

İSTANBUL TEKNİK ÜNİVERSİTESİ ★ FEN BİLİMLERİ ENSTİTÜSÜ

**ÖRME KUMAŞLARDAKİ ÜRETİM HATALARININ
GÖRÜNTÜ İŞLEME TEKNİKLERİ İLE OTOMATİK
TESPİTİ VE SINIFLANDIRILMASI**

YÜKSEK LİSANS TEZİ

Mak. Müh. Volkan ATMACA

Anabilim Dalı: DİSİPLİNLERARASI

Programı: MEKATRONİK MÜHENDİSLİĞİ

HAZİRAN 2005

**ÖRME KUMAŞLARDAKİ ÜRETİM HATALARININ
GÖRÜNTÜ İŞLEME TEKNİKLERİ İLE OTOMATİK
TESPİTİ VE SINIFLANDIRILMASI**

YÜKSEK LİSANS TEZİ

Mak. Müh. Volkan ATMACA

518031030

Tezin Enstitüye Verildiği Tarih : 4 Mayıs 2005

Tezin Savunulduğu Tarih : 1 Haziran 2005

Tez Danışmanı : Y.Doç.Dr. Şeniz ERTUĞRUL (İ.T.Ü.)

İkinci Danışman : Doç.Dr. Nuray UÇAR (İ.T.Ü.)

Diğer Jüri Üyeleri : Y.Doç.Dr. Ayhan KURAL (İ.T.Ü.)

Y.Doç.Dr. Zeki Yağız

BAYRAKTAROĞLU (İ.T.Ü.)

Y.Doç.Dr. Hale KARAKAŞ (İ.T.Ü.)

HAZİRAN 2005

ÖNSÖZ

Bu çalışmada örme kumaş üretiminde gerçek zamanlı kalite kontrol yapabilecek bir yöntem geliştirilmeye çalışılmıştır. Bu tür bir kontrol ile zamandan tasarruf sağlanmakla birlikte hatanın aynı kumaşta tekrar etmesi olasılığının ortadan kaldırılabileceği düşünülmüştür. Bu amacı gerçekleştirmek üzere görüntü işleme teknikleri ve yapay sinir ağları kullanılmıştır.

Çalışmamda değerli bilgileri ile bana yol gösteren sayın hocalarım Yrd. Doç. Dr. Şeniz ERTUĞRUL ve Doç. Dr. Nuray UÇAR ile yardımlarını esirgemeyen sevgili arkadaşım Özkan ÇELİK' e teşekkürü zevkli bir görev bilirim.

Mayıs, 2005

Volkan ATMACA

İÇİNDEKİLER

KISALTMALAR	iv
TABLO LİSTESİ	v
ŞEKİL LİSTESİ	vi
SEMBOL LİSTESİ	vii
ÖZET	viii
SUMMARY	xiii
1. GİRİŞ	1
2. ÖRME KUMAŞ YAPISI VE KUMAŞ HATALARI	3
2.1. Örme Kumaş Yapısı	3
2.2. Enine Yönde Hatalar	3
2.3. Boyuna Yönde Hatalar	4
2.4. Dokusal Hatalar	5
3. GÖRÜNTÜ İŞLEME VE ANALİZ METODLARI	6
3.1. Görüntünün İki Boyutlu Bir Sinyal Olarak Tanımlanması	6
3.2. Ön Görüntü İşleme Metotları	7
3.2.1. Basit Piksel Operasyonları	7
3.2.2. Histogram Eşitleme	7
3.2.3. Eşikleme	8
3.2.4. Orta Filtreleme	9
3.3. Fourier Dönüşümü	10
3.4. Nitelik Çıkarımı ve Kullanılan Yöntemler	15
4. HATA TESPİTİ VE SINIFLANDIRILMASI	24
4.1. Bulanık Bölgelere Ayırma	24
4.1.1. Bulanık Küme Teorisi	24
4.1.2. Bulanık Bölgelere Ayırma Algoritması	25
4.2. Yapay Sinir Ağları	27
5. YAPAY GÖRME	34
5.1. Yapay Görme Sistemleri	34
5.2. Kameralar	35
5.2.1. Görüntü Elde Etme	35
5.2.2. CCD Kameralar	35
5.3. Aydınlatma	38
6. SONUÇLAR VE TARTIŞMA	40
6.1. Yöntem ve Sonuç	40
6.2. Gerçek Zamanda Uygulama	41
KAYNAKLAR	44
ÖZGEÇMİŞ	47

KISALTMALAR

ADC	: Analog-Digital Conversion
CCD	: Charge Coupled Device
FCM	: Fuzzy C-Means
FFT	: Fast Fourier Transform
FIR	: Finite Impulse Response
RBP	: Resilient Back Propagation
YSA	: Yapay Sinir Ağı

TABLO LİSTESİ

	<u>Sayfa No</u>
Tablo 3.1. Tek boyutlu güç spektrumlarından çıkarılan nitelikler.....	19
Tablo 3.2. Sınıflandırmada kullanılacak tüm nitelikler ve tanımları.....	23
Tablo 4.1. Hatalı ve hatasız örneklerin ait oldukları sınıfları temsil eden numaralar.....	31
Tablo 4.2. YSA deneme sonuçları.....	33

ŞEKİL LİSTESİ

	Sayfa No
Şekil 2.1 : Örme kumaş yapısında may ve sıra.....	3
Şekil 2.2 : Örme kumaşta enine gerginlik hatası.....	4
Şekil 2.3 : Örme kumaşta yağ lekesi ve may kaçığı.....	4
Şekil 2.4 : Örme kumaşta patlak (delik).....	5
Şekil 3.1 : Grilik farkından yararlanılarak yapılan ayrıştırma.....	6
Şekil 3.2 : Histogram Eşitleme.....	8
Şekil 3.3 : Eşikleme işleminin kumaş görüntüsüne uygulanması.....	9
Şekil 3.4 : Histogram eşitleme uygulanmış görüntüye orta filtre uygulanması.....	10
Şekil 3.5 : Fourier Spektrumu.....	11
Şekil 3.6 : Güç spektrumunun kaydırılması.....	14
Şekil 3.7 : Kumaş doğrultularının belirlenmesi.....	16
Şekil 3.8 : İki boyutlu güç spektrumundan tek boyutlu güç spektrumuna geçilmesi.....	17
Şekil 3.9 : Örnek tek boyutlu güç spektrumu.....	18
Şekil 3.10 : Ters Fourier dönüşümü ile görüntü elde edilmesi.....	20
Şekil 3.11 : Fourier filtrelerinin uygulanacağı kumaş görüntüsü.....	20
Şekil 3.12 : Örnek kumaş görüntüsünün Fourier spektrumuna uygulanan filtreler ve ters Fourier dönüşümü sonuçları.....	21
Şekil 3.13 : Delik kumaşların ayrılmasında kullanılan niteliklerin Fourier spektrumundaki yerleri ve ters Fourier dönüşümleri ile elde edilen görüntüler.....	22
Şekil 4.1 : Basit nöron modeli.....	27
Şekil 4.2 : Değişik etkinlik fonksiyonları.....	28
Şekil 4.3 : İki ara katmanlı ileri beslemeli YSA yapısı.....	29
Şekil 4.4 : Çalışmada kullanılan YSA yapısı.....	31
Şekil 5.1 : İnsan gözünün anatomik yapısı.....	34
Şekil 5.2 : Çizgi tarama CCD.....	36
Şekil 5.3 : Alan tarama CCD.....	36
Şekil 5.4 : Önden ve arkadan aydınlatma.....	38
Şekil 5.5 : Dağınık ve yönlendirilmiş aydınlatma.....	38
Şekil 5.6 : Koyu alan ve açık alan aydınlatması.....	39
Şekil 6.1 : Yuvarlak örme makinası ve temel kısımları.....	42
Şekil 6.2 : NI firmasının görüntü yakalama kartı ve kompakt makine görüşü sistemi.....	43

SEMBOL LİSTESİ

I	: Grilik seviyesi
H	: Histogram fonksiyonu
r_k	: Grilik değeri
P	: Nitelik vektörü
f	: Geleneksel kümelerde üyelik fonksiyonu
μ_A	: Bulanık kümelerde üyelik fonksiyonu
v_k	: <i>k</i> bölgesinin merkezi
m	: Üyelik matrisinin bulanıklığının derecesini etkileyen üstel ağırlık
p	: Sinir ağı girişleri
w	: Ağırlıklar
b	: Yanlılık terimi (bias)
f	: Etkinlik (transfer) fonksiyonu
δ	: Hata terimi
d	: Sinir ağının hedef çıkışı
o	: Sinir ağı çıkışı
η	: Öğrenme oranı
E	: Sinir ağında toplam hata


ÖRME KUMAŞLARDAKİ ÜRETİM HATALARININ GÖRÜNTÜ İŞLEME TEKNİKLERİ İLE OTOMATİK TESPİTİ VE SINIFLANDIRILMASI

ÖZET

Bu tez çalışmasında düz örme kumaşların üretimi esnasında ortaya çıkan çeşitli hataların görüntü işleme yöntemleriyle otomatik olarak tespiti ve sınıflandırılması üzerinde çalışılmıştır. Ayrıca bu işin gerçek zamanlı olarak yapılabilirliği de araştırılmıştır.


Örme kumaşlar üretim esnasında herhangi bir kontrol işlemine tabi tutulmamaktadır. Bu kumaşlar ancak üretim sona erdiğinde kumaş topunun tekrar açılıp bir insan operatörce incelenmesi ile kalite kontrolden geçmektedir. Bu tür bir kontrol üretim sonrası ek bir işlem olarak yapıldığı için hem zaman almakta hem de insan operatörlerce yapılıyor olması kontrolün güvenilirliğini azaltmaktadır. Bunun yerine bilgisayar ve görüntü işleme tekniklerinin kullanılmasının daha güvenilir olacağı düşünülmektedir. Bu işlem zamandan tasarruf sağlamakla birlikte, makinede kumaşın örülmesi ile eşzamanlı olarak gerçekleştirildiğinde hata kaynağına anında müdahale edilmesine olanak vererek hatanın aynı kumaşta tekrarı olasılığını da ortadan kaldıracaktır.

Örme kumaşlarda üretim esnasında genellikle dört farklı hata oluşabilmektedir. (Şekil 1)



Şekil 1 : Hatalı ve hatasız kumaşlar; a) Hatasız kumaş, b) Boyuna hatalı kumaş (iğne izi), c) Enine hatalı kumaş (iplik gerginliği), d) Delik kumaş, e) Yağ lekeli kumaş

Çalışmada öncelikle sözü geçen hataları içeren kumaşlar ve hatasız kumaşlar grup başlıkları altında örnek kumaş resimleri bilgisayara aktarılmıştır. Yapılacak işlemleri kolaylaştırmak amacı ile gerçek renkli örnek resimler gri seviyeli hale getirilmiş ve kalitelerini artırmak amacı ile bazı ön görüntü işlemleri uygulanmıştır. Bu amaçla önce Histogram eşitleme yapılmıştır. Bu işlemin amacı resimde daha homojen bir parlaklık dağılımı elde etmektir. Histogram eşitleme ile mevcut piksellerin bulunduğu parlaklık aralığı maksimum aralığa dağıtılmaktadır. Bu işlemden sonra resimlerin ayrıntıları ilk duruma göre daha belirgin hale gelmektedir. (Şekil 2)



Şekil 2 : Histogram eşitleme; a) Örnek resim, b) Örnek resmin histogramı, c) Histogram eşitlemeden sonraki resim, d) Eşitlenmiş histogram

İkinci ön görüntü işlemi resimlerdeki gürültünün giderilmesi amacı ile yapılan orta filtrelemedir. Orta filtrelemede, görüntüdeki bir piksel işleme alındığında bu pikselin parlaklık değeri ile birlikte bu pikselin komşusu olan piksellerin parlaklık değerleri bir küme olarak ele alınır. Bu küme içindeki orta parlaklık değeri işleme alınan pikselin yeni parlaklık değeri olarak atanır ve aynı işlem resimdeki tüm pikseller için sürdürülür. Detayları belirginleştirilmiş ve gürültüsü giderilmiş olan örnek resimler bilgisayarda işlenmek üzere hazır hale gelmiştir.

Sınıflandırma işlemi için öncelikle bulanık mantık ve yapay sinir ağları düşünülmüştür. Sınıflandırmada kullanması için örnek kumaş görüntülerini en iyi şekilde temsil edecek sayılara (nitelik) ihtiyaç duyulmaktadır.

Kumaşın periyodik yapısı göz önüne alınarak sınıflandırmada kullanılacak nitelik çıkarımında Fourier Analizi'nden faydalanılmıştır.

