

**EGE ÜNİVERSİTESİ FEN BİLİMLERİ ENSTİTÜSÜ**

**(YÜKSEK LİSANS TEZİ)**

**GÖRÜNTÜ İŞLEME TEKNİĞİ İLE EKMEKLİK BUĞDAY  
ÇEŞİDİNDE KALİTEYE ESAS BAZI ÖZELLİKLERİN  
BELİRLENMESİ**

**Abbas MASOUMI**

**Tez Danışmanı: Prof.Dr. Engin ÇAKIR**

**Tarım Makinaları Anabilim Dalı**

**Bilim Dalı Kodu: 501.08.00**

**Sunuş Tarihi: 01.02.2013**

**Bornova-İZMİR**

**2013**



Abbas MASOUMI tarafından Yüksek Lisans tezi olarak sunulan “Görüntü İşleme Tekniđi ile Ekmeklik Buđday eşidinde Kaliteye Esas Bazı Özelliklerin Belirlenmesi” başlıklı bu alıřma E.Ü. Lisansüstü Eđitim ve Öđretim Yönetmeliđi ile E.Ü. Fen Bilimleri Enstitüsü Eđitim ve Öđretim Yönergesi’nin ilgili hükümleri uyarınca tarafımızdan deđerlendirilerek savunmaya deđer bulunmuř ve 01.02.2013 Tarihinde yapılan tez savunma sınavında aday oybirliđi/oyokluđu ile başarılı bulunmuřtur.

**Jüri Üyeleri:**

**İmza**

**Jüri Başkanı** : **Prof.Dr. Engin AKIR** .....

**Raportör Üye** : **Do.Dr. Hüseyin GÜLER** .....

**Üye** : **Yrd.Do.Dr. Haldun SARNEL** .....



**ÖZET****GÖRÜNTÜ İŞLEME TEKNİĞİ İLE EKMEKLİK BUĞDAY  
ÇEŞİDİNDE KALİTEYE ESAS BAZI ÖZELLİKLERİN****BELİRLENMESİ**

MASOUMI, Abbas

Yüksek Lisans Tezi, Tarım Makinaları Anabilim Dalı

Tez Danışmanı: Prof.Dr. Engin ÇAKIR

Şubat 2013, 131 sayfa

Tarımsal ürünlerde kalite, pazarlamada önemli faktörlerden biridir. Bu nedenle, kalite kontrol sistemlerinde sınıflandırma makineleri önemli bir yer tutar. Günümüzdeki sınıflandırma makinelerindeki en etkin yöntem görüntü işlemedir.

Bu çalışmanın amacı, CUMHURİYET-75 ekmeçlik buğday çeşidinin bazı kalite kriterlerinin; kırık tane, yabancı ot (yabani hardal ve yabani yulaf), ve diğçer hububat (mısır ve arpa), “MATLAB” programı yardımıyla görüntü işleme ve yapay sinir ağı (YSA) tekniklerini kullanarak belirlenmesidir. Bu amaçla, farklı oranlarda yabancı madde, kırık tane ve diğçer hububatların bulunduğçu bir birinden ayrı olarak yerleřtirilmiř 100 taneden oluřan buğday örneklerinin görüntüleri bir dijital kamera vasıtasıyla 3 farklı arka plan ve 3 farklı ışık ortamında alınarak, Matlab programında yapay sinir ağıları yöntemiyle deęerlendirilmiřtir.

Buğday örneklerinin kalitesinin belirlenmesinde deęerlendirme kriteri olarak tahıl morfolojisi, doku ve rengi dikkate alınmıřtır. Buğday örneklerinden görüntü alabilmek için görüntüleme odası hazırlanmıř ve örneklere ait resimleri işlemek için Matlab’da bir program yazılmıřtır. Morfoloji özellikleri için tohumların alanı ve 16 faktör seçilmiřtir. Doku özellikleri için, kontrast, homojenlik, korelasyon, enerji ve entropi hesaplanmıřtır. Renk özellikleri için, görüntülerin ortalaması, varyans, standart sapma, çarpıklık ve basıklık deęerleri RGB (Kırmızı, Yeřil, Mavi), NTSC ve l\*a\*b\* renk uzaylarında çıkarılmıřtır.

Daha etkili parametreleri belirlemek için, SPSS yazılım paketi ile kademeli diskriminant analizi her tane için yapılmıřtır. SPSS sonuçlarından, 6 morfoloji özellikleri, 1 doku ve 11 renk özellikleri bir Çok Katmanlı Perseptron (ÇKP) YSA’nın girişleri olarak elde edilmiřtir.

En iyi YSA belirlemek için farklı yapılarda ađlar kurulmuřtur. En iyi YSA'da verilerin % 60 eđitim ařamasında, onaylama için % 20 ve test edilmesi için ise % 20 kullanılmıřtır. Buđday kalitesinin belirlenmesinde genel bařarı oranı % 97 olarak elde edilmiřtir.

**Anahtar szckler:** Buđday kalitesi, Grnt iřleme, Sınıflandırma, Yapay sinir ađları, Diskriminant analiz.

**ABSTRACT****DETERMINATION OF SOME QUALITY PARAMETERS  
OF BREAD WHEAT WITH IMAGE PROCESSING**

MASOUMI, Abbas

Master of Science thesis, Department of Agricultural Machinery

Supervisor: Prof. Dr. Engin ÇAKIR

February, 2103, 131 pages

Quality of agricultural products is one of the most important factors in marketing. For this reason, grading machineries have a great impact on quality control systems. The most efficient method in the present grading machineries is of image processing.

The objective of this study was to determine some quality parameters; broken kernels, foreign materials (*Sinapis Arvensis* and *Avena sterilis*), other cereals (corn and barley) by using image processing and artificial neural network (ANN) with Matlab software. For this purpose, samples of one layer of 100 singulated wheat kernels including different percentage of broken kernels, foreign materials and other cereals were prepared and their images were taken by digital camera under 3 different backgrounds with 3 different illuminations. Later, images were evaluated with Matlab software using artificial neural network.

The evaluation criteria for determining the quality of the wheat kernels were based on grain morphology, texture and colour. In order to capture images from the samples, an image chamber was developed and a program was coded in Matlab for segmentation of the samples. Area and 16 factors for describing shapes of grain were chosen as morphology features. For texture features; entropy, contrast, correlation, homogeneity, and energy, for colour features; average, standard deviation, variance, skewness and kurtosis values of images in RGB, NTSC and  $l^*a^*b^*$  colour spaces were extracted.

To identify the best classification parameters, a total of 6 morphological features, 1 texture and 11 color features were extracted from color images of kernels by stepwise discriminant analysis with the SPSS software package and used as inputs to a Multi-layer Perceptron (MLP) neural network.

Networks with different configurations to determine the best neural network has been established. In the best neural network, 60 % images were used in the training stage of ANN, 20 % images for validation, and testing of the ANN was performed with 20 % images. The overall success classification rate was 97 %.

**Keywords:** Wheat quality, Classification, Image processing, Artificial neural network, Discriminant analysis.



## TEŞEKKÜR

Yüksek lisans öğrenimime başladığım günden bu yana çalışma konusunun seçimi, yürütülmesi, değerlendirilmesi ve yazım aşamalarında her zaman destek ve katkılarını yanımda gördüğüm, danışman hocam Sayın Prof.Dr. Engin ÇAKIR' a en içten saygı ve teşekkürlerimi sunarım. Bu çalışma süresince gerekli denemelerin yapılmasında yardımcı olan Yard.Doç.Dr. Haldun SARNEL uzman Nebahat KULDEMİR, ve arkadaşlarım İkbal AYGÜN, Masud GHARIBKHANI, ve ayrıca Toprak Mahsülleri Ofisi (TMO) verdiği katkılardan dolayı teşekkür ederim.



**İÇİNDEKİLER**

	<u>Sayfa</u>
ÖZET.....	v
ABSTRACT.....	vii
TEŞEKKÜR.....	ix
ŞEKİLLER DİZİNİ.....	xvii
ÇİZELGELER DİZİNİ .....	xx
1. GİRİŞ .....	1
2. GÖRÜNTÜ İŞLEME TEKNİĞİ.....	5
2.1 Sayısal Görüntünün Gösterimi .....	7
2.2 Görüntü Hazırlama ve İyileştirme.....	8
2.3 Gri Seviye Dönüşümü.....	9
2.4 Histogram İşleme .....	10
2.5 Görüntü Filtreleme .....	12
2.6 Bölümlendirme (Segmentasyon).....	14
2.7 Eşikleme (Thresholding).....	15
2.8 Görüntü Yapısal İşlemleri.....	16
2.9 Birbirleriyle İlişkili Piksel Gruplarının Etiketlenmesi (Labeling) .....	19

**İÇİNDEKİLER (devam)**

	<u>Sayfa</u>
2.10 Renk Temelleri ve Modelleri .....	21
2.11 Doku Hesaplamaları .....	26
2.12 Yapay Sinir Ağları .....	29
2.12.1 Çok katmanlı perseptron .....	35
2.12.2 Geriye yayılım algoritması .....	36
2.13 Görüntü İşleme Sistemleri .....	37
2.13.1 Çevrenin aydınlatılması .....	37
2.13.2 Çevre aydınlatma yolları .....	40
3. ÖNCEKİ ÇALIŞMALAR .....	41
4. MATERYAL VE YÖNTEM .....	47
4.1 Materyal .....	47
4.2 Yöntem .....	48
4.2.1 Görüntü hazırlama .....	48
4.2.2 Görüntü işleme ön hazırlık .....	50
4.2.3 Morfolojik özelliklerinin belirlenmesi ve çıkartılması .....	51
4.2.4 Renk özelliklerinin belirlenmesi ve çıkartılması .....	55

**İÇİNDEKİLER (devam)**

	<u>Sayfa</u>
4.2.5 Doku özelliklerinin belirlenmesi ve çıkartılması .....	56
4.2.6 Özelliklerin seçiminde sınıflandırma modeli .....	58
4.2.7 Yapay sinir ağları ile taneleri tanıma .....	59
5. ARAŞTIRMA BULGULARI ve TARTIŞMA .....	63
5.1 Kırık Tane Analizleri .....	63
5.2 Yabancı Ot Tohumların Analizleri.....	66
5.2.1 Yabani hardal analizleri .....	66
5.2.2 Yabani yulaf analizleri .....	68
5.3 Diğer Hububat Tohumların Analizleri .....	71
5.3.1 Mısır analizleri .....	71
5.3.2 Arpa analizleri .....	73
5.4 Son Analizler .....	76
6. SONUÇLAR VE ÖNERİLER .....	85
KAYNAKLAR DİZİNİ .....	87
ÖZGEÇMİŞ .....	91
EKLER .....	.....

## İÇİNDEKİLER (devam)

Sayfa

EK 1. Segmentasyon sonuçları.....	
EK 2. Spss diskriminant analiz sonuçları (kırık dane) .....	
EK 3. Spss diskriminant analiz sonuçları (yabancı madde) .....	
EK 4. Spss diskriminant analiz sonuçları (diğer hububat) .....	
EK 5. Tohumların özellik değerlerinin gösterimi .....	

## ŞEKİLLER DİZİNİ

<u>Şekil</u>	<u>Sayfa</u>
2.1 Görüntü işleme .....	5
2.2 Sayısal görüntülerin koordinat düzleminde gösterimi.....	8
2.3 Farklı $\gamma$ değerleri için muhtemel dönüşüm eğrileri.....	10
2.4 Bazı görüntülere ait histogram grafikleri .....	11
2.5 Histogram eşitleme yapılmış görüntüler .....	12
2.6 3X3 lük bir maske ile, maskenin resim üzerinde uygulanma yapısı .....	14
2.7 Genişleme işlemi .....	17
2.8 Aşınma işlemi .....	18
2.9 Açma ve kapama işlemi .....	19
2.10 Piksel komşuluk setleri .....	20
2.11 Etiketleme (Labelling) .....	20
2.12 Görünür ışığı da içeren elektromanyetik spektrum.....	21
2.13 XYZ renk modeli.....	22
2.14 RGB birim renk küpü.....	23
2.15 RGB ve HSI renk modelleri arasındaki ilişki, renk özü ve doygunluk bileşenlerinin gösterimi .....	24

## ŞEKİLLER DİZİNİ (devam)

<u>Şekil</u>	<u>Sayfa</u>
2.16 Referans bir piksele göre hedef piksel gösterim yönleri.....	28
2.17 a. Pencere pozisyonu 1 iken sonuç matrisine değer aktarılması b. Pencere pozisyonu 2 iken sonuç matrisine değer aktarılması .....	29
2.18 Bir nöronun blok diyagram gösterimi .....	31
2.19 Doğrusal fonksiyon. ....	32
2.20 Sigmoid fonksiyon .....	32
2.21 Tanjant hiperbolik fonksiyon. ....	33
2.22 İleri beslemeli (a) ve geri beslemeli (b) ağ yapıları .....	34
2.23 Çevre aydınlatma yolları.....	40
4.1 Floresan lamba ve tungsten ışık aydınlatma.....	48
4.2 Farklı deneme ortamlarında çekilen fotoğraflar .....	49
5.1 Kırık tane için YSA'nın eğitim, durdurma ve test performansı .....	65
5.2 Kırık tane için YSA ve deneysel sonuçların karşılaştırılması .....	65
5.3 Yabani hardal için YSA'nın eğitim, durdurma ve test performansı .....	68
5.4 Yabani hardal için YSA ve deneysel sonuçların karşılaştırılması .....	68
5.5 Yabani yulaf için YSA'nın eğitim, durdurma ve test performansı .....	70



**ŞEKİLLER DİZİNİ (devam)**

<u>Şekil</u>	<u>Sayfa</u>
<b>5.6</b> Yabani yulaf için YSA ve deneysel sonuçların karşılaştırılması.....	70
<b>5.7</b> Mısır için YSA'nın eğitim, durdurma ve test performansı .....	72
<b>5.8</b> Mısır için YSA ve deneysel sonuçların karşılaştırılması .....	72
<b>5.9</b> Arpa için YSA'nın eğitim, durdurma ve test performansı .....	74
<b>5.10</b> Arpa için YSA ve deneysel sonuçların karşılaştırılması.....	76
<b>5.11</b> Son analiz'de YSA'nın yapısı.....	83
<b>5.12</b> Son analiz'de YSA'nın eğitim, durdurma ve test korelasyon değeri .....	83
<b>5.13</b> Son analiz'de YSA'nın eğitim, durdurma ve test performansı.....	84
<b>5.14</b> Son analiz'de YSA'nın gerçek değer ile tahmin edilen değerler arasındaki ortalama sapma .....	84

## ÇİZELGELER DİZİNİ

<u>Çizelge</u>	<u>Sayfa</u>
<b>1.1</b> Buğday kalitesini etki eden faktörler.....	3
<b>3.1</b> Bazı gıda ürünlerine ait fiziksel özelliklerin tespiti için yapılan çalışmalar..	41
<b>3.2</b> Gıda ürünlerinin sınıflandırılmasında kullanılan bazı yöntemler .....	42
<b>4.1</b> Denemelerde kullanılan kameraya ait teknik özellikler .....	47
<b>4.1</b> Görüntü önişlemeyi gerçekleştiren kod parçası .....	51
<b>5.1</b> Kırık tane ve buğday ayırımında diskriminant analiz sonuçları .....	64
<b>5.2</b> Yabani hardal ve buğday ayırımında diskriminant analiz sonuçları.....	67
<b>5.3</b> Yabani yulaf ve buğday ayırımında diskriminant analiz sonuçları .....	69
<b>5.4</b> Mısır ve buğday ayırımında diskriminant analiz sonuçları .....	71
<b>5.5</b> Arpa ve buğday ayırımında diskriminant analiz sonuçları.....	73
<b>5.6</b> Son analizde seçilmiş özellikler .....	77
<b>5.7</b> Kurulan bazı ağların topolojisi.....	78
<b>5.8</b> Sinir ağların tahmin ettiği değerlerin hata oranları.....	79
<b>5.11</b> Bazı seçilmiş deney noktaları için gerçek-tahmin değer performansı .....	81

## 1. GİRİŞ

Buğday, insan ve hayvan beslenmesinde çok önemli bir yere sahip olan bir kültür bitkisidir. Dünya’da ve Türkiye’de ekiliş ve üretim açısından ilk sırada yer almaktadır. Dünya’da her yıl işlenen toprakların 1/6’sını tek başına buğday kaplamaktadır (Elçi vd. 1994). 2011 yılı IGC1 (uluslararası tahıl konseyi) verilerine göre Dünya’ da buğday ekim alanı 221,1 milyon ha olup, üretimi ise 695,5 milyon tondur. Aynı yıl itibariyle Türkiye’de ise 8,0 milyon ha alanda 18,8 milyon ton buğday üretilmiştir. Türkiye buğday üretiminde dünya’ da dokuzuncu sırada yer almaktadır. Türkiye’de buğdayın verimi, dünya buğday veriminden düşüktür. Türkiye buğday verimi 244.11 kg/da, dünya buğday verimi ise 300.92 kg/da’ dır (Anonim 2011).

