

# Yerel İkili Örüntüler İçin Sınıflandırma Yöntemlerinin Karşılaştırılması

## A Comparison of Classification Methods for Local Binary Patterns

Nihan Kazak	Mehmet Koc	Burak Benligiray	Cihan Topal
Bilgisayar Müh. Böl.	Elek.-Elektronik Müh. Böl.	Elek.-Elektronik Müh. Böl.	Elek.-Elektronik Müh. Böl.
Bilecik Şeyh Edebali Üniversitesi	Bilecik Şeyh Edebali Üniversitesi	Anadolu Üniversitesi	Anadolu Üniversitesi
Bilecik, Türkiye	Bilecik, Türkiye	Eskişehir, Türkiye	Eskişehir, Türkiye
nihan.kazak@bilecik.edu.tr	mehmet.koc@bilecik.edu.tr	burakbenligiray@anadolu.edu.tr	chiant@anadolu.edu.tr

**Özetçe** —Doku tanıma içerik tabanlı görüntü erişimi, yüz tanıma ve uydu resimlerinin sınıflandırılması çalışmalarında kullanılan önemli bir araçtır. Doku tanıma için kullanılan özneliklerin arasında en başarılı olanlarından birisi yerel ikili örüntülerdir (YİÖ). YİÖ bir pikselin belirli bir komşuluğundaki piksellerle arasındaki gri seviye farklarını hesaplayan bir operatördür. Literatürdeki birçok çalışmada YİÖ özneliklerinin sınıflandırılması için histogram tabanlı benzerlik ölçütleri kullanılmaktadır. Bu çalışmada YİÖ özneliklerinin başarımının artırılması için destek vektör makineleri, doğrusal ayırtaç analizi ve doğrusal regresyon sınıflandırıcısı irdelenmiştir. Yapılan deneylerde doğrusal regresyon sınıflandırıcısı ile %84.4 tanıma başarımı elde edilmiştir.

**Anahtar Kelimeler**—doku sınıflandırma; yerel ikili örüntüler; sınıflandırma yöntemleri; UIUC doku veritabanı.

**Abstract**—Texture recognition is an important tool used for content-based image retrieval, face recognition, and satellite image classification applications. One of the most successful features for texture recognition is local binary patterns (LBP), which computes local intensity differences for a pixel with respect to its neighbor pixels. In many studies in the literature, histogram based similarity measures are employed to classify LBP features. In this study, we investigate the performance of support vector machines, linear discriminant analysis, and linear regression classifier to improve the success of LBP features. We achieved 84.4% classification success using linear regression classification.

**Keywords**—texture classification; local binary patterns; classification methods; UIUC texture database.

### I. GİRİŞ


Doku, birbirini tekrar eden yerel örüntülerin oluşturduğu bir yapı olarak tanımlanabilmektedir. Bu örüntüler yer yer benzer geometrik yapıdaki şekillerin tekrarı olarak ortaya çıkarken, bazen de tekrarlanan ışık şiddeti dalgalanmaları olarak bulunabilir. Doku tanıma özellikle yüz tanıma, uydu imgelerinin sınıflandırılması, içerik tabanlı görüntü erişimi ve birçok nesne tanıma probleminde etkin bir role sahiptir [1–5].

Doku tanıma birçok örüntü tanıma probleminde olduğu gibi öznelik çıkarımı ve sınıflandırması olarak iki aşamadan oluşmaktadır. Dokular genellikle yapı gereği belirgin özellikler barındırmayıp kendini tekrar eden örüntülerden oluştuğu için tanıma işlemlerinde bütüncül öznelikler kullanılmaktadır. Literatürde bulunan ve doku tanıma için kullanılan en yaygın öznelik yerel ikili örüntüler (YİÖ) olarak karşımıza çıkmaktadır [1]. YİÖ, doku imgesindeki her pikselin belirli bir yarıçaptaki komşularıyla olan ışık şiddeti farklarını ikili olarak kodlayan bir operatördür. Sonrasında elde edilen ikili kodların histogramı oluşturularak nihai öznelik elde edilir. YİÖ yüz tanıma [2, 3], cinsiyet tanıma [4], el izi tanıma [5] ve şekil lokalizasyonu [6] gibi birçok tanıma uygulamasında kullanılmıştır. YİÖ farklı uygulamalarda başarılı tanıma oranları vermesinden dolayı yoğun olarak çalışılan ve birçok çeşidi türetilen bir özneliktir [9]. Bu çalışmada temel ve tekdüze YİÖ yöntemi olmak üzere iki türüne yer verilmiştir.