Herhangi bir kavram iki dilde nasıl ifade edilebiliyorsa, görüntü işleme problemlerinde de veri hem uzaysal tanım kümesi hem de frekans tanım kümesinde değerlendirilebilir.

x gerçek bir değişken olmak üzere $f(x)$ sürekli bir fonksiyon olsun. $f(x)$ fonksiyonun Fourier dönüşümü;

$$F\{f(x)\} = F(u) = \int_{-\infty}^{\infty} f(x)e^{-j2\pi ux} dx \quad (1)$$

Gerçek bir fonksiyonun Fourier dönüşümü hemen her zaman kompleks bir sonuç verir.


$$F(u) = R(u) + jI(u) \quad (2)$$

$F(u)$ 'nın şiddeti $|F(u)|$, $f(x)$ 'in Fourier spektrumu olarak adlandırılır. Spektrumun karesi ise $f(x)$ 'in güç spektrumu veya spektral yoğunluk olarak isimlendirilir.

$$|F(u)| = \sqrt{R^2(u) + I^2(u)} \quad (3)$$

$$P(u) = |F(u)|^2 = R^2(u) + I^2(u) \quad (4)$$


Fourier analizi, temel olarak kumaştaki uzaysal periyodikliğin frekans domeninde ifade edilmesine dayanır. Kumaşta hata bulunması durumunda periyodik yapı bozulacağından spektrumun değişmesi ve hatanın spektrumda kendini göstermesi beklenir.



Şekil 3 : Bir örnek kumaşa ait iki (solda) ve tek boyutlu (sağda) güç spektrumları


Şekil 3'te örnek kumaşlardan birine hızlı Fourier Dönüşümü uygulanarak elde edilmiş olan iki ve tek boyutlu güç spektrumları görülmektedir. Örnek kumaşlar için tek boyutlu güç spektrumları elde edildikten sonra, bu spektrumlar incelenerek kumaşın hangi gruba dahil edileceğinin belirlenebilmesi için yeterince ayırt edici olabilecek nitelikler belirlenmeye çalışılmıştır. Literatürdeki çalışmalarda genellikle dikkate alınanlar birincil ve ikincil tepe büyüklükleri ile bu tepeler arasındaki uzaklıklardır. Bu çalışmada da öncelikle tepe büyüklüklerine dayanan nitelikler araştırılmıştır. Ancak bulunan niteliklerin yetersiz olduğu anlaşılmış ve iki boyutlu güç spektrumundan da nitelik teşkil edebilecek büyüklükler çıkarılmaya çalışılmıştır.

Bu amaçla iki boyutlu güç spektrumlarından aşağıda gösterildiği gibi özel bölgeler seçilerek incelenmiştir. (Şekil 4)



Şekil 4 : İki boyutlu güç spektrumunun incelenen bölgeleri; a) Alçak frekans bölgesi, b) Yüksek frekans bölgesi, c) Ara frekans bölgesi

Güç spektrumlarından Şekil 4'teki gibi özel bölgeler seçmek amacıyla basit filtreler tanımlanmıştır. Aynı filtreler kullanılarak Fourier dönüşümlerinden seçilen bölgelere ters Fourier dönüşümü uygulanarak bu frekansların kumaş resminde temsil ettiği özellikler belirlenmeye çalışılmıştır. (Şekil 5)



Şekil 5 : Ters Fourier Dönüşümü sonuçları; a) Orijinal görüntü, b) Güç spektrumu, c,e) Filtrelerden sonraki görüntüler, d,f) Filtrelerden sonraki güç spektrumları

Yapılan arařtırmalardan sonra, ara frekans b6lgelerindeki bazı frekans genliklerinin toplamlarının olduka ayırt edici olduėu g6r6lm6řt6r. (řek.4c) İki boyutlu g6 spektrumunda bulunan iki farklı ara frekans b6lgesindeki g6 deėerleri kullanılarak iki adet nitelik hesaplanmıřtır. Bir boyutlu g6 spektrumundan da beř adet nitelik ıkarılmıř ve elde edilen toplam yedi adet nitelik sınıflandırma iřleminde kullanılmıřtır.

Yapılan 6n alıřmada yapay sinir aėlarının bulanık b6lgelere ayırma metodundan daha iyi sonu verdiėi g6zlemlendiėinden sınıflandırma iřlemi iin yapay sinir aėları seilmiřtir. Yapılacak sınıflandırma iřlemi lineer ayrıřtırılabilir olmadıėından tek ara katmanlı sinir aėları yeterli doėrulukta sınıflandırma yapamamıřtır. Literat6rde de bu tip sınıflandırma iřlemlerinde genellikle iki ara tabakalı yapay sinir aėları kullanıldıėı g6r6lm6řt6r. Hazırlanan nitelikler iki ara tabakalı ve farklı n6ron sayılarına sahip yapay sinir aėlarına beslenerek en iyi sonucu veren yapay sinir aėı belirlenmiřtir. İki ara tabakalı ve bu tabakalarında altıřar adet n6ron bulunan ve Resilient Back Propagation 6ėrenme algoritmasına g6re eėitilen yapay sinir aėı alıřmada kullanılan 6rnek kumař resimlerini % 100 doėrulukla sınıflandırabilmiřtir.

alıřmada ayrıca gerek bir sistemin oluřturulması iin gerekli kameralar ve aydınlatma konuları ele alınmıř ve gerek zamanlı olarak alıřacak sistemin makinenin 6rme hızına yetiřebilmesi iin bilgisayar algoritmasının sahip olması gereken hız hesaplanarak geliřtirilen algoritmanın hız bakımından yeterli olup olmadıėı incelenmiřtir.

AUTOMATIC FAULT DETECTION AND CLASSIFICATION OF KNITTED FABRICS USING IMAGE PROCESSING TECHNIQUES

SUMMARY

The main goal of this thesis has been to develop a reliable method for automatic fault detection in plain knitted fabrics using image processing techniques. The feasibility of a real time system to realize the method has also been investigated.

The knitted fabrics are inspected and faults are classified by human inspectors. This operation is very time consuming and also subjective. Instead of human inspectors, machine vision and image processing techniques would be more reliable and real time inspection allows the operator to intervene the knitting machine to correct the source of error. This process removes the possibility of repetition of the same fault at the same fabric.

In general, four types of faults occur at knitted fabrics during production. (Fig.1)




Figure 1 : The fabric samples; a) Faultless, b) Longitudinal fault due to needle, c) Horizontal fault due to yarn density, d) Hole, e) Oil Spot

In the first step, images of four different types of faults and faultless fabric samples were transferred to the computer in gray scale. Histogram Equalization and Median Filtering were applied to gray scaled images to improve image quality.

The aim of Histogram Equalization is to have better contrast values in the image. This operation adjusts the contrast by distributing the image's pixel values over the full potential range for the storage class of the image.

Median Filtering was used for noise removal. In this operation the value of an output pixel is determined by the median of the neighborhood pixels, rather than the mean. This process was repeated for all the pixels in the image.




Figure 2 : Histogram equalization; a) Sample image, b) Histogram of the sample image, c) Image after histogram equalization, d) Equalized histogram

Neural Networks and Fuzzy Clustering were considered for the classification purpose. Some distinctive properties of the fabric image should be obtained for classification.

The fabric structure and its image has periodical components, hence the Fourier Analysis is a very convenient tool to explore the frequency components of the signal obtained from the fabric image.

Mathematical definition of the Fourier Transformation is as follows:

$$F\{f(x)\} = F(x) = \int_{-\infty}^{\infty} f(x)e^{-j2\pi ux} dx \quad (1)$$

The Fourier transform of a real function always gives complex numbers.

$$F(u) = R(u) + jI(u) \quad (2)$$

$$|F(u)| = \sqrt{R^2(u) + I^2(u)} \quad (3)$$

$$P(u) = |F(u)|^2 = R^2(u) + I^2(u) \quad (4)$$

Where $|F(u)|$ is the Fourier Spectrum of $f(x)$ and the square of the Fourier Spectrum is the Power Spectrum or the Spectral Density of $f(x)$.

The main purpose of using the Fourier Analysis is to detect the differences in frequency domain whenever the structure contains any fault. Then, it is expected to detect the inconsistencies from the normal structure by comparing the power spectrums.




Figure 3 : 2-D (left) and 1-D power spectrums (right) of a fabric sample.

Fig. 3 shows the 1-D and 2-D power spectrums obtained from Fast Fourier Transform of a fabric sample image. All of the 1-D power spectrums of samples were examined and some distinctive features of the power spectrum were tried to be found which is present in each of the faults. There are many studies that use the first and the second peak values and the distance between the peaks in the literature. In this work, firstly the peak values and related numbers have been examined. It has been seen that the 1-D power spectrum is not sufficiently distinctive for each kind of fault and 2-D power spectrums have been examined by the same way. The peak values and related numbers did not look distinctive. Therefore some special regions were specified and examined instead of individual peaks. These regions are shown below. (Fig.4)




Figure 4 : The regions chosen from 2-D power spectrums; a) Low frequency region, b) High frequency region, c) Specified band region

Three simple filters were used to separate the specified regions from the power spectrum. Same filters were applied to Fourier transforms and the inverse Fourier transforms of those separated regions were examined to understand the effects of

those frequencies in the original image. Different regions of 2-D power spectrums were examined by this way. (Fig.5)




Figure 5 : Inverse Fourier Transforms of specified regions; a) Original image
b) Power spectrum of the original image, c,e) Images after filtering, d,f) Power spectrums after filtering

It has been seen that distinctive features are present within certain radius or certain band region. (Fig.4c) Five features were obtained using amplitude values and the sum of amplitude values from 1-D power spectrum. Two features were calculated using the amplitude values from two different specified band regions. Thus, seven features obtained from 1-D and 2-D power spectrums have been chosen as characteristic features representing all types of the fabrics.

Fuzzy Clustering and Neural Networks were first tested. Neural Networks worked better than Fuzzy Clustering for this problem, hence neural networks have been chosen for classification purpose.

The most common classifiers in the literature are neural networks with two hidden layers. The training data obtained as explained above and scaled into interval 0-1 were used to train neural networks with two hidden layers but with different number of neurons.

Finally, a neural network with two hidden layers and six neurons at each hidden layer classified all of the sample fabric images with the accuracy of 100%. The Resilient Back Propagation algorithm was used as the training algorithm.

Having an algorithm with 100% classification accuracy, a real time fault classification system has been investigated. For this purpose, the required hardware was determined. The illumination problem was also mentioned. The speed of the algorithm was measured and compared to the necessary speed for real time fault inspection.

1. GİRİŞ

Endüstrinin çeşitli kollarında uygulanan otomatik kalite kontrol sistemlerinden biri de yapay görme sistemleri içeren makina görüşü uygulamalarıdır. Makina görüşü uygulamaları sayesinde üretim döngüsü içinde kontrol yapılabilmekte ve insan görüşünden kaçabilecek türde hataların da tespiti sağlanmaktadır. Tekstil endüstrisinin örmecilik sektörünün de bu tip bir kontrole ihtiyacı bulunmaktadır. Uygulamada kumaş üretim döngüsünden çıktıktan sonra kalite kontrolden geçmekte ve bu işlem yanılma ve yorulma ihtimali olan insan operatörler tarafından yapılmaktadır. Yuvarlak örme makinalarından çıkan kumaşların makina görüşü olan bir sistemle kalite kontrolünün yapılması ile zamandan tasarruf sağlanabileceği ve daha etkin bir kalite kontrol işlemi yapılabileceği düşünülmektedir.

Daha önce yapılan çalışmalarda görüntü işleme ve analiz yöntemlerinden yararlanılarak dokuma kumaşlarda olan atkı yokluğu, çözgü yokluğu, patlak, yağ izi, kalın yer, çift atkı gibi hatalar tespit edilebilmiştir. Ancak literatürde örme kumaşlarda hata tespitine yönelik yeterince başarılı bir çalışmaya rastlanmamıştır.

Literatürde sıkça rastlanan hata tespiti yöntemlerinden en basit olanları basit piksel operasyonlarıdır. Bu işlemler, Sobel filtresi, orta filtreleme, histogram eşitleme ve eşikleme işlemleridir. Bu ön görüntü işlemleri kullanılarak hatalı bölge kumaş görüntüsünden ayrılmaktadır [1,2,3,4,5]. Bu işlemler tek başlarına kullanıldıkları gibi diğer işlemlerden önce görüntü iyileştirme amacı ile de kullanılmışlardır.

İstatistiki veriler de hata tespitinde sıkça kullanılmaktadır. Bu yaklaşımda görüntünün piksellerinin grilik dağılımını temsil etmek üzere standart sapma, ortalama v.b. gibi istatistik veriler toplanmıştır. Ayrıca pikseller için komşuluk ilişkileri de tanımlanmıştır. Elde edilen veriler bu halleriyle kullanıldıkları gibi FIR filtre tasarımı ve Yapay Sinir Ağları gibi yöntemler kullanılarak hatalı ve hatasız kumaşlar sınıflandırılmışlardır [6,7,8].


Kumaş yapısının periyodik oluşu nedeni ile bir çok çalışmada sinyal işleme yöntemleri kullanılmıştır. Bu yöntemlerden ilki olan Fourier Analizi temel olarak kumaştaki uzaysal periyodikliğin frekans domeninde ifade edilmesine dayanır. Kumaşta hata bulunması durumunda periyodik yapı bozulacağından hatanın Fourier Spektrumu'nda kendini göstermesi beklenir. Fourier dönüşümünden elde edilen veriler Yapay Sinir Ağları ve Bulanık Mantık ile sınıflandırılarak kumaş hataları tespit edilmiştir [9,10,11,12,13,14].

