

DOKU HATALARININ YÜKSEK DERECELİ İSTATİSTİKLER KULLANILARAK BELİRLENMESİ*

Birkan ARAS, Aysın ERTÜZÜN¹ ve Aytül ERÇİL²

¹Elektrik-Elektronik Mühendisliği Bölümü,

²Endüstri Mühendisliği Bölümü,

Boğaziçi Üniversitesi Bebek, 80815, İstanbul

ertuz@boun.edu.tr, ercil@boun.edu.tr

Özetçe

Bu bildiriye, yüksek dereceli istatistikler, önemli doku analizi uygulama alanlarından biri olan doku hatalarının belirlenmesi probleminin çözümü için kullanılmış, elde edilen sonuçlar hem başarı, hem de hesaplama karmaşıklığı bakımından ikinci dereceli istatistiklere dayanan yöntemlerle karşılaştırılmıştır.

1. Giriş

Kalite kontrol, imalat sektöründe hatalı ürünlerin müşteriye ulaşmamasını garantileyen çok önemli bir konudur. Yapay görme, kalite kontrol işleminde hassas ve ucuz çok önemli bir teknolojidir. Herhangi bir yüzeyin kalitesi en iyi dokusu ile tanımlanabilir; bundan dolayı da doku analizi yapay görme kalite kontrol işlemlerinde çok önemli bir rol oynar. Doku işleme tekniklerinin kalite kontrol konusuna uygulanmasında yapılan çalışmalar şöyle sıralanabilir: Erçil ve *çalışma arkadaşları*[1] verilen boyalı bir yüzeydeki hataları sezme ve konumlarını belirlemek üzere model temelli bir yöntem geliştirmişlerdir. Jain ve *çalışma arkadaşları*[2] boyalı metalik yüzeylerdeki düzgünlüğün otomatik olarak sınıflandırılması için Gabor süzgeç çıktılarından öznelikler hesaplamışlardır. Chen ve Jain ve *çalışma arkadaşları*[3] doku imgelerindeki hataları bulmak için yapısal bir yaklaşım kullanmışlardır. Connors ve *çalışma arkadaşları*[4] doku analiz metodlarını kullanarak ahşap dokulardaki hataları sezimlemişlerdir. Siew ve *çalışma arkadaşları*[5] halılardaki aşınmayı algılayan bir metod geliştirmişlerdir. Dewaele ve *çalışma arkadaşları*[6] işaret işleme metodları ile doku imgelerinde rastlanabilecek bölgesel ve çizgisel hataları sezimlemişlerdir.

Dokuların ikinci dereceli istatistiklerine dayanan işaret işleme araçları, doku analizi için uzun yıllardır kullanılmaktadır [7]. Son yıllarda gerçekleştirilen işaret işleme çalışmalarında, ikinci dereceli istatistiksel analize dayalı yöntemleri, daha yüksek derecelere doğru geliştirmek yönünde bir eğilim bulunmaktadır [8]. Yüksek dereceli istatistikler, Gaussal olmamanın, karma evreliliğin, renkli gürültünün veya doğrusalsızlığın önemli olduğu problemlerin çözümü için çok yararlı olmuşlardır. Tsatsanis ve Giannakis yüksek dereceli istatistiklerin (izgenin) doku sınıflandırılması probleminde uygulanması konusunda çalışmışlardır[9].

Sunulan çalışmada ise yüksek dereceli istatistikler ve yüksek dereceli istatistikleri ikinci dereceli istatistiklerle beraber kullanan karma yöntemler doku hatalarının belirlenmesin probleminde kullanılmıştır[10]. Hata belirleme sisteminin öznelik çıkarım kısmında değişik istatistiklerden oluşturulan öznelik vektörleri hesaplanmış; öznelik analiz kısmında ise mahalonobis uzaklığı sınıflandırıcısı dokuyu, hatalı veya hatasız olarak iki sınıfa ayırmıştır. Önerilen yöntem gerçek tekstil ürünleri üzerinde denenmiştir.

*Bu çalışma, Türkiye Teknoloji Geliştirme Vakfı tarafından TTGV 169 proje numarası ile kısmen desteklenmiştir.

