

BAĞIMSIZ BİLEŞENLER ANALİZİ İLE OTOMATİK KUMAŞ KALİTE KONTROLU

AUTOMATED INSPECTION OF TEXTILE DEFECTS USING INDEPENDENT COMPONENT ANALYSIS

Osman Gökhan Sezer¹, Aysin Ertüzün¹, Aytül Erçil²

¹Boğaziçi Üniversitesi, Elektrik-Elektronik Mühendisliği Bölümü, İstanbul

²Sabancı Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi, İstanbul
ogsezer@hotmail.com, ertuz@boun.edu.tr, aytulercil@sabanciuniv.edu

Özetçe

Bu bildiriye tekstil doku imgelerindeki hataların yerlerini belirleyen ve kısmen tanımlayan Bağımsız Bileşenler Analizi (BBA) kullanan bir yöntem önerilmiştir. Bu yöntemde aynı kumaştan elde edilmiş çok sayıda tekstil imgesinden elde edilen BBA temel vektörlerinden öznelik vektörleri çıkarılmış ve bu öznelik vektörleri daha önce hatasız bir imgeden elde edilen referans öznelik vektörü ile karşılaştırılmıştır. Önerilen metodun döndürmeye karşı duyarsız olduğu gözlemlenmiştir. Fabrika ortamında elde edilmiş gerçek tekstil imgeleri üzerinde yapılan deneysel çalışmalar bu yöntemin başarımını göstermiştir.

Abstract

This paper addresses a new defect detection method that uses Independent Component Analysis (ICA) for locating and also partially identifying defects in textile fabric images. The method is based on obtaining ICA basis vectors for a large number of textile images obtained from the same fabric. Feature vectors are computed for the test images and these are compared with the true feature vector predetermined from a defect-free image. The proposed method is shown to be invariant under rotation. Experimental results demonstrating the use of this method for visual inspection of textile products obtained from a real factory environment are also presented.

I. Giriş

Doku analizi, yüzeylerin otomatik ve görsel olarak denetiminde önemli bir rol üstlenir. Bununla beraber doku analizinin yapay görme yöntemleriyle denetim amaçlı kullanıldığı sınırlı sayıda çalışma olagelmıştır. Amet *et al.* [1] alt bant co-occurrence dizgeleri kullanmıştır. Karra *et al.* [2] imgelerin dalgacık dönüşümlerinden ve bu dönüşümlerin vektör nicemlemelerinden hata çıkarımı üzerinde çalışmıştır. Chen ve Jain [3] dokulu imgelerdeki hataların saptanması için yapısal bir yaklaşım kullanmıştır. Dewaele *et al.* [4] işaret işleme yöntemleriyle doku imgelerindeki nokta veya çizgi şeklindeki hataları bulmaya çalışmıştır. Cohen *et al.* [5] Markov rassal alan modelleri kullanarak tekstil yüzeyleri üzerinde çalışmış, Erçil *et al.* [6] benzer teknikleri boyalı metalik yüzeylere uygulamıştır. Connors *et al.* [5] tahta yüzeylerdeki hataları otomatik olarak saptamak amacıyla doku analiz yöntemlerini kullanmıştır. Atalay [7] Markov rassal alanlarını kullanan modele dayalı bir yöntemi gerçek zamanlı olarak kumaşlarda hata denetimini başarmıştır. Lambert *et al.* [8] doku hata tespiti için çok ölçekli dalgacık yöntemlerine dayalı bir yöntem önermiş; Iivarinen [9] histogram temelli doku analiz tekniklerini karşılaştırmıştır. Bodnarova [10] Gabor süzgeç parametrelerini Fisher başarımlı fonksiyonu ile eniyileyip hata sezimine uygulamıştır. Chan ve Pang [11] 3-B frekans izgesi kullanmışlardır. Bağımsız bileşenler analizinin (BBA) doku analizine uygulanmasında ön sonuçlar [12] 'de verilmiştir. Doku analizi konusundaki literatür taramaları için Van Gool *et al.* [13], Reed *et al.*

[14], Rao [15], Tuceryan ve Jain [16] referans gösterilebilir.