Literatürde kullanılmış olan diğer sinyal işleme yöntemi Wavelet Analizi'dir. Bu yöntemde görüntü sinyali daha basit alt bileşenlerine ayrılıp başka tanım aralıklarında temsil edilmektedir. Bu sayede görüntü sinyalinin yorumlanması kolaylaştırılır [15,16,17,18,19]. Wavelet Analizi'nden elde edilen veriler tek başlarına kullanıldıkları gibi bu verileri Bulanık Mantık kullanarak sınıflandıran çalışmalar da mevcuttur [20].

2. ÖRME KUMAŞ YAPISI VE KUMAŞ HATALARI

2.1 Örme Kumaş Yapısı

Örme kumaşlar ilmek denen birimlerden oluşurlar. İlmeklerin kumaşın boyuna yönünde sıralanması ile oluşan çubuk biçiminde görünen yapılara “may” denmektedir. İlmeklerin enine sıralanması ile oluşan yapılar ise “sıra” olarak isimlendirilmektedir. (Şekil 2.1)




Şekil 2.1 : Örme kumaş yapısında may ve sıra

Kumaş örme makinasında örülürken her sıra değişik bir iplik kullanılarak örülür. 90 iplik besleme ünitesi ve bobini bulunan bir makinada kumaş örülürken, makina bir tam tur döndüğünde silindir şeklinde oluşan kumaşta 90 sıra birden örülür. Örme makinalarının bu çalışma şekilleri nedeniyle örme kumaşlar çok hızlı üretilmektedir.

2.2 Enine Yönde Hatalar

Kumaşlarda enine yönde ortaya çıkan hatalar sıralarda meydana gelen hatalardır. Enine yönde başlıca hata kaynağı farklı tip (farklı numara veya farklı hammaddeden üretilmiş) ipliklerin makina besleniyor olmasıdır. Yani enine hataların bu türü aslında iplikten kaynaklanan bir hatadır. Bir başka enine hata kaynağı makinada meydana gelmiş aşınma, eskime veya ayar bozuklukları sebebiyle ipliklerin beslenmesinde normalden farklı gerginlik oluşmasıdır.

Bu hatalar anlatılan şekilde beslenen ipin oluşturduğu sıranın diğer sıralara göre açık şekilde enine yönde kayması ile kendini belli eder. (Şekil 2.2)




Şekil 2.2 : Örne kumaşta enine gerginlik hatası

2.3 Boyuna Yönde Hatalar

Örne kumaşlarda boyuna yönde meydana gelen hatalar maylarda ortaya çıkarlar. Örne makinasında bir mayın oluşumunu belirli bir iğne sağladığı için, bir iğnede veya bir iğnenin tahrikini sağlayan kam sisteminde olabilecek aşınma veya başka sebeplerden kaynaklı bozukluklar o iğnenin oluşturduğu mayda ve dolayısı ile kumaşın boyuna yönünde bir hataya sebep olur. Boyuna hataların bir kaynağı da makinanın yüksek hızlarda çalışmasını mümkün kılan ve aşınmaları azaltan yağın fazla gelmesi ve örülen kumaşa bulaşmasıdır. (Şekil 2.3.a)


May kaçığı olarak adlandırılan hata ise bir iğnenin taşıdığı ilmeği herhangi bir sebeple bırakması sonucu ortaya çıkar. Bu hata kumaşta boyuna bir boşluk olarak göze çarpar. (Şekil 2.3.b)



Şekil 2.3 : Örne kumaşta yağ lekesi ve may kaçığı; a) Yağ lekesi, b) May kaçığı

2.4 Dokusal Hatalar

Başlıca doku hatası patlak veya deliktir. Bu hatanın olası kaynağı iplik kalitesi veya makina aksamındaki iğne, platin gibi parçalardan kaynaklanan sorunlardır.(Şekil 2.4)




Şekil 2.4 : Örme kumaşta patlak (delik)

3. GÖRÜNTÜ İŞLEME VE ANALİZ METOTLARI

3.1 Görüntünün İki Boyutlu Bir Sinyal Olarak Tanımlanması

Terimsel anlamıyla görüntü iki boyutlu bir ışık yoğunluğu fonksiyonunu ifade eder. $f(x,y)$ olarak ifade edebileceğimiz görüntü sinyali, herhangi x ve y koordinatlarındaki bir pikselin sahip olduğu ışık enerjisinin bir ölçüsüdür. $f(x,y)$ fonksiyonu, ışıklandırma ve yansıtma olmak üzere iki ayrı fonksiyonun süper-pozisyonundan oluşur. Monokrom bir f görüntüsüne ait (x,y) koordinatlarındaki enerji miktarı grilik seviyesi olarak adlandırılır ve $I(x,y)$ olarak gösterilir.

Başka bir yaklaşıma göre [24], görüntü iki ayrı tabakanın üst üste konulmuş hali olarak düşünülebilir. Tabakalardan biri görüntünün belirlenimci kısmını veren ve varyasyon göstermeyen kısmı, diğeri ise pikseller arasında büyük enerji farkları barındıran ve detayları veren, olasılıkla ifade edilebilen bölümüdür. Bir elma fotoğrafına bakıldığında elmanın silüetini ve şeklini belli eden kısım belirlenimci, üzerindeki tonlamaları, yüzeyindeki noktacıkları veren kısmın da olasılıksal kısım olduğu düşünülebilir. İşte resimlerin bu olasılık içeren tabakası cisimle ilgili önemli özelliklerin bilgilerini taşır ve bu bilgiler cismin farklı bölgelerinin ışığı farklı derecelerde soğurmasına ve yansıtmasına bağlıdır. Şekil 3.1’de bu yaklaşımdan yararlanılarak kan hücresinde sitoplazma ve hücre çekirdeği bölgelerinin ayrıştırılması görülmektedir [24].



Şekil 3.1 : Grilik farkından yararlanılarak yapılan ayrıştırma; a) Kan hücresi, b) Belirlenimci kısım, c) Olasılıksal kısım

Cismin üzerine gelen ışığa karşı cevabı bir atım fonksiyonuna cevabıdır ve bu anlık ışığa tepkiye görüntü denir. Görüntü yukarıda açıklandığı gibi iki ayrı bileşenden oluşur , $f(x,y) = g(x,y) + n(x,y)$. Burada $n(x,y)$ olasılığa bağlı olan kısımdır. Bu modelleme sayesinde görüntüyü istatistik biliminin bir malzemesi olarak görmek mümkündür. Böylece görüntüyü karakterize edebilen 1. dereceden ve 2. dereceden istatistik bilgiler görüntü analizinde ve sınıflandırmada kullanılır.

3.2 Ön Görüntü İşleme Metotları

3.2.1 Basit Piksel Operasyonları

Sayısallaştırılan görüntüde bulunan her bir piksel 0-255 arasında değişen bir grilik seviyesine sahiptir (0 siyah, 255 beyaz). Alınan kumaş görüntüsünün grilik seviyeleri aynı ışıklandırma koşulları ve aynı desen için aşağı yukarı aynı dağılımı göstermektedir. Fakat hatalı kumaşlarda bu dağılım bozulmakta ve görüntüde bulunan piksellerin toplam enerji değeri düşmekte veya yükselmektedir. Ancak bazı hatalarda bu enerji değerleri çok fazla etkilenmemektedir. Bu gibi durumlarda bazı basit piksel operasyonları ile detaylar daha belirgin hale getirilebilir hatta hatalı bölge arka plandan ayırt edilebilir.

3.2.2 Histogram Eşitleme

Gri seviyeli bir görüntüde hangi grilik değerinde kaç piksel bulunduğunu gösteren grafikler histogram olarak adlandırılır. Histogramın matematiksel tanımı aşağıdaki gibidir; [25]

$$H(r_k) = \frac{n_k}{n} \quad (3.1)$$

Burada ;

r_k : k'inci grilik değeri,


n_k : k'inci grilik değerine sahip piksellerin sayısı,

n : görüntüdeki toplam piksel sayısıdır.

$H(r_k)$ fonksiyonu grilik değeri r_k 'nın ortaya çıkma olasılığını veren tahmin fonksiyonu olarak da düşünülebilir. Böylece bu olasılık fonksiyonunu herhangi bir grilik değerine karşılık o değerın olasılığı şeklinde veren bir grafik ile göstermek mümkündür. Düşük kontrastlı yani ayrıntıların tam seçilemediği bir görüntüde r_k

değerleri dar bir aralıkta bulunmaktadır. Yüksek kontrastlı yani ayrıntıların rahatlıkla seçilebildiği bir görüntüde ise r_k değerleri geniş bir aralığa dağılmıştır. Bu nedenle kumaş görüntülerindeki ayrıntıların belirginleştirilmesi ve aydınlatma farklarının giderilmesi için kumaş görüntülerine histogram eşitleme uygulanmıştır.

Aşağıda bir örnek kumaş görüntüsüne histogram eşitleme işlemi uygulanmasının sonuçları görülmektedir (Şekil 3.2).



Şekil 3.2 : Histogram eşitleme; a) Örnek resim, b) Örnek resmin histogramı, c) Histogram eşitlemeden sonraki resim, d) Eşitlenmiş histogram

3.2.3 Eşikleme

Eşikleme işlemi gri seviyeli bir görüntüyü siyah-beyaza çevirme işlemidir. Bu işlemde belli bir grilik eşik değeri belirlenir ve o değerin altında grilik değerine sahip pikseller siyaha (0), üstündekiler beyaza (1) atanır. Bu işlem sonucunda hatalı bölge arka plandan tamamen bağımsız bir şekilde görülebilir hale getirilir. (Şekil 3.3)



Şekil 3.3 : Eşikleme işleminin kumaş görüntüsüne uygulanması; a) Orijinal kumaş görüntüsü (gri seviyeli), b) Eşikleme işlemi uygulanmış görüntü (siyah-beyaz)


Ancak örme kumaş yüzeyinde bulunması muhtemel hataların bir kısmı histogram eşitleme ve eşikleme ile tespit edilemez, çünkü hatalı bölgeyi gösteren pikseller arka plandan farklı bir grilik dağılımına sahip değildirler. İşte böyle basit piksel işlemleriyle ve ön işleme yöntemleriyle ayırt edilemeyen hatalar görüntüye ait daha ayrıntılı bilgi veren görüntü analiz yöntemleriyle ayırt edilebilirler.

3.2.4 Orta Filtreleme

Dijital resimlerin elde edilmesi ve iletilmesinde birçok farklı kaynaktan dolayı gürültüler oluşabilmektedir. Bu gürültülerin giderilmesi için kullanılan en etkin yöntem orta filtrelemedir.

Orta filtrelemede, görüntüdeki bir piksel işleme alındığında bu pikselin parlaklık değeri ile birlikte bu pikselin komşusu olan piksellerin parlaklık değerleri bir küme olarak ele alınır. Bu küme içindeki orta parlaklık değeri işleme alınan pikselin yeni parlaklık değeri olarak atanır. Bu şekilde işlem resimdeki tüm pikseller için sürdürülür. İşlemde kullanılan komşuluk alanı da ayrıca tanımlanabilmektedir.

Orta değerin kullanılmasının amacı en küçük ve en büyük değerlerin etkilerinin azaltılmasıdır. Orta değeri bulmak için tüm değerler küçükten büyüğe sıralanır, dizinin ortasında kalan değer o dizinin orta değeridir. Örneğin “3, 5, 6, 7, 14, 16, 18” sayı dizisinin ortalama değeri yaklaşık 9 iken orta değeri 7’dir. Orta filtreleme ile gürültü gidermenin bir örneği Şekil 3.4’te verilmiştir.



a

b

Şekil 3.4 : Histogram eşitleme uygulanmış görüntüye orta filtre uygulanması;
a) Gürültü eklenmiş görüntü , b) Orta filtreleme uygulanmış görüntü

3.3 Fourier Dönüşümü

Fourier analizinden yararlanarak kumaş görüntüleri üzerinde analiz yapan ve güç spektrumlarını kullanarak hataları inceleyen birçok çalışma bulunmaktadır [9,10,11,12,13,14]. Bu çalışmaların ortak yanı kumaşın periyodik yapısını temsil edecek dönüşüm olarak Fourier dönüşümünü almaları ve sonuçları istatistiksel bazı bilgilerle elde etmeleridir.

Fourier dönüşümü, bir görüntüyü görüntüdeki her bir frekans değerine karşılık gelen genlik ve faz değerlerinden oluşan bir matris şekline dönüştürür.

x gerçek bir değişken olmak üzere $f(x)$ sürekli bir fonksiyonunun Fourier dönüşümü;

$$F\{f(x)\} = F(x) = \int_{-\infty}^{\infty} f(x)e^{-j2\pi x} dx \quad (3.2)$$

şeklinde ifade edilebilir ($j = \sqrt{-1}$).

$F(u)$ fonksiyonuna ters Fourier dönüşümü uygulanarak $f(x)$ fonksiyonuna ulaşılabilir.

$$F^{-1}\{F(u)\} = f(x) = \int_{-\infty}^{\infty} F(u)e^{-j2\pi u x} du \quad (3.3)$$

Fourier dönüşüm çifti olarak adlandırılan bu denklemlerin varlık koşulu $f(x)$ 'in sürekli ve integrali alınabilir, $F(u)$ 'nin ise integrali alınabilir olmasıdır.


