

**TETRA BRİK ASEPTİK KARTONLARDAKİ
ŞERİT DİKİŞLERİNİN
SAYISAL GÖRÜNTÜLEME TABANLI
KALİTE KONTROLÜ**

Kemal ADEM

**Yüksek Lisans Tezi
Mekatronik Mühendisliği Anabilim Dalı
Yrd. Doç. Dr. Mahmut HEKİM
İkinci Danışman: Yrd. Doç. Dr. Umut ORHAN
2013**

Her hakkı saklıdır

T.C.
GAZİOSMANPAŞA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
MEKATRONİK ANABİLİM DALI

Y.LİSANS TEZİ

TETRA BRİK ASEPTİK KARTONLARDAKİ
ŞERİT DİKİŞLERİNİN
SAYISAL GÖRÜNTÜLEME TABANLI KALİTE KONTROLÜ

Kemal Adem

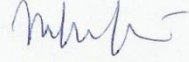
TOKAT

2013


Her hakkı saklıdır

Yrd. Doç. Dr. Mahmut HEKİM danışmanlığında, Kemal ADEM tarafından hazırlanan bu çalışma, 17/06/2013 tarihinde aşağıdaki jüri tarafından oy birliği ile Mekatronik Mühendisliği Anabilim Dalı'nda Yüksek Lisans tezi olarak kabul edilmiştir.


Başkan : Yrd. Doç. Dr. Mahmut HEKİM

İmza : 

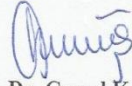
Üye : Yrd. Doç. Dr. Hakan YAVUZ

İmza : 

Üye : Yrd. Doç. Dr. Cemal KAYA

İmza : 

Yukarıdaki sonucu onaylarım



Yrd. Doç. Dr. Cemal KAYA

Enstitü Müdür V.

20/06/2013

TEZ BEYANI

Tez yazım kurallarına uygun olarak hazırlanan bu tezin yazılmasında bilimsel ahlak kurallarına uyulduđunu, başkalarının eserlerinden yararlanılması durumunda bilimsel normlara uygun olarak atıfta bulunulduđunu, tezin içerdiđi yenilik ve sonuçların başka bir yerden alınmadıđını, kullanılan verilerde herhangi bir tahrifat yapılmadıđını, tezin herhangi bir kısmının bu üniversite veya başka bir üniversitedeki başka bir tez çalışması olarak sunulmadıđını beyan ederim.

Kemal ADEM

ÖZET

Yüksek Lisans Tezi

TETRA BRİK ASEPTİK KARTONLARDAKİ ŞERİT DİKİŞLERİN SAYISAL GÖRÜNTÜLEME TABANLI KALİTE KONTROLÜ

Kemal ADEM

Gaziosmanpaşa Üniversitesi
Fen Bilimleri Enstitüsü
Mekatronik Mühendisliği Anabilim Dalı

Danışman: Yrd. Doç. Dr. Mahmut HEKİM

Sıvı gıda imalatının gerçekleştirildiği işletmelerde Tetra Brik Aseptik karton paketlerdeki şerit dikişlerin kalite kontrol işlemi uzman işçiler tarafından geleneksel şekillerde yapılmaktadır. Bu denetim süreci insana dayalı olduğu için birçok dezavantaja sahiptir. Bu çalışmada, çeşitli görüntü işleme teknikleri kullanılarak karton paketlerdeki şerit dikişlerin kalite kontrolünün bilgisayar destekli bir sistem aracılığıyla yapılabilmesi amaçlanmıştır. Piksel bazlı görüntü bölütleme, kenar tespit etme yöntemleri ile doğrusal regresyon, çok katmanlı sinir ağı, destek vektör makinesi ve genelleştirilmiş regresyon sinir ağı modelleri bir arada kullanılmıştır. DİMES firmasından sağlanan karton paketlerin görüntüleri üzerinde test işlemleri gerçekleştirilmiştir. Önerilen yöntemlerin doğru sınıflandırma oranları tatmin edici düzeyde bulunmuş ve gelecek çalışmalar için önerilerde bulunulmuştur.

2013, 64 sayfa

Anahtar Kelimeler: Tetra brik aseptik karton paket, görüntü işleme, piksel bazlı görüntü bölütleme, kenar belirleme, kalite kontrolü.

ABSTRACT

M.Sc. Thesis

DIGITAL IMAGE PROCESSING BASED QUALITY CONTROL OF SEAMS ON TETRA BRIK ASEPTIC CARTONS

Kemal ADEM

Gaziosmanpaşa University
Graduate School of Natural and Applied Sciences
Department of Mechatronic Engineering

Supervisor: Asst. Prof. Dr. Mahmut HEKİM

The quality control process of the seal seams at Tetra Brik Aseptic carton package is traditionally performed by specialized workers in liquid food manufacturing businesses. Because it is based on the people, this control process has many drawbacks. In this study, we focused on performing the quality control of seal seams on carton package by using computer-aided system. Pixel-based image segmentation, edge detection methods, linear regression, multi layer neural network, support vector machine and general regression neural network methods were used together, and this quality control was tested on the images of carton packages provided by DIMES company. We showed that the proposed method resulted in satisfactory classification accuracy rates and recommendations are made for future studies.

2013, 64 pages

Keywords: Tetra Brik Aseptic carton package, image processing, pixel-based image segmentation, edge detection, quality control.

TEŐEKKÜR

Yüksek lisans çalışmam boyunca, her türlü konuda yardımlarını esirgemeyen, değerli fikirleriyle çalışmama yön veren kıymetli hocalarım Sayın Yrd.Doç.Dr. Mahmut HEKİM ve Sayın Yrd.Doç.Dr. Umut ORHAN'a sonsuz teşekkürler. Ayrıca çalışmamda kullandığım verilerin toplanması sırasında yardımcı olan DİMES firması çalışanları Koray AYBEK, Özcan MERT ve Muhsin TÜCCAR'a katkılarından dolayı sonsuz teşekkürlerimi sunarım.

Kemal ADEM

Haziran, 2013

İÇİNDEKİLER

	<u>Sayfa</u>
ÖZET	i
ABSTRACT	ii
TEŞEKKÜR	iii
İÇİNDEKİLER.....	iv
SİMGE VE KISALTMALAR DİZİNİ	vi
ŞEKİLLER DİZİNİ	vii
ÇİZELGELER DİZİNİ.....	ix
1. GİRİŞ	1
2. KAYNAK ÖZETLERİ	3
2.1. Aseptik Ambalajlamaya Genel Bir Bakış	3
2.1.1. Aseptik Ambalajların Dolum Süreci.....	4
2.1.2. Aseptik Ambalaj Malzemesi ve Donanımların Sterilizasyonu.....	4
2.1.3. Aseptik Ambalajlamada Isıl Kapatma	5
2.1.4. Aseptik Ambalajlamanın Avantajları	5
2.1.5. Aseptik Ambalajlamanın Dezavantajları	6
2.2. Görüntü İşleme Tabanlı Kalite Kontrolü	6
3. MATERYAL VE YÖNTEM	10
3.1. Kullanılan Veri.....	10
3.2. Sayısal Görüntü İşleme Tanımları	13
3.2.1. Görüntü	13
3.2.2. Piksel.....	14
3.2.3. Çözünürlük.....	14
3.2.4. Renkler	14
3.3. Görüntü İşleme Teknikleri.....	16
3.3.1. Parlaklık Ayarlama	16
3.3.2. Kontrast Ayarlama	17
3.3.3. Gölge Düzeltme	18
3.3.4. Görüntü Histogramı	18

3.3.5. Histogram Eşitleme.....	20
3.3.6. Görüntü Bölütleme.....	21
3.3.7. Görüntü İşlemedeki Vektörizasyon Teknikleri.....	27
3.4. Görüntü İşlemenin Uygulama Alanları.....	28
3.5. Sınıflandırma.....	29
3.5.1. Doğrusal Regresyon.....	29
3.5.2. Çok Katmanlı Sinir Ağı.....	30
3.5.3. Destek Vektör Makinesi.....	32
3.5.4. Genelleştirilmiş Regresyon Sinir Ağı.....	34
4. BULGULAR VE TARTIŞMA	36
4.1. Boyuna Dikiş Hatası Çözümleri	37
4.1.1. Yüksek Sıcaklık Yüksek Basınç Boyuna Dikiş Hatası Çözümleri.....	37
4.1.2. Düşük Sıcaklık Düşük Basınç Boyuna Dikiş Hatası Çözümleri.....	44
4.2. Enine Dikiş Hatası Çözümleri.....	48
4.3. Dikiş Hatalarının Çözümündeki Başarı Oranlarının Karşılaştırılması	51
4.4. En Başarılı Yöntemlerin ROC Eğrileri.....	53
4.4.1. YSYB Boyuna Dikiş Çözümü için ROC Eğrisi.....	54
4.4.2. DSDB Boyuna Dikiş Çözümü için ROC Eğrisi.....	55
4.4.3. Enine Dikiş Çözümü için ROC Eğrisi	56
5. SONUÇ	58
KAYNAKLAR	60
ÖZGEÇMİŞ	64

SİMGE VE KISALTMALAR DİZİNİ

Simgeler

Açıklama

∇f	Görüntünün eğimi
$ \nabla f $	Görüntünün genliği
G_x, G_y	Eğim operatörleri

Kısaltmalar

Açıklama

LDPE	Low Density Polyethylene
LLDPE	Linear Low Density Polyethylene
YSA	Yapay Sinir Ağı
GA-YSA	Genetik Algoritma-Yapay Sinir Ağı
Dpi	İnç başına düşen nokta miktarı
EKK	En Küçük Kareler
ÇKSA	Çok Katmanlı Sinir Ağı
DVM	Destek Vektör Makinesi
GRNN	Genelleştirilmiş Regresyon Neural Network
RBF	Radyal Tabanlı Fonksiyonlar
YSYB	Yüksek Sıcaklık Yüksek Basınç
DSDB	Düşük Sıcaklık Düşük Basınç
ROC	Receiver Operating Characteric

ŞEKİLLER DİZİNİ

Sayfa

Şekil 2.1. Aseptik Ambalajlama Örneği	3
Şekil 3.1. Örnek bir karton kutu kesiti.....	11
Şekil 3.2. Veri kümesi için hazırlanan dikiş görüntüleri	11
Şekil 3.3. Boyuna dikişler için sıcaklık ve basınç değerleri ile oluşan hatalar.....	12
Şekil 3.4. Enine dikiş üzerinde oluşan hatalar	12
Şekil 3.5. RGB renk modeli.....	15
Şekil 3.6. Gri seviye renk modeli örneği	16
Şekil 3.7. Parlaklık ayarlama örneği.....	17
Şekil 3.8. Kontrast ayarlama örneği.....	18
Şekil 3.9. Görüntü histogramı için verilen örnek resim.....	19
Şekil 3.10. Görüntünün histogramı.....	19
Şekil 3.11. Histogram eşitlemesi örneği	20
Şekil 3.12. Histogram eşitleme sonrası yapılan görüntünün histogramı	21
Şekil 3.13. Orijinal görüntü ve Kenar bulma algoritması uygulanmış görüntü.....	24
Şekil 3.14. Manüel eşikleme örneği.....	25
Şekil 3.15. Otsu metodu ile yapılan eşikleme.....	26
Şekil 3.16. ÇKSA ağların kullanılan nöron şekli.....	30
Şekil 3.17. Optimum düzlem ve Destek vektörleri.....	32
Şekil 3.18. Örnek bir GRNN ağı.....	34
Şekil 4.1. Fotoğraf makinesi ile yapılan çekim	36
Şekil 4.2. Tarayıcı ile yapılan çekim	36
Şekil 4.3. YSYB Boyuna dikiş örnekleri.....	38
Şekil 4.4. Prewitt kenar bulma algoritması ile elde edilen sonuçlar.....	39
Şekil 4.5. Sobel kenar bulma algoritması ile elde edilen sonuçlar	40
Şekil 4.6. Canny kenar bulma algoritması ile elde edilen sonuçlar	41
Şekil 4.7. YSYB için kenar bulma algoritmalarının karşılaştırılması	42
Şekil 4.8. Kullanılan ÇKSA modeli.....	43
Şekil 4.9. YSYB hatasının sınıflandırma türlerine göre karşılaştırılması.....	44
Şekil 4.10. DSDB hatalı paket örneği.....	45

Şekil 4.11. DSDB hatasız paket örneği.....	45
Şekil 4.12. Manüel eşikleme.....	46
Şekil 4.13. Otsu yöntemi ile eşikleme	46
Şekil 4.14. DSDB için eşikleme yöntemlerinin karşılaştırılması	47
Şekil 4.15. Enine dikiş hatalı kutu örneği.....	49
Şekil 4.16. Enine dikiş hatasız kutu örneği.....	49
Şekil 4.17. Otsu yöntemi kullanılarak Enine dikiş hatasının çözümü	49
Şekil 4.18. Manüel eşikleme kullanılarak Enine dikiş hatasının çözümü	49
Şekil 4.19. Enine dikiş için eşikleme yöntemlerinin karşılaştırılması.....	51
Şekil 4.20. Hata Matrisi	53
Şekil 4.21. YSYB Boyuna Dikiş Hata Matrisi	54
Şekil 4.22. YSYB boyuna dikiş hatası için çizdirilen ROC eğrisi	54
Şekil 4.23. DSDB Boyuna Dikiş Hata Matrisi	55
Şekil 4.24. DSDB boyuna dikiş hatası için çizdirilen ROC eğrisi	56
Şekil 4.25. DSDB Boyuna Dikiş Hata Matrisi	57
Şekil 4.26. Enine dikiş hatası için çizdirilen ROC eğrisi.....	57

ÇİZELGELER DİZİNİ

	<u>Sayfa</u>
Çizelge 2.1. Bazı Aseptik Ambalaj Malzemelerinin İşlevsel Nitelikleri.....	5
Çizelge 3.1. Elde edilen sağlam ve hatalı kutu sayıları	10
Çizelge 4.1. YSYB hatası nedeniyle toplanan veri sayısı.....	37
Çizelge 4.2. Prewitt yöntemi ile elde edilen sonuçlar.....	39
Çizelge 4.3. Sobel yöntemi ile elde edilen sonuçlar	41
Çizelge 4.4. Canny yöntemi ile elde edilen sonuçlar.....	42
Çizelge 4.5. DSDB hatası nedeniyle toplanan veri sayısı.....	44
Çizelge 4.6. Enine dikiş hatası nedeniyle toplanan veri sayısı	48
Çizelge 4.7. Tüm dikiş hataları için kullanılan teknikler ve başarı oranları	52

1. GİRİŞ

İnsan için hayati bir tüketim gereksinimi olduğundan sıvı gıda üretimi günümüz dünyasının vazgeçilmez bir parçasıdır. Sıvı gıda üretim sürecinde ürünün üretilmesi kadar önemli bir diğer husus da paketleme ve saklama aşamalarıdır. Sıvı gıdaların paketlenmesi sırasındaki işlemlerden kaynaklanan karton kutulardaki şerit dikişi kusurları paket içerisindeki sıvı gıdaların hava almasına ve bu ürünlerin bozulmasına sebep olmaktadır (Paine, 1992). İmalat işleminin paketleme aşamasında, ürünler belirli süreler aralığında kontrol edilmekte ve hatalı bir paket tespit edildiği anda sorunun çözülmesi için üretim durdurulmaktadır. Hata tespitinin belirli süreler aralığında tekrarlanarak yapılması bir sonraki imalat aşamasına daha az hatalı girdi sağlanması açısından büyük önem arz etmektedir. Bunun nedeni sonraki aşamalarda hatanın oluşturduğu maliyetin katlanarak artmasıdır. Paketleme teknolojisindeki gelişmeler sayesinde hata sayısı azaltılmış olsa da makinelerdeki farklı basınç ve sıcaklık uygulamalarının neden olduğu hatalar, üretici açısından hala ciddi zararlara sebep olmaktadır.

Üretilen sıvı gıda karton kutularındaki şerit dikişlerin kalite kontrol işlemi uzman kişiler tarafından gözle kontrol edilerek gerçekleştirilmektedir. Karton kutular şerit dikişlere zarar verilmeden kesilmekte ve kalite kontrol elemanları tarafından bir ön inceleme tabi tutulmaktadır. Daha sonra kesilen karton kutudaki boyuna dikişlere bir şırınga yardımıyla kırmızı renkli özel bir mürekkep enjekte edilmekte ve mürekkebin dikiş içerisindeki dağılımına göre hata tespit edilmeye çalışılmaktadır. Gözle yapılan bu kalite kontrol işleminde kontrol elemanının yorgunluğu ya da tecrübesizliği maddi kayıplarla sonuçlanmaktadır (Üçüncü, 2011).


Bu tez, gözle yapılan kontrol işleminin dezavantajlarından dolayı bilgisayarla görüntü işleme teknikleri kullanılarak aseptik kartonlardaki şerit dikişlerin kalite kontrolünün otomatik olarak gerçekleştirilmesi hakkındadır. Bu çalışmada, kullanılan veri DİMES firması tarafından sağlanmıştır.

