



TEKSTİL VE MÜHENDİS

(Journal of Textiles and Engineer)



<http://www.tekstilvemuhendis.org.tr>

Kumaşlarda Hatayı Yerel Olarak Arayan Denetimsiz Bir Sistem

An Unsupervised System Locally Seeking Fabric Defects

Fatma Günseli YAŞAR ÇIKLAÇANDIR^{*1}, Semih UTKU², Hakan ÖZDEMİR³

¹İzmir Katip Çelebi Üniversitesi, Bilgisayar Mühendisliği Bölümü, İzmir, Türkiye

²Dokuz Eylül Üniversitesi, Bilgisayar Mühendisliği Bölümü, İzmir, Türkiye

³Dokuz Eylül Üniversitesi, Tekstil Mühendisliği Bölümü, İzmir, Türkiye

Online Erişime Açıldığı Tarih (Available online):30 Aralık 2020 (30 December 2020)

Bu makaleye atıf yapmak için (To cite this article):

Fatma Günseli YAŞAR ÇIKLAÇANDIR, Semih UTKU, Hakan ÖZDEMİR (2020): Kumaşlarda Hatayı Yerel Olarak Arayan Denetimsiz Bir Sistem, Tekstil ve Mühendis, 27: 120, 252- 259.

For online version of the article: <https://doi.org/10.7216/1300759920202712005>

Arastırma Makalesi / Research Article

KUMAŞLARDA HATAYI YEREL OLARAK ARAYAN DENETİMSİZ BİR SİSTEM

Fatma Günseli YAŞAR ÇIKLAÇANDIR^{*1}

Semih UTKU²

Hakan ÖZDEMİR³

¹İzmir Katip Çelebi Üniversitesi, Bilgisayar Mühendisliği Bölümü, İzmir, Türkiye

²Dokuz Eylül Üniversitesi, Bilgisayar Mühendisliği Bölümü, İzmir, Türkiye

³Dokuz Eylül Üniversitesi, Tekstil Mühendisliği Bölümü, İzmir, Türkiye

Gönderilme Tarihi / Received: 12.02.2020

Kabul Tarihi / Accepted: 30.10.2020

ÖZET: Kumaşlarda dokuma sırasında veya sonrasında oluşan kusurlar kumaşların kalitesini düşürür. Teknolojinin gelişmesiyle birlikte, kumaşlarda görülen kusurların sıklığı azalmıştır, ancak yine de ortaya çıkmaktadır. Kalite kontrol amacıyla kumaşlardaki kusurların tespiti bir personel tarafından yapılmaya çalışılır. Bu işlem yorucu olduğu kadar zordur. Ayrıca, kişinin hata yapma olasılığı çok yüksektir. Bu kontrol sürecini otomatikleştirmek için pek çok çalışma yapılmıştır. Bu çalışmada, kumaşın herhangi bir bölgesinde hata olup olmadığını bulmak için kumaş görüntüsü eşit boyutlarda bloklara ayrılmıştır. Görüntüye ait her bir bloğa özellik çıkarılma metodu uygulanıp çıkarılan bu özellikler K-means kümeleme algoritmasına sokulmuştur. Çalışmada özellik çıkarımı için gri seviye eş oluşum matrisi ve ortanca (medyan) farkı olmak üzere iki farklı metod uygulanıp performansları karşılaştırılmıştır. Yapılan deney sonuçlarına göre, gri seviye eş oluşum matrisi kullanıldığında hatayı bulma başarısının %97.99'a kadar yükseldiği gözlemlenmiştir. Medyan farkı kullanılarak kümeleme yapıldığında ise başarı oranı %86.91'e kadar çıkmaktadır. Ayrıca, başarılar atkı yönündeki hatalar ve çözgü yönündeki hatalar için ayrı ayrı hesaplandığında atkı yönündeki hataların çözgü yönündeki hatalara kıyasla daha kolay bulunduğu sonucuna varılmıştır.

Anahtar Kelimeler: Kumaş hatası bulma; gri seviye eş oluşum matrisi; medyan farkı; K-means; kumaş hataları.

AN UNSUPERVISED SYSTEM LOCALLY SEEKING FABRIC DEFECTS

ABSTRACT: Defects in the fabrics during or after weaving reduce the quality of them. With the development of technology, the frequency of the defects seen in fabrics has decreased, but still occurs. In the process of detecting fabric defects, the quality control unit tries to detect fabric defects. This process is both personal and time consuming, leading to costly and personal errors. For this reason, solutions have been proposed in studies to carry out and automate the process under computer control. In this study, fabric images are divided into blocks of equal sizes to find out whether there are any defects in the fabrics. The features, which are extracted by applying feature extraction method to each block of the image, are inserted into the K-means clustering algorithm. Two different methods are applied for feature extraction (gray level co-formation matrix and median difference) and their performances have been compared. The success rate of detecting the defect increases up to 97.99% when the gray level co-occurrence matrix is used. The success rate of detecting the defect increases up to 86.91% when the median differences are used. In addition, when the success rates are calculated separately for the defects in the weft direction and the defects in the warp direction, it is concluded that the defects in the weft direction are easier to find than the defects in the warp direction.

