

A Novel Texture Classification Method Based on Neutrosophic Truth

 Nuh ALPASLAN¹

¹Bingöl Üniversitesi, Bilgisayar Mühendisliği Bölümü;
nalpaslan@bingol.edu.tr; <https://orcid.org/0000-0002-6828-755X>

Received 25 March 2020; Revised 18 April 2020; Accepted 22 April 2020; Published online 30 April 2020

Abstract

Texture analysis is one of the basic procedures used in solving problems in computer vision and image processing. In this study, we propose a new local binary pattern (LBP) method based on neutrosophic set. The proposed method is named as the *NZ-LBP*. In the proposed *NZ-LBP* method, the texture image is converted into a neutrosophic set and the texture image is expressed by truth membership set. The local binary pattern features are calculated, by using the neutrosophic truth set instead of the original input image. The neutrosophic membership sets are more resistant to noise than the original input image. The neutrosophic set suppresses noise components, so that edge information can be calculated more accurately. Thus, utilization of the neutrosophic truth set instead of the original image has provided more effective local binary pattern features. The proposed method is able to achieve high classification accuracy with low feature size, reasonable computational cost. Experimental results show that the proposed method increases the accuracy of the local binary pattern method to the classification by approximately 11% without increasing the feature dimension. The obtained results reveal that the proposed method is applicable for real-time applications.

Keywords: Neutrosophic set, local binary pattern, texture classification

Nötrozofik Doğruluk Temelli Yeni Bir Doku Sınıflandırma Yöntemi

Öz

Doku analizi, bilgisayar görmesi ve görüntü işleme alanlarındaki problemlerin çözümünde başvurulan temel işlemlerden biridir. Bu çalışmada, nötrozofik küme temelli yeni bir yerel ikili örüntü (LBP) yöntemi önerilmiştir. Önerilen yöntem *NZ-LBP* olarak isimlendirilmiştir. Önerilen *NZ-LBP* yönteminde doku görüntüsü nötrozofik kümeye dönüştürülür ve doku görüntüsü doğruluk üyelik kümesi ile ifade edilir. Görüntünün yerel ikili örüntü öznelikleri orijinal giriş görüntüsü yerine nötrozofik doğruluk küme görüntüsü kullanılarak hesaplanır. Nötrozofik üyelik kümeleri orijinal giriş görüntüsüne göre gürültüye karşı daha dayanıklıdır. Nötrozofik küme gürültü bileşenlerini baskılar ve bu sayede kenar bilgileri daha doğru bir şekilde hesaplanabilir. Böylece orijinal görüntünün yerine nötrozofik doğruluk kümesinin kullanılması daha etkili yerel ikili örüntü özneliklerinin elde edilmesini sağlamıştır. Önerilen yöntem düşük öznelilik boyutu, uygun hesaplama maliyeti ile yüksek sınıflandırma doğrulukları elde edebilmiştir. Deneysel sonuçlar önerilen yöntemin öznelilik boyutunu artırmadan yerel ikili örüntü yönteminin sınıflandırma doğruluğunu yaklaşık 11% artırdığını göstermektedir. Elde edilen sonuçlar önerilen yöntemin gerçek zamanlı uygulamalar için uygulanabilir olduğunu ortaya koymaktadır.

Anahtar Kelimeler: Nötrozofik küme, yerel ikili örüntü, doku sınıflandırma

1. Giriş

Bilgisayar görmesi ve örüntü tanıma alanlarındaki problemlerin çözümünde başvurulan temel işlemlerden birisi doku analizidir. Doku, görüntüde ilgilenilen bölgedeki nesnelere tanımlamada kullanılan en önemli karakteristiklerden biridir. Doku analizi ile görüntülerdeki farklı sınıfların ayırt edici özelliklerinin elde edilmesi amaçlanmaktadır. Her bir sınıfı tanımlayan benzersiz özelliklerin elde edilmesi ile görüntülerdeki farklı dokular sınıflandırılabilir. Ancak görüntülerde özellikle aynı sınıf içerisindeki dönme, aydınlanma ve bakış açısı değişimleri doku analizini ve sınıflandırmasını zorlaştıran en temel problemlerdendir. Bu nedenle sadece renk ve kenar bilgileri gibi özellikler kullanılarak görüntüleri analiz etmek istenen sonuçları vermemektedir. Bunun sonucu olarak,

görüntüleri farklı ve güçlü yaklaşımlar ile analiz eden özellik çıkarma metotları kullanılarak etkin sonuçlar elde edilebilmiştir [1], [2].

Etkili bir görüntü analizi gerçekleştirmenin yolu görüntüdeki doku yapılarının temel karakteristiklerini ifade ve analiz etmekten geçmektedir. Literatürde yapılan çalışmalar incelendiğinde birçok doku özneliği elde eden ve yorumlayan yöntem olduğu görülmektedir. Bu yöntemler genel olarak istatistiksel [3], [4], model tabanlı [5], yapısal [6] ve filtre tabanlı [7]–[9] yöntemler olmak üzere dört kategoriye ayrılmıştır. İstatistiksel ve model temelli yöntemler genellikle küçük piksel komşuluklarını temel alarak piksellerin uzamsal ilişkilerini analiz etmektedir. Bu yöntemlerin en bilinenleri gri seviye eş oluşum matrisi (GLCM) [10], Markov rastgele alanlar modeli (MRF) [11] ve yerel ikili örüntü (LBP) yöntemleridir [12]. Yapısal yöntemler ise dokusal temellerin (textural primitives) düzenli yerleşimlerini temel alarak dokuyu karakterize ederler [6]. Filtre temelli yöntemler içerisinde dalgacık dönüşümü [13], [14], Gabor dönüşümü [15] ve filtre bankaları [3] gibi birçok yöntem geliştirilerek doku analizi ve sınıflandırması yapılmıştır. Gabor filtreleri sinyal analizinde kullanılan lineer filtrelerdir. İnsan görme sistemine benzer tasarlanan farklı ölçek ve açılardaki Gabor filtreleri ile dönme bağımsız doku analizi yapılabilmektedir [15]. Başka güncel bir çalışmada ise Gaussian türev filtrelerinden elde edilen doku özellikleri kullanarak görüntü sınıflandırması yapılmıştır [16]. Bu yöntemlerin dışında yönlü gradyan histogramı (histogram of oriented gradients, HOG) ve yönlü gradyan eş oluşum histogramı (co-occurrence histogram of oriented gradients, CoHOG) gibi yöntemler ile de oldukça başarılı doku sınıflandırma çalışmaları yapılmıştır [17], [18].

