

# Dokudaki düzenlilik ve yönlülük öğeleri ile bağımsız bileşenler modelinin algısal ilişkisi ve bunu kullanarak doku hata sezimi

## Perceptual relation of regularity and anisotropy in the texture with independent components model and using this for defect detection

O. G. Sezer<sup>1</sup>, A. Erçil<sup>1</sup> and A. Ertüzün<sup>2</sup>

1-Mühendislik ve Doğa Bilimleri Fakültesi, Sabancı Üniversitesi

2- Elektrik ve Elektronik Mühendisliği, Boğaziçi Üniversitesi

[ogsezer@su.sabanciuniv.edu](mailto:ogsezer@su.sabanciuniv.edu), [aytulercil@sabanciuniv.edu](mailto:aytulercil@sabanciuniv.edu), [ertuz@boun.edu.tr](mailto:ertuz@boun.edu.tr)

### Özetçe

Bu makale işlenmemiş tekstil kumaşlarında doku hatalarını bulma sorununu insan görme sisteminden çıkarımlar ve bağımsız bileşen analiziyle (BBA) incelemektedir. Bilindiği üzere insan görme sistemi belli görsel işaretlere tepki veren alanlara sahiptir. Temel görsel kortekste bulunan yön seçici çubuk ve ızgara hücreleri de bu tepki alanlarıdır. Çubuk ve ızgara hücrelerinin diğer hücrelerden farkı ise bunların periodik ve periodik olmayan örüntülere verdikleri tepkide yatar. Doku algısında üst düzey özniteliklerden olan düzenlilik ve yönlülükte meydana gelebilecek bozukluklar dokuda yapısal hatalara neden olur. Araştırmalarımız sonucunda elde ettiğimiz bağımsız bileşenler, kullanılan tekstilin yapısına bağlı olarak çubuk veya ızgara hücrelerinin tepki alanlarına benzediğini gözlemledik. Eğer bağımsız bileşenlerini çıkardığımız tekstilde düzenlilik öğesi baskın ise ızgara hücrelerinin, yönlülük öğesi baskın ise de çubuk hücrelerinin tepki alanlarına benzeyen bağımsız bileşenler elde ettik. Bu nedenle hatalı ve hatasız bölgelere farklı bağımsız bileşenlerin tepki vermesinin gerektiğini ileri sürdük. Bu motivasyon ile BBA kullanarak dokunun istatistiksel özelliklerini incelemenin, doku yapısında oluşan bozuklukların algıda ne farklılıklar yarattığını anlamak için umut verici olduğunu düşünüyoruz ve elde ettiğimiz sonuçlar da bunu destekliyor.

### Abstract

This paper addresses the raw textile defect detection problem using independent components approach with insights from human vision system. Human vision system is known to have specialized receptive fields that respond to certain type of input signals. Orientation-selective bar cells and grating cells are examples of receptive fields in the primary visual cortex that are selective to periodic- and aperiodic-patterns, respectively. Regularity and anisotropy are two high level features of texture perception, and we can say that disruption in regularity and/or orientation field of the texture pattern causes structural defects. In our research, we observed that independent components extracted from texture images give bar or grating cell like results depending on the structure of the texture. For those textures having lower regularity and dominant local anisotropy (orientation or directionality), independent components look similar to bar cells whereas textures with high regularity and lower anisotropy have

independent components acting like grating cells. Thus, we will expect different bar or grating cell like independent components to respond to defective and defect-free regions. With this motivation, statistical analysis of the structure of the texture by means of independent components and then extraction of the disturbance in the structure can be a promising approach to understand perception of local disorder of texture in human vision system. In this paper, we will show how to detect regions of structural defects in raw textile data that have certain regularity and local orientation characteristics with the application of independent component analysis (ICA), and we will present results on real textile images with detailed discussions.