Literatüre bakıldığında YİÖ ile yapılan çalışmaların büyük çoğunluğunda elde edilen öznelik vektörlerinin benzemezlilik ölçütleri kullanan istatistiksel testlerle sınıflandırıldığı görülmektedir [7, 10, 11]. Bunun yanında destek vektör makineleri (DVM) [12], doğrusal ayırtaç analizi (DAA) [13] gibi sınıflandırma yöntemlerinin de kullanıldığı az sayıda çalışma da bulunmaktadır. Ancak farklı sınıflandırma algoritmalarının aynı veri seti üzerinden elde edilen YİÖ öznelikleri üzerindeki performanslarının irdelendiği bir çalışma bulunmamaktadır.

Bu çalışmada iki farklı YİÖ çeşidi kullanılarak güncel bir doku veri setinden öznelikler çıkarılmıştır. Sonrasında, elde edilen YİÖ öznelikleri farklı yöntemlerle sınıflandırılarak her bir sınıflandırma yönteminin başarımı ölçülmüştür. Yapılan deneysel çalışmalarda literatürde bu amaçla kullanılmayan doğrusal regresyon sınıflandırıcısının (DRS) yüksek tanıma oranları elde ettiği görülmüştür.

Bildirinin organizasyonu şu şekilde devam etmektedir: ikinci bölümde yerel ikili örüntüler yöntemi kısaca anlatılmaktadır. Üçüncü bölümde deneylerde kullanılan farklı sınıflandırıcılar olan G-testi, Ki-kare, destek vektör makineleri (DVM), doğrusal ayırtaç analizi (DAA) ve doğrusal regresyon



Şekil 1. Temel YİÖ operatörü.

sınıflandırıcı (DRS) kısaca açıklanmaktadır. Dördüncü bölümde gerçekleştirilen deneysel çalışmalar sunulmakta ve son bölümde deneysel sonuçlarda elde edilen bulgular yorumlanmıştır.

## II. YEREL İKİLİ ÖRÜNTÜLER (YİÖ)

İlk defa Ojala vd. tarafından önerilen yerel ikili örüntüler operatörü gri-seviye değişmez bir özneliktir [1]. Bu operatör bir pikselin gri seviyesinin belirli bir yarıçap komşuluğunda bulunan diğer piksellere göre yüksek ya da düşük olmasını inceleyerek ikili değerler oluşturur. Temel YİÖ, 3×3 bloklar kullanmaktadır. Blok içerisindeki her bir pikselin gri-seviye değeri, merkez pikselin gri-seviye değeri ile karşılaştırılır. Eğer merkez pikselin değeri ile karşılaştırılan pikselin değeri arasındaki fark sıfırdan büyük veya eşitse komşu piksel değeri ikili olarak 1, diğer durumda ise 0 kodlanır. Daha sonra merkez pikselin LBP kodu, oluşan ikili kodun onluk tabana dönüştürülmesiyle hesaplanır. Şekil 1’de temel YİÖ operatörü bir örnek ile gösterilmiştir.