Bilindiği gibi doku sınıflandırma yöntemleri iki temel adımdan meydana gelmektedir. İlk adım dokuyu karakterize eden doku özelliklerinin çıkartılmasıdır. İkinci adım ise farklı dokuları ayırt etmek için elde edilen öznelilikler kullanılarak yapılan sınıflandırma işlemidir. Son yıllarda evrimsel sinir ağları (ESA) yaklaşımları kullanılarak öznelilik çıkarma ve sınıflandırma işlemleri birlikte yapılmaktadır. Geleneksel bir ESA mimarisi genellikle çoklu evrim katmanları ve bunları takip eden tam bağlı katmanlar ile SoftMax sınıflandırıcının birbirine bağlanmasından oluşmaktadır. Hand-crafted özneliliklerden farklı olarak, ESA tarafından öğrenilen tam bağlı katman özellikleri yüksek seviyeli anlamsal bilgi içermektedir [19]. Bu özelliklerinden dolayı birçok çalışmada ESA mimarileri kullanılarak etkin doku sınıflandırma çalışmaları yapılmıştır [20], [21]. Talo ve diğerleri ise derin transfer öğrenme metotları ile normal ve anormal Magnetic resonance (MR) görüntülerini sınıflandırmışlardır [22]. Yapılan derin öğrenme tabanlı çalışmalar incelendiğinde bazı üstün ve zayıf yönlerinin olduğu görülmektedir. Öncelikle yüksek doğruluk ve detaylı tanımlayıcı bilgi sunabilmeleri en önemli avantajları olarak öne çıkmaktadır. Bununla birlikte yüksek hesaplama maliyeti, öğrenme süreci için yüksek boyutlu veriye ihtiyaç duymaları ve donanım gereksinimi en önemli zayıflıkları olarak görülmektedir. Bu nedenle geleneksel özellik çıkarma yöntemlerine olan ihtiyaç devam etmektedir. Bu nedenle LBP, dalgacık dönüşümü, ve Gabor dönüşümü gibi geleneksel ve güçlü yöntemlerin geliştirilmesine yönelik çalışmalar devam etmektedir [23], [24].

Ojala ve diğerleri tarafından geliştirilen LBP yöntemi gri seviye görüntülerin uzamsal karakteristiklerini hesaplayan etkili bir gri seviye doku operatörüdür [12]. Bu yöntemin performansını iyileştirmek için birçok LBP yöntemi önerilmiştir. Böylece doku bilgilerini güçlü bir şekilde ayırt etmekle birlikte düşük hesapsal karmaşıklığa sahip LBP yöntemleri geliştirilmiştir. Geliştirilen yöntemler orijinal LBP yönteminin gürültü, dönme ve ışık değişimlerine karşı güçlü kalmasını sağlamıştır. Bunun sonucu olarak yüz tanıma [2], doku sınıflandırma [25], [26], duman tespiti [27] ve medikal görüntü işleme [28] gibi alanlarda yoğun bir şekilde kullanılmaktadır. Heikkilä ve diğerleri tarafından geliştirilen center-symmetric LBP (CS-LBP) yöntemi merkez piksel ile komşularını karşılaştırmak yerine piksellerin merkez simetrik çiftlerini karşılaştırmaktır [29]. LBP yönteminin stabil doku doku analizi yapmasını sağlamak için local concave and convex microstructure patterns (LCvMSP and LCxMSP) yöntemleri geliştirilmiştir [30]. Bu özellikler ile doku örüntülerinin yerel dalgalanması ortaya çıkarılır ve değişimleri ifade edilir. Elde edilen concave ve convex özellikler Binary Thresholding fonksiyonları kullanılarak eşiklenir. Böylece merkez pikselin etrafında kapalı bir yol etrafındaki pikseller detaylı olarak karakterize edilmiştir.

Doku görüntülerindeki sınıf içi ve sınıflar arası değişimi daha iyi karakterize etmek için, bu çalışmada nötrozofik küme teorisi temelli LBP yöntemi (NZ-LBP) geliştirilmiştir. Yapılan kapsamlı literatür

araştırması sonucunda, nötrozofik küme teorisinin LBP yönteminin doku sınıflandırma gücünü artırmak için ilk kez entegre edildiği görülmüştür. Böylece LBP yönteminin öznelik vektör boyutunu artırmadan sınıflandırma başarısı artırılmış ve doku sınıflandırma problemine karşı iyi sonuçlar üretilmiştir. Önerilen yöntemde giriş görüntüsünün nötrozofik küme bileşenlerinden doğruluk küme bilgisi LBP yöntemine giriş parametresi olarak verilmiştir. NZ-LBP yönteminin uygulanmasında nötrozofik küme için farklı h türev filtreleri ve LBP yöntemi için farklı R yarıçap değerleri kullanılarak hesaplanmıştır. Her bir h türev filtresi ve R yarıçap değeri için hesaplanan yönelimden bağımsız LBP öznelikleri kullanılarak nihai öznelik vektörü elde edilmiştir. Bölüm 2’de nötrozofik küme teorisi ve LBP yöntemleri kısaca açıklanmıştır. Bölüm 3’te önerilen yeni doku sınıflandırma yöntemi açıklanmıştır. Bölüm 4’te farklı veri setleri üzerinde gerçekleştirilmiş deneysel sonuçlar verilmiştir. Önerilen yöntemle ait genel sonuçlar Bölüm 5’te sunulmuştur.

