

Yüz Tanıma Sistemlerinde Yerel Özniteliklerin Kullanılması

Using Local Features in Face Recognition Systems

Yıldız AYDIN¹, Funda AKAR²

¹Bilgisayar Mühendisliği Bölümü, Erzincan Üniversitesi, Erzincan, Türkiye
yciltas@erzincan.edu.tr

²Bilgisayar Mühendisliği Bölümü, Erzincan Üniversitesi, Erzincan, Türkiye
fakar@erzincan.edu.tr

Özetçe— Bilgisayarla görme alanındaki birçok uygulama arasında, yüz tanıma sistemleri; üzerinde yoğun çalışmalar yapılan ve uzun zamandır çalışılan bir konudur. Genel olarak öznitelik çıkarımı ve sınıflandırıcı adımlarından oluşan yüz tanıma sistemlerinin başarısı sadece sınıflandırıcıya değil aynı zamanda kullanılan özniteliklere de bağlıdır. Yüz tanıma sisteminde öznitelik seçiminin amacı farklı yüz görüntülerinin tanınması için ayırt edici özniteliklerin elde edilmesidir. Bu amaç doğrultusunda bu çalışmada ölçeklemeye ve afin dönüşümlere karşı değişmeyen öznitelikler olan SIFT, SURF ve SIFT+SURF özniteliği kullanılmıştır. Ayrıca bu yerel özniteliklerle ile kıyaslama yapılabilmesi için global bir öznitelik olan HOG özniteliği de çalışmaya eklenmiştir. Sınıflandırma destek vektör makinesi kullanılarak gerçekleştirilmiştir. Deneyel sonuçlar yerel özniteliklerin global öznitelik olan HOG özniteliğine kıyasla daha başarılı olduğunu göstermiştir.

Anahtar Kelimeler—Yerel öznitelikler; SIFT; SURF; SIFT+SURF; yüz tanıma sistemleri.

Abstract— Among the many applications in the field of computer vision, face recognition systems; is a subject that has been studied extensively and has been working for a long time. In general, the success of facial recognition systems, which consist of feature extraction and classifier steps, depends not only on the classifier but also on the features used. In a face recognition system, the feature selection is to obtain distinctive features for recognition of different facial images of interest. For this purpose, SIFT, SURF and SIFT + SURF features, which are unchanging features to scaling and affine transformations, are used in this study. In addition, to be able to compare with these local features, the HOG feature which is a global feature, also has been added to the study. Classification was performed using support vector machine. Experimental results show that local features are more successful than the global feature HOG.

Keywords—Local features; SIFT; SURF; SIFT+SURF; face recognition systems.

I. GİRİŞ

Yüz tanıma sistemleri, bilgisayarla görme alanındaki en önemli konulardan biridir. Yüz tanıma, kişinin tanımlanması için önemli bir araştırma alanı olduğu için güvenlik sistemlerine birçok bakımdan önemli ölçüde katkıda bulunmaktadır. Bunlara örnek olarak;

1. Pinler ve yanlış kullanılan veya unutulmuş şifrelerden farklı olarak her kullanıcıya özgü olması,
2. Kimlik doğrulama için bizzat kullanıcının fiziksel varlığını veya işlemini gerektirmesi,
3. Diğer biyometrik uygulamalar (iris ve parmak izi tanıma) pahalı donanım gerektirirken kullanıcının açık bir eylem yapmasına gerek kalmadan yüz verilerini yakalayabilen güvenlik kameraları vasıtasıyla mevcut altyapı üzerinde uygulanabilir olması,
4. Diğer biyometrik uygulamalardan daha kolay veri toplayabilmesi