2. Yüksek Dereceli İstatistikler ile İlgili Temel Bilgiler

İkinci dereceli istatistiklerden ve/veya güç izgesinden yararlanılan işaret işleme yöntemlerinde, frekans bileşenleri arasındaki evre ilişkileri gözönünde bulundurulmaz; bu sebepten dolayı bu yöntemler evre bilgisine karşı kördürler. Ayrıca ikinci dereceli istatistikler ve güç izgesi Gauss olmayan süreçlerin istatistiksel açıdan tam olarak tanımlanmaları için yeterli değildir. Son yıllarda, rassal süreçlerin istatistiksel olarak daha hassas olarak tanımlanmaları ve evre bilgilerinin işlenmesi için yüksek dereceli istatistikler (ikiden büyük) ve izge üzerinde çalışmalar yapılmaktadır.

$\{x_1, x_2, \dots, x_n\}$ n tane gerçel rassal değişkenden oluşan bir küme ise, kümedeki elamanların $r = k_1 + k_2 + \dots + k_n$ dereceden ortak kumulantları şu şekilde ifade edilebilir:

$$C [x_1^{k_1}, x_2^{k_2}, \dots, x_n^{k_n}] = (-j)^r \frac{\partial^r \ln \Phi(w_1, w_2, \dots, w_n)}{\partial w_1^{k_1} \partial w_2^{k_2} \dots \partial w_n^{k_n}} \Big|_{w_1 = w_2 = \dots = w_n = 0} \quad (2.1)$$

Burada $\Phi(w_1, w_2, \dots, w_n)$ ortak karakteristik fonksiyonudur ve aşağıda tanımlanmıştır. Aşağıdaki tanımda kullanılan $E\{\cdot\}$ beklenti operatörüdür.

$$\Phi(w_1, w_2, \dots, w_n) = E\left\{\exp(j(w_1 x_1 + w_2 x_2 + \dots + w_n x_n))\right\} \quad (2.2)$$

Gerçel, durağan ve ayrık zamanda tanımlı $X(k)$ işaretinin n'inci dereceden moment fonksiyonu aşağıdaki gibi tanımlanır:

$$m_n^x(\tau_1, \tau_2, \dots, \tau_{n-1}) = E\{X(k)X(k + \tau_1) \dots X(k + \tau_{n-1})\} \quad (2.3)$$

Yukarıda (2.3) numaralı ifadede tanımlanan moment fonksiyonu zaman farklarını temsil eden $\tau_1, \tau_2, \dots, \tau_{n-1}$ değerlerinin fonksiyonudur. $X(k)$ işaretinin birinci dereceden moment $m_1^x = E\{X(k)\}$, işaretin ortalama değeridir; ikinci dereceden moment fonksiyonu $m_2^x(\tau_1) = E\{X(k)X(k + \tau_1)\}$ ise $X(k)$ 'in özilinti fonksiyonudur.

Gerçel, durağan ve ayrık zamanda tanımlı $X(k)$ işaretinin n'inci dereceden kumulant fonksiyonu ise aşağıdaki gibi tanımlanır:

$$c_n^x(\tau_1, \tau_2, \dots, \tau_{n-1}) = E\{X'(k), X'(k + \tau_1), \dots, X'(k + \tau_{n-1})\} \quad (2.4)$$

Burada $X'(k)$ işareti $X(k)$ işaretinin sıfır ortalamalı halidir. Bundan dolayı işaret sıfır ortalamalı ise ikinci ve üçüncü dereceden kumulantları, sırasıyla, ikinci ve üçüncü dereceden momentlerine eşit olur. Ancak daha yüksek dereceden kumulantlar için bu ilişki geçerli değildir.

Gerçel, durağan rassal alanlar için yüksek dereceli moment ve kumulant tanımları yukarıda verilen tanımlara çok benzemektedir. (2.3) ve (2.4) numaralı ifadelerdeki k ve τ değişkenleri, gerçel, durağan ayrık zaman işaretleri için skalar niteliklerdir. Bu değerler vektör değişkenler $k = [k_1, k_2]^T$ ve $\tau = [\tau_1, \tau_2]^T$ olarak yorumlanırsa, gerçel, durağan, rassal alanların yüksek dereceli istatistiklerinin tanımları ve denklemleri ortaya çıkar.

