kümesinin yüzde 50 (213 özellik) oranında en iyi özellik seti PCC özellik seçimi yöntemi uygulanarak belirlenmiştir. Burada ikinci işlem olarak boyut indirgeme yöntemleri uygulanarak 60 PCA ve 28 LDA özellik setine düşürülmüştür. Her iki aşama için bakıldığında biyometrik kullanıcı kimlik doğrulama için en yüksek sınıflandırma başarımları K-ELM ile elde edilmiştir. Çalışma süreleri açısından en hızlı sınıflayıcıda K-ELM'dir. İki aşama içinde en iyi boyut indirgeme yöntemi LDA olarak görülmektedir. Makine öğrenimi sınıflandırıcıların bu aşamalar için başarımları ve çalışma süreleri Tablo 2'de sunulmuştur. Tablo 2'deki başarımları oranı grafikleri ise sırasıyla Şekil 7 ve Şekil 8'de verilmiştir.

Tablo 2. İkinci ve üçüncü aşama veri kümelerinin sınıflandırma başarımları ve çalışma süreleri

Sınıflandırıcı	2.AŞAMA						3.AŞAMA					
	PCC (320 özellik)		PCA (91 özellik)		LDA (32 özellik)		PCC (213 özellik)		PCA (60 özellik)		LDA (28 özellik)	
	Doğruluk (%)	Ç. Süresi (sn)	Doğruluk (%)	Ç. Süresi (sn)	Doğruluk (%)	Ç. Süresi (sn)	Doğruluk (%)	Ç. Süresi (sn)	Doğruluk (%)	Ç. Süresi (sn)	Doğruluk (%)	Ç. Süresi (sn)
ELM	93,20	0,0142	82,30	0,006	92,70	0,0069	95,90	0,0141	87,70	0,0071	93,30	0,0069
K-ELM	95,20	0,0112	86,80	0,0044	95,20	0,0053	96,50	0,0112	95,80	0,0052	95,70	0,0052
FFNN	94,25	0,6948	84,75	0,2064	94,50	0,1973	93,25	0,6573	92,50	0,2061	95,20	0,1801
DNN	94,07	5,1418	64,75	2,7792	95,25	2,6207	90,25	5,2896	81,07	2,7398	91,05	2,7095
SVM	95,00	9,6787	85,25	8,5404	95,75	8,3221	95,89	9,3019	93,50	8,4569	94,25	8,4028



Şekil 7. İkinci aşama veri kümelerinin sınıflandırma başarımları




Şekil 8. Üçüncü aşama veri kümelerinin sınıflandırma başarımları


Dördüncü aşamada orijinal veri kümesinin yüzde 25 (107 özellik) oranında en iyi özellik seti PCC özellik seçimi yöntemi uygulanarak çıkarılmıştır. İkinci adım olarak boyut indirgeme yöntemleri uygulanarak 30 PCA ve 19 LDA özellik setine düşürülmüştür. Beşinci aşamada da orijinal veri kümesinin yüzde 13 (55 özellik) oranında en iyi özellik seti PCC özellik seçimi yöntemi uygulanarak belirlenmiştir. Burada ikinci adım olarak boyut indirgeme yöntemleri uygulanarak 15 PCA ve 11 LDA özellik setine düşürülmüştür. Her iki aşama için bakıldığında en yüksek sınıflandırma başarımları K-ELM ile elde edilmiştir. Çalışma süreleri açısından en hızlı sınıflayıcıda K-ELM'dir. İki aşama içinde en iyi boyut indirgeme yöntemi LDA olarak görülmektedir. Bu aşamalar için başarımları ve çalışma süreleri Tablo 3'de sunulmuştur. Tablo 3'deki başarımları grafikleri ise sırasıyla Şekil 9 ve Şekil 10'de verilmiştir.