Bu tez çalışması beş bölümden oluşmaktadır. Birinci bölüm “Giriş” bölümüdür ve burada aseptik ambalajlamadaki dikişlerin kalite kontrolünün gözle yapılmasının dezavantajlarından ve tez çalışmasının içeriğinden bahsedilmiştir. İkinci bölümde aseptik ambalajlama ile ilgili kaynak araştırması ve genel bilgiler verilmiştir. Bu bölümde ayrıca dikişlerin kalite kontrolünün görüntü işleme tabanlı yöntemlerle gerçekleştirildiği bilimsel çalışmaların özetlerine yer verilmiştir. Üçüncü bölüm “Materyal ve Yöntem” bölümüdür. Bu bölümde kullanılan veri kümeleri ve dikişlerdeki hata çeşitleri anlatılmıştır. Ayrıca bu hata çeşitlerinin çözümü için kullanılan görüntü işleme teknikleri anlatılmıştır. Dördüncü bölüm “Bulgular ve Tartışma” bölümüdür. Bu bölümde üç hata tipi için elde edilen veri kümelerine görüntü işleme teknikleri ve farklı sınıflandırma yöntemleri uygulanarak doğru sınıflandırma oranları elde edilmiştir. Kullanılan sınıflandırma yöntemlerinin sonuçları karşılaştırılarak grafiklerle gösterilmiş ve çıkan sonuçlar tartışılmıştır. Beşinci bölüm olan sonuç bölümünde ise aseptik ambalajlamadaki dikişlerin sayısal görüntüleme tabanlı kalite kontrolünün yapılabileceği konusunda ümit verici sonuçlar sunulmuştur.

2. KAYNAK ÖZETLERİ

2.1. Aseptik Ambalajlamaya Genel Bir Bakış

Aseptik ambalajlama, sterilize hale getirilen ambalaj malzemesi ile gıda maddesinin steril bir ortamda bir araya getirilmesi ve ısı işlemleri kullanılarak kapatılması işlemidir. Sterilizasyon ise gıda malzemesinde bulunan mikroorganizmaların öldürülmesi veya bulunma olasılığının düşürülmesi işlemidir. Aseptik ambalajların oksijen ve ışık geçirmemesi gerekmektedir. Bu nedenle aseptik karton ambalajlarının hava ve ışık temasını önlemek için 6 katmanlı bir yapı kullanılmaktadır. Bu yapı Şekil 2.1’de gösterilmektedir.



Şekil 2.1. Aseptik ambalajlama örneği (Anonim, 2012)

Şekil 2.1’de görüldüğü gibi aseptik ambalajlar polietilen, alüminyum folyo ve karton’dan oluşmaktadır. Kullanılan bu malzemeler sayesinde ambalaj içerisindeki gıda maddesinin hava ve ışıkla temas etmeyerek bozulması önlenmektedir (Üçüncü, 2011).

2.1.1. Aseptik Ambalajların Dolum Süreci

Aseptik ambalajlar, dolum işlemi başlamadan önce sterilizasyon sürecinden geçmektedir. Bu ambalajın içine çok yüksek sıcaklıkta işlem gören ürün doldurulmaktadır. Bu işlem sonucunda ürün mikro organizmalardan arınmıştır. Ayrıca gerekli ambalajlama kurallarına uyulması halinde ürünün piyasada yer alma süresi uzamaktadır.

Aseptik ambalajlama teknolojisi iki alanda uygulanmaktadır.

- Ön sterilizasyon yapılmış ambalajların kullanıldığı ürünlerde (örneğin süt, meyve suyu, puding vb.)
- Mikroorganizma enfeksiyonlarından kaçınılması için sterilize edilmemiş ürünlerin ambalajlanmasında (örneğin yoğurt)

Ürün ile ambalaj malzemesinin steril hale getirilmesinden sonra dolum işleminin gerçekleştirileceği ortam ile üretim sürecinde kullanılan dolum ve yapıştırma sistemlerinin de steril olması gerekmektedir (Paine, 1992).

2.1.2. Aseptik Ambalaj Malzemesi ve Donanımların Sterilizasyonu

Aseptik ambalajların ve ambalajlamayı gerçekleştiren araçların sterilizasyonu için ısı, kimyasal ve radyasyon gibi işlemler kullanılmaktadır. Isı sterilizasyonu için genellikle basınç altında doymuş buhar ile sterilizasyon gerçekleştirilmektedir. Kimyasal sterilizasyon için genellikle hidrojen peroksit kullanılmaktadır. Radyasyon sterilizasyonu ise özellikle asitli gıdaların aseptik dolum ve ambalajlamasında gamma ışınları ile yapılmaktadır (Dinnage, 1983).

Kullanılan aseptik ambalaj malzemelerinin özellikleri Çizelge 2.1'de gösterilmektedir.

Çizelge 2.1. Bazı Aseptik Ambalaj Malzemelerinin İşlevsel Nitelikleri (Dinnage,1983)

Malzeme	Engelleme Özelliği			Yapışma	Dayanıklılık		
	Oksijen	Nem	Işık		Bükülme	Yırtılma	Delinme
Karton			✓		✓		
Alüminyum Folyo	✓	✓	✓				
Metalize Film	✓		✓				
Etilen Akriklik Asit				✓			✓
LDPE		✓		✓			
LLDPE		✓		✓		✓	✓
Naylon						✓	✓
Polipropilen		✓		✓		✓	
Polistiren					✓		
Etilen Vinil Alkol	✓						

2.1.3. Aseptik Ambalajlamada Isıl Kapatma

Aseptik ambalaj malzemesi ısı kullanılarak kapatılmaktadır. Isıyla kapanan aseptik ambalajın dışarıyla ilişkisinin kesilmesinin yanında ambalajlanan ürünün steril bir şekilde kalması sağlanmaktadır. Bu nedenle, dikişlerin tamamen yapışması ve yapışmanın kalitesi oldukça önemlidir. Tetrapak sistemlerinde ambalajın kapatılması boyuna ve enine dikişlerin gerçekleştirilmesiyle sağlanmaktadır (Üçüncü, 2011).

2.1.4. Aseptik Ambalajlamanın Avantajları

- Paketleme fiyatları diğer ambalajlama çeşitlerine göre daha düşüktür.
- Düşük sıcaklıkta uzun süre sterilizasyon yerine yüksek sıcaklıkta çok kısa sürede sterilizasyonun gerçekleşmesi, gıdanın beslenme öğelerinde kaybı azaltmaktadır.

- Gıdalara uzun raf ömrü sağlamaktadır.
- Diğer sistemlere göre daha az enerji kullanmaktadır (Kumar ve ark., 2010).

2.1.5. Aseptik Ambalajlamanın Dezavantajları

- Dolum ve dikiş işlemlerini gerçekleştiren makineler ile ortamdaki havanın sürekli steril olmasının sağlanması gerekmektedir.
- Aseptik ambalajlamada çalışan personelin diğer ambalajlama çeşitlerine göre daha yetenekli ve dikkatli olması gerekmektedir (Kılınç ve Çaklı, 2001).

2.2. Görüntü İşleme Tabanlı Kalite Kontrolü

Sayısal görüntüler, çoğu uygulama alanında yaygın olarak kullanılan önemli veri kaynaklarıdır. Sayısal görüntü işleme konusu üzerine uzun süredir birçok çalışma yapılmıştır ancak literatürde tez konusuyla ilgili görüntü işleme teknikleri kullanan çalışmaya rastlanmamıştır. Tetra Brik Aseptik karton kutulardaki şerit dikişlerinin geleneksel kalite kontrolü özellikle tekstil sektöründeki kumaş dikişlerinin kalite kontrolüne çok benzemektedir. Bu nedenle tekstil dikişlerinin görüntü işleme tabanlı kalite kontrolü ile ilgili kaynaklar aşağıda özetlenmiştir.

Jasper ve Potapalli (1995), yaptıkları çalışmada dokuma kumaşların görüntülerini sayısallaştırmıştır. Sayısallaştırılan görüntüler sobel kenar bulma yöntemi, Fourier dönüşümü ve ayrık dalgacık dönüşümü gibi üç farklı görüntü analiz tekniği ile incelenmiştir. Test örneklerinin sonuçları gözlemlendiğinde ayrık dalgacık dönüşümünün hataları çok iyi karakterize ettiği görülmüş ve diğer iki yönteme göre sonuçları daha hızlı ve doğru bulduğu tespit edilmiştir.

Conci ve Proenca (2000), dikiş hatalarının tespiti için gerçekleştirdikleri tasarımın hem doğru hem de hızlı karar vermesi gerekliliği üzerine yoğunlaşmışlardır. Hataların tespiti için fraktal boyutlar, kenar tespiti ve eşikleme yöntemleri uygulanmıştır. Bu teknikler ile ortalama olarak %85'den daha iyi bir sınıflandırma gerçekleştirilmiştir. Tüm

deneyle dikkate alındığında, fraktal boyut tekniğinin kumaşların kalite kontrolü için oldukça umut verici olduğu gözlemlenmiştir.

Stojanovic ve ark. (2001), gerçekleştirdikleri çalışmada tekstil kumaşlarının kalite kontrolü için makine görmesi tabanlı bir sistem sunmaktadır. Düşük maliyetli bu sistem için üç katmanlı geri beslemeli yapay sinir ağı modeli önerilmiştir. Önerilen bu çalışmada hata tespiti için %86,2 gibi bir başarı oranı sağlanmıştır. Çalışmanın test ve değerlendirme aşamaları önerilen yaklaşıma dayalı sanayide kullanılabilir görsel bir kontrol sisteminin gerçekleştirilebileceği sonucunu göstermiştir.

Kuo ve Lee (2003), yaptıkları çalışmada düz beyaz kumaşların hata tespiti için üç katmanlı geri beslemeli yapay sinir ağı modeli önermişlerdir. Dört farklı hata sınıfı ve 160 hatalı görüntü kullanılarak yapılan bu çalışmada %91,88 gibi bir başarı oranı sağlanmıştır. Bu kadar iyi bir başarı oranının olmasının nedeni, doğrusal olmayan regresyon algoritmasına dayanan çok boyutlu bir model kullanılmasıdır.

Kuo ve ark. (2003), gerçekleştirdikleri çalışmada düz beyaz kumaş çeşidi için farklı bir yapay sinir ağı modeli kullanmış ve resimler üzerinde hataların daha net tespiti için ön işlemler gerçekleştirmişlerdir. Bu şekilde dört farklı hata sınıfı ve 240 sorunlu görüntünün hatalarının tespiti için başarı oranı %94,38'e kadar çıkartılmıştır.

Kumar (2003), ileri beslemeli yapay sinir ağı modeli kullanarak kumaşların hata tespiti için yeni bir yaklaşım önermiştir. Hesaplama karmaşıklığını azaltmak için uygulanan yöntemler başarılı sonuçlar vermiştir. Farklı kumaş tipleri ve farklı kumaş hata tipleri üzerinde yapılan test sonuçları kullanılan tekniğin etkili ve doğru sonuç verdiğini göstermektedir. Çalışmada ayrıca doğrusal sinir ağı kullanan düşük maliyetli bir web denetim sistemi önerilmiştir. Önerilen sistemin performansı gerçek kumaş örneklerinde test edilmiştir. Sonuçlar kullanılan metodun hata tespiti için sadece bilgisayar kullanmasına rağmen oldukça başarılı ve düşük bir maliyete sahip olduğunu göstermektedir.

Kısaoglu (2006), yaptığı çalışmada bilgisayar destekli kumaş kalite kontrol sistemlerini inceleyerek elle yapılan kontrollere karşı avantajlarını vurgulamıştır. Teknolojik gelişmeler doğrultusunda kaliteyi artırmaya yönelik faaliyetler hızla artmaktadır. Bu durum hatasız üretimin zorunluluğunu ortaya çıkarmaktadır. İnsan faktöründen kaynaklı hataları en aza indiren kumaş kalite kontrol sistemlerinin ekonomik açıdan da işletmeler için uygun olacağını ortaya koymuştur.

Majumdar ve ark. (2008), düz dokuma kumaşların gerilmeye karşı dayanma gücünü yapay sinir ağı (YSA) ve doğrusal regresyon yöntemlerini kullanarak tahminde bulunmuşlardır. Bu iki yöntemin de gerçekleştirdiği tahminlerin iyi olmasına rağmen YSA modelinin doğrusal regresyona göre daha doğru ve genel bir tahmin yaptığı gösterilmiştir.

Zhang ve ark. (2010), gerçekleştirdikleri çalışmada hatalı kumaşların tespiti için Gaussian modeli incelenmesiyle geliştirilen radyal tabanlı fonksiyonu kullanmışlardır. Önerilen algoritmayla gerçekleştirilen sistemde 9 farklı hata sınıfı için 270 hatalı görüntüde %83,4 başarı oranıyla hatalar tespit edilmiştir.

Zeydan (2010), yaptığı çalışmada dokuma kumaşların kalitesini ölçmek için kullanılan en temel özelliklerden biri olan dokuma kumaşların gerginliğe karşı dayanma gücünün tahmin edilmesi önerisinde bulunmuştur. Bu tahmin için YSA, Genetik Algoritma-YSA hibrit modeli ve çoklu doğrusal regresyon modeli kullanılarak bu yöntemlerin karşılaştırılması yapılmıştır. Yapılan karşılaştırma sonucunda GA-YSA hibrit modelinin tahmin için en uygun teknik olduğu gözlemlenmiştir.

Çelik ve ark. (2012), kumaş hatalarının tespiti için önerdikleri dalgacık yöntemi, gabor filtresi ve fourier dönüşümü yöntemlerinin birlikte kullanılmasıyla başarılı sonuçlar alınabileceği sonucunu ortaya çıkarmışlardır. Bu yöntemlerin birlikte uygulanmasından önce görüntüyü düzgünleştirmek ve gürültülerden arındırmak için eşikleme, filtreleme ve genişletme gibi morfolojik işlemler kullanılmıştır. Hataların sınıflandırılması için yapay sinir ağı modeli kullanılmıştır. Çalışmada, güçlü ve etkili bir kumaş hata denetimi

için birçok görüntü işleme uygulamalarının birlikte ve uyum içerisinde kullanılması sonucu çıkmıştır.

3. MATERYAL VE YÖNTEM

3.1. Kullanılan Veri

Çalışmada kullanılan veri kümeleri içerisindeki örnekler TetraPak'ın ürettiği sıvı gıda karton kutuları olup Dimes'in Tokat'taki fabrikasından temin edilmiştir. Temin edilen karton kutuların sağlamlığı veya hata tipi fabrikanın kontrol uzmanları tarafından belirlenmiştir. Bu kutulardaki hata tipleri enine ve boyuna dikiş hatalarıdır. Veri kümelerinde kullanılan enine ve boyuna dikiş hatası bulunan kutu örnekleri ile hatasız kutu örneklerinin sayısı Çizelge 3.1'de gösterilmektedir.


Çizelge 3.1 Elde edilen sağlam ve hatalı kutu sayıları

Hata Tipi	Sağlam Kutu Sayısı	Hatalı Kutu Sayısı
Boyuna Dikiş Hatası*	35	30
Boyuna Dikiş Hatası**	35	30
Enine Dikiş Hatası	31	44

(*: Yüksek sıcaklık ve yüksek basınç altında)

(**): Düşük sıcaklık ve düşük basınç altında)

Veri kümelerinde bir standart olması açısından veriyi oluşturmak için toplanan tüm karton kutular Canon N670U tarayıcı cihazıyla aynı ayarlarda taranmıştır. Görüntüler üretim esnasında rastgele alınan kutuların uygun bir şekilde kesilip iç yüzeyinin taratılmasıyla elde edilmiştir. Şekil 3.1'de örnek bir karton kutu kesiti gösterilmektedir.



Şekil 3.1. Örnek bir karton kutu kesiti

Şekil 3.1’de gösterilen karton kutu kesiti ile karton kutunun enine ve boyuna dikişlerinin konumları da işaretlenmiştir. Şekil 3.1’deki gibi hazırlanan ve taratılan görüntülerden enine ve boyuna dikişlerin olduğu kısımlar kesilerek veri kümesi için hazırlanmıştır. Veri kümeleri için hazırlanan enine ve boyuna dikişler sırasıyla Şekil 3.2.a ve Şekil 3.2.b’de gösterilmektedir.



Şekil 3.2. Veri kümesi için hazırlanan dikiş görüntüleri

Şekil 3.2’de gösterilen sağlam enine ve boyuna şerit dikişleri ortalama 250–280°C sıcaklık değerinde ve 2,5–3 bar basınç değerlerinde oluşturulmuştur. Uygulanan sıcaklık değerleri mevsim şartlarına göre 10–20 °C arasında değişim gösterebilmektedir. Boyuna dikiş kontrolü için uzmanların hatalı olarak işaretlediği iki örnek Şekil 3.3’te gösterilmektedir.



Şekil 3.3. Boyuna dikişler için sıcaklık ve basınç değerleri ile oluşan hatalar

Şekil 3.3.a'da verilen görüntüde şerit dikişin etrafında istenilen sıcaklık ve basınç seviyelerine çıkılmadığı için belirgin bir matlık bulunmaktadır. Şekil 3.3.b'de ise şerit dikişin etrafında aşırı sıcaklık ve basınç yüzünden kırışıklıklar oluştuğu gözlenmektedir. Enine dikiş için ise hatalı dikiş örneği Şekil 3.4'te gösterilmektedir.