3. Doku Hata Belirlemede Yüksek Dereceli İstatistikler

İkinci dereceli istatistik veya güç izgesine dayanan işaret işleme teknikleri, genellikle işaretin özilinti gecikmelerinin (autocorrelation lags) sayısına bağlıdır. Analizde kullanılan özilinti gecikmelerinin sayısı analizin karmaşıklığını belirlemektedir. Model temelli bir açıdan bakıldığında, özilinti gecikmelerinin sayısı işareti ürettiği düşünülen modelin karmaşıklığını belirlemektedir. İmge işleme de ise özilinti gecikmeleri komşuluk ilişkileri ile tanımlanmaktadır.

Komşuluk ilişkileri pikseller arasındaki uzaklıklar ile tanımlandığı için belirli bir pikselden aynı uzaklığa sahip piksellerin komşuluk dereceleri aynıdır.

Markov rassal alanlar (MRA) özilinti fonksiyonu kavramından yararlanan model tabanlı imge analiz yöntemleridir. İmgedeki herhangi bir noktanın parlaklık seviyesi, imge beyaz gürültü olmadığı sürece, komşu noktaların parlaklık seviyelerine bağlıdır. MRA bu bağımlılığın hassas bir modelini kullanarak imgedeki uzamsal bağımlılığı yakalamaktadırlar. Bu modellerde imgedeki herhangi bir pikselin parlaklığının komşu piksel parlaklıklarına bağımlı olduğu varsayılmakta ve özilintinin çift fonksiyon olmasından dolayı özilinti gecikmeleri yerine yeterli istatistikler kullanılmaktadır[1]. Özilinti gecikmelerine bağlı olan komşuluk ilişkileri iki piksel arasındaki uzaklığa bağlı olduğu için yüksek dereceli istatistikler için kullanılamazlar. Yüksek dereceli istatistikler ikiden fazla piksel ile ilgili oldukları için komşuluk tanımının piksel grubuna genelleştirilmesi gerekmektedir. Piksel grubundaki piksel sayısı yüksek dereceli istatistiğin derecesine bağlıdır. Bir grup pikselin komşuluk derecesi, o gruptaki iki piksellik kombinezonların komşuluk derecelerinin en büyüğüne eşittir [10]. Bu çalışmada geliştirilmiş olan komşuluk kavramı yüksek dereceli istatistiklerle MRA aynı çatı altına koymaktadır.

Herhangi bir yapay görme sistemi öznitelik çıkarım kısmı ve öznitelik analiz kısmı olmak üzere iki ana kısımdan oluşmaktadır. Veri uzayının boyutlarının küçültülmesi olarak yorumlanabilen öznitelik çıkarım kısmı en önemli kısımdır çünkü sistemin genel başarımı bu kısma bağımlıdır. Uygun özniteliklerin seçimi son derece önemlidir. Öznitelik analiz kısmı ise özniteliklerin taşıdığı bilgiler hakkında karar veren bir mekanizmadır.

Bu çalışmadaki ana amaç yüksek dereceli istatistiksel özniteliklerin diğer bir deyişle kumulant gecikmelerinin doku hata sisteminin öznitelik çıkarım kısmında kullanılmasıdır[10]. Aşağıda, bu çalışmada denenen tüm öznitelik vektörleri sıralanmışlardır:

- 1) İkinci komşuluğa dek ikinci dereceli istatistikler (İ2)
- 2) Beşinci komşuluğa dek ikinci dereceli istatistikler (İ5)
- 3) Dokuzuncu komşuluğa dek ikinci dereceli istatistikler (İ9)
- 4) İkinci komşuluğa dek üçüncü dereceli istatistikler (Ü2)
- 5) Beşinci komşuluğa dek üçüncü dereceli istatistikler (Ü5)
- 6) Tsatsanis ve Giannakis [9] tarafından önerilen üçüncü dereceli istatistikler (Ü31)
- 7) İkinci komşuluğa dek dördüncü dereceli istatistikler (D2)
- 8) İkinci komşuluğa dek ikinci ve üçüncü dereceli istatistikler (İ2Ü2)
- 9) Beşinci komşuluğa dek ikinci dereceli istatistikler ve ikinci komşuluğa dek üçüncü dereceli istatistikler (İ5Ü2)
- 10) Dokuzuncu komşuluğa dek ikinci dereceli istatistikler ve ikinci komşuluğa dek üçüncü dereceli istatistikler (İ9Ü2)
- 11) İkinci komşuluğa dek ikinci, üçüncü ve dördüncü dereceli istatistikler (İ2Ü2D2)