Bu araştırmada Türkiye’de üretilen buğdaylar içinden Cumhuriyet-75 çeşidi seçilmiştir. Kılçıklı, çıplak beyaz kavuzludur. Yumuşak yapıda, Rengi çok beyaz olup, eliptik-uzun, orta geniş bir taneye sahiptir. Beyaz buğdaylar içinde en iri olanıdır. 1000 tane ağırlığı 50-54 gr’dır. Yazlık gelişme tabiatlıdır. Kışa dayanması sahil bölgeleri için iyi, kurağa dayanması orta, erkenci ve yüksek verimli bir çeşittir. Bu buğdayın verimi 280 kg/da dır. Gübreye karşı reaksiyonu iyidir. Tane dökmez ve harman olma kabiliyeti iyidir. Kara ve kahverengi pasa dayanıklı, sarı pasa hassas, septoria’ya orta derecede dayanıklı, rastık ve sürmeye hassastır. Sahil kuşağında, kır-taban sahalarda ekimi tavsiye edilir(Anonim 2011).

Buğdayda verim ve kalite; bölgelere ve yıllara göre kuraklık, kış zararı, sıcak stresi ve mikro element noksanlığı gibi cansız etmenler ile hastalık ve zararlılar gibi canlı etmenler tarafından önemli derecede etkilenmektedir. Ülkemizde buğday verimi ve kalitesi büyük ölçüde;

- ekimde toprağın nem durumuna,
- ürün üzerine düşen yağış miktarı ve yağışın yıl içindeki dağılımına,
- aşırı soğuk ve sıcaklar ile kuru rüzgârlara (sam yeline)

---

<sup>1</sup> International Grain Council

- hastalıkların ve süne zararlısının epidemi seviyelerine bağlı olarak değişmektedir.

Ayrıca işlenecek nihai ürüne göre buğdayın kalite kriterleri değişir. İstenen kalite kriterleri buğdaydan elde edilecek ekmek (somun), pide, lavaş, yufka, bisküvi, pasta, şehriye ve makarna ürünlerine göre özellik arz eder. Örneğin buğday üreticisi için yetiştirdiği buğdayın saf, temiz ve sağlıklı olmasını ister ve bu kriterler mahsulün pazar kalitesi ile doğrudan ilgilidir. Değirmenci için Una işleyeceği buğdayın temiz, beyaz un randımanının yüksek ve una işleme anında sarfedilen enerjiyi minimize edecek buğday tipi arzu eder. Buğdaylar TS 2974 buğday standardına göre tür ve alt türlerine göre, tane rengi ve tane yapılarına göre, alt sınıflara ve belli faktörlere göre de kalite derecelerine ayrılmışlardır. Bu standardizasyondaki kalite dereceleri, toprak mahsulleri ofisi hububat alım ve satış esaslarına ilişkin uygulama yönetmeliği Çizelge 1.1' de verilmiştir.

Buğday'ın satışa sunulmasından önce, fiyat tespitinde önemli bir kriter olan kalite belirleme işlemi, laboratuarlarda yapılmakta ve bunun için 20'ye yakın personel uzun ve zahmetli bir işlem ile kaliteyi belirlemeye çalışmaktadır. Laboratuarlarda insan işgücü kullanılarak yapılan kalite belirleme sadece uzun bir zaman dilimine ihtiyaç duymasının yanında, aynı zamanda maliyetli bir işlem olup insan hatasını da içermektedir. Bu çalışmada, buğday'da kalite belirlenmesinde görüntü işleme tekniği kullanarak, bu işlem için gereken süre ve maliyeti minimuma indirgenmesi amaçlanmıştır.

Bu amaçla, Cumhuriyet-75 ekmeçlik buğday çeşidinin bazı kalite kriterleri; kırık tane, yabancı madde (yabani hardal ve yabani yulaf), ve diğer hububat (mısır ve arpa), "MATLAB" programı yardımıyla görüntü işleme ve yapay sinir ağı tekniklerini kullanarak belirlenmiştir. Farklı oranlarda yabancı madde, kırık tane ve diğer hububatların bulunduğu bir birinden ayrı olarak yerleştirilmiş 100 taneden oluşan buğday örneklerinin görüntüleri bir dijital kamera vasıtasıyla 3 farklı arka plan ve 3 farklı ışık ortamında alınmış ve görüntüler MATLAB programına aktararak, sinir ağı tekniği yardımıyla buğday kalitesi belirlenmiştir.

**Çizelge 1.1** Buğday Kalitesini etki eden faktörler

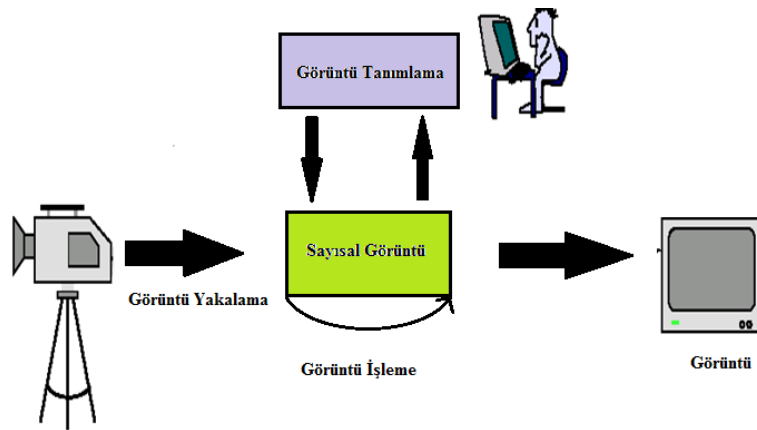
	1.Derece	2.Derece	3.Derece	Yemlik Buğday
Hektolitre (Kg/hl)	78	76	73	72
Protein (%)	12	11	10	ARAMAZ
Kırık Tane (%)	0-3	3.1 - 6	6.1 - 8	8.1 – 18
Diğer Hububat (%)	2	4	5	14
Haşere Tahribatına Uğramış Tane (%)	1	2	3.5	14
Embriyosu Kararmış Tane (%)	EN FAZLA (%8)			14
Kurutma Esna.Fazla Isıya Mar. Kal. Tane (%)	0	EN FAZLA (%5)		
Süne Kıvımlı Tahribatına Uğramış Tane (%)	1	2	3.5	14
Kısmen veya Dönmeli Tane (%)	1	2	3.5	14
Lekli Benekli Fusarium Etkisinde Kal.Tane (%)	EN FAZLA (%1.5)			
Çimlenmiş Filizlenmiş Taneler (%)	0	2.5	4	4.1 VE USTU
Zararlı Ot Tohumları (%)	EN FAZLA (%1)			
Kızışmış ve Kurutma Esna.Yanmış Taneler (%)	0	EN FAZLA (%1)		
Sürme ve Rastıklı Buğday (%)	EN FAZLA (%0.6)			
Yabancı Madde (%)	0.5	0.51 -1	1.01 - 2	2.01 – 3
Çavdar Mahmuzu (%)	0	EN FAZLA ( %0.5 )		
Çürümüş Taneler (%)	0	EN FAZLA ( %5)		
Diğer Muhtelif Maddeler (%)	En fazla (%3)			
Rutubet	En fazla (%14.5)			



## 2. GÖRÜNTÜ İŞLEME TEKNİĞİ

İlk görüntü transferi 1920’de Londra ile New York arasında, deniz altından çekilen bir kablo ile gerçekleştirilmiştir. Bu kablolu görüntü transfer sistemi sayesinde Atlantik üzerinden daha önceleri en az bir haftada yapılabilen görüntü transferi işlemi 3 saatten daha az bir sürede gerçekleştirilmiştir. 1960’ların başında sayısal görüntü işleme uygulamalarını gerçekleştirebilecek bilgisayarların geliştirilmesi ile görüntü işleme uygulamalarında büyük atılımlar görülmüştür. Bu döneme denk gelen ve Amerika Birleşik Devletleri’nin uzay programında olan ay yüzeyinin incelenmesi çalışmalarında, gönderilen uzay aracı tarafından çekilen ay yüzeyi görüntülerindeki bozuklukların giderilmesi ve görüntü kalitesinin artırılması işlemlerinde, sayısal görüntü işlemenin önemi bir kez daha gösterilmiştir. Uzay uygulamalarına paralel olarak, 1970’lerin başında, tıp alanında, ücra yeryüzü kaynaklarının tespitinde ve astronomi alanlarında da görüntü işleme uygulamaları yaygın olarak uygulanmaya başlanmıştır. Yine, 1970’lerin başında bilgisayarlı tomografinin (Computerized Axial Tomograph, CAT) keşfiyle, görüntü işlemenin en önemli uygulama alanı olan tıbbi teşhis ortaya çıkmıştır (Gonzales ve Woods, 2008).

Günümüzde görüntü işleme tekniğinden çeşitli amaçlar için kullanılmaktadır. Görüntü işleme, sayısal tip video kamera veya kamerayla elde edilen görüntülerin bilgisayar ortamına uygun dosyalar halinde aktarılması ve özel programlar aracılığıyla, saklanması, değerlendirilmesi ve incelenmesi olarak tanımlanabilir (şekil 2.1) (Anonim 1999).



Şekil 2.1 Görüntü işleme.

Görüntü, bir ya da daha fazla sayıda doğal veya yapay ışık kaynağı tarafından aydınlatılmış bir nesneden yayılan ışık ışınlarının, bir görüntü yüzeyi üzerinde toplanarak sözkonusu nesnenin görüntüsünün elde edilmesidir (Chelappa and Sanvchuk 1985). Resim, şekil veya fotoğraf şeklinde olabilen görüntü, bir şeklin veya nesnenin görsel ifadesidir (Niblack, 1986).

Görüntü işleme tekniğinde ölçüm sistemi; girdi, işleme ve çıktı birimlerinden oluşmaktadır. Bir görüntü işleme sisteminde en önemli birim girdi birimidir. girdi birimi; görüntülerin fotoğraflanmasında ya da görüntülerin bilgisayarın anlayacağı hale dönüştürülmesinde kullanılan dijital fotoğraf makinası, tarayıcı, kamera vb.'lerini içermektedir. Günümüzde üretilen dijital fotoğraf makinaları CCD (Charge Coupled Device) denilen ışığa duyarlı elektronik hücrelerden oluşmuş bir alet yardımıyla görüntüyü oluştururlar. CCD'ler ışığı algılayıp düşük gerilimde elektrik akımına dönüştürürler. Bir analog çevirici yardımıyla bu elektrik akımı dijital ortama bit'ler olarak aktarılmaktadır. Görüntü, şeklin yada fotoğrafın eninde ve boyunda bulunan piksel sayısı ile tanımlanmaktadır. Piksel, kare şeklinde olan görüntünün en küçük birimidir. Dijital görüntüler yan yana gelen pikseller topluluğundan oluşur (Anonim 2003). İşleme birimi ise bilgisayar ve görüntü işleme programından oluşmaktadır. Son olarak çıktı birimi, monitör ve yazıcıyı kapsamaktadır.


Görüntü işleme uygulamalarını geliştirmek, gerçekleştirmek, eğitimini vermek klasik programlama dilleri ve teknikleri ile mümkündür. Uygulamada çok çeşitli görüntü işleme programları vardır. UTHSCSA Image Tool, Nih Image, Scion Image, ImageJ, Optimas, Win/MacCAM, MATLAB, PC Image, Mac and Windows Lispix, VayTek Image bunlardan bazılarıdır. Bu programlar değişik amaçlar için tasarlanmış programlardır. Bu nedenle görüntü işleme algoritmalarına yönelik fonksiyon kütüphaneleri bazı programlama dillerine eklenmiş ve hazır araçlar geliştirilmiş, hatta bu işlemlere yönelik özel programlama dilleri geliştirilmiştir (MATLAB Image Processing Toolbox User Guide, 2009).



## 2.1 Sayısal Görüntülerin Gösterimi

Sayısal görüntü, analog bir görüntünün sayısallaştırılarak, piksellerden oluşan bir görüntüdür. Sayısal bir görüntü, m adet satır ve n adet sütundan oluşan bir matris olduğu kabul edilerek, her bir satır ve sütunun kesiştiği kare bir piksel olarak adlandırılmaktadır. Her piksel noktasında görüntünün o noktadaki parlaklığını ve koyuluğunu bir tamsayı ile temsil edilmektedir. Bu işlem tüm pikseller için yapıldığında, görüntü tamsayılardan oluşan iki boyutlu bir dizi şeklinde ifade edilebilir hale gelmektedir (Gonzales ve Woods, 2008).

Sayısal görüntü, iki boyutlu tam sayılardan oluşmuş bir matristir ve her bir renk bandı için bir dizi iki boyutlu tamsayı ile ifade edilebilmektedir. Sayısallaştırılmış parlaklık değerleri, gri seviyesi değerleri olarak adlandırılmaktadırlar. Görüntüyü oluşturan her bir dizi elemanı da bir piksel olmaktadır. Bazı görüntüler yüzlerce hatta binlerce pikselden oluşabilmektedir. Piksel sayısı arttıkça, görüntü kalitesi de artarken, azalması durumunda da görüntü kalitesi azalmaktadır. Görüntünün piksel değerlerinin belirli aralıklarda olması, meydana gelen görüntünün niteliğini değiştirir. Örneğin 0 beyazı ve 1 de siyahı temsil ederse arasındaki değerler de gri tonlarını ifade eder. Monokrom bir görüntü, iki boyutlu bir ışık yoğunluk fonksiyonu  $f(x,y)$  şeklinde tanımlanmaktadır. Burada x ve y uzaysal koordinatları, f fonksiyonu ise görüntünün (x,y) noktasındaki parlaklık değerini göstermektedir. Eğer görüntü renkli ise f bir vektördür ve görüntünün (x,y) noktasında renk bandına uygun her bir parlaklık değerlerini içerecektir. Kolaylık olması açısından koordinat değerleri tamsayı olarak alınacaktır. O halde koordinatların başlangıç değeri  $(x,y) = (0,0)$  yani orijin olur. İlk sıranın ikinci elemanı ise  $(x,y) = (0,1)$  olur. Şekil 2.2 burada kullanılacak olan koordinat sistemini göstermektedir (Gonzales ve Woods, 2008).