Yüz tanıma işlemi için literatürde kullanılan teknikler genel olarak özellik tabanlı ve görüntü tabanlı olmak üzere iki bölüme ayrılmıştır. Bu yöntemler arasında şablon eşleme, bilgi tabanlı, makine öğrenmesi, özellik tabanlı, geometri tabanlı yöntemler sayılabilir. Öncelikle yüz tanıma işlemi bazı ön işlem adımlarına tabi tutulur ve daha sonra kişi tanımlaması yapılır. Bu ön işlemlerden bazıları; arka plan kaldırma ve yüz algılama, öznitelik çıkarma, sınıflandırma ve tanıma sayılabilir [1]. Yüz tanıma, yaygın olarak biyometrik kimlik doğrulama, gözetim, insan-bilgisayar etkileşimi, multimedya yönetimi, akıllı kartlar ve fotoğrafların otomatik etiketlenmesi vb. birçok alanda uygulanabilir. Yüz özelliklerini algılama tekniğinde birçok yöntem kullanılmaktadır. Bu çalışmada yerel öznitelik dedektörleri ve tanımlayıcıları kullanılmıştır.

II. ÖZNİTELİK ÇIKARMA

Görsel özellikler, görüntülerin yapılarını ve ilkelerini ifade eder. Bilgisayarla görme ve görüntü işleme alanında çok önemlidirler. Öznitelik çıkarma işlemi, dijital görüntülerde göze çarpan görsel ipuçlarını vurgulamak amacıyla; ilgili görüntü ilkelerinin (örn. noktalar, çizgiler/eğriler ve bölgeler) tanımlanması olarak adlandırılır. Öznitelik çıkarma işlemi için farklı teknikler kullanılmaktadır. Bu tekniklere örnek olarak; Temel Bileşen Analizi (PCA) veya öz yüz yöntemi (Eigen Face) [2], [3], Bağımsız Bileşen Analizi (ICA) [4], Gri Düzeyli Eş Olay Matrisi (GLCM) [5], Ayrık Dalgacık Dönüşümü (DWT) [6], Yüz Özniteliklerini algılama [7], [8], [9] verilebilir.

Sınıflandırma ve algılama işlemi için kullanılan bazı teknikler; Mesafeye göre sınıflandırma (Distance-wise classification), K - en yakın komşu (K-NN), Sinir Ağı (Neural Network), Karar Ağacı (Decision Tree) ve Destek Vektör Makinesi (SVM) dir.

Nesne tanıma, nesne izleme, 3D yeniden yapılandırma, görüntü birleştirme ve görsel haritalama konularında, öznitelik dedektörleri ve tanımlayıcıları sıklıkla kullanılmaktadır. Bir öznitelik detektörü, bir görüntü içinde benzersiz içeriğe sahip ilgi çekici noktaları seçer. Öznitelik algılamanın anahtar noktası, yerel olarak değişmeyen özelliklerini bulmaktır. Böylece rotasyon, ölçek ve aydınlatma değişiklikleri gibi herhangi bir deformasyon durumunda onları tespit edebilirsiniz. İdeal bir öznitelik detektörü tekrarlanabilirlik, ayırtedici olma, yerellik, nicelik, doğruluk ve verimlilik sağlamalıdır [10].

Bir öznitelik tanımlayıcı (çıkarıcı), algılanan her özneliğin çevresindeki bölgeyi tanımlar. Öznitelik tanımlayıcıları, yerel bir piksel komşuluğunu kompakt bir vektör gösterimine dönüştürmek için görüntü işleme konusuna dayanır. Ortaya çıkan öznitelik tanımlayıcıları, daha sonra herhangi bir deformasyona bakılmaksızın komşuluk karşılaştırması ve eşleştirilmesi için kullanılır. İki tür tanımlayıcı vardır; yama tanımlayıcıları ve ikili tanımlayıcılar. İdeal bir öznitelik tanımlayıcı, döndürme, görüntü paraziti ve aydınlatma değişiklikleri gibi genel deformasyonlara karşı belirgin, etkili ve değişmez olmalıdır. Dahası, gerçek zamanlı uygulamalarda kullanılabilmesi için dedektör ve tanımlayıcı yeterince hızlı olmalıdır [11].