BBA, gözlemlenen verinin istatistiksel olarak bağımsız gizli bileşenlerin lineer dönüşümünden oluştuğu modeller için kullanılan genel amaçlı bir istatistiksel tekniktir. BBA'ların çok farklı uygulama alanları mevcuttur: kör kaynak ayırıştırması, kör tersevirşim ve kör kanal denkleştirme, öznelik çıkarımı. Hurri iki ayrı çalışmada [17-18] BBA yöntemini imgelere uygulamıştır.

Bu bildiriye, BBA yöntemi ile doku hata tespiti için bir yöntem geliştirilmiştir. Hatasız kumaş imgelerinin çakışmayan alt pencerelerinden BBA yöntemi ile öznelik çıkarımı gerçekleştirilmekte, daha sonra bilinmeyen bir kumaşın alt pencerelerinden elde edilen BBA-öznelikler bu özneliklerle karşılaştırılarak bilinmeyen kumaş hatalı veya hatasız olarak damgalanmaktadır.

Bildirinin organizasyonu aşağıdaki gibidir: BBA yönteminin temel prensipleri ve BBA modeli 2. bölümde verilmiştir. 3. bölümde önerilen hata bulma sistemi anlatılmıştır. Gerçek kumaş imgelerine bu yöntemlerin uygulanması ile ilgili ayrıntılar, uygulama sonuçları ve diğer yöntemlerle karşılaştırılması 4. bölümde verilmiş, 5. bölümde ise konu ile ilgili genel vargılar ve değerlendirmeler sunulmuştur.

II. BBA Temelleri

BBA, çok boyutlu istatistiksel verilerde saklı faktörlerin bulunması için geliştirilmiş olan oldukça yeni istatistiksel bir yöntemdir. BBA modelinde saklı faktörler ya da bağımsız bileşenler doğrusal veya doğrusal olmayan şekilde bilinmeyen bir karıştırma mekanizması ile karıştırılarak gözlem verilerini oluştururlar. Temel doğrusal karışım modeli matematiksel olarak şu şekilde ifade edilebilir [19-20]:

$$\mathbf{x} = \mathbf{A}\mathbf{s} \quad (1)$$

Burada \mathbf{x} gözlem verileri x_j 'lerden oluşan gözlem vektörü, \mathbf{s} ise s_i olarak adlandırılan bağımsız bileşenlerden oluşan kaynak vektörü; \mathbf{A} da karıştırma matrisidir. Amaç bilinmeyen \mathbf{A} and \mathbf{s} değerlerinin gözlem vektörü \mathbf{x} kullanılarak kestirilmesidir. [19-20]. Temel BBA modelinde \mathbf{A} matrisi kare olarak yani kaynak ve bağımsız bileşen sayısı eşit olarak kabul edilir [21]. Modeldeki varsayımlar kullanılarak; \mathbf{A} matrisi kestirilir daha sonra da kaynaklar aşağıdaki gibi hesaplanır:

$$\mathbf{s} = \mathbf{W}\mathbf{x} \quad (2)$$

Burada \mathbf{W} matrisi \mathbf{A} matrisinin tersidir [19-20].

2.2-Imgelerde Öznelik Çıkarımı için BBA modeli

Temel olarak imge modeli $a_i(p,q)$ öznelikler veya temel fonsiyonları cinsinden ifade edilebilir:

$$I(p,q) = \sum_{i=1}^n a_i(p,q)s_i \quad (3)$$

Burada s_i 'lar her imge için farklı olan katsayılarıdır. (3) numaralı ifade aşağıdaki şekilde ifade edilebilir:

$$x=As \quad (4)$$

Bu ifade (1)'de verilen temel BBA modeli ile aynıdır. Öznitelikler veya temel fonksiyonlardan oluşan A matrisi yine kare olarak kabul edilmiştir.