İlk üç öznitelik vektörü sadece ikinci dereceli istatistiklerden oluşmuştur. Daha sonraki dört öznitelik vektörü ise sadece yüksek dereceli istatistikleri kapsamaktadır. Bunlardan üçü komşuluk bağlamında tanımlı istatistiklerden bu çalışmada oluşturulmuştur [10]; bir tanesi ise Tsatsanis ve Giannakis [9] tarafından doku sınıflandırması için önerilmiş olan $\{c_3^x([i_1, i_2], [j_1, j_2]), i_1 = 0, i_2 = 0, 1, 0 \leq j_1, j_2 \leq 3\}$ kumulant kümesinden oluşan öznitelik vektörüdür. Bu kümedeki kumulant gecikmeleri asimetriktir. Geriye kalan dört öznitelik vektörü ise hem ikinci dereceli istatistiklerden, hem de yüksek dereceli istatistiklerden oluşan karma öznitelik vektörleridir.

Bu çalışmada, $N \times N$ boyutundaki $I(n, m)$ imgesi pxp boyutunda örtüşmeyen alt pencerelere (S_i) bölünür. Her alt pencere için ikinci ve yüksek dereceli istatistikler hesaplanır ve yukarıda verilmiş olan öznitelik vektörleri oluşturulur. Öznitelik vektörleri, her alt pencere için x_i olarak isimlendirilir; i alt pencere sayısını göstermektedir.

Sistemin öznitelik analiz kısmı, öğrenim ve sınıflandırma fazlarından oluşmaktadır:

Öğrenim Fazı

- (i) $N \times N$ boyutundaki k adet hatasız doku imgesinin her alt penceresi için öznitelik vektörleri hesaplanır ve bunlar doğru öznitelik vektörleri, \mathbf{t}_i , olarak kabul edilir.
- (ii) Öznitelik vektörleri \mathbf{t}_i 'lerin ortalama vektörü \mathbf{m} ve çapraz değişinti matrisi \mathbf{K} hesaplanır.

Sınıflandırma Fazı

- (i) Verilen test imgesi için öznitelik vektörleri \mathbf{x}_i 'ler hesaplanır.
- (ii) Her öznitelik vektörü \mathbf{x}_i ile ortalama vektör \mathbf{m} arasındaki mahalanobis uzaklık d_i çapraz değişinti matrisi \mathbf{K} 'yi kullanarak aşağıdaki gibi bulunur:

$$d_i = (\mathbf{x}_i - \mathbf{m})^T \mathbf{K}^{-1} (\mathbf{x}_i - \mathbf{m}) \quad (3.1)$$

- (iii) Her S_i alt penceresi ile ilgili olan d_i uzaklığı belli bir eşik değeri α 'yı geçiyorsa, o alt pencere hatalı, geçmiyorsa hatasız olarak belirlenir.

$$S_i = \begin{cases} \text{hatalı} & d_i > \alpha \\ \text{hatasız} & d_i < \alpha \end{cases}$$

Eşik değeri α , mahalanobis uzaklıkların küçükten büyüğe doğru sıralanması ile elde edilen sıra istatistiklerinin örnek ortanca değeri (D_m) ve örnek üst çeyrek kütle (D_q) cinsinden şu şekilde tanımlanmıştır:

$$\alpha = D_m + \eta (D_q - D_m) \quad (3.2)$$

Burada η deneysel olarak bulunan bir sabittir. M adet alt pencereye bölünmüş olan bir imge için $D_m = (D_{M/2} + D_{M/2+1})/2$ ve $D_q = (D_{M-M/4} + D_{M-M/4+1})/2$. Eşik değeri bulunurken, uzaklıkların ortalama değeri yerine örnek ortanca değerinin kullanılmasının sebebi hatalı alt pencereler için ortalama değerlerin güvenilir bir ölçüt olmamasıdır.

Sınıflandırıcı, imgenin diğer kısımlardan önemli ölçüde farklılık gösteren alt pencereleri hatalı olarak nitelendirmektedir.