Şekil 2.2 Sayısal görüntülerin koordinat düzleminde gösterimi (Gonzales ve Woods, 2008).

## 2.2 Görüntü Hazırlama ve İyileştirme

Daha önce de bahsedildiği gibi örnekleme ve kuantalama işlemlerinin sonucu bir reel sayılar matrisidir.  $f(x,y)$  görüntüsünün örneklendiği ve sonuçtaki sayısal görüntünün yapısı ve şekli önemlidir. Görüntü hazırlama ve iyileştirmenin amacı uygulamanın yapısına, şekline göre orjinal resimden daha kullanışlı bir görüntü elde etmektir. Görüntü iyileştirme ve geliştirmede ele alınacak yaklaşım iki ana kategoriye ayrılabilir. Bunlar; Resim Tanım Bölgesi (Spatial Domain) de iyileştirme ve geliştirme, yani direk olarak resim düzlemi üzerinde piksellerle işlem yapmayı; diğeri, Frekans Tanım Bölgesi (Frequency Domain) de iyileştirme ve geliştirme, görüntünün Fourier dönüşümü yapılarak uygulanan iyileştirme tekniklerini içerir.

Görüntü Tanım Bölgesinde direk resim pikselleri üzerinde yapılan işlemler Eş.2.1 ile gösterilir (Gonzales ve Woods, 2008).

$$g(x,y) = D[f(x,y)] \quad (2.1)$$

Burada  $f(x,y)$  üzerinde işlem yapılacak görüntü,  $g(x,y)$  işlenmiş görüntü,  $D$  ise giriş görüntüsündeki  $(x,y)$  noktasının özel piksel komşuluklarına göre tanımlanan işlem operatörüdür.


### 2.3 Gri Seviye Dönüşümü

Gri seviye dönüşümü en basit dönüşüm formudur. Tekrenk (Monochrome) görüntülerde (ör: gri seviye görüntü) ışık şiddeti seviyesi, gri seviye ile aynı anlamda kullanılabilir. Renkli görüntüde ise intensity terimi ilgili renk bileşenlerini ifade eder. Gri seviyede,  $g'$  deki  $(x,y)$  noktasının değeri sadece  $f$ 'deki  $(x,y)$ 'nin ışık seviyesi şiddetine (intensity level) bağlıdır.  $f$  ve  $g$  deki ilgili noktalara ait intensity dönüşümü Eş.2.2 dir.

$$s = D(r) \quad (2.2)$$

Burada  $r$  ve  $s$  sırasıyla  $f$  ve  $g'$  nin ilgili  $(x,y)$  noktaları için gri seviye değerleridir. 8 bit' lik renk seviyesinde  $D$ , 0 ile 256 arasında değer alabilir. Bu da 256 farklı gri seviyesini ifade etmektedir.

Gri Seviye dönüşümünün üç temel kullanımı; lineer dönüşüm, logaritmik dönüşüm, üssel dönüşümle ilgili grafik Şekil 2.3' de görülmektedir (Gonzales ve Woods, 2008).




Şekil 2.3 farklı  $\gamma$  değerleri için muhtemel dönüşüm eğrileri.

Kullanılan Görüntü İşleme Yazılımın da bu işlemi kolaylaştıran önceden tanımlı fonksiyonlar mevcuttur. Giriş ve çıkış görüntüsüne ait parametreler tanımlanarak görüntü üzerinde istenen düzeltme yapılabilir.

## 2.4 Histogram İşleme

Histogram, görüntü tanım bölgesindeki pek çok işlem (görüntü geliştirme, görüntü düzeltme, görüntü sıkıştırma, bölümlendirme) için temel teşkil eder. Histogram  $[0, L-1]$  arasındaki renk derinliğine sahip dijital bir görüntünün her bir renkteki piksel sayısının göstermektedir. Şekil 2.4'de değişik görüntülerin histogram analizleri görülmektedir. Koyu görüntünün histogramı, sol tarafta, siyah bölgesine yakın şekilde dağılım göstermiş, benzer şekilde parlak görüntüde ise histogram beyaz bölgesinde toplanmıştır. Düşük kontrasta sahip görüntüde histogram dar bir aralıktayken, yüksek kontrasta sahip görüntünün histogramı tüm gri seviye bandını kaplayacak şekilde dağılım göstermiştir. Normalize edilmiş görüntüyü elde etmek için  $h$  toplam piksel sayısına bölünmelidir. Toplam piksel sayısı giriş görüntüsünün satır ve sütun değerleri çarpılarak elde edilir (Gonzalesve Woods, 2008).




Şekil 2.4 Bazı görüntülere ait histogram grafikleri (Gonzales ve Woods, 2008).

Histogram da olduğu gibi, ayrık miktarlarla işlem yapıldığında, bu teknik Histogram Eşitleme (Histogram Equalization) olarak adlandırılır. Histogram eşitleme yöntemi, gri ton değerlerini tekrar dağıtmayı hedefleyen bir yöntemdir. Histogram eşitleme yönteminde piksel sayısının fazla olduğu gri ton değerlerine daha geniş bir aralık, piksel sayısının az olduğu gri ton değerlerine daha dar bir aralık ayrılır (Gonzalez ve Woods, 2008).

Şekil 2.5’de Şekil 2.4’deki görüntülerin histogram eşitleme işlemi uygulanmış şekli görülmektedir. Şekil 2.6’daki ilk sütun orjinal görüntüyü, ikinci

sütun histogram eşitleme uygulanmış görüntüyü, üçüncü sütun ise işlenmiş görüntülerin histogramını ifade etmektedir.



Şekil 2.5 Histogram eşitleme yapılmış görüntüler (Gonzalez ve Woods, 2008).

## 2.5 Görüntü Filtreleme


Görüntü filtrelemenin amacı görüntüdeki gürültü ve bozuklukları ortadan kaldırmaktır. Bu gürültü ve bozukluklar sensörlerden veya iletim ortamlarından kaynaklanmaktadır. Bazı ortak gürültü tipleri; salt & pepper (tuz ve biber), impulse gürültü, gaussian gürültü olarak sayılabilir. Tuz biber gürültüsü, görüntüde rastgele siyah-beyaz noktacıklar şeklinde görünür.

Anlık deęerli (impulse) gürültü sadece beyazlanma, renk açılması şeklinde görünür. Gaussian gürültü ise gri seviye görüntüde normal dağılım gösterir. Görüntüdeki bu gürültüleri silmek için lineer ve non-lineer filtreler kullanılır. Bazı komşuluk operatörleri komşu piksellerin deęerleriyle işlem yapar. Filtre maskesindeki deęerler aslında piksel deęerlerinden çok, bir katsayı olarak görülmelidir.

Filtreleme mekanizmasının temelinde komşuluk ilişkileri yatmaktadır. Bu işlem basamakları;

- i.** Merkez noktayı  $(x, y)$  tanımlamak
- ii.** Merkez noktasının etrafındaki komşularla işlem uygulamak (8'li komşuluk, 4'lü komşuluk)
- iii.** İşlem sonucunu o nokta için almak
- iv.** İşlemi resimdeki tüm pikseller için uygulamak

şeklinde sıralanabilir. Görüntü tanım bölgesinde filtreleme mekanizması aşağıdaki Şekil 2.6' de gösterilmiştir (Gonzalez ve Woods, 2008). Görüldüğü gibi filtreleme işlemi filtre maskesinin görüntü içinde noktadan noktaya taşınmasıyla uygulanır. Herbir  $(x, y)$  noktasında filtreleme işleminin sonucu maske ve görüntünün aynı piksel hücrelerinin çarpılıp, hepsinin toplanmasıyla elde edilir.



Şekil 2.6 3X3'lük bir maske ile, maskenin resim üzerinde uygulanma yapısı

## 2.6 Bölümlendirme (Segmentasyon)

Görüntü işlemedeki en önemli problemlerden biri görüntü içerisinde, nesnelerin bulunduğu alt bölümlerin belirlenmesi işlemidir. Bölümlendirme bir görüntüyü kendisini oluşturan bölge ve nesnelere ayırma işlemidir. Bölümlendirme bir görüntüyü anlamlandırmak için önemli bir aşamadır.

Bölümlendirme algoritması, görüntüdeki gri seviye değerinin benzerlik ve süreksizlik özelliğini temel alır. Benzerlikte görüntü içerisinde gri seviye değerleri birbirine benzeyen kısımları bölgelere ayırma mantığı yatar. Süreksizlik ise görüntü içerisinde kendini gri seviye değerinde normal olmayan (Ör.: nesne kenarı gibi) değişiklik şeklinde gösterir. Kenar belirleme, thresholding, region growing, region splitting ve watershed, bölümlendirme için örnek metotlar olarak verilebilir.



Bir görüntüye baktığımızda görüntüyü oluşturan nesnelere temel olarak bölgeler ve bu bölgeleri sınırlandıran kenarlar şeklinde görmekteyiz. Bölge, görüntüde yer alan aynı ya da benzer piksellerin bir araya gelmesiyle oluşan homojen kümeler olarak tanımlanabilmektedir. Kenar ise, pikseller arasındaki geçişlerde veya iki homojen bölgenin kesiştiği yerlerde meydana gelen, ani değişimlerin olduğu bölgeler şeklinde tanımlanabilmektedir. Kenar belirleme işleminde piksellerin özellikleriyle birlikte komşu piksellerle olan bağlantıları da çok önemli işleve sahiptir. Kenar belirlemede yaygın olarak kullanılan yöntemlerden biri maske kullanmaktır. Görüntüdeki kenar pikseller çevrelerindeki diğer piksellerden keskin farklılıklar gösterdikleri için maske işlemi bir çeşit yüksek geçiren filtre etkisi gösterirler.

## 2.7 Eşikleme (Thresholding)

Eşikleme işlemi, değişik gri ton seviyelerine sahip bir resmi ikilik seviyeye yani; 0 siyah, 1 beyaz rengi göstermek üzere resmi 0 ve 1'lerden oluşan bir matris haline getirir. Eşikleme yaparken bir eşik değeri belirlenir ve bu değer üstündeki değerler için çıkış imgesindeki ilgili piksele 1, altındaki değerler için 0 değeri atanır. Eşiklemenin genel ifadesi denklem (2.2)'de verilmiştir.

$$\begin{aligned} G(i, j) &= 1 & f(i, j) &\geq T & \text{ için} \\ G(i, j) &= 0 & f(i, j) &< T & \text{ için} \end{aligned} \tag{2.3}$$

Eğer görüntüdeki nesnelere temassız ve gri seviyeleri açıkça arka planın gri seviyesinden farklı ise eşikleme uygun bir ayrıştırma metodudur. Doğru eşik seçimi başarılı bir görüntünün ayrıştırılabilmesi için gereklidir. Bu seçim etkisiz veya çeşitli eşik tanımlama algoritmalarıyla yapılır.

Otsu-1979'da bu değişken eşik seviyesini bulmak için ve görüntü bölütleme probleminin çözümü için bir ayırt etme kriteri (Discriminant Criterion) önermiştir. Önerdiği bu yöntemi orijinal görüntü ile bölütlenmiş görüntü (ikilik görüntü) arasındaki toplam karesel hatanın minimizasyonu olarak adlandırmıştır. Bulunan eşik seviyesi  $[0,1]$  aralığında, parlaklık parametresidir. Otsu'nun bölgesel

eşikleme algoritması; kendi içinde ağırlıklandırılmış ve sınıflandırılmış değışintiyi (varyansı) minimize edecek şekilde çalışır. Bu sınıfların birbiri ile olan değışintisini ise maksimize edecektir.

## 2.8 Görüntü Yapısal İşlemleri


İkili resim yapısı, resimdeki bazı özellikleri çıkarmak için kullanılabilir. 8 bit gri düzey resimi ikili resim yapısına dönüştürüldükten sonra değışik işlemlere tabi tutularak istenen alan, kütle merkezi vb. nesneye ait özellikler resimden çıkartılabilir. İkili düzey resimde her iki piksel ve belirtilen komşuluk ilişkisine göre komşuları, yapısal eleman ile resim içindeki nesnelere ilgili bilgilerin edinilmesinde daha doğru sonuçlar elde edilmesini sağlar.

Genişleme, kalınlaştırma ve büyütme işlemidir. Bu büyütme işleminin şeklini yapısal eleman tayin eder. Şekil 2.7 (a)'da verilen resim bölümü için, (b)'deki yapısal elemanın nasıl uygulandığı ve (c)'de işlem sonucu görülmektedir (Gonzalez ve Woods, 2008). Yapısal elemanın şekli elde edilecek sonucu belirler. Yapısal elemanı, baklava dilimi, disk, çizgi, kare, dikdörtgen gibi şekillerde tanımlanabilir veya bizim istediğimiz özel bir şekle sahip olabilir. Böylece nesne kenarları istenilen forma sokulabilir.

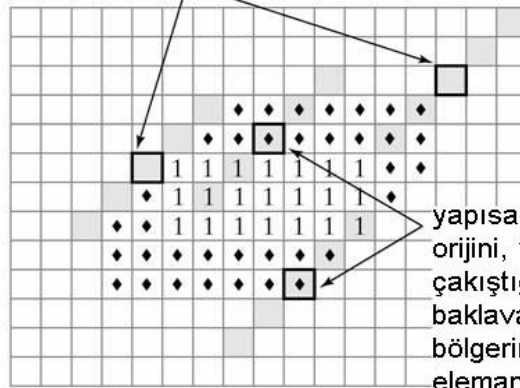
Aşınma işlemi ise genişlemenin tersidir. Aşınmada da genişlemede olduğu gibi aşınmanın şeklini yapısal eleman belirler. Şekil 2.8 (a)'de verilen resim bölümü için, (b)'deki yapısal elemanın orijinal görüntüye nasıl uygulandığı ve (c)'de sonucu görülmektedir (Gonzalez ve Woods, 2008).

Pratikte genişleme ve aşınma işlemleri çoğunlukta beraber, değışik kombinasyonlarla kullanılırlar. Yani görüntü farklı veya aynı yapısal maske elemanlarıyla bir dizi genişleme ve/veya aşınma işlemine tabii tutulabilir. Bunlardan açma ve kapatma işlemleri yaygın olarak kullanılmaktadır. Açma işlemi kendisini genişlemenin takip ettiği basit bir aşınma işlemidir. Şekil 2.9'da açma ve kapatma işlemleri görülmektedir (Gonzalez ve Woods, 2008). Şekil 2.9 (a)'da A nesneyi, B de yapısal elemanı göstermektedir. Şekil 2.9 (b)'de opening işleminin uygulanışı, Şekil 2.9 (c)'de ise sonucu görülmektedir. Açma


uygulandıktan sonra beyaz kalan kısımlar artık nesnenin dışındadır. Genişleme ve aşınma işleminde olduğu gibi, sonucu maske elemanı belirler. Maskenin örtüştüğü nesne bölümleri düzelirken, maskenin yapısını karşılamayan yerler silinir. Şekil 2.9 (c)'de üçgenler içindeki boyalı olmayan kısımlara disk şeklindeki yapısal eleman örtüşmediğinden bu kısımlar silinmiştir. Böylece nesne hatları yumuşar, ince bağlantılar kopar ve ince çıkıntılar temizlenir.



yapısal maske elemanının orijini, 1 değerli bir pixeler örtüşmediğinden çıkışta değişiklik oluşturmaz.




yapısal maske elemanının orijini, 1 değerli bir pixelle çakıştığında baklava dilimi şeklindeki bölgerin değeri, maske elemanı tarafından belirlenir.