Gerçek bir fonksiyonun Fourier dönüşümü aşağıdaki gibi ifade edilir ;

$$F(u) = R(u) + jI(u) \quad (3.4)$$

$F(u)$ 'nin şiddeti $|F(u)|$, $f(x)$ 'in Fourier spektrumu olarak adlandırılır. Spektrumun karesi ise $f(x)$ 'in güç spektrumu veya spektral yoğunluk olarak isimlendirilir.

$$|F(u)| = \sqrt{R^2(u) + I^2(u)} \quad (3.5)$$

$$P(u) = |F(u)|^2 = R^2(u) + I^2(u) \quad (3.6)$$



Şekil 3.5 : Fourier Spektrumu

$R(u)$ ve $I(u)$ sırasıyla gerçek ve sanal kısımlardır.

$\phi(u)$ faz açısı ise ;

$$\phi(u) = \tan^{-1} \left(\frac{I(u)}{R(u)} \right) \quad (3.7)$$

Fourier dönüşümünde kullanılan u terimi frekans değışkeni adını alır [24].

$$e^{-j2\pi ux} = \cos(2\pi ux) - j \sin(2\pi ux) \quad (3.8)$$

Sürekli bir fonksiyon olan $f(x)$ bir diziye açılarak ayrık hale getirilebilir;

$$\{f(x_0), f(x_0 + \Delta x), f(x_0 + 2\Delta x), \dots, f(x_0 + (N-1)\Delta x)\} \quad (3.9)$$

$$f(x) = f(x_0 + x\Delta x)$$

Denklem 3.9’da $x = 0, 1, 2, \dots, N-1$ değerlerini alabilir. Bir başka deyişle, $\{f(0), f(1), f(2), \dots, f(N-1)\}$ dizisi, bu ayrık fonksiyona karşılık gelen sürekli fonksiyondan alınmış N eşit aralıklı örneklemei temsil etmektedir.

Yukarıdaki gösterime göre ayrık Fourier dönüşüm çifti şu şekilde ifade edilir;

$$F(u) = \frac{1}{N} \sum_{x=0}^{N-1} f(x) \cdot e^{-\frac{j2\pi ux}{N}} \quad (3.10)$$

$$u = 0, 1, 2, \dots, N-1$$

$$f(x) = \frac{1}{N} \sum_{u=0}^{N-1} F(u) \cdot e^{-\frac{j2\pi ux}{N}} \quad (3.11)$$

$$x = 0, 1, 2, \dots, N-1$$

Ayrık Fourier dönüşümündeki $u = 0, 1, 2, \dots, N-1$ değerleri, sürekli dönüşümdeki $0, \Delta u, 2\Delta u, \dots, (N-1)\Delta u$ değerlerine karşılık gelir. Bu gösterim $F(u)$ ’ nun frekans ekseninin orijininden başlaması dışında ayrık $f(x)$ ’te kullanılan ile benzerdir. Δu ve Δx terimleri arasındaki bağıntı ise;

$$\Delta u = \frac{1}{N \cdot \Delta x} \quad (3.12)$$

Ayrık Fourier dönüşümünde iki değişkenli durum ise şu şekilde ifade edilir;

$$F(u, v) = \frac{1}{MN} \sum_{x=0}^{N-1} \sum_{y=0}^{M-1} f(x, y) \cdot e^{-2j\pi \left(\frac{ux}{M} + \frac{vy}{N} \right)} \quad (3.13)$$

$$u = 0, 1, 2, \dots, M-1, \quad v = 0, 1, 2, \dots, N-1$$

ve

$$F(x, y) = \frac{1}{MN} \sum_{u=0}^{N-1} \sum_{v=0}^{M-1} f(u, v) \cdot e^{2j\pi \left(\frac{ux}{M} + \frac{vy}{N} \right)} \quad (3.14)$$

$$x = 0, 1, 2, \dots, M-1, \quad y = 0, 1, 2, \dots, N-1$$

İki değişkenli fonksiyon örneklendiğinde x ve y eksenlerinde sırasıyla Δx ve Δy farkları kullanılır. Bir boyutlu durumda olduğu gibi ayrık $f(x, y)$ fonksiyonu $f(x_0 + x\Delta x, y_0 + y\Delta y)$ fonksiyonunun $x = 0, 1, 2, 3 \dots M-1$ ve $y = 0, 1, 2, \dots, N-1$ için örneklenmesini gösterir.

Örneklemede kullanılan artışın frekans düzleminde ve uzaysal düzlemdeki ilişkisi;

$$\Delta u = \frac{1}{M\Delta x} \quad (3.15)$$

$$\Delta v = \frac{1}{N\Delta y} \quad (3.16)$$

Görüntülerin karesel diziler halinde örneklenmesi durumunda $M = N$ olacaktır. Bu durumda;

$$F(u, v) = \frac{1}{N} \sum_{x=0}^{N-1} \sum_{y=0}^{N-1} f(x, y) \cdot e^{-\frac{2j\pi(ux+vy)}{N}} \quad (3.17)$$

$u, v = 0, 1, 2, \dots, N-1$ için

$$f(x, y) = \frac{1}{N} \sum_{u=0}^{N-1} \sum_{v=0}^{N-1} F(u, v) \cdot e^{\frac{2j\pi(ux+vy)}{N}} \quad (3.18)$$


$x, y = 0, 1, 2, \dots, N-1$ için

Örneklenmiş bir sinyalin ya da görüntünün Fourier dönüşümü için ayrık Fourier dönüşümünün kullanılması durumunda, gerçekleştirilmesi gereken çarpım ve toplam işlemlerinin sayısı N^2 ile orantılıdır. Her ne kadar ifadenin üstel kısmının değerleri bir kez hesaplanıp hafızaya kaydedilse de ayrık Fourier dönüşümü oldukça yavaş bir yöntemdir.


Ayrık Fourier dönüşümünde işlem sayısını $N \cdot \log_2 N$ 'e indirmek hızlı Fourier dönüşümü (Fast Fourier Transform-FFT) ile mümkündür. İşlem sayısının N^2 'den $N \cdot \log_2 N$ 'e düşmesi hesaplamada büyük ölçüde hafifleme getirir. Örnek olarak, 8192 noktadan oluşan bir dizi için FFT algoritması kullanılarak yapılan hesaplamaların süresi ayrık Fourier dönüşümünün 600'de biri kadardır [25].

Hızlı Fourier dönüşümünün uygulanabilmesi için N küçük tamsayılara ayrılabilir olmalıdır. FFT'de en iyi sonuçlar ve uygulamanın en basit olduğu durum N 'in 2'nin kuvvetleri şeklinde ifade edilebildiği haldir [25]. Bu sebeple bu çalışmada hızlı Fourier algoritmasının kullanılabilmesi için incelenen kumaş görüntüleri 256x256 piksel olacak şekilde ön işleminden geçirilmiştir.

Kumaşlara yukarıda bahsedildiği gibi hızlı Fourier dönüşümü uygulanması sonucunda birincil tepe ve ikincil tepeler olarak nitelendirilen yapılar dağınık bir şekilde ortaya çıkmaktadırlar. (Şekil 3.6.a) Bu dağınıklığı gidermek ve birincil tepeyi merkeze almak için bir kaydırma algoritması bulunmaktadır. Bu işlemle birinci çeyrek dördüncü çeyrekle, ikinci çeyrek de üçüncü çeyrekle yer değiştirilerek güç spektrumunun orta noktası spektrumun merkezi yapılır ve frekanslar düzenlenmiş olur. Ayrıca normalde Fourier dönüşümünden gelen değerler arasında birincil tepe diğer değerlere oranla çok büyük bir değer aldığından sonuçları bir grafiğe yansıtmak pek anlamlı olmamaktadır. Bu sorunu çözmek, yani bakıldığında anlaşılması ve yorumlanması daha kolay grafikler elde etmek için güç spektrumu $P(u)$ yerine $\log(1+P(u))$ değerleri hesaplanmakta, bu değerler 0-1 aralığına normalize edilerek grafiğe yansıtılmakta, böylece değerler arasındaki büyük farklar ortadan kaldırılmaktadır.



a



b

Şekil 3.6 : Güç spektrumunun kaydırılması (üstten görünüş)

Şekil 3.6.b' de görüldüğü gibi, güç spektrumundaki tepeler periyodikliğin maksimum olduğu yönlerde dizilmişlerdir. Yataydaki tepeler kumaşın düşey doğrultudaki periyodik yapılarının sonucudur (maylar). Düşeydeki tepeler de kumaşın yatay doğrultudaki periyodik yapılarının sonucudur (sıralar).

3.4 Nitelik Çıkarımı ve Kullanılan Yöntemler

Çalışmanın bu kısmında, farklı hata türlerine sahip kumaş görüntüleri için güç spektrumlarından yeterince ayırt edici özellikler (nitelik) çıkarılmaya çalışılmıştır. Niteliklerin doğru seçiminde yardımcı olabilecek analitik yöntemler sınırlıdır. Nitelikler oluşturulurken göz önünde bulundurulması gereken bazı önemli noktalar şunlardır; [28]


- Ayıricılık : Farklı sınıflara ait olan nesnelerin nitelikleri de anlamlı farklılıklar gösteren değerlerde olmalıdır.
- Güvenilirlik : Aynı sınıfta bulunan nesnelerin nitelikleri benzer değerlere sahip olmalıdır.
- Bağımsızlık : Kullanılmakta olan nitelikler birbirleriyle etkileşim içinde olmamalıdır.
- Sayıca az olma : Kullanılan niteliklerin sayısına bağlı olarak görüntü işleme sisteminin yaptığı işlemlerin sayısı da artmaktadır.

Literatürde dokuma kumaşlar ile ilgili çalışmalarda güç spektrumlarında incelenen büyüklükler genellikle birincil ve ikincil tepeler (en büyük iki tepe) ile bu tepeler arasındaki mesafelerdir [9]. Bu tepeler kumaştaki periyodikliklerin en fazla olduğu doğrultularda yer alacaktır. Örme makinasında üretilmekte olan kumaşın görüntüsünün bir görme sistemi ile bilgisayara aktarılması sırasında kumaşın may doğrultusu ile kameranın y ekseninin çakışık olması neredeyse imkansızdır. Kumaş doğrultularının belirlenmesi ile bu sorunun giderilecektir. Ayrıca belirlenen kumaş doğrultuları kullanılarak bir kumaş için iki boyutlu güç spektrumundan tek boyutlu güç spektrumlarına geçilerek daha ayrıntılı inceleme yapmak da mümkün olacaktır.

Kumaş doğrultularının tespitinde Fourier dönüşümünün dönme özelliği kullanılmıştır. Kumaş resminin Fourier dönüşümü elde edildikten sonra, yatay eksenindeki tepelerin maylara tam dik doğrultuda oluşacağı bilinmektedir. Bu tepelerin doğrultularının belirlenmesi için Fourier dönüşümünden elde edilen iki boyutlu matris, merkezinden geçen ve yatay ile belirli bir miktar (+) ve (-) yönlerde açı yapan birkaç tane doğru ile taranmış ve bu doğru üzerindeki spektrum değerleri toplanmıştır [14]. Tam olarak tepelerin doğrultusu ile çakışan doğru için bu toplam

değeri maksimum olacağından kumaşın x doğrultusu (maylara dik olan doğrultu) belirlenmiş olur. (Şekil 3.7)

Kumaşın y doğrultusunun (sıralara dik olan doğrultu) belirlenmesinde iki seçenek bulunmaktadır. İlk seçenek, belirlenen x doğrultusuna tam dik olan doğrultuyu seçmektir. Ancak gerçekte maylar ve sıralar çoğu zaman birbirlerine tam dik değildir. Bu yüzden y doğrultusu bulunurken x doğrultusunun bulunmasında izlenen yöntemle benzer bir yöntem kullanılmıştır. Ancak tarama işlemine başlamadan önce güç spektrumunun ortasında kare şeklinde bir bölge sıfırlanmıştır. Bunun nedeni, y doğrultusunda merkezde net tepeler yerine genellikle dağınık yapıların ortaya çıkması bunun da anlamlı bir sonuç oluşturmada kullanılamamasıdır.




Şekil 3.7 : Kumaş doğrultularının belirlenmesi; a) Histogram eşitleme ve orta filtrelemeden geçmiş kumaş görüntüsü, b) Görüntünün güç spektrumu, c) Belirlenen x doğrultusu, d) Belirlenen y doğrultusu

x ve y doğrultularının belirlenmesinde kullanılan tarama doğrularının açılarının seçiminde dikkatli olmak gerekmektedir. Doğrular dar bir aralıkta tutulursa (yataya göre $\pm 3^\circ$ aralığı gibi) daha büyük sapmaya sahip kumaşlar için doğrultuları belirlemek mümkün olmaz. Aralık çok geniş tutulduğunda ise doğrular bir doğrultudaki tepeleri izlemek yerine çaprazdaki tepelerden geçebilir ve tamamen

hatalı bir doğrultu seçilebilir. Bu çalışmada kullanılan kumaş örnekleri için yataya göre $\pm 14^\circ$ uygun görülmüştür.