Şekil 3.4. Enine dikiş üzerinde oluşan hatalar

Şekil 3.4'te gösterilen görüntüde kırmızı dairelerle işaretlenmiş bölgeler tam olarak yapışmadığından enine dikiş hatası oluşmuştur.

3.2. Sayısal Görüntü İşleme Tanımları

Tıp, biyoloji, uzaktan algılama, endüstri gibi uygulama ve araştırma alanlarında veri kaynağı olarak genellikle sayısal görüntüler kullanılmaktadır. Bu nedenle sayısal görüntülerin içerdikleri özelliklerin en iyi şekilde kullanılması her uygulama ve araştırma alanı için oldukça önemlidir. Sayısal görüntü işleme, gerçek hayattaki görüntülerin giriş resmi olarak işlenmesiyle istenen özelliklerinin bulunması sonucu yeni bir çıkış resmi oluşturulmasıdır (Umbaugh, 1998; Eriksson ve Papanikotopoulos, 1997; Merchant ve Schnell, 2000; Çayırılı, 2006).

3.2.1. Görüntü

Görüntü, gerçek yaşamdaki üç boyutlu nesnelere oluşan bir sahnenin basit iki değişkenli bir fonksiyon olarak tanımlanmasıdır. Tanımlanan $f(x, y)$ fonksiyonunda ifade edilen bir görüntüde f parlaklık, karışıklık gibi bir şiddet birimi iken x ve y değişkenleri ise görüntünün koordinatlarıdır.

Siyah-Beyaz Görüntü

Siyah beyaz bir görüntü, ışık yoğunluğunu gösteren iki boyutlu bir fonksiyon olarak tanımlanır. Bu $f(x, y)$ fonksiyonunda x ve y düzlemsel koordinatları, fonksiyonun (x, y) noktasındaki değeri resmin o noktadaki parlaklığını gösterir. $f(x, y)$ fonksiyonu ortamın aydınlanma miktarına ve nesnenin ışığı yansıtma oranına bağlıdır. Aydınlatmayı $a(x, y)$, yansıtmayı $b(x, y)$ ile gösterirsek $f(x, y)$ bunların çarpımı olacak şekilde Eşitlik 3.1'de verilmektedir.

$$f(x, y) = a(x, y).b(x, y) \quad (3.1)$$

$a(x, y)$ 'yi ışık kaynağı, $b(x, y)$ 'yi nesnelere yansıtma özellikleri belirler. $b(x, y)$ için 0 limit değeri ışığın tamamen emilmesi, 1 limit değeri ışığın tamamen yansıtılması anlamına gelmektedir (Gonzalez ve Woods, 1993).

Renkli Görüntü

Renkli görüntü, seçilen rengin parlaklık ve karşıtlığına göre siyah ve beyazın 256 farklı ton seviyesine göre gösterilir. Görüntü işleme tekniklerini kullanırken renkli görüntüler kullanarak nesnelerin daha kolay tanımlanması sağlanmaktadır. Ancak düşük kontrastlı görüntülerde nesnelerin tanınma performansı beklenen seviyelerde olmamaktadır (Anonim, 2013).

3.2.2. Piksel

Piksel, sayısal görüntülerin en küçük birimidir. Sayısal görüntüler yan yana gelen piksellerden oluşmaktadır. Sayısal görüntü, imgenin eninde ve boyunda bulunan piksel sayıları ile tanımlanır. Genellikle piksellerin en ve boy oranları eşittir. Görüntülerin en küçük birimi olan her piksel sadece tek bir renk değeri içerir. Görüntü işleme tekniklerinin tamamı piksellerin rengi ve konumunu değiştirerek işlem yapmaktadır (Çayırılı, 2006).

3.2.3. Çözünürlük

Çözünürlük, görüntüde birbirinden ayırt edilebilen nokta sayısıdır. Çözünürlük için görüntünün örneklenme frekansı miktarı esas alınır. Sayısal görüntülerin çözünürlüğünü ifade ederken genellikle inç başına düşen nokta miktarı kullanılır. Görüntüdeki çözünürlüğü iyileştirmek için örnekleme sıklığının artırılması gerekmektedir (Edizer, 2006).


3.2.4. Renkler

Renk, ışığın farklı dalga boylarının gözün retinasında oluşturduğu algılamadır. İnsan tarafından renklerin algılanması, ışığa, ışığın cisimler tarafından yansıtılışına ve öznenin göz yardımıyla beyne iletilmesi sayesinde gerçekleşir (Bastı, 2007). Bir insanın renkleri ayırt edebilmesi için dalga boyunun 0,4–0,7 mikron arasında olması gerekir. Kırmızı en düşük dalga boylu renk iken mor da en yüksek dalga boylu renktir. İnsan gözü,

yapısından dolayı bütün renkleri ana renk olarak adlandırılan kırmızı, yeşil ve mavinin değişik oranda karışımları olarak algılamaktadır. Temel renklerin bir araya gelmesiyle ikincil renkler meydana gelir. Renkleri belirli bir standarda göre tanımlamak için renk modelleri kullanılır. Sayısal görüntüleme en sık kullanılan renk modeli RGB ve HSL modelleridir (Polat, 2007).

RGB Renk Modeli


RGB renk modeli, 'Red', 'Green', 'Blue' kelimelerinin baş harflerinden ismini alan bir renk modelidir. En sık kullanılan renk modellerindendir. Doğada bulunan tüm renkler bu üç temel rengin belirli oranlarda karışımıyla elde edilmektedir. Şekil 3.5'de görüldüğü gibi bu üç temel renk tamamen karıştırıldığında beyaz renk oluşmaktadır. Bu renklerin karışım oranı sıfıra indiğinde ise bu renk modelinin arka planı olan siyah renk oluşmaktadır. Günümüzde bu renk modeli tarayıcılarda ve televizyonlarda standart olarak kullanılır (Yılmaz, 2002).



Şekil 3.5. RGB renk modeli

Gri Seviye Renk Modeli

Gri seviye renk modeli için sadece beyaz renk kullanılır. Bu rengin değerinin 0 olması durumunda siyah, 255 olması durumunda ise beyaz renk oluşmaktadır. Bu renk modelinde 256 farklı seçenek olduğundan renkler 8 bit ile gösterilir. Şekil 3.6’da gri seviye renk modeli kullanan bir görüntü ve bu modeldeki sayısal değerleri görülmektedir.



Şekil 3.6. Gri seviye renk modeli örneği

Gri seviye renk modeli, genellikle görüntülerin gri seviye tonlarını yoğun içerdiği medikal, endüstri gibi alanların uygulamalarında kullanılır (Polat, 2007).

3.3. Görüntü İşleme Teknikleri

3.3.1. Parlaklık Ayarlama

Parlaklık ayarlaması, görüntülerin gri değerlerinin ağırlıklı ortalaması alınarak bulunur. Gri değerlerin varyansı hesaplanarak da görüntünün kontrastı ölçülmektedir. Görüntünün parlaklığını ayarlamak için görüntüdeki piksellerin gri ton değerlerine sabit c sayısı eklenir. Bu durumda dönüşüm fonksiyonu eşitlik 3.2’de verilmektedir.

$$s = T(r) = r + c \quad (3.2)$$

Burada $c < 0$ olursa görüntünün şekli değişmeden parlaklığı artacaktır. c değerinin 0'dan büyük olması durumunda ise parlaklık azalacaktır (Bellanger, 2000). Şekil 3.7'de çalışmadan alınan örnek bir görüntünün parlaklığı ayarlanarak dikiş bölgelerinin daha net ortaya çıkması sağlanmaktadır.



a- Orijinal görüntü



b- Parlaklığı artırılmış görüntü



c- Parlaklığı azaltılmış görüntü

Şekil 3.7. Parlaklık ayarlama örneği

Şekil 3.7'de görüldüğü gibi görüntünün parlaklığı uygun derecede azaltılarak dikişler hakkında daha doğru kararlar verilebilmektedir.

3.3.2. Kontrast Ayarlama

Görüntünün ayırt edilebilirliğini ifade etmek kontrast yani karşıtlık kullanılır. Kontrastı ölçmek için gri değerlerin varyansı kullanılır. Kontrastı düşük olan görüntülerin histogramlarında belirli aralıklarda çok sayıda pikselin yoğunlaştığı görülür. İnsan gözü bu kadar yakın gri ton değerlerini ayırt etmekte zorlanmaktadır. Bu görüntüleri daha uygun hale getirmek için gri ton değerlerini yüksek değerlere doğru kaydırarak görüntünün histogramının daha geniş bir aralığa yayılması gerekmektedir (Bellanger, 2000; Çayırılı, 2006). Şekil 3.8'de çalışmadan alınan örnek bir görüntünün kontrastı ayarlanarak dikiş bölgelerinin daha net ortaya çıkması sağlanmaktadır.



a- Orijinal görüntü



b- Kontrastı azaltılmış görüntü



c- Kontrastı artırılmış görüntü

Şekil 3.8. Kontrast ayarlama örneği

Şekil 3.8'de görüldüğü gibi görüntünün kontrastı azaltıldığında dikişlerin netliği de azalmaktadır. Kontrast artırıldığında ise dikişler daha iyi ayırt edilebilmektedir. Bu sayede dikişlerin durumu hakkında daha net kararlar verilebilmektedir.

3.3.3. Gölge Düzeltme

Görüntüler fiziksel nesnelere elde edilirken, ışık, kamera veya gerçek nesnenin kaynaklandığı durumlardan dolayı görüntü üzerinde gölgeler oluşabilir. Bu gölgeleri düzeltmek için genellikle iki yaklaşım kullanılır.

- Farklı bir ortamdaki veriyle yer değiştirerek
- Radyometrik düzeltmeler yaparak

Radyometrik düzeltme olarak adlandırılan doğrusal korelasyon düzeltme Sarabandi ve ark. (2004) tarafından önerilmiştir. Bu yöntemde aynı yüzeyi içeren gölgeli alanları çevreleyen bir bölge seçilir. Bu bölgeden elde edilen değerler gölgedeki piksel değerlerini ayarlamak için kullanılır (Becker ve Menz, 2011).

3.3.4. Görüntü Histogramı

Görüntü üzerindeki piksellerin değerlerinin grafiksel ifadesine görüntü histogramı denir. Görüntü histogramı, görüntünün her bir noktasındaki piksellerin tespiti ile bu piksellerin


sayısının hangi miktarda olduğunu gösterir. Görüntü histogramının sağladığı kolaylıklar maddeler halinde ifade edilirse,

- Histogramlar resimlerdeki istatistiksel bilgileri gösterir.
- Dijital kameralar ve fotoğraf makinelerinde kullanılan görüntü yakalama özelliğinde histogramdan faydalanılır.
- Görüntülerin görünümünde iyileştirme yapmak için kullanılır.
- Görüntü işleme sürecinde histogramlara bakılarak hangi tekniklerin kullanılacağı hakkında bilgi toplanabilir.

Şekil 3.9 ve 3.10'da örnek bir görüntü ve bu görüntünün histogramı görülmektedir.



Şekil 3.9. Görüntü histogramı için verilen örnek resim



Şekil 3.10. Görüntünün histogramı

Görüntü histogramı görüntünün genel görünümü hakkında bir bilgi verir. Ancak histogramlar resimlerdeki piksellerin yerleşimi ile ilgili bilgi içermezler. Histograma bakılarak piksellerin yoğunlaştığı bölgelere göre farklı yorumlar yapılabilir. Pikseller histogramın küçük değerlerinde yoğun olarak bulunuyorsa resim çok karanlık yani siyaha yaklaşmış bir tondadır. Pikseller histogramın büyük değerlerinde yoğunlaşıyorsa resim çok aydınlık yani beyaza yakın bir tondadır. Pikseller histogramın orta değerlerinde yoğunlaşıyorsa görüntüye gri ton hakimdir. Bu durumlar, kontrast geliştirme, parlaklık ayarlama veya histogram eşitleme tekniklerinin uygulanması konusunda fikir verir (Bellanger, 2000).

3.3.5. Histogram Eşitleme

Histogram eşitleme yöntemi gri ton değerlerinin aralığını tekrar düzenlemeyi hedefleyen bir yöntemdir. Histogram eşitleme yönteminde gri ton değerlerinin yoğun olduğu yere daha geniş bir aralık, yoğunluğun az olduğu yere daha dar bir aralık ayrılır (Gonzalez ve Woods, 1993).

Histogram eşitleme algoritmasının çalışma adımları şu şekilde sıralanabilir:

Adım1: Öncelikle görüntünün histogramı çıkartılır.


Adım2: Gri seviye tonlarının görüntü içerisindeki bulunma olasılıkları hesaplanarak bu değerler bir diziye atılır.

Adım3: Son olarak görüntü üzerindeki herhangi bir gri seviye tonu için önceki adımda oluşturulan diziden gerekli değer çekilir ve 255 ile çarpılıp yeni görüntüdeki değer olarak hesaplanır.

Histogram eşitleme yöntemi tüm resimleri iyileştirmez. Görüntü içerisindeki tüm piksellerin belli aralıkta renk değerine sahip olduğu resimlerde etkilidir. Resim gri ve tonlarından oluşuyorsa histogram eşitleme işe yarar. Eğer renkli bir resimde histogram eşitleme yapılacaksa renkleri ayrıştırıp örneğin kırmızı, yeşil ve mavi renk kanalları için ayrı ayrı histogram eşitleme yapılmalıdır (Çayırılı, 2006). Çalışmadan alınan örnek bir görüntünün histogramının eşitlenmesiyle elde edilen sonuç Şekil 3.11’de, eşitleme yapılmış resmin histogram dağılımı da Şekil 3.12’de gösterilmektedir.

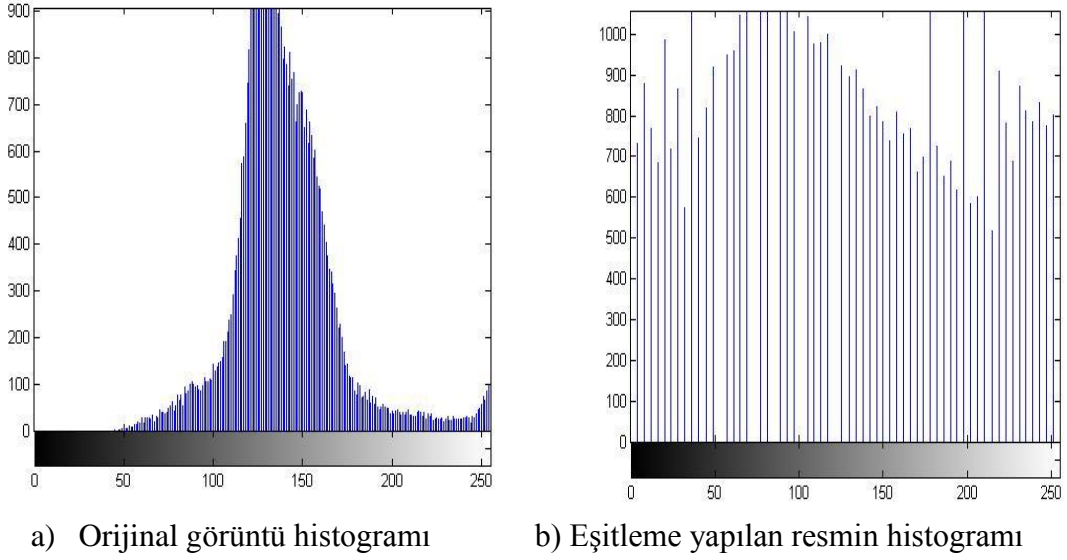


a) Orijinal görüntü



b) Histogram eşitlemesi yapılmış görüntü

Şekil 3.11. Histogram eşitlemesi örneği



Şekil 3.12. Histogram eşitleme sonrası yapılan görüntünün histogramı

Şekil 3.11’de histogram eşitlemesi yapılmış görüntünün son hali gösterilmiştir. Şekil 3.12’de ise eşitleme yapıldıktan sonra elde edilen histogram’da renk değerlerinin eşit bir şekilde dağıldığı gösterilmiştir. Çalışmada kullanılan görüntüler gri ve kahverenginin tonlarından oluştuğu için histogram eşitlemenin özellik çıkartımı için etkili bir yöntem olmadığı görülmüştür.

3.3.6. Görüntü Bölütleme

Görüntü bölütleme işlemleri, görüntü içerisindeki nesnelere daha iyi tanımak ve bu nesnelere arka plandan ayırmak için kullanılmaktadır. Bu işlem için görüntüdeki her pikselin tanımlanan nesnenin bir parçası olup olmadığının kontrolü gerekmektedir. Bu işlem sonucunda ikili bir resim üretilir. Eğer piksel tanımlanan nesneye aitse ikili resimdeki değer 1, ait değilse değer 0 olmaktadır. Bu yapılan işlemlere görüntü bölütleme adı verilmektedir. Görüntü bölütleme sonunda hangi pikselin hangi nesneye ait olduğu tespit edilmektedir (Young ve ark., 2002; Edizer, 2006).

Kenar Tabanlı Görüntü Bölütleme

Kenar tabanlı görüntü bölütleme algoritmaları renk değişimlerinin veya kontrast değişimlerinin hızlı geçiş yaptığı yerleri tespit etmeye çalışır.