Temel YİÖ operatörü farklı yarıçap ve komşuluklarda da hesaplanabilir [8]. Şekil 2’de farklı yarıçaplara sahip iki dairesel simetrik komşu seti görülmektedir. R yarıçapına sahip bir dairesel komşuluk üzerinde P adet komşu piksel olduğunu varsayarsak merkez pikselin YİÖ kodu aşağıdaki formül ile hesaplanmaktadır:


$$LBP_{P,R} = \sum_{p=0}^{p-1} s(g_p - g_c)2^p, s(x) = \begin{cases} 1, & x \geq 0 \\ 0, & x < 0 \end{cases} \quad (1)$$

Denklem (1)’de  $g_c$  merkez pikselin gri-seviye değerini  $g_p$  ise  $p$ . komşunun gri-seviye değerini ifade etmektedir.

Tekdüze YİÖ, yerel örüntülerden daha az sayıda öznelik çıkarma amacıyla geliştirilmiştir. Bir örüntünün ikili kodunda 0’dan 1’e veya 1’den 0’a geçiş sayısı iki ya da daha çok ise bu örüntü tekdüze örüntü değildir, diğer durumdaki örüntü tekdüze örüntü olarak adlandırılır. Örneğin; Şekil 1’de verilen örüntünün ikili kodu 00101101 olmakla birlikte toplamda 0-1 ve 1-0 geçişleri ikiden fazla olması sebebiyle tekdüze değildir. Sınıflandırma yapılırken sadece tekdüze örüntülerin LBP kodları dikkate alınmaktadır.

## III. SINIFLANDIRICILAR

Doku sınıflandırmada bir imgeye YİÖ uygulandığında öznelik vektörü olarak histogram elde edilir. Örnek ve model histogramların benzerliğini ölçmek için genellikle parametrik olmayan istatistiksel testler kullanılır. Bu bölümde, doku sınıflandırmada çoğunlukla kullanılan G-testi ve Ki-kare ( $\chi^2$ ) testinin yanısıra, destek vektör makineleri (DVM), doğrusal ayırtaç analizi (DAA) ve doğrusal regresyon sınıflandırıcısı (DRS) yöntemleri kısaca anlatılmıştır.



Şekil 2. (8,1) ve (16,2) YİÖ operatörü.

### A. G-Testi

G-testi aşağıdaki gibi tanımlanır.

$$G(S, M) = 2 \sum_{b=1}^B S_b \log \frac{S_b}{M_b} \quad (2)$$

Burada B, histogramdaki çubuk (bin) sayısını  $S_b$  ve  $M_b$  sırasıyla  $b$ . çubuktaki ilgili örnek ve model olasılıklarını temsil etmektedir.

G-testi, sınıflandırma yapılırken  $S_b \log S_b$  her model için aynı olması sebebiyle aşağıdaki şekilde sadeleştirilebilir:

$$L(S, M) = 2 \sum_{b=1}^B S_b \log M_b \quad (3)$$

Test örneği  $S$ ,  $L$ -istatistiğini maksimize eden  $M$  modelinin sınıfına atanır.

### B. Ki-kare ( $\chi^2$ ) Testi

Karşılaştırılacak olan histogramlar  $S$  ve  $M$  olsun. Ki-kare testi aşağıdaki denklem ile hesaplanır.

$$d_{\chi^2}(S, M) = \sum_{i=1}^B \frac{(s_i - m_i)^2}{s_i + m_i} \quad (4)$$

Burada, B, histogramlardaki çubuk sayısını,  $s_i$  ve  $m_i$  sırası ile  $S$  ve  $M$ ’nin  $i$ . histogram çubuğunu göstermektedir. Sınıflandırma en yakın komşuluk kuralı ile yapılmaktadır.


### C. Destek Vektör Makineleri (DVM)

DVM ile öznelikleri iki sınıfa ayıran bir hiper-düzlemin bulunması amaçlanmaktadır. Öznelikler doğrusal olarak ayrılabilir bir yapıda ise bu işlem doğrudan uygulanabilir. Aksi durumda öznelikler önce doğrusal olarak ayrılacakları daha yüksek boyutlu bir uzaya yansıtılırlar.