Her bir kumaş resmi için doğrultular belirlendikten sonra, x ve y doğrultularındaki tek boyutlu güç spektrumlarını elde etmek üzere iki boyutlu güç spektrumu belirlenen doğrultularda okutulmuştur. Tek boyutlu güç spektrumları birincil tepe merkez alınarak her iki tarafta simetrik olan değerler arasından daha büyük olanın her iki tarafa da atanması sureti ile simetrikleştirilmiştir [9]. (Şekil 3.8)




Şekil 3.8 : İki boyutlu güç spektrumundan tek boyutlu güç spektrumuna geçilmesi;

a) İki boyutlu güç spektrumunda belirlenen x doğrultusu, b) İki boyutlu güç spektrumunda belirlenen y doğrultusu, c) x doğrultusunda simetrikleştirilmiş tek boyutlu güç spektrumu, d) y doğrultusunda simetrikleştirilmiş tek boyutlu güç spektrumu

Yukarıdaki işlem sonucunda her bir örnek kumaş için ikişer adet tek boyutlu güç spektrumu elde edilmiştir. Tüm tek boyutlu güç spektrumları incelenerek hangi hata durumunda spektrumda nasıl değişiklikler olduğu gözlenmiştir.(Şekil 3.9) Tek boyutlu güç spektrumlarından yalnızca sıra doğrultusundaki spektrumda nitelik

oluşturması muhtemel büyüklükler bulunmuştur. Tablo 3.3'te bu büyüklükler ve tanımları verilmiştir.



Şekil 3.9 : Örnek bir tek boyutlu güç spektrumu


Şekil 3.9'da görülen tek boyutlu güç spektrumunda yatay eksen frekans eksen, dikey eksen de bu frekanslara karşılık gelen güç değerlerini temsil etmektedir. Kumaş görüntülerinin tek boyutlu güç spektrumları dağınık olan tepeler düzenlenerek simetrikleştirilmiştir. (Şekil 3.6) Buna göre Şekil 3.9'daki frekans eksen, bu haliyle indekslenmiş durumdadır. Yani frekans ekseninde güç spektrumunun merkezi 0 noktası değil birincil tepenin bulunduğu 129'uncu noktadır. Bu noktadan sağa ve sola gidildiğinde frekanslar artmaktadır. Nitelikler tanımlanırken sözü edilen frekanslar indeks numaraları ile anılacaktır.

Tablo 3.1 : Tek boyutlu güç spektrumlarından çıkarılan nitelikler


Nitelik	Tanımı	Sınıflandırmadaki Rolü
P_1	x doğrultusundaki tüm güç değerlerinin toplamı	Enine hatalı örneklerin diğerlerinden ayrılması
P_2	x doğrultusundaki 117 indeks no'lu frekansa karşılık gelen güç değeri (ikincil tepe)	Hatasız örneklerin diğerlerinden ayrılması
P_3	x doğrultusunda 80-90 arasındaki en büyük tepe değeri ile 100-110 arasındaki en büyük tepe değerinin farkı	Hatasız örneklerin diğerlerinden ayrılması
P_4	x doğrultusundaki 120-128 arası güç değerlerinin toplamı	Yağ lekeli örneklerin diğerlerinden ayrılması
P_5	x doğrultusundaki 134-137 arası güç değerlerinin toplamı	Boyuna hatalı örneklerin diğerlerinden ayrılması

Tablo 3.3'te verilen nitelikler incelendiğinde, delik hatası olan örnekler haricinde diğer tüm hata türleri için ayırt edici büyüklükler bulunduğu görülmektedir. Tek boyutlu güç spektrumlarından delik örnekleri ayırt etmede kullanılabilecek bir nitelik çıkarılamamıştır. Literatürde, Fourier Analizi kullanarak hata tespiti yapılan çalışmalarda da tek boyutlu güç spektrumları kullanılmıştır [9,13,14,17]. Ancak sadece dokuma kumaşlarda hata tespiti yapan çalışmada tatmin edici sonuçlar elde edildiği görülmektedir [9].

Tek boyutlu güç spektrumlarından elde edilen niteliklerin yetersiz olduğu anlaşıldığından iki boyutlu güç spektrumlarından da nitelik oluşturması muhtemel büyüklükler çıkarılmaya çalışılmıştır. Bu amaçla, ters Fourier dönüşümü kullanılarak Fourier dönüşümündeki farklı frekansların kumaş görüntüsünde temsil ettiği özellikler bulunmaya çalışılmıştır. (Şekil 3.10)




a




b

Şekil 3.10 : Ters Fourier dönüşümü ile görüntü elde edilmesi; a) Örnek görüntünün güç spektrumu, b) Örnek görüntünün Fourier dönüşümüne ters Fourier dönüşümü uygulanması sonucu elde edilen görüntü

Fourier dönüşümünden farklı bölgeler seçmek amacıyla üç adet basit filtre tanımlanmıştır [10]. Bu filtreler sırasıyla, “Alçak Geçiren Filtre”, “Yüksek Geçiren Filtre” ve “Bant Geçiren Filtre” dir. Bu filtrelerin bir örnek kumaş görüntüsünün (Şekil 3.11) Fourier dönüşümüne uygulanması ve seçilen bölgelere ters Fourier dönüşümü uygulanmasının sonuçları Şekil 3.12’de verilmiştir.




Şekil 3.11 : Fourier filtrelerinin uygulanacağı örnek kumaş görüntüsü



Şekil 3.12 : Örnek kumaş görüntüsünün Fourier dönüşümüne uygulanan filtreler ve ters Fourier dönüşümü sonuçları; a,b) “Alçak Geçiren Filtre” ve ters Fourier dönüşümü sonucu, c,d) “Yüksek Geçiren Filtre” ve ters Fourier dönüşümü sonucu, e,f) “Bant Geçiren Filtre” ve ters Fourier dönüşümü sonucu

Şekil 3.12’deki sonuçlar incelenerek, Fourier spektrumu ile ilgili bazı genellemeler yapılabilir. Merkezdeki (129,129) frekansa karşılık gelen güç değeri kumaş görüntüsünün ortalama parlaklığını temsil etmektedir. Ayrıca merkeze yakın frekanslar kumaşın genel yapısına ait bilgileri barındırırken, merkezden uzak frekanslar kumaşın detaylarını içeren bilgileri barındırmaktadır. Bu bilgiler ışığında, her üç filtre uygulamasının sonuçları değişik filtre çapları için ayrıntılı olarak incelenerek delik bilgisinin spektrumun belirli bir bölgesinde temsil edilip edilmediği araştırılmıştır. Şekil 3.12.b’ den anlaşılacağı üzere delik bilgisi merkeze yakın bir

daire içinde bulunmaktadır. Bu yüzden çalışmalar bu bölge içinde yoğunlaştırılmıştır. Sonuçta delik olan örnekler için ayırt edici büyüklükler kumaşın genel yapısına ait bilgileri içeren alçak frekans bölgesinde belli bant aralıkları içinde bulunmuştur. (Şekil 3.13) Bu bölgelerdeki güç değerlerinin toplamaları delik örnekler için diğer hata türlerine göre çok büyük değerler almaktadır.



Şekil 3.13 : Delik örneklerin ayrılmasında kullanılan niteliklerin Fourier spektrumundaki yerleri ve ters Fourier dönüşümleri ile elde edilen görüntüler

256x256 piksel boyutlu bir görüntünün güç spektrumu da 256x256 boyutlarında bir matristir. Şekil 3.13.a’ da görülen bölgenin dış yarıçapı merkezden itibaren matrisin 10 elemanı iç çapı da 3 matris elemanıdır. Bu bölge birinci ara frekans bölgesi olarak adlandırılabilir. Şekil 3.13.c’ de görülen bölgenin dış yarıçapı 8, iç yarıçapı 5 matris elemanından oluşmaktadır. Bu bölge de ikinci ara frekans bölgesi olarak adlandırılabilir.

Sonuç olarak tek boyutlu güç spektrumundan beş adet ve iki boyutlu güç spektrumundan iki adet olmak üzere toplam yedi adet nitelik sınıflandırma işleminde kullanılmak üzere seçilmiştir.

Tablo 3.2 : Sınıflandırmada kullanılacak tüm nitelikler ve tanımları

Nitelik	Tanımı	Sınıflandırmadaki Rolü
P ₁	x doğrultusundaki tüm güç değerlerinin toplamı	Enine hatalı örneklerin diğerlerinden ayrılması
P ₂	x doğrultusundaki 117 indeks no'lu frekansa karşılık gelen güç değeri (ikincil tepe)	Hatasız örneklerin diğerlerinden ayrılması
P ₃	x doğrultusunda 80-90 arasındaki en büyük tepe değeri ile 100-110 arasındaki en büyük tepe değerinin farkı	Hatasız örneklerin diğerlerinden ayrılması
P ₄	x doğrultusundaki 120-128 arası güç değerlerinin toplamı	Yağ lekeli örneklerin diğerlerinden ayrılması
P ₅	x doğrultusundaki 134-137 arası güç değerlerinin toplamı	Boyuna hatalı örneklerin diğerlerinden ayrılması
P ₆	Birinci ara frekans bölgesindeki tüm güç değerlerinin toplamı	Delik örneklerin diğerlerinden ayrılması
P ₇	İkinci ara frekans bölgesindeki tüm güç değerlerinin toplamı	Delik örneklerin diğerlerinden ayrılması

4. HATA TESPİTİ VE SINIFLANDIRILMASI

4.1 Bulanık Bölgelere Ayırma

4.1.1 Bulanık Küme Teorisi

Bulanık sistemlerin iki temel bileşeni bulanık kümeler ve bulanık kümeler üzerinde yapılan işlemlerdir. Bulanık mantık bu işlemleri kullanarak ve bulanık kümelerin kombinasyonlarına dayanarak kurallar tanımlar [29].

$X = \{x\}$ şeklinde verilen bir tanım evreninde katı (geleneksel-klasik) bir A kümesi, A 'nın elemanı olan tüm $x \in X$ elemanlarını numaralandırarak tanımlanır.

$$A = \{x_1, x_2, \dots, x_n\} \quad (4.1)$$

Elemanların A kümesine üyelikleri bir f_A fonksiyonu ile şu şekilde ifade edilebilir ;

$$f_A : X \rightarrow \{0,1\}, \quad f_A = \begin{cases} 1 & x \in A \text{ için} \\ 0 & x \notin A \text{ için} \end{cases} \quad (4.2)$$

Yani, rasgele seçilen bir x , A katı kümesine ya üyedir ya da değildir, kısmî üyeliğe izin verilmez. A ve B gibi iki küme için aşağıdaki işlemler tanımlanabilir ;

$$A \cup B = \{x \mid x \in A \text{ veya } x \in B\} \quad (4.3)$$

$$A \cap B = \{x \mid x \in A \text{ ve } x \in B\} \quad (4.4)$$

$$\bar{A} = \{x \mid x \notin A, x \in X\} \quad (4.5)$$

Ayrıca katı kümelerde şu kurallar da sağlanmalıdır;

$$A \cap \bar{A} = \emptyset \quad \text{ve} \quad A \cup \bar{A} = X \quad (4.6)$$

Bulanık kümeler klasik kümelerin genelleştirilmiş halleridir. Bir A bulanık kümesi, $x \in X$ olan her x elemanına gerçel değerli sıfır ile bir arasında değişen bir değer atayan bir $\mu_A(x)$ üyelik fonksiyonu ile karakterize edilir [29].

$$A = \{(x, \mu_A(x)) \mid x \in X\} \quad (4.7)$$

Üyelik fonksiyonu $\mu_A(x)$, katı kümelerdeki f_A fonksiyonunun karşılığı olarak x elemanının hangi derecede A vasfını taşıdığını gösterir. Üyelik fonksiyonlarının seçimi ise rasgeledir. Seçim, ilgilenilen konu ve bulanık teknik için konulan hedefe göre yapılmalıdır. En sık kullanılan üyelik fonksiyonları parçalı-doğrusal fonksiyonlar, ikinci derece polinomlar veya trigonometrik fonksiyonlardır [29].

Görüntü işlemede birçok belirsizliğin bulunması bulanık yöntemlerin diğer yöntemlere göre bu alanda daha çok tercih edilmesini sağlamıştır. Bulanık mantık şablon tanıma (pattern recognition), bölge analizleri ve sınıflayıcı tasarımı gibi işlemlerde kullanılmaktadır [30]. Görüntü verisini tamamen üyelik fonksiyonu değerleri olarak histogram eşitleme, aşındırma (erosion), genişletme (dilation) gibi çeşitli görüntü işlemlerini tamamen bulanık mantık temelli olarak gerçekleştiren algoritmalar geliştirilmiştir [29].

4.1.2 Bulanık Bölgelere Ayırma Algoritması

Bulanık bölgelere ayırma algoritmaları ayrılacak bölge sayısı belirli olanlar ve olmayanlar olmak üzere başlıca iki türe ayrılmaktadır. Bölge sayısı belirli olan algoritmalar doğal olarak daha basit ve hızlıdır. Bu çalışmada sınıflanması gereken grup sayısı belirli (beş) olduğundan ilk tür algoritmalar kullanılmıştır.