Tablo 3. Dördüncü ve beşinci aşama veri kümelerinin sınıflandırma başarımları ve çalışma süreleri

Sınıflandırıcı	4.AŞAMA						5.AŞAMA					
	PCC (107 özellik)		PCA (30 özellik)		LDA (19 özellik)		PCC (55 özellik)		PCA (15 özellik)		LDA (11 özellik)	
	Doğruluk (%)	Ç. Süresi (sn)	Doğruluk (%)	Ç. Süresi (sn)	Doğruluk (%)	Ç. Süresi (sn)	Doğruluk (%)	Ç. Süresi (sn)	Doğruluk (%)	Ç. Süresi (sn)	Doğruluk (%)	Ç. Süresi (sn)
ELM	91,20	0,0333	91,80	0,0069	92,80	0,0068	94,30	0,0105	90,50	0,0058	92,20	0,0056
K-ELM	95,92	0,0154	95,15	0,0054	95,80	0,0049	95,30	0,0085	95,03	0,0040	95,30	0,0041
FFNN	94,25	0,7721	94,75	0,2058	95,35	0,1837	92,25	0,4520	94,50	0,1559	94,75	0,1525
DNN	89,75	6,0631	85,25	2,9347	93,55	2,7344	90,50	4,8363	91,05	2,5683	92,50	2,4184
SVM	95,02	9,5993	92,75	8,6100	95,02	8,5449	94,05	7,6328	92,50	6,4539	93,75	6,5291



Şekil 9. Dördüncü aşama veri kümelerinin sınıflandırma başarımları



Şekil 10. Beşinci aşama veri kümelerinin sınıflandırma başarımları

Özellik seçimi ve boyut indirgeme yöntemlerinin çalışma sürelerine bakıldığında LDA sınıf içi ve sınıf dışı hesaplama yaptığından çok küçük de olsa yavaştır. Veri kümelerinin boyutları küçüldükçe bu yöntemlerin çalışma süreleri birbirine yaklaşmaktadır. Makine öğrenimi algoritmaları ile kıyasladığımızda ise ELM ve K-ELM algoritmaları ile yakın değerler verirken diğerlerine göre çok hızlıdır. Bu ön işlem aşama süreçlerinde çalışma süreleri Tablo 4’de sunulmuştur.

Tablo 4. Özellik seçimi ve boyut indirgeme yöntemlerinin çalışma süreleri

	PCC	PCA	LDA
	Çalışma Süresi (sn)	Çalışma Süresi (sn)	Çalışma Süresi (sn)
Orijinal veri kümesi		0,036	0,126
PCC 320 özellik içeren veri kümesi	0,0198	0,026	0,079
PCC 213 özellik içeren veri kümesi	0,0191	0,021	0,044
PCC 107 özellik içeren veri kümesi	0,0188	0,020	0,022
PCC 55 özellik içeren veri kümesi	0,0187	0,017	0,018

Tüm aşamalarda yapılan uygulamalar incelendiğinde, K-ELM sınıflandırıcısının genel olarak diğer sınıflandırıcılara göre başarımlarını koruduğu ve en yüksek başarıyı sağladığı gözlemlenmiştir. Ayrıca, K-ELM'nin kararlı bir yapıya sahip olduğu söylenebilir. Algoritmaların farklı yapıları nedeniyle çalışma sürelerinde de farklılıklar ortaya çıkmıştır; en hızlı sınıflayıcı K-ELM'dir. PCA ve LDA uygulanan veri kümeleri, başarı, süre ve öznetelik sayısı bakımından karşılaştırıldığında, LDA'nın boyut indirgeme yöntemi olarak sınıflandırma algoritmalarında etkili olduğu gözlemlenmektedir. K-ELM'nin boyut indirgenmiş veri kümeleri üzerindeki başarımlarını koruduğu da gözlemlenmiştir. Oransal ve kademeli olarak özellik seçiminde kullanılan PCC

algoritmasının tüm aşamalarda iyi bir seçim yaptığı ve performans gösterdiği görülmüştür. Tüm uygulama aşamalarında algoritmalar içerisinde çalışma süresi en yavaş SVM ve başarımları en düşük DNN olmuştur. İki aşamalı süreçle özellik sayısının azaltılması ve boyut küçültülmesi, oluşturulan veri kümelerinin hesaplama, süre, depolama ve başarımları açısından avantaj sağlamaktadır.