4. Uygulama ve Sonuçlar

Yukarıda detaylı şekilde anlatılan doku hata tespit yöntemi tekstil ürünlerindeki dokuma hatalarının bulunmasında kullanılmıştır. Bu amaçla laboratuvar ortamında CCD kamera ile gerçek kumaş imgeleri elde edilmiştir[10]. İmgeler 256x256 boyutunda 8 bitlik gri tonlu imgelerdir ve çözünürlükleri 3 piksel/mm'dir. Deneilerin yapıldığı veri tabanı sekiz değişik doku tipinden oluşmaktadır. Birinci doku tipi 35 tane imgeden oluşmaktadır. Bu imgelerden 16 tanesi hatasızdır, geri kalanları ise tekstil endüstrisinde rastlanabilecek çeşitli hataları içerecek şekilde seçilmiştir (Şekil 1). Diğer yedi doku kümesinde ikisi hatalı ikisi hatasız olmak üzere dört imge vardır. Sistem, 30 hatasız imge ile eğitilmiş, 33 hatalı imge de test imgesi olarak kullanılmıştır. Pencere boyutları kullanılan kameranın çözünürlüğüne, kumaşın dokusal özelliklerine ve hataların ne kadar bölgesel olduğuna bağlıdır ve deneylerde en yüksek başarı 32x32'lik alt pencereler ile elde edilmiştir. Kullanılan tüm öznitelik vektörleri için doğru sınıflandırma yüzdeleri Şekil 2'de verilmiştir. Doğru sınıflandırma yüzdeleri doğru sınıflandırılan toplam alt pencere sayısının (yani hatasız olarak sınıflandırılan hatasız alt pencere sayısı ile hatalı olarak sınıflandırılan hatalı alt pencere sayısının toplamının) test edilen toplam alt pencere sayısına bölünmesi ile bulunabilir.

Deneilerin sonuçları şu şekilde özetlenebilir: İki doku tipi için sadece ikinci dereceli istatistiklerden oluşan 19 öznitelik vektörü en iyi sonuçları vermiştir. Sadece yüksek dereceli

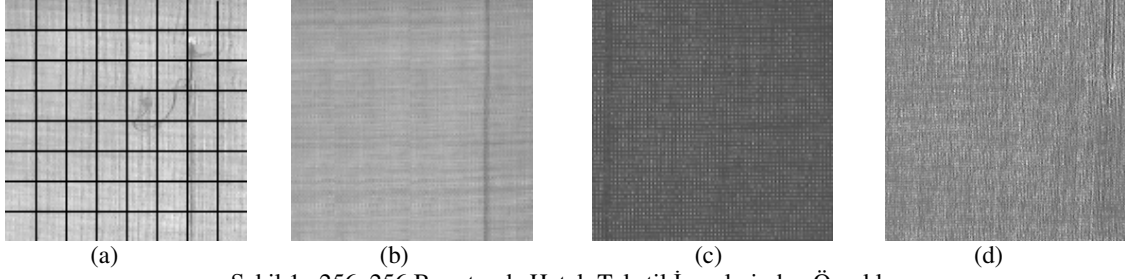
istatistiklerden oluşan öznitelik vektörleri (Ü2,Ü5,D2), hiçbir doku tipi için diğer öznitelik vektörleri kadar başarılı olamamışlardır. Ancak yüksek dereceli istatistikler, ikinci dereceli istatistiklerle birlikte kullanıldıklarında (yani karma öznitelik vektörleri İ2Ü2, İ5Ü2, İ9Ü2) beş doku tipi için en başarılı sonuçları vermişlerdir. Geriye kalan tek doku tipi içinse hem sadece ikinci dereceli istatistiklerden oluşan İ2 öznitelik vektörü, hem de karma öznitelik vektörleri İ2Ü2, İ5Ü2 hataların yüzde yüz olarak belirlenmesini sağlamışlardır. Böylece, bazı doku tipleri için yüksek dereceli istatistiklerin ikinci dereceli istatistiklerle birlikte kullanılmasının, hataların belirlenmesi işleminin başarısını arttırdığı gözlenmiştir. Ancak bu karma öznitelik vektörlerinin hesaplanma karmaşıklığı da sadece ikinci dereceli istatistiklerden oluşan öznitelik vektörlerinden oldukça fazladır. Kullanılan öznitelik vektörlerinin hesaplama karmaşıklıkları Tablo 1’de verilmiştir.