### D. Doğrusal Ayırtaç Analizi (DAA)

DAA, veri içerisinde bulunan farklı sınıflara ait grupların doğrusal ayrılabilirliğini maksimize ederek boyut azaltması yapan bir yöntemdir. Doğrusal ayırtaç analizindeki amaç sınıflar arası dağılımı en büyük yaparak farklı sınıfların örneklerini birbirinden ayırırken, sınıf içi değişimti en küçük yapmaktır. Böylece boyut indirilmesi yapılırken aynı zamanda da sınıflandırmada kullanılacak bilgiler korunacaktır. DAA yönteminde aşağıdaki amaç fonksiyonu maksimize edilir:

$$J(w) = \frac{w^T S_B w}{w^T S_T w} \quad (5)$$



Şekil 3. UIUC veritabanından örnek doku imgeleri.

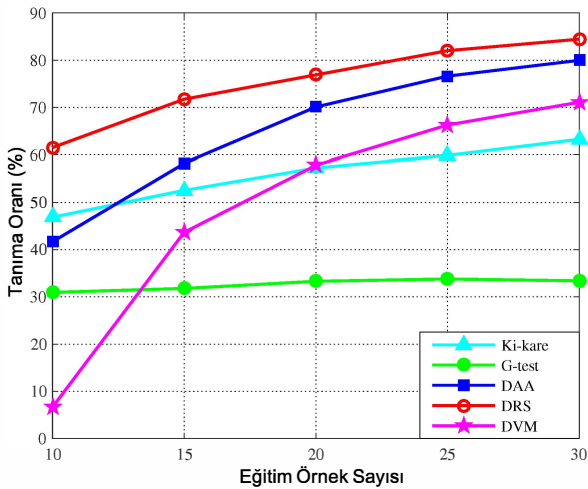
Burada  $S_B$  sınıflar arası saçılım matrisi,  $S_T$  ise sınıf içi saçılım matrislerinin toplamıdır.  $J$  amaç fonksiyonunu maksimize eden  $w$  vektörlerinin geldiği altuzayda Öklid uzaklığı ile sınıflandırma yapılır.

#### E. Doğrusal Regresyon Sınıflandırıcı (DRS)

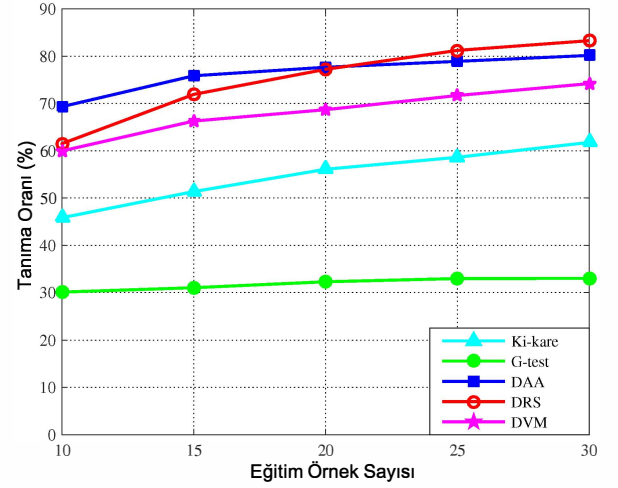
Doğrusal Regresyon Sınıflandırıcı (DRS) çoğunlukla yüz tanıma uygulamalarında kullanılan [13–15] altuzay tabanlı bir yöntemdir. Yöntemde, eğitim örnekleri ile regresyon analizi yapılarak sınıflara ait  $X_i, i = 1, \dots, C$  modelleri elde edilmektedir. Sınıflandırılmak istenen  $y$  öznelik vektörünün sınıf modelleri kullanılarak  $\hat{y}_i = X_i(X_i^T X_i)^{-1} X_i^T, i = 1, \dots, C$  tahminleri elde edilir.  $y$ , en yakın olan tahminin ait olduğu sınıfa atanır.

### IV. DENEYSSEL SONUÇLAR

Farklı sınıflandırma yöntemlerinin başarımını ölçmek amacıyla UIUC doku veritabanı kullanılmıştır [16]. Veritabanı farklı görüş açıları ve ölçek farklılıklarına sahip toplam 25 sınıf



Şekil 4. Temel YİÖ ile sınıflandırma oranları.