Keywords: Fabric defect detection; gray level co-occurrence matrix; median difference; K-means; fabric defects

*Sorumlu Yazar/Corresponding Author: fatma.gunseli.yasar@ikc.edu.tr

DOI: <https://doi.org/10.7216/1300759920202712005> www.tekstilvemuhendis.org.tr

1. GİRİŞ

Tekstil, insanlığın en temel ihtiyaçlarından biridir ve giyim ihtiyacını karşılar. Herkes kendi bütçesine göre alabileceği en güzel kıyafetleri giymek ister. Ancak müşteri bazen üzerindeki kusurdan dolayı hoşlandığı bir elbiseyi almaktan vazgeçer. Bu hem satıcı hem de alıcı için, dolayısıyla üretici için de olumsuz bir olaydır. Goldberg [1] kitabında kumaş hatalarını ham kumaş işletme hataları, iplik hataları, boya ve bitim hataları, giysi kumaşlarındaki hatalar, çeşitli düzgünsüzlükler olmak üzere beş farklı grupta toplayıp 194 adet hata çeşidine yer verirken Patel [2] ise 235 farklı kumaş hatasını listelemiştir. ISO standartlarında kumaş hataları iplik hataları, atkı yönündeki hatalar, çözgü yönündeki hatalar, boya, baskı veya bitim hataları, kenar hataları ve genel hatalar olmak üzere altı farklı şekilde kategorize edilirken 130 farklı hataya yer verilmiştir [3]. Bu hataların oluşma sebepleri hammadde kaynaklı, makine kaynaklı veya insan kaynaklı olabilmektedir [4].

Geleneksel olarak üretim işleminden sonra görsel olarak incelenen kumaş üzerindeki hatalar daha sonraki analizler için kaydedilir [5]. Kumaş daha sonra kusurların şiddetine göre derecelendirilir. Bazen de üretim esnasında incelenip herhangi bir hatanın oluşması durumunda müdahale edilir. Ancak, üretim sırasında personel ile yapılan kalite kontrolü personelin hata yapma ihtimalinin yüksek olması nedeniyle yeterince etkin bir çözüm değildir. Bu durum, otomatik bir sisteme duyulan ihtiyacı ortaya koymaktadır. Literatürde, kumaşlardaki kusurları otomatik olarak tespit etmeye çalışan birçok çalışma vardır. Oni ve ark. yapılan çalışmalarda desenli ve hem desenli hem renkli kumaşlar üzerine yapılan çalışmaların referans olarak verilmekte çok tercih edilmediğini belirtip bu kumaşlar için geliştirilen çalışmaları inceleyip karşılaştırmıştır [6]. Hanbay ve ark. bu alanda yapılan 99 farklı çalışmayı avantaj ve dezavantajlarıyla birlikte incelemiştir [7]. Çalışmaların büyük çoğunluğunun kendi oluşturdukları veri kümesini kullanmaları sebebiyle yöntemler birbiriyle karşılaştırılmaz, dolayısıyla da güvenilirliği ve geçerliliği tartışılmalıdır. İncelenen çalışmaların bir kısmı da TILDA veri kümesini kullanmaktadır [8]. Ancak bu ücretli bir veri kümesi olduğundan ulaşılması zordur. Bu alanda halka açık ve ücretsiz bir veri kümesi ihtiyacı söz konusudur. Kumaş hatası bulma üzerine yapılan çalışmalar Hanbay'ın yapmış olduğu çalışmada istatistik tabanlı, yapısal, spektral tabanlı, model tabanlı, öğrenme tabanlı ve melez yöntemler olmak üzere altı temel gruba ayrılmıştır [9].

Yapısal yaklaşımlarda öncelikle görüntüde temel doku analizi yapılarak elde edilen bilgiler modellenir. Abouelela ve ark. bu yaklaşımı kullanarak kumaş hatası bulmaya çalışmışlardır [10]. Görüntülerdeki ortalama, varyans ve medyan değerlerinin kullanıldığı bu çalışmada basit ve hızlı bir şekilde kumaş hataları tespit edilmiştir.

İstatistiksel tabanlı çalışmalarda eş oluşum matrisi [11-12] ve morfolojik işlemler [13] en çok karşılaşılan metotlardır. Zuo ve ark. gri seviye eş oluşum matrisi ile çıkardıkları özellikleri öklid uzaklığı kullanarak sınıflandırmıştır [11]. Hamdi ve ark. ise görüntüleri eşit boyutlarda bloklara bölüp gri seviye eş oluşum

matrisi kullanarak çıkardıkları özellikleri [11]'deki gibi öklid uzaklığı kullanarak sınıflandırmıştır [12].

Fourier dönüşümü [14], dalgacık dönüşümü [15-19], gabor filtresi [20] spektral tabanlı metotlardır. Hanbay ve ark. Fourier dönüşümü ile kumaşlarda yedi farklı dokusal özelliği çıkarır [14]. Çıkarılan özellikler vasıtasıyla sistem yapay sinir ağı kullanılarak eğitilmiştir. Çevrimdışı (gerçek zamanlı olmayan) ve çevrimiçi (gerçek zamanlı) olarak gerçekleştirilen testlerde sistemin başarılı olduğu görülmüştür. Ngan ve ark. dalgacık dönüşümünü baz alarak doğrudan eşikleme (direct thresholding) kullanan yeni bir metot geliştirirler [15]. Bu metotta golden görüntü çıkarma kullanılarak hatalı alan çıkarıldığında daha yüksek başarı elde edilmiştir (%96,7).

Denetimsiz (un-supervised) bir makine öğrenmesi tekniği olan kümeleme metotları Hanbay'ın çalışmasında model tabanlı çalışmalar arasında yerini almıştır. Öncesinde bir eğitimin olmadığı bu modelde algoritmaya sokulan verileri kümelere ayırma hedeflenir. Amaç, birbiriyle yakın özelliklerdeki verileri aynı kümeye atayıp birbirinden farklı özelliktekileri farklı kümelere atamaktır. Hamdi ve ark. görüntüleri eşit boyutta bloklara bölüp bu blokları hatalı/hatasız diye ayırmakta K-Means kümeleme algoritması kullanırlar [21]. Kumaşlar %95 başarı oranıyla kusurlu veya kusursuz olarak kümelendirilmiştir. Kumaşın herhangi bir bloğunda bir kusur varsa, hatalı blok K-Means vasıtasıyla bulunur. Kümeleme metotlarının yanı sıra gaussian mixture model de model tabanlı çalışmalar arasında yerini alır. İncelenen çalışmalara göre gaussian mixture model kullanıldığında bu metodun başka metotlarla güçlendirildiği görülmüştür [22-23].

