



POLİTEKNİK DERGİSİ

JOURNAL of POLYTECHNIC

ISSN: 1302-0900 (PRINT), ISSN: 2147-9429 (ONLINE)

URL: <http://dergipark.org.tr/politeknik>



Siyam sinir ağları ve yerel ikili örüntü kullanılarak temassız avuç içi doğrulaması

Contactless palm verification using siamese neural networks and local binary pattern

Yazar(lar) (Author(s)): İmren DAŞDEMİR YAŞAR¹, Hüseyin ÇAKIR², Aysun COŞKUN³

ORCID¹: 0000-0002-3562-9242

ORCID²: 0000-0001-9424-2323

ORCID³: 0000-0002-8541-9497

To cite to this article): Daşdemir Yaşar İ., Çakır H. ve Coşkun A., “Siyam sinir ağları ve yerel ikili örüntü kullanılarak temassız avuç içi doğrulaması”, *Journal of Polytechnic*, 26(4): 1475-1483, (2023).

Bu makaleye şu şekilde atıfta bulunabilirsiniz: Daşdemir Yaşar İ., Çakır H. ve Coşkun A., “Siyam sinir ağları ve yerel ikili örüntü kullanılarak temassız avuç içi doğrulaması”, *Politeknik Dergisi*, 26(4): 1475-1483, (2023).

Erişim linki (To link to this article): <http://dergipark.org.tr/politeknik/archive>

DOI: 10.2339/politeknik.1143420

Siyam Sinir Ağları ve Yerel İkili Örüntü Kullanılarak Temassız Avuç İçi Doğrulaması


Contactless Palm Verification Using Siamese Neural Networks and Local Binary Pattern

Önemli noktalar (Highlights)

- ❖ Siyam Sinir Ağı kullanılarak temassız avuç içi görüntülerinin doğrulanması / Verification of contactless palm images using the Siamese Neural Network
- ❖ Yerel İkili Örüntü yönteminin temassız avuç içi görüntü doğru tanıma oranına etkisi / The effect of the Local Binary Pattern method on the contactless palm image recognition rate

Grafik Özet (Graphical Abstract)

Çalışma Kapsamında Hong Kong Politeknik Üniversitesi Temassız 3B/2B Veri seti (Sürüm 1.0) (PolyU Contactless Database 1.0) kullanılmıştır. Çalışmada, avuç içi görüntüleri doğrudan kullanılarak elde edilen doğrulama sonuçları ile ön işlem olarak Yerel İkili Örüntü (YİÖ) kullanılarak elde edilen doğrulama sonuçları birbirleriyle karşılaştırılmıştır. Doğrulama için Siyam Sinir Ağı kullanılmıştır. / Within the scope of the study, Hong Kong Polytechnic University Contactless 3D/2D Database (Version 1.0) (PolyU Contactless Database 1.0) was used. In the study, the validation results obtained using the palm images directly and the validation results obtained by using Local Binary Pattern (LBP) as a pre-process were compared with each other. Siamese Neural Network was used for validation.



Şekil. Grafik Özet / Figure. Graphical Abstract

Amaç (Aim)

Temassız avuç içi doğrulamasında ön işlem olarak Yerel İkili Örüntü kullanılmasının sonuçlara etkisinin ortaya çıkarılması. / Investigation of the effect of using Local Binary Pattern as a preprocessing on the results in contactless palm verification.

Tasarım ve Yöntem (Design & Methodology)

Siyam Sinir Ağları ve Yerel İkili Örüntü kullanılmıştır. / Siamese Neural Networks and Local Binary Pattern were used.

Özgünlük (Originality)

Temassız avuç içi doğrulaması için Yerel İkili Örüntü ve Siyam Sinir Ağları ilk defa birlikte kullanılmıştır. / Local Binary Pattern and Siamese Neural Networks were used together for the first time for contactless palm verification.

Bulgular (Findings)

Avuç içi görüntüleri doğrudan kullanılarak ve ön işlem olarak Yerel İkili Örüntü kullanılarak elde edilen Eşit Hata Oranları sırasıyla 0,1277 ve 0,0938 olarak gerçekleşmiştir. / Equal Error Rates obtained by using palm images directly and using Local Binary Pattern as preprocessing were 0.1277 and 0.0938, respectively.

Sonuç (Conclusion)

Ön işlem olarak Yerel İkili Örüntü kullanılması temassız avuç içi doğrulama başarısını önemli ölçüde iyileştirmektedir. / The use of Native Binary Pattern as a preprocess significantly improves the success of contactless palm verification.

Etik Standartların Beyanı (Declaration of Ethical Standards)

Bu makalenin yazar(lar)ı çalışmalarında kullandıkları materyal ve yöntemlerin etik kurul izni ve/veya yasal-özel bir izin gerektirmediğini beyan ederler. / The author(s) of this article declare that the materials and methods used in this study do not require ethical committee permission and/or legal-special permission.

Siyam Sinir Ağları ve Yerel İkili Örüntü Kullanılarak Temassız Avuç İçi Doğrulaması

Araştırma Makalesi / Research Article

İmren DAŞDEMİR YAŞAR^{1*}, Hüseyin ÇAKIR², Aysun COŞKUN³

¹Gazi Üniversitesi, Fen Bilimleri Enstitüsü, Bilgi Güvenliği Mühendisliği Bölümü, Ankara/Türkiye

²Gazi Üniversitesi, Eğitim Fakültesi, Bilgisayar ve Öğretim Teknolojileri Eğitimi Bölümü, Ankara/Türkiye

³Gazi Üniversitesi, Teknoloji Fakültesi, Bilgisayar Mühendisliği Bölümü, Ankara/Türkiye

(Geliş/Received : 29.07.2022 ; Kabul/Accepted : 20.09.2022 ; Erken Görünüm/Early View : 24.10.2022)