Görüntü çiftlerinin eşleme stratejilerinin birçoğu Zitova and Flusser (2003) ın geliştirdiği 4 aşamadan oluşan bir metodolojiyi izlemektedir:

- Öznitelik tespiti (feature detection)
- Öznitelik eşleme (feature matching)
- Dönüşüm modeli tahmini (transform model estimation)
- Görüntü yeniden örnekleme (image resampling).

Birçoğu medikal görüntülemeye olmak üzere özellik tabanlı eşleştirmeye alternatif olan birçok çalışma yapılmıştır [12].

Pek çok uygulamada yaygın olarak kullanılan öznitelik dedektörlere örnek olarak; SIFT Ölçeklemeden Bağımsız Öznitelik Dönüşümü algoritması (Scale Invariant Feature Transform) [13], SURF Hızlandırılmış Gürbüz Özniteliği (Speeded-Up Robust Features) [14], ORB (Oriented FAST and Rotated BRIEF) [15], FAST (Features from Accelerated Segment Test) [16] ve BRISK (Binary Robust Invariant Scalable Keypoints) [17] verilebilir.


Öznitelik tanımlayıcılara örnek olarak; SIFT, SURF, HOG Yönlendirilmiş Gradyan Histogramı (Histogram of Oriented Gradient) [18], GLOH (Gradient Location Orientation Histogram) [19], ORB, BRISK ve BRIEF (Binary Robust Independent Elementary Features) verilebilir.

III. MATERYAL VE YÖNTEM

Bu çalışmada SIFT, SURF, SIFT+SURF ve HOG öznitelikleri kullanılmıştır. SIFT özniteliği ile çevresel faktörlere göre değişmeyen öznitelik vektörleri çıkartılmaktadır. Bu öznitelik, nesne tanımlama ve karşılaştırma uygulamalarında sıklıkla kullanılmaktadır. SURF, ilgili nokta etrafında bilgiye dayalı değişmez ve tekrarlanabilir yönelimleri tanımlar. SIFT özniteliği ile karşılaştırıldığında, ışık değişimine karşı daha az duyarlı olup SIFT özniteliğinden daha hızlıdır [14]. HOG özniteliği plaka tanımlama, araç tanıma gibi farklı sistemlerde kullanılan küresel bir özniteliktir. Eğim yönlerine bakarak bir öznitelik vektörü oluşturur. Bu çalışmada yerel özniteliklerle kıyaslama yapmak amacıyla kullanılmıştır.

SURF ve SIFT yöntemlerinde, görüntüde bulunan belirgin bölgelere odaklanılarak öznitelik vektörleri çıkartılmaktadır. Böylece tüm görüntünün işlenmesi gerekmediği için işlem hesaplama maliyeti düşmektedir. Fakat bu tanımlayıcılar verilen her görüntüde farklı sayıda ilgili nokta çıkartmaktadır. Dolayısıyla sınıflandırma adımı yalnızca eşleştirme algoritması ile kullanılmaktadır. Eşleştirme algoritmasından daha başarılı olan klasik makine sınıflandırıcıları (KNN, DVM vb.) ile bu tanımlayıcıların kullanılabilmesi için tüm görüntü öznitelik vektörlerinin boyutu eşit olmalıdır. Bu tanımlayıcılardan eşit sayıda görüntü özniteliklerinin elde edilebilmesi için ise kelimelerin torbası yönteminin (BoW) kullanılması gerekmektedir. Bu metot görüntü sınıflandırmada görüntüye sınıf etiketi atamak için kullanılmaktadır. BoW eğitim ve test aşamalarını içeren öğrenmeye dayalı bir metottur. Bu metotta, tüm tanımlayıcılar kümelere bölünmektedir [20].