Öğrenme tabanlı çalışmalarda denetimli (supervised) makine öğrenmesi tekniklerinden yapay sinir ağları [24-26] ve destek vektör makineleri [27] en çok karşılaşılan metotlardır. Denetimli makine öğrenmesi tekniklerinde elde edilen veri eğitim ve test için olmak üzere ikiye ayrılır. Eğitim işleminin gerçekleşmesi zaman alır ancak özellikle karmaşık problemlerde daha iyi sonuç elde edilmesini sağlar. Buradaki önemli unsur, eğitim verisinin doğru hazırlanmasıdır. Jmalı ve ark. [24] kumaş örneklerindeki hataları bulup sınıflandırmak için tek katmanlı sinir ağı kullanırken Kumar [25] ile Kuo ve Lee [26] geri beslemeli sinir ağı kullanırlar. Destek vektör makinelerinin kullanıldığı çalışmalarda sınıfları en iyi ayıran hiperdüzlemi bulmak için genellikle melez sistemlerin geliştirildiği saptanmıştır.

Yukarıda bahsedilen beş gruptaki metotların güçlü yönlerinin yanı sıra zayıf yönleri de vardır. Bu zayıf yönleri ortadan kaldırmak veya bu zayıf yönlerin etkisini en aza indirmek için başka metotlarla birleştirilip melez sistemler geliştirilebilmektedir [28-30]. Latif-Amet ve arkadaşlarının yapmış olduğu çalışmada dalgacık teorisi ve eş oluşum matrisi kullanılarak bir algoritma geliştirilir [28]. Görüntü kesişmeyen alt çerçevelere bölünür ve her bir çerçeveden çıkarılan eş oluşum özellikleri yardımıyla çerçeveler hatalı-hatasız şeklinde %90,78'e varan bir başarıyla sınıflandırılır. Abdullah ve ark. ile Dongli ve ark. çalışmalarında genetik algoritma ile destek vektör makineleri birleştirilerek sınıflandırma başarısını arttırmışlardır [29-30].

Literatürdeki çalışmaların çoğu belli hataları bulmak üzere geliştirilmiştir. Hata türü çeşitliliğinin çok fazla olması ve hataların farklı karakteristik özelliklere sahip olması bir sistemde hepsinin birden bulunmasını imkansız hale getirmektedir. Bu alanda geliştirilen melez sistemler sistemin geçerliliğini arttıracaktır [31].

Yukarıdaki çalışmalardan da görüldüğü üzere kumaş üzerindeki hatayı bulmak için önerilen sistemler farklı yaklaşımları içermektedir. Bu çalışmada model tabanlı bir sistem geliştirilmiş olup K-Means algoritması kullanılarak kumaşın herhangi bir yerindeki hatayı bulmak hedeflenmiştir. K-Means algoritmasında girdi olarak görüntüleri kullanmak zaman kaybına sebep olacağından görüntülerden özellikler çıkarılarak çıkarılan bu özellikler girdi olarak kullanılmıştır. Özellik çıkarma aşamasında [21] ve [12]'deki çalışmalarda yapıldığı gibi bloklaşma yapılmıştır. Referans verilen çalışmalardan farklı olarak ise medyan farkı metodu ile gri seviye eş oluşum matrisi metodunun sonuçları desensiz kumaşlar üzerinde araştırılmıştır. Bu çalışmada ayrıca farklı filtre etkileri de araştırılmıştır. Makalenin organizasyonu şu şekildedir: Bölüm 2'de bloklara ayırmanın ayrıntılarına yer verilmiştir. Bölüm 3'de, kümelemede girdi olacak özellikleri elde etmek için kullanılan gri seviye eş oluşum matrisi ve medyan farklarına yer verilmiştir. Bölüm 4'de K-Means kümeleme algoritmasından kısaca bahsedilmektedir. Bölüm 5'de elde edilen uygulama ve sonuçlar gösterilmiştir. Bölüm 6'da çalışmanın genel değerlendirmesi yapılmıştır.

2. MATERYAL VE YÖNTEM

2.1. BLOKLARA AYIRMA

Veri kümesindeki 256 x 256 boyuttaki görüntünün her biri eşit büyüklükte olan ve birbiriyle kesişmeyen bloklara bölünmüştür. Çalışma blok sayısı 16 ve 64 iken olmak üzere iki farklı durum için gerçekleştirilmiştir.

Çalışmada kullanılan uçuntu hatasına ait görüntünün bloklara ayrılmış hali Şekil 1'de verilmiştir. Şekil 1(a)'da görüntü 16

bloğa ayrılmıştır ve blokların her biri 32x32 pikseldir. Şekil 1(b)'de ise görüntü 64 bloğa ayrılmıştır ve blokların her biri 16x16 pikseldir.

2.2. ÖZELLİK ÇIKARIMI

2.2.1. Gri Seviye Eş Oluşum Matrisi (Gray Level Co-occurrence Matrix, GLCM)

1973 yılında Haralick tarafından geliştirilen gri seviye eş oluşum matrisi istatistiksel ölçümlere dayanır [32]. Matristen çıkarılan kontrast, korelasyon, enerji, homojenlik özellikleri bu çalışmada kullanılmıştır.