ÖZ

Biyometrik kimlik doğrulama, kişilerin sahip olduğu fizyolojik veya davranışsal özellikler kullanılarak gerçekten iddia ettikleri kişi olup olmadığının teyit edilmesidir. Avuç içi doğrulama, biyometrik doğrulama içinde en yaygın kullanıma sahip yöntemlerden birisidir. 2019 yılının son aylarında ortaya çıkan COVID-19 (Coronavirus Disease 2019) pandemisi insanların ortak kullanıma sahip nesnelere temas konusundaki duyarlılığını artırmıştır. Bu sebeple, temassız şekilde elde edilen görüntülerin kullanıldığı avuç içi doğrulama çalışmalarının yapılması önem kazanmaktadır. Çalışmada, Hong Kong Politeknik Üniversitesi Temassız 3B/2B Veri Seti (Sürüm 1.0) (PolyU Contactless Database 1.0) kullanılmış olup doğrulama için Siyam Sinir Ağlarından (SSA) yararlanılmıştır. SSA eğitimleri 3.540 adet "benzer" ve 31.152 adet "benzemeyen" olmak üzere toplam 34.692 adet görüntü çifti kullanılarak gerçekleştirilmiştir. Çalışmanın test işlemleri ise 885 adet "gerçek" ve 31.152 adet "sahte" olmak üzere toplam 32.037 adet giriş örneği kullanılarak yapılmıştır. Çalışmada, avuç içi görüntüleri doğrudan kullanılarak elde edilen doğrulama sonuçları ile ön işlem olarak Yerel İkili Örüntü (YİÖ) kullanılarak elde edilen doğrulama sonuçları birbirleriyle karşılaştırılmıştır. Çalışma sonuçları ön işlem olarak YİÖ kullanılmasının doğrulama başarısını önemli ölçüde iyileştirdiğini göstermektedir. Çalışmada, avuç içi görüntüleri doğrudan kullanılarak elde edilen Eşit Hata Oranı (EHO) 0,1277 iken ön işlem olarak YİÖ kullanılarak elde edilen EHO 0,0938 olarak gerçekleşmiştir.

Anahtar Kelimeler: Siyam sinir ağları, yerel ikili örüntü, temassız avuç içi doğrulama.

Contactless Palm Verification Using Siamese Neural Networks and Local Binary Pattern

ABSTRACT

Biometric authentication is the confirmation of whether people are really the person they claim by using their physiological or behavioral characteristics. Palm verification is one of the most widely used methods in biometric verification. The COVID-19 (Coronavirus Disease 2019) pandemic emerging in the last months of 2019 has increased people's sensitivity to contact with objects of common use. In the study, Hong Kong Polytechnic University Contactless 3D/2D Dataset (Version 1.0) (PolyU Contactless Database 1.0) and Siamese Neural Networks (SNN) were used for validation. SNN trainings were carried out using a total of 34,692 pairs of images, of which 3,540 were "similar" and 31,152 were "dissimilar". Testing of the study was carried out using a total of 32,037 input samples, 885 of which were "real" and 31,152 were "fake". In the present study, the validation results were obtained using the palm images directly and the validation results were obtained by using Local Binary Pattern (LBP) as a pre-process. Then, these results were compared with each other. The results of the study show that the use of LBP as a pre-process significantly improves the validation success. In the study, while the Equal Error Rate (EER) obtained by using the palm images directly was 0.1277, the EER obtained by using the LBP as a pre-process was 0.0938.

Keywords: Siamese neural networks, local binary pattern, contactless palm verification

1. GİRİŞ (INTRODUCTION)

Biyometrik kimlik doğrulama, kişilerin sahip olduğu fizyolojik veya davranışsal özellikleri kullanılarak gerçekten iddia ettikleri kişi olup olmadığının teyit edilmesidir. Aynı özellikler kişilerin kimliğinin tespit edilmesi yani tanınmasında da kullanılabilir.

Biyometrik kimlik doğrulama ve tanıma sistemlerinde parmak izi, avuç içi, yüz, iris, retina, kulak, el damarı, DNA bilgisi gibi fizyolojik özellikler veya ses, yürüyüş, imza, klavye tuşlarına basma şekli gibi davranışsal özellikler kullanılmaktadır [1]. Fizyolojik özellikler doğuştan gelen özellikler olup zaman içinde değişmemektedir. Yani, fizyolojik özellikler genel olarak statiktir. Davranışsal özellikler ise fizyolojik özelliklere göre zaman içinde değişim gösterebilmektedir yani daha dinamiktir [2,3]. Bu sebeple, biyometrik kimlik doğrulama ve tanıma sistemlerinde fizyolojik özellikler davranışsal özelliklere göre daha çok tercih edilmektedir.

*Sorumlu Yazar (Corresponding Author)
e-posta : imren.yasar@gazi.edu.tr

Avuç içi doğrulama, biyometrik doğrulama içinde en yaygın kullanıma sahip yöntemlerden birisidir [4]. Günümüzde finans sistemlerinden sağlık sistemlerine, personel takip sistemlerinden güvenlik sistemlerine kadar geniş bir uygulama alanına sahiptir. Avuç içi kullanımının geçmişi on altıncı yüzyıla kadar dayanmakta olup ilk çalışmalar Çin'de yapılmıştır [5]. On altıncı ile yirminci yüzyıl arasında avuç içi üzerine birçok temel çalışma gerçekleştirilmiştir. Avuç içi kanıtları, 1930'lu yıllarda Büyük Britanya'da biyometrik kanıt olarak kabul edilmiştir [4]. Bilgisayarların ve buna bağlı olarak finans, sağlık, güvenlik gibi sektörlerde hizmet eden dijital sistemlerin yaygınlaşmasıyla kimlik doğrulama sistemlerine olan ihtiyaç artmaya başlamıştır. 1990 yıllardan itibaren avuç içi doğrulama ve tanıma üzerine birçok çalışma gerçekleştirilmiştir. 2015 yılına kadar gerçekleştirilen avuç içi doğrulama çalışmaları genel olarak avuç içi ilgi alanının belirlenmesi, avuç içi özelliklerinin çeşitli özellik çıkarma yöntemleri (Ayrık Kosinüs Dönüşümü, Ayrık Dalgacık Dönüşümü, Yerel İkili Örüntü (YİÖ) gibi) ile elde edilmesi ve klasik sınıflandırıcı (Öklid Mesafesi gibi) veya makine öğrenmesi sınıflandırıcılar (Destek Vektör Makinesi, k-En Yakın Komşu gibi) kullanılarak eşleştirilmesini esas almaktadır.