### 1. Giriş

Doku hata analizi uzun zamandır araştırmacıların üzerinde çalıştığı ve ürün kalite kontrolü için büyük önem taşıyan bir konu olarak karşımıza çıkar. Literatürdeki mevcut metodlar genellikle çözülecek probleme yönelik atılmış adımlar olup, genel anlamda doku analizini tanımlamaya çalışan metod sayısı az ve performansları kısıtlıdır. Bununla beraber insanın hatayı algılamadaki kolaylık ve başarıyı mevcut metodların hepsinin üzerindedir. Rao ve Lahso [1] insanların doku algısını anlamaya yönelik yaptıkları klasik deneyinde, düzenlilik (regularity) ve yönlülük (anisotropy) öğelerinin üst düzey öznitelikler olduğunu ortaya çıkarmışlardır. Bu düşünce ile dokunun yapısındaki bozuklukların düzenlilik ve yönlülük öğelerindeki anormallikler ile bulunabileceğini gösteren metodlar mevcuttur [2]. Bu makalede mevcut metodlardan farklı olarak, BBA gibi bir istatistiksel metod kullanarak insan görme sistemiyle doku algısındaki üst düzey öznitelikleri ilişkilendirip hata analizi yapılması anlatılacaktır.

Hubel ve Wiesel'in [3,4] öncü çalışmalarının ardından, insan görme sistemini nasıl çalıştığına dahil çeşitli tezler ileri sürüldü. Bu tezlerin ortak buluşma noktası ise görme sisteminin gözden gelen veriyi çeşitli aşamalarda işleyerek bunu anlamlı hale getirdiğidir. İşte BBA de bu düşünceden yola çıkarak geliştirilmiş bir metodur. BBA veride bağımsız bileşenler bularak faktöryel kodlama yapar. Çeşitli çalışmalarda [5],[6] geniş bir doğal imge setinden elde edilmiş bağımsız bileşenler ile makak maymununun korteksindeki basit hücrelerin tepki alanlarının karşılaştırılmış ve büyük ölçüde benzerliklerin olduğunu gözlemlenmiştir. Bu da beyindeki tepki alanlarının çevremizde bulunan doğal

uyaranların istatistiksel özelliklerinden etkilendiğini göstermiştir. Bu düşüncelerden yola çıkarak, BBA ile doku imgelerinin istatistiksel durumunu inceleyerek, imgeleri görme sistemindeki tepki alanlarına ayırıştırmanın hata analizinde ve doku algısının anlaşılmasında yardımcı olacağını düşünüyoruz. Yaptığımız deneylerde de bu düşüncenin doğruluğunu gösteren sonuçlar elde ettik.

Daha önceki BBA üzerine yapılan çalışmalardan farklı olarak bu çalışmada doku imgelerinin istatistiksel özellikleri ayrı ayrı incelenmiştir. Bahsedildiği üzere doku algısındaki temel öznitelikler düzenlilik ve yönlülük olduğu için kullandığımız veri setini bu öğelerden meydana gelen işlenmemiş tekstil imgeleri olarak seçtik. Sadece işlenmemiş tekstil imgelerini seçmemizin nedeni ise üzerine çeşitli desenler işlenmiş veya basılmış olan kumaşlarda şekiller ve desenlerin temel öznitelikler olan düzenlilik ve yönlülük öğelerini bastırmasıdır. Deneylerimiz sonucunda elde ettiğimiz bağımsız bileşenlerin dokunun yapısına bağlı olarak farklı karakteristikler gösterdiğini gözlemledik. Elimizdeki doku imgelerinde düzenlilik öğesi baskın ise ızgara hücreleri gibi özellikler gösteren, yönlülük öğesi baskınsa çubuk hücrelerine benzeyen bağımsız bileşenler elde ettik. Basit ve kompleks hücrelerden farklı olarak ızgara ve çubuk hücreleri sırası ile periodik ve periodik olmayan yönlü örüntü seçici hücreler olarak tanımlanır[7,8]. İşlenmemiş tekstil imgelerinin yapısal özelliği de periodiklik ve yönlülük öznitelikleri ile tanımlanabileceği gibi bu öğelerde meydana gelebilecek değişiklik veya bozukluklar dokudaki hatanın temelini oluşturacaktır. Dolayısıyla bu hücrelerle hata analizini ilişkilendirmek hata analizi sorunsalının çözümünde ve doku algısında önemli bir adım olduğunu düşünmekteyiz.