M matris formdaki gri seviye görüntü olmak üzere matrisin her bir elemanı 0 ile 255 arasındadır. (1) kontrast değeri M'deki yerel varyasyonları hesaplar. (2)'de ortalama değerleri olan μ_i ve μ_j denklemi verilmiştir. σ standart dağılım ve μ ortalama değerlerinin kullanılarak korelasyon değerinin elde edildiği denklem (3)'de verilmiştir. Korelasyon değeri M'deki doğrusal bağımlılığı hesaplar. Enerji, M'deki elemanların karelerinin toplamıdır (4). Görüntüde homojenlik arttıkça enerji de artar [33]. Homojenlik ise M'deki elemanların benzerliğini veren bir değerdir (5).

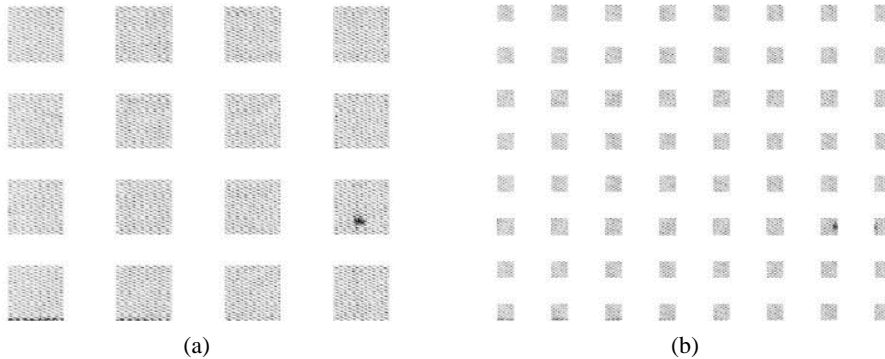
$$Konstrast = \sum_{i,j} |i - j|^2 p(i, j) \quad (1)$$

$$\mu_i = \sum_{i,j=0}^{N-1} iM(i, j), \quad \mu_j = \sum_{i,j=0}^{N-1} jM(i, j) \quad (2)$$


$$Korelasyon = \sum_{i,j} \frac{(i - \mu_i)(j - \mu_j)M(i, j)}{\sigma_i \sigma_j} \quad (3)$$

$$Enerji = \sum_{i,j} M(i, j)^2 \quad (4)$$

$$Homojenlik = \sum_{i,j} \frac{M(i, j)}{1 + |i - j|} \quad (5)$$



Şekil 1. Uçuntu hatası (a) Blok sayısı 16 iken (b) Blok sayısı 64 iken



Şekil 2. Uçuntu hatası (a) Filtresiz hal (b) Medyan filtre kullanıldığında (c) Entropi filtre kullanıldığında

2.2.2. Filtreleme ve Medyan Farkı Hesabı

Filtreleme görüntü işlemede yumuşatma, keskinleştirme, gürültü giderme, kenar algılama gibi pek çok amaç için kullanılmaktadır. Bu çalışmada medyan farkları üç farklı durum için uygulanmıştır (filtresiz iken, medyan filtre ile, entropi filtre ile). Şekil 2’de uçuntu hatası için filtrenin etkisi gösterilmektedir.

Mod, medyan (ortanca) ve mean (ortalama) istatistiksel kavramlardır. Veri kümesinde en çok tekrarlanan değer mod değerini, veri kümesindeki elemanların ortalaması mean değerini, veri kümesindeki elemanlar sıralandığında ortadaki değer de medyan değerini verir. Literatürdeki çalışmalarda medyanın mod ve mean’e göre daha etkili ve veri kümesindeki outlierlara karşı gürbüz (robust) bir yaklaşım olduğu bahsedilip medyan kullanılmaktadır [34]. Bu çalışmada da bloklardan özellik çıkarımında medyan değeri kullanılmıştır.

Aşağıda medyan farkı hesabı için gerekli denklemler verilmiştir. n blok sayısı olmak üzere (6), görüntünün bloklara ayrılmasının ardından her bir blok B_i için medyan değeri hesaplanmıştır (7). Tüm blok medyanların ortalaması (A_v) hesaplanıp her bir bloğun medyan değeri ile A_v arasındaki farkın mutlak değeri (Diff) bulunur (8). Her bir blok için bulunan bu fark değerleri K-Means algoritmasının girdisi olarak kullanılır.

$$i = 1, \dots, n \quad (6)$$

$$M_i = \text{medyan}(B_i) \quad (7)$$

$$\text{Diff}_i = |M_i - A_v| \quad (8)$$

2.3. K-MEANS ALGORİTMASI

Verileri anlamlı kümelerle bölmek için kullanılan birçok kümeleme algoritması bulunmaktadır. K-Means algoritması, J. B. MacQueen [35] tarafından önerilen ve en sık kullanılan kümeleme algoritmalarından biridir.

K küme sayısı olmak üzere her kümenin bir küme merkezi bulunmaktadır. Merkezlere başlangıç koordinat atamak için çeşitli yöntemler bulunmakla birlikte rasgele değerler de atanabilmektedir [36]. Algoritmada temel olarak veri kümesinin her

bir elemanı en yakın küme merkezine atanır. Ardından, her küme merkezinin koordinatları, bu kümeye atanan öğelerin ortalamaları alınarak güncellenir. Eleman atamaları ve küme merkezleri, küme merkezlerinin koordinatlarında bir değişiklik olduğu sürece güncellenmeye devam eder. Merkezlerin koordinatları değişmediğinde algoritma sonlandırılır. Algoritmanın adım algoritması aşağıda verilmiştir:

Adım 1. Küme sayısı K ve veri kümesi girdi parametreleri olarak kullanıcıdan alınır.

Adım 2. Merkezlerin başlangıç koordinatları belirlenir.

Adım 3. Veri kümesindeki her bir elemanın tüm küme merkezlerine olan uzaklığı hesaplanır.

Adım 4. Elemanlar, hangi kümenin merkezine daha yakınsa o kümeye atanır.