Bulanık c-ortalama bölgeye ayırma algoritması, ayrılacak bölge sayısı belli olan mevcut algoritmalar arasında oldukça kullanışlı ve en yaygın olanıdır. Bulanık c-ortalama bölgeye ayırma algoritması p-boyutlu uzaydaki küresel bulutları tespit eder. Bölgelerin yaklaşık aynı büyüklükte olduğu kabul edilir. Her bölge merkezi ile temsil edilir.

Bölgeye ait olan tüm bilgiyi temsil eden bu tanımlamaya (yani merkeze) prototip adı verilir. Mesafe ölçümü için, veri ile prototip arasındaki Öklit mesafesinden faydalanılır. Algoritmanın ismindeki c harfi bölge sayısını göstermektedir, örneğin 5 bölgeye ayırma yapılacaksa algoritma bulanık 5-ortalama adını almaktadır, fakat bu şekilde kullanım pek yaygın değildir, genellikle c değiştirilmeden bırakılır [27].

Bulanık olmayan kesin bölgelere ayırma yönteminde farklı bölgelerin sınırları tam anlamıyla bir bölgeyi temsil eden şablonlardır. Diğer taraftan, bulanık bölgelere ayırma, farklı derecelerde aitlik gösteren bölge üyelik değerleri tarafından sağlanan ek bilgileri kullanarak ayırım yapar. p-boyutlu Öklit uzayının R^p elemanları olan sonlu küme elemanları olan $X = \{x_1, \dots, x_n\}$ 'de amaç, verilmiş olan ölçüte bağlı kalarak bu elemanların oluşturduğu bölgelerin numarasını temsil eden c tane bulanık kümeye ayırmaktır. Genellikle bu ölçüt, bölgelendirmenin başarı göstergesi olarak davranan amaç fonksiyonunu optimize etmektir. Sonuçta bulanık bölgelere ayırma, bölücü matris U şeklinde ifade edilebilir.

$$U = [\mu_{ij}] \quad i = 1, \dots, c, \quad j = 1, \dots, n \quad (4.8)$$

μ_{ij} , x_j 'nin i'inci bölgeye aitlik derecesini açıklayan, 0-1 arasında sayısal bir değerdir. Yaygın olarak kullanılan bölgelere ayırma yöntemi ise Bezdek tarafından geliştirilmiş olan bulanık c-ortalama (Fuzzy C-Means - FCM) algoritmadır. [30] Bu algoritmanın amaç fonksiyonunun aldığı form şu şekildedir;

$$J(\mu_{ij}, v_k) = \sum_{i=1}^c \sum_{j=1}^n \mu_{ij}^m \|x_j - v_k\|^2, \quad m > 1 \quad (4.9)$$

Burada v_k k bölgesinin merkezini ifade ederken, m üyelik (ayırma) matrisinin bulanıklığının derecesini etkileyen üstel ağırlık olarak adlandırılır. Bu en aza indirme problemini çözmek için, (4.9) numaralı denklemdeki amaç fonksiyonunun ilk olarak v_i 'ye göre (sabit $\mu_{ij}, i = 1, \dots, c; j = 1, \dots, n$ için) ve ardından μ_{ij} 'ye göre (sabit $v_i, i = 1, \dots, c; j = 1, \dots, n$ için) türevi alınır.

(4.9) numaralı denkleme $\sum_{i=1}^c \mu_{ij} = 1, \forall j = 1, \dots, n$ şartı uygulanırsa;

$$v_i = \frac{1}{\sum_{j=1}^n \mu_{ij}^m} \sum_{j=1}^n \mu_{ij}^m x_j, \quad i = 1, \dots, c \quad (4.10)$$

$$\mu_{ij} = \frac{(1 / \|x_j - v_i\|^2)^{1/m-1}}{\sum_{k=1}^c (1 / \|x_j - v_k\|^2)^{1/m-1}}, \quad i = 1, \dots, c; \quad j = 1, \dots, n \quad (4.11)$$


(4.10) ve (4.11) numaralı denklemlerin oluşturduğu denklem takımı analitik olarak çözülemez. Bununla birlikte bulanık c ortalama bölgelere ayırma algoritması, verilmiş olan bir pozisyon ile başlayan amaç fonksiyonunun en küçük değerini hesap etmek için adım adım ilerleyen bir yaklaşım sağlar. Bölüm 3.4'te elde edilen nitelikler kullanılarak örnek kumaş görüntüleri bulanık c ortalama bölgelere ayırma algoritması ile sınıflandırılmaya çalışılmıştır. Sınıflandırma işleminden önce baskınlıklarının eşit hale getirilmesi amacıyla tüm nitelikler kendi aralarında 0-1 aralığına ölçeklendirilmişlerdir. Sınıflandırma sonucu her bir kumaş görüntüsü için beş farklı kümeye üyelik değerleri elde edilmiştir. Bu üyelik değerlerinden maksimum olan değer o örneğin ait olduğu sınıfın belirlenmesinde kullanılmıştır.

Her bir hata grubundan 20'şer adet olmak üzere toplam 100 adet örnek kullanılarak yapılan sınıflandırma sonucunda % 67 başarı sağlanmıştır. Çok hızlı çalışması bir avantaj olarak düşünülse de sınıflandırma başarısının yetersiz oluşu bu algoritmanın mevcut haliyle kullanılmasını mümkün kılmamaktadır.

4.2 Yapay Sinir Ağları


Yapay sinir ağları (YSA) makina görüş sisteminin önemli bir parçasını teşkil etmektedir. YSA hem görüntü işleme sistemleri hem de tekstil uygulamalarında geniş uygulama alanı bulmuştur [5,8,9,13,14]. Bu parça, makina görüş sisteminin karar verme ve tanımlama işlemini yapabilmesi için gereklidir.

Tek girişli basit bir nöron Şekil 4.1'de görülmektedir. Buna göre nöron basit doğrusal bir matematiksel operatör olarak düşünülebilir.



Şekil 4.1 : Basit nöron modeli


Bir skaler değer olan p burada başka bir skaler olan ağırlık ile (w), çarpılır ve toplama ünitesine gönderilir. Diğer giriş yanlılık terimi olarak bilinen değerle (b) çarpılır ve yine toplama ünitesine verilir. Toplama ünitesinin çıkışı $wp+b$ şeklindedir ve net giriş olarak isimlendirilir. Net giriş f ile gösterilen etkinlik fonksiyonuna iletilir ve sonuçta yine skaler bir değer olan a üretilir. Eğer bu matematiksel verilerle biyolojik sistemdeki nöronlar arasında bir benzerlik kurmak gerekirse; w olarak alınan ağırlıklar nöronlar arasındaki sinapsların kuvvetini, toplama ünitesi ve etkinlik fonksiyonu nöronun gövdesini, çıkış (a) ise aksonlardaki çıkış sinyalini temsil etmektedir. Nöronlardaki etkinlik fonksiyonları çok çeşitli yapılarda olabilirler. En çok kullanılan etkinlik fonksiyonları Şekil 4.2’de verilmiştir.



Şekil 4.2 : Değişik etkinlik fonksiyonları

Uygulamamızdaki problem bir sınıflandırma problemidir ve sınıflandırma problemlerinin çözümünde en sık kullanılan ağ yapısı çok katmanlı ileri beslemeli ağ yapısıdır.

Çok katmanlı ileri beslemeli ağ yapıları girişlerin ve çıkışların sahip olduğu lineer olmayan ilişkiyi ağırlık ve yanlılık terimlerini belli bir öğrenme kuralı ve performans indeksini kullanarak ayarlayabilmekte ve hedef çıkışları sağlayabilmektedirler. Şekil 4.3’de iki ara katmanlı ileri beslemeli bir ağ yapısı görülmektedir.



Şekil 4.3 : İki ara katmanlı ileri beslemeli YSA yapısı

Şekil 4.3'den de anlaşılacağı üzere ilk katman girişlerin beslendiği katmandır (giriş), her bir katmanın çıkışları sonraki katman için girişleri oluşturur. Her bir giriş değeri uygun ağırlıklara çarpılarak etkinlik fonksiyonundan geçtikten sonra ara katmandaki tüm nöronlarca işleme alınır. Bu işlem tüm katmanlar boyunca ilerler. Burada amaçlanan, giriş vektörleri ile belirlenmiş çıkış vektörleri arasındaki lineer olmayan ilişkiyi temsil edecek şekilde w_i ve b_i değerlerinin belli bir öğrenme ve performans kuralı uyarınca değiştirilmesi ve performans kriteri sağlandığında öğrenime son verilmesidir. Öğrenime son verildikten sonra YSA test girişleri ile doğru sınıflandırma yapıp yapmadığının kontrol edilebilmesi için beslenir ve çıkış olarak verilen değerler doğru sınıflandırılmışsa belli bir yüzde ile ağ yapısının başarısı ifade edilir.

Geri Yayılım algoritması en genel haliyle aşağıdaki gibi çalışır;

- Tüm ağırlıklar ve yanlılık terimi değerleri ilk adım için belli aralıklarda rastgele atanır.
- Girişler YSA'ya ileri yönde beslenerek sinir ağının bu girişlere karşılık verdiği çıkış hesaplanır. Çıkış katmanındaki nöronlar için hata değeri sinir ağının verdiği çıkış değerleri kullanılarak aşağıdaki gibi hesaplanır. Hata terimi geriye doğru beslenerek daha önceki tabakalardaki nöronlar için delta değerleri hesaplanır.

$$\delta_i = (d_i - o_i) \partial f(I_i) \quad (4.12)$$

burada ;

δ_i : Geri yayılım hata terimi

d_i : Gerçek çıkış değeri

o_i : YSA çıkışı

∂f : Etkinlik fonksiyonunun birinci türevi

- Ara katmanlardaki nöronlar için ;

$$\delta_j = \left[\sum_{i=1}^m \delta_i w_{ij} \right] \partial f(I_j) \quad (4.13)$$

eşitliği kullanılır.

- Ağırlıklar aşağıdaki gibi güncellenir ;

$$w_{ij}^{k+1} = w_{ij}^k + \Delta w_{ij} \quad (4.14)$$

$$\Delta w_{ij} = \eta \delta_j I_k$$

burada η ; öğrenme oranı ve I_k ; j indisli nöronun girişidir.


Toplam hatayı en küçültmek için her iterasyonda ağırlık ve yanlılık terimi güncellemesi yapılır. Ağırlık güncellenmesi için genelleştirilmiş kural aşağıdaki gibidir ;

$$\Delta w_{ij} = -\eta \frac{\partial E}{\partial w_{ij}} \quad (4.15)$$

burada E her iterasyondaki toplam hatayı temsil etmektedir. η değerinin büyük alınması öğrenmeyi hızlandırırsa da çıkışta büyük hatalar oluşmasına sebep olur. Küçük alınan η değeri ise öğrenmenin çok uzun sürmesine sebep olur.

Bu çalışmada yapılması gereken sınıflandırma işleminde toplam 7 adet nitelik kullanılacağından YSA 7 girişli olacaktır. Çıkış ise hatanın dahil olduğu grubu temsil edecek tek bir sayıdır ve YSA'nın çıkış katmanında tek bir nöron bulunacaktır.

Yapılacak sınıflandırma lineer ayrıştırılabilir olmadığından tek katmanlı YSA'lar yeterli doğrulukta sınıflandırma yapamamıştır. Bu sebeple farklı sayılarda ara katmanlara sahip YSA'lar denenmiştir. Literatürde de bu tip sınıflandırma işlemlerinde genellikle iki ara katmanlı YSA'ların yeterli performans sağladığı görülmüştür.



Şekil 4.4 : Çalışmada kullanılan YSA yapısı

Hazırlanan nitelik vektöründe 8 adet sayı bulunmaktadır. Bu sayılardan ilk 7 adedi o örneğe ait nitelikler, son sayı da o örneğin sahip olduğu hatayı temsil eden sayıdır. Hatalı ve hatasız örnek sınıfları aşağıdaki gibi belirlenmiştir.

Tablo 4.1 : Hataların ait oldukları sınıfları temsil eden numaralar

Hata Türü	Numarası
Hatasız	1
Boyuna Hatalı	2
Enine Hatalı	3
Yağ Lekeli	4
Delik	5

Nitelikler YSA'lara verilmeden önce baskınlıklarının eşit hale getirilmesi ve nöronların doymasının önlenmesi amacı ile kendi aralarında 0-1 arasına ölçeklendirilmişlerdir.

Çalışmada her hata grubundan 20'ser adet olmak üzere toplam 100 adet örnek kullanılmıştır. Tüm YSA denemelerinde her 20 örnekten rastgele 15'i YSA'ların eğitiminde kalan 5'i denemede kullanılmıştır.

Hazırlanan nitelikler farklı ara katman ve nöron sayılarına sahip YSA'lara beslenerek en iyi sonucu veren YSA bulunmuştur.