Kenar bulma algoritmalarının çalışma adımları şu şekilde sıralanabilir:

Adım1: Öncelikle görüntü gri seviyeye dönüştürülür.

Adım2: Kenarların tespiti için x ve y doğrultusu olmak üzere iki ayrı filtre kalıbı kullanılarak konvülüsyon işlemi uygulanır. Her iki yönde elde edilen değerlerin kareleri alınarak sonuçlar toplanır ve daha sonra toplamın karekökü alınır. Elde edilen sonuç eğimin büyüklüğünü vermektedir.

$$\nabla f(x) = I(x, y) * G_x \quad \nabla f(y) = I(x, y) * G_y \quad (3.3)$$

$$|\nabla f| = \sqrt{\nabla f(x)^2 + \nabla f(y)^2} \quad (3.4)$$

Adım3: Elde edilen eğim büyüklükleri belirlenen eşik değerinden büyükse noktanın kenara ait olduğu belirlenirken, eşik değerinden küçükse nokta arka plan olarak ayarlanmaktadır (Balcı, 2008).

Eşitlik 3.3'de verilen G_x ve G_y eğim operatörleri kullanılan algoritmaya göre değişmektedir. En sık kullanılan kenar bulma algoritmaları Prewitt, Sobel ve Canny algoritmalarıdır.

Prewitt Kenar bulma algoritmasında G_x ve G_y 'nin hesaplanması için Eşitlik 3.5'de verilen filtreler kullanılmaktadır (Prewitt, 1970).

$$G_x = \begin{bmatrix} -1 & -1 & -1 \\ 0 & 0 & 0 \\ 1 & 1 & 1 \end{bmatrix} \quad G_y = \begin{bmatrix} -1 & 0 & 1 \\ -1 & 0 & 1 \\ -1 & 0 & 1 \end{bmatrix} \quad (3.5)$$

Sobel Kenar bulma algoritması görüntü işlemede en çok kullanılan kenar bulma algoritmasıdır. Bu algorithmada kullanılan G_x ve G_y filtreleri görüntü içerisinde ışık

yoğunluk değişiminin ani olduğu yerleri belirlememize yarar. G_x ve G_y filtreleri Eşitlik 3.6'da verilmektedir.

$$G_x = \begin{bmatrix} 1 & 2 & 1 \\ 0 & 0 & 0 \\ 1 & 2 & 1 \end{bmatrix} \quad G_y = \begin{bmatrix} 1 & 0 & 1 \\ 2 & 0 & 2 \\ 1 & 0 & 1 \end{bmatrix} \quad (3.6)$$

Burada hedef piksel, filtre ile görüntünün kesiştiği piksellerin matrisler çarpımı gerçekleştirilerek hesaplanır. Bu şekilde tüm görüntüye filtreyi taratarak görüntünün kenarları çıkarılır. G_x filtresi görüntüdeki yatay kenarları ortaya çıkarırken, G_y filtresi de dikey kenarları bulmaktadır (Sobel, 1970; Soytürk, 2005).

Canny Kenar İşleci, kenar bulmada son derece etkin bir algoritmadır. Bu algoritmanın çalışma adımları şu şekilde sıralanabilir:

Adım1: Öncelikle görüntü gri seviyeye dönüştürülür.

Adım2: Gri seviyeye dönüştürülen görüntüye Gaussian filtresi uygulanarak gürültüler temizlenir ve kenarların tespit edilmesi kolaylaşır. (σ :Yumuşatma katsayısı)

$$F(x, y) = I(x, y) * G(x, y, \sigma) \quad (3.7)$$

Adım3: Filtreleme sonucu oluşturulan görüntünün kısmi türevleri hesaplanarak her bir noktanın eğim değerleri bulunur.

$$M(x, y) = |\nabla I(x, y)| = \sqrt{\left(\frac{\partial F(x, y)}{\partial x}\right)^2 + \left(\frac{\partial F(x, y)}{\partial y}\right)^2} \quad (3.8)$$

Adım4: Görüntünün eğim değerlerinde maksimum olmayan noktaların bastırılması işlemi uygulanır.

Adım5: Hatalı bulunan kenar noktalarını azaltmak için algoritmanın son adımında $M(x, y)$ 'e bir eşik değeri uygulayarak eşik değerinin altında kalan bütün noktalar arka plan olarak ayarlanır (Canny, 1986; Balcı, 2008).

Canny kenar bulma algoritması uygulanan resmin sonraki hali Şekil 3.13'de gösterilmektedir.



Şekil 3.13. Orjinal görüntü ve kenar bulma algoritması uygulanmış görüntü

Eşikleme

Görüntülerdeki nesneyi arka plandan ayırmak için kullanılan en basit ve en sık kullanılan tekniklerden biridir (Kittler ve Illingworth, 1986; Bin ve Jain, 1997). Genel ve yerel eşikleme gibi iki farklı eşikleme tekniği bulunur. Genel eşiklemede görüntüdeki nesneyi arka plandan ayırmak için sabit bir eşik değeri seçilmektedir. Genel eşikleme kullanım kolaylığı ve daha hızlı sonuç vermesi bakımından daha çok kullanılır. Ancak düz olmayan şekiller içeren görüntülerde yerel eşiklemenin kullanılması gerekmektedir.

Eşikleme yöntemi için öncelikle eldeki veri kümesine uygun eşik değerinin belirlenmesi gerekmektedir. Eşik değerinin belirlenmesi için genellikle görüntü histogramından faydalanılır. Bu yöntemin başarısı daha sonra uygulanacak tekniklerin başarı oranını etkileyeceğinden eşik değerinin doğru seçilmesi oldukça önemlidir. Bunun için eşik değerini otomatik olarak belirleyen çok sayıda yöntem önerilmiştir.

Eşikleme yöntemi görüntülerin farklı özelliklerini birlikte kullanan diğer yöntemlere göre daha hızlı sonuç verir. Bu yöntem çalışmamızda da gerçekleştirdiğimiz endüstriyel ortamlarda ürün kalite kontrolü gibi görüntü işleme uygulamalarında kullanılmaktadır.

Manüel eşikleme, görüntü içerisindeki istenilen nesnelere ön plana çıkartmak için en sık kullanılan eşikleme yöntemlerindedir.

Manüel eşiklemenin çalışma adımları şu şekilde sıralanabilir:

Adım1: Görüntü gri seviye formatına dönüştürülür.

Adım2: Gri seviyeye dönüştürülen görüntünün histogramı çıkarılır.

Adım3: Görüntünün histogramı incelenerek bir eşik değeri belirlenir. Manüel eşikleme yönteminde eşik değeri; histogramın şekline, entropisine, nesne özelliklerine veya yerel uyarlamaya bakılarak seçilmektedir (Ridler ve Calvard, 1978; Otsu, 1979; Yasuda ve ark., 1980; Tsai, 1985; Sezan, 1985; Hertz ve Schafer, 1988; Cheng ve ark., 1999).

Adım4: Seçilen eşik değerinden büyük olan pikseller 1, küçük olan pikseller 0 yapılarak görüntü ikili resme dönüştürülür. Bu ikili resmin 1 olduğu yerler görüntüde ön plana çıkarılmak istenen nesnenin yerlerini gösterirken, 0 olan yerler ise arka planı göstermektedir.

Şekil 3.14'te Manüel eşikleme kullanılarak yapılan görüntü bölütleme işleminin sonucu gösterilmektedir.



Şekil 3.14. Manüel eşikleme örneği (*Eşik değeri = 110*)

Otsu yöntemi ile eşikleme, gri seviye görüntüler üzerinde uygulanabilen bir eşik belirleme yöntemidir. Bu yöntem ile her bir gri seviye tonunun görüntü üzerindeki bulunma sayılarına bakılmaktadır.

Otsu yöntemi ile yapılan eşiklemenin çalışma adımları şu şekilde sıralanabilir:

Adım1: Görüntünün histogramı çıkarılır.

Adım2: Bu histograma bakılarak belirlenen bir k eşiğiyle görüntü C_0 ve C_1 gibi iki sınıfa ayrılır.

Adım3: Belirlenen sınıfların toplam varyansları hesaplanır. ($P_v: v$ pikselinin olasılık yoğunluk fonksiyonu)

$$\sigma_T^2 = \sum_{v=0}^{255} (v - \mu_T)^2 \cdot P_v \quad \mu_T = \sum_{v=0}^{255} v \cdot P_v \quad (3.9)$$

Adım4: Son adımda toplam varyansı en küçük yapan k değeri aranır ve bu değer Otsu yönteminin belirlediği eşik değeri olarak seçilmektedir.

Şekil 3.15’de Otsu yöntemini kullanan görüntü bölütleme sonucu gösterilmektedir.



Şekil 3.15. Otsu yöntemi ile yapılan eşikleme

Histogram grafiğinin çok tepeli olduğu görüntülerde yani renk geçişi sayısının fazla olduğu görüntülerde ön plan ve arka plan gibi iki piksel sınıflandırması yapmak mümkün değildir. Bu nedenle Otsu metodu bu tip görüntülerde istenilen eşik değerlerini belirleyememektedir (Otsu, 1979).

3.3.7. Görüntü İşlemedeki Vektörizasyon Teknikleri

Vektörizasyon, görüntülerden vektörleri bulma işlemidir. Görüntü işleme teknikleri kapsamında günümüzde birçok vektörizasyon tekniği geliştirilmiştir. Görüntülerin vektörizasyonu, döküman ve grafik çizimlerin analizi ve tanınması için yeni olmayan bir konu olmasına rağmen halen mükemmel olmaktan uzaktır ve gelişmeye devam etmekte olan bir konudur (Tombre, 1998). Geleneksel vektörizasyon yöntemleri, bütün mühendislik çizimlerine uygulanmakla birlikte her bir mühendislik alanının kendine has çizim kuralları vardır. Bunları dikkate almadan gerçekleştirilen bir vektörizasyon işlemi yeterince başarılı olamamaktadır (Karabörk ve ark., 2005).

Hough Dönüşümü

Hough dönüşümü, sayısal görüntü işleme, bilgisayar görmesi ve görüntü analizleri için kullanılan bir özellik çıkarma tekniğidir. Hough dönüşümü, kenar bilgisi elde edilmiş gri seviye imgeler üzerine uygulanır. Bu yöntem görüntüdeki şekil bulma problemini yoğunluk bulma problemine dönüştürerek istenilen doğruları ve şekilleri kolaylıkla ortaya çıkarmaktadır. Hough dönüşümü görüntü üzerinde sıfırdan farklı değerler alan her bir nokta için Eşitlik 3.10'da verilen doğru denklemi ile ifade edilmektedir.

$$y = mx + c \quad (3.10)$$

Eşitlik 3.10'da verilen doğru denklemi ile ifade edilen eğim (m) ve doğrunun y eksenini kestiği noktanın (c) hesaplanması sağlanmaktadır. Hough dönüşümü ile önerilen yöntemde Eşitlik 3.10'un Eşitlik 3.11'de verildiği gibi yeniden yapılandırılması gerekmektedir.

$$c = -mx + y \quad (3.11)$$

Eşitlik 3.11 kullanılarak (m, c) katsayılarının en küçük ve en büyük değerleri belirlenir. Her bir (m, c) noktası için bir toplama kümesi oluşturulur. c_{min} 'den c_{max} 'a kadar her c

değerine karşılık gelen m değeri Eşitlik 3.11 kullanılarak hesaplanır, her bir hesap için ilgili toplama hücrelerinin değeri 1 arttırılır. Bu işlem bittiğinde toplama hücreleri yüksek değere sahip olanlar resimde yer alan doğruları gösterir (Safran ve Öktem, 2007).

Bu yöntem daha çok resimdeki doğruların tespitinde kullanılır ancak genelleştirilmiş Hough dönüşümünün kullanılmasıyla matematiksel olarak ifade edilebilen tüm şekillerin görüntülerde tespiti için de kullanılmaktadır (Karabörk ve ark., 2005).

Şekil Tabanlı Teknikler

Şekil tabanlı teknikler, öncelikle görüntülerden kenar bulma algoritmalarını kullanarak şekiller çıkarmakta ve daha sonra bu şekilleri tanımlanan şekillerle eşleştirerek belirlemeyi esas almaktadır. Şekil tabanlı tekniklerin uygulanmasında görüntüdeki kesişme noktalarının oluşturduğu iki önemli sorun tespit edilmiştir. Bu iki sorun küçük açılı kenarları bulunan şekillerde ve çapraz kesişimin bulunduğu şekillerde ortaya çıkmaktadır. Bu nedenle Şekil tabanlı tekniklerin kesişimin ve eğik çizgilerin çok olduğu görüntülerde kullanılması uygun değildir (Liu ve Dori, 1999).

3.4. Görüntü İşlemenin Uygulama Alanları

Görüntü işleme uygulamaları hemen her sektörde uygulanmakta ve bu uygulamaların kullanım alanları giderek artmaktadır. Görüntü işleme teknolojisini kullanan sektörlerle endüstriyel otomasyon, savunma sanayi, tıbbi görüntüleme, trafik denetimi gibi alanlar örnek gösterilebilir.

Örneğin endüstri alanına bakacak olursak üretim bantlarında kameralarla ürünlerin resimleri üzerinde yüzey alanı, hacim, renk analizi gibi işlemler yapıp ürün kalite kontrolünün gerçekleştirilmesi sağlanmaktadır. Tıp biliminde hastalık alanına göre hücrelerin görüntüsü alınarak sağlıklı olup olmadığı kararı verilmektedir. Savunma sanayinde çoğu askeri araç görüntü işleme sistemlerini kullanarak çalışmaktadır (Gonzalez ve Woods, 1993).

3.5. Sınıflandırma

Sınıflandırma, nedeni ve sonucu bilinen örneklerden yararlanarak yeni karşılaşılan bir örnek hakkında yorum yapabilmeyi sağlayan bir işlemdir. Sınıflandırma işleminin amacı, veri gruplarını oluşturan sınıf özellikleri ve bu sınıfların çıkış karakterleri arasındaki ilişkileri keşfetmek ve bu sayede yeni bir veri örneğinin sınıf etiketini tahmin etmektir (Telcioğlu, 2007).

3.5.1. Doğrusal Regresyon

Doğrusal regresyon, giriş çıkış arasında doğrusal bir denklem bulmayı sağlayan analizdir. Başka bir tabirle regresyon analizi, iki değişken arasındaki ilişkinin matematiksel bir denklemle modellenmesidir. Tek değişkenli doğrusal bir regresyon denklemi Eşitlik 3.12’de verilmektedir.

$$Y = \beta_0 + \beta_1 X, i = 1, 2, \dots, n \quad (3.12)$$

Eşitlik 3.12’de yer alan β_0 ve β_1 terimlerinin değerini bulmak için en sık kullanılan yöntem en küçük kareler (EKK) yöntemidir (Chapra ve Canale, 2003). EKK yöntemi, karesel hataların toplamını en küçük yapan denklem katsayılarını bulmaya çalışır. Hata (ε_i) terimini, hesaplanan değer (Y_i) ile beklenen değer (D_i) arasındaki fark oluşturmaktadır ve EKK optimizasyon problemi Eşitlik 3.13’de gösterilmektedir.

$$L = \min\left(\sum_i \varepsilon_i^2\right) = \min\left(\sum_i (D_i - Y_i)^2\right) = \min\left(\sum_i (D_i - (\beta_0 + \beta_1 X_i))^2\right) \quad (3.13)$$

EKK yönteminin β_0 ve β_1 katsayıları hakkındaki tahminlerini elde edebilmek için Eşitlik 3.13’ün bu katsayılarla göre kısmi türevlerini sıfıra eşitleyerek Eşitlik 3.14 elde edilir.


$$\beta_1 = \frac{n \left(\sum_{i=1}^n X_i D_i \right) - \left(\sum_{i=1}^n X_i \right) \left(\sum_{i=1}^n D_i \right)}{n \left(\sum_{i=1}^n X_i^2 \right) - \left(\sum_{i=1}^n X_i \right)^2} \quad (3.14)$$

$$\beta_0 = \frac{\sum_{i=1}^n D_i + \beta_1 \sum_{i=1}^n X_i}{n}$$

Doğrusal, tek değişkenli ve hesaplama karmaşıklığı yönünden düşük maliyete sahip olması sebebiyle önerilen çalışmada sınıflandırıcı olarak öncelikle en küçük karelere dayalı doğrusal regresyon modeli kullanılmıştır.

3.5.2. Çok Katmanlı Sinir Ağı

Çok Katmanlı Sinir Ağı (ÇKSA) doğrusal olmayan aktivasyon fonksiyonu içeren nöronlardan oluşan yapay sinir ağı modelidir. Şekil 3.16'da ÇKSA' da kullanılan nöronların genel görünümü verilmektedir.