Derin öğrenme, klasik sınıflandırıcı veya makine öğrenmesi sınıflandırıcı kullanılırken ayrı bir aşamada gerçekleştirilen özellik çıkarma işlemlerini otomatik olarak yapmaktadır [6-8]. Bu açıdan özellik çıkarma ve eşleştirme işlemlerini bünyesinde birleştirmekte ve tek bir aşamada gerçekleştirmektedir. Sınıflandırma, bölütleme, eşleştirme gibi konu başlıklarında derin öğrenme yöntemlerinin makine öğrenmesi yöntemlerine göre daha başarılı sonuçlar sağladığı birçok çalışma ile ortaya konulmuştur. Bilgisayar kapasitelerinin derin öğrenmenin çalıştırılması için yeterli seviyeye ulaşması 2010'lu yılların ilk yarısında gerçekleşmiştir. 2015 yılından itibaren biyometrik kimlik doğrulama ve tanıma için derin öğrenme yöntemlerinin kullanıldığı birçok çalışma gerçekleştirilmiştir. Bu kapsamda, Otokodlayıcı ve Evrişimsel Sinir Ağları (ESA) en çok çalışmaya konu olan derin öğrenme yöntemleridir. Otokodlayıcı genel olarak özellik boyutlarının azaltılmasında kullanılmaktadır. ESA ise bünyesinde birçok evrişim işlemi gerçekleştirerek görüntülerin özelliklerinin derinlemesine çıkarılmasını ve eşleştirilmesini (sınıflandırılmasını) sağlamaktadır.

Siyam Sinir Ağları (SSA), ESA'nın özel bir türüdür. Genel olarak ESA, sınıflandırma işlemlerinde test örneğinin hangi sınıfa ait olduğuna odaklanmaktadır. SSA ise test örneği çiftlerinin birbirlerine benzeyip benzemediğini gösteren iki sınıflı bir eşleştirme gerçekleştirilmektedir. Biyometrik kimlik doğrulama sistemleri, kişi tarafından sisteme girilen biyometrik veriyi analiz etmektedir. Analiz sonucunda, kişinin daha önce veri tabanında yer alan biyometrik kaydı ile eşleştirme yapılmaktadır. Bu açıdan, SSA'nın biyometrik kimlik doğrulama sistemlerinde kullanılmaya oldukça uygun bir yapısı vardır.

SSA'nın avuç içi doğrulama sistemlerinde kullanılmasına ilişkin ilk çalışma 2018 yılında Zhong ve arkadaşları tarafından gerçekleştirilmiştir [9]. VGG-16 mimarisi ile ilişkili bir SSA kullanılan çalışmada PolyU multispektral veri seti (500 gönüllüden elde edilen 6000 örnek) ve XJTU veri seti (114 gönüllüden elde edilen 2078 örnek) olmak üzere iki farklı veri setinden yararlanılmıştır. Çalışmada öncelikle, VGG-16 mimarisi çok sınıflı avuç içi sınıflandırma gerçekleştirmek üzere eğitilmiştir. VGG-16 mimarisinin eğitimler sonucunda elde edilen bazı katman ağırlıkları SSA'ya transfer edilmiştir. Her gönüllüye ait örneklerden ikişer tanesi ile gerçekleştirilen eğitim işlemlerinde pozitif ve negatif örnekler arasında 1:2 oranı kullanılmıştır. Çalışma sonucunda Eşit Hata Oranı (EHO) söz konusu veri setleri için sırasıyla %0,2819 ve %4,559 olarak elde edilmiştir.

2019 yılında Thapar ve arkadaşları tarafından SSA kullanılarak gerçekleştirilen multispektral görüntülerden avuç damar izi doğrulama çalışmasının eğitim işlemlerinde üçlü kayıp ve uyarlanabilir sert madencilik yaklaşımı kullanılmıştır [10]. Çalışmada Otokodlayıcı kullanılarak özellik kümesinin boyutlarının azaltılması, ESA kullanılarak yeni özellik görüntülerin oluşturulması ve SSA kullanılarak görüntülerin eşleştirilmesi yapılmıştır. CASIA (200 gönüllüye ait örnekler), IITI Vein (370 gönüllüye ait örnekler) ve PolyU (500 gönüllüye ait örnekler) multispektral veri setleri kullanılarak gerçekleştirilen çalışma sonucunda veri setleri için EHO sırasıyla %3,71; %0,93 ve %0,66 olarak gerçekleşirken Doğru Tanıma Oranları (DTO) ise sırasıyla %85,16; %97,47 ve %98,78 olarak hesaplanmıştır.

2019 yılında Du ve arkadaşları tarafından gerçekleştirilen avuç içi doğrulama çalışmasında meta SSA'dan yararlanılmıştır [11]. Çalışmada, SSA eğitim maliyetinin azaltılması için n-yollu k-atış (n-way k-shot) yaklaşımı kullanılmıştır. Bu yaklaşımda ESA yardımıyla atış sayısı kadar örneğin özellikleri birleştirilmekte ve yoğunlaştırılmaktadır. PolyU multispektral veri seti (500 gönüllüden elde edilen 6000 örnek) kullanılarak gerçekleştirilen çalışmada eğitim ve test işlemleri %80 eğitim ve %20 test ayrışımına göre gerçekleştirilmiştir. Çalışmada 5-yollu 1-atış, 5-yollu 3-atış, 5 yollu 5-atış, 15-yollu 1-atış, 15-yollu 3-atış ve 15 yollu 5-atış olmak üzere altı farklı senaryo için eğitim ve test işlemleri gerçekleştirilmiştir. Çalışma sonucunda en yüksek DTO %97,3 olarak hesaplanmıştır. Aynı yıl benzer bir çalışma Liu ve arkadaşları tarafından Karma SSA kullanılarak gerçekleştirilmiştir [12]. Çalışmada PolyU multispektral veri seti (500 gönüllüden elde edilen 6000 örnek) kullanılmıştır. Görüntü filtreleme, ilgi alanı çıkartma ve boyut ayarlama ön işlemlerinden sonra SSA kullanılarak eşleştirme gerçekleştirilmiştir. Bu aşamada eğitimlerde n-yollu k-atış yaklaşımı kullanılmıştır. Çalışmanın deneyleri %80 eğitim ve %20 test ayrışımına göre yapılmıştır. Çalışmada 5-yollu 1-atış, 5-yollu 3-atış, 5 yollu 5-atış, 10-yollu 1-atış, 10-yollu 3-atış ve 10 yollu 5-atış olmak üzere altı farklı senaryo için eğitim ve test işlemleri gerçekleştirilmiştir. Çalışma sonucunda en

yüksek DTO %96,25 olarak hesaplanmıştır. Söz konusu çalışmanın genişletilmiş versiyonu 2021 yılında Shoa ve arkadaşları tarafından yayınlanmıştır [13].