5. Çıkarımlar

Bu bildiriye, yüksek dereceli istatistiksel analiz metodları doku hata tespitinde kullanılmıştır. Bu yolla ikinci dereceli istatistiklerin modellemekte yetersiz kaldığı doku tipleri için kullanılabilir modeler dayalı bir doku analiz yöntemi sunulmuştur. Bazı doku tipleri için beklendiği üzere karma istatistiklerin kullanılması daha başarılı sonuçlar vermiştir. Ancak karma öznitelik vektörlerin hesap karmaşıklığı oldukça fazladır bu da yüksek dereceli istatistiklerin hesaplama açısından yüklü olmasına bağlıdır. Yüksek dereceli istatistiklerin hesaplama karmaşıklıklarının azaltılması üzerine bir çalışma, bu istatistiklerin doku analizi ve daha başka imge işleme yöntemleri için kullanılmasını kolaylaştırabilir.


Kaynakça

- [1] A. Erçil, B. Özüyılmaz, "Automated Visual Inspection of Painted Metallic Surfaces", *Proc. Int. Conf. on Automation, Robotics and Computer Vision (ICARCV'94)*, ss. 1950-1954, Kasım 1994.
- [2] A. K. Jain, F. Farrokhina, D. Alman, "Texture Analysis of Automotive Finishes", *Proceedings SME Machine Vision Applications Conf.*, ss. 1-16, Detroit, MI, Kasım 1990.
- [3] J. Chen, A. K. Jain, "A Structural Approach to Identify Defects on Textural Images", *Proc. IEEE Int'l Conf. on Systems, Man, and Cybernetics*, ss. 29-32, Beijing, 1988.
- [4] R. Connors, "Identifying and Locating Surface Defects in Wood", *IEEE PAMI*, Vol.5, Kasım. 1983.
- [5] L. H. Siew, R. M. Hodgson, E. J. Wood, "Texture Measures for Carpet Wear Assessment", *IEEE Trans. on Pattern Analysis and Machine Intelligence PAMI-10*, ss. 92-105, 1988.
- [6] P. Dewaele, P. Van Gool, A. Oosterlinck, "Texture Inspection with Self-Adaptive Convolution Filters", *Proc. 9th Int. Conf. on Pattern Recognition*, ss. 56-60, Rome, Italy, Nov. 14-17, 1988.
- [7] M. Tuceryan and A. K. Jain, "Texture Analysis" in C.H. Chen, L.F. Pau, P. S. P. Wang (eds.), *The Handbook of Pattern Recognition and Computer Vision*, World Scientific Publishing Co., River Edge, NJ, 1993.
- [8] C. L. Nikias and J. M. Mendel, "Signal Processing with Higher-Order Spectra," *IEEE Signal Proc. Mag.*, ss.10-37, Temmuz 1993.
- [9] M. K. Tsatsanis and G. B. Giannakis, "Object and Texture Classification Using Higher Order Statistics," *IEEE Trans. on Pattern Analysis and Mach. Intelligence*, Vol. 14, Temmuz 1992.
- [10] Aras B., "Texture Defect Detection Using Higher Order Statistics," M.S. Tezi, Boğaziçi Üniversitesi, İstanbul, 1997.




Şekil 1. 256x256 Boyutunda Hatalı Tekstil İmgelerinden Örnekler


(a) İlk imge 32x32 Boyutunda Alt pencerelere Bölünmüş ($S_i; i=1, \dots, 64$) (b) Doku tipi 1, (c) Doku Tipi 2, (d) Doku tipi 3



(a)



(b)



(c)

Şekil 2 (a) Doku Tipi 1, (b) Doku Tipi 2, (c) Doku tipi 3 için Başarımların Grafikleri

Tablo 1 Öznitelik Vektörlerinin Hesaplama Karmaşıklığı

Öznitelik Kümesi	Toplama ($\times 10^6$)	Çarpma ($\times 10^6$)
İ2	0.66	0.33
İ5	1.72	0.87
İ9	3.32	1.64
Ü2	4.27	4.28
Ü5	24.26	24.31
D2	20.49	29.05
İ2Ü2	4.93	4.62
İ5Ü2	6.01	5.17
İ9Ü2	7.63	6.01
İ2Ü2D2	25.49	33.73
Ü31	10.22	10.24