Adım 5. Küme merkezlerinin koordinatları elemanların koordinatlarının ortalaması alınarak güncellenir.

Adım 6. Adım 5’de küme merkezlerinin koordinatlarında değişiklik olduğu sürece Adım 3’ e gidilir ve işlemler tekrar edilir.

Bu çalışmada bloklar hatalı ve hatasız olmak üzere iki kümeye ayrılmak istenmiş ve bu iki kümenin merkez koordinatlarına veri setindeki minimum değer ve maksimum değer başlangıç koordinat olarak atanmıştır. Veri kümesindeki elemanlar ile merkezler arası uzaklık Öklid uzaklığı kullanılarak ölçülmüştür. x veri kümesinde bir nokta, c de merkezlerden biri olmak üzere x ile c arasındaki Öklid uzaklığı denklem (9)’daki gibi hesaplanır.

$$\text{uzaklık}(x, c) = \text{uzaklık}(c, x) = (\sum_{i=1}^n (x_i - c_i)^2)^{1/2} \quad (9)$$

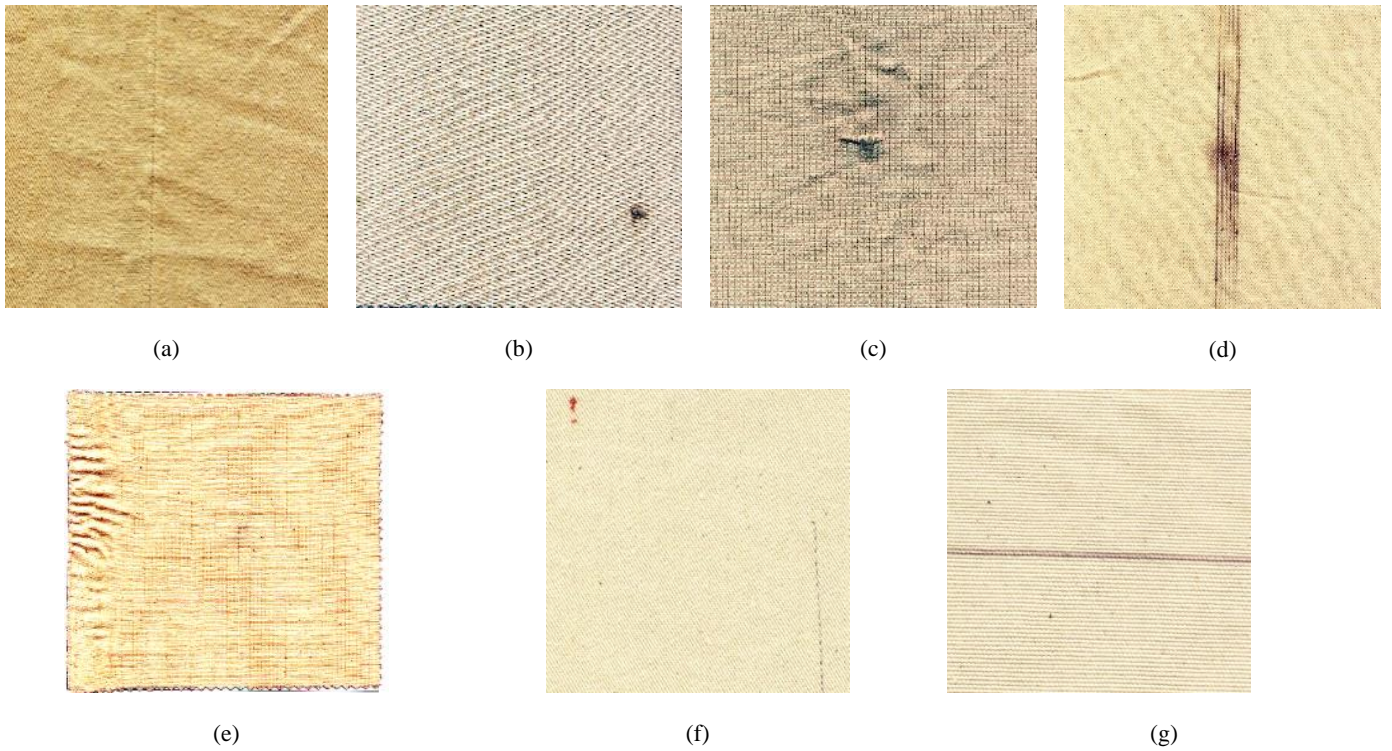
2.4. GELİŞTİRİLEN YÖNTEM

Sistem MATLAB R2019a’da geliştirilmiştir. Çalışmada Kısaoğlu’nun çalışmasında sunulan yedi farklı kumaş hatası üzerinde testler gerçekleştirilmiştir [37]. Bu hata tipleri; çözgü kopuğu, uçuntu, atkı yığılması, kirli çözgü, gergin gevşek, yabancı elyaf, kirli

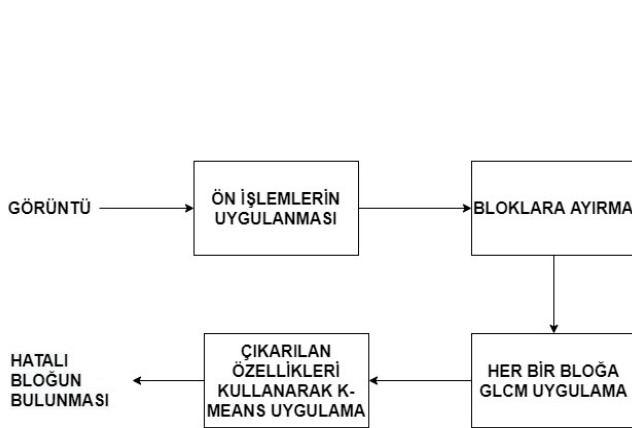
atkıdır (Şekil 3). Hazır veri kümesindeki görüntülerin genişlik ve yükseklikleri değişmekte olup 1100 ila 2000 piksel arasındadır.