2. İlgili Çalışmalar

2.1. Geleneksel Yerel İkili Örüntü

Geleneksel LBP yönteminde bir merkez piksel onun komşu pikselleri ile karşılaştırılarak belirlenir [12]. Merkez piksel için LBP öznelikleri denklem (1)’de verildiği gibi hesaplanmaktadır.

$$LBP_{P,R} = \sum_{p=0}^{P-1} s(g_p - g_c) 2^p \quad (1)$$

burada g_c merkez pikselin gri seviye değerini, g_p ise merkez pikselin ilgili komşu pikselinin değerini göstermektedir. P komşu sayısını, R ise dairesel komşuluk yarıçapını göstermektedir. $s(x)$ ise eşikleme fonksiyonu olup denklem (2)’de verildiği gibi tanımlanmaktadır.

$$s(x) = \begin{cases} 1 & x \geq 0 \\ 0 & x < 0 \end{cases} \quad (2)$$

LBP yönteminin farklı dokusal durumlarda etkinliğini arttırmak için farklı modelleri geliştirilmiştir [12]. Bunlar üniform, yönelimden bağımsız, and yönelimden bağımsız üniform LBP metotlarıdır. Bir LBP örüntüsünün üniform değeri dairesel uzamsal (spatial) geçişlerin sayısını ifade edip denklem (3)’de verildiği gibi tanımlanabilir. Denklem 4’te eğer $U \leq 2$ ise, LBP örüntüleri üniform örüntülere atanır. Diğer durumda ise LBP örüntüleri üniform olmayan örüntüler olarak sınıflandırılır.

$$U(LBP_{P,R}) = |s(g_{p-1} - g_c) - s(g_0 - g_c)| + \sum_{p=1}^{P-1} |s(g_p - g_c) - s(g_{p-1} - g_c)| \quad (3)$$


$$LBP_{P,R}^{riu2} = \begin{cases} \sum_{p=0}^{P-1} s(g_p - g_c) & U(LBP_{P,R}) \leq 2 \\ P+1 & \text{degilse} \end{cases} \quad (4)$$

2.2. Nötrozofik Küme

Nötrozofik küme (NK), felsefenin bir dalı olup doğayı ve nötralitenin kapsamını inceleyen bir alandır [31]. Nötrozofide her olay sadece doğruluk, yanlışlık ve belirsizlik derecesine sahiptir. Nötrozofik dizide belirsizlik doğruluk derecesi, belirsizlik derecesi ve yanlışlık derecesi ile ölçülebilir.

U bir evrensel küme ve bu küme NK A ’yı içersin. A kümesi içerisindeki bir x elemanı, t ’nin T içinde, i ’nin I içinde ve f ’nin F içinde değişkenlik gösterdiği $x(t,i,f)$ olarak gösterilsin. $x(t,i,f)$ elemanı, aşağıdaki şekilde A kümesi ile ilişkilendirilir. Bu eleman $\%t$ doğru, $\%i$ belirsiz, $\%f$ yanlıştır.

Burada olarak T, I, F üyelik kümeleri olmakla beraber, T, I ve F bilinen ve/veya bilinmeyen parametrelere bağlı olarak fonksiyonlardır. Örnek doku görüntüsünün nötrozofik dönüşümü ile elde edilen T, F ve I kümesi görüntüleri Şekil 1’de görülmektedir.



Şekil 1 Giriş doku görüntüsünün nötrozofik kümeye dönüştürülmesi ile elde edilen alt küme görüntüleri. (a) Orijinal görüntü, (b) T doğruluk kümesi, (c) F yanlışlık kümesi, (d) I belirsizlik kümesi

3. Önerilen Yöntem

LBP yönteminin gürültü ve kontrast eksikliği gibi dış etkilere karşı yeteri kadar dayanıklı olmaması öznelik çıkarma işlemi üzerinde olumsuz etkilere yol açabilmektedir. Giriş görüntüsünde bulunan gürültü ve ışık değişimi gibi istenmeyen faktörler elde edilecek öznelik kalitesini etkilemektedir. Bunun sonucunda bilgi kaybı meydana gelmekte, sınıflandırma veya bölütleme gibi süreçlerde başarı oranı düşmektedir. Nötrozofik küme gürültü bileşenlerini baskılaması ve bu sayede kenar bilgileri daha doğru bir şekilde hesaplanabilmesi, kaliteli öznelik çıkarılması anlamında oldukça önemlidir. Bu noktada görüntünün farklı bölgelerindeki ayırt edici özneliklerin korunması sağlanmalıdır. Aksi halde görüntüden ayırt edici öznelik bilgisi elde edilemediğinden sınıflandırma performansı düşecektir.

Bu çalışmada doku görüntülerindeki sınıf içi ve sınıflar arası değişimi daha iyi karakterize etmek için nötrozofik küme teorisi temelli LBP yöntemi (NZ-LBP) geliştirilmiştir. Bu amaçla öncelikle, gri seviyeli giriş görüntüsü nötrozofik alana dönüştürülür. Giriş doku görüntüsü yerine kullanılacak olan nötrozofik doğruluk kümesi T hesaplanır. Bu kısım Bölüm 3.1’de ayrıntılı olarak anlatılacaktır.

3.1. Görüntünün Nötrozofik Kümeye Dönüştürülmesi

U evrensel küme ve pikselin parlaklığını gösteren $\omega \subseteq U$ olsun. Bir nötrozofik görüntü PNS T, I ve F olmak üzere üç üyelik kümesi tarafından tanımlanır. P pikseli $p(t, i, f)$ olarak tanımlanır ve aşağıdaki yol ile ω ’ye ait olur. P pikseli, piksel parlaklığı kümesi içerisinde % t doğru, % i belirsiz ve % f yanlışdır. Böylece görüntü alanındaki $P(i, j)$ pikseli, nötrozofik alana dönüştürülür [32], [33].

$PNS(i, j) = \{ T(i, j), I(i, j), F(i, j) \}$. $T(i, j)$, $I(i, j)$ ve $F(i, j)$ üyelik değerleri denklem (5), (6), (7), (8) ve (9)’da verildiği gibi tanımlanır.

$$T(i, j) = \frac{\bar{g}(i, j) - \bar{g}_{\min}}{\bar{g}_{\max} - \bar{g}_{\min}} \quad (5)$$

$$\bar{g}(i, j) = \frac{1}{w \times w} \sum_{m=i-w/2}^{i+w/2} \sum_{n=j-w/2}^{j+w/2} g(m, n) \quad (6)$$

$$I(i, j) = \frac{\delta(i, j) - \delta_{\min}}{\delta_{\max} - \delta_{\min}} \quad (7)$$