Şekil 2.7 Genişleme işlemi



bu pixel bölgeleri, yapısal maske elemanını aştığı için çıkışta geriplan değeri atanacaktır.



Şekil 2.8 Aşınma işlemi




Şekil 2.9 Açma ve kapama işlemi

Kapatma işlemi ise açmanın tersine kendisini aşınmanın takip ettiği bir genişleme işlemidir. Şekil 2.9 (d)'de görüldüğü gibi uygulanır ve sonucu Şekil 2.9 (e)'de dir. Kapama işlemi de açmaya benzer olarak nesne sınırlarını yumuşatır. Açmadan farkı ise yapısal elemandan küçük olan girinti kırık ve delikler kapatılır.

## 2.9 Birbirleriyle İlişkili Pksel Gruplarının Etiketlenmesi (Labeling)

Etiketleme, ikili resim içerisindeki her bir pikselin belli bir komşuluk ilişkisi göz önüne alınarak gruplanması işlemidir. Etiketleme işlemi sonucu her bir ayrı grup ayrı bir nesneyi temsil eder. Birden fazla nesne içeren resimlerde nesne özelliklerini ayırt edebilmek için etiketleme gerekli bir aşamadır. Pksel gruplama işlemi pikselin komşularının kontrolüyle yapılır.


Şekil 2.10'daki gibi bir  $P(x,y)$  noktası için dörtlü komşuluk seti  $(x+1,y)$   $(x-1,y)$   $(x,y+1)$   $(x,y-1)$  şeklindedir.  $N_4(p)$  ile gösterilir. Diyagonal komşular ise  $(x+1,y+1)$   $(x+1,y-1)$   $(x-1,y+1)$   $(x-1,y-1)$  dir. Tüm bu pikseller 8'li komşuluk ilişkisini verir.



Şekil 2.10 Piksel komşuluk setleri

İki  $p$  ve  $q$  noktaları için verilen komşuluk ilişkisine göre bir yol varsa bu durumda  $p$  ve  $q$  noktaları bağlı piksellerdir ve aynı piksel grubunun içindedirler (Connected Component). Yani piksellerin bağlı olup olmadığını seçilen komşuluk ilişkisi belirler.


Şekil 2.11 (a)'de bir resim bölümünün 4'lü ve (b)'de 8'li komşuluk ilişkisine göre bağlı bölgelerinin belirlenmesi görülmektedir. (c)'de 4'lü komşuluga göre belirlenen bölgenin ve (d)'de ise 8'li komşuluga göre bu bölümlerin etiketlenmesi görülmektedir. Etiketlemede geri plan pikselleri sıfır ile ifade edilir. Sonra her bir piksel grubu 1'den başlayarak etiketlenir.



Şekil 2.11 Etiketleme (Labelling)

## 2.10 Renk Temelleri ve Modelleri

Renk spektrum'u altı farklı bölgeye bölünebilir: mor, mavi, yeşil, sarı, turuncu ve kırmızı. Şekil 2.12'de görüldüğü gibi hiçbir rengin ani bir bitişi yoktur, her rengin bir sonrakine yumuşak bir karışım şeklinde geçişi vardır.




Şekil 2.12 Görünür ışığı da içeren elektromanyetik spektrum

Bir rengi diğerinden ayırmak için genelde kullanılan karakteristikler parlaklık, renk özü ve doygunluktur. Parlaklık, ışık şiddetinin akromatik ölçüsünü oluşturur. Renk özü, bir ışık dalgaları karışımındaki baskın bir dalgaboyu ile ilişkili olan bir niteliktir. Renk özü bir izleyici tarafından algılanan baskın rengi ifade eder. Bu nedenle, bir nesneye kırmızı, sarı yada turuncu dendiğinde, onun renk özü belirtilmiş olur. Doygunluk, bir renk özü ile karıştırılmış olan beyaz ışığın nisbi saflığı veya miktarını belirtir. Saf spektrum renkleri tam doygun hale getirilmiştir. Pembe (kırmızı ve beyaz) ve lavanta (mor ve beyaz) gibi renkler, eklenen beyaz ışığın miktarına ters orantılı olan bir doygunluk derecesi ile az doygun edilmiştir. Renk özü ve doygunlukluk birlikte alındığında “kromatiklik” adını alır ve böylece bir renk parlaklığı ve kromatikliği ile karakterize edilebilir (Gonzalez ve Woods, 2008).

Renk uzayları renkleri tanımlamak için kullanılan matematiksel modellerdir. Renk uzayları, bütün renkleri temsil edecek şekilde oluşturulur. Renk uzayları 3D olarak tasarlanır. Çünkü renkmetri biliminin temelini oluşturan Grassmann'ın birinci kanununa göre bir rengi belirlemek için birbirinden bağımsız üç değişkene gerek vardır. Renklerin renk uzayındaki yerleri bu değişkenlere göre belirlenir. Her renk uzayının kendine özgü biçimde renk oluşturma için bazı standartları vardır. Renk uzayları oluşturulurken bir başka renk uzayına doğrusal yada doğrusal olmayan yöntemlerle dönüşüm yapılabilir (Yılmaz 2002).

Bugün kullanılan çoğu renk modeli donanıma yöneliktir (monitörler ve yazıcılar gibi) veya renk karışımının amaçlandığı uygulamalara yöneliktir (animasyon için renkli grafiklerin oluşturulması gibi). Dijital resim işlemede pratikte en yaygın olarak kullanılan model RGB (Red, Green, Blue; Kırmızı, Yeşil, Mavi) modelidir. Renkli monitörler ve geniş bir sınıf video kameralar için kullanılan modeller ise; CMY (Cyan, Magenta, Yellow; Camgöbeği, Macenta, Sarı) modeli, CMYK (Cyan, Magenta, Yellow, Black; Camgöbeşi, Macenta, Sarı, Siyah) modeli ve YCbCr (Y bileşeni parlaklık bilgisi, Cb ve Cr renklilik bilgileri) modelleridir. Amerika Birleşik Devletlerinde kullanılan televizyonlardaki NTSC renk uzayı ve renkli yazım için HSI (Hue, Saturation, Intensity; Renk özü, Doygunluk, Şiddet) modeli kullanılmaktadır.

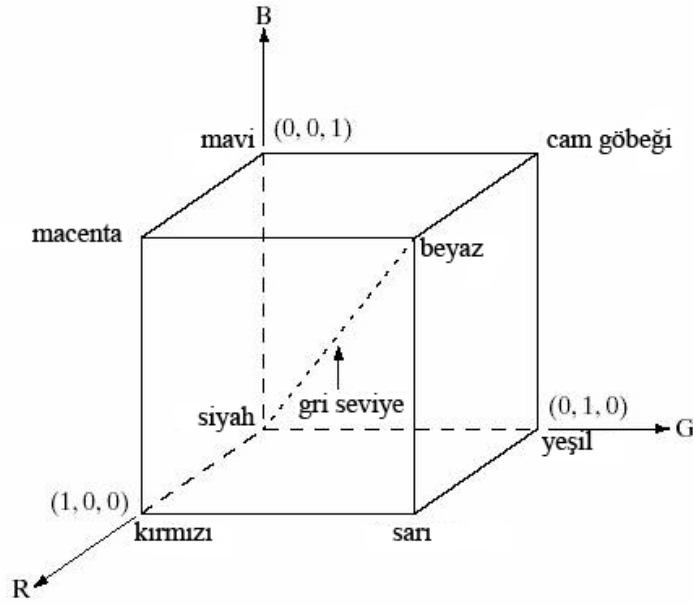
Renk algılama çalışmalarında matematiksel olarak yapılan ilk tanımlama CIE (International Commission on Illumination) tarafından tanımlanan “CIE 1931 color space” olarak da bilinen CIE XYZ renk modelidir. CIE XYZ (1931), tüm renk ölçüm işlemlerinin temelini oluşturur. Bu sistemde renkler pozitif değerler ve Y harfi ile temsil edilen parlaklık (luminance) değerleriyle tanımlanabilir. İnsan gözü kırmızı, yeşil, mavi olarak bilinen kısa, orta ve uzun dalga boylarına duyarlı hücrelere sahiptir. Bu renk hissinin tanımlanabilmesi için üç parametrenin yeterli olması anlamına gelmektedir. XYZ renk uzayı doğrudan insan gözünün ölçümünü esas aldığı için diğer renk modlarından farklıdır ve diğer renk modellerine de temel oluşturur. (Şekil 2.13)



Şekil 2.13. XYZ renk modeli (Anonim)



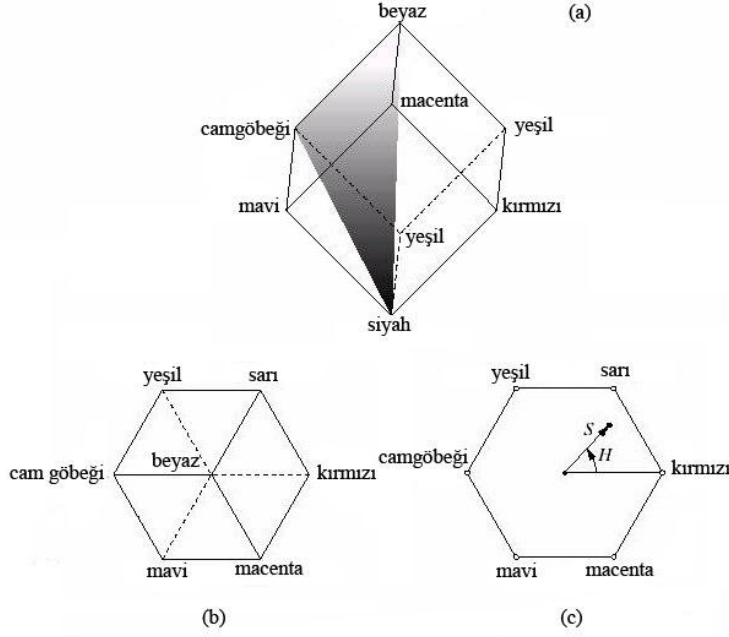
RGB modelinde her renk, kendi kırmızı, yeşil ve mavisinin ana spektrumsal bileşeni olarak görünür. Bu model bir kartezyan koordinat sistemi üzerine kuruludur. RGB renk alt boşluğu Şekil 2.14’de gösterilen küptür. Burada RGB değeri üç köşededir; camgöbeği, macenta ve sarı diğer üç köşede; siyah orijinde ve beyaz orjinden en uzak köşededir. Bu modelde gri skala (eşit RGB değerleri noktaları) siyahtan beyaza kadar, bu iki noktayı birleştiren çizgi boyunca uzanır. Bu modeldeki farklı renkler küpün üstünde veya içindeki noktalardır ve orijinden çıkan vektörlerle tanımlanır (Gonzalez ve Woods, 2008).



Şekil 2.14 RGB birim renk küpü

HSI renk modeli, bir renkli resimdeki şiddet bileşenini, rengi taşıyan bilgiden (renk özü ve doygunluk) ayırır. HSI modeli insanlar için doğal ve sezgisel olan renk tanımlamaları üzerine kurulu resim işleme algoritmaları geliştirmek için ideal bir araçtır. HSI uzayını oluşturmak için gereken renk özü, doygunluk ve şiddet değerleri, RGB renk küpünden elde edilebilir. Renk özünün verilen bir RGB noktasının nasıl belirlendiğini anlamak için, Şekil 2.15(a)’ya bakıldığında görülen siyah beyaz-camgöbeği düzlemi içerisinde siyah ve beyaz noktaların olduğu gerçeğinden; düzlemin ışık şiddeti eksenini de içerdiği anlaşılır. Ayrıca buradan, şiddet eksenini ve küpün sınırları ile tanımlanmış düzlem kısmındaki bütün noktaların aynı renk özüne (bu durumda camgöbeği) sahip olduğu sonucu da çıkmaktadır. Üç renk ile oluşturulan bütün renkler, o renkler ile tanımlanan üçgen içerisindeyler. Eğer o noktaların ikisi siyah ve beyaz, ve

üçüncüsü de bir renkli olursa, üçgen üzerindeki bütün noktalar aynı renk özünü sahip olur, çünkü siyah ve beyaz bileşenler renk özünü değiştirmezler. (tabi ki bu üçgendeki noktaların şiddeti ve doygunluğu farklı olur). Renk tonu düzlemi dikey şiddet eksenini etrafında döndürülerek farklı renk özleri elde edilir. Buradan hareketle herhangi bir RGB noktasının, HSI renk modelinde karşılık gelen noktaya çevrilebileceği sonucu çıkar (Gonzalez ve Woods, 2008).



Şekil 2.15 RGB ve HSI renk modelleri arasındaki ilişki, renk özü ve doygunluk bileşenlerinin gösterimi

RGB bileşenleri aşağıdaki formül ile HSI bileşenlerine çevrilebilir:

$$H = \begin{cases} \theta & \text{eger } B \leq G \\ 360 - \theta & \text{eger } B > G \end{cases} \quad (2.4)$$

$$\theta = \cos^{-1} \left\{ \frac{\frac{1}{2}[(R-G) + (R-B)]}{(R-G)^2 + (R-G)(G-B)^2} \right\} \quad (2.5)$$

$$S = 1 - \frac{3}{(R+G+B)} [\min(R, G, B)] \quad (2.6)$$

$$I = \frac{1}{3} [R + G + B] \quad (2.7)$$

YCbCr renk uzayının, simetrik olmayan RGB renk uzayının renk noktaları arasındaki uzaklığını düzgün bir skalada algısal farkla temsil edilememesi

nedeniyle bölütleme zorunlu olacağından, YCbCr renk uzayı tercih edilir. YCbCr renk uzayının tercih edilmesinin nedenleri şunlardır;

- a) MPEG ve JPEG gibi video sıkıştırma standartlarında bu renk uzayının kullanılması,
- b) İnsan algısındaki renk farkları bu uzayda öklid uzaklığıyla direk olarak ifade edilebilmesi,
- c) Yoğunluk ve doygunluk bileşenlerinin kolaylıkla ve birbirinden bağımsız kontrol edilebilmesidir.

RGB bileşenleri aşağıdaki formül ile YCbCr bileşenlerine çevrilebilir.

$$Y = 0,299R + 0,587G + 0,114B \quad (2.8)$$

$$Cb = - 0,169R - 0,332G + 0,500B \quad (2.9)$$

$$Cr = 0,500R - 0,419G - 0,081B \quad (2.10)$$

Lab renk uzayının en belirgin özelliği, renk uzayının algılama yönünden düzgün değişim göstermesidir. Lab renk uzayı Munsell renk sistemi üzerine kuruludur. Lab renk uzayı 1976 yılında görsel medya için tasarlanıp oluşturulmuştur. Günümüzde Lab renk uzayı çeşitli alanlar için standart renk uzayı olarak seçilmiştir ve bugün pek çok uygulamada kullanılmaktadır.