Şekil 4’de GLCM kullanıldığında izlenen adımlar gösterilmektedir. Ön işlem olarak 256×256 görüntü elde edilip ardından gri seviyeye çevrilmiştir. Görüntünün bloklara ayrılmasının ardından gri seviye eş oluşum matrisi kullanılarak her bir bloğun kontrast, korelasyon, enerji ve homojenlik özellikleri elde edilir. Ardından her bir blok için çıkarılan bu dört özellik K-Means kümeleme algoritmasına sokulur. Görüntüdeki bloklar bu özellikler vasıtasıyla kümelenebilir.

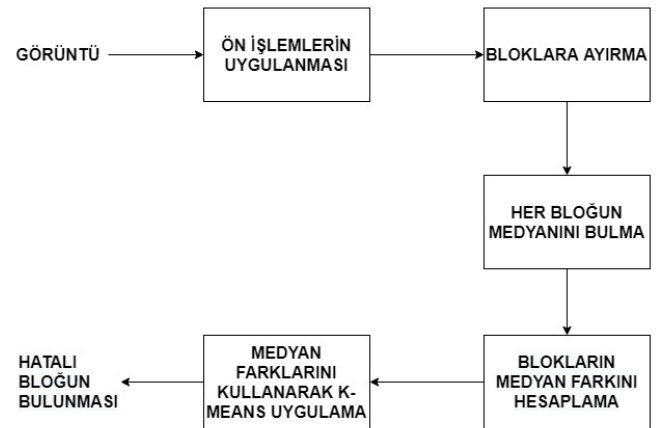
Şekil 5’de medyan farkı metodu kullanıldığında takip edilen adımlar gösterilmektedir. Burada ön işlem olarak boyutlandırma sonrası iki farklı filtre uygulanmış ve bu filtrelerin başarıya etkileri incelenmiştir. Görüntünün bloklara ayrılmasının ardından her bir blok için Denklem (8) kullanılarak Diff değerine ulaşılmıştır. Elde edilen Diff özelliklerine göre K-Means ile kümeleme gerçekleştirilmiştir.



Şekil 3. Kumaş Hataları (a) Çözgü kopuğu (b) Uçuntu (c) Atkı yığılması (d) Kirli Çözgü (e) Gergin gevşek (f) Yabancı iplik (g) Kirli atkı



Şekil 4. GLCM’nin Kullanıldığı Sistemin Akış Şeması



Şekil 5. Medyan Farkının Kullanıldığı Sistemin Akış Şeması

3. BULGULAR

Tablo 1’de metotlardan elde edilen doğruluk oranları verilmiştir. Farklı blok sayılarının sonuçları nasıl etkilediği araştırılmak istenmiş ve blok sayısı 16 iken ve 64 iken kümeleme gerçekleştirilmiş ve her iki durum için de sonuçlar kıyaslanmıştır. Bu veriler blokların hatalı-hatasız şeklinde doğru bir şekilde ayırt edilme oranlarını göstermektedir. Tabloya göre, blok sayısının 16 veya 64 olması durumunda elde edilen sonuçların değişiklik gösterdiği görülmektedir. Örneğin, gri seviye eş oluşum matrisinde ve medyan farklarında entropi filtre kullanıldığında blok sayısının artması başarı oranını artırırken diğer metotlarda başarı oranının düşürdüğü görülür. Ortalamalara bakıldığında ise 16 blok için %86.24 başarı sağlanırken 64 blok için %85.27 başarı elde edilmiştir.

Gri seviye eş oluşum matrisinde blok sayısı 16 iken %95.54 başarı elde edilmiş olup blok sayısı 64 iken %97.99 başarı elde edilmiştir. Medyan farkları metodunda ise 16 blok için K-Means algoritmasının herhangi bir filtre kullanmadan daha başarılı olduğu sonucuna varılmaktadır (%86.91). 64 blok için ise medyan farkları metodunda en yüksek başarı entropi filtre kullanıldığında elde edilmiştir (%82.59).

Tablo 1. Elde edilen doğruluk oranları

Metot		16 blok için	64 blok için
Gri seviye eş oluşum matrisi		0.9554	0.9799
Medyan Farkları	Filtresiz	0.8691	0.8170
	Medyan Filtre	0.8125	0.7879
	Entropi Filtre	0.8125	0.8259
Ortalama		0.8624	0.8527

Hataları dörde ayıracak olursak bunlar; çözgü yönünde olan hatalar, atkı yönünde olan hatalar, rastgele yönlü yüzey hataları ve kenar hatalarıdır. Bu çalışmada çalışılan çözgü kopuğu (kaçığı), kirli çözgü ve yabancı elyaf hataları çözgü yönünde iken atkı yığılması ve kirli atkı hataları atkı yönünde olup, gergin gevşek kenar hatası, uçuntu ise kumaş yüzey hatasıdır. Tablo 2’de uygulanan metotların atkı ve çözgü yönündeki doğruluk oranları verilmiştir. Veri kümesinde kenar hatası ve yüzey hatası içeren birer tane kumaş olması nedeniyle bu hata tipleri için ortalama başarı oranı verilmemiştir. Medyan farkları metodu için verilen oranlar en iyi sonucun elde edildiği filtresiz görüntü içindir.