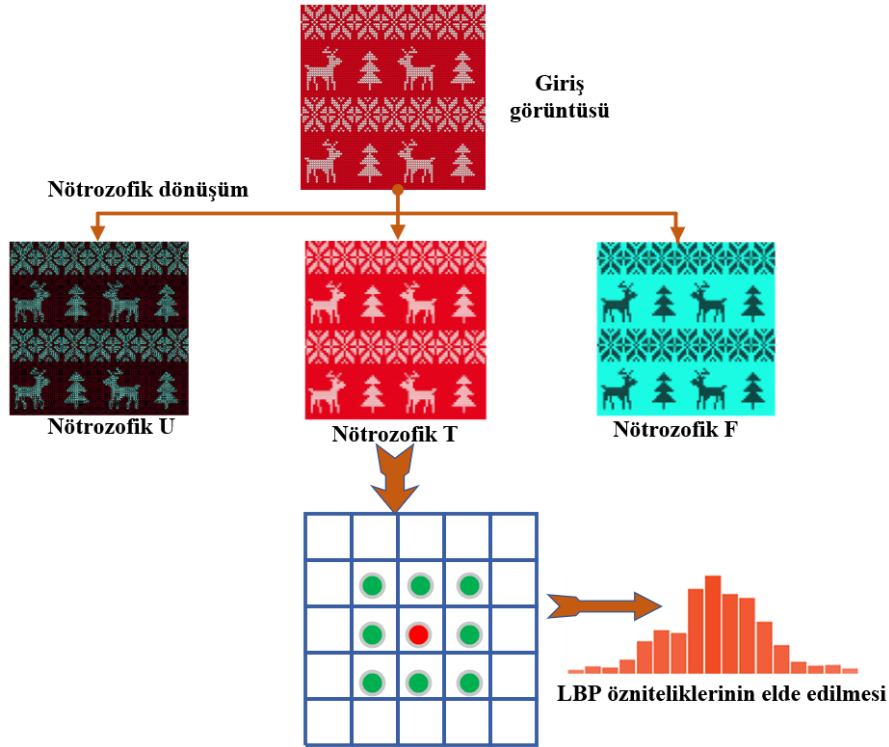
$$\delta(i, j) = \text{abs}(g(i, j) - \bar{g}(i, j)) \quad (8)$$

$$F(i, j) = 1 - T(i, j) \quad (9)$$

$g(i, j)$ sembolü (i, j) pikselinin yoğunluk değerini gösterirken, $\bar{g}(i, j)$ sembolü $g(i, j)$ değerinin lokal ortalama değerini göstermektedir. $\delta(i, j)$ sembolü ise, $g(i, j)$ ve onun lokal ortalama değerini gösteren $\bar{g}(i, j)$ arasındaki mutlak değer farkıdır.

Denklem (5)'de T giriş görüntüsünün nötrozofik alana dönüştürülmesi ile elde edilen nötrozofik doğruluk kümesi görülmektedir. Önerilen yöntemde giriş görüntüsünün nötrozofik küme bileşenlerinden doğruluk küme bilgisi LBP yöntemine giriş parametresi olarak verilmiştir. NZ-LBP yönteminin uygulanmasında nötrozofik küme için farklı türev filtreleri ve LBP yöntemi için farklı yarıçap değerleri kullanılarak hesaplanmıştır. Her bir türev filtresi ve yarıçap değeri için hesaplanan yönelimden bağımsız LBP öznelikleri kullanılarak nihai öznelik vektörü elde edilmiştir.

Böylece giriş görüntüsünü temel alarak yapılan öznelik çıkarma sürecine yeni bir bakış açısı kazandırılmıştır. Nötrozofik küme bileşenlerinin öznelik çıkarma sürecinde kullanılması ile etkin öznelik hesaplamaları gerçekleştirilmiştir. Bu sayede değişimin yoğun olduğu bölgelerde daha ayırt edici öznelikler elde edilirken, homojen bölgelerdeki bilgi kaybı azaltılmıştır. Önerilen yöntemin akış diyagramı Şekil 2'de verilmiştir.



Şekil 2 Önerilen yöntemin temel işlem adımları

4. Deneysel Sonuçlar

Önerilen NZ-LBP yönteminin doku sınıflandırma problemindeki etkinliğini göstermek için kapsamlı veri tabanları kullanılarak farklı deneysel çalışmalar yapılmıştır. Önerilen metodun ayırt edici gücünü ortaya çıkarmak için doğrusal ayrımcılık sınıflandırıcı (Linear discriminant classifier) kullanılmıştır. Önerilen $NZ - LBP_{(P,R)}^h$ yöntemi 3 farklı parametre içermektedir. Bunlar örnekleme komşuluğu P , nötrozofik filtre h ve örnekleme yarıçapı R 'dir. Bu çalışmadaki bütün deneylerde, özellik vektörü boyutunu ve hesaplama süresini düşürmek için $P=8$ olarak sabitlenmiştir. Ancak türev filtrelerinin tasarımında kullanılan nötrozofik filtre h ve LBP örnekleme yarıçapı R parametreleri farklı değerlerde kullanılarak önerilen yöntemin sınıflandırma doğruluğu test edilmiştir. Outex_TC_00010 [34] ve

Brodatz [35] veri setleri özellikle aynı sınıf içerisindeki dönme, aydınlanma ve bakış açısı değişimleri gibi doku analizini zorlaştıran faktörler içerdiğinden literatürde yoğun olarak kullanılmaktadır. Bu nedenle, farklı parametrelerin değerlendirmeleri için Brodatz veriseti kullanılmıştır. Bunun yanında literatür kıyaslaması için ise Outex_TC_00010 [34] ve Brodatz [35] veri setleri kullanılmıştır. Outex_TC_00010 veri seti 128x128 boyutunda 24 farklı doku sınıfına ait 4320 adet görüntüden oluşmaktadır. Brodatz veri seti ise 128x128 boyutunda 112 farklı doku sınıfına ait 1792 adet görüntüden oluşmaktadır. Sınıflandırma performansının değerlendirmesi için doğruluk (accuracy) ölçütü kullanılmıştır. Doğruluk ölçütünün nasıl hesaplandığı denklem (10)'da görülmektedir. Burada, TP, gerçekte o sınıfa ait olan ve doğru olarak tahmin edilen örnek sayısını; FN, gerçekte o sınıfa ait olan ancak hatalı şekilde tahmin edilen örnek sayısını; FP, gerçekte o sınıfa ait olmayan ve hatalı şekilde o sınıfa ait olarak belirlenen örnek sayısını; TN, gerçekte o sınıfa olmayan ve doğru şekilde tahmin edilen örnek sayısını ifade etmektedir.

$$\text{Dogruluk} = \frac{TP + TN}{TP + FP + TN + FN} \quad (10)$$

Tablo 1 Brodatz veriseti için farklı h ve R değerleri için sınıflandırma sonuçları (%).