Bu bildiride BBA modeli kullanılarak doku imgelerindeki öznitelikler çıkarılmıştır. Bu uygulamada A matrisinin kolonları BBA basis vektörlerini, s vektörünün s_i elemanları ise i 'inci basis vektörün gözlemlenen verideki katsayısını göstermektedir.

III- Sistem ve Yöntem

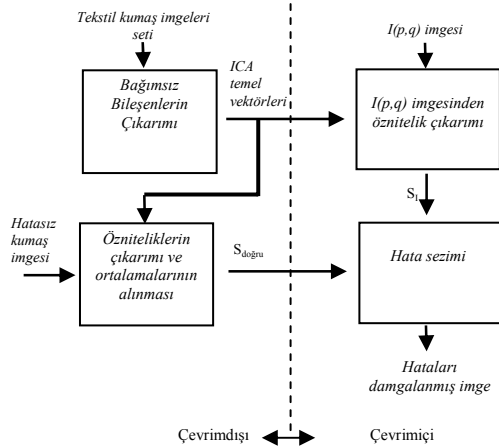
3.1. Genel Bakış

Doku hata analizi tanımlama ve sınıflandırma problemlerine göre daha zor bir problemdir; burada amaç doku geriplan piksellerinden şiddet ve uzamsal düzenlenim özellikleri açısından büyük farklılıklar gösteren piksellerin konum ve boyutlarını bulmaktır[1]. Hata seziminde öznitelikler hatanın tipine veya boyutuna göre her zaman topaklar oluşturmayabildiklerinden hata sezimi zor bir problemdir.

Bilgisayarla görme sistemleri verinin boyutunun ileride yapılacak işlemlerin kolaylığı açısından küçültüldüğü öznitelik çıkarım aşaması ve öznitelik çıkarımı aşamasında elde edilen veri ile ilgili kararların verildiği karar aşaması olmak üzere iki aşamadan oluşur. Öznitelik çıkarımı sistemin tüm başarımını etkilediği için önemli bir aşamadır. Tanımlama problemlerinde, karar aşamasında önceden elde edilmiş veri ile eşleştirilen nesnenin bilinenlerden hangisine benzediğine karar verilir. Sınıflandırma problemlerinde ise karar mekanizması benzerlik ölçütleri kullanarak verinin çeşitli sınıflara ayrılması işlemidir.

3.2. Hata Sezim Sistemi

Önerilen hata sezim sistemi (i) öznitelik çıkarım ve (ii) hata sezimi olmak üzere iki kısımdan meydana gelmektedir:



Şekil 3.1: Hata sezim sisteminin blok şeması

Bu çalışmada öznitelik çıkarım kısmı iki kısımdan oluşmaktadır. Birincisi öğrenme fazı olarak da adlandırılan çevrimdışı blok ve test imgesinin özniteliklerinin çıkarıldığı çevrimiçi kısım. Çevrimdışı kısımda doku imgelerinden bağımsız bileşenler bulunur; BBA temel vektörleri olarak adlandırılan bu bileşenler BBA modelindeki A matrisinin kolonlarını oluştururlar. Hatasız imgenin katsayı (öznitelik) vektörü de çevrimdışı olarak hesaplanır ve çevrimiçi sezim aşamasında referans olarak kullanılmak üzere s_{dogru} vektörü bulunur. Çevrimiçi kısımda ise önce değişik hatalara sahip test imgelerine ait alt pencerelerin katsayı vektörleri bulunur. Bu işlem