X. TARTIŞMA VE SONUÇ

Çalışmada, tek elle gerçekleştirilen LM tabanlı biyometrik kullanıcı kimlik doğrulama modeli ile yeni bir yaklaşım tarzı sunulmuştur. LM, birçok açıdan sunduğu avantajlar nedeniyle benzer cihazlar arasında tercih edilmiştir. Ayrıca, LM cihazı biyometrik kimlik doğrulama sürecinde çoğu ortamda kullanım imkanına sahiptir. Önerilen model, el hareket girdilerini kullanarak sunulan stratejiyi etkin bir şekilde değerlendirdiği için sağlamdır. Doğrulama modeli için farklı sınıflandırma yöntemleri kullanılmış ve başarımları analiz edilmiştir. Özgün oluşturulan veri kümesi kullanarak, veri setinin özellik sayısı azaltma ve boyut düşürme aşamalarında kimlik doğrulama başarımları birçok yönü ile ele alınmıştır. Kimlik doğrulama, farklı makine öğrenimi sınıflandırma türleriyle gerçekleştirilmiştir ve en iyi doğruluk %96 oranı ile K-ELM yaklaşımı kullanılarak kaydedilmiştir. Oransal ve kademeli özellik seçimi ve boyut indirgeme süreçlerinde PCC ve LDA ile elde edilmiş veri kümeleri ile her bir makine öğrenimi algoritmasının başarımlarının birbirine yakın olduğu gözlemlenmiştir. Bu çalışmada uygulanan strateji sayesinde, öznelik seçimi ve boyut azaltma teknikleri kullanılarak yüksek sınıflandırma başarımları sağlanmıştır. Çalışmanın ilerleyen safhalarında, LM cihazı ile çok faktörlü yüksek güvenlik gerektiren kimlik doğrulama çalışması planlanmaktadır.