Lab renk uzayının bileşenleri değer (L: lightness), tonlama ve doygunluk (a, b) dir. L, bir rengin açıklığını, a ve b ise rengi oluşturmaktadır. Bu değerler RGB renk uzayına bağımlı olarak hesaplanır. Bu hesaplama için gerekli ilişki beyazın XYZ uzayındaki değerleriyle sağlanır. Dolayısıyla bu değerlerin hesaplanması için yani X, Y ve Z değerlerinden L, a ve b değerlerinin hesaplanması için standart aydınlatıcının ve standart gözlemcinin hangisi olacağına karar verilmelidir.

XYZ bileşenleri aşağıdaki formül ile Lab bileşenlerine çevrilebilir.

$$L = \begin{cases} 116 \left(\frac{Y}{Y_n}\right)^{\frac{1}{3}} - 16 & \text{eger } \frac{Y}{Y_n} > 0.008856 \\ 903.3 \left(\frac{Y}{Y_n}\right) & \text{eger } \frac{Y}{Y_n} \leq 0.008856 \end{cases} \quad (2.11)$$

$$a = 500 \times \left( f\left(\frac{X}{X_n}\right) - f\left(\frac{Y}{Y_n}\right) \right) \quad (2.12)$$

$$b = 200 \times \left( f\left(\frac{Y}{Y_n}\right) - f\left(\frac{Z}{Z_n}\right) \right) \quad (2.13)$$

$$\text{Burada } f(t) = \begin{cases} t^{\frac{1}{3}} & \text{eger } t > 0.008856 \\ 7.787 \times t + \frac{16}{116} & \text{eger } t \leq 0.008856 \end{cases} \quad (2.14)$$

## 2.11 Doku Hesaplamaları

Doku analizinin endüstride yüzey üzerinde kusur denetiminde, biomedikalde hastalıklı dokunun tespitinde, havadan veya uydudan çekilen görüntülerden yapılan coğrafi analizler gibi uygulama alanları vardır. Fakat bir çok alanda uygulanma potansiyeline rağmen %100 başarılı çalışmaların sayısı çok fazla değildir. Bunun en önemli sebepleri gerçek dünyanın tek biçimli olmaması, doku hesaplamalarının çok fazla matematiksel işlem gerektirmesidir.

Doku hesaplamaları, doku görüntüsünü oluşturan piksellerin değerleri üzerinden hesaplanır. Doku hesaplamaları işleme giren piksel ve piksel komşuluk sayısına göre derecelendirilir:

1. derece doku hesaplamaları orijinal görüntü üzerinden yapılan istatistiksel hesaplardır. Varyans, ortalama, standart sapma gibi değerler birinci derece hesaplamalardır.


2. derece doku hesaplamaları ise görüntü piksellerinin ikili komşuluk grupları halinde incelenmesi sonucunda yapılır.

3. ve daha yukarı derecede ise 3 veya daha fazla pikselin gruplanarak incelenir. Fakat hesaplamaların uzun sürmesi ve yorum çıkarmanın zorluğu sebebiyle genellikle kullanılmaz (Beber ve ark. 2003).

Doku sınıflandırma uygulamalarında kullanılan istatistiksel yöntemler genellikle 2.derece doku hesaplamaları kullanılarak yapılır.

İkinci derece doku hesaplamaları, görüntü matrisini oluşturan piksel değerlerinin ikili komşuluk kombinasyonları ile oluşturulan yardımcı matrisler üzerinden yapılan hesaplamalardır. En sık kullanılan yardımcı matris gri düzeyi eş-oluşum matrisidir (GDOM). Gri düzeyi eş-oluşum matrisi (Gray Level Co-occurrence Matrix, (GDOM)) görüntüyü oluşturan piksellerin ikili komşulara göre gri düzeylerinin (grey level) kombinasyonlarının hangi sıklıkta olduğunu tablolandığı iki boyutlu matristir. Bu matrisi oluşturan değerler üzerinden dokuya özgü hesaplamalar yapılır (Haralick ve ark. 1973).

GDOM iki pikselin komşuluk ilişkisine göre oluşturulur. Birinci piksele referans piksel, ikincisine komşu piksel veya hedef piksel denir. Komşuluğun yönü GDOM'u oluşturmak için önemlidir. Referans pikselin sağındaki piksel ile komşuluğu incelenecekse yön (0, D) olarak veya doğu olarak belirtilir. Buna (0,1)'da denir. Referans piksele göre satır numarasını 0, sütun numarasını 1 arttırarak hedef piksele ulaşılır. Bu şekilde komşunun referansa göre yerini belirten vektöre mesafe vektörü (distance vector) denir. Bir görüntü için 8 yönde komşuluğa göre GDOM hesaplanabilir. Fakat genellikle 4 yön tercih edilir. Sol üst köşeden, sağ alt köşeye kadar bütün pikseller sıra ile referans olurlar. (0,1) için GDOM oluşturulurken son sütundaki değerlerin sağ taraflarında komşusu olmadığı için hesaba katılmazlar. Boyutları  $m*n$  piksel olan bir görüntü matrisinden yönü (D, D) olan GDOM oluşturulurken m. satır ve n. sütundaki değerler, yönü (D, 0) olan GDOM oluşturulurken ise m. satırdaki değerler hedef pikselleri matris boyutunu aştığı için dikkate alınmazlar. Şekil 2.16'de referans piksele göre hedef piksel gösterimleri yer almaktadır (Haralick ve ark. 1973).

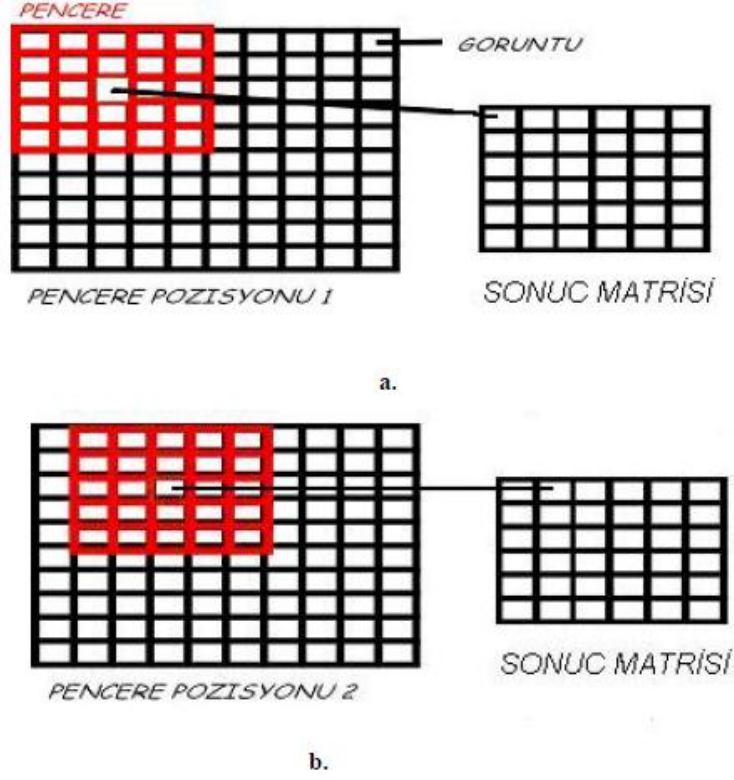


şekil 2.16 Referans bir piksele göre hedef piksel gösterim yönleri

GDOM boyutları görüntünün gri ton kademesi kadardır. Görüntü 4 ton griden oluştuğu için 4\*4 GDOM oluşturulur. 256 farklı gri tonu olsaydı 256\*256 boyutunda bir GDOM oluşurdu. GDOM'nin elemanları üzerinden hesaplanan bir çok doku değeri aslında matris elemanlarının ağırlıklı ortalamalarıdır. Ağırlıklı ortalama, ortalama alma işleminin her bir değer için belli bir katsayı ile çarpılmasından sonra yapılmasıdır.

GDOM görüntü matrisi üzerinden elde edilir. Doku görüntüsü bir örnek ise görüntü matrisinin tamamı üzerinden GDOM elde edilebilir. Doku görüntüsü bir örnek olmayan durumlarda ise bölümler halinde GDOM elde etmek daha sağlıklı sonuç verir. Bir yüzey üzerinde kusur denetiminde, biomedikal görüntülerinde hastalıklı dokunun tespitinde, havadan veya uydudan çekilen görüntülerde farklı coğrafi birimlerin, bitki örtülerinin, jeolojik birimlerin tespitinde bu yöntem fayda sağlamaktadır. Bu yöntemde belirli bir boyuttaki pencere görüntü matrisi üzerinde belirli mesafelerde hareket ettirilir. Her hareket ettirildiğinde pencere içerisindeki bölüme ait GDOM elde edilir ve değerler hesaplanır. Hesaplanan değerler bir sonuç matrisine aktarılır. GDOM üzerinden kaç değer hesaplanacak ise o sayıda sonuç matrisine ihtiyaç vardır. Pencere boyutu belirlenirken dikkat edilmesi gereken hususlar pencere büyüklüğünün incelenecek dokunun bir motifini kapsayabilmesi ve boyutlarının tek sayı olan bir matris olmasıdır (5\*5, 9\*9 vb.). Pencere matrisinin boyutlarının çift sayı olması hesap zorluğu çıkaracağı için tercih edilmez. Hareket mesafesi olacak piksel sayısı dokunun motifini atlamayacak şekilde belirlenmelidir. Büyük bir hareket mesafesi doku motifinin

atlanmasına sebep olacağı gibi, çok kısa bir mesafe belirlenmesi de işlemlerin uzun sürmesine ve sonuç matrisinin boyutlarının büyümesine sebep olacaktır (Haralick, 1979).



**Şekil 2.17** a. Pencere pozisyonu 1 iken sonuç matrisine değer aktarılması b. Pencere pozisyonu 2 iken sonuç matrisine değer aktarılması

Şekil 2.17’de 10\*10 boyutlarındaki bir görüntü matrisinden, 5\*5 boyutlarındaki bir pencere matris gezdirilerek sonuç matrisine değer aktarılması görülmektedir. Pencere 1 pozisyonunda iken içinde kalan değerlere göre GDOM elde edilir ve doku değerleri hesaplanır. Hesaplanan sonuç matrisine (1,1) elemanı olarak yerleşir. Pencere bir piksel kaydırılarak işlemler tekrarlanır. Hesaplanan sonuç bu sefer matrisin (1,2) elemanı olarak yerleşir. Bu şekilde devam ederek 6\*6 boyutlarında bir sonuç matrisi oluşur (Haralick, 1979).

## 2.12 Yapay Sinir Ağı

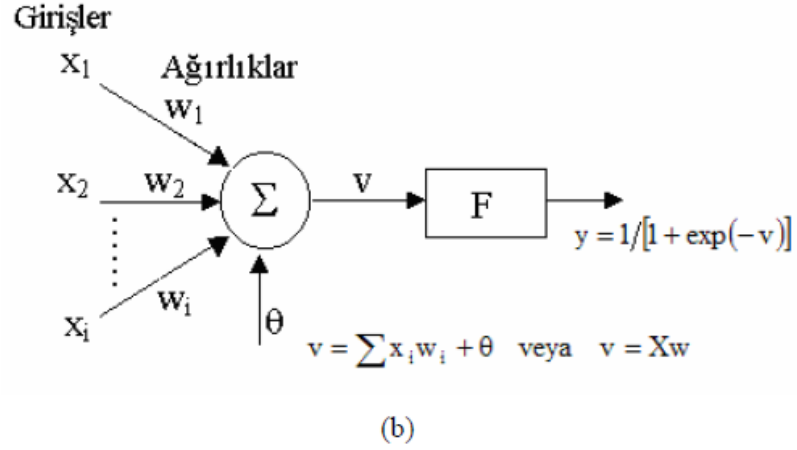

İnsan beyni bilinen en gizemli ve karmaşık hesaplayıcıdır. Yapay sinir ağları (YSA), insan beyninin işleyişini taklit ederek yeni sistem oluşturmaya

çalışan yaklaşımlardır. İstisnasız tüm YSA yapılarının esin kaynağı biyolojik sinir ağlarının işleyiş yöntemidir. Pek çok araştırmacı beyin fonksiyonlarını taklit edebilen YSA modelleri üzerinde çalışmaktadır. YSA, öğrenme özelliği ile cazibesini her geçen gün arttırmıştır. YSA mühendislik alanında, imalat sanayinde, askeri proje uygulamalarında, tıp alanında, tarımsal alanda, uzay ve havacılık sanayinde, yüzey modellemede gibi alanlarda tahmin, sınıflandırma, veri ilişkilendirme, veri yorumlama, veri filtreleme vb. amaçlarla kullanılmaktadır (Sağıroğlu ve ark. 2003).

YSA, bir sisteme ait tek veya çoklu parametrelere bağlı olarak tanımlanan giriş verileri ile sistemin yine tek veya çoklu parametrelere bağlı olarak tanımlanabilen çıkışları arasında ilişki kurabilme yeteneğine sahiptir. Bu ilişkinin doğrusal bir formda olması zorunlu değildir. YSA, giriş değerlerine uygun olarak çıkış değerleri üretirler. YSA, genel olarak birbirleri ile bağlantılı işlemci birimlerden (nöron) oluşurlar. Bir yapay nöron temel olarak girişler, ağırlıklar, toplama fonksiyonu, transfer fonksiyonu ve çıkış olmak üzere 5 bölümde incelenebilir (Sağıroğlu ve ark. 2003).

Şekil 2.18’de  $x$  girişleri,  $y$  çıkışı,  $F$  transfer (aktivasyon) fonksiyonunu,  $p$  nöron giriş sayısını,  $n$  çıkış sayısını,  $w$  ise ağırlıkları ifade etmektedir. Nöronlar arasındaki bağlantılar ağırlık adı verilen ayarlanabilir parametreler ile karakterize edilir. Ağırlıklar bir nörona gelen bilginin önemini ve nöron üzerindeki etkisini gösterir (Öztemel 2003). Girişler  $p$  elemanlı sütun vektörü, ağırlıklar ise  $p$  elemanlı satır vektörü ile gösterilir.





Şekil 2.18 Bir nöronun blok diyagram gösterimi (a), detaylı gösterimi (b)

Girdiler; bir yapay sinir hücresine (Proses Elemanına) dış dünyadan gelen bilgilerdir. Bu bilgiler kullanılarak ağı eğitilmesi sağlanır. Yapay sinir hücresine dış dünyadan olduğu gibi başka hücrelerden veya kendi kendisinden de bilgiler gelebilir. Ağırlıklar; bir yapay hücreye gelen bilginin önemini ve hücre üzerindeki etkisini gösterir. Ağırlıklar, girdi ile toplama noktaları arasındaki bağlantılara karşılık gelir. Ağırlıkların büyük ya da küçük olması önemli veya önemsiz olduğu anlamına gelmez. Toplama fonksiyonu ise bir hücreye gelen net girdiyi hesaplar. Bunun için değişik fonksiyonlar kullanılmaktadır. En yaygın olanı ağırlıklı toplamı bulmaktır. Burada her gelen girdi değeri kendi ağırlığı ile çarpılarak toplanır. Böylece ağa gelen net girdi bulunmuş olur.