Literatürde SSA ile gerçekleştirilen avuç içi tanıma çalışmalarında genellikle multispektral görüntüler içeren ve bir cihaza temas ile toplanan veriler kullanıldığı görülmektedir. Ancak, doğrulama işlemi esnasında avuç içi görüntüsünün elde edilmesini sağlayacak bir cihaza ihtiyaç duyulması hem maliyetli hem de kısıtlayıcı bir durumdur. Ayrıca, 2019 yılının son aylarında ortaya çıkan COVID-19 (Coronavirus Disease 2019) pandemisi insanların ortak kullanıma sahip nesnelere temas konusundaki duyarlılığını artırmıştır. Bir diğer önemli husus ise pandemi sürecinde zaman zaman uygulanan sokağa çıkma yasakları sebebiyle bu cihazlara erişiminde kısıtlanmış olmasıdır. Bu sebeple, temassız şekilde elde edilen verilerin kullanıldığı avuç içi doğrulama çalışmalarının yapılması daha da önem kazanmaktadır.

Literatürde daha önce gerçekleştirilen bazı avuç içi doğrulama çalışmalarında [4] derin öğrenme yöntemlerinin Destek Vektör Makinesi, k-En Yakın Komşu gibi klasik makine öğrenmesi yöntemlerine göre daha başarılı olduğu gösterildiği için bu çalışma doğrudan derin öğrenme yöntemlerinden biri olan SSA üzerine yoğunlaşmıştır. Makale çalışmasında, temassız avuç içi doğrulaması için SSA'dan yararlanılmıştır. Genel olarak, SSA ile gerçekleştirilen literatür çalışmalarında avuç içi görüntüsünün doğrudan veya normalizasyon gibi basit ön işlemler yapılarak kullanıldığı görülmektedir. Bu aşamada, görüntü özellikleri evrişim işlemleriyle otomatik olarak ortaya çıkarılmaktadır. Genel olarak, temassız şekilde elde edilen avuç içi görüntüleri bir cihaz yardımı ile elde edilen temaslı avuç içi görüntülerine göre global ve özellikle lokal özellikleri yansıma açısından daha düşük kalitededir. Bu çalışmanın temel amacı, temassız avuç içi görüntülerine ön işlem olarak özellik çıkarma yöntemi uygulanmasıyla global ve yerel özelliklerin daha belirgin hale getirilip getirilemeyeceğinin ortaya çıkarılmasıdır. Çalışmada, avuç içi görüntülerinin doğrudan kullanılmasıyla elde edilen doğrulama sonuçları ile ön işlem olarak YİÖ kullanılarak elde edilen doğrulama sonuçları birbirleriyle karşılaştırılmıştır.

Makale çalışmasının literatüre sağladığı katkılar aşağıda sıralanmıştır.

- Multispektral avuç içi görüntülerinin doğrulanmasında daha önce sıklıkla kullanılan SSA ilk kez temassız avuç içi görüntülerinin doğrulanmasında kullanılmıştır.
- SSA ve YİÖ avuç içi doğrulaması için ilk defa birlikte kullanılmıştır. Çalışma sayesinde YİÖ'nin ön işlem olarak kullanılmasının SSA kullanılarak gerçekleştirilen doğrulama sonuçlarına etkisi ortaya çıkarılmıştır.

2. MATERYAL VE METOD (MATERIAL AND METHOD)

2.1. Veri Seti (Data Set)

Çalışmada, Hong Kong Politeknik Üniversitesi Temassız 3B/2B Veriseti (Sürüm 1.0) (PolyU Contactless Database 1.0) kullanılmıştır [14]. Veri seti temassız şekilde elde edilmiş 3 boyutlu ve 2 boyutlu el görüntülerini içermektedir. Veri seti içinde yer alan el görüntüleri 177 farklı gönüllüden toplanmıştır. Gönüllülerin yaşı 18 ile 55 arasında değişmektedir. Her gönüllüden 10 farklı örnek alınmıştır. Bu örneklerin yarısı birinci aşama çekimlerde kalan yarısı ise bir hafta ile üç ay arasında değişen süreler sonrasında gerçekleştirilen ikinci aşama çekimlerde elde edilmiştir. Veri seti içinde el görüntülerinin 640×480 çözünürlükteki orijinal hallerinin yanı sıra avuç içi ilgi alanının bölütlenmesiyle elde edilen 128×128 çözünürlükteki versiyonları da yer almaktadır. Çalışmada doğrudan ilgi alanı çıkarılmış 128×128 çözünürlükteki 1.770 adet avuç içi görüntüsü kullanılmıştır.


Çalışmada, her gönüllüye ait görüntülerin ilk yarısı eğitim işlemlerinde ikinci yarısı ise test işlemlerinde kullanılmıştır. SSA eğitiminde her gönüllüye ait ilk 5 örnek kendi içinde eşleştirilerek "benzer" giriş çiftleri elde edilmiştir. Bu kapsamda her gönüllü için 5×4 olmak üzere 20 adet "benzer" görüntü çifti oluşturulmuştur. Toplamda 177 gönüllü için 3.540 adet "benzer" etiketli görüntü çifti elde edilmiştir. Veri seti içinde yer alan görüntüler kullanılarak çok fazla sayıda "benzemeyen" etiketli görüntü çiftinin oluşturulması mümkündür. Ancak, eğitim seti içinde veri dengesizliği oluşmasının önüne geçilmesi için her gönüllüye ait ilk görüntüler diğer gönüllülerin ilk görüntüleri ile eşleştirilerek "benzemeyen" görüntü çiftleri elde edilmiştir. Bu kapsamda 177×176 olmak üzere toplamda 31.152 adet "benzemeyen" etiketli görüntü çifti oluşturulmuştur. Sonuç olarak SSA eğitimleri 3.540 "benzer" ve 31.152 "benzemeyen" olmak üzere toplam 34.692 görüntü çifti kullanılarak gerçekleştirilmiştir.

Çalışmada test işlemlerinde kullanılacak "gerçek" girişlerin oluşturulması, her gönüllüye ait ikinci 5 görüntü kullanılarak gerçekleştirilmiştir. Bu kapsamda, her "gerçek" test görüntüsü eğitimlerde kullanılan ilk 5 görüntü ile ayrı ayrı eşleştirilmiş ve SSA ile benzerlik skorları hesaplanmıştır. Test görüntüsünün sonuç benzerlik skoru bu 5 benzerlik skorunun ortalaması alınarak bulunmuştur. Çalışmada 177×5 olmak üzere toplam 885 "gerçek" giriş için test işlemleri gerçekleştirilmiştir. Test işlemleri için birçok "sahte" giriş oluşturulması mümkündür. Ancak, "gerçek" giriş sayısı ile aşırı dengesizlik oluşmaması için "sahte" girişler her gönüllü haricindeki 176 gönüllünün altıncı görüntüleri kullanılarak oluşturulmuştur. Bu kapsamda, 177×176 olmak üzere toplamda 31.152 adet "sahte" giriş elde edilmiştir. Her "sahte" test görüntüsü eğitimlerde kullanılan ilk 5 görüntü ile ayrı ayrı eşleştirilmiş ve SSA ile benzerlik skorları hesaplanmıştır. Test görüntüsünün

sonuç benzerlik skoru bu 5 benzerlik skorunun ortalaması alınarak bulunmuştur.