$NZ - LBP$	$H = 1$	$H = 2$	$H = 3$	$H = 4$	$H = 5$
(P,R)=(8,1)	91.39	91.95	91.87	91.02	91.97
(P,R)=(8,2)	89.78	89.72	89.63	90.38	90.34
(P,R)=(8,3)	89.87	90.54	90.47	91.10	91.56
(P,R)=(8,4)	94.14	95.06	95.56	95.63	95.24
(P,R)=(8,5)	96.01	96.02	96.21	98.19	97.75

Nötrozofik Doğruluk kümesi hesaplanırken nötrozofik ortalama filtre (average filter) kullanılmaktadır. Bu filtrelerin yarıçapı h parametresi ile belirlenmektedir. Eğer h değeri çok küçük seçilirse, elde edilen filtrelenmiş görüntü gürültüye karşı hassas olmaktadır. Daha büyük değerli h kullanılarak tasarlanan filtreler doku detayları ve kenar-köşe gibi önemli değişim bilgilerini göz ardı edebilmektedir. Yapılan çalışmada h değerinin optimal değerleri deneysel olarak analiz edilerek çok ölçekli doku analizi gerçekleştirilmiştir. Yapılan farklı deneysel çalışmalarda 1 ile 5 arasında değişen farklı h değerleri ile yöntem analiz edilmiştir. Farklı parametrelerin sınıflandırma başarısı üzerindeki etkisi Brodatz veri seti kullanılarak analiz edilmiştir. İlk olarak farklı h ve R değerlerinin önerilen $NZ - LBP_{(P,R)}^h$ yöntemi üzerindeki etkileri gözlemlenmiştir. Tablo 1'de görüleceği üzere en yüksek doğruluk değerine h değeri 4 ve 5 alındığında ulaşılmıştır. Bunun yanında, R değeri arttıkça doğruluk değerinin arttığı sonucuna ulaşılmıştır. En yüksek başarı $R = 5$ ve $h = 4$ iken elde edilmiştir.

Tablo 2 Outex_TC_00010 veri seti için literatür kıyaslama sonuçları (%)


Yöntem	Doğruluk	Yayınlandığı Yer	Öznitelik Boyutu
Önerilen Yöntem	98.80		59
SLGP [43]	97,79	SPL 2018	168
EMCLBP [44]	99,61	MTAP 2018	8712
LSP [45]	86,12	Optik 2016	–
LNP [46]	94,97	TCSVT 2015	–
LCP [47]	98,65	SPL 2014	180
PRICoLBP [48]	94,48	TPAMI 2014	3540
Dis(S + M) [49]	98,93	PR2012	2668
LDDP [50]	98,64	NCAA2012	1100
LBPV [51]	97,63	PR 2010	2211
LBP [12]	97,7	TPAMI 2002	864

Önerilen $NZ - LBP_{(P,R)}^h$ yöntemi güncel LBP yöntemleri ile Outex_TC_00010 ve Brodatz veri setleri üzerinde karşılaştırılmıştır. Deneysel sonuçlar Tablo 2 ve Tablo 3’de verilmiştir. Karşılaştırmada kullanılan yöntemlerin sonuçları orijinal literatürden alınmıştır. Geliştirilen $NZ - LBP_{(P,R)}^h$ yöntemi tüm veri setlerinde en yüksek sınıflandırma doğruluğu elde etmiştir. Vurgulanması gereken en önemli nokta şudur: Nötrozofik kümenin gürültü bileşenlerini baskılaması ve bu sayede kenar bilgileri daha doğru bir şekilde hesaplanabilmesi ile daha ayırt edici öznelikler elde edilmiştir. Nötrozofik doğruluk kümesinin LBP öznelikleri elde edilerek nihai doku analizi gerçekleştirilmiştir. Dolayısıyla LBP yönteminin doku analiz gücü ile nötrozofik kümenin gücü birleştirilmiştir. Tablo 2 ve 3’de görüldüğü gibi, önerilen yöntem düşük öznelik boyutuna rağmen tüm veri setlerinde iyi sonuçlar elde etmiştir. Brodatz veri seti için sınıflandırma doğruluğunu en az %1 en fazla %56 oranında artırılmıştır. Ayrıca geleneksel LBP yönteminin sınıflandırma doğruluğunu %11 oranında artırılmıştır.

Tablo 3 Brodatz veri seti için literatür kıyaslama sonuçları (%).

Yöntem	Kaynakça	Doğruluk
Önerilen Yöntem		98.19
LDENP [36]	Pillai et al. (2018)	95.86
LBDP[37]	Dubey et al. (2016)	97.08
dLBP α [38]	Kaya et al. (2015)	97.28
AECLBP_C[39]	Kecheh et al. (2015)	43.54
LBDP[40]	Hong et al. (2014)	51.12
NTLBP[41]	Fathi and Naghsh-Nilchi (2012)	97.85
LOSIB[42]	Garca-Olalla et al. (2014)	86.71
LBP	Ojala et al. (1996)	87.30

Geliştirilen yöntem yüksek doğruluk sonuçları elde etmekle birlikte aynı zamanda hesaplama maliyeti açısından da çok uygun bir konumdadır. Bu durum Şekil 3’de açıkça görülmektedir. Deneyler Intel Core i5-7400 CPU ve 8GB RAM özelliklerine sahip bir bilgisayarda bir görüntü için öznelikleri hesaplamak için farklı yöntemlerin ortalama çalışma süreleri karşılaştırılmıştır. Zaman karşılaştırması için LBP [52], RALBGC [53], LDTP [54], LCxMSP [30], MRELBP [55], PCLBP [56], BPPC [57], LGDiP [58], LGBPHS [59] yöntemleri kullanılmıştır. Geliştirilen $NZ - LBP_{(P,R)}^h$ yöntemi geleneksel LBP yönteminin sınıflandırma doğruluğu öznelik boyutunu artırmadan iyileştirilmiştir. Ayrıca önerilen yöntem sınıflandırma doğruluğunu artırırken hesapsal maliyeti dikkate değer oranda artırmamıştır. Bununla birlikte, nötrozofik küme hesaplaması çok zaman alıcı olmadığından, önerilen $NZ - LBP_{(P,R)}^h$ yönteminin gerçek zamanlı uygulamalarda kullanımı uygundur.