yapılırken çevrim dışında bulunmuş olan A matrisi kullanılır. Alt pencereler için bulunan katsayı vektörleri öğrenme aşamasında bulunmuş olan referans vektörü s_{dogru} ile karşılaştırılarak adı geçen alt pencerenin hatalı veya hatasız olduğuna Öklid uzaklığı sınıflandırıcısı ile karar verilir. Tüm imgeler işleme sokulmadan önce BBA standard işlemlerine yani normalizasyona [21], tabi tutulurlar, diğer bir deyişle sıfır ortalamalı yapılır ve beyazlatılırlar. Beyazlatma işlemi temel bileşenler analizi (PCA) kullanılarak yapılır ki bu sayede boyut küçültme de başarılı olur. Boyut küçültme işlemi varolan gürültüyü de azaltması açısından önemlidir. Sıfır ortalamalı ve beyazlatılmış imgeler hata sezim sisteminde kullanılır. Normalizasyon sonucunda A matrisinin tersi devriğine (transpozuna) eşit olduğundan öznitelik yani katsayı vektörlerinin hesaplanması kolaylaşır. Bu aşamalar şu şekilde özetlenebilir:

Çevrimdışı (öğrenme) aşama:

- 1) Tekstil imgelerinden BBA temel vektörlerinin hesaplanması
- 2) BBA temel vektörlerinin A matrisinin kolonlarını oluşturması
- 3) Hatasız bir imgenin $N \times N$ boyutlu çakışmayan alt pencerelere bölünmesi
- 4) Her alt pencere için (2) numaralı ifadedeki katsayı (öznitelik) vektörünün hesaplanması
- 5) Her alt pencere için hesaplanan öznitelik vektörlerinin ortalamasının alınarak s_{dogru} vektörünün bulunması

Çevrimiçi öznitelik çıkarım aşaması:

- 1) $I(p,q)$ test imgesinin $N \times N$ boyutlu çakışmayan alt pencerelere bölünmesi
- 2) Her alt pencere için (2) numaralı ifadedeki katsayı (öznitelik) vektörünün yani s_i vektörünün hesaplanması
- 3) s_i vektörlerinden S_I matrisinin oluşturulması. Her s_i vektörü, S_I matrisinin bir kolonunu oluşturmaktadır.

Çevrimiçi sezim aşaması:

- 1) S_I matrisinin alt pencerelerin özniteliklerine karşılık gelen her kolonu ile s_{dogru} vektörünün arasındaki Öklid uzaklığının aşağıdaki şekilde hesaplanması

$$uzaklik_i = [(s_{dogru} - s_i)^T (s_{dogru} - s_i)]^{1/2} \quad (6)$$

Burada s_i vektörü S_I matrisinin i 'inci kolonudur.

- 2) Her alt pencerenin belli bir eşik değeri α 'yı aşması durumunda hatalı olarak damgalanması eğer

$$alt\ pencere_i = \begin{cases} hatali & eger\ uzaklik_i > \alpha \\ hatasiz & diger \end{cases}$$

Eşik değeri aşağıdaki formül ile hesaplanmaktadır:

$$\alpha = D_m + \eta IQR \quad (7)$$

Burada D_m alt pencerenin öznitelik vektörünün ortanca değeri, IQR dörttebirlikler arası açıklık, η ise deneysel olarak bulunan bir sabittir. (Gauss dağılımlar için $\eta=1.67$ ve %95 güven aralığına karşılık gelmektedir)

Bu bildiride, veri kümesi bir hatasız ve değişik hatalar içeren 19 hatalı imgeden oluşmaktadır. Bunlardan üçü Şekil 3.2'de verilmiştir.





Fig. 3.2 (a)- (b) Hatalı tekstil imgeleri (c) Hatasız tekstil imgesi $I(p,q)$ test imgesi 256×256 boyutludur ve CCD kamera ile elde edilmiştir. Bu imgeler $N \times N$ boyutunda

çakışmayan alt pencerelere bölünmüştür. Her alt pencere $I(p,q)$ imgesinin farklı bir bölgesini temsil etmektedir. Alt pencere boyutunun seçimi hataların boyutlarına ve alt pencere içindeki verinin hatasız imgeyi ne kadar iyi temsil ettiğine bağlıdır [1]. Çok küçük pencere boyutları dokuyu temsil etmeyen BBA temel vektörlerinin elde edilmesine yol açtıklarından ikinci faktör önemlidir. Bu çalışmada deneme yanılma metodu ile en iyi pencere boyutunun 16x16 olduğuna karar verilmiş ve deneylerde bu boyut kullanılmıştır.