Çalışmada öncelikle, avuç içi görüntüleri doğrudan kullanılarak biyometrik doğrulama yapılmıştır. Bu kapsamda, 128×128 çözünürlükteki orijinal avuç içi görüntüleri kullanılarak SSA eğitilmiş ve test işlemleri gerçekleştirilmiştir. Daha sonra, ön işlem olarak YİÖ kullanılarak biyometrik doğrulama yapılmıştır. YİÖ uygulanması görüntünün boyutlarında küçük bir azalmaya neden olmaktadır. Bu kapsamda, 126×126 çözünürlükteki YİÖ avuç içi özellik görüntüleri

kullanılarak SSA eğitilmiş ve test işlemleri gerçekleştirilmiştir. Bu aşamada kullanılan “benzer” ve “benzemeyen” görüntü çiftlerinin elde edilmesi ile “gerçek” ve “sahte” test girişlerinin oluşturulmasında aynı prosedürler kullanılmıştır. Bu kapsamda tek farklılık avuç içi görüntünün doğrudan veya ön işlem olarak YİÖ uygulanmış halinin kullanılmasındadır. Şekil 1(a)’da çalışmada kullanılan örnek bir “benzer” görüntü çiftinin orijinal ve YİÖ uygulanmış hali görülmektedir. Şekil 1(b)’de ise çalışmada kullanılan örnek bir “benzemeyen” görüntü çiftinin orijinal ve YİÖ uygulanmış hali verilmiştir.

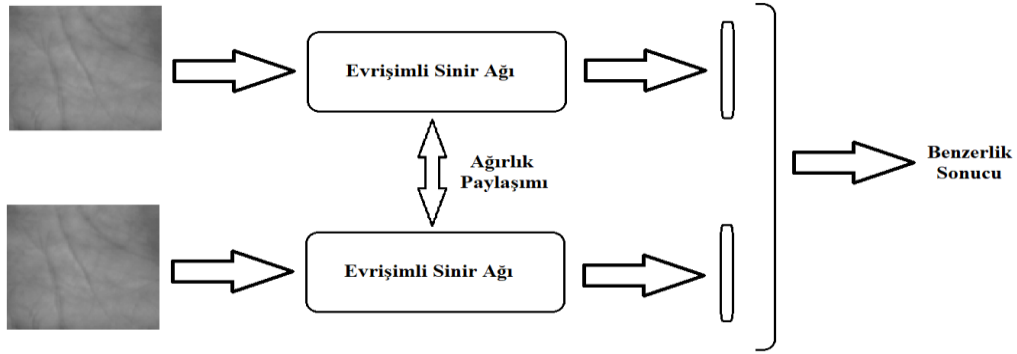


Şekil 1. Çalışmada kullanılan örnek bir a) “benzer” ve b) “benzemeyen” görüntü çiftinin orijinal ve YİÖ uygulanmış hali (The original and LBP features of a sample a) “similar” and b) “dissimilar” image pair used in the study)


2.2. Siyam Sinir Ağları (Siamese Neural Networks)

Siyam Sinir Ağları (SSA), birbiri ile bire bir aynı iki ESA'nın ağırlıklarının ortaklaşa kullanılmasıyla oluşturulmaktadır [15]. Bu sayede, ESA'ya verilen giriş çiftlerinin birbirleri ile “benzer” veya “benzemeyen” olduğuna karar verilmektedir. SSA'nın ilk uygulaması Yapay Sinir Ağlarının ortaklaşa kullanılmasıyla gerçekleştirilmiştir. Konvolüsyon katmanları ile Yapay Sinir Ağları birleştirilerek ESA kullanımının yaygınlaşmasıyla uygulamaya yoğunluğu bu yöne kaymıştır. SSA'nın genel çalışma yapısı Şekil 2’de verilmiştir. Çalışma kapsamında uygulamaya özel bir mimari tasarlanmıştır. Çalışmada kullanılan SSA mimarisinin katman yapısı ve parametreleri ise Çizelge 1 ve Şekil 3’de yer almaktadır. Çalışmada yazılımlar MATLAB

2022-a programı kullanılarak oluşturulmuştur. Çizelge 1’de yer alan katmanlar, parametreler ve varsayılan değerler hakkında MathWorks sayfasından [16] bilgi alınması mümkündür. Çalışmada gerçekleştirilen bütün deneylerde söz konusu SSA mimarisi kullanılmıştır. Bu aşamada tek farklılık, imageInputLayer katmanı giriş büyüklüğünün avuç içi görüntüsünün doğrudan kullanıldığı deneylerde [128 128 1], YİÖ özellik görüntüleri kullanıldığı deneylerde [126 126 1] olarak belirlenmesidir. Çalışmada SSA eğitiminde mini küme boyutu 128, iterasyon sayısı ise 10.000, öğrenme oranı $6e-5$ ve bozulma derecesi ise 0,9 olarak belirlenmiştir. Çalışmada SSA eğitimlerinde geçen süre de ölçülmüştür. Çalışmanın deneyleri, MATLAB 2022-a programı kullanılarak İntel(R) Core (TM) i7-8565U CPU@1,80 GHz bir bilgisayar ile gerçekleştirilmiştir.



Şekil 2. SSA'nın genel çalışma yapısı (General operating structure of the SNN)



Şekil 3. Çalışmada kullanılan SSA mimarisinin blok gösterimi (Block representation of the SNN architecture used in the study)


Çizelge 1. Çalışmada kullanılan SSA mimarisi (SNN architecture used in the study)

Katman Numarası	Katman İsmi	Katman Parametreleri
1	imageInputLayer	[128 128 1],Normalization="none"; [126 126 1],Normalization="none"
2	convolution2dLayer	10,8,WeightsInitializer="narrow-normal",BiasInitializer="narrow-normal"
3	ReLU	default
4	maxPooling2dLayer	2,Stride=2
5	convolution2dLayer	7,16,WeightsInitializer="narrow-normal",BiasInitializer="narrow-normal"
6	ReLU	default
7	maxPooling2dLayer	2,Stride=2
8	convolution2dLayer	4,16,WeightsInitializer="narrow-normal",BiasInitializer="narrow-normal"
9	ReLU	default
10	maxPooling2dLayer	2,Stride=2
11	convolution2dLayer	3,32,WeightsInitializer="narrow-normal",BiasInitializer="narrow-normal"
12	ReLU	default
13	fullyConnectedLayer	1024,WeightsInitializer="narrow-normal",BiasInitializer="narrow-normal")

2.3. Yerel İkili Örüntü (Local Binary Pattern)

Yerel İkili Örüntü (YİÖ), yerel mekansal yapıların ortaya çıkarılması için 1996 yılında ortaya atılmıştır [17]. YİÖ

bir merkez pikselin komşuları ile karşılaştırılmasını esas almaktadır. Şekil 4'de YİÖ yönteminin matematiksel olarak işletilmesi uygulamalı olarak görülmektedir.