İki ara katmanlı ve bu katmanlarında altışar adet nöron bulunan ve Resilient Back Propagation öğrenme algoritmasına göre eğitilen YSA çalışmada kullanılan örnekleri % 100 doğrulukla sınıflandırabilmiştir.

Resilient Back Propagation (RBP) öğrenme algoritmasının en büyük avantajı ağırlıkların güncellenmesi sırasında hatanın türevinin yerine bu türevin işaretini kullanarak hatayı minimum yapacak ağırlık değerlerinden fazla uzaklaşmamasıdır. Bu yaklaşım sinir ağının performansını iyileştirmektedir. Ağırlık değişimlerinin salınım yapmasını engellemek üzere değişim miktarı önceki iterasyonlardaki değişim miktarları göz önünde bulundurularak aşağıdaki gibi belirlenir [31].

$$\Delta w_{ij}^k = -\Delta_{ij}^k * \text{sign}\left(\left(\frac{\partial E}{\partial w_{ij}}\right)^k\right) \quad (4.16)$$

$$\Delta_{ij}^k = \begin{cases} 1.2 * \Delta_{ij}^{k-1} & \text{eger} \quad \left(\frac{\partial E}{\partial w_{ij}}\right)^k \cdot \left(\frac{\partial E}{\partial w_{ij}}\right)^{k-1} > 0 \\ 0.5 * \Delta_{ij}^{k-1} & \text{eger} \quad \left(\frac{\partial E}{\partial w_{ij}}\right)^k \cdot \left(\frac{\partial E}{\partial w_{ij}}\right)^{k-1} < 0 \end{cases} \quad (4.17)$$

Tablo 4.2'de farklı deneme grupları için YSA sonuçları verilmiştir.

Tablo 4.2 : YSA deneme sonuçları


GRUP 1		GRUP 2		GRUP 3		GRUP 4	
Hata No	YSA sonucu	Hata No	YSA sonucu	Hata No	YSA sonucu	Hata No	YSA sonucu
1	1	1	1	2	2	5	5
3	3	5	5	5	5	4	4
4	4	4	4	4	4	3	3
2	2	3	3	3	3	1	1
5	5	2	2	1	1	2	2
3	3	2	2	3	3	2	2
2	2	5	5	4	4	4	4
4	4	4	4	1	1	5	5
1	1	3	3	2	2	1	1
5	5	1	1	5	5	3	3

5. YAPAY GÖRME

5.1 Yapay Görme Sistemleri

Yapay görme sistemlerinin esin kaynağı biyolojik sistemlerdeki görme mekanizmasıdır denilebilir [25]. Bu sistemler insan görüşünden esinlenerek tasarlandıkları ve bazı durumlarda insan görüşünün kalitesinden uzak kaldıkları halde insan görüşünün yetersiz kaldığı bir çok uygulamada kontrol ve gözlem amaçlı kullanılmaktadır. Ancak hala insan görüş sisteminin bazı özelliklerini taklit edebilmekten uzaktırlar ve onun kadar hızlı değildirler. Bu hız farkını ortadan kaldırmak için bir yandan hızlı algoritmalar içeren yazılımlar oluşturulmaya çalışılırken diğer yandan seçilen donanımın işlem süreleri en düşük olanlar olması gerekmektedir.

İnsan görüş sistemini daha iyi anlamak için gözün anatomik yapısına bakmak gereklidir.



Şekil 5.1 : İnsan gözünün anatomik yapısı

İnsan gözünde mevcut olan anatomik birimlerin fonksiyonları yapay görme sisteminde birer karşılık bulurlar. Gözbebeği iris sayesinde ışığın şiddetine göre ayarlanabilir objektif gibi davranırken, mercek görüntüyü algılayıcı hücrelerin olduğu retina üzerine düşürmek için adapte olup görüntüyü sarı lekeye odaklar. Kamera sistemlerinde de bu tür odaklama ve net görüntü eldesi için ayarlar bulunmaktadır. Retina üzerinde oluşan görüntü optik sinirler tarafından işlenip

anlamlandırılması için beyne iletilir. Yapay görme sistemlerinde ise elde edilen görüntü bir ADC kartıyla dijitalleştirilip işlemciye (PC) iletilir.

İnsanların görüntüyü algılaması ve tanımlaması için görüntü beyinde işlenmektedir, burada devreye kortekste bulunan işlemci nöronlar girmektedir. Yapay görme sistemlerinde ise anlamlandırma ve tanımlama kısımları için çeşitli dönüşümler kullanılır (Fourier, Wavelet, FIR). Bu dönüşümler sonucu elde edilen sayısal veriler yapay sinir ağlarına beslenerek görüntüdeki ayrıntılar tanımlanabilir. Böylece insanın görme ve görüntü tanımlama özelliği taklit edilmiş olur.

5.2 Kameralar

5.2.1 Görüntü Elde Etme

Görüntülerin sürekli olarak gösterilmesi, bir resmin sonlu sayıda bitler tarafından temsil edildiği bir bilgisayar görüntüleme sisteminin ayrık ve sayısal gösterimi ile karşılaştırılabilir [24].


Bir resmin fiziksel ve sürekli ortamdan ayrık alana dönüştürülmesi 4 işlevsel birimden oluşur ;

1. Algılama; Parlaklığı elektriksel büyüklüğe dönüştürür (yük veya voltaj).
2. Tarama; 2-boyutlu uzay alanını 1-boyutlu zaman alanına dönüştürür.
3. Uzaysal örnekleme; Sürekli uzay alanını ayrık uzay alanına dönüştürür.
4. Analogdan dijitale çevirme; Elektriksel büyüklüğü sayısal karşılıklarına dönüştürür (tam sayılar).


Günümüzde görüntü elde etme sistemleri daha çok CCD'lere dayanır.

5.2.2 CCD Kameralar

CCD aleti (charge-coupled device: yük bağlanmış cihaz) bir grup yük-depolama birimi, iletim mekanizması ve bir çıkış cihazından oluşur. Yük depolama elemanları ya çizgisel olarak dizilirler ya da bir matris oluşturacak şekilde bir araya gelirler. Örnek CCD aletleri Şekil 5.2 ve 5.3'te görülmektedir [24].



Şekil 5.2 : Çizgi tarama CCD



Şekil 5.3 : Alan tarama CCD

Her eleman, üzerine gelen ışık enerjisini bir elektrik yüküne çevirebilir. Elemanların altındaki bir elektronik gönderme mekanizması, bu yükleri cihazın çıkış kapısına yönlendirir.

Bir çizgi tarama CCD'sinin işleme yapısı şu şekildedir;

Belirli bir anda bütün depolama elemanlarındaki elektrik yükleri sıfır olsun. Bu andan itibaren herhangi bir elemanın üstüne gelen parlak ışık, o elemanın yükünü, akıyla doğru orantılı olarak artırır. Bu toplama süresinin sonunda, her bir elemandaki yük analog değişim kaydına gönderilir. Bu işlem bütün elemanlar için eşzamanlıdır. Devamında zamanlayıcının her çevriminde yükler aynı anda sağa doğru kayar. Bu sayede en sağdaki yük miktarı çıkış devresine itilip, çıkış kapısındaki gerilim değerine dönüştürülür. Sonuç olarak, birbirini takip eden saat çevrimlerinde çıkış gerilimi sıralı elemanların parlaklık enerjileriyle orantılı olur.

Çizgi tarama CCD'lerinin, resim düzleminin 2 boyutlu bir taramasını elde edebilmek için cihazın veya sahnenin doğrusal hareketine gereksinimleri vardır. Kalite kontrol

uygulamalarında ürünler çoğunlukla bir konveyör tarafından taşınır. Eğer konveyörün hareketi sabitse, CCD'nin sırası konveyörün hareket yönüne dik olacak şekilde ayarlandıktan sonra ürünlerin 2 boyutlu resimleri elde edilebilir. Aynı teknik uydu görüntüleme sistemlerinde de kullanılır. Optik karakter okuyucularında kullanılan resim tarayıcıları da aynı prensibe göre çalışır. Resim, kağıdı tarayıcıdan geçirmekle elde edilir. Elde tutulan tarayıcılarda ise, CCD kağıt üzerinde hareket ettirilir. Çizgi tarama CCD'lerinin avantajı çözünürlükleridir. Doğrusal bir dizi 4000 adet elemanı rahatlıkla içerebilir, bu şekilde 4000x4000 birimlik bir resim verebilir. Bir alan CCD'si tipik olarak 600x600 eleman içerir. Çizgi tarama CCD'lerin dezavantajı tek bir resmin elde edilmesinin, alan CCD ile karşılaştırıldığında çok uzun sürmesidir. Bu nedenle video uygulamalarında alan CCD tercih edilir.

Alan CCD'si daha karmaşık bir elektronik taşıma mekanizmasına sahiptir. Bu mekanizma, mekanik bir tarama olmadan tam bir resmin elde edilmesini sağlar. Yük depolama elemanları bir yığın değişim kayıtlarının paralel girişlerine bağlantılıdır (çerçeve depolama). Bu değişim kayıtlarının çıkışları, paralel yığına dik olarak yerleşmiş bulunan bir diğer değişim kaydına bağlıdır. Bir görüntü elde etme çevrimi iki aşamadan oluşur ;

Toplama devresi: Bu süre içerisinde her elemana gelen ışık akısı elektriksel yüke çevrilir. Bu işlem sonunda yükler çerçeve deposuna yüklenir.


Yük iletim devresi: Çerçeve deposundaki yükler dikey yönde değiştirilir, böylece yatay değişim kaydı bölgesini bir satırdan aldığı bilgilerle yükler. Daha sonra yatay değişim kaydı yüksek hızla okunur. Bu işlem çerçeve deposundaki bütün satırlar okununcaya kadar tekrarlanır. Normalde bu iki aşama birbirini tekrar eder. İletim devresinin başlangıcında, bir sonraki resmin toplama devresi başlamış olur.

Çalışma kapsamında geliştirilen algoritmalar iki boyutlu resimlere ihtiyaç duyduğundan alan tarama CCD kameraların kullanılması gerekmektedir.

5.3 Aydınlatma


Başlangıçta nesnenin önden mi yoksa arkadan mı aydınlatılacağına karar verilmelidir. Saydam olmayan cisimler için, örneğin cismin silueti çıkartılacaksa, arkadan aydınlatma daha avantajlıdır. Burada dezavantaj, yüzeylerin yansıtma dağılımlarının hesaplanamamasıdır. Bu da bilgi kaybına yol açar [24].

Aydınlatılan nesne yüzeyinin yansıtma dağılımı resimdeki tanımlayıcı özelliklerden biri ise önden aydınlatma yapısıdır. Malzeme yüzeyindeki hata, çizik ve diğer hasarların tespit edilmesi gibi uygulamaları bulunmaktadır. Arkadan ve önden aydınlatma şematik olarak Şekil 5.4’te gösterilmiştir.



Şekil 5.4 : Önden ve arkadan aydınlatma

Bir diğer çözüm de yönlendirilmiş veya dağınık aydınlatma kullanmaktır [24]. (Şekil 5.5)




Şekil 5.5 : Dağınık ve yönlendirilmiş aydınlatma

Genellikle iki yöntemin birleşimi kullanılır, bu nedenle bu tip aydınlatmaların maliyeti düşüktür. Bir yayıcı, ışığı arkadan öne doğru bütün yönlerde sabit ışıma yoluyla dağıtan saydam bir yüzeydir. Bazı uygulamalarda dağınık aydınlatma avantajlıdır çünkü gölge oluşmaz. Diğer uygulamalarda yönlendirilmiş aydınlatma tercih edilir. Bu teknik, bir toplayıcı ile elde edilir. Kullanım amacı paralel ışık demeti elde etmektir. Sonuçta, açıkça belirlenmiş gölgelerden oluşan bir ortam meydana gelir.

Koyu alan aydınlatması yönlendirilmiş aydınlatmanın özel bir uygulamasıdır. Ayna veya küresel bir yüzeye çarpan ışık, gelen ışının gelme açısıyla yüzeyden yansır. Kameraya gelen tek ışın dağınık yansıyan ışık ışınıdır. Bu yöntem hataların tespit edilmesinde kullanılmaya çok uygundur.

Açık alan aydınlatması da koyu alan aydınlatması ilkesine göre çalışır. Sadece kamera, yansıyan ışının yolu üzerine yerleştirilmiştir. Bu yöntem de yüzey hasar belirmelerinde kullanılır. Bu iki aydınlatma biçimi de aşağıdaki şekilde gösterilmiştir.



Şekil 5.6 : Koyu alan ve açık alan aydınlatması

Örme kumaş hatalarının tespitinde ve sınıflandırılmasında kullanılacak sistemin aydınlatılmasında yöntem olarak önden ve dağınık aydınlatmanın kullanılmasının uygun olacağına karar verilmiştir.

6. SONUÇLAR VE TARTIŞMA

6.1 Yöntem ve Sonuç

Bu tez çalışmasında örme kumaşların üretimi esnasında ortaya çıkan çeşitli hataların görüntü işleme yöntemleriyle otomatik olarak tespiti ve sınıflandırılması üzerinde çalışılmıştır. Ayrıca bu işin gerçek zamanlı olarak yapılabilirliği de araştırılmıştır.