IV. Uygulama ve Sonuçlar


İmgeler normalize edildikten sonra imgelerden rassal olarak 16 X 16 lık 10,000 alt pencere seçilir. Daha sonra ana bileşenler analizi kullanarak verilerin boyutu 16'ya düşürülür. 16 boyut genel olarak toplam enerjisinin %90'ından fazlasını kapsamaktadır. Simetrik sabit nokta BBA algoritması [22] ve $\tanh(x)$ fonksiyonu kullanılarak BBA temel vektörleri bulunur.

İlk deney setinde, BBA yöntemi dokuma yapısından dolayı yatay ve dikey çizgilerden oluşan orjinal imgelere uygulanmıştır. Bu durumda bazı BBA temel vektörlerinin yüksek frekans özelliği bulunduğu görülmüştür. (Şekil 1, 5, 7, 8, 9, 11, 13, ve 15 nolu temel vektörler) Bu bileşenler Öklid uzaklığı etkilediği için hata tespit sisteminin performansı düşük olmaktadır. Doğru hata bulma oranı 88.59% olarak gözlemlenmiştir. (Bu deneylerde η 1.0 olarak alınmıştır.)




Şekil 1: Orjinal setin BBA temel vektörleri

Bu problemin çözümü için yüksek frekanslı temel vektörler atılmış ve mesafeler geri kalan temel vektörlerle hesaplanmıştır. Bu işlem sonucu hata bulma oranı % 89.41'e çıkmıştır.




Şekil 2: (a) Yüksek frekanslı BBA temel vektörleri ile birlikte hata tanımlama; (b) Yüksek frekanslı BBA temel vektörleri olmadan hata tanımlama; (beyaz kutular hatalı olarak tanımlanan alanları göstermektedir).

Eşik değerinin (α) değiştirilmesinin sonucu etkilemediği gözlemlenmiştir. Bu gözlemler ışığında hataların temel özelliklerini koruyarak yüksek frekanslı bileşenlerin elenmesinin uygun olduğu kararlaştırılmıştır. Dokunun yüksek frekanslı bileşenlerden arındırılması için 3X3 Medyan filtre ile imge düzgünleştirilmiş, 200'den yüksek gri seviyeleri 200 olarak değiştirilerek şiddet seviyesi dilimlemesi uygulanmıştır. (Şekil 3).



Şekil 3: (a) Medyan filtre ve histogram değişimlerinden sonar imge; (b) Hataları işaretlenmiş imge (siyah kutular hatalı olarak işaretlenmiş bölgeleri gösterir).


Bu önışlem tüm imgelere uygulandıktan sonra elde edilen imgelerden yüksek frekanslardan arındırılmış BBA temel vektörleri çıkarılır. Elde edilen BBA temel vektörleri Şekil 4 de gösterilmektedir. 1, 9, ve 11 numaralı bileşenlerdeki dikey çizgilerin dikey hataları modellediği, 2, 3, 7, 8, 13, ve 16 nolu bileşenlerdeki yatay çizgilerin yatay hataları modellediği, 10, 12, 14, ve 15 bileşenlerinin ise bölgesel hataları modellediği düşünülmektedir. 4, 5 and 6 gibi diğer bazı bileşenler ise tipik doku yapısını göstermektedir.



Şekil 4: Önışlemler sonucu elde edilen imgelerin BBA temel vektörleri

İmgedeki hatalı bir bölgenin hatayı belirten bir veya birden fazla baskın temel vektörü olması beklenmektedir. (Şekil 5).

Şekil 5'de hatalı bir penceredeki (Şekil 3'de 40 nolu pencere) temel bileşenlerin katsayıları gösterilmektedir. Bu şekilde 11'inci temel vektörün diğer vektörleri göre daha baskın olduğu görülmektedir. Bu temel bileşen Şekil 4'de görüldüğü gibi dikey bir yapıya sahiptir. Böylece, kumaş imgesindeki dikey bir hatanın dikey yapıyı bileşenleri active ettiği görülmektedir. Bu şekilde hata sınıflandırılması da mümkün olabilmektedir.