KAYNAKLAR

- [1] Selbes, B., & Elihoş, A. (2023). Deep Learning Based Latent Palmprint Recognition. In *2023 31st Signal Processing and Communications Applications Conference (SIU)* (pp. 1-4). IEEE.
- [2] Iula, A. (2021). Biometric recognition through 3D ultrasound hand geometry. *Ultrasonics*, 111, 106326.
- [3] Aydemir, E., Tuncer, T., Dogan, S., & Unsal, M. (2021). A novel biometric recognition method based on multi kernelled bijection octal pattern using gait sound. *Applied Acoustics*, 173, 107701.
- [4] Devi, R. M., Keerthika, P., Suresh, P., Sarangi, P. P., Sangeetha, M., Sagana, C., & Devendran, K. (2022). Retina biometrics for personal authentication. In *Machine Learning for Biometrics* (pp. 87-104).
- [5] Ammour, B., Boubchir, L., Bouden, T., & Ramdani, M. (2020). Face-iris multimodal biometric identification system. *Electronics*, 9(1), 85.
- [6] Bibi, K., Naz, S., & Rehman, A. (2020). Biometric signature authentication using machine learning techniques: Current trends, challenges and opportunities. *Multimedia Tools and Applications*, 79(1), 289-340.
- [7] Wong, A. M. H., & Kang, D. K. (2016). Stationary hand gesture authentication using edit distance on finger pointing direction interval. *Scientific Programming*, 2016(1). DOI: 10.1155/2016/7427980.
- [8] Imura, S., & Hosobe, H. (2018). A hand gesture-based method for biometric authentication. In *Human-Computer Interaction. Theories, Methods, and Human Issues: 20th International Conference, HCI International 2018, Las Vegas, NV, USA, July 15–20, 2018, Proceedings, Part I 20* (pp. 554-566). Springer International Publishing.
- [9] Maruyama, K., Shin, J., Kim, C. M., & Chen, C. L. (2017). User authentication using leap motion. In *Proceedings of the international conference on research in adaptive and convergent systems* (pp. 213-216).
- [10] Bernardos, A. M., Sánchez, J. M., Portillo, J. I., Wang, X., Besada, J. A., & Casar, J. R. (2016). Design and deployment of a contactless hand-shape identification system for smart spaces. *Journal of Ambient Intelligence and Humanized Computing*, 7, 357-370.
- [11] Manabe, T., & Yamana, H. (2019). Two-factor authentication using leap motion and numeric keypad. In *HCI for Cybersecurity, Privacy and Trust: First International Conference, HCI-CPT 2019, Held as Part of the 21st HCI International Conference, HCII 2019, Orlando, FL, USA, July 26–31, 2019, Proceedings 21* (pp. 38-51). Springer International Publishing.
- [12] Xu, W., Tian, J., Cao, Y., & Wang, S. (2017). Challenge-response authentication using in-air handwriting style verification. *IEEE Transactions on Dependable and Secure Computing*, 17(1), 51-64. doi:10.1109/TDSC.2017.2752164.
- [13] Lu, D., Xu, K., & Huang, D. (2017). A data driven in-air-handwriting biometric authentication system. In *2017 IEEE International Joint Conference on Biometrics (IJCB)* (pp. 531-537). IEEE.
- [14] Lu, D., Huang, D., & Rai, A. (2019). FMHash: Deep hashing of In-Air-Handwriting for user identification. In *ICC 2019-2019 IEEE International Conference on Communications (ICC)* (pp. 1-7). IEEE.
- [15] Saritha, L. R., Thomas, D., Mohandas, N., & Ramnath, P. (2017). Behavioral biometric authentication using Leap Motion sensor. *Int. J. Latest Trends Eng. Technol*, 8(1), 643-649.
- [16] Xiao, G., Milanova, M., & Xie, M. (2016). Secure behavioral biometric authentication with leap motion. In *2016 4th international symposium on digital forensic and security (isdfs)* (pp. 112-118). IEEE.
- [17] Taher, M. M., & George, L. E. (2022). A digital signature system based on hand geometry. *Journal of Algebraic Statistics*, 13(3), 4538-4556.