Çalışmada sınıflandırıcı olarak, literatürde SIFT, SURF ve HOG özniteliği ile sıklıkla kullanılan SVM seçilmiştir (Şekil 1). ORL ve Face95 yüz tanıma veri setleri ile çalışılmıştır.



Şekil 1. İşlem Basamakları

IV. BULGULAR

Çalışmada kullanılan ORL veri setinde, 40 farklı kişinin her birinden 10 ar olmak üzere toplam 400 görüntü bulunmaktadır. Bu veri setindeki görüntüler farklı zamanlarda, farklı aydınlatma koşullarında, farklı yüz ifadeleriyle (açık/kapalı gözler, gülen/gülmeyen, gözlüklü/gözlüksüz yüzler) çekilmiştir. Her bir görüntü PNG formatında, piksel başına 256 gri seviyeyle 92x112 pikseldir.

Kullanılan diğer veri seti Face95' de 72 kişinin her birinden ardarda çekilmiş 20 şer olmak üzere toplam 1440 görüntü bulunmaktadır (180x200 piksel).

Çalışmada her iki veri seti de K Katlamalı Çapraz Doğrulama yöntemi kullanılarak, eğitim seti ve test veri seti olmak üzere 10 kez ayrılmıştır. Bu yöntemle elde edilen 10 farklı test veri setinden elde edilen sınıflandırma performansının ortalaması alınarak yüz tanıma sisteminin başarıları belirlenmiştir (Tablo 1).

	ORL Veri Seti	Face95 Veri Seti
Öznitelikler	Sınıflandırma Performansı(%)	Sınıflandırma Performansı(%)
SIFT	98.5	100
SURF	95.75	100
SIFT+SURF	97.5	100
HOG	97.25	88.61

Tablo 1. Yüz Tanıma Sisteminin Başarısı

V. SONUÇ VE ÖNERİLER

Bu çalışmada yüz tanıma işlemi için 4 öznitelik algılayıcı ve tanımlayıcı karşılaştırılmıştır. ORL veri setinde SIFT yerel öznitelik yöntemi en başarılı yöntem olmuştur. Face95 veri setinde kullanılan yerel öznitelik yöntemlerinin hepsinde %100 başarı elde edilmiştir. Global öznitelik yöntemi olan HOG, ORL veri setinde diğer yöntemlerin başarısına yaklaşırken Face95 veri setinde daha az başarı sağlamıştır.

Kişilerin ardarda çekilmiş görüntülerini içermesinden dolayı Face95 veri setinde elde edilen başarı çok yüksek çıkmıştır.

Bundan sonra yapılacak çalışmalarda farklı veri setleri kullanılarak kıyaslama yapılabilir. Ayrıca yüksek başarı elde edilmiş olan bu yöntemleri hareketli görüntülere de uygulama yönünde çalışmalar yapılabilir.

YAZAR KATKILARI

Birinci yazar çalışmanın sorumlu yazarı olup öznitelik çıkarma ve sınıflandırma ile ilgili yazılımı yapmıştır. *İkinci yazar* çalışmadaki yüz tanıma sisteminin tasarımı ve yazılımın testini yapmıştır.