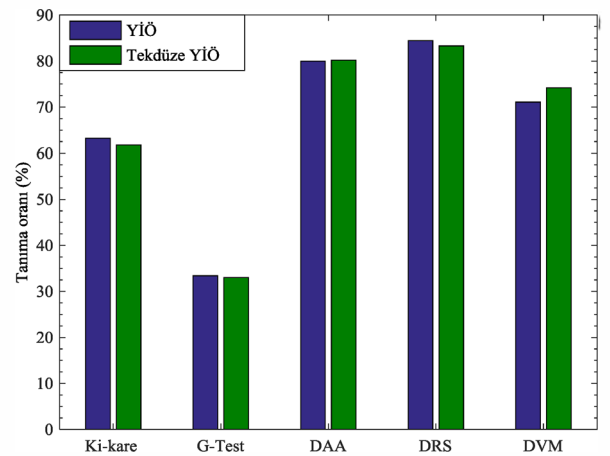
Şekil 5. Tekdüze YİÖ ile sınıflandırma oranları.

ve her sınıfa ait 40 doku imgesi içermektedir. Her bir imgenin boyutu  $640 \times 480$  pikseldir. Veritabanındaki her sınıftan bir örnek doku imgesi Şekil 3'de gösterilmektedir.

Yapılan deneylerde sırasıyla her sınıftan rastgele seçilmiş 10, 15, 20, 25 ve 30 adet doku imgesi eğitim için geriye kalanlar ise test için kullanılmıştır. Şekil 4 ve Şekil 5'de sırasıyla temel YİÖ ve tekdüze YİÖ kullanılarak üçüncü bölümde değinilen sınıflandırma yöntemlerinin başarıları gösterilmektedir. Doğruluk oranları, 10 kez rastgele seçilen örnek sayısına bağlı sınıflandırma oranlarının ortalaması alınarak elde edilmiştir. Her sınıftan rasgele seçilen 30 adet test imgesi için temel YİÖ ve tekdüze YİÖ yöntemlerinden elde edilen öznelikler Ki-kare, Log-likelihood, DAA, DRS ve DVM ile sınıflandırılarak 10 kere çalıştırılmıştır. Elde edilen tanıma oranlarının ortalamaları Şekil 6'daki grafikte karşılaştırmalı olarak verilmiştir.

### V. SONUÇ

Bu çalışmada sayısız örüntü tanıma uygulamasında kullanılan yerel ikili örüntüler (YİÖ) yönteminin farklı



Şekil 6. Sınıflandırma yöntemlerinin YİÖ ve Tekdüze YİÖ için sınıflandırma başarımları.

sınıflandırıcılar karşısındaki performansının irdelenmesi amaçlanmıştır. Bu yöntemlerin sınıflandırma oranlarını test etmek amacıyla UIUC doku veritabanı kullanılmıştır. Yapılan deneysel çalışmalarda literatürde genellikle Ki-kare gibi benzerlik ölçütü tabanlı istatistiksel testlerle sınıflandırılan YİÖ'nün, doğrusal regresyon sınıflandırıcı gibi altuzay tabanlı yöntemlerde daha iyi sonuçlar verdiği görülmüştür. Yapılan deneylerde altuzay tabanlı yöntemlerin benzerlik ölçütü kullanan sınıflandırma yöntemlerine göre %41'e varan oranlarda daha başarılı sonuçlar verdiği görülmektedir.

Yapılan deneysel çalışmalarda elde edilen diğer bir bulgu ise G-Test ve Ki-kare gibi benzerlik tabanlı sınıflandırıcılara ait başarımların eğitim örnek sayısının artmasıyla çok fazla değişmemesidir. Bu sınıflandırıcıların aksine alt uzay tabanlı sınıflandırıcılarda eğitim örnek sayısı arttıkça sınıflandırma başarısı da önemli ölçüde artmaktadır. Bunun nedeni alt uzay tabanlı sınıflandırıcıların eğitim örnek sayısı arttıkça veriyi daha iyi ve kapsamlı bir şekilde modellemeleri olduğu düşünülmektedir.