- [18] Chahar, A., Yadav, S., Nigam, I., Singh, R., & Vatsa, M. (2015). A leap password based verification system. In *2015 IEEE 7th International Conference on Biometrics Theory, Applications and Systems (BTAS)* (pp. 1-6). IEEE.
- [19] Shin, J., Islam, M. R., Rahim, M. A., & Mun, H. J. (2020). Arm movement activity based user authentication in P2P systems. *Peer-to-peer networking and applications*, 13(2), 635-646. DOI: 10.1007/s12083-019-00775-7.
- [20] Wu, J., Konrad, J., & Ishwar, P. (2013). Dynamic time warping for gesture-based user identification and authentication with Kinect. In *2013 IEEE International Conference on Acoustics, Speech and Signal Processing* (pp. 2371-2375). IEEE.
- [21] Lai, K., Konrad, J., & Ishwar, P. (2012). Towards gesture-based user authentication. In *2012 IEEE Ninth International Conference on Advanced Video and Signal-Based Surveillance* (pp. 282-287). IEEE.
- [22] LM Cihazı. (2023). Leap Motion C# SDK Documentation. Retrieved from <https://developer-archive.leapmotion.com/documentation/csharp/index.html>. Accessed September 11, 2024.
- [23] Katılmış, Z., & Karakuzu, C. (2023). Double handed dynamic Turkish Sign Language recognition using Leap Motion with meta learning approach. *Expert Systems with Applications*, 228, 120453.
- [24] Katılmış, Z., & Karakuzu, C. (2021). ELM based two-handed dynamic Turkish sign language (TSL) word recognition. *Expert Systems with Applications*, 182, 115213.
- [25] Ameer, S., Khalifa, A. B., & Bouhlef, M. S. (2020). Hand-gesture-based touchless exploration of medical images with leap motion controller. In *2020 17th International multi-conference on systems, signals & devices (SSD)* (pp. 6-11). IEEE.
- [26] Ferreira, S. C., Chaves, R. O., Scrucco, M. C. D. R., Pereira, A., Azar, A. P. D. S., Dias, Â. V., ... & Brito, M. V. H. (2020). Empirical evaluation of a 3D virtual simulator of hysteroscopy using Leap Motion for gestural interfacing. *Journal of Medical Systems*, 44, 1-10.
- [27] Korayem, M. H., Madihi, M. A., & Vahidifar, V. (2021). Controlling surgical robot arm using leap motion controller with Kalman filter. *Measurement*, 178, 109372.
- [28] Korayem, M. H., Vosoughi, R., & Vahidifar, V. (2022). Design, manufacture, and control of a laparoscopic robot via Leap Motion sensors. *Measurement*, 205, 112186.
- [29] Najafinejad, A., & Korayem, M. H. (2023). Detection and minimizing the error caused by hand tremors using a leap motion sensor in operating a surgeon robot. *Measurement*, 221, 113544.
- [30] Tarakci, E., Arman, N., Tarakci, D., & Kasapcopur, O. (2020). Leap Motion Controller-based training for upper extremity rehabilitation in children and adolescents with physical disabilities: A randomized controlled trial. *Journal of Hand Therapy*, 33(2), 220-228.
- [31] Aguilar-Lazcano, C. A., & Rechy-Ramirez, E. J. (2020). Performance analysis of Leap motion controller for finger rehabilitation using serious games in two lighting environments. *Measurement*, 157, 107677.
- [32] Dunai, L., Novak, M., & García Espert, C. (2020). Human hand anatomy-based prosthetic hand. *Sensors*, 21(1), 137.
- [33] Geng, J., Zhang, W., Ge, Y., Wang, L., Huang, P., Liu, Y., ... & Cheng, X. (2024). Inter-rater variability and repeatability in the assessment of the Tanner-Whitehouse classification of hand radiographs for the estimation of bone age. *Skeletal Radiology*, 1-8.
- [34] Vishnoi, V. K., Kumar, K., & Kumar, B. (2022). A comprehensive study of feature extraction techniques for plant leaf disease detection. *Multimedia Tools and Applications*, 81(1), 367-419.
- [35] Uçar, M. K., Örenç, S., Bozkurt, M. R., & Bilgin, C. (2017). Evaluation of the relationship between chronic obstructive pulmonary disease and photoplethysmography signal. In *2017 Medical Technologies National Congress (TIPTKNO)* (pp. 1-4). IEEE.
- [36] Şeker, D., & Özerdem, M. S. (2020). Classification and Statistical Analysis of Schizophrenic and Normal EEG Time Series. In *2020 Medical Technologies Congress (TIPTKNO)* (pp. 1-4). IEEE.
- [37] Sun, S., Hu, M., Wang, S., & Zhang, C. (2023). How to capture tourists' search behavior in tourism forecasts? A two-stage feature selection approach. *Expert Systems with Applications*, 213, Article 118895. <https://doi.org/10.1016/j.eswa.2022.118895>
- [38] Daru, A. F., Hanif, M. B., & Widodo, E. (2021). Improving neural network performance with feature selection using Pearson correlation method for diabetes disease detection. *JUITA: Jurnal Informatika*, 9(1), 123-130. <https://doi.org/10.30595/juita.v9i1.9941>
- [39] Hasan, B. M. S., & Abdulazeez, A. M. (2021). A review of principal component analysis algorithm for dimensionality reduction. *Journal of Soft Computing and Data Mining*, 2(1), 20-30
- [40] Choubey, D. K., Kumar, M., Shukla, V., Tripathi, S., & Dhandhanian, V. K. (2020). Comparative analysis of classification methods with PCA and LDA for diabetes. *Current diabetes reviews*, 16(8), 833-850.
- [41] Martinez, M., & Kak, A. C. (2001). PCA versus LDA. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 23, 228-233. <https://doi.org/10.1109/34.908974>
- [42] Cruz, J. A., & Wishart, D. S. (2006). Applications of machine learning in cancer prediction and prognosis. *Cancer informatics*, 2, 117693510600200030.