Şekil 5 BBA temel vektörlerinin katsayıları Bar a) 40 nolu alt pencere. b) 49 nolu alt pencere

Şekil 5b'de ise Şekil 3'de hatasız bir bölgeye karşılık gelen 49 nolu alt pencerenin profile gösterilmektedir. Bu şekilden de görülebileceği gibi 49'uncü alt pencerede baskın bir temel vektör bulunmamaktadır ve katsayılar sıfıra yakındır. Üçüncü deney setinde doğru sınıflama oranı 96.74 % olarak görülmüştür. ($\eta=1.5$).


Doğru sınıflama oranları aşağıdaki formüle göre hesaplanmaktadır:

$$CR = 100 \times (N_{CC} + N_{DD}) / N_{Total} \quad (8)$$


N_{CC} doğru sınıflanan hatasız pencerelerin sayısını, N_{DD} doğru sınıflanan hatalı pencerelerin sayısını ve N_{Total} toplam test edilen pencere sayısını göstermektedir.

Önerilen yöntemin doku hata tanımlamasında kullanılan Piramit yapıları dalgacık dönüşümü (PSWT), Dalgacık paket imzaları (WPS), Uzamsal Uzay Co-occurrence Matrisleri (SDCM), Altband Uzay Co-occurrence Matrisleri (SBCM), Markov Rassal Alanlar (MRF), Altband Markov Rassal Alanlar (SBMRF) gibi diğer bazı yöntemlerle karşılaştırılması Şekil 6 ve 7'de gösterilmiştir.


BBA tabanlı hata bulma yönteminin dönmeye karşı gürbüzlüğünü sınamak için test imgeleri 45 derece döndürülmüştür. Şekil 8'de döndürülmüş imgelerde hatalı olarak işaretlenen pencereler gösterilmektedir. Önerilen hata tespit yönteminin dönme altında da gürbüz olduğu gözükmektedir. (Deneylerde $\eta=1.8$ kullanılmıştır).



Şekil 6. Farklı yöntemlerin sistem çalışma eğrisi



Şekil 7. Diğer yöntemlerle performans karşılaştırılması



Şekil 8. Önışlemeden geçirilmiş imgelerin 45° döndürüldükten sonra hatalı işaretlenen pencereleri

Tüm yöntemlerin işlem yoğunlukları Tablo 1'de gösterilmektedir. BBA tabanlı hata bulma yönteminin SDCM ve SBCM dışındaki yöntemlere göre işlem yoğunluğunun oldukça düşük olduğunu görmekteyiz.

TABLO 1. 256 x 256 imgelerde öznelitik çıkarımının işlem yoğunluğu

| Yöntem | Toplama (X 10 ⁶) | Çarpma (X 10 ⁶) |
|--------|------------------------------|-----------------------------|
| BBA | 1.04 | 1.05 |
| PSWT | 2.52 | 2.62 |
| WPS | 4.00 | 4.20 |
| Gabor | 383.51 | 763.36 |
| SDCM | 0.48 | 0.18 |
| SBCM | 0.95 | 0.92 |
| MRF | 1.64 | 1.64 |
| SBMRF | 1.14 | 1.20 |

V- Vargılar

Doku hata tespiti için BBA tabanlı yeni bir yöntem önerilmiştir. Önerilen sistemin hata bulma oranlarında 4-5 % artış sağladığı gözlemlenmiştir. Ayrıca, önerilen yöntemin işlem yoğunluğu oldukça düşük olduğu ve imgedeki dönmelere karşı gürbüz olduğu için tekstil endüstrisinde gerçek zamanlı hata kontrolü için ümit verici bir çözüm olarak ortaya çıkmaktadır.