## 2. Bağımsız Bileşen Analizi (BBA)

BBA kör kaynak ayırma yapabilen bir metoddur. Burada kör hem kaynak işaretlerinin hem de bunların nasıl karışıklarının bilinmemesi demektir. BBA algoritması öyle bir doğrusal koordinat sistemi bulur ki elde edilen işaretler istatistiksel olarak birbirinden bağımsız olur. Temel bileşen analizi (TBA) gibi korelasyon tabanlı dönüşümlerden farklı olarak, BBA işareti sadece dekorele etmekle kalmaz (2. derece istatistik) ayrıca yüksek derece istatistiksel bağımlılığı da azaltır [Te-won-Lee].

BBA yöntemi birbirinden bağımsız ve gauss dağılımına sahip olmayan faktörlerin bulunmasında klasik yöntemlere göre çok güçlü bir araçtır. 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 [9,10]:

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

Burada  $\mathbf{x}$  gözlem verileri  $x_j$ 'lerden oluşan gözlem vektörü,  $\mathbf{s}$  kaynak vektörü;  $\mathbf{A}$  da karıştırma matrisidir. Amaç bilinmeyen  $\mathbf{A}$  and  $\mathbf{s}$  değerlerinin gözlem vektörü  $\mathbf{x}$  kullanılarak kestirilmesidir. Kaynak dağılımları bilinmemekte sadece gauss olmadıkları varsayılmaktadır. [9,10].


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 [9,10]. Bizim uygulamamızda bu kaynaklar bağımsız bileşenlerin katsayılarını verir.

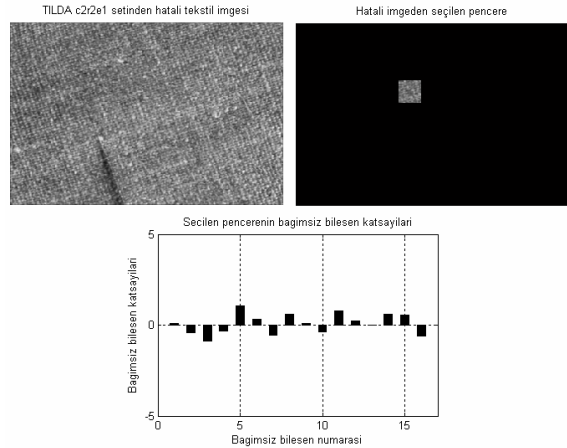
## 3. Metod

Uyguladığımız metod verilen hatasız dokunun istatistiksel özelliklerini belirli bir boyuttaki rassal pencerelerle toplayıp BBA ile o dokuya has bağımsız bileşenler elde etmektedir. Daha sonra gelen hatalı test doku imgesini birbiriyle çakışır halde pencerelere bölmek ve her bir pencerenin yapısını elde ettiğimiz bağımsız bileşenler ile ifade edilmesini incelemektir. Bu inceleme sonucunda hatalı bölgelerin hatasız bölgelerden farklı tepki verdiğini gözlemledik. Bunun sebebi ise bu bölgelerde doku yapısının kısmen veya tamamen değişiklik göstermesidir (bkz. Şekil 1,2,3). İşte bu değişikliği elimizdeki hatasız imgelerden elde ettiğimiz referans özniteligi ile karşılaştırarak verilen imgeyi veya imge parçasını hatalı veya hatasız diye sınıflandıra biliriz.