Şekil 3.16. ÇKSA ağlarında kullanılan nöron şekli

Şekil 3.16'daki nöronun dört girişi ve tek çıkışı mevcuttur. Verinin her boyutu (i_1, i_2, i_3, i_4) ayrı bir ağırlıkla (w_1, w_2, w_3, w_4) çarpılarak nörona ulaşmakta ve girişler nöronda işlem gördükten sonra üretilen değer y adıyla çıkışa verilmektedir. Nöronun içerisinde iki adet işlem birimi bulunmaktadır. Bunlardan ilki gelen bilgileri toplayan doğrusal birimdir ve toplama sonucunu ikinci birime göndermektedir. İkinci birime giriş olarak hazırlanan n değeri Eşitlik 3.15'de verilmektedir (Bellanger, 2000).

$$n = \sum_k i_k w_k \quad (3.15)$$

İkinci birim, nöronun doğrusal olmayan fonksiyonunu içeren birimdir. Gelen toplam, bu aktivasyon fonksiyonundan geçtikten sonra elde ettiği değeri nöronun çıkışına vermektedir. Nöron çıkışındaki değeri temsil eden y değeri Eşitlik 3.16'da verildiği gibi hesaplanmaktadır.

$$y_{\text{out}} = f(n) \quad (3.16)$$

Eşitlik 3.13'deki f ifadesi tercih edilen aktivasyon fonksiyonunu temsil etmektedir. En sık kullanılan aktivasyon fonksiyonları sigmoid, hiperbolik tanjant ve basamak fonksiyonlarıdır. Her zaman olmasa da her bir aktivasyon fonksiyonunun diğerlerine göre daha başarılı olduğu problemler de mevcuttur.

ÇKSA'da eğitim algoritması olarak genelde geriye yayılım algoritması türevleri kullanılmaktadır. Eğitim algoritması yardımıyla nöronlar arasındaki bağlantıların ağırlıkları ayarlanarak ağın çıkışı optimize edilir. Veride bulunan çıkış değerinin y değeri ile temsil edildiğini kabul edelim. Ağın çıkışında elde edilen y^* değerinin y değerinden farkı yardımıyla ağdaki tüm bağlantıların ağırlıkları güncellenir ve bu güncelleme yapılırken genellikle hedefe yakınsayarak yaklaşan eğim azaltma yöntemi kullanılır. Eşitlik 3.17'de verilen denklemlerin uygulanmasıyla bir ÇKSA üzerinde geri yayılım algoritmasını kullanarak katsayıların güncellenmesi sağlanmaktadır.

$$e = y^* - y$$


$$\varepsilon = \frac{1}{2} e^2 \quad (3.17)$$

$$\Delta w = -\eta \frac{\partial \varepsilon}{\partial w}$$

Eşitlik 3.17’de üç adet birbirinin devamı niteliğinde denklem verilmiştir. Bunlardan ilki daha önce bahsedildiği gibi ağırlık hesapladığı değerin verideki çıkış değerine göre ne kadar saptığını gösteren e değerinin bulunmasını sağlamaktadır. İkinci denklemde ise üzerinde hesaplama yapılan nörona ilişkin ani hata enerjisi (ϵ) değeri hesaplanmaktadır. Son olarak ani hata enerjisinin ilgili nörona gelen tüm bağlantı ağırlıklarına mevcut ağırlıkların (w) tersi oranında dağıtılması yardımıyla her ağırlığın güncellenme miktarı (Δw) hesaplanmaktadır. Her ağırlığın güncelleme miktarı bir öğrenme oranı parametresiyle (η) orantılı şekilde küçültülmektedir. Bu işlem verinin her noktası için tekrarlanmakta ve η parametresi sayesinde bir anlamda bulunan çözümlerin ortalaması hesaplanmaktadır.

3.5.3. Destek Vektör Makinesi

Destek Vektör Makineleri (DVM) istatistiksel öğrenme teorisine dayalı bir sınıflandırıcıdır. DVM’nin çalışma amacı, iki sınıfı birbirinden ayırabilen en uygun karar fonksiyonunun tahmin edilmesi işlemidir (Vapnik, 1995). Bu karar fonksiyonunun bulunmasıyla Şekil 3.17’de gösterildiği gibi eğitim verilerini ayırabilecek en uygun hiper düzlem tespit edilmektedir.



Şekil 3.17. Optimum düzlem ve destek vektörleri

Doğrusal olarak ayrılabilen iki sınıflı bir sınıflandırma probleminde DVM' deki destek vektörlerinin denklemleri Eşitlik 3.18'de verilmektedir.

$$\begin{aligned} w \cdot x + b &= +1 & y = +1 \text{ sınıfı için} \\ w \cdot x + b &= -1 & y = -1 \text{ sınıfı için} \end{aligned} \quad (3.18)$$

Burada y sınıf etiketlerini, w ağırlık vektörünü ve b ise yaklaşım değerini göstermektedir. Optimum düzlem aralığını arttırmak için Eşitlik 3.19'da görüldüğü gibi w değerinin minimum değerde tutulması gerekmektedir.

$$m = \frac{2}{\sqrt{w \cdot w}} \quad f_{min}(w) = \frac{w \cdot w}{2} \quad (3.19)$$

Eşitlik 3.19'a bağlı olarak,

$$y_i(w \cdot x_i + b) - 1 \geq 0 \quad (3.20)$$

elde edilir. Eşitlik 3.20 Lagrange denklemleriyle çözülerek Eşitlik 3.21'de gösterilmektedir.

$$L(w, b, a) = \frac{w^2}{2} - \sum_{i=1}^k a_i \cdot y_i(w \cdot x_i + b) + \sum_{i=1}^k a_i \quad (3.21)$$

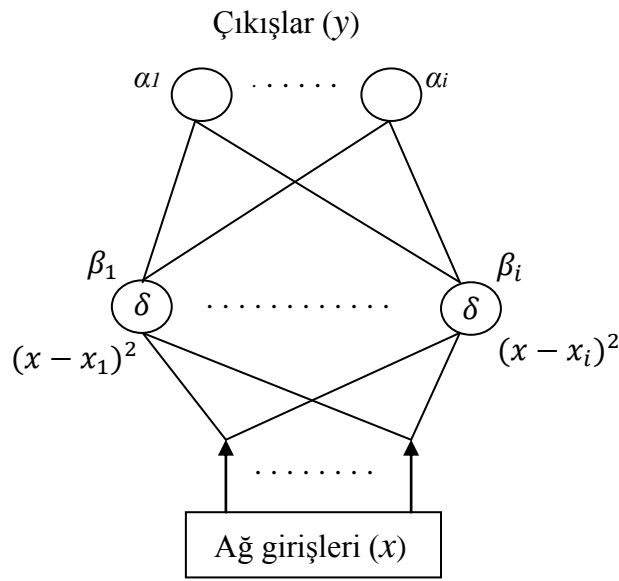
İki sınıflı bir problem için destek vektör makinesinin vereceği karar fonksiyonu Eşitlik 3.22'de verilmektedir (Osuna ve ark., 1997).

$$f(x) = \text{sign}(\sum_{i=1}^k a_i \cdot y_i(x \cdot x_i) + b) \quad (3.22)$$

3.5.4. Genelleştirilmiş Regresyon Sinir Ağı

Genelleştirilmiş regresyon sinir ağları (General Regression Neural Networks - GRNN) radyal tabanlı ağların (RBF) fonksiyon yaklaşırma problemleri için kullandığı

sınıflandırma yöntemidir. GRNN ağı Şekil 3.18’de gösterildiği gibi belirli sayıda gizli katman nöronu kullanarak yüksek bir başarı oranıyla sürekli fonksiyonlara yaklaşım sağlamaktadır. ÇKSA’daki gibi tekrarlı eğitime ihtiyaç duymamaktadır. Eğitim veri kümesinden elde ettiği sonuçları kullanarak fonksiyon yaklaşımında bulunur. Bu durum eğitim kümesindeki veri sayısının artmasının fonksiyon yaklaşımını iyileştirmesini ve sınıflandırmadaki başarı oranının artmasını sağlamaktadır.



Şekil 3.18. Örnek bir GRNN ağı

Şekil 3.18’de gösterilen örnek bir GRNN ağında uygulanan x_i eğitim girişi için gizli katmandaki RBF biriminin çıkışı Eşitlik 3.23’de verilmektedir.

$$\beta_i = \exp \left[-\frac{(x-x_i)^T \cdot (x-x_i)}{2\sigma^2} \right] \quad (3.23)$$

Eşitlik 3.20’de kullanılan σ kullanıcı tarafından tanımlanan yumuşatma parametresidir. Gizli katman sonucu oluşan β_i değerleri kullanılarak Eşitlik 3.24’deki α_i katsayıları elde edilmektedir.

$$\alpha_i = \frac{\beta_i}{\sum_{i=1}^K \beta_i} \quad (3.24)$$

GRNN ađında herhangi bir x giriři için ađın ıkıřı olan y Eřitlik 3.25'deki gibi hesaplanmaktadır (Wong ve ark., 2000).

$$y = \sum_{i=1}^K \alpha_i y_i \quad (3.25)$$

4. BULGULAR VE TARTIŞMA

Önceki bölümde elde edilen veri kümeleri ve anlatılan teknikler kullanılarak farklı deneyler yapılmıştır. Yapılan deneylerde sıvı gıda ürününün paketlenmesi sırasında karşılaşılan boyuna dikiş ve enine dikiş hataları üzerinde durulmuştur. Boyuna dikiş hatası, Yüksek Sıcaklık Yüksek Basınç (YSYB) ve Düşük Sıcaklık Düşük Basınç (DSDB) nedeniyle iki farklı şekilde ortaya çıkmaktadır. Dikişleri incelemek için öncelikle fotoğraf makinesi ile görüntüleme yapılmıştır (Şekil 4.1). Ancak Şekil 4.1’de görüldüğü gibi fotoğraf makinesi kullanılarak yapılan çekimlerde parlamalar oluşmaktadır. Bu parlamalar dikişlerde oluşan hataların net bir şekilde görünmesini engellemiştir. Hataların görünmemesinden dolayı yapılan sınıflandırmalarda başarı oranı oldukça düşük çıkmıştır. Bu nedenle dikişlerin görüntülenmesi için tarayıcı kullanılmasına karar verilmiştir (Şekil 4.2).



Şekil 4.1.

Fotoğraf makinesi ile yapılan çekim



Şekil 4.2.

Tarayıcı ile yapılan çekim

Şekillerde verilen hatalı paket örnekleri DSDB altındaki boyuna dikiş hatalarının örnekleridir. Görüldüğü gibi tarayıcı ile yapılan görüntüleme hatanın daha net ortaya çıktığı tespit edilmiştir.

Görüntüleme cihazının belirlenmesinden sonra dikişlerdeki hataları tespit etmek için kullanılacak görüntü işleme teknikleri araştırılmıştır. Çalışmalar sonucunda kenar bulma algoritmalarının ve eşikleme tekniğinin hatalı bölgeleri net olarak tespit ettiği görülmüştür. YSYB altında oluşan boyuna dikiş hatalarının kenar bulma algoritmaları ile tespit edildiği, enine dikiş ve DSDB altında oluşan boyuna dikiş hatalarının da eşikleme tekniği kullanılarak tespit edildiği belirlenmiştir.

Görüntü işleme teknikleri kullanılarak yapılan analiz sonucunda paketlerdeki dikişlerin durumuyla ilgili karar verilmesi gerekmektedir. Karar aşamasında kullanılacak olan sınıflandırmalar Doğrusal regresyon, ÇKSA, DVM ve GRNN için başarı kriteri olarak, elde edilen doğru sınıflandırma oranlarının ortalaması hesaplanmıştır. Doğru sınıflandırma oranı, tespit sisteminde kullanılan sınıflandırıcının doğru olarak sınıflandırdığı örnek sayısının veri kümesindeki tüm örneklerin sayısına oranı şeklinde hesaplanmaktadır.

4.1. Boyuna Dikiş Hatası Çözümleri

4.1.1. YSYB Boyuna Dikiş Hatası Çözümleri

Bu hata tipinde aseptik kartonlar makine kaynaklı yüksek sıcaklığa ve yüksek basınca maruz kalmaktadır. Bu hata çeşidini incelemek için kullanılan içecek kutularının dağılımı Çizelge 4.1’de verilmektedir.

Çizelge 4.1. YSYB hatası nedeniyle toplanan veri sayısı

Hata Tipi	Toplam Kutu Sayısı	Sağlam Kutu Sayısı	Hatalı Kutu Sayısı
YSYB Boyuna Dikiş Hatası	65	35	30

Özellikle aşırı basınç nedeniyle kartonların dikiş bölgesinde dalgalanmaların olduğu gözlemlenmiştir. Bu durum Şekil 4.3.a'da gösterilmektedir. Sorunsuz paketlerde ise dalgalanmaların olmadığı Şekil 4.3.b'de gösterilmektedir.



a) Sorunlu paket



b) Sorunsuz paket

Şekil 4.3. YSYB Boyuna Dikiş Örnekleri

Hatalı paketlerde oluşan bu dalgalanmaları tespit etmek için kenar bulma algoritmaları kullanılmıştır. Kenar bulma algoritmaları olarak Prewitt, Sobel ve Canny yöntemleri uygulanmıştır.

Prewitt kenar bulma algoritması ile gerçekleştirilen sınıflandırma

Sıcaklık ve basınç değerlerinin fazla uygulanmasından kaynaklanan dalgalanmaları tespit etmek için öncelikle Prewitt çözümü kullanılmıştır. Hatalı ve hatasız paketlerde Prewitt yönteminin uygulanmasıyla elde edilen sonuçlar Şekil 4.4'de gösterilmektedir.



a) Hatalı paket



b) Hatasız paket

Şekil 4.4. Prewitt kenar bulma algoritması ile elde edilen sonuçlar

Şekil 4.4.b'de görüldüğü gibi özellikle hatasız paketlerin çözümünde Prewitt yöntemi sınıflayıcının hata olarak tanınmasını sağlayan gürültüleri de sonuç olarak vermektedir. Bu durum örneklerin sınıflandırması aşamasında hatalı kararlar verilmesine neden olmaktadır. Prewitt yöntemiyle elde edilen sonuçların sınıflandırması için 5 parçalı çapraz geçerlilik içeren doğrusal regresyon kullanılmıştır. Eldeki 65 veri 5 parçaya bölünerek 13'ü eğitim için geri kalan 52'si de test için kullanılmıştır. Eğitim ve test veri kümeleri her iterasyonda değiştirilerek ortalama başarı oranı tespit edilmiştir. Prewitt yöntemiyle elde edilen sonuçların doğrusal regresyon kullanılarak yapılan sınıflandırmasındaki başarı oranı Çizelge 4.2'de sunulmaktadır.


Çizelge 4.2. Prewitt yöntemi ile elde edilen sonuçlar

Hata Tipi	Kullanılan Yöntem	Başarı Oranı(%)
YSYB Boyuna Dikiş Hatası	Prewitt	67,69

Çizelge 4.2’de görüldüğü üzere Prewitt yöntemi kullanılarak yapılan çözüm önerisinde %67,69 gibi düşük bir başarı oranı sağlanmıştır. Bu yöntem ile yapılan sınıflandırmalar incelendiğinde gerçekte hatasız olan paketleri dikişlerin üzerindeki gürültüleri de kenar olarak algıladığından hatalı olarak sınıflandırdığı görülmüştür.

Sobel kenar bulma algoritması ile gerçekleştirilen sınıflandırma

Hatalı paketlerin oluşumuna neden olan dalgalanmaları tespit etmek için kullanılan yöntemlerden birisi de Sobel kenar bulma algoritmasıdır. Hatalı ve hatasız paketlerde Sobel yönteminin uygulanmasıyla elde edilen sonuçlar Şekil 4.5’de gösterilmektedir.



a) Hatalı paket

b) Hatasız paket

Şekil 4.5. Sobel kenar bulma algoritması ile elde edilen sonuçlar

Şekil 4.5’deki hatalı ve hatasız paketler incelendiğinde gürültüler de Prewitt yöntemine göre azalmalar olsa da tam olarak istenilen seviyeye gelinmediği görülmüştür. Sobel yönteminin bulduğu bu sonuçların da hatalı sınıflandırmalar yaptığı görülmüştür. Sobel yöntemiyle elde edilen sonuçların sınıflandırması için aynı şekilde 5 parçalı çapraz

geçerlilik içeren doğrusal regresyon kullanılmıştır. Sobel yöntemiyle elde edilen sonuçların doğrusal regresyon kullanılarak yapılan sınıflandırmasındaki başarı oranı Çizelge 4.3’de gösterilmektedir.


Çizelge 4.3. Sobel yöntemi ile elde edilen sonuçlar

Hata Tipi	Kullanılan Yöntem	Başarı Oranı(%)
YSYB Boyuna Dikiş Hatası	Sobel	73,85

Çizelge 4.3’de görüldüğü üzere Sobel yöntemi ile yapılan sınıflandırma sonucu çıkan başarı oranı %73,85 seviyelerine çıkmıştır. Prewitt yöntemine göre başarı oranı yükselmiş ancak istenilen başarı oranları bu yöntemde de sağlanamamıştır.