Bir işlemci elemanın çıkış değeri, diğer işlemci elemanlarına giriş veya ağı çıkış değeri olabilir. YSA' da giriş vektörü ile ağırlık vektörünün çarpımı önce toplama fonksiyonuna uygulanır ve fonksiyonun çıkışı eşitlik 2.15'e göre hesaplanır.

$$V_i = \sum_{j=1}^n X_j W_{ij} - \theta_i \quad (2.15)$$


Burada  $X_i$  i. girişi,  $W_{ij}$  j. elemandan i. elemana bağlantı ağırlığını ve  $\theta_i$  eşik (threshold) değerini göstermektedir.

Aktivasyon fonksiyonları bir YSA' da nöronun çıkış genliğini istenilen değerler arasında olmasını sağlar. Bu değerler genellikle  $[0,1]$  veya  $[-1,1]$  arasındadır. Ayrıca, yapay sinir ağına bir kutuplama (bias) değeri uygulanarak aktivasyon fonksiyonu arttırılabilir. YSA'larda kullanılacak aktivasyon fonksiyonlarının türevi alınabilir olması ve süreklilik arz etmesi gerekmektedir. YSA'da kullanım amacına uygun olarak tek veya çift yönlü aktivasyon fonksiyonları kullanılabilir (Sağiroğlu ve ark. 2003). Aktivasyon fonksiyonu olarak çoğunlukla doğrusal fonksiyon, tanjant hiperbolik veya sigmoid fonksiyon kullanılır.

**Doğrusal fonksiyon**, işlemci elemanın girişini doğrudan çıkış olarak veren fonksiyondur.

$$y = Ax$$


A sabit bir katsayıdır



Şekil 2.19 Doğrusal fonksiyon


**Sigmoid fonksiyon**, YSA uygulamalarında en çok kullanılan aktivasyon fonksiyonlarından birisidir.

$$y = \frac{1}{1+e^{-x}}$$



Şekil 2.20 Sigmoid fonksiyon

**Tanjant hiperbolik fonksiyon**, YSA uygulamalarında en çok kullanılan aktivasyon fonksiyonlarından biridir



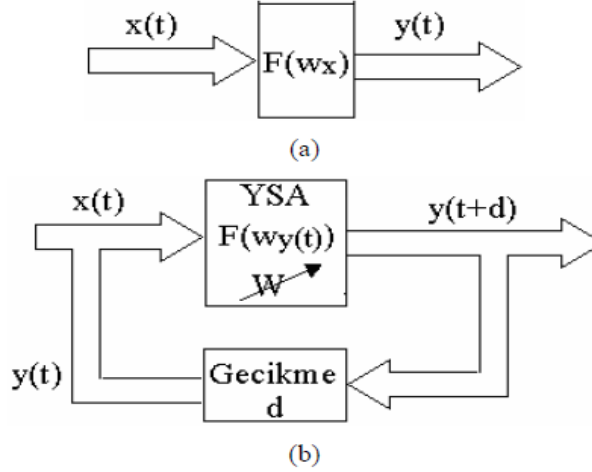
**Şekil 2.21** Tanjant hiperbolik fonksiyon

Nöronlar arasındaki bağlantıların yapısı ağı yapısını belirler. İstenilen hedefe ulaşmak için bağlantıların nasıl değiştirileceği öğrenme algoritması tarafından belirlenir. Kullanılan öğrenme kuralına göre, hatayı sıfıra indirecek şekilde, ağı ağırlıkların değiştirilir. YSA, yapısına ve öğrenme algoritmasına göre sınıflandırılır. Yapılarına göre yapay sinir ağları iki grupta incelenir:

**1-İleri beslemeli ağlar**, Şekil 2.22a'daki gibidir. İleri beslemeli ağlarda, işlem elemanları birbiri ardı sıra sıralanırlar. Girdiler dışarıdan ya da bir önceki neuronun çıktısından alınır; neuronların çıktıları da bir sonraki neurona veya dışarıya verilir. Bu ağlarda, neuronun önceki veya aynı katmandaki herhangi bir neurona bağlantısı ve veri iletmesi söz konusu değildir. Bu mimarilerde ağı çıktısı tamamen ağa giren girdilere bağlıdır. İleri beslemeli ağlar herhangi bir dinamiklik özelliği taşımazlar ve gösterdikleri özellik bakımından doğrusal ve doğrusal olmayan kararlı problem alanlarına uygulanabilirler (Cichocki, 1993).

**2-Geri beslemeli ağlar**, Şekil 2.22b'deki gibidir. Genellikle gıda alanlarında yapılan analizlerin değerlendirilmesinde YSA modeli oluşturulurken geri beslemeli ağlar (back propagation) yaygın olarak kullanılan yöntemdir (Eerikainen vd., 1993). Geri beslemeli sinir ağı, çıkış ve ara katlardaki çıkışların, giriş birimlerine veya önceki ara katmanlara geri beslendiği bir ağ yapısıdır. Böylece, girişler hem ileri yönde hem de geri yönde aktarılmış olur. Bu çeşit sinir ağlarının dinamik hafızaları vardır ve bir andaki çıkış, hem o andaki hem de

önceki girişleri yansıtır. Bundan dolayı, özellikle önceden tahmin uygulamaları için uygundur. Bu ağlar çeşitli tipteki zaman-serilerinin tahmininde oldukça başarı sağlamışlardır (Öztemel, 2003).



Şekil 2.22 İleri beslemeli (a) ve geri beslemeli (b) ağ yapıları

Öğrenme algoritmalarına göre yapay sinir ağları üç grupta incelenir:

**1- Danışmanlı öğrenmede;** Bu tip öğrenmede, YSA'ya örnek olarak bir doğru çıkış verilir. İstenilen ve gerçek çıktı arasındaki farka (hataya) göre işlemci elemanlar arası bağlantıların ağırlığı en uygun çıkışı elde etmek için sonradan düzenlenebilir. Bu sebeple danışmanlı öğrenme algoritmasının bir “öğretmene” veya “danışmana” ihtiyacı vardır (Öztemel, 2003).

**2- Danışmansız öğrenme,** Girişe verilen örnekten elde edilen çıkış bilgisine göre ağ sınıflandırma kurallarını kendi kendine geliştirmektedir. Bu öğrenme algoritmalarında, istenilen çıkış değerinin bilinmesine gerek yoktur. Öğrenme süresince sadece giriş bilgileri verilir. Ağ daha sonra bağlantı ağırlıklarını aynı özellikleri gösteren desenler (patterns) oluşturmak üzere ayarlar. (Öztemel, 2003).

**3- Takviyeli öğrenme,** Bu öğrenme kuralı danışmanlı öğrenmeye yakın bir metottur. Denetimsiz öğrenme algoritması, istenilen çıkışın bilinmesine gerek duymaz. Hedef çıktıyı vermek için bir “öğretmen” yerine, burada YSA'ya bir çıkış verilmemekte fakat elde edilen çıkışın verilen girişe karşılık iyiliğini değerlendiren bir kriter kullanılmaktadır (Öztemel, 2003).

### 2.12.1 Çok Katmanlı Perseptron

Bir ÇKP modeli, danışmanlı öğrenme algoritması kullanan ileri beslemeli bir ağ türüdür. Bir giriş katmanı, bir veya daha fazla gizli katman ve bir çıkış katmanından oluşmaktadır. Her katmanda değişik sayıda nöron bulunabilir. Giriş ve çıkış katmanındaki nöron sayıları probleme göre tespit edilir. Gizli katman sayısı ve gizli katmanlardaki nöron sayısı deneme yoluyla bulunur. Herhangi bir nöron çıkışı eşitlik 2.16 ile bulunur:

$$y_k = f \left( \sum_k W_k X \right) \quad (2.16)$$

X: giriş vektörü

w: ağırlık vektörü

Bir katmandaki tüm nöronlar bir üst katmandaki tüm nöronlara ağırlıkları ile bağlıdır. Giriş katmanında herhangi bir işlem yapılmaz, sadece veriler ağa sunulur. Bu veriler, gizli katmanlarda işlenir ve çıkış katmanından çıkışlar elde edilir. ÇKP eğitilirken, ağın çıkışı ile arzu edilen çıkış arasındaki hata, geriye doğru yayılarak, hata minimuma düşünceye kadar ağırlıklar değiştirilir. ÇKP, geriye yayılım, delta bar delta, genişletilmiş delta bar delta, esnek yayılım gibi eğitme algoritmaları kullanılarak eğitilebilir (Sağıroğlu ve ark. 2003, Öztemel 2003).

### 2.12.2 Geriye Yayılım Algoritması

Çıkıştan girişe doğru ağırlıkları güncelleyerek, hatayı azaltmaya çalışan öğrenme algoritmasıdır. En çok tercih edilen öğrenme algoritmalarından birisidir. Geriye yayılım algoritması kullanılarak ağın eğitimi esnasında, ağın çıkışındaki hataya bağlı olarak, i. ve j. katmandaki işlem elemanları arasındaki ağırlıklardaki  $\Delta w_{ij}(t)$  değişikliği eşitlik 2.17'e göre hesaplanır:

$$\Delta W_{ij}(t) = \eta \delta_j X_i + \alpha \Delta W_{ij}(t-1) \quad (2.17)$$

Burada,  $\Delta W_{ij}(t-1)$ : (t-1) anında i. ve j. katmandaki işlem elemanları arasındaki ağırlık değişim miktarı,  $\eta$ : öğrenme katsayısı,  $\alpha$ : momentum katsayısı ve  $\delta_j$ : ara veya çıkış katmanındaki herhangi bir j nöronuna ait faktördür.

Çıkış katı için bu faktör eşitlik 2.18'a göre hesaplanır:

$$\delta_j = \frac{\partial f}{\partial net_j} (y_j^{(t)} - y_j) \quad (2.18)$$

$$net_j = \sum X_j W_{ji}$$

$y_j^{(t)}$ , j. nöronun hedef çıkışıdır. Gizli katmanlardaki nöronlar için ise  $\delta_j$  eşitlik 2.19'a göre verilir:

$$\delta_j = \left( \frac{\partial f}{\partial net_j} \right) \sum W_{qi} \delta_q \quad (2.19)$$

Geriye yayılım algoritması, eğim azaltmalı bir algoritmadır. Öğrenme süresi oldukça yavaştır. Öğrenme hızını arttırabilmek amacıyla sezgisel tekniklere dayanan değişken öğrenme katsayılı eğim azaltmalı geriye yayılım algoritması “traingdx” tercih edilebilmektedir. Standart eğim azaltmalı öğrenmede, eğitme işlemi boyunca öğrenme katsayısı sabit olarak kalmaktadır. Öğrenme katsayısı çok büyük ise algoritma salınımlar yapabilir, öğrenme katsayısı çok küçük ise algoritmanın sonuca yakınsaması uzun zaman alır. MATLAB’ın eğim azaltmalı algoritması olan traingd yavaş cevap vermektedir. Arttırmalı eğitimde kullanılmaktadır. Öğrenme katsayısı sabittir. Eğitme işlemi boyunca öğrenme katsayısının değişmesine imkân tanınırsa hızlı eğim düşürme algoritması oluşturulmuş olur. Bu algoritmada, yeni hata değeri ile bir önceki döngüde elde edilen hata değeri karşılaştırılır. İki hata arasındaki fark, önceden belirlenen değerden büyük ise ağırlık ve bias değerleri bir önceki değerine dönüştürülür. Öğrenme katsayısı belirlenen oranda azaltılır. Yeni hata değeri önceki hata değerinden düşük ise öğrenme katsayısı belirlenen oranda arttırılır. Aksi durumda ağırlıklar ve bias değerleri aynı kalır. Bu işlemler algoritma istenilen hata değerine ulaşıncaya kadar devam eder (Sağıroğlu ve ark 2003). Ağırlıkların değişimi denklem 2.20’ a göre gerçekleştirilir.

$$\Delta W_{ji}(t) = \alpha \Delta W_{ji}(t-1) + \eta \alpha \frac{\partial perf}{\partial W_{ji}} \quad (2.20)$$

Burada perf, performans fonksiyonunu göstermektedir.

## **2.13 Görüntü İşleme Sistemleri**

### **2.13.1. Çevrenin Aydınlatılması**

Görüntü işlemede ışık kaynağının düzgün açıda seçilmesi çok önemlidir. Işık kaynağı sistemin çalışma alanına uygun olmalıdır. Işıklandırmanın iyi seçilmiş olması, en iyi görüntünün elde edilmesini dolayısıyla imajın onarılması için gereken işlemlerin azaltılmasını sağlar. Burada asıl hedef imajın dinamiklerini ve kontrastını optimize etmektir. Bunun anlamı obje maksimum yoğunluk basamağıyla fotoğraflanırken aynı zamanda mümkün olan en iyi kontrastın sağlanmasıdır. Işık kaynağının seçiminde, objenin yüzey özelliklerine göre (yapı, renk, saydamlık vb.) radyasyon özellikleri (dalga boyu, osilasyon doğrultusu, düzlemsel yoğunluk dağılımı vb.) seçilebilir (Erhardt, 2000).

#### **Gün Işığı**

Gün ışığı, görüntü işlemede çevre aydınlatması için genellikle çok uygun değildir. Çünkü ışığın renk ve yoğunluğu günün saatine, yılın zamanına ve hava durumuna göre değişir. Kontrolsüz ışığın engellenemediği durumlarda görüntü işleme sistemleri olumsuz yönde etkilenmektedir (Erhardt, 2000).

#### **Tungsten Işık Kaynakları**

Tungsten ışık kaynakları ucuz olmalarının yanısıra görüntü işleme için özellikle kameranın imaj okuma frekansının net frekansla (50 Hz veya 60 Hz) uyumsuz olduğu durumlarda çok uygun değildir. Böyle bir durumda ışık frekansı ile kamera frekansının farklılığı, istenmeyen kesişmelere neden olur ve ekranda açık ve koyu çizgilerin görünmesi neticesinde resim kalitesinin azalmasına neden olur (Erhardt, 2000).

### **Floresan Lamba**

Floresan lambalar büyük bir homojen aydınlatma alanına sahiptir. Frekans doğrultucular kullanılarak ışık yoğunluğu değişimleri ve sonuç bileşenleri modülasyonu engellenebilir. Floresan lambaların ısınma problemi yoktur. Olası bir dezavantaj, floresan lambaların spektrum limitidir ancak uygulamaya bağlı olarak bu limit istenilen bir özellik olabilir. Bu özellikleri düşünülerek floresan lambalar görüntü işleme esnasında çevre aydınlatmasında sıkça kullanılır (Erhardt, 2000).

### **Kuvars Tungsten Halojen Lamba**

Kuvars tungsten halojen lambalar şebeke frekansları ile bir problem yaşamamaktadır. İçinde elektriğe bağlandığında kızaran, normal tungsten lambalarda bulunan tungsten filaman bulunur. Normal tungsten lambaların tersine yoğun olmayan bir gaz ve bir miktar halojen (iyodin veya bromin) ile doldurulurlar. Normal tungsten lambalara nazaran filaman sıcaklığı daha yüksek olmasına rağmen ışık yoğunluğu çok fazla değişmez. Sonuçta halojen lambalar sabit ışık yoğunluğuna sahip ışık kaynaklarıdır. Çevre aydınlatmada direk kullanımından ziyade fiberoptik sistemlerin ışık kaynağı beslemesinde kullanılır.

Fiberoptik sistemelerde küçük objelerin aydınlatılmasında kullanılması ile ışık yoğunluğunun açısal dağılımı, uygulama ihtiyaçlarına göre ayarlanabilmektedir. Fiberoptik sistemlerin dezavantajı yaklaşık % 40 oranındaki ışık yoğunluğunun saçılma ve geri yansıma etkileri ile kaybı ve lambaların yüksek fiyatlarıdır (Erhardt, 2000).