Kaynakça

- [1] A. Latif-Amet, A. Ertüzün, A. Erçil, An efficient method for texture defect detection: subband domain co-occurrence matrices, *Image and Vision Computing*, 18, (2000), 543-553.
- [2] D.A. Karras, S.A. Karkanis, D.K. Iakovidis, D.E. Maroulis and B.G. Mertzios, Improved defect detection in manufacturing using novel multidimensional wavelet feature extraction involving vector quantization and PCA techniques, *Proceedings of 8th Panhellenic Conference on Informatics*, Nicosia, Cyprus, 2001.
- [3] J. Chen, A.K. Jain, A structural approach to identify defects in textural images, *Proc. of IEEE International Conference on Systems, Man and Cybernetics*, Beijing, (1988),29-32
- [4] P. Dewaele, L. Van Gool, A. Oosterlinck, Texture inspection with self-adaptive convolution filters, *Proc. 9th ICPR*, pp. 56-60, Rome, Italy, Nov. 14-17, 1988.
- [5] F.S. Cohen, Z. Fan, and S. Attali, Automated inspection of textile fabrics using textural models, *IEEE PAMI*, 13, (1991), 803-808.
- [6] A. Erçil, and B. Özüyılmaz, Automated visual inspection of metallic surfaces, *Proceedings of The Third International Conference on Automation, Robotics and Computer Vision (ICARCV'94)*, Singapore, (1994), 1950-1954.
- [7] A. Atalay, *Automated Defect Inspection of Textile Fabrics Using Machine Vision Techniques*, M.S. Thesis, Boğaziçi University, 1995.
- [8] G. Lambert, F. Bock, Wavelet methods for texture defect detection, *Proc. of the IEEE ICIP*, 3, (1997), 201-204.
- [9] J. Iivarinen, Surface defect detection with histogram-based texture features, *Proceedings of SPIE 4197*, 2000, 140-145.
- [10] A. Bodnarova, M. Bennamoun, S. J. Latham, Constrained minimisation approach to optimise Gabor filters for detecting flaws in woven textiles, *Proc. of the IEEE ICASSP 6 (2000)* 3606-3609.
- [11] C. -H. Chan, K. H. Pang, Fabric defect detection by Fourier analysis, *IEEE Trans. Industry Applications* 36 (2000) 1267-1276.
- [12] O. G. Sezer, A. Ertüzün, A. Erçil, Independent component analysis for texture defect detection, *Proceedings of OGRW-6, Katun Village, Novosibirsk*, (2003), 210-213.
- [13] L. Van Gool, P. Dewaele, and A. Oosterlinck, Survey: texture analysis anno 1983, *CVGIP*, 29, (1985), 336-357.
- [14] T.R. Reed, J.M. Hans Du Buf, A review of recent texture segmentation and feature extraction techniques", *CVGIP: Image Understanding*, 57, (1993), 359-372.
- [15] Rao, A.R., A taxonomy for texture description and identification, Springer-Verlag, New York, 1990.
- [16] M. Tuceryan, A. Jain, *Texture analysis* ", *The Handbook of Pattern Recognition and Computer Vision*, by C.H. Chen, L.F. Pau, P.S.P. Wang (eds.) World Scientific Publishing Co., 1993.
- [17] J. Hurri, A. Hyvarinen, J. Karhunen and E. Oja, Image feature extraction using independent component analysis, <http://citeseer.nj.nec.com/hurri96image.html>
- [18] J. Hurri, *Independent component analysis of image data*, MS Thesis, Helsinki University of Technology, Helsinki, Finland, 1997.
- [19] A. Hyvarinen, Survey on independent component analysis, *Neural Comp. Surveys*, 2, (1999), 94-128.
- [20] A. Hyvarinen, E. Oja, Independent component analysis: algorithms and applications, *Neural Networks*, 13 (2000), 411-430.
- [21] A. Hyvarinen, J. Karhunen and E. Oja, *Independent Component Analysis*, John Wiley and Sons. Inc., 2001.
- [22] <http://www.cis.hut.fi/projects/ica/imageica>