Şekil 1, TILDA c2r2 tekstil grubunun bağımsız bileşenleri

Çalışmalarımızda kullandığımız veri seti tekstil ve doku hata analizinde standard hale gelmiş olan TILDA veri setidir [TILDA]. Bu veri seti farklı özelliklere sahip tekstil imgeleri içerir. Ayrıca her tekstil grubu için 50'şer imgeden oluşan 4 farklı hata ve bir de hatasız imge sınıfı barındırır. Bu imge sınıflarında tekstil kumaşının aynı bölgesinin farklı öteleme ve dönmelerdeki durumu olduğu gibi kumaşın farklı bölgelerini de içerir. Şekil 1 de c2r2 tekstil grubunun hatasız imgelerinden elde edilmiş bağımsız bileşenleri görebilirsiniz. Burada dikkat edilecek özellik bazı bağımsız bileşenlerin ızgara gibi olması, birinci ve ikinci bağımsız bileşenler gibi, bazıları ise çubuğa benzemesidir, 9 ve 11'inci bağımsız bileşenler gibi.



Şekil 2 Hatalı tekstil imgesinin hata olmayan kısmının bağımsız bileşen katsayıları



Şekil 3 Hatalı tekstil imgesinde hatanın bir kısmının bağımsız bileşen katsayıları

Şekil 2 ve 3'ü incelersek, hatasız kısımda en baskın bağımsız değişken 5 iken hatalı kısımda 11'inci bağımsız bileşenin egemen olduğunu görürüz. Bu sonuç hem algoritmanın hatalı ve hatasız kısımlara farklı tepkiler verdiğini gösteriyor hem de hatasız kısma periyodik örüntü seçici ızgara hücrelerine benzeyen bağımsız bileşenler tepki verirken örüntünün bozulduğu yerlere ise periyodik olmayan örüntü seçici çubuk hücrelerine benzeyen bağımsız bileşenlerin tepki verdiğini gösteriyor. İşte bu çıkarım bize kesin olmasa da dokudaki hatanın nasıl algılandığını ve bahsi geçen sınır hücrelerinin nasıl oluşmuş olabileceği hakkında fikir veriyor.

Algoritmada bağımsız bileşen sayısı deneme yanılma yoluyla 16 olarak kullanılmıştır. Dikkat edilmesi gereken husus, bağımsız bileşen sayısının fazla tutulması halinde doğacak olan aşırı-öğrenmedir (over-learning). **Bu durum birbirine benzer özellikte birçok gereksiz?(unnecessary) bağımsız bileşen elde etmemize neden olur ki bu da hesaplama açısından istenen bir özellik değildir.**


Kullandığımız algoritmanın iki tane önemli parametresi vardır. İlki hata eşiği, ikincisi ise istatistiksel veri toplamak için kullandığımız pencerelerin boyutları. Eşik değeri aşağıdaki formül ile hesaplanmaktadır:

$$\alpha = D_m + \eta IQR \quad (1)$$

Burada  $D_m$  altpencerenin öznitelik vektörünün ortanca değeri,  $IQR$  dörttebirlikler arası açıklık (inter quartile range)  $\eta$  ise deneysel olarak bulunan bir sabittir.  $\eta$  deneme yanılma yoluyla bulunabileceği gibi çapraz-dogrulama gibi metodlarla otomatik olarak da belirlenebilir. Biz  $\eta$  değerini bulurken hatasız imgelerde algoritmanın az **false-alarm** vermesini bunun yanında hatalı imgelerde ise hata yakalama başarımını göz önünde tutarak karar verdik.