Şekil 4. YİÖ hesaplama örneği (LBP calculation example)

2.4. Değerlendirme Kriterleri (Evaluation Criteria)

Çalışmada deney sonuçlarının değerlendirilmesinde Alıcı İşlem Karakteristiği Eğrisi (AİKE) ve bu eğri altında kalan alandan (Az) yararlanılmıştır. AİKE, bir sınıflandırma işleminde etiketlendirmeyi sağlayan eşik değerin minimum değerden maksimum değere doğru değişirken Duyarlılık parametresinin 1-Özgüllük parametresine göre değişimini yansıtmaktadır. Doğrulama sistemlerinde Duyarlılık parametresinin bir diğer ismi Doğru Kabul Oranıdır (DKO) ve doğrulama sisteminde kabul edilen gerçek girişlerin sayısının toplam gerçek giriş sayısına oranını yansıtmaktadır. Doğrulama sistemlerinde 1-Özgüllük parametresinin bir diğer ismi Yanlış Kabul Oranıdır (YKO) ve doğrulama sisteminde kabul edilen sahte girişlerin sayısının toplam sahte giriş sayısına oranını yansıtmaktadır. Eşitlik (1) ve Eşitlik (2), sırasıyla DKO ve YKO parametrelerinin matematiksel olarak hesaplanmasını göstermektedir. Bu eşitliklerde, DP (Doğru Pozitif) kabul edilen gerçek

girişlerin sayısını, YP (Yanlış Pozitif) kabul edilen sahte girişlerin sayısını, DN (Doğru Negatif) ret edilen sahte girişlerin sayısını ve YN (Yanlış Negatif) ret edilen gerçek girişlerin sayısını ifade etmektedir. AİKE altında kalan alanın (Az) 1 değerine yaklaşması sınıflandırmanın daha başarılı yapıldığını göstermektedir. Bu eğri üzerinde Duyarlılık ve Özgüllük parametrelerinin birbirine eşit olduğu değer Eşit Hata Oranı (EHO) parametresi olarak tanımlanmaktadır. EHO parametresinin 0 değerine yaklaşması sınıflandırmanın daha başarılı yapıldığını göstermektedir.

Sistem doğruluğu veya bir diğer deyişle Doğru Tanıma Oranı (DTO), doğru olarak eşleştirilen girişlerin sayısının toplam giriş sayısına oranını ifade etmektedir. DTO, matematiksel olarak Eşitlik (3) kullanılarak hesaplanmaktadır. DTO parametresinin birçok etiketlendirme eşik değeri için hesaplanması mümkündür. Çalışmada bu parametre EHO'yu sağlayan eşik değeri için hesaplanmış ve paylaşılmıştır.

$$\text{Duyarlılık} = \text{Doğru_Kabul_Oranı} = DP / (DP + YN) \quad (1)$$

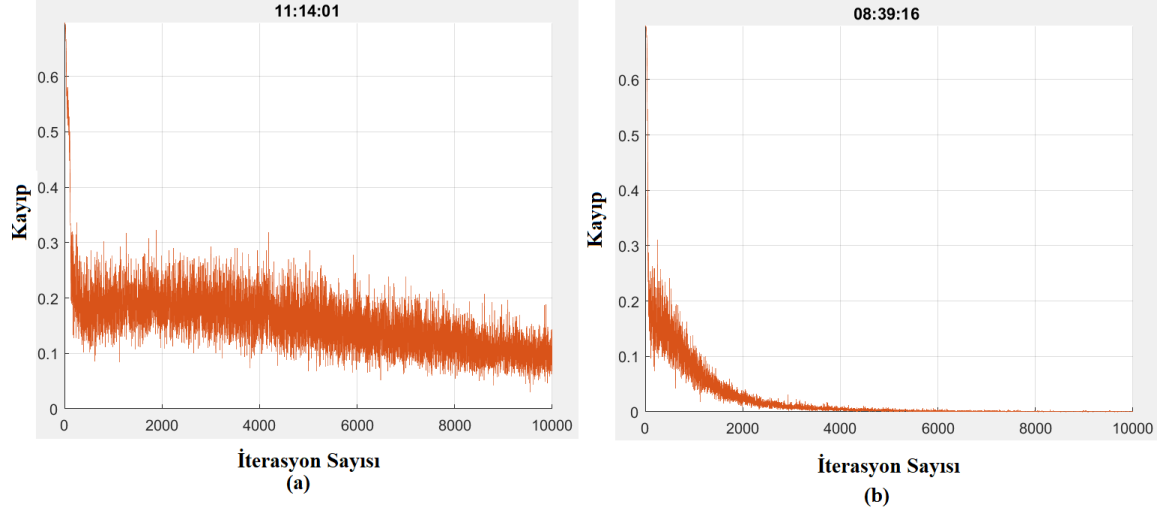
$$1 - \text{Özgüllük} = \text{Yanlış_Kabul_Oranı} = YP / (YP + DN) \quad (2)$$

$$\text{Doğruluk} = \text{Doğru_Tanıma_Oranı} = DP + DN / (DP + DN + YP + YN) \quad (3)$$

3. DENEY SONUÇLARI (EXPERIMENT RESULTS)

SSA eğitiminde, avuç içi görüntülerinin doğrudan ve ön işlem olarak YİÖ kullanımlarına ilişkin iterasyon sayısı ile kayıp değeri değişimini gösteren eğitim grafikleri Şekil 5’de yer almaktadır. Şekil 5’de ayrıca, eğitim işlemlerinde geçen toplam süreler de verilmiştir. Bu kapsamda, avuç içi görüntülerinin doğrudan kullanılması