Örme kumaş üretiminde hâlihazırda insanlar tarafından yapılmakta olan yorucu ve zaman alan hata tespiti işleminin bir görüntü işleme sistemi kullanılarak gerçek zamanlı olarak yapılması üretim hızının artması ve hataların anında tespiti ile tekrarlarının önlenmesi gibi büyük avantajlar getirecektir.

Öncelikle, çalışmada kullanılacak örnek kumaş resimlerine histogram eşitleme ve orta filtreleme ön görüntü işlemleri uygulanmıştır. Histogram eşitleme ile kumaş görüntülerindeki ayrıntılar belirgin hale getirilmiş ve aydınlatma farklarının etkisi ortadan kaldırılmıştır. Orta filtreleme ile de kumaş görüntülerindeki muhtemel gürültüler giderilmiştir.

Kumaşın periyodik yapısı göz önüne alınarak sınıflandırmada kullanılacak nitelik çıkarımında Fourier Analizi'nden faydalanılmıştır. Tüm örnekler için iki boyutlu güç spektrumları elde edildikten sonra sıra ve may doğrultuları tespit edilerek bu doğrultulardaki tek boyutlu güç spektrumları elde edilmiştir. Bu spektrumlar incelenerek hatanın hangi gruba dahil edileceğinin belirlenebilmesi için yeterince ayırt edici olabilecek nitelikler belirlenmeye çalışılmıştır. Literatürdeki çalışmalarda genellikle tek boyutlu güç spektrumlarından elde edilen tepe büyüklüklerine dayanan nitelikler kullanılmıştır [9,13,14,17]. Bu çalışmada da öncelikle tepe büyüklüklerine dayanan nitelikler elde edilmeye çalışılmıştır. Yapılan araştırmalardan sonra sıra doğrultusundaki tek boyutlu güç spektrumlarından dört hata türü için ayırt edici nitelikler çıkarılmıştır. Ancak delik hatası olan örnekleri ayırt etmede kullanılabilecek nitelikler bulunamamıştır. Bu yüzden iki boyutlu güç spektrumundan delik kumaşlar için nitelik teşkil edebilecek büyüklükler bulunmaya çalışılmıştır. Bu amaçla Fourier dönüşümlerine basit filtreler uygulanarak istenilen

bölgeler seçilmiş ve ters Fourier dönüşümü uygulanarak bu bölgelerdeki frekansların kumaş resminde temsil ettikleri özellikler anlaşılmaya çalışılmıştır.

Değişik büyüklükte filtreler kullanılarak yapılan araştırmalardan sonra, iki boyutlu güç spektrumunda kumaşın genel yapısına ait bilgilerin bulunduğu alçak frekans bölgesinden bant geçiren filtre ile seçilen bazı bölgelerdeki güç değerlerinin toplamalarının delik hatası olan örnekler için ayırt edici olduğu gözlemlenmiştir.

İki boyutlu güç spektrumundan iki adet ve tek boyutlu güç spektrumundan beş adet olmak üzere toplam yedi adet nitelik sınıflandırma işleminde kullanılmak üzere seçilmiştir.

Sınıflandırma işlemi için öncelikle Bulanık Bölgelere Ayırma ve Yapay Sinir Ağları denenmiş, daha iyi sonuç vermesi sebebiyle yapay sinir ağları seçilmiştir. Yapılması gereken sınıflandırma işlemi doğrusal ayrıştırılabilir olmadığından tek katmanlı sinir ağları yeterli doğrulukta sınıflandırma yapamamıştır. Bu sebeple farklı ara katman sayılarına sahip YSA'lar denenerek en iyi sonucu veren YSA bulunmuştur. Literatürde genelde bu tip sınıflandırma işlemlerinde iki ara katmanlı YSA'ların yeterli performans sağladığı görülmüştür.

Sonuçta iki ara katmanlı ve bu katmanlarında altışar adet nöron bulunan ve Resilient Back Propagation öğrenme algoritmasına göre eğitilen YSA çalışmada kullanılan tüm örnekleri % 100 doğrulukla sınıflandırmıştır.

Bu çalışmada geliştirilen algoritmanın değişik özellikte (değişik iplik numarası, ilmek sıklığı, desen) kumaşlar için performansının araştırılması gerekmektedir.


Çalışmada ayrıca gerçek bir sistemin oluşturulması için gerekli kameralar ve aydınlatma konuları da ele alınmıştır.

6.2 Gerçek Zamanda Uygulama

Bir yuvarlak örme makinasının bir tur dönmesiyle makinadaki bobin sayısı kadar sıra örülmüş olur. Şekil 6.1'de bir yuvarlak örme makinası görülmektedir. 90 iplik besleme ünitesi olan bir yuvarlak örme makinasında bir tam devirde 90 sıra kumaş örülmektedir. 20 devir/dakika hızla çalışan bu makina 1 dakikada 1800 sıra kumaş örülmüş olur. Bir sıranın genişliği 1 mm olduğuna göre, örme makinasından saniyede

3 cm kumaş çıkmaktadır. 1 metre çapındaki kumaş silindirin çevresi 314 cm'dir. Buna göre saniyede 942 cm² kumaşın kontrol edilmesi gerekmektedir.

Matlab araç kutuları kullanan gelişmiş bir bilgisayarla saniyede en fazla 4 cm² kumaş kontrol edilebilmektedir. Bu durum sözü geçen kontrol işleminin bilgisayar ve Matlab kullanılması ile gerçek zamanlı olarak yapılamayacağı anlamına gelmektedir.



Şekil 6.1 : Yuvarlak örme makinası ve temel kısımları

Bu tip endüstriyel uygulamalarda kullanılmak üzere otomasyon firmalarının “Makina Görüşü” (Machine Vision) başlığı altında donanım ve yazılımın birlikte sunulduğu ürünleri mevcuttur. Örnek olarak, aynı görüntü için bir kenar belirleme (edge detection) işlemi Matlab kullanılarak 1,5 saniyede yapılabiliyor iken National Instruments firmasının LabVIEW kullanan donanımı ile 7,5 milisaniyede yapılmaktadır (Matlab'ın 1/200 katı).



Şekil 6.2 : NI firmasının görüntü yakalama kartı ve Kompakt Makine Görüşü sistemi

Örnek kenar belirleme uygulaması için elde edilen sonuçlara bakılarak sözü geçen donanımdan birden fazlasının aynı anda çalışmasıyla hata tespiti ve sınıflandırılması işleminin gerçek zamanlı olarak yapılabileceği anlaşılmıştır.

KAYNAKLAR

- [1] **Schael, M. and Burkhardt, H.**, 2000. Automatic Detection of Errors on Textures Using Invariant Grey Scale Features and Polynomial Classifiers, *Texture Analysis in Machine Vision*, Ed. Pietikäinen M. K., World Scientific, London, s. 219-229.
- [2] **Abouelela, A. et.al.**, 2004. Automated vision system for localizing structural defects in textile fabrics, *Pattern Recognition*, Makale basım aşamasında.
- [3] **Harwood, R.J., Norton-Wayne, L. and Campbell, R.A.**, 1996. Inspecting The Back of Woven Carpets For Pattern Distortion, *The Journal of Textile Institute*, **1**, 381-389.
- [4] **Kang, T.J., Choi, S.H. and Kim, S.M.**, 2001. Automatic Structure Analysis and Objective Evaluation of Woven Fabric Using Image Analysis, *Textile Research Journal*, **71**, 261-270.
- [5] **Sette, S., Boullart, L. and Kiekens, P.** , 1995. Self-Organizing Neural Nets: A New Approach to Quality in Textiles, *Textile Research Journal*, **65**, 196-202.
- [6] **Kumar, A. and Pang, K.H.**, 2002. Defect Detection in Textured Materials Using Optimized Filters, *IEEE Transactions On Systems, Man and Cybernetics*, **32**, 553-570.
- [7] **Zhang, Y.F.**, 1995. Fabric Defect Detection and Classification Using Image Analysis, *Textile Research Journal*, **65**, 1-9.
- [8] **Kumar, A.**, 2003. Neural Network Based Detection of Local Textile Defects, *Pattern Recognition*, **36**, 1645 -1659.
- [9] **Chen, P. et.al.**, 1998. Classifying Textile Faults with a Back Propagation Network Using Power Spectra, *Textile Research Journal*, **68**, 121-126.
- [10] **Xu, B.**, 1996. Identifying Fabric Structures with Fast Fourier Transform Techniques, *Textile Research Journal*, **66**, 496-506.
- [11] **Ravandi, S.A.H. and Toriumi, K.**, 1995. Fourier Transform Analysis of Plain Weave Fabric Appearance, *Textile Research Journal* , **65**, 676-683.
- [12] **Chan, C. and Pang, K.H.**, 2000. Fabric Defect Detection by Fourier Analysis, *IEEE Transactions On Industry Applications*, **36**, 1267-1276.
- [13] **Çalı, S. et.al.**, 2004. Fault Detection and Classification Using Fourier Analysis and Neural Networks, *The 9th Mechatronics Forum*, Ankara, 30 Ağustos-1 Eylül, s. 445-448.

- [14] **Aydın, A.E., Oral, Ö. ve Çelik,Ö.**, 2004. Örme Kumaşlardaki İmalat Hatalarının Belirlenmesi ve Sınıflandırılması İçin Bir Yapay Görüş Sistemi Oluşturulması, *Lisans Tezi*, İ.T.Ü. Makina Fakültesi, İstanbul.
- [15] **Wen, C.Y., et.al.**, 2001. Defect Segmentation of Texture Images with Wavelet Transform and a Co-occurrence Matrix, *Textile Research Journal*, **71**, 743- 749.
- [16] **Zhi, X.Y., Pang, K.H. and Yung, N.H.C.**, 2001. Fabric Defect Detection Using Adaptive Wavelet, *Acoustics, Speech and Signal Processing, ICASSP'01*, Salt Lake City, 7-11 Mayıs, s. 3697 - 3700.
- [17] **Boyraz, P. et.al.**, 2004. Fault Detection in Knitted Structures Using Wavelet Analysis and Optimized Filter Design, *The 9th Mechatronics Forum*, Ankara, 30 Ağustos-1 Eylül, s. 449-455.
- [18] **Kumar, A. and Pang, K.H.**, 2000. Fabric Defect Segmentation Using Multichannel Blob Detectors, *Optical Engineering*, **39**, 3176-3190.
- [19] **Ngan, H.Y.T. e.al.**, 2004. Wavelet Based Methods On Patterned Fabric Defect Detection, *Pattern Recognition*, **38**, 559-576.
- [20] **Dorrity, J.L., Vachtsevanos, G. and Jasper, W.**, 1995. G94-2: Real-Time Fabric Defect Detection And Control In Weaving Processes, *National Textile Center Annual Report*, North Carolina.
- [21] **Kumar, A. and Pang, K.H.**, 2000. Defect detection in textured materials Using Gabor filters, *Proc. 35th IAS Annual Meeting, Rome, Italy, Oct. 8-12*.
- [22] **Campbell, J.G. et.al.**,1999. Model-Based Methods for Textile Fault Detection, *International Journal of Imaging Systems Technology*, **10**, 339-346.
- [23] **Stolpmann, H. and Dooley, L. S.**, 2000. A Texture Classification System Using Statistical and Soft-Computing Methods, *Texture Analysis in Machine Vision*, Ed. Pietikäinen M. K., World Scientific, London, s.53-67.
- [24] **Heijden, F.**, 1994. Image Based Measurement Systems, John Wiley & Sons, West Sussex.
- [25] **Gonzalez, R.C. and Woods, R.E.**, 1992. Digital Image Processing, Addison Wesley, Massachusetts.
- [26] **Banks, S.P.**, 1991. Signal Processing, Image Processing and Pattern Recognition, Prentice-Hall, New York.
- [27] **Höppner, F., Klawonn, F., Kruse, R., Runkler, T.**, 1999. Fuzzy Cluster Analysis, John Wiley & Sons, West Sussex.
- [28] **Castleman, K.R.**, 1996. Digital Image Processing, Prentice Hall, New Jersey.
- [29] **Kulkarni, A. D.**, 2001. Computer Vision and Fuzzy-Neural Systems, Prentice Hall PTR, Upper Saddle River, New Jersey.

- [30] **Bezdek, J. C., Keller, J., Krisnapuram, R., Pal, N. R.,** 1999. Fuzzy Models and Algorithms for Pattern Recognition and Image Processing, Kluwer Academic Publishers, Boston.
- [31] **Hannan, J.M., Bishop, J.M.,** 1997. A Comparison of Fast Training Algorithms Over Two Real Problems, *5th International Artificial Neural Networks Conference*, Cambridge, 7-9 Temmuz, s. 1-6.

ÖZGEÇMİŞ

1980 yılında İstanbul’da doğdum. İlkokul, ortaokul ve lise öğrenimimi İstanbul’un çeşitli semtlerinde tamamladım. 1998-2002 yılları arasında Yıldız Teknik Üniversitesi’nde Makina Mühendisliği eğitimi aldım. 2003 yılından bu yana İstanbul Teknik Üniversitesi Mekatronik Mühendisliği bölümünde yüksek lisans eğitimime devam etmekteyim.