Canny kenar bulma algoritması ile gerçekleştirilen sınıflandırma

Hatalı paketlerin oluşumuna neden olan dalgalanmaları tespit etmek için kenar bulmada oldukça etkili bir yöntem olan Canny kenar bulma algoritması kullanılmıştır. Hatalı ve hatasız paket örneklerinde Canny yönteminin uygulanmasıyla elde edilen sonuçlar Şekil 4.6’da gösterilmektedir.



a) Hatalı paket

b) Hatasız paket


Şekil 4.6. Canny kenar bulma algoritması ile elde edilen sonuçlar

Şekil 4.6'daki hatalı ve hatasız paketler incelendiğinde Canny yönteminin diğer iki yöntemle göre gürültüleri oldukça azalttığı görülmektedir. Canny yöntemiyle elde edilen sonuçların sınıflandırılması için de 5 parçalı çapraz geçerlilik içeren doğrusal regresyon kullanılmıştır. Yapılan bu sınıflandırma sonucu elde edilen başarı oranı Çizelge 4.4'te gösterilmektedir.

Çizelge 4.4. Canny yöntemi ile elde edilen sonuçlar

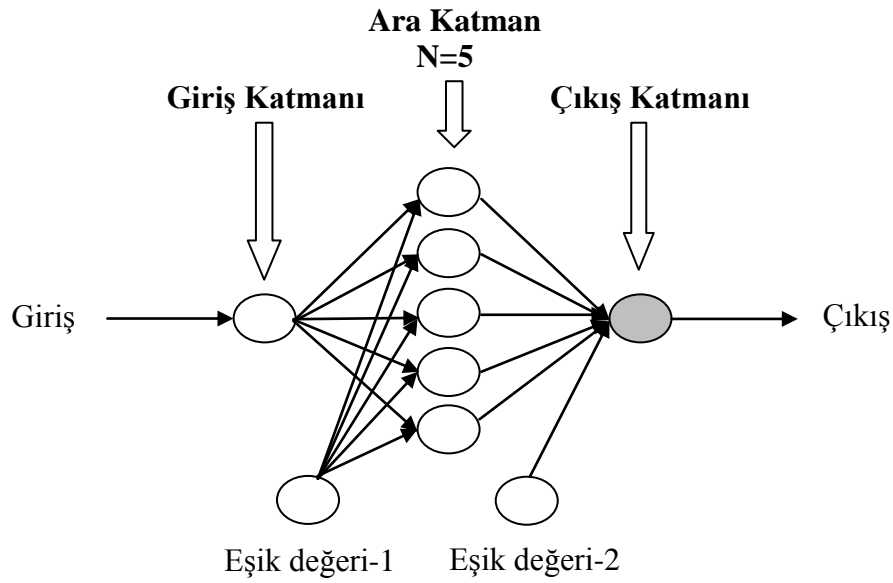
Hata Tipi	Kullanılan Yöntem	Başarı Oranı(%)
YSYB Boyuna Dikiş Hatası	Canny	98,46

Çizelge 4.4'te görüldüğü üzere Canny yöntemi ile yapılan sınıflandırma sonucu %98,46 gibi oldukça yüksek bir başarı oranı sağlanmıştır. YSYB Boyuna dikiş hatasının çözümü için yüksek başarısı nedeni ile Canny kenar bulma algoritması kullanılmıştır. Kenar bulma algoritmalarının doğrusal regresyon ile sınıflandırmaları sonucu çıkan başarı oranları Şekil 4.7'de sunulmaktadır.



Şekil 4.7. YSYB için kenar bulma algoritmalarının doğru sınıflandırma oranları

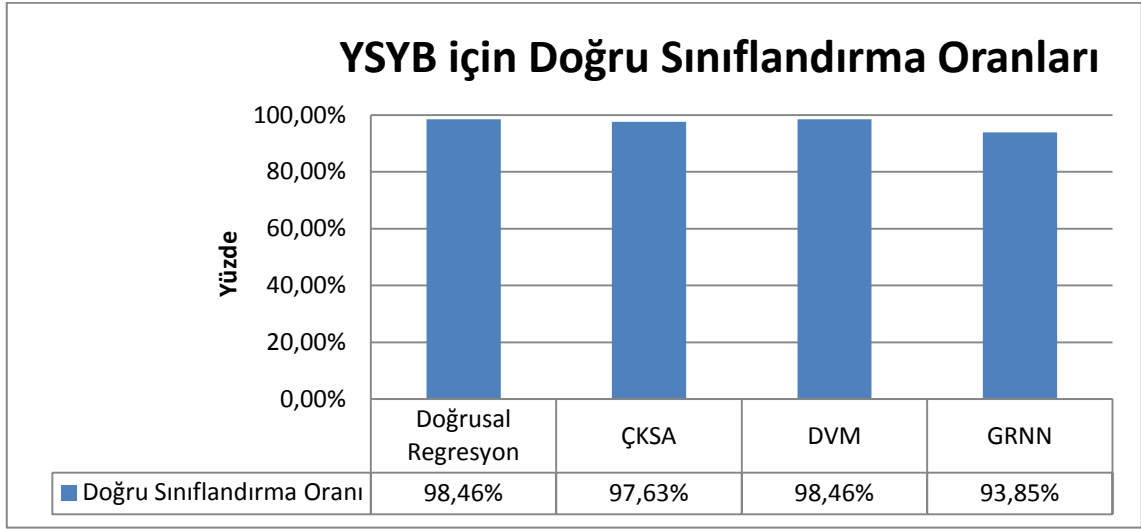
Şekil 4.7’de görüldüğü gibi Canny kenar bulma algoritması diğer algoritmalara göre oldukça başarılı sonuçlar vermektedir. Doğrusal regresyon ile yapılan sınıflandırma sonucunda en başarılı yöntem olan Canny kenar bulma algoritması ayrıca ÇKSA, DVM ve GRNN modelleriyle de sınıflandırmaya tabi tutulmuştur. Buradaki amaç bu dört sınıflandırma arasında karşılaştırma yapmak ve başarı oranını olabildiğince yüksek seviyelere çıkarmaktır. Kullanılan ÇKSA modeli Şekil 4.8’de gösterilmektedir.



Şekil 4.8. Kullanılan ÇKSA Modeli

Kullanılan ÇKSA modelinin gizli katmanında 5 nöron kullanılmıştır. Eğitim algoritması olarak geri yayılım algoritması kullanılmıştır. ÇKSA kullanılarak yapılan sınıflandırma sonucu başarı oranı %97,63 bulunmuştur. DVM modeli kullanılarak elde edilen başarı oranı %98,46 olarak bulunmuştur. GRNN modeli kullanılarak yapılan sınıflandırmada ise %93,85 başarı oranı ile doğru sınıflandırma gerçekleştirilmiştir.

Şekil 4.9’da Doğrusal regresyon, ÇKSA, DVM ve GRNN kullanılarak yapılan sınıflandırma sonuçları karşılaştırılmaktadır.



Şekil 4.9. YSYB hatasının sınıflandırma türlerine göre karşılaştırılması

Doğrusal Regresyon ve DVM modelleriyle yapılan sınıflandırmaların ÇKSA ve GRNN'ye göre daha başarılı sonuç verdiği Şekil 4.9'da gösterilmiştir. Doğrusal Regresyon ve DVM modellerinin de aynı başarı oranı yakaladığı görülmüştür. YSYB altında boyuna dikiş hatasının çözümü için yapılan deneyler sonucunda görüntü işleme tekniği olarak Canny kenar bulma algoritmasının kullanılmasına karar verilmiştir. Bu algoritma sonucu oluşan veri kümesi de ÇKSA ve GRNN modellerine göre daha yüksek başarı sağladığı için Doğrusal regresyon veya DVM ile sınıflandırılabilir.

4.1.2. DSDB Boyuna Dikiş Hatası Çözümleri

Bu hata tipinde aseptik kartonlardaki dikişler makinelerden kaynaklanan hatalar sebebiyle düşük sıcaklık ve düşük basınçla yapıştırılmaktadır. Bu durum dikiş bölgesindeki polietilen tabakanın erimemesine ve gerçekleştirilen dikişin hatalı olmasına sebep olmaktadır. Bu hata çeşidini incelemek için kullanılan içecek kutularının dağılımı Çizelge 4.5'de verilmektedir.


Çizelge 4.5. DSDB hatası nedeniyle toplanan veri sayısı

Hata Tipi	Toplam Kutu Sayısı	Sağlam Kutu Sayısı	Hatalı Kutu Sayısı
DSDB Boyuna Dikiş Hatası	65	35	30

Bu hata tipinde sıcaklığın istenilen seviyelere gelmemesinden dolayı aseptik kartonların dikiş yerlerinin tam olarak yapışmadığı tespit edilmiştir. Bu durum Şekil 4.10'da görüldüğü gibi yapışmayan dikiş bölgelerinin olması gerekenden daha mat bir yapıda olduğu sonucunu çıkarmıştır. Hatasız paketlerde ise bu matlıkların oluşmadığı Şekil 4.11'de gösterilmektedir.




Şekil 4.10. DSDB Hatalı Paket Örneği




Şekil 4.11. DSDB Hatasız Paket Örneği

Hatalı paketlerde oluşan bu renk farklılıklarını tespit etmek için görüntü bölütleme yöntemlerinden eşikleme tekniği kullanılmıştır. Eşikleme yöntemi olarak manüel ve otomatik eşikleme tekniği olan Otsu metodu kullanılmıştır. Bu iki metodun veri kümesi üzerindeki uygulama sonuçları Şekil 4.12 ve Şekil 4.13'de gösterilmektedir.



a) Hatalı b) Hatasız

Şekil 4.12. Manüel Eşikleme

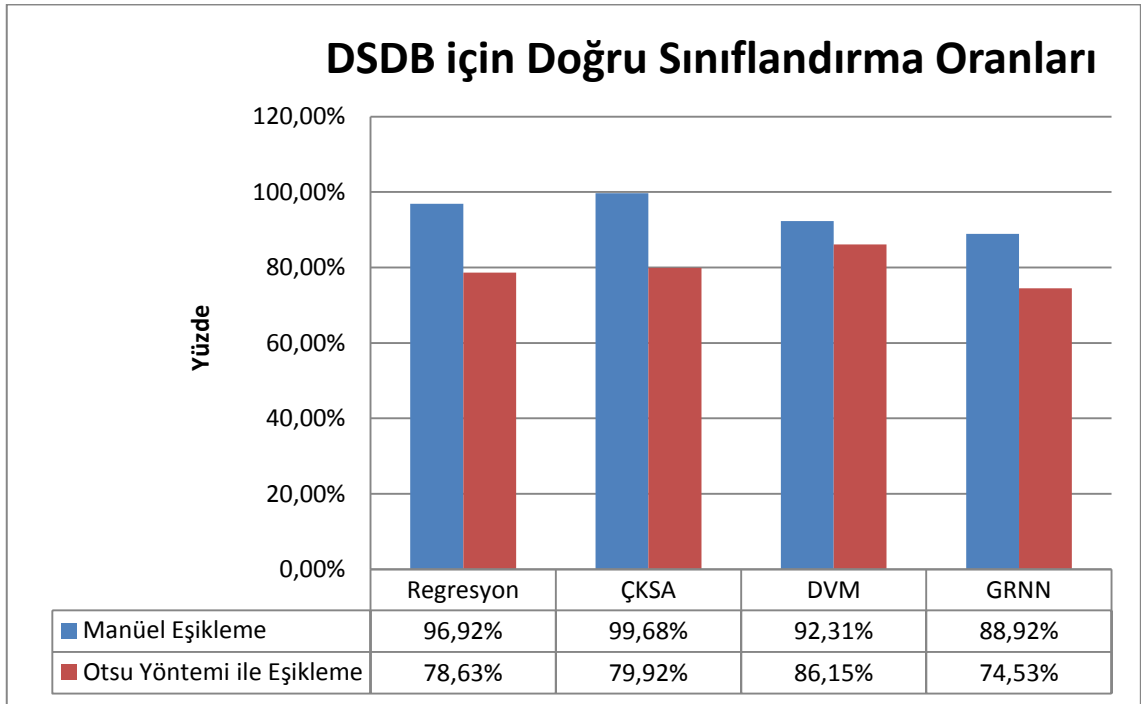


a) Hatalı b) Hatasız

Şekil 4.13. Otsu yöntemi ile eşikleme

Otsu yöntemi kullanılarak yapılan eşiklemede hatalı ve hatasız dikişleri sınıflandırırken hatalı dikiş sonucunun çıkma olasılığı daha yüksektir. Bu durumun nedeni Otsu yöntemiyle yapılan sınıflandırmalar incelendiğinde hatası olmayan dikişleri hatalı dikiş olarak sınıflandırmasından kaynaklanmaktadır (Şekil 4.13). Bu durum doğru sınıflandırma oranını düşürmektedir. Manüel eşiklemede ise hatalı ve hatasız örneklerin histogramları analiz edilmiştir. Bu analiz sonucunda eşik değerinin 210 olarak uygulanmasıyla elde edilen sonuç Şekil 4.12’de gösterilmektedir. Seçilen bu eşik değeri ile yapılan bölütleme sonucu Otsu yöntemi uygulanan sonuçlara göre daha yüksek başarı oranları sağlamaktadır.

Kullanılan eşikleme yöntemlerinin sonuçlarını sınıflandırırken Doğrusal Regresyon, ÇKSA, DVM ve GRNN kullanılmıştır. Doğrusal regresyonun sınıflandırma başarısını genellemek için 5 parçalı çapraz geçerlilik yöntemi kullanılmıştır. Bu şekilde elimizde bulunan 65 DSDB boyuna dikiş örneğinin 13'ü test, kalan 52'si de eğitim için kullanılmıştır. Her iterasyonda bu test ve eğitim veri kümelerinin yerlerini değiştirerek ortalama sınıflandırma başarısı tespit edilmiştir. ÇKSA modelinde aktivasyon için sigmoid fonksiyonu ve eğitim için de geri yayılım algoritması kullanılmıştır. Bu yöntemde modelin tarafsız olarak testine imkan veren rasgele seçimli çapraz geçerlilik yöntemi kullanılmıştır. Çalışmada elde edilen veri kümeleri %40 eğitim, %20 geçerlilik ve %40'ı da test verisi olarak dağıtılarak ortalama başarı oranı tespit edilmiştir. DVM ile yapılan sınıflandırmada çekirdek seçeneklerinden doğrusal, polinomsal ve sigmoid fonksiyonları denenmiştir. Çalışmada en iyi sonuçlar doğrusal fonksiyonlarda elde edildiği için bu çekirdek kullanılmıştır. GRNN sınıflandırıcısında ise başarı oranını hesaplarken 5 parçalı çapraz geçerlilik yöntemi kullanılmıştır. Bu eşikleme yöntemlerine dört farklı sınıflandırma uygulanarak doğru sınıflandırma oranları Şekil 4.14'te karşılaştırılmaktadır.



Şekil 4.14. DSDB için eşikleme yöntemlerinin doğru sınıflandırma oranları

Şekil 4.14'te görüldüğü üzere DSDB Boyuna dikiş hatası için manüel eşikleme tekniğinin Otsu metodu kullanılarak yapılan eşiklemeye göre daha iyi sonuçlar verdiği gözlemlenmiştir. Sınıflandırma yöntemlerinde ise ÇKSA'nın Doğrusal regresyon, DVM ve GRNN'ye göre doğru sınıflandırma oranı daha yüksek çıkmıştır.

DSDB altında Boyuna dikiş hatasının çözümü için yapılan deneyler sonucunda görüntü işleme tekniği olarak Manüel eşikleme yönteminin kullanılmasına karar verilmiştir. Bu algoritma sonucu oluşan veri kümeleri yüksek doğru sınıflandırma oranından dolayı ÇKSA kullanılarak sınıflandırılacaktır.

4.2. Enine Dikiş Hatası Çözümleri

Dikiş işlemini gerçekleştiren makinelerin özellikle kutuların birleşim yerlerine hatalı basınç uygulamaları nedeniyle oluşan hatalara enine dikiş hatası adı verilmektedir. Bu hatalı bölgelerdeki polietilen tabakaların erimemesi kutuların hava almasına neden olmaktadır. Bu durum aseptik kutular içerisindeki içeceklerin üreticiye ulaşmadan bozulmasına ve üretici firmaların zarara uğramasına neden olmaktadır. Bu hata çeşidini incelemek için kullanılan içecek kutularının dağılımı Çizelge 4.6'da verilmektedir.

Çizelge 4.6. Enine dikiş hatası nedeniyle toplanan veri sayısı

Hata Tipi	Toplam Kutu Sayısı	Sağlam Kutu Sayısı	Hatalı Kutu Sayısı
Enine Dikiş Hatası	75	31	44

Bu hata tipinde sıcaklığın istenilen seviyelere gelmemesinden dolayı aseptik kartonların dikiş bölgelerindeki polietilen tabakanın erimediği gözlemlenmiştir. Bu bölgedeki dikişlerin tam olarak yapışmadığı tespit edilmiştir. Bu durum Şekil 4.15'de görüldüğü gibi yapışmayan dikiş bölgelerinin olması gerekenden daha parlak bir yapıda olduğu sonucunu çıkarmıştır. Hatasız paketlerde ise polietilen tabakanın erimesinden dolayı bu parlaklıkların oluşmadığı Şekil 4.16'da gözlemlenmektedir.