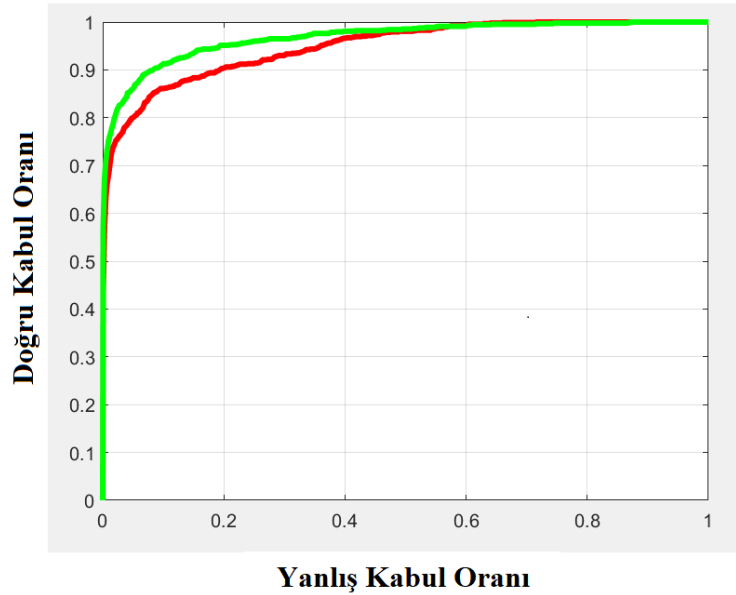
durumunda eğitim işlemlerinin 11 saat 14 dakika sürdüğü görülmektedir. YİÖ özellik görüntüleri kullanılması durumunda ise eğitim işlemlerinin 8 saat 39 dakika sürdüğü görülmektedir. Çizelge 2’de test işlemleri sonucunda EHO’yu sağlayan eşik değeri için elde edilen DP, YP, DN, YN, DKO, YKO ve DTO parametreleri ile Az ve EHO sonuçları yer almaktadır. Şekil 6’da ise AIKE grafiklerinin karşılaştırılması görülmektedir.



Şekil 5. SSA eğitiminde a) avuç içi görüntülerinin doğrudan b) YİÖ görüntüleri kullanımlarına ilişkin eğitim grafikleri (Training graphics for the use of a) palm images directly b) LBP images in SNN training)

Çizelge 2. Deneysel sonuçları (Experiment results)

Görüntü Tipi	DP	YN	DN	YP	DKO	YKO	DTO	Az	EHO
Orijinal Görüntü	772	113	27.174	3.978	0,8723	0,1277	0,8723	0,94829	0,1277
YİÖ Özellik Görüntüsü	802	83	28.230	2.922	0,9062	0,0938	0,9062	0,96702	0,0938



Şekil 6. Deneysel sonuçları elde edilen AIKE grafiklerinin karşılaştırması (Kırmızı Çizgi: Avuç içi görüntülerinin doğrudan kullanılması, Yeşil Çizgi: YİÖ özellik görüntülerinin kullanılması) (Comparison of the Receiver Transaction Characteristic Curve graphs obtained as a result of the experiments (Red Line: Direct use of palm images, Green Line: Use of LBP feature images))

4. TARTIŞMA VE SONUÇ (DISCUSSION AND CONCLUSION)

Çalışmada, Hong Kong Politeknik Üniversitesi Temassız 3B/2B Veriseti (Sürüm 1.0) (PolyU Contactless Database 1.0) kullanılmış olup doğrulama için SSA'dan yararlanılmıştır. SSA eğitimleri 3.540 adet "benzer" ve 31.152 adet "benzemeyen" olmak üzere toplam 34.692 adet görüntü çifti kullanılarak gerçekleştirilmiştir. Çalışmanın test işlemleri ise 885 adet "gerçek" ve 31.152 adet "sahte" olmak üzere toplam 32.037 adet giriş örneği kullanılarak yapılmıştır. Çalışmada, avuç içi görüntüleri doğrudan kullanılarak elde edilen doğrulama sonuçları ile ön işlem olarak YİÖ kullanılarak elde edilen doğrulama sonuçları birbirleriyle karşılaştırılmıştır.

Çalışmada elde edilen sonuçlar incelendiğinde ön işlem olarak YİÖ kullanılmasının DTO, Az ve EHO parametrelerinin tamamında iyileşme sağladığı görülmektedir. Bu kapsamda DTO ve EHO parametrelerinde %3,390 iyileşme sağlanmıştır. Az parametresinde ise %1,874 artış olduğu görülmektedir. Bu kapsamda en yüksek DTO 0,9062; en yüksek Az 0,967 ve en düşük EHO 0,0938 olarak elde edilmiştir. SSA eğitim grafikleri incelendiğinde ön işlem olarak YİÖ kullanılmasının eğitim süreçlerinde de önemli bir iyileşme sağladığı görülmektedir.

Çalışmanın eğitim süreçlerinde ve test sonuçlarında YİÖ kullanımına bağlı olarak ortaya çıkan iyileşmenin temel sebebi, YİÖ kullanılarak temassız avuç içine ait global ve lokal özelliklerinin daha belirgin hale getirilmesinden kaynaklanmaktadır. Temassız avuç içi görüntülerin elde edilmesi sırasında görüntülerinin elde edildiği mesafe ve ortam aydınlatma farklılıklarına bağlı olarak görüntüler üzerinde çeşitli gürültüler oluşmaktadır. Bu durum avuç içine ait global özelliklerinin algılanmasını kısmi olarak etkilerken lokal özelliklerin algılanmasında ciddi zorluklara sebep olmaktadır. YİÖ görüntüler üzerindeki küçük piksel farklılıklarını ortadan kaldırarak lokal özelliklerin daha stabil hale gelmesini sağlamaktadır. Ayrıca, global özellikleri daha da belirgin hale getirmektedir.

Literatürde SSA kullanılarak avuç içi doğrulama yapılması üzerine gerçekleştirilen geçmiş çalışmaların özet bilgileri Çizelge 3'de yer almaktadır.

Çalışmada ulaşılan sonuçlar ile Çizelge 3'de yer alan çalışma sonuçları karşılaştırıldığında çalışmada daha düşük sonuçlar elde edildiği görülmektedir. Ancak, bu aşamada dikkate alınması gereken en önemli husus, Çizelge 3'de yer alan çalışmalarda kullanılan görüntülerin multisepektral ve bir cihaza temas ile toplanmış nitelikte olmasıdır.