### **Deşarj Lamba**

Deşarj lambalar, aydınlatıcı gaza bağlı olarak, yüksek radyasyon yoğunluğuna sahip, zamana göre sabit ışıldayan ve elektromanyetik spektrumu sürekli ve farklı çizgiler gösteren ışık kaynaklarıdır. Diğer ışık kaynaklarına nazaran daha pahalıdır (Erhardt, 2000).



### **Işık Yayan Diyot (Led)**

Işık yayan diyotlar anında tepki verirler ve hiçbir duraksama olmadan büyük bir alandaki ışık yoğunluğu kontrol edilebilir. Bu amaçla stroboskopik uygulamalarda da kullanılırlar. Kamera objektiflerinde yaşanan renk kırılmalarına karşın doğası gereği tek renkli olması birçok işe uygun olmasına sağlar. Ayrıca fiyatlarının ve işletme maliyetlerinin düşük olması, hafif ve küçük olmaları ayrı avantajlarıdır. Kullanım ömürlerinin 100.000 saat gibi uzun bir süre olması pratik olarak bakım gerektirmemelerini göstermektedir. LED'lerin kullanılması ile birlikte ısı, gürültü, vibrasyon ve yüksek voltaj etkilerinin bulunmayışı endüstriyel görüntü işlemede son yıllarda çok fazla uygulama alanında kullanılmasını sağlamıştır (Erhardt, 2000).

### **Lazer**

Lazerler çok küçük alanlarda odaklanmış yüksek radyasyon gücüne sahiptirler ve yüksek renk doygunluğuna ve uyumuna sahiptirler. Günümüzde güvenlik sebebiyle büyük lazer üniteleri yerini lazer diyot modüllerine bırakmıştır. Bir lazer diyot modülü, lazer diyotu, elektronik ve optiğin aynı çatı altında toplanmasından elde edilmiştir. Bir lazer diyot modülü, LED'e benzeyen, parmak büyüklüğünde ve sınırlı alanlara rahatlıkla adapte edilebilecek bir sistemdir. Lazer diyot modülleri ile çizgi, nokta, daire gibi şekiller yansıtılabilir. Dolayısıyla imaj kaydedilmeden optik desteğiyle mekanik ayarlamalar yapılabilir. Halojen lambalar ve LED'ler gibi lazerler de fiber optik sistemlerin ışık kaynağı beslemesinde kullanılır (Erhardt, 2000).

### **Kızılötesi Işık**

Kızılötesi ışık kaynakları daha çok gün ışığı etkilerinin ve diğer ışık kaynaklarından saçılan radyasyonun engellenemediği durumlarda tercih edilir. Gün ışığını bloke eden filtreye sahip bir kızılötesi kamera kullanılırsa havadaki belirsiz ışık etkisi tamamen giderilebilir (Erhardt, 2000).

### 2.13.2 Çevre aydınlatma yolları

Kamera ve ışık kaynağı objeye göre aynı taraftadır. Resimde görünen obje tarafından yansıtılan ışık yoğunluğudur (Erhardt, 2000).

#### Verici Işık Aydınlatması

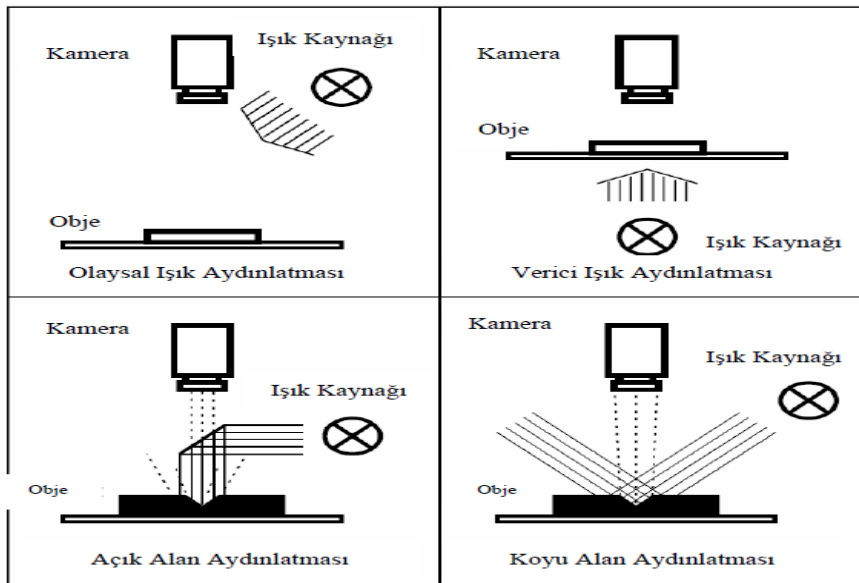
Kamera ve ışık kaynağı objeye göre ters taraftadır. Ekranda açık arka plan üzerinde objenin koyu biçimi görünür (Erhardt, 2000).

#### Açık-Alan Aydınlatması

Olaysal ışık aydınlatması gibi kamera ve ışık kaynağı objeye göre aynı taraftadır. Kameraya yansıtılan ışığın bir kısmı görüntü işleme için kullanılır. Açık arkaplan üzerinde koyu renkli objeleri göstermek için kullanılır (Erhardt, 2000).

#### Koyu-Alan Aydınlatması

Kamera ve ışık kaynağı objeye göre aynı taraftadır ve sadece saçılan ışık kamera tarafından yakalanır. Koyu arkaplan üzerinde açık renkli objeleri göstermek için kullanılır (Erhardt, 2000).



Şekil 2.23 Çevre aydınlatma yolları (Erhardt, 2000)

### 3. ÖNCEKİ ÇALIŞMALAR

Günümüzde gıda endüstrisinde görüntü işleme ve yapay zekâ teknikleri, ürünlerin kalite kontrolü, kusur tespiti, sınıflandırılması gibi işlemlerde yoğun bir şekilde kullanılmaktadır. Eğitilmiş kişiler tarafından yapılan kalite değerlendirmesi ve sınıflandırma işlemlerinde, kişiye bağlı etkenlerden dolayı tutarsızlıklar oluşabilmektedir. Bu nedenle objektifliği, doğruluğu, tutarlılığı ve hızı arttırabilmek için bilgisayar destekli sistemlere ihtiyaç duyulmaktadır. Bilgisayar destekli kalite denetim sistemlerinde görüntüleme aracı olarak CCD kameralar, manyetik rezonans tomografi, X-ray aygıtları kullanılabilir. Elde edilen görüntüler üzerine ön işleme, segmentasyon, uzay dönüşümleri, nitelik çıkarımı gibi görüntü işleme teknikleri uygulanarak resmi ve resimdeki objeleri tanımlayıcı nitelikler elde edilmektedir. Elde edilen nitelikler yapay sinir ağları, karar destek sistemleri, yapay bağışıklık sistemleri gibi yapay zekâ teknikleri ve istatistiksel yöntemler kullanılarak değerlendirilmekte ve ürün hakkında bilgi edinilmektedir (Cheng-Jin ve Da-Wen 2004).

Çizelge 3.1’de bazı gıda ürünlerine ait fiziksel özelliklerin tespit edilmesi için yapılan çalışmalar sunulmuştur.

**Çizelge 3.1** Bazı gıda ürünlerine ait fiziksel özelliklerin tespiti için yapılan çalışmalar

Ürün	morfoloji	Renk	Doku	Referans
Elma	√	√		Leemans ve ark.1998
Greyfurt	√			Miller 1992
Şeftali	√	√		Miller ve ark. 1989
Domates	√	√		Jahns ve ark. 2001
Arpa	√		√	Luo ve ark.1999 ; Majumdar ve Jayas 2000
Çavdar	√		√	Luo ve ark.1999 ; Majumdar ve Jayas 2000
Buğday	√	√	√	Paliwal ve ark. 2001

Sayısal görüntüden elde edilen objelere ait fiziksel özellikler Çizelge 3.2’de görüldüğü gibi istatistik yöntemler ile bulanık mantık ve yapay sinir ağı gibi yapay zekâ yöntemleriyle değerlendirilebilmektedir (Luo ve ark. 1999, Xiao ve ark. 2009, Paliwal ve ark. 2001, Raudys ve ark. 2007).

**Çizelge 3.2** Gıda ürünlerinin sınıflandırılmasında kullanılan bazı yöntemler

Ürün	Metot	Başarı (%)	Referans
Arpa	İstatistiksel	99	Luo ve ark. 1999
	Yapay Sinir Ağı	88	Paliwal ve ark. 2001
Çavdar	İstatistiksel	98,2	Luo ve ark. 1999
	Yapay Sinir Ağı	88	Paliwal ve ark. 2001
Yulaf	İstatistiksel	99	Luo ve ark. 1999
	Yapay Sinir Ağı	97	Paliwal ve ark. 2001
Buğday	Yapay Sinir Ağı	97	Paliwal ve ark. 2001
	Çoklu Sınıflayıcı	95	Raudys ve ark. 2007
mısır	Yapay Sinir Ağı	94	Xiao Chen ve ark.2009

Zayas et al. (1996); 17 farklı buğday çeşitinde görüntü işleme tekniğiyle buğdayların şekil özelliklerinin belirlenmesi ve sınıflanması konusu üzerinde durmuşlardır. Araştırmaları sırasında buğday tanelerinin sertlik derecelerini de ölçtüklerini belirtmişlerdir. Farklı şekil özelliklerini görüntü işleme tekniğiyle başarıyla belirleyerek tohumları analiz ettiklerini açıklamışlardır.

Luo ve ark. (1999) zarar görmüş buğday tanelerinin 6 farklı tipi için, bunların sağlıklı durumlarını saptaya bilmek amacıyla bir renk görüntü işleme sistemi kullanmışlardır. Çalışmada, sağlıklı ve zarar görmüş tanelerin görüntülerinden çeşitli morfolojik ve renk özelliklerini çıkartmak amacıyla bir yazılım program geliştirilmiştir. Farklı özellik (morfolojik, renk, morfolojik ve renk) içeren modeller SAS, STAPDISC ve DISCRIM yöntemleri kullanılarak tanımlama analizi değerlendirilmiştir. Parametrik ve parametrik olmayan istatistiksel sınıflandırma yöntemleri seçilen özellikteki modeller için ayrı ayrı değerlendirilmiştir.

El-faki ve ark. (2001) makalelerinde buğday ve soyanın gövdelerinin yeşil olduğu fakat birçok yabancı türün kırmızısı gövdeye sahip olduğunu bildirmişlerdir. Bu renk özellikleri renk görüntü işleme sistemi yardımıyla basit bir yabancı ot saplama yöntemi kurulması için kullanılmıştır. Bu metod, üst üste gelme, yaprak yönü, kamera odaklanması ve rüzgarın etkisine bağlı olarak düşük hassasiyeti sebebi ile doku veya şekil tabanlı yöntemlerden daha pratiktir. RGB nin gri seviyeleri ile oluşan bağlı renk indisinin 4 tipi tasarlanmıştır. Bu renk

indislerinin en efektif kombinasyonları istatikselsel metod kullanılarak seçilmiştir. Bu kombinasyonlar, iki yapay sinir ağı(NN) sınıflandırıcı ve fark analizi (DA) tabanlı istatikselsel sınıflandırıcı için deęişen girişler olarak kullanılmıştır. Bu sınıflandırıcılar buędayda 3 yabancı türü, soyada 3 yabancı türü kullanılarak eğitilmiş ve test edilmiştir. Ön işlem ve sonra işlem algoritmaları pürüzleri azaltmak işlem zamanı kısaltmak için geliştirilmiştir. Sonuçlar göstermiştir ki sonuçlandırmanın başarısında istatikselsel DA sınıflandırılmasının sınıflandırıcıdan daha doğru olduğunu bildirmişlerdir. Yabancı ot türlerinin yanlış sınıflandırma oranları %3 ün altında olmuştur. Bunun sebebinin bitkilerin gelişme dönemine baęlı olarak bazı yabancı otların gövdelerindeki kırmızımsı renkteki deęişimler olduğunu açıklamışlardır.

Göknur-Dursun (2001); çalışmasında buęday, arpa, mısır, nohut, mercimek, fasulye, barbunya ve soya gibi bazı taneli ürünlerin izdüşüm alanlarının görüntü işleme teknięiyle belirlenmesi konusu üzerinde durmuştur. Tarımsal ürünlerin bilinen geometrik şekillere benzemeyen düzensiz yapılarının izdüşüm alanı ölçümlerini güçleştirdięinden söz etmiştir. Araştırmasında ele aldığı taneli ürünlerin izdüşüm alanlarının görüntü işleme teknięi ile ölçülmesinde “UTHSCSA Image Tool IT Version 2.0” görüntü işleme programını kullandığını belirtmiştir. Programın doğruluęunu kontrol etmek için bilinen bazı geometrik şekillerin alanlarını elle ve görüntü işlemeyle ölçmüştür . Elle ve görüntü işlemeyle ölçülen deęerler arasındaki regrasyon katsayısını 0.99 olarak belirlemiştir.

Philipp ve Rath (2002) dijital fotoğraf makinesi ile alınan renkli görüntülerdeki zemin ve bitkinin ayırt edilmesi için en iyi metodu bulmak amacıyla RGB (Fark analizi HSI, HSV, LAB, ili2i3 ve standart dönüşüm) renk uzayının farklı dönüşümlerini karşılaştırmışlardır. Logaritmik fark analizi (yaklaşık %2 piksel hata oranı ile) zemin ve bitkinin yanlış sınıflandırılması ile en uygun dönüşümü kanıtlamıştır. Buna rağmen gerçek çalışmada güçlü bir bilgisayar sistemi ile bu daha iyi geliştirilebilir. Bu arada ili2i3 renk uzayı veya optimize edilmiş renk uzayı otomatik ikili sistem ile kombinasyonunda kullanılabilir.

Bacci et al. (2002), eserlerinde durum buğdayının tanesinin kalitesinin, gıda endüstrisinde ürün işleme ve pazarlama aşamalarında önemli bir faktör olduğunu belirtmişlerdir. Görüntü işleme tekniğinin gıda endüstrisinde birçok alanda kullanıldığından söz etmişlerdir. Kamera veya diğer yöntemlerle buğday tanelerinin görüntülerini bilgisayara aktardıklarını ve bu görüntüleri görüntü işleme tekniğiyle analiz ettiklerini bildirmişlerdir. Görüntü işleme tekniğiyle buğdayda zedelenmiş tohum yüzdesini belirlediklerini açıklamışlardır.

Shahin and Symons (2002), araştırmalarında baklagil tohumlarının boyut ve renk analizinde görüntü işleme tekniğinden yararlandıklarını belirtmişlerdir. Bu amaçla tohumların görüntülerinin bir bilgisayara aktarıldığını belirtmişlerdir. Bilgisayara aktarılan görüntülerin bir görüntü işleme programıyla analiz edildiğini bildirmişlerdir. Elle ve görüntü işleme tekniğiyle ölçülen değerler arasında % 95' in üzerinde ilişki belirlemişlerdir. Shahin and Symons (2005), yaptıkları çalışmada; şekil, renk ve büyüklük olarak birbirinden ayrılan dört farklı tip tohumun boyut özelliklerini görüntü işleme ve elek yöntemiyle tespit etmeye çalışmışlardır. Yeşil bezelye, sarı bezelye, soya fasulyesi ve nohut tohumlarını test objesi olarak kullanmışlardır. Elek yöntemi ve görüntü işleme yönteminin, testi yapılan ürünler için, tohumların boyut özelliklerinin belirlenmesinde aynı sonuçları verdiğini tespit etmişlerdir. Görüntü işleme yönteminin, tohumların boyut özelliklerinin belirlenmesinde etkili bir şekilde kullanılabileceğini ortaya koymuşlardır.