Şekil 3 Örnek test görüntüsü için yöntemlere ait öznelik çıkarma süreleri

5. Sonuç

Bu çalışmada doku sınıflandırma problemi için yerel ikili örüntü (LBP) yöntemi nötrozofik küme temelinde yeniden yorumlanmış ve nötrozofik küme bileşenlerini kullanan yeni bir öznelik çıkarma yöntemi önerilmiştir. Önerilen yöntemde geleneksel LBP tanımlayıcıları hesaplanırken orijinal giriş görüntüsü yerine görüntünün nötrozofik doğruluk kümesi kullanılmıştır. Böylece gürültü etkileri azaltılmış daha anlamlı bir görüntü elde edilmiştir. Nötrozofik kümenin gürültü bileşenlerini baskılaması ile kenar ve dokusal bilgiler daha anlamlı bir şekilde hesaplanmıştır. Nötrozofik doğruluk kümesinin LBP öznelikleri elde edilerek nihai doku analizi gerçekleştirilmiştir. Dolayısıyla LBP yönteminin doku analiz gücü ile nötrozofik kümenin gücü birleştirilmiştir. Önerilen yöntem, düşük öznelik boyutu, uygun hesaplama maliyeti ile yüksek sınıflandırma doğrulukları elde etmiştir. Deneysel sonuçlar önerilen yöntemin öznelik boyutunu artırmadan yerel ikili örüntü yönteminin sınıflandırma doğruluğunu yaklaşık %11 artırdığını göstermektedir. Elde edilen sonuçlar önerilen yöntemin gerçek zamanlı uygulamalar için uygulanabilir olduğunu ortaya koymaktadır. Önerilen yöntem sınıflandırma, anlamsal bölütleme ve nesne takibi gibi birçok alanda ara işlem olarak kullanılabilir. Bununla birlikte örnekleme komşuluğu P , nötrozofik filtre h ve örnekleme yarıçapı R parametreleri sonuçlar üzerinde etkili olmakla beraber yöntemin parametre bağımlılığını artırmaktadır. Ayrıca öznelik çıkarma işlemi öncesinde görüntü nötrozofik alana dönüştürüldüğü için, LBP yöntemine göre kısmen zaman maliyeti içermektedir.

Kaynakça

- [1] G. Doretto, A. Chiuso, Y. N. Wu, and S. Soatto, "Dynamic Textures," *Int. J. Comput. Vis.*, vol. 51, no. 2, pp. 91–109, 2003, doi: 10.1023/A:1021669406132.
- [2] M. A. Muqet and R. S. Holambe, "Local binary patterns based on directional wavelet transform for expression and pose-invariant face recognition," *Appl. Comput. Informatics*, vol. 15, no. 2, pp. 163–171, Jul. 2019, doi: 10.1016/J.ACI.2017.11.002.
- [3] M. Varma and A. Zisserman, "A Statistical Approach to Texture Classification from Single Images," *Int. J. Comput. Vis.*, vol. 62, no. 1/2, pp. 61–81, Apr. 2005, doi: 10.1023/B:VISI.0000046589.39864.ee.
- [4] P. P. Ohanian and R. C. Dubes, "Performance evaluation for four classes of textural features," *Pattern Recognit.*, vol. 25, no. 8, pp. 819–833, Aug. 1992, doi: 10.1016/0031-3203(92)90036-I.
- [5] A. Speis and G. Healey, "Feature extraction for texture discrimination via random field models with random spatial interaction," *IEEE Trans. Image Process.*, vol. 5, no. 4, pp. 635–645, Apr. 1996, doi: 10.1109/83.491339.
- [6] W.-K. Lam and C.-K. Li, "Rotated texture classification by improved iterative morphological decomposition," *IEE Proc. - Vision, Image, Signal Process.*, vol. 144, no. 3, p. 171, 1997, doi: 10.1049/ip-vis:19971198.
- [7] T. Randen and J. H. Husoy, "Filtering for texture classification: a comparative study," *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 21, no. 4, pp. 291–310, Apr. 1999, doi: 10.1109/34.761261.
- [8] N. Dasgupta and L. Carin, "Texture analysis with variational hidden Markov trees," *IEEE Trans. Signal Process.*, vol. 54, no. 6, pp. 2353–2356, Jun. 2006, doi: 10.1109/TSP.2006.872588.
- [9] A. Maleki, B. Rajaei, and H. R. Pourreza, "Rate-Distortion Analysis of Directional Wavelets," *IEEE Trans. Image Process.*, vol. 21, no. 2, pp. 588–600, Feb. 2012, doi: 10.1109/TIP.2011.2165551.
- [10] R. M. Haralick, K. Shanmugam, and I. Dinstein, "Textural Features for Image Classification," *IEEE Trans. Syst. Man. Cybern.*, vol. SMC-3, no. 6, pp. 610–621, Nov. 1973, doi: 10.1109/TSMC.1973.4309314.