Tabloda verilen oranlara bakıldığında, bu çalışmada kullanılan hata görüntüleri bazında atkı yönündeki hataların bulunma başarısının daha yüksek olduğu gözlemlenir (%95.9). Çözgü yönündeki hataların bulunma başarısı ise %90.89’dur. Gri seviye eş oluşum matrisi kullanıldığında blok sayısının artması ile başarı oranının da %95.32’den %98.83’e arttığı gözlenirken medyan farkları metodunda blok sayısı ile başarı doğru orantılı değildir.

Tablo 2. Metotların atkı yönünde ve çözgü yönündeki hataları bulma başarıları

Metot	Atkı yönünde	Çözgü yönünde	Ortalama
Gri seviye eş oluşum matrisi (16 blok)	0.9688	0.9375	0.9532
Gri seviye eş oluşum matrisi (64 blok)	0.9922	0.9844	0.9883
Medyan Farkları (16 blok)	0.9375	0.9167	0.9271
Medyan Farkları (64 blok)	0.9375	0.7969	0.8672
Ortalama	0.959	0.9089	

4. SONUÇ

Bu çalışmada kumaş görüntüsü üzerinde hata bulma işlemini piksel piksel gerçekleştiren bir sistem değil, görüntüyü bloklara ayırıp bloklardan çıkarılan özellikler yardımıyla gerçekleştiren bir sistem geliştirilmiştir. Böylelikle eğitime gerek kalmadan kumaş üzerindeki değişiklikler hızlı bir şekilde tespit edilir ve kumaş üretimi esnasında gerekli müdahale yapıp hatanın tekrar etmesinin önüne geçilmiş olur.

Geliştirilen sistemde istatistiksel bir ölçüm olan medyan değerlerinden elde edilen özellik ile gri seviye eş oluşum matrisinden elde edilen dört özelliğin kumaş bloklarını hatalı-hatasız olarak ayırt etmedeki başarısı araştırılmıştır. Çalışmada en iyi başarının elde edildiği metot gri seviye eş oluşum matrisi olmuştur (%95.54-%97.99). Ayrıca, görüntüler üzerinde filtrelerin elde edilecek sonuçlara etkisi araştırılmış olup medyan farklarına göre kümeleme sonuçları iki farklı filtre ile incelenmiştir. Elde edilen sonuçlara göre, filtresiz görüntüler üzerinde daha iyi sonuçlar elde edilmiştir (%86.91-%81.70). 16 blok için medyan filtre ve entropi filtrenin başarıları %81.25 olup 64 blok için başarıları değişkenlik göstermiştir (medyan filtre için %78.79, entropi filtre için %82.59). Blok sayısının başarıya etkisi incelendiğinde gri seviye eş oluşum matrisi kullanıldığında blok sayısı arttıkça başarı artarken medyan farkı metodu kullanıldığında net bir ilişki tespit edilememiştir. Veri kümesinde kullanılan örnek sayısının azlığı bu sonucu doğurmuş olabilir.

Çalışmada kullanılan metotların atkı ve çözgü yönündeki hataları bulma performansları karşılaştırıldığında atkı yönündeki hataların %95.9 başarı oranı ile bulunduğu, çözgü yönündeki hataların ise %90.89 başarı oranı ile bulunduğu sonucuna ulaşılır. Blok sayısının artması gri seviye eş oluşum matrisi kullanıldığında hem atkı hem de çözgü yönündeki hataların bulunma başarısını olumlu etkilerken (%95.32-%98.83) medyan farkları metodunda başarıyı düşürmüştür (%92.71-%86.72).

Bu çalışmada desensiz kumaşlarda hatalı bölgeyi bulmak hedeflenmiştir. [21] ve [12]'de desenli kumaşlar üzerinde gerçekleştirilen çalışmalara ek olarak gri seviye eş oluşum matrisi ile medyan farkı metotlarının performansları karşılaştırılmıştır ve yöntemlerin desensiz kumaşlarda nasıl sonuç verdiği araştırılmıştır. Bu iki metot sonucunda da elde edilen özellikler K-Means kümeleme algoritması kullanılarak hatalı-hatasız şekilde kümelendirilmiştir. Ayrıca [20]'den farklı olarak medyan farkı metodunda farklı filtrelerin etkisi de araştırılmıştır.