- [43] Guang-BinHuang, Zhu, Q.-Y., & Siew, C.-K. (2006). Extreme learning machine: Theory and applications. *Neurocomputing* , 70, s. 489–501.
- [44] Tang, J., Deng, C., Huang, G.-B., & Zhao, B. (2015). Compressed-Domain Ship Detection on Spaceborne Optical Image Using Deep Neural Network and Extreme Learning Machine. *IEEE Transactions on Geoscience and Remote Sensing* , 53 (3), s. 1174-1185.
- [45] Huang, G. B. (2014). An Insight into Extreme Learning Machines: Random Neurons, Random Features and Kernels. *Cognitive Computation* , 6 (3), s. 376-390.
- [46] Cao, J., Lin, Z., Huang, G. B., & Liub, N. (2012). Voting based extreme learning machine. *Information Sciences* , 185 (1), s. 66–77.
- [47] Cambria, E., Huang, G.-B., Kasun, L. L., Zhou, H., Vong, C. M., Lin, J., et al. (2013). Extreme learning machines. *IEEE Intelligent Systems* , 28 (6), s. 30–59.
- [48] Cambria, E., Huang, G. B., Kasun, L. L. C., Zhou, H., Vong, C. M., Lin, J., ... & Liu, J. (2013). Extreme learning machines [trends & controversies]. *IEEE intelligent systems*, 28(6), 30-59.
- [49] Cao, F., Yang, Z., Ren, J., Chen, W., Han, G., & Shen, Y. (2019). Local block multilayer sparse extreme learning machine for effective feature extraction and classification of hyperspectral images. *IEEE Transactions on Geoscience and Remote Sensing*, 57(8), 5580-5594.
- [50] Cambria, E., Huang, G. B., Kasun, L. L. C., Zhou, H., Vong, C. M., Lin, J., ... & Liu, J. (2013). Extreme learning machines [trends & controversies]. *IEEE intelligent systems*, 28(6), 30-59.
- [51] Pal, M., Maxwell, A. E., & Warner, T. A. (2013). Kernel-based extreme learning machine for remote-sensing image classification. *Remote Sensing Letters*, 4(9), 853-862.
- [52] Chen, C., Li, W., Su, H., & Liu, K. (2014). Spectral-spatial classification of hyperspectral image based on kernel extreme learning machine. *Remote Sensing*, 6(6), 5795-5814.
- [53] Huang, G. B., Zhou, H., Ding, X., & Zhang, R. (2012). Extreme learning machine for regression and multiclass classification. *IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics)*, 42(2), 513-529.
- [54] Zhou, L., & Ma, L. (2019). Extreme learning machine-based heterogeneous domain adaptation for classification of hyperspectral images. *IEEE Geoscience and Remote Sensing Letters*, 16(11), 1781-1785.
- [55] Huang, C.-L., Chen, M.-C., & Wang, C.-J. (2007). Credit scoring with a data mining approach based on support vector machines. *Expert Systems with Applications*, 33, s. 847–856.
- [56] Tiboni, M., & Remino, C. (2024). Condition Monitoring of Pneumatic Drive Systems Based on the AI Method Feed-Forward Backpropagation Neural Network. *Sensors*, 24(6), 1783. <https://doi.org/10.3390/s24061783>
- [57] Büyük, O., & Arslan, L. M. (2018). Age identification from voice using feed-forward deep neural networks. In *2018 26th Signal Processing and Communications Applications Conference (SIU)* (pp. 1-4). IEEE.
- [58] Baştürk, A., Yüksel, M. E., Çalışkan, A., & Badem, H. (2017). Deep neural network classifier for hand movement prediction. In *2017 25th Signal Processing and Communications Applications Conference (SIU)* (pp. 1-4). IEEE.
- [59] Hinton, G. E., & Salakhutdinov, R. R. (2006). Reducing the dimensionality of data with neural networks. *Science*, 313(5786), 504-507. <https://doi.org/10.1126/science.112764>.