- [11] G. R. Cross and A. K. Jain, "Markov Random Field Texture Models," *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. PAMI-5, no. 1, pp. 25–39, Jan. 1983, doi: 10.1109/TPAMI.1983.4767341.
- [12] T. Ojala, M. Pietikainen, and T. Maenpaa, "Multiresolution gray-scale and rotation invariant texture classification with local binary patterns," *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 24, no. 7, pp. 971–987, Jul. 2002, doi: 10.1109/TPAMI.2002.1017623.
- [13] P. Subudhi and S. Mukhopadhyay, "An efficient graph reduction framework for interactive texture segmentation," *Signal Process. Image Commun.*, vol. 74, pp. 42–53, May 2019, doi: 10.1016/J.IMAGE.2019.01.010.
- [14] C. Li, Y. Huang, X. Yang, and H. Chen, "Marginal distribution covariance model in the multiple wavelet domain for texture representation," *Pattern Recognit.*, vol. 92, pp. 246–257, Aug. 2019, doi: 10.1016/J.PATCOG.2019.04.003.
- [15] C. Li, Y. Huang, and L. Zhu, "Color texture image retrieval based on Gaussian copula models of Gabor wavelets," *Pattern Recognit.*, vol. 64, pp. 118–129, Apr. 2017, doi: 10.1016/J.PATCOG.2016.10.030.
- [16] Y. Song *et al.*, "Gaussian derivative models and ensemble extreme learning machine for texture image classification," *Neurocomputing*, vol. 277, pp. 53–64, Feb. 2018, doi: 10.1016/J.NEUCOM.2017.01.113.
- [17] K. Hanbay, N. Alpaslan, M. F. Talu, and D. Hanbay, "Principal curvatures based rotation invariant algorithms for efficient texture classification," *Neurocomputing*, vol. 199, pp. 77–89, Jul. 2016, doi: 10.1016/j.neucom.2016.03.032.
- [18] K. Hanbay, N. Alpaslan, M. F. Talu, D. Hanbay, A. Karci, and A. F. Kocamaz, "Continuous rotation invariant features for gradient-based texture classification," *Comput. Vis. Image Underst.*, vol. 132, pp. 87–101, 2015, doi: 10.1016/j.cviu.2014.10.004.
- [19] X. Bu, Y. Wu, Z. Gao, and Y. Jia, "Deep convolutional network with locality and sparsity constraints for texture classification," *Pattern Recognit.*, vol. 91, pp. 34–46, Jul. 2019, doi: 10.1016/J.PATCOG.2019.02.003.
- [20] S. Basu *et al.*, "Deep neural networks for texture classification—A theoretical analysis," *Neural Networks*, vol. 97, pp. 173–182, Jan. 2018, doi: 10.1016/J.NEUNET.2017.10.001.
- [21] J. Zhang, Y. Xie, Q. Wu, and Y. Xia, "Medical image classification using synergic deep learning," *Med. Image Anal.*, vol. 54, pp. 10–19, May 2019, doi: 10.1016/J.MEDIA.2019.02.010.
- [22] M. Talo, U. B. Baloglu, Ö. Yildirim, and U. Rajendra Acharya, "Application of deep transfer learning for automated brain abnormality classification using MR images," *Cogn. Syst. Res.*, vol. 54, pp. 176–188, May 2019, doi: 10.1016/J.COGSYS.2018.12.007.
- [23] G. Srivastava and R. Srivastava, "Salient object detection using background subtraction, Gabor filters, objectness and minimum directional backgroundness," *J. Vis. Commun. Image Represent.*, vol. 62, pp. 330–339, Jul. 2019, doi: 10.1016/J.JVCIR.2019.06.005.
- [24] X. Zhao, Y. Lin, and J. Heikkila, "Dynamic Texture Recognition Using Volume Local Binary Count Patterns With an Application to 2D Face Spoofing Detection," *IEEE Trans. Multimed.*, vol. 20, no. 3, pp. 552–566, Mar. 2018, doi: 10.1109/TMM.2017.2750415.
- [25] Z. Pan, Z. Li, H. Fan, and X. Wu, "Feature based local binary pattern for rotation invariant texture classification," *Expert Syst. Appl.*, vol. 88, pp. 238–248, Dec. 2017, doi: 10.1016/J.ESWA.2017.07.007.
- [26] N. Alpaslan and K. Hanbay, "Multi-Resolution Intrinsic Texture Geometry-Based Local Binary Pattern for Texture Classification," *IEEE Access*, vol. 8, pp. 54415–54430, 2020, doi: 10.1109/ACCESS.2020.2981720.
- [27] F. Yuan, X. Xia, and J. Shi, "Mixed co-occurrence of local binary patterns and Hamming-

- distance-based local binary patterns,” *Inf. Sci. (Ny)*, vol. 460–461, pp. 202–222, Sep. 2018, doi: 10.1016/J.INS.2018.05.033.
- [28] S. Naeem, F. Riaz, A. Hassan, and R. Nisar, “Description of Visual Content in Dermoscopy Images Using Joint Histogram of Multiresolution Local Binary Patterns and Local Contrast,” in *International Conference on Intelligent Data Engineering and Automated Learning*, 2015, pp. 433–440, doi: 10.1007/978-3-319-24834-9_50.
- [29] M. Heikkilä, M. Pietikäinen, and C. Schmid, “Description of Interest Regions with Center-Symmetric Local Binary Patterns,” in *Computer Vision, Graphics and Image Processing*, 2006, pp. 58–69, doi: 10.1007/11949619_6.
- [30] Y. El merabet and Y. Ruichek, “Local Concave-and-Convex Micro-Structure Patterns for texture classification,” *Pattern Recognit.*, vol. 76, pp. 303–322, Apr. 2018, doi: 10.1016/J.PATCOG.2017.11.005.
- [31] F. Smarandache, *A Unifying Field in Logics: Neutrosophic Logic. Neutrosophy, Neutrosophic Set, Neutrosophic Probability*, Third edit. American Research Press, 2003.
- [32] K. Hanbay, “Nötrozofik Küme Temelli Difüzyon Metodu Kullanılarak Görüntülerdeki Örtüşme Problemini Azaltma,” *Eur. J. Sci. Technol.*, no. 18, pp. 505–514, Apr. 2020, doi: 10.31590/ejosat.695191.
- [33] J. Mohan, V. Krishnaveni, and Y. Guo, “MRI denoising using nonlocal neutrosophic set approach of Wiener filtering,” *Biomed. Signal Process. Control*, vol. 8, no. 6, pp. 779–791, Nov. 2013, doi: 10.1016/j.bspc.2013.07.005.
- [34] T. Ojala, T. Mäenpää, M. Pietikäinen, J. Viertola, J. Kyllönen, and S. Huovinen, “Outex - New framework for empirical evaluation of texture analysis algorithms,” *Proc. - Int. Conf. Pattern Recognit.*, vol. 16, no. 1, pp. 701–706, 2002, doi: 10.1109/icpr.2002.1044854.
- [35] Y. Xu, H. Ji, and C. Fermüller, “Viewpoint invariant texture description using fractal analysis,” *Int. J. Comput. Vis.*, vol. 83, no. 1, pp. 85–100, Jun. 2009, doi: 10.1007/s11263-009-0220-6.
- [36] A. Pillai, R. Soundrapandiyan, S. Satapathy, S. C. Satapathy, K. H. Jung, and R. Krishnan, “Local diagonal extrema number pattern: A new feature descriptor for face recognition,” *Futur. Gener. Comput. Syst.*, vol. 81, pp. 297–306, Apr. 2018, doi: 10.1016/j.future.2017.09.055.
- [37] S. R. Dubey, S. K. Singh, and R. K. Singh, “Local Bit-Plane Decoded Pattern: A Novel Feature Descriptor for Biomedical Image Retrieval,” *IEEE J. Biomed. Heal. Informatics*, vol. 20, no. 4, pp. 1139–1147, Jul. 2016, doi: 10.1109/JBHI.2015.2437396.
- [38] Y. Kaya, Ö. F. Ertuğrul, and R. Tekin, “Two novel local binary pattern descriptors for texture analysis,” *Appl. Soft Comput.*, vol. 34, pp. 728–735, Sep. 2015, doi: 10.1016/J.ASOC.2015.06.009.
- [39] K. Song, Y. Yan, Y. Zhao, and C. Liu, “Adjacent evaluation of local binary pattern for texture classification,” *J. Vis. Commun. Image Represent.*, vol. 33, pp. 323–339, Nov. 2015, doi: 10.1016/j.jvcir.2015.09.016.
- [40] X. Hong, G. Zhao, M. Pietikäinen, and X. Chen, “Combining LBP difference and feature correlation for texture description,” *IEEE Trans. Image Process.*, vol. 23, no. 6, pp. 2557–2568, 2014, doi: 10.1109/TIP.2014.2316640.
- [41] A. Fathi and A. R. Naghsh-Nilchi, “Noise tolerant local binary pattern operator for efficient texture analysis,” *Pattern Recognit. Lett.*, vol. 33, no. 9, pp. 1093–1100, Jul. 2012, doi: 10.1016/j.patrec.2012.01.017.
- [42] O. García-Olalla, E. Alegre, L. Fernández-Robles, and V. González-Castro, “Local oriented statistics information booster (LOSIB) for texture classification,” in *Proceedings - International Conference on Pattern Recognition*, 2014, pp. 1114–1119, doi: 10.1109/ICPR.2014.201.
- [43] T. Song, L. Xin, C. Gao, G. Zhang, and T. Zhang, “Grayscale-Inversion and Rotation Invariant