Şekil 4.15. Enine Dikiş hatalı kutu örneği



Şekil 4.16. Enine Dikiş hatasız kutu örneği

Hatalı paketlerde oluşan yerel parlamaları tespit etmek için görüntü bölütleme yöntemlerinden eşikleme yöntemi kullanılmıştır. Eşikleme yöntemi olarak manüel ve otomatik eşikleme tekniği olan Otsu metodu kullanılmıştır. Bu iki metodun veri kümesi üzerindeki uygulama sonuçları Şekil 4.17 ve Şekil 4.18’de gösterilmektedir.



a. Otsu yöntemiyle hatalı kutu analizi



b. Otsu yöntemiyle hatasız kutu analizi

Şekil 4.17. Otsu Yöntemi Kullanılarak Enine Dikiş Hatasının Çözümü



a. Manüel Eşikleme yöntemiyle hatalı dikiş analizi




b. Manüel Eşikleme yöntemiyle hatasız dikiş analizi

Şekil 4.18. Manüel Eşikleme Kullanılarak Enine Dikiş Hatasının Çözümü

Şekil 4.17’de görüldüğü gibi Otsu yöntemi enine dikiş hatasının çözümü konusunda başarılı sonuçlar üretememiştir. Yapılan incelemeler sonucunda bu yöntemle bulunan eşik değerinin hatasız paketleri de hatalı paket olarak sınıflandırdığı gözlemlenmiştir. Bu durum yapılan doğru sınıflandırma oranını düşürmektedir.

Manüel eşiklemede ise sorunlu paketlerdeki hatalı olan bölgeler incelendiğinde RGB değerleri 110’dan küçük ve 200’den büyük olduğu tespit edilmiştir. Eşik değeri T ile gösterilirse $T < 110$ ve $T > 200$ kurallarını uygulayarak hatalı bölgeler tespit edilmektedir. Seçilen bu eşik değerleri ile yapılan bölütleme sonucunun Otsu yöntemine göre daha belirleyici sonuçlar çıkardığı Şekil 4.18’de görülmektedir.

Kullanılan bu iki eşikleme yönteminin sonuçlarını sınıflandırırken Doğrusal regresyon, ÇKSA, DVM ve GRNN yöntemleri kullanılmıştır. Dört farklı sınıflandırıcı kullanılarak en iyi başarı oranına ulaşılması amaçlanmaktadır. Doğrusal regresyonun sınıflandırma başarısını genellemek için 5 parçalı çapraz geçerlilik yöntemi kullanılmıştır. Bu şekilde elimizde bulunan 75 enine dikiş örneğinin 15’i test, kalan 60’ı da eğitim için kullanılmıştır. Her iterasyonda bu test ve eğitim veri kümelerinin yerlerini değiştirerek ortalama sınıflandırma başarısı tespit edilmiştir. Kullanılan ÇKSA modelinde aktivasyon için sigmoid fonksiyonu ve eğitim için de geri yayılım algoritması kullanılmıştır. Bu yöntemde modelin tarafsız olarak testine imkan veren rasgele seçimli çapraz geçerlilik yöntemi kullanılmıştır. Çalışmada eldeki veri kümeleri %40 eğitim, %20 geçerlilik ve %40’ı da test verisi olarak dağıtılarak ortalama başarı oranı tespit edilmiştir. DVM ile yapılan sınıflandırmada çekirdek seçeneklerinden doğrusal, polinomsal, sigmoid ve radyal tabanlı fonksiyonlar denenmiştir. Çalışmada en iyi sonuçlar radyal tabanlı fonksiyonlarda elde edildiği için bu çekirdek kullanılmıştır. GRNN sınıflandırıcısında ise başarı oranını hesaplarken 5 parçalı çapraz geçerlilik yöntemi kullanılmıştır. Bu eşikleme yöntemlerine dört farklı sınıflandırma uygulanarak doğru sınıflandırma oranlarına göre karşılaştırması Şekil 4.19’da verilmektedir.



Şekil 4.19. Enine dikiş için eşikleme yöntemlerinin karşılaştırılması

Otsu yöntemi kullanılarak yapılan eşikleme sonucunda DVM sınıflayıcısı kullanılarak ancak %54,67 gibi bir başarı oranı elde edilmiştir. Manüel Eşikleme yöntemi ve ÇKSA sınıflayıcısı kullanıldığında enine dikiş hataları %98,53 gibi yüksek bir başarı oranı ile tespit edilmiştir (Adem ve Orhan, 2013).

Enine Dikiş hatası için yapılan çalışmalar sonucu Şekil 4.19’da görüldüğü üzere Manüel eşikleme yönteminin Otsu yöntemi ile yapılan eşiklemeden daha başarılı olduğu görülmektedir. Bu derece yüksek bir başarı oranının çıkmasında iki farklı eşik değerinin beraber kullanılması oldukça önemlidir. Sınıflayıcı olarak da kullanılan ÇKSA modelinin doğrusal regresyon, DVM ve GRNN modellerine göre daha yüksek başarı oranı sağladığı ortaya çıkmıştır.

4.3. Dikiş Hatalarının Çözümündeki Başarı Oranlarının Karşılaştırılması

Yapılan çalışmalar sonucunda YSYB Boyuna dikiş hatasının çözümü için kenar bulma yöntemleri kullanılmıştır. Enine ve DSDB boyuna dikiş hatalarının çözümü için de görüntü bölütleme yöntemlerinden eşikleme tekniği kullanılmıştır. Kullanılan yöntemler sonucunda oluşan veri kümelerinin sınıflandırılması için genellikle ÇKSA modeli

kullanılmıştır. Çizelge 4.7’de karşılaşılan üç dikiş hatasının tespiti için kullanılan görüntü işleme teknikleri ve sınıflayıcılarına göre elde edilen başarı oranları gösterilmektedir.

Çizelge 4.7. Tüm dikiş hataları için kullanılan teknikler ve başarı oranları

Hata Tipi	Veri Sayısı	Gör. İşl. Tekniği	Sınıflandırıcı	Başarı Oranı (%)
YSYB Boyuna	65	Prewitt Kenar B.	Regresyon	67,69
			ÇKSA	69,13
			DVM	64,36
			GRNN	65,23
		Sobel Kenar B.	Regresyon	73,85
			ÇKSA	75,24
			DVM	70,38
			GRNN	71,63
		Canny Kenar B.	Regresyon	98,46
			ÇKSA	97,63
			DVM	98,46
			GRNN	93,85
DSDB Boyuna	65	Manüel Eşikleme	Regresyon	96,92
			ÇKSA	99,68
			DVM	92,31
			GRNN	88,92
		Otsu yöntemi	Regresyon	78,63
			ÇKSA	79,92
			DVM	86,15
			GRNN	74,53
Enine	75	Manüel Eşikleme	Regresyon	97,33
			ÇKSA	98,53
			DVM	97,33
			GRNN	87,31
		Otsu yöntemi	Regresyon	48,67
			ÇKSA	52,48
			DVM	54,67
			GRNN	51,76

Çizelge 4.7’de görüldüğü üzere 3 hata çeşidi için de %98’in üzerinde doğru sınıflandırma oranları elde edilmiştir. Kullandığımız yöntemler ile en yüksek başarı %99,68 başarı oranı ile DSDB Boyuna Dikiş hatası çözümünde elde edilmiştir.

4.4. En Başarılı Yöntemlerin ROC Eğrileri

ROC eğrisi, test işlemi sırasında karar vermek amacıyla kullanılan bir değişkenin aldığı tüm değerlerin hesaplanacak duyarlılık değerlerinin, yanlış pozitif oranına (1 - özgüllük) karşı noktalanması ile elde edilir. ROC eğrilerinin altında kalan alan incelenerek sınıflandırmanın doğruluğu hakkında yorum yapılabilmektedir. ROC eğrisinin oluşturulacağı koordinat sisteminde, Y ekseninde tanılama testinin gerçek pozitif değerleri (duyarlılık), X ekseninde ise yanlış pozitif değerleri (1-özgüllük) yer alır. Her noktadaki doğru pozitif ve yanlış pozitive karşılık gelen noktalar birleştirilerek ROC eğrisi çizdirilmektedir (Hanley ve McNeill, 1983). İki sınıflı bir veri kümesinin ROC eğrisini çizmek için dört parametre kullanılır. Bunlar pozitif örnek doğru sınıflandırıldığında Doğru Pozitif (DP), yanlış sınıflandırıldığında Yanlış Pozitif (YP) olarak ifade edilirken, Negatif örnek doğru sınıflandırıldığında Doğru Negatif (DN) ve yanlış sınıflandırıldığında Yanlış Negatif (YN) olarak ifade edilir. Doğru Pozitif Oranı ve Yanlış Pozitif Oranı Eşitlik 4.1 ve 4.2 kullanılarak hesaplanmaktadır.

$$\text{Doğru Pozitif Oranı} = \frac{DP}{DP+YN} \quad (4.1)$$

$$\text{Yanlış Pozitif Oranı} = \frac{YP}{YP+DN} \quad (4.2)$$

Buradan elde edilen değerlere göre hata matrisi ise Şekil 4.20’de gösterilmektedir.

		Gerçek sınıf	
		Pozitif	Negatif
Tahmin edilen sınıf	Pozitif	Doğru Pozitif (DP)	Yanlış Pozitif (YP)
	Negatif	Yanlış Negatif (YN)	Doğru Negatif (DN)

Şekil 4.20. Hata Matrisi

4.4.1. YSYB Boyuna dikiş çözümü için ROC eğrisi

YSYB Boyuna dikiş hatasının sınıflandırması sonucunda oluşan duyarlılık ve özgüllük değerleri Eşitlik 4.1 ve 4.2’de hesaplanmaktadır.

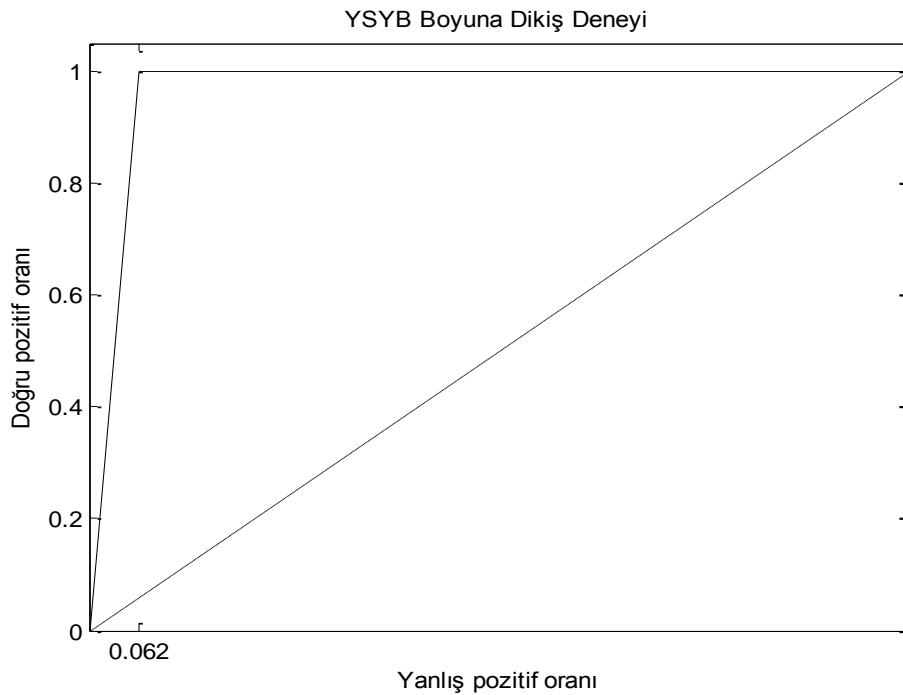
$$\text{Duyarlılık} = \text{DP Oranı} = \frac{DP}{DP+YN} = \frac{30}{30+2} = 0,938 \quad (4.3)$$

$$\text{Özgüllük} = (1 - \text{YP Oranı}) = \left(1 - \frac{YP}{YP+DN}\right) = \left(1 - \frac{0}{0+33}\right) = 1 \quad (4.4)$$

YSYB Boyuna dikiş hatası için hesaplanan değerler kullanılarak oluşturulan hata matrisi Şekil 4.21’de, ROC eğrisi ise Şekil 4.22’de gösterilmektedir.

		Gerçek	
		Pozitif	Negatif
Tahmin	Pozitif	30	0
	Negatif	2	33

Şekil 4.21. YSYB Boyuna Dikiş Hata Matrisi



Şekil 4.22. YSYB Boyuna dikiş hatası için çizdirilen ROC eğrisi

Doğru sınıflandırma yapılan bir analizde ROC eğrisi (0,0), (0,1) ve (1,1) noktalarını birleştirmektedir. Hatalı sınıflandırmalar gerçekleştiren bir çalışmada ise ROC eğrisi (0,0) dan (1,1) e kadar 45 açı yaparak uzanan köşegen şeklindedir. Yapılan test işleminde sınıflandırma oranı ne kadar yüksekse eğri sol üst köşeye doğru kaymaktadır. Oran düşük çıktığında da eğri Şekil 4.22’de gösterilen kesikli çizgiye yaklaşmaktadır. Gerçekleştirilen testlerde sorunsuz ve hatalı paketleri ayırmadaki doğruluk oranını belirlemek için ROC eğrisinin altında kalan alan kullanılmaktadır. ROC eğrisinin altında kalan alanın büyüklüğü yapılan sınıflandırmanın doğruluğunu göstermektedir. YSYB Boyuna dikiş hatası için çizdirilen ROC eğrisi $1-0,938=0,062$ ’de 1 değerine ulaşmıştır.

4.4.2. DSDB Boyuna dikiş çözümü için ROC eğrisi

DSDB Boyuna dikiş hatasının sınıflandırması sonucunda oluşan duyarlılık ve özgüllük değerleri Eşitlik 4.5 ve 4.6’da hesaplanmaktadır.

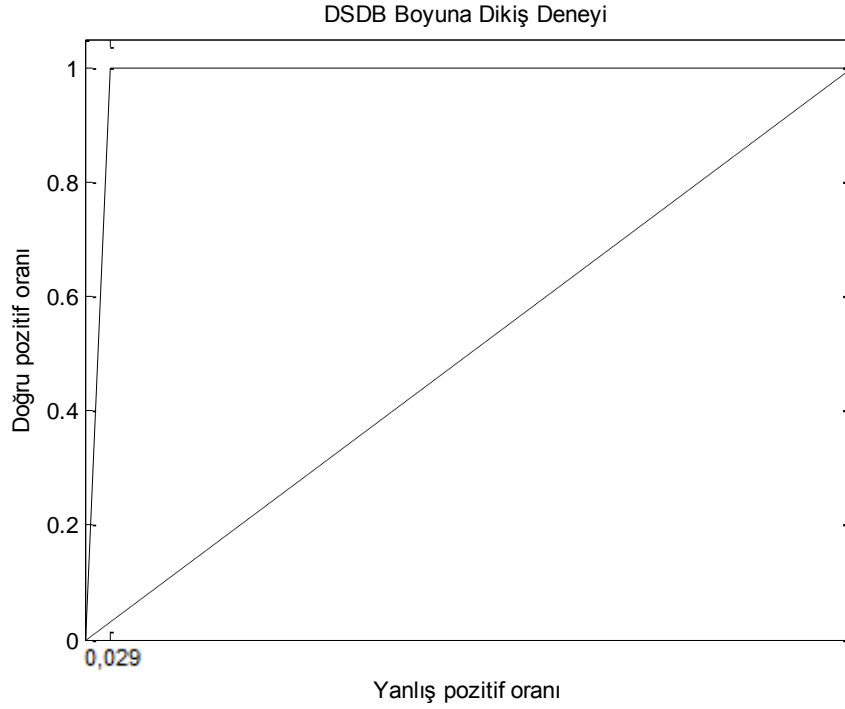
$$\text{Duyarlılık} = \text{DP Oranı} = \frac{DP}{DP+YN} = \frac{34}{34+0} = 1 \quad (4.5)$$

$$\text{Özgüllük} = (1 - \text{YP Oranı}) = \left(1 - \frac{YP}{YP+DN}\right) = \left(1 - \frac{1}{1+33}\right) = 0,971 \quad (4.6)$$

DSDB Boyuna dikiş hatası için hesaplanan değerler kullanılarak oluşturulan hata matrisi Şekil 4.23’de, ROC eğrisi ise Şekil 4.24’te gösterilmektedir.

		Gerçek	
		Pozitif	Negatif
Tahmin	Pozitif	34	1
	Negatif	0	30

Şekil 4.23. DSDB Boyuna Dikiş Hata Matrisi



Şekil 4.24. DSDB Boyuna dikiş hatası için çizdirilen ROC eğrisi

DSDB Boyuna dikiş hatası için çizdirilen Şekil 4.24'de verilen ROC eğrisi $1 - 0,971 = 0,029$ 'de 1 değerine ulaşmıştır.

4.4.3. Enine dikiş çözümü için ROC eğrisi

Enine dikiş hatasının sınıflandırması sonucunda oluşan duyarlılık ve özgüllük değerleri Eşitlik 4.7 ve 4.8'de hesaplanmaktadır.