KAYNAKLAR

- Goldberg, J.B. (1950) . Fabric Defects - Case Histories Of Imperfections In Woven Cotton And Rayon Fabrics, Mcgraw-Hill Book Company, Inc., New York.
- Patel, A. (1974). Toward Zero Defects: Plug Profit Leak. Meena.
- ISO 1990, 'Woven Fabrics – Description of defects – Vocabulary', ISO 8498: 1990 (E/F).
- Bariş, B., & Özek, H. Z. (2019). Dokuma Kumaş Hatalarının Sistematik Sınıflandırılması Üzerine Bir Çalışma. *Tekstil ve Mühendis*, 26(114), 156-167.
- Behera, B. K. (2004). Image-processing in textiles. *Textile Progress*, 35(2-4), 1-193.
- Oni, D. I., Ojo, J. A., Alabi, B. O., Adebayo, A. A., & Amoran, A. E. (2018). Patterned Fabric Defect Detection and Classification (FDDC) Techniques: A Review [J]. *International Journal of Scientific & Engineering Research*, 9(2), 1156-1165.
- Hanbay, K., Talu, M. F., & Özgüven, Ö. F. (2016). Fabric defect detection systems and methods—A systematic literature review. *Optik*, 127(24), 11960-11973.
- TILDA Textile Texture-Database, <http://mb.informatik.uni-freiburg.de/resources/datasets/tilda.en.html> (2013).
- Hanbay, K. (2016). Yuvarlak örgü makineleri için görüntü işleme tabanlı kumaş hatası tespit sistemi. İnönü Üniversitesi Doktora Tezi.
- Abouelela, A., Abbas, H. M., Eldeeb, H., Wahdan, A. A., & Nassar, S. M. (2005). Automated vision system for localizing structural defects in textile fabrics. *Pattern recognition letters*, 26(10), 1435-1443.
- Zuo, H., Wang, Y., Yang, X., & Wang, X. (2012, October). Fabric defect detection based on texture enhancement. In 2012 5th International Congress on Image and Signal Processing, 876-880.
- Hamdi, A. A., Sayed, M. S., Fouad, M. M., & Hadhoud, M. M. (2016, May). Fully automated approach for patterned fabric defect detection. In 2016 Fourth International Japan-Egypt Conference on Electronics, Communications and Computers (JEC-ECC), 48-51.
- Çelik, H.İ., Dülger, L.C., & Topalbekiroğlu, M. (2014). Fabric Defect Detection Using Linear Filtering and Morphological Operations, *Indian Journal of Fibre & Textile Research*, 39, 254-259.
- Hanbay, K., Talu, M. F., & Özgüven, Ö. F. (2017). Fourier dönüşümü kullanılarak gerçek zamanlı kumaş hatası tespiti. *Gazi Üniversitesi Mühendislik-Mimarlık Fakültesi Dergisi*, 32(1).
- Ngan, H. Y., Pang, G. K., Yung, S. P., & Ng, M. K. (2005). Wavelet based methods on patterned fabric defect detection. *Pattern recognition*, 38(4), 559-576.
- Sakhare K., Kulkarni A., Kumbhakarn M., & Kare N. (2015). Spectral and Spatial Domain Approach for Fabric Defect Detection and Classification. In 2015 international conference on industrial instrumentation and control (ICIC), 640-644.
- Basturk A., Ketencioglu H., Yugnak Z., & Yuksel M.E. (2007). Inspection of Defects in Fabrics Using Gabor Wavelets and Principle Component Analysis. In 2007 9th International Symposium on Signal Processing and Its Applications, 1-4.
- Lambert, G., & Bock, F. (1997). Wavelet methods for texture defect detection. In Proceedings of International Conference on Image Processing, 3, 201-204.
- Hu, M. C., & Tsai, I. S. (2000). Fabric inspection based on best wavelet packet bases. *Textile Research Journal*, 70(8), 662-670.
- Jing, J., Yang, P., Li, P., & Kang, X. (2014). Supervised Defect Detection on Textile Fabrics via Optimal Gabor Filter. *Journal of Industrial Textiles*, 44(1), 40-57.
- Hamdi, A.A., Sayed, M.S., Fouad, M.M., & Hadhoud, M.M. (2018). Unsupervised patterned fabric defect detection using texture filtering and K-Means clustering. *International Conference on Innovative Trends in Computer Engineering*.
- Zhang, Y., Lu, Z., & Li, J. (2009, September). Fabric defect detection and classification using gabor filters and gaussian mixture model. In Asian conference on computer vision, Springer, Berlin, Heidelberg, 635-644.
- Kim, S. C., & Kang, T. J. (2006). Automated defect detection system using wavelet packet frame and Gaussian mixture model. *JOSA A*, 23(11), 2690-2701.
- Jmali M., Zitouni B., & Sakli F. (2014). Fabrics Defects Detecting using Image Processing and Neural Networks. *Information and Communication Technologies Innovation and Application*. DOI: 10.1109/ICTIA.2014.7883765.
- Kumar A. (2003). Neural Network Based Detection of Local Textile Defects. *Pattern Recognition*, 36, 1645 – 1659.
- Kuo C.F.J., & Lee C.J. (2003). A Back Propagation Neural Network for Recognizing Fabric Defects. *Textile Res. J.*, 73(2), 147-151.
- Ghosh, A., Guha, T., Bhar, R. B., & Das, S. (2011). Pattern classification of fabric defects using support vector machines. *International Journal of Clothing Science and Technology*.
- Latif-Amet, A., Ertüzün, A., and Erçil, A.. "An efficient method for texture defect detection: sub-band domain co-occurrence matrices", *Image and Vision computing*, 18(6-7), 543-553, 2000.
- Abdellah, H., Ahmed, R., & Slimane, O. (2014). Defect Detection and Identification in Textile Fabric by SVM Method. *IOSR Journal of Engineering*, 4(12), 69-77.
- Dongli, T., Zhitao, X., Fang, Z., Lei, G., & Jun, W. (2013). Cloth Defect Classification Method Based on SVM, *International Journal of Digital Content Technology and its Applications*, 7(3), 614-622.
- Hanbay, K., & Talu, M. (2014). Kumaş hatalarının online/offline tespit sistemleri ve yöntemleri. *Sakarya Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 18(1), 49-69.
- Haralick, R. M., Shanmugam, K., & Dinstein, I. H. (1973). Textural features for image classification. *IEEE Transactions on systems, man, and cybernetics*, (6), 610-621.
- Çalışkan, A., and Ergen, B. (2014). GRI seviye eş-oluşum matrisi tabanlı avuç içi tanıma sistemi.

34. Yang, J., Zhang, D., & Yang, J. Y. (2006, October). Median LDA: a robust feature extraction method for face recognition. In 2006 IEEE International Conference on Systems, Man and Cybernetics (Vol. 5, pp. 4208-4213).
35. MacQueen, J.B. (1967). Some Methods for Classification and Analysis of Multivariate Observations, Proc. Symp. Math. Statist. and Probability (5th), 281– 297.
36. Li, C.S. (2011). Cluster Center Initialization Method for K-means Algorithm over Data Sets with Two Clusters, International Conference on Advances in Engineering, 24, 324-328.
37. Kısaoğlu, Ö. (2002). Orta Büyüklükte Bir Dokuma İşletmesinde İstatistiksel Kalite Kontrol Sisteminin Kurulması, Dokuz Eylül Üniversitesi Yüksek Lisans Tezi.