Cihaza temas ile toplanan görüntüler genel olarak 5 ile 10 santimlik bir mesafeden elde edilmektedir. Bu sebeple avuç içinde yer alan lokal özellikleri daha belirgin şekilde yansıtmaktadır. Ayrıca, cihazın her seferinde stabil bir aydınlatma gerçekleştirilmesi avuç içi görüntüler üzerinde oluşan gürültü miktarını azaltmaktadır. Çalışma kapsamında kullanılan temassız avuç içi görüntüleri 70 santimetrelik bir uzaklıktan elde edilmiştir. Bu sebeple

Çizelge 3. SSA kullanılarak gerçekleştirilen geçmiş avuç içi doğrulama çalışmalarının özet bilgileri (Summary of previous palm validation studies using SNN)

Çalışma	Veri Seti	DTO	EHO
Zhong ve ark. [9]	PolyU ve XJTU multispektral	X	%0,2819 ve %4,559
Thapar ve ark. [10]	CASIA, IITI Vein ve PolyU multispektral	%85,16 %97,47 ve %98,78	%3,71 %0,93 ve %0,66
Du ve ark. [11]	PolyU multispektral	%97,3	X
Liu ve ark. [12]	PolyU multispektral	%96,25	X

avuç içinin lokal özelliklerini yansıtmaması açısından daha düşük kalitedir. Bir diğer önemli husus ise temassız avuç içi görüntülerinin elde edildiği mesafe ve ortam aydınlatma farklılıklarına bağlı olarak daha fazla gürültü içermesidir. Bu hususlar dikkate alınarak bir karşılaştırma yapıldığında, YİÖ kullanımının da katkısıyla çalışma sonucunda DTO parametresinin %90 seviyesini aşması önemli bir netice olarak değerlendirilmektedir.

Çalışma sonuçları SSA'nın temassız avuç içi doğrulaması için kayda değer başarılı sonuçlar sağladığı ve iyi bir alternatif olduğunu göstermektedir. Temassız avuç içi doğrulama başarısının artırılması için gelecek çalışmalarda YİÖ dışındaki diğer özellik çıkarma yöntemleri kullanılmasının yararlı olabileceği değerlendirilmektedir. Ayrıca, SSA mimari tasarımının geliştirilmesinin sonuçlara olumlu yansıtacağı öngörülmektedir.

ETİK STANDARTLARIN BEYANI (DECLARATION OF ETHICAL STANDARDS)

Bu makalenin yazar(lar)ı çalışmalarında kullandıkları materyal ve yöntemlerin etik kurul izni ve/veya yasal-özel bir izin gerektirmediğini beyan ederler.

YAZARLARIN KATKILARI (AUTHORS' CONTRIBUTIONS)

İmren DAŞDEMİR YAŞAR: Deneyleri yapmış ve sonuçlarını analiz etmiştir.

Hüseyin ÇAKIR: Makalenin organizasyonu ve danışmanlığını yapmıştır.

Aysun COŞKUN: Makalenin organizasyonu ve danışmanlığını yapmıştır.

ÇIKAR ÇATIŞMASI (CONFLICT OF INTEREST)

Bu çalışmada herhangi bir çıkar çatışması yoktur.

KAYNAKLAR (REFERENCES)

- [1] Richiardi J. and Drygajlo A., “Gaussian mixture models for on-line signature verification”, *Proceedings of the 2003 ACM SIGMM workshop on Biometrics methods and applications*, Berkley, California, 115–122, (2003).
- [2] Bowyer K.W., “Introduction to the special issue on recent advances in biometrics”, *IEEE Transactions on Systems, Man, and Cybernetics-Part A: Systems and Humans*, 40(3): 434–436, (2010).
- [3] Veeramachaneni K., Osadciw L.A. and Varshney P.K., “An adaptiv multimodal biometric management algorithm”, *IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews)*, 35(3): 344–356, (2005).
- [4] Hardalac F., Yaşar H., Akyel A. and Kutbay U., “A novel comparative study using multi-resolution transforms and convolutional neural network (CNN) for contactless palm print verification and identification”, *Multimedia Tools and Applications*, 79(31): 22929–22963, (2020).
- [5] Cummins H. and Midlo C., “*Finger Prints, Palms and Soles: An Introduction to Dermatoglyphics (Vol. 319)*”, Dover Publications, New York, (1961).
- [6] Şenalp F.M. and Ceylan M., “Termal yüz görüntülerinden oluşan yeni bir veri seti için derin öğrenme tabanlı süper çözünürlük uygulaması”, *Politeknik Dergisi*, Erken Görünüm, (2022).
- [7] Korkmaz Ş. and Alkan M., “Derin öğrenme algoritmalarını kullanarak deepfake video tespiti”, *Politeknik Dergisi*, Erken Görünüm, (2022).
- [8] Gençaslan S., Utku A. and Akcayol M.A., “Derin öğrenme tabanlı video üzerinde olay sınıflandırma”, *Politeknik Dergisi*, Erken Görünüm, (2022).
- [9] Zhong D., Yang Y. and Du X., “Palmprint recognition using siamese network”, *Chinese Conference on Biometric Recognition*, Zhuzhou, 48–55, (2018).
- [10] Thapar D., Jaswal G., Nigam A. and Kanhangad V., “PVSNet: Palm vein authentication siamese network trained using triplet loss and adaptive hard mining by learning enforced domain specific features”, *2019 IEEE 5th International Conference on Identity, Security, and Behavior Analysis (ISBA)*, Hyderabad, 1–8, (2019).
- [11] Du X., Zhong D. and Li P., “Low-shot palmprint recognition based on meta-siamese network”, *2019 IEEE International Conference on Multimedia and Expo (ICME)*, Shanghai, 79–84, (2019).
- [12] Liu C., Shao H., Zhong D. and Du J., “Siamese-hashing network for few-shot palmprint recognition”, *2019 IEEE Symposium Series on Computational Intelligence (SSCI)*, Xiamen, 3251–3258, (2019).
- [13] Shao H., Zhong D., Du X., Du S. and Veldhuis R.N., “Few-shot learning for palmprint recognition via meta-siamese network”, *IEEE Transactions on Instrumentation and Measurement*, 70: 1–12, (2021).
- [14] https://www4.comp.polyu.edu.hk/~csajaykr/myhome/data_base_request/3dhand/Hand3D.htm
- [15] Chicchón M. and Huerta R., “Semantic segmentation using convolutional neural networks for volume estimation of native potatoes at high speed”, *Annual International Conference on Information Management and Big Data*, Lima, 236–249, (2020).
- [16] www.mathworks.com, “Train a Siamese Network to Compare Images”, (2022).
- [17] Ojala T., Pietikäinen M. and Harwood D., “A comparative study of texture measures with classification based on featured distributions”, *Pattern Recognition*, 29 (1): 51–59, (1996).