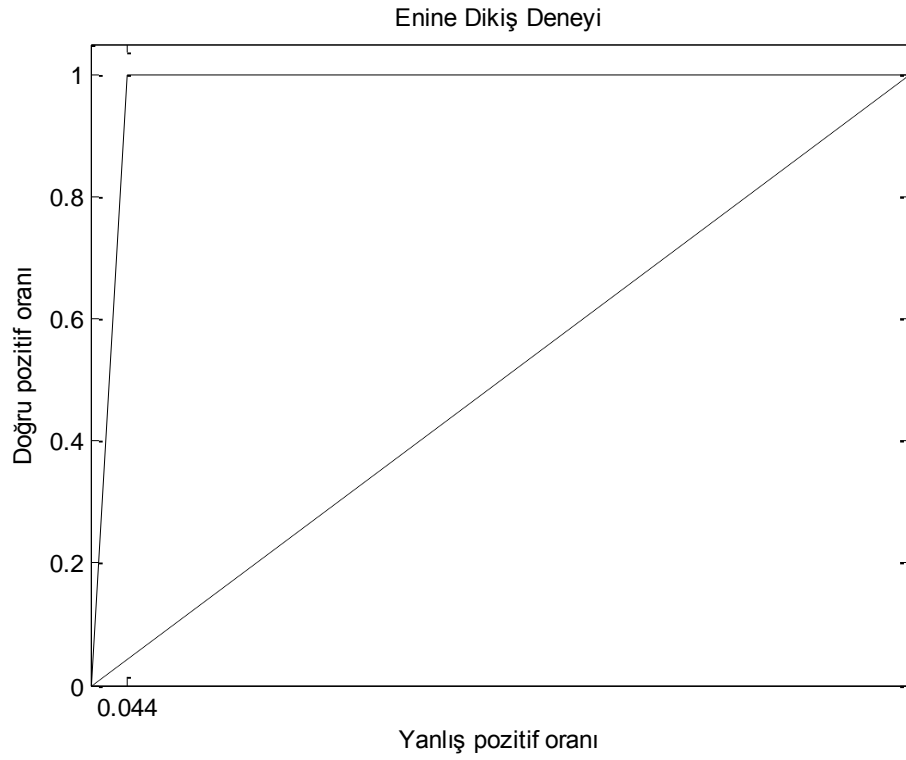
$$\text{Duyarlılık} = DP \text{ Oranı} = \frac{DP}{DP+YN} = \frac{44}{44+2} = 0,956 \quad (4.7)$$

$$\text{Özgüllük} = (1 - YP \text{ Oranı}) = \left(1 - \frac{YP}{YP+DN}\right) = \left(1 - \frac{0}{0+29}\right) = 1 \quad (4.8)$$

Enine dikiş hatası için hesaplanan değerler kullanılarak oluşturulan hata matrisi Şekil 4.25'de, ROC eğrisi ise Şekil 4.26'da gösterilmektedir.

		Gerçek	
		Pozitif	Negatif
Tahmin	Pozitif	44	0
	Negatif	2	29

Şekil 4.25. Enine Dikiş Hata Matrisi



Şekil 4.26. Enine dikiş hatası için çizdirilen ROC eğrisi

Enine dikiş hatası için çizdirilen Şekil 4.26'da verilen ROC eğrisi $1-0,956=0,044$ 'de 1 değerine ulaşmıştır. YSYB Boyuna dikişde 0,062 değerinde, DSDB Boyuna dikiş hatasında 0,029 değerinde ve Enine dikiş hatasında ise 0,044 değerinde 1 seviyesine ulaştığı görülmektedir. DSDB Boyuna dikiş hatasında daha erken 1 seviyesine ulaşıldığı için en başarılı sınıflandırma bu hata türünde gerçekleştirilmiştir.

5. SONUÇLAR

Sıvı gıda imalatının gerçekleştirildiği işletmelerde Tetra Brik Aseptik kartonlardaki şerit dikişlerin kalite kontrol işlemi kalite uzmanı işçiler tarafından yapılmaktadır. İyi bir kalite uzmanının yetişmesi yıllar sürmektedir ayrıca bu kişilerin yetişmesi ciddi bir mali yük oluşturmaktadır. Bu sorunların çözümü için yapılan çalışmada kalite kontrolünün bilgisayar destekli bir sistem tarafından gerçekleştirilmesi hedeflenmiştir.

Çalışmada öncelikle kalite kontrol uzmanı yardımıyla karşılaşılabilecek hata çeşitleri belirlenmiştir. Belirlenen hata çeşitlerinin çözümü için kullanılacak görüntü işleme teknikleri araştırılmıştır. Bu araştırmalar sonucunda eşikleme ve kenar belirleme yöntemlerinin kullanılmasına karar verilmiştir. Eşikleme yöntemi olarak Manüel eşikleme ve Otsu yöntemi ile yapılan eşikleme kullanılmıştır. Manüel eşikleme yönteminin daha başarılı sonuçlar verdiği belirlenmiştir. Kenar belirleme yöntemlerinden ise Sobel, Prewitt ve Canny algoritmaları dikiş hatalarının tespiti için kullanılmıştır. Canny algoritmasının diğer iki yönteme göre daha başarılı sonuçlar verdiği gözlenmiştir. Kullanılan görüntü işleme yöntemleri sonucunda oluşturulan veri kümelerine doğrusal regresyon, ÇKSA, DVM ve GRNN gibi farklı sınıflandırıcılar uygulanarak hatalı-hatasız paket ayrımı gerçekleştirilmiştir. Bu dört sınıflandırma yönteminin sonuçları karşılaştırılarak doğru sınıflandırma oranı artırılmıştır. Yapılan deneysel çalışmalar sonucunda ÇKSA modelinin sınıflayıcılar arasında daha başarılı olduğu tespit edilmiştir.

Şerit dikişlerin hata kontrolleri üzerine yapılan bu deneyler sonucunda bilgisayarlı kalite kontrolü literatürünün büyük bir kısmının üstünde başarı elde edilmiştir. Dolayısıyla önerilen çalışma, ürün kalitesini etkileyen ve büyük bir maliyete neden olan Tetra Brik Aseptik karton kutularda şerit dikiş kontrolünün bilgisayar destekli sistemler tarafından yapılabilmesi konusunda ümit vericidir.

Yapılan tez çalışmasındaki teknikler kullanılarak veri sayılarının da artmasıyla sanayide kullanılmak üzere gerçek zamanlı olarak dikişlerin kalite kontrolünü gerçekleştiren bir

ürün tasarlanması düşünülmektedir. Böylece hatalı paketlenen sıvı gıda üretimi ve buna bağlı olarak üretim maliyeti de oldukça azalacaktır.

KAYNAKLAR

- Adem, K. ve Orhan, U., 2013. Tetra Brik Aseptik Kartonlarda Enine Dikişlerin Görüntü İşleme Tabanlı Kalite Kontrolü, 21. Sinyal İşleme ve İletişim Uygulamaları Kurultayı, 24-26 Nisan, KKTC.
- Anonim, 2013. Gerçek Renk Algılama. <http://www.abkontrol.com/Makale/25/GENEL-Gercek-Renk-Algılama> (04.04.2013).
- Balcı, K., 2008. Üretim otomasyonunda görüntü tabanlı hata tanıma sistemi. (Yüksek Lisans Tezi), Yıldız Teknik Üniversitesi. Fen Bilimleri Enstitüsü, İstanbul.
- Bastı M., 2007. Renk Modelleri. <http://www.fatih.edu.tr/~mbasti/Ders/RENK.ppt> (05.04.2013).
- Becker F. ve Menz G., 2011. Shadow analysis in the urban area of Cologne using very high resolution optical satellite data. 31st EARSeL Symposium and 35th General Assembly, Prague, Czech Republic.
- Bellanger, M., 2000. Digital Processing of Signal: Theory and Practice, John Wiley and Sons, USA.
- Bin Y. ve Jain A.K., 1997. Address Block Location on Complex Mail Pieces. Accepted for oral presentation at the International Conference on Document Analysis and Recognition, 18-20 Ağustos, Ulm, Germany.
- Canny, J., 1986. A Computational Approach to Edge Detection, IEEE Transactions on Pattern Analysis and Machine Intelligence, 679-700.
- Chapra, C.C. ve Canale, R.P., 2003. Numerical Methods For Engineers. McGraw– Hill.
- Cheng H.D., Chen, Y.H., Sun, Y., 1999. A novel fuzzy entropy approach to image enhancement and thresholding. Signal Processing. 75, 277-301.
- Conci A. ve Proença C. B., 2000. A computer vision approach to textile inspection. Text. Res. J. 70, 347-350.
- Çayırılı, M., 2006. Yanma Olayının Modellenmesi ve Görüntü İşleme Yoluyla Yanma Performansının Optimizasyonu. (Yüksek Lisans Tezi) Süleyman Demirel Üniversitesi. Fen Bilimleri Enstitüsü, Isparta.
- Çelik H. İ., Dülger L. C., Topalbekiroğlu M., 2012. Görüntü İşleme Teknikleri Kullanarak Kumaş Hatalarının Belirlenmesi. Tekstil Teknolojileri Elektronik Dergisi, 6(1), 22-39.

- Dinnage D. F., 1983. Aseptic Processing of liquids in Proceedings of the National Food Processors Association Conference, Washington DC, s. 31.
- Edizer, E., 2006. Sayısal Görüntü İşleme Yöntemi ile Tane Boyut Dağılımı Analizi. (Yüksek Lisans Tezi), Çukurova Üniversitesi. Fen Bilimleri Enstitüsü, Adana.
- Eriksson, M. ve Papanikotopoulos, N.P., 1997. Eyetracking for Detection of Driver Fatigue, IEEE Conference On Intelligent Transportation System, ITSC '97, 314-319, Boston.
- Gonzalez, R.C. ve Woods, R.E., 1993. Digital Image Processing SE. Addison-Wesley Publishing Company, USA.
- Hanley J.A. ve McNeil B.J., 1983. The meaning and use of the area under a receiver operating characteristic curve , Radiology, 143, 29-36.
- Hertz, L. ve Schafer, R., 1988. Multilevel thresholding Using Edge Matching. CVGIP, 44, 279-295.
- Jasper, W. J. ve Potapalli, H., 1995. Image analysis of mispicks in woven fabrics. Text. Res. J., 65, 683-692.
- Karabörk, H., Gündüz, M., Bildirici, İ.Ö., Yıldız, F., 2005. Raster görüntülerin vektörizasyonları ve Jeodezi ve Fotogrametri mühendisliğindeki önemi. TMMOB Harita ve Kadastro Odası 10. Türkiye Harita Bilimsel ve Teknik Kurultayı, Ankara.
- Kılınç, B., Çaklı, Ş., 2001. Paketleme Tekniklerinin Balık ve Kabuklu Su Ürünleri Mikrobiyal Florası Üzerine Etkileri. Ege Üniversitesi Su Ürünleri Dergisi, 18 (1-2), 279-291.
- Kısaoğlu, Ö., 2006. Kumaş Kalite Kontrol Sistemleri. Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi, 12 (2), 233-241.
- Kittler, J. ve Illingworth J., 1986. Minimum Error Thresholding. Pattern Recognition, 19 (1), 41-47.
- Kumar, A., 2003. Neural network based detection of local textile defects, Pattern Recognition, 36, 1645–1659.
- Kumar, P., Simunovic, J., Swartzel, K. R., 2010. Aseptic Processing and Packaging. In Encyclopedia of Agricultural, Food and Biological Engineering, New York, 87-90.
- Kuo C.F.J. ve Lee C., 2003. A back-propagation neural network for recognizing fabric defects. Textile Research Journal, 73 (2), 147–151.

- Kuo C.F.J., Lee C., Tsai C., 2003. Using a Neural Network to Identify Fabric Defects in Dynamic Cloth Inspection. *Textile Research Journal*, 73 (3), 238–244.
- Liu, W. ve Dori, D., 1999. From Raster to Vectors: Extracting Visual Information From Line Drawing. *Pattern Analysis & Applications*, 2, 10-21.
- Majumdar, A., Ghosh, A., Saha, S.S., Roy, A., Barman, S., Panigrahi, D., Biswas, A., 2008. Empirical Modelling of Tensile Strength of Woven Fabrics. *Fibers and Polymers*, 9 (2), 240-245.
- Merchant, S. ve Schnell, T., 2000. Applying Eye Tracking As An Alternative Approach for Activation of Controls and Functions in Aircraft. *DASC, The 19th Digital Avionics Systems Conferences*, Philadelphia.
- Osuna, E.E., Freund, R., Girosi, F., 1997, Support Vector Machines: Training and Applications, Massachusetts Institute of Technology and Artificial Intelligence Laboratory, Massachusetts. Pal, M., Mather, 1602, 144.
- Otsu, N., 1979. A threshold selection method from gray level histograms. *IEEE Transactions on Systems, Man and Cybernetics*, 9 (1), 62-66.
- Paine, F.A., 1992. *A Handbook of Food Packaging*. Chapman Hall, London, UK.
- Polat, R., 2007. *Biyomedikal Görüntü Bölütleme. (Yüksek Lisans Tezi)*, Fırat Üniversitesi. Fen Bilimleri Enstitüsü, Elazığ.
- Prewitt, J., 1970. *Object Enhancemet and Extraction. Picture Processing and Psychopictorics*, Academic Pres, NY.
- Ridler, T.W. ve Calvard, S., 1978. Picture Thresholding Using an iterative selection Method. *IEEE Transactions on Systems, Man, and Cybern.*, 8 (8), 632-632.
- Safran, M.İ. ve Öktem, R., 2007. *Hızlı Hough Dönüşümü Yaklaşıklığı ve Çubuk Kod Tespitine Uygulanması. Sinyal İşleme ve İletişim Uygulamaları*, Eskişehir.
- Sarabandi, P., Yamazaki, F., Matsuoka, M., Kiremidjian, A., 2004. Shadow Detection and Radiometric Restoration in Satellite High Resolution Images. *Geoscience and Remote Sensing Symposium Proceedings*.
- Sezan, M.I., 1985. A Peak Detection Algorithm and its Application to Histogram-Based Image Data Reduction. *CVGIP*, 29, 47-59.
- Sobel, I., 1970. *Camera Models and Perception. (Doktora Tezi)*, Stanford Üniversitesi. CA.
- Soytürk M.A., 2005. *Sayısal Kenar Çıkarma ve Yapay Sinir Ağları Yardımıyla Araç Tanıma. (Yüksek Lisans Tezi)*, Erciyes Üniversitesi. Fen Bilimleri Enstitüsü, Kayseri.

- Stojanovic R., Mitropulos P., Koulamas C., Karayiannis Y., Koubias S., Papadopoulos G., 2001. Real-time vision-based system for textile fabric inspection. *Real-time Imaging*, 507–518.
- Tombre K., 1998. Analysis of Engineering Drawings: State of the Art and Challenges. *Proceedings of the Graphics Recognition-Algorithms and Systems*, 257-264.
- Telcioğlu, B., 2007. Veri madenciliğinde genetik programlama temelli yeni bir sınıflandırma yaklaşımı ve uygulaması. (Yüksek Lisans Tezi), Erciyes Üniversitesi. Fen Bilimleri Enstitüsü, Kayseri.
- Tsai, W.H.,1985. Moment-preserving thresholding: A new approach. *Graphical Models and Image Processing*, 19, 377-393.
- Umbaugh, S.E., 1998. *Computer Vision and Image Processing*. Prentice-Hall, International Inc., Upper Saddle River, New Jersey.
- Üçüncü, M., 2011. *Gıda Ambalajlama Teknolojisi*. Ambalaj Sanayicileri Derneği, İstanbul.
- Vapnik, V., 1995. *The Nature of Statistical Learning Theory*. Springer-Verlag, New York.
- Wong, H. S., Wu, M., Joyce, R. A., Guan, L., Kung, S. Y., 2000. A Neural Network Approach for Predicting Network Resource Requirements in Video Transmission Systems. *Proceedings Of Ieee Pacific rim Conference On Multimedia*.
- Yasuda, Y., Dubois, M., Huang, T.S., 1980. Data Compression for check Processing Machines. *Proceeding of IEEE*, 68 (7), 874-885.
- Yılmaz, İ., 2002. Renk Sistemleri, Renk Uzayları ve Dönüşümler. Selçuk Üniversitesi Jeodezi ve Fotogrametri Mühendisliği Öğretiminde 30. Yıl Sempozyumu,16-18 Ekim, Konya
- Young I.T., Gerbrands J.J., van Vliet L.J., 2002. *Image Processing Fundamentals*.
- Zeydan, M., 2010. Prediction of Fabric Tensile Strength By Modelling the Woven Fabric. *Woven Fabrics*.
- Zhang Y., Lu Z., Li J., 2010. Fabric defect classification using radial basis function network. *Pattern Recognition Letters*, 31 (13), 2033–2042.

ÖZGEÇMİŞ**Kişisel Bilgiler**

Adı Soyadı : Kemal ADEM
Doğum Tarihi ve Yeri : 15.07.1987 - MALATYA
Medeni Hali : Evli
Yabancı Dili : İngilizce
Telefon : 533 4959916
e-mail : kemal.adem@gop.edu.tr

Eğitim

Derece	Eğitim Birimi	Mezuniyet Tarihi
Lisans	Fırat Üniversitesi, Elazığ	2008
Lise	Malatya Lisesi, Malatya	2004

İş Deneyimi

Yıl	Yer	Görev
2011-Devam e.	Gaziosmanpaşa Üni., Tokat	Öğretim Görevlisi
2009-2011	Harran Üni., Şanlıurfa	Bilgisayar Mühendisi