Amaçımız dönem ve öteleme gibi değişimlerden etkilenmeden tekstilin genel özelliklerini elde etmektir. Gözlemlerimiz sonucu eğer doku ile ilgili istatistiksel bilgi toplamak için birçok rassal pencere kullanılırsa elde edilen bu bilginin dönme ve öteleme ile değişmediğini not ettik. Ayrıca Şekil 4'te görülebileceği üzere pencerenin boyutu arttıkça orijinal imge


ile onun ötelenmiş ve döndürülmüş hallerinin arasındaki istatistiksel fark giderek azalıyor. Burada istatistiksel fark ortalama-kare-hata (MSE) cinsinden hesaplanmıştır. Şekil 4 (d)-(e) bize 30x30 pencere boyutundan sonra istatistiksel farkın pek değişmediğini gösteriyor. Seçtiğimiz pencere boyutunun çok büyük olması durumunda küçük hataları kaçırabileceğimiz için en uygun pencere boyutu 30x30'a yakın olmalıdır. Bu nedenle 32x32 boyutunu seçtik. Bir diğer sebebi ise elimizdeki veri seti 32x32'lik pencerelere tam bölünebilmesiydi.



Şekil 4 TILDA veri setinden hatalı bir imge (a), ötelenmiş hali (b), ve döndürülmüş hali (c). Karşılık gelen semi-log grafikler; (d) ötelenmiş ve (e) döndürülmüş imgelerin ortalama-MSE'ye karşı pencere boyutları

#### 4. Sonuçlar

Algoritmanın başarımını incelemek için TILDA veri setindeki işlenmemiş tekstil imgelerini kullandık. Bu imgeler kullanırken elimizde herhangi dönme ve öteleme bilgisi bulunmadığı gibi hataların tam yeri de veri setinde belirtmemişti. Dolayısıyla sistem çalışma eğri ve yüzdelik hata sezim başarımı elde edilememiştir. Fakat algoritmanın performansı göstermek için bulunan hata resimleri ve nicel başarımlar tablosu verilmiştir.



Şekil 5 TILDA veri setinden hatalı tekstil imgeleri ve etiketlenmiş hatalar.


Yukarıdaki şekilde, kullandığımız dört çeşit tekstil grubunun herbirinden alınmış farklı hataların algoritma ile etiketlenmesi verilmiştir. Eğer algoritma hatanın bir kısmını veya tamamını etiketliyorsa o hatalı tekstil imgesini 'hata sezimi başarılı' diye sayıyoruz aksi takdirde o imgeyi hata sezimi başarısız olan imgeler arasına ayırıyoruz. **False-alarm rate** hakkında ise

hatasız tekstil imgelerinde hatalı olarak etiketlenen pencere sayısına bakarak karar veriyoruz. İşte Tablo-1 bu tanımlara göre düzenlenmiş nicel başarımları göstermektedir. Tablonun ilk sütununda TILDA veri setinde bulunan tekstil gruplarının kodu ve algoritmanın kullandığı  $\eta$  değeri verilmiştir. İlk satırda ise hatasız imgeler sınıfı (e0) ve farklı hata imgeleri sınıfları (e1-e4) verilmiştir. Hatasız imgeler sınıfı olan e0 için sonuçlar; etiketlenmiş pencere sayısına ( $N_{FA-S}$ ) karşılık, o sınıfın analizde kullanılan toplam pencere sayısı ( $N_{T-S}$ ) olarak verilmiştir. Hatalı imgelerin bulunduğu sınıflarda (e1-e4) ise sonuçlar; hata seziminin başarısız olduğu imge sayısına ( $N_M$ ) karşılık, o hata sınıfında bulunan toplam imge sayısı ( $N_T$ ) olarak verilmiştir.

Tablo 1. Algoritmanın nicel başarımları.


	e0 $N_{FA-S}/N_{T-S}$	e1 $N_M/N_T$	e2 $N_M/N_T$	e3 $N_M/N_T$	e4 $N_M/N_T$
c1r1 $\eta=2.5$	67/17250	0/50	0/50	2/50	1/50
c1r3 $\eta=2.5$	77/17250	0/50	2/50	0/50	2/50
c2r2 $\eta=2$	201/17250	3/50	0/50	7/50	2/50
c2r3 $\eta=2$	339/17250	2/50	26/49	-	14/50

Genel olarak algoritmanın performansı c1r1 ve c1r3 tekstil gruplarında daha başarılı iken c2r2 ve c2r3' te performansın düştüğünü gözlemliyoruz. Bunun en büyük nedeni c2r2 ve c2r3 tekstil gruplarında hata kabul edilmeyen kusurların bulunması ve algoritmanında bu kusurları bulabilmesi (bkz Şekil 6). Bu etki c2r3 grubu imgelerin e3 hata sınıfında sağlıklı hata analizi yapmayı dahi engellemiştir ve bu yüzden bu sınıfa ait sonuçlar tablodan çıkarılmıştır.