- Texture Description Using Sorted Local Gradient Pattern,” *IEEE Signal Process. Lett.*, vol. 25, no. 5, pp. 625–629, May 2018, doi: 10.1109/LSP.2018.2809607.
- [44] M. H. Shakoor and R. Boostani, “A novel advanced local binary pattern for image-based coral reef classification,” *Multimed. Tools Appl.*, vol. 77, no. 2, pp. 2561–2591, Jan. 2018, doi: 10.1007/s11042-017-4394-6.
- [45] S. Du, Y. Yan, and Y. Ma, “Local spiking pattern and its application to rotation- and illumination-invariant texture classification,” *Optik (Stuttg.)*, vol. 127, no. 16, pp. 6583–6589, Aug. 2016, doi: 10.1016/j.ijleo.2016.04.002.
- [46] S. Wang, Q. Wu, X. He, J. Yang, and Y. Wang, “Local N-Ary Pattern and Its Extension for Texture Classification,” *IEEE Trans. Circuits Syst. Video Technol.*, vol. 25, no. 9, pp. 1495–1506, Sep. 2015, doi: 10.1109/TCSVT.2015.2406198.
- [47] T. Song *et al.*, “Noise-robust texture description using local contrast patterns via global measures,” *IEEE Signal Process. Lett.*, vol. 21, no. 1, pp. 93–96, 2014, doi: 10.1109/LSP.2013.2293335.
- [48] X. Qi, R. Xiao, C. G. Li, Y. Qiao, J. Guo, and X. Tang, “Pairwise rotation invariant co-occurrence local binary pattern,” *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 36, no. 11, pp. 2199–2213, Nov. 2014, doi: 10.1109/TPAMI.2014.2316826.
- [49] Y. Guo, G. Zhao, and M. Pietikäinen, “Discriminative features for texture description,” *Pattern Recognit.*, vol. 45, no. 10, pp. 3834–3843, Oct. 2012, doi: 10.1016/j.patcog.2012.04.003.
- [50] Z. Guo, Q. Li, J. You, D. Zhang, and W. Liu, “Local directional derivative pattern for rotation invariant texture classification,” *Neural Comput. Appl.*, vol. 21, no. 8, pp. 1893–1904, Apr. 2012, doi: 10.1007/s00521-011-0586-6.
- [51] Z. Guo, L. Zhang, and D. Zhang, “Rotation invariant texture classification using LBP variance (LBPV) with global matching,” *Pattern Recognit.*, vol. 43, no. 3, pp. 706–719, Mar. 2010, doi: 10.1016/j.patcog.2009.08.017.
- [52] T. Ojala, M. Pietikainen, and T. Maenpaa, “Multiresolution gray-scale and rotation invariant texture classification with local binary patterns,” *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 24, no. 7, pp. 971–987, Jul. 2002, doi: 10.1109/TPAMI.2002.1017623.
- [53] I. El Khadiri, M. Kas, Y. El Merabet, Y. Ruichek, and R. Touahni, “Repulsive-and-attractive local binary gradient contours: New and efficient feature descriptors for texture classification,” *Inf. Sci. (Ny)*, vol. 467, pp. 634–653, Oct. 2018, doi: 10.1016/J.INS.2018.02.009.
- [54] A. Ramírez Rivera, J. Rojas Castillo, and O. Chae, “Local Directional Texture Pattern image descriptor,” *Pattern Recognit. Lett.*, vol. 51, pp. 94–100, Jan. 2015, doi: 10.1016/j.patrec.2014.08.012.
- [55] L. Liu, S. Lao, P. W. Fieguth, Y. Guo, X. Wang, and M. Pietikäinen, “Median Robust Extended Local Binary Pattern for Texture Classification,” *IEEE Trans. Image Process.*, vol. 25, no. 3, pp. 1368–1381, Mar. 2016, doi: 10.1109/TIP.2016.2522378.
- [56] Q. Kou, D. Cheng, L. Chen, and Y. Zhuang, “Principal curvatures based local binary pattern for rotation invariant texture classification,” *Optik (Stuttg.)*, vol. 193, p. 162999, Sep. 2019, doi: 10.1016/J.IJLEO.2019.162999.
- [57] S. Shojailangari, W. Y. Yau, J. Li, and E. K. Teoh, “Feature extraction through Binary Pattern of Phase Congruency for facial expression recognition,” in *2012 12th International Conference on Control, Automation, Robotics and Vision, ICARCV 2012*, 2012, pp. 166–170, doi: 10.1109/ICARCV.2012.6485152.
- [58] S. M. Z. Ishraque, A. K. M. H. Banna, and O. Chae, “Local Gabor directional pattern for facial expression recognition,” in *Proceeding of the 15th International Conference on Computer and Information Technology, ICCIT 2012*, 2012, pp. 164–167, doi:

10.1109/ICCITech.2012.6509762.

- [59] W. Zhang, S. Shan, W. Gao, X. Chen, and H. Zhang, “Local Gabor Binary Pattern Histogram Sequence (LGBPHS): A novel non-statistical model for face representation and recognition,” in *Proceedings of the IEEE International Conference on Computer Vision*, 2005, vol. I, pp. 786–791, doi: 10.1109/ICCV.2005.147.