KAYNAKÇA

- [1] Ashlesha D. Kolap, S.V. Shrikhande, Nitin K. Jagtap, "Review on Various Face Recognition Techniques", *International Journal of Innovative Research in Computer and Communication Engineering*, Vol. 3, Issue 3, March 2015.
- [2] Heng Fui Liao, Li-Minn Ang, Kah Phooi Seng, "A Multiview Face Recognition System Based on Eigenface Method", *IEEE Information Technology*, 2008.
- [3] M. Satone, G.K. Kharate, "Selection of Eigenvectors for Face Recognition", *(IJACSA) International Journal of Advanced Computer Science and Applications*, Vol. 4, No.3, 2013.
- [4] I. Dagher, R. Nachar, "Face Recognition Using IPCA-ICA Algorithm", *IEEE Transactions On Pattern Analysis and Machine Intelligence*, Vol. 28, No. 6, June 2006.
- [5] A. Eleyan, H. Demirel, "Co-Occurrence based Statistical Approach for Face Recognition", *IEEE Computer and Information Sciences*, 2009.
- [6] K. H. Ghazali, M. F. Mansor, M. Mustafa, A. Hussain, "Feature Extraction Technique using Discrete Wavelet Transform for Image Classification", *The 5th Student Conference on Research and Development -SCORED*, Malaysia, 11-12 Dec 2007.
- [7] J. Mazloun, A. Jalali, J. Amiryani, "A Novel Bidirectional Neural Network for Face Recognition", *2nd International Conference on Computer and Knowledge Engineering (ICCCKE)*, October 18-19, 2012.
- [8] Yong-An Li, Yong-Jun Shen, Gui-Dong Zhang, Taohong Yuan, Xiu-Ji Xiao, Hua-Long Xu, "An Efficient 3D Face Recognition Method Using Geometric Features", *IEEE*, 2010.
- [9] Vinay A. Dixit, Hebbur, Vinay S. Shekhar, K. N. Balasubramanya Murthy, S. Natarajan, "Two Novel Detector-Descriptor Based Approaches for Face Recognition using SIFT and SURF", *4th International Conference on Eco-friendly Computing and Communication Systems*, ICECCS 2015.
- [10] M. Kashif, T.M. Deserno, D. Haak, S. Jonas, "Feature Description with SIFT, SURF, BRIEF, BRISK, or FREAK? A general question answered for bone age assessment", *Computers in Biology and Medicine*, 68(2016) s.67-75.
- [11] F. A. Khalifa, N. A. Semary, H. M. El-Sayed, M. M. Hadhoud, "Local Detectors and Descriptors for Object Class Recognition", *I.J. Intelligent Systems and Applications*, 2015, 10, 12-18.
- [12] M. Gesto-Diaz, F. Tombari, D. Gonzalez-Aguilera, L. Lopez-Fernandez, P. Rodriguez-Gonzalez, "Feature Matching Evaluation for Multimodal Correspondence", *ISPRS Journal of Photogrammetry and Remote Sensing*, 129 (2017) 179-188, 2017.
- [13] D. Lowe, "Distinctive Image Features from Scale-Invariant Keypoints", *International Journal of Computer Vision*, 60(2), 91-110, 2004.

- [14] H. Bay, A. Ess, T. Tuytelaars, L. V. Gool, "Speeded-Up Robust Features (SURF)", *Computer Vision and Image Understanding*, 110 (2008) 346–359, 2008.
- [15] E. Rublee, V. Rabaud, K. Konolige, G. Bradski, "ORB: an efficient alternative to SIFT or SURF", *IEEE International Conference on Computer Vision, ICCV 2011*, Barcelona, Spain, November 6-13, 2011.
- [16] E. Rosten, T. Drummond, "Machine learning for highspeed corner detection," *Proceedings of the 9th European Conference on Computer Vision*, pp. 430-443, 2006.
- [17] S. Leutenegger, M. Chli, and R. Y. Siegwart, "BRISK: binary robust invariant scalable keypoints," *Proceedings of the International Conference on Computer Vision*, pp.2548-2555, 2011.
- [18] Dalal, N., Triggs, B., "Histograms of Oriented Gradients for Human Detection", *Conference on Computer Vision and Pattern Recognition, San Diego*, 2005.
- [19] K. Mikolajczyk, C. Schmid, "A Performance Evaluation of Local Descriptors", *Ieee Transactions On Pattern Analysis And Machine Intelligence*, Vol. 27, NO. 10, OCTOBER 2005.
- [20] Y. Aydın, "Dengesiz Veri Setlerinde Trafik İşaretlerini Tanıma", *Atatürk Üniversitesi Fen Bilimleri Enstitüsü Yüksek Lisans Tez*, Erzurum, 2016.