Şekil 6. (a) c2r2, ve (b) c2r3 sınıflarının hatasız imge sınıflarındaki kabul edilebilir kusurlar.

Uyguladığımız metodun başarımını azaltan iki durum vardır: (i) hatanın boyutu pencere boyutuna göre çok küçük kalıyorsa, (ii) **when defect causes minor perturbations in the intensity value**. Şekil 7'de c2r3 grubunun e4 hata sınıfından bu iki durum için örnek verilmiştir.



Şekil 7. Algoritmanın sınırlamaları: (a) küçük hata boyutu (hata imgenin aşağı kısmındaki iplikler) ve (b) **minor intensity perturbations** (hata üst sağ köşede).

## 5. Vargılar

Dokudaki düzenlilik ve yönlülük öğelerinin bağımsız bileşen analizi kullanarak tanımı elde edilmiş ve bunun hata seziminde nasıl kullanılabilceği gösterilmiştir. Düzenlilik öğesinin baskın olduğu dokularda periyodik örüntü seçici izgara hücrelerine benzeyen bağımsız bileşenler elde edilirken, yönlülük öğesinin baskın olduğu dokularda periyodik olmayan örüntü seçici çubuk hücrelerine benzeyen bağımsız bileşenler elde edilmiştir. Geliştirilen metod bu tanımları da kullanarak düzenlilik ve yönlülük öğelerindeki kusurları bağımsız bileşenleri izleyerek bulabilmiştir. Bu da dönme ve ötelemeye karşı dayanıklı hata sezimi elde etmemizi sağlamıştır.

## 6. Kaynakça

- [1] A.R. Rao and G.L. Lohse, Identifying high level features of texture perception, CVGIP: Image Processing, 55 (1993) 218-233.
- [2] D.Chetverikov, A.Hanbury, Finding defects in texture using regularity and local orientation, Pattern Recognition, 35 (2002) 203-218.
- [3] D. Hubel, T. Wiesel, Receptive fields, binocular interaction and functional architecture in the cat's visual cortex, J.Physiology (London), 160 (1962) 106-154.
- [4] D. Hubel, T. Wiesel, Receptive fields and functional architecture of monkey striate cortex, Journal of Physiology, 195 (1968) 215-243.
- [5] J.H. van Hateren and A. van der Schaaf, Independent Component Filters of Natural Images Compared with Simple Cells in Primary Visual Cortex, Proc.R.Soc.Lond.B, 265 (1998) 359-366.
- [6] J. H. van Hateren and D. L. Ruderman, Independent Component Analysis of Natural Image Sequences Yields Spatio-temporal Filters Similar to Simple Cells in Primary Visual Cortex, Proc.R.Soc.Lond. B 265:2315-2320, 1998)
- [7] R. von der Heydt, E. Peterhans, and M.R. Dürsteler, Periodic-pattern-selective cells in monkey visual cortex, J. Neuroscience, 12 (1992) 1416-1434.
- [8] N. Petkov, P. Kruizinga, Computational models of visual neurons specialized in the detection of periodic and aperiodic oriented visual stimuli: bar and grating cells, Biol. Cybern.,76 (1997) 83-96.
- [9] A. Hyvarinen, Survey on independent component analysis, Neural Computing Surveys, 2, (1999), 94-128.
- [10] A. Hyvarinen, E. Oja, Independent component analysis: algorithms and applications, Neural Networks, 13 (2000), 411-430.