#### KAYNAKÇA

- [1] Ojala, T., Pietikainen M., and Harwood, D., "A Comparative Study of Textur Measures with Classification Based on Feature Distributions," *Pattern Recognition*, 29(1):51-59, 1996.
- [2] Zhao, G. and Pietikainen, M., "Dynamic Texture Recognition Using Local Binary Patterns with an Application to Facial Expressions," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 29(6):915-928, 2007.
- [3] Tan, X., and Triggs, B., "Enhanced Local Texture Feature Sets for Face Recognition Under Difficult Lighting Conditions," *IEEE Trans. Image Processing*, 19(6):1635-1650, 2010.
- [4] Shan C., "Learning local binary patterns for gender classification on real-world face images," *Pattern Recognition Letters*, 33:431-437, 2012.
- [5] Michael G.K.O., Connie T., and Teoh A.B.J., "Touch-less palm print biometrics: Novel design and implementation," *Image and Vision Computing*, 26:1551-1560, 2008.
- [6] Heikkilä, M., Pietikainen, M., and Schmid, C., "Description of interest regions with local binary patterns," *Pattern Recognition*, 42:425-436, 2009.
- [7] Pietikäinen, M., Hadid, A., Zhao, G., and Ahonen, T., "Local Binary Patterns for Still Images," in *Computer Vision Using Local Binary Patterns*.: Springer, 2011, pp. 13-47.
- [8] Ojala, T., Pietikainen, M., and Maenpää, T., "Multiresolution Gray-Scale and Rotation Invariant Texture Classification with Local Binary Patterns," *IEEE Trans. Pattern Analysis and Machine Intelligence*, 24(7):971-987, 2002.
- [9] Guo, Z., Zhang, L., and Zhang, D., "A Completed Modeling of Local Binary Pattern Operator for Texture Classification," *IEEE Transactions on Image Processing*, 19(6): 1657-1663, 2010.
- [10] Maenpää, T., *The Local Binary Pattern Approach to Texture Analysis-Extensions and Applications*, 2003.
- [11] Liao, S., Law, M.W.K., and Chung, A.C.S., "Dominant Local Binary Patterns for Texture Classification," *IEEE Transactions on Image Processing*, vol. 18(5):1107-1118, 2009.
- [12] Shan, C., Gong, S., and McOwan, P.W., "Facial Expression Recognition Based on Local Binary Patterns: A comprehensive study," *Image and Vision Computing*, 27:803-816, 2009.
- [13] Naseem, I., Togneri, R., and Bennamoun, M., "Linear Regression for Face Recognition," *IEEE Trans. Pattern Analysis and Machine Intelligence*, 32(11):2106-2112, 2010.
- [14] Naseem, I., Togneri, R., and Bennamoun, M., "Robust regression for face recognition," *Pattern Recognition*, 45(1): pp. 104-118, 2012.
- [15] Koc, M. and Barkana, A., "Application of Linear Regression Classification to Low Dimensional Datasets," *Neurocomputing*, 131:331-335, 2014.
- [16] Lazebnik, S., Schmid, C., and Ponce, J., "A Sparse Texture Representation Using Local Affine Regions," *IEEE Trans. Pattern Analysis and Machine Intelligence*, 27(1):1265-1278, 2005.
- [17] Topi, M., Timo, O., Matti, P., and Maricor, S., "Robust Texture Classification by Subsets of Local Binary Patterns," *15th International Conference on Pattern Recognition (Vol.3)*, Barcelona, 2000, pp. 935-938.
- [18] Zhao, Y., Jia, W., Hu, R.X., and Min, H., "Completed Robust Local Binary Pattern for Texture Classification," *Neurocomputing*, 106:68-76, 2013.