Paliwal ve ark. (2003) 5 farklı tohum tipinin yüksek çözünürlükteki görüntülerinden 51 morfolojik, 123 renk ve 56 dokusal özelliklerinin tümünü ortaya çıkartan bir algoritma yazmışlardır. Farklı özellik modelleri yapay sinir ağları sınıflandırılması kullanılarak onların sınıflandırma performansı test edilmiştir. RGB değerlerinin 256 gri seviyesi 16 banda gruplandırılmış ve bir histogram oluşturulmuştur.

Draganova ve ark. (2003) çalışmalarında görüntü işlem analizi kullanarak Fusarium (Spp) hastalığına yakalanan mısır tanelerinin belirlenmesi için bir yazılım geliştirmişlerdir. Geliştirilen model, bulanık mantık kanunları ve yapay sinir ağları (PNN) temelli, sınıflandırma, renk ve doku özelliği kullanılabilirliği

için istatiksels yaklaşımlar ve görüntü işlemeıı birleştirmektedir. Model üç çeşit mısır tanesinde denenmiştir. Mısır tanesinin renk ve tekstür analizinin birleştirilmesinde en iyi başarı (% 98) yapay sinir ağıları (PNN) temelli sınıflandırıcı kullanarak sağlanmıştır.

Dalen (2004), araştırmasında kırılan pirinç yüzdesini belirlemek için görüntü işleme tekniğinden yararlandığını açıklamıştır. Bir tarayıcı üzerine yerleştirdiğı pirinç tanelerinin üzerlerini beyaz renkli bir kağıtla kapattıktan sonra tarayarak görüntülerini bilgisayara aktarmış ve görüntü işleme programıyla analiz etmiştir. Elle de ölçümler yapmış ve bunlardan elde ettiğı sonuçları görüntü işlemeden elde ettiğı sonuçlarla karşılaştırmıştır. Tarayıcılı görüntü işlemeli ölçüm yönetiminde ölçüm için gerekli sürenin 3 dakika, elle ölçümde ise aynı işlem için gerekli olan sürenin 30 dakikanın üzerinde olduğunu açıklamıştır. Görüntü işleme tekniğinin basit ve hızlı bir ölçüm sağladığını belirtmiştir. Araştırma sonucunda, pirinç tanelerini uzunluk, genişlik gibi boyutlarının, tane boyut dağılımlarının ve kırılmış tane yüzdelerinin görüntü işleme tekniğıyle başarıyla belirlendiğı bildirilmiştir.

Neuman ve ark. (2009) buğday sınıf ve türlerine bağılı olarak taneleri ayırt etmek için video renk ölçümü ile ölçülen buğday renklerini incelemişlerdir. Dijital görüntü analizi ile elde edilen RGB özelliklerine bağılı olarak farklılık analizleri yapılmıştır. Farklılık modellerini geliştirmek için 6 farklı buğday türünü temsil eden 10 adet buğday tanesinden toplanan renk verileri kullanılmıştır. Farklı buğday sınıflarını temsil eden türler arasındaki ikili farklılıklar başarıyla ortaya konmuştur. Tüm hepsinin ikili denemeleri ortalamanın üzerinde % 88 olarak saptanmıştır.





## 4. MATERYAL VE YÖNTEM

### 4.1 Materyal

Görüntü işleme tekniği ile buğday kalitesinin belirlenmesinde araştırma materyeli olarak Ege Bölgesi'nde en çok üretilen Cumhuriyet-75 buğdayı (triticum) ele alınmıştır. Buğday'ın kalitesini belirlenmesinde kullanılan temel kriterlerden önemli olan üç ana kriter: **kırık tane oranı**, **yabancı ot tohumlarının oranı** ve **diğer hububat oranı** seçilmiştir.

Buğday kalitesinin belirlenmesinde ele alınan kriterlerin belirlenmesinde, farklı özelliklere (morfoloji ve renklere) sahip olan ve en çok buğdaylar içinde bulunan yabancı ot tohumları ve diğer hububat tohumları seçilmiştir. Bu amaçla, yabancı ot olarak **yabani hardal** (lapsanum) ve **yabani yulaf** (avenae) ve diğer hububat olarak ise en çok gözlenen **arpa** (hordeum) ve **mısır** (frumentum) tohumları ele alınmıştır.

Araştırmada buğday taneleri TMO'dan (Toprak Mahsülleri Ofisi) temin edilmiş olup diğer taneler piyasadan temin edilmiştir.

Dijital görüntü algılama 10.0MP çözünürlüğe sahip kamera ile alınmıştır. Bu kameraya ait teknik özellikler aşağıda verilmiştir.

**Çizelge 4.1** Denemelerde kullanılan kameraya ait teknik özellikler.

<b>Model</b>	Canon Powershot SX 10 IS
<b>Toplam çözünürlüğü</b>	10.0 MP
<b>Maksimum çözünürlüğü</b>	3648 ×2736 piksel
<b>Sensor Boyutu</b>	1/2.3 (6.17 x 4.55 mm)
<b>Sensor Tipi</b>	CMOS

Araştırmada dijital görüntülerin değerlendirilmesinde yaygın olarak kullanılan, teknik hesaplamalar ve matematiksel problemlerin çözümü ve analizi için tasarlanmış bir yazılım geliştirme aracı olan MATLAB yazılım programından yararlanılmıştır.

## 4.2 YÖNTEM

### 4.2.1 Görüntü hazırlama

Görüntü hazırlama ve iyileştirmenin amacı, uygulamanın yapısına ve şekline göre orjinal resimden daha kullanışlı bir görüntü elde etmektir. Basit bir ifadeyle, uygulamanın yapısı ve şekli önemlidir. Bu amaçla araştırmada ilk olarak örneklerin görüntüleri çekmek için özel bir platform hazırlanmıştır. Kamera ve taneler arasındaki mesafe, kamera ile sadece taneleri yakalanan bir şekilde kurulmuştur (hiçbir kenar veya diğer arka planlar olmadığı şekilde). Kamera platform tabanından 12 cm yükseklikte olacak şekilde yerleştirilmiştir. Tüm tohumların görüntüleri  $1296 \times 972$  pixel çözünürlükte alınmıştır.

Yüksek kaliteli görüntü elde etme görüntü işleme sisteminde en önemli süreçlerden birisidir. Dolayısıyla görüntüleri çekerken üç tip aydınlatma kullanılmıştır.

**1-Gün Işığı:** bu kısma ait çalışmalar kamera ile görüntü alma işlemleri havanın güneşli olduğu günlerde saat 12.00 – 14.00 arasında gerçekleştirilmiştir.

**2- Tungsten Işık Kaynakları:** İki ampul platformun her iki tarafına monte edilmiştir.

**3-Floresan Lamba:** Bir floresan halka ışık 270 mm çapında, dairesel bir paslanmaz çelik kase üstünde monte edilmiştir.(Şekil 4.1).



Şekil 4.1. Floresan lamba ve tungsten ışık aydınlatma

Bütün görüntü işleme sistemleri, objeleri daha iyi tanımlama ve bu objeleri diğer objelerden ve arka planlardan ayırmayı amaçlamaktadır. Bununla ilgili olarak, her pikselin objeye ait olup olmadığının kontrolü gerekmektedir. Eğer arka plan düzgün değilse ya da değişik gri tonlar görüntü içinde mevcutsa bölümlenimin uygulanması daha da zorlaşmaktadır. Araştırmada yabancı ot tohumları ve diğer hububat tohumları farklı renklerde olduğu için, farklı arka planlar kullanılmıştır. Arka plan renklerinin seçiminde yabancı ot tohumlarının renkleri ve diğer hububat tohumlarının renkleri dikkate alınmış ve 3 farklı renkte arka plan (kırmızı, yeşil ve mavi) seçilmiştir. Dolayısıyla, 3 farklı arka plan ve 3 farklı ışık olmak üzere toplam 9 tane deneme ortamı hazırlanmıştır (Şekil 4.2).

Üç tekrürde ve üç farklı oranda ( % 5, % 10 ve % 15 ) yabancı madde, kırık tane ve diğer hububatların bulunduğu birbirinden ayrı olarak yerleştirilmiş 100 tane buğday örneklerinin görüntüleri bir dijital kamera vasıtasıyla deneme ortamlarında alınmıştır. Aynı anda yabancı made, diğer hububat ve kırık tanelerden oluşan karışım şeklinde üç farklı oranda ( % 5, % 10 ve % 15 ) 100 tane buğday içine yerleştirilmiştir.



Şekil 4.2. Farklı deneme ortamlarında çekilen fotoğraflar

### 4.2.2. Görüntü işleme için ön hazırlık

Nesne tanıma işleminde de çeşitli önışleme yöntemlerinden yararlanılır. Bu önışleme yöntemleri vasıtasıyla, nesne görüntüsü özellik çıkartmaya uygun hale getirilmektedir. Nesne önışlemede en çok kullanılan yöntemlerin başında renksel dönüşüm, filtreleme, ikili resme dönüştürme gelir.

Renksel dönüşüm, bir renk uzayının başka bir renk uzayına dönüştürülmesidir. Nesne görüntülerinde, renksel özelliklerden yararlanılmadığı durumlarda, RGB' den ve diğer uzaylar'dan gri renk düzeyine dönüşüm işlemi gerçekleştirilebilir. Böylelikle fotoğraftaki gereksiz ayrıntıların ayrıştırılması sağlanır.

Renkli resimlerde RGB bileşenleri aydınlatma koşullarına bağımlıdır ve bu nedenle de nesne bulma, aydınlatma koşulları değiştiğinde başarısız olabilir. Bu çalışmada RGB, HSI, HSV ve YCbCr renk uzayı kullanılmıştır. Ek-1'de tüm bölütlemeler (segmentasyon) verilmiştir. YCbCr renk uzayında, Y bileşeni parlaklık bilgisini tutarken, Cb ve Cr bileşenleri ise renklilik bilgilerini tutmasından dolayı parlaklık bilgisi kolaylıkla çıkarılabilir. Tez boyunca, tane örneklerinin segmentasyonunu göz önüne alındığında, tanelere ait piksellerin daha kolay tespit edilebilmesi amacıyla Cr kanal kullanılmıştır.

MATLAB programında YCbCr renk uzayından yararlanmak için dijital görüntüler ilk aşamada double formatına dönüşümü yapılmıştır. Resmin etkili ve hızlı bir şekilde işlenebilmesi için en temel model olan siyah beyaz modele (ikili resim) dönüştürülmüştür.

İkili resme dönüşmenin eşik seviyesini bulmak için Otsu'nun bölgesel eşikleme algoritmasından yararlanılmıştır. İkili resimlerdeki tanelerin içindeki delikler doldurulduktan sonra açma işlemi daire biçimindeki bir yapısal eleman ile morfoloji uygulanmıştır. Açma işlemlerin sonucunda, daire biçimli yapısal elemanın ulaşamadığı yerler, diğer bir ifade ile sığmadığı yerler (sivri çıkıntı) açma işlemi sonrasında silinmişlerdir. Açma işlemi genelde büyük parlak bölgeleri bozmadan küçük parlak detayların silinmesi için kullanılır.

Görüntü önışlemenin son aşamasında, resimdeki piksellerin 8'li komşulukları göz önüne alınarak birbiri ile ilişkili pikseller belirlenmiş ve bir tane olarak kabul edilen her bölge etiketlenmiştir.

Görüntü önışlemenin MATLAB ortamında gerçekleştirimini sağlayan kod parçası Çizelge 4.2' de gösterilmektedir.

**Çizelge 4.2.** Görüntü önışlemeyi gerçekleştiren kod parçası.

```
I = imread(imgName);
I=im2double(I);
I=rgb2ycbcr(I);
imR=squeeze(I(:,:,3));
I=im2bw(I,graythresh(I));
I=imfill(I,'holes');
Se=strel('disk',6);
I=imopen(I,Se);
I=imcleanborder(I);
[labels, numobjects]=bwlabel(I,8);
```

### 4.2.3. Morfolojik Özelliklerinin Belirlenmesi ve Çıkartılması

Denemeler sırasında literatürde bilinen 4 adet temel geometrik özellik (alan, çevre, ana eksen ve ikinci eksen) kullanılmış ve bunlara ek olarak literatürde en çok kullanılan 13 adet düşük maliyetli morfolojik özellik hesaplanmıştır. Bunlar;

#### **Alan (Area):**

Bir nesnenin alanı, o nesneyi oluşturan piksel sayısının toplamıyla bulunabilir.  $B(x,y)$  n satır m sütuna sahip etiketlenmiş bir resmin x'inci sütununu ve y'inci satırdaki değerini ifade etsin. k'nıncı nesnenin alanı Eş 4.1 ile bulunabilir.

$$A_K = \sum_{x=1}^n \sum_{y=1}^m B(x, y) \quad (4.1)$$

$$B(x,y) = \begin{cases} 1 & \text{eğer } B(x,y) \in K \text{ ise} \\ 0 & \text{eğer } B(x,y) \notin K \text{ ise} \end{cases}$$

### **Çevre (Perimeter):**

Çevre, nesnenin kenar piksellerinin sayısıdır. Diğer bir ifade ile nesne bölgesinin çevre uzunluğudur.

### **Ana Eksen (Major Axis):**

Nesne bölgesiyle aynı normalize ikinci merkez momentine sahip elipsin büyük eksenidir.

### **İkincil Eksen (Minor Axis):**

Nesne bölgesiyle aynı normalize ikinci merkez momentine sahip elipsin küçük eksenidir.

### **Dışbükey Kabuk (Convex Area):**

Nesne bölgesini çevreleyen en küçük dışbükey çokgendir (Math Works Inc., 2011).

### **Kapsam (Extent):**

Belirli bir bölge içerisindeki piksellerin, çevreleyen dikdörtgenin içerisindeki toplam piksellere oranını betimleyen sayısal değerdir (Math Works Inc., 2011). Tane bölgesi alanının, çevreleyen dikdörtgenin alanına oranı şeklinde hesaplanır.

$$\text{Kapsam} = \frac{A_{ROI}}{A_{Rect}} \quad (4-2)$$

$A_{ROI}$  , ilgi alanının alanı;  $A_{Rect}$  , çevreleyen dikdörtgenin (bounding box) alanı gösterir.

### **Dışmerkezlilik (Eccentricity):**

Nesnenin bölgesiyle aynı ikinci momente sahip elipsin dışmerkezliğinin sayısal büyüklüğü olarak ifade edilir (Math Works Inc., 2011). İlgi alanı (region of interest – ROI)' nin ana eylemsizlik eksen uzunluğunun (EA), ilgi alanının ikincil eylemsizlik eksen uzunluğuna (EB) oranıdır. Değeri 0 ile 1 arasında değişkenlik göstermektedir. Dışmerkezlilik şu şekilde ifade edilmektedir:

$$E = \frac{E_A}{E_B} \quad (4-3)$$

### **Katılık (Solidity):**

İlgilenilen bölge alanının, dışbükey kabuğun alanına oranı olarak hesaplanır (Math Works Inc., 2011). Şu şekilde ifade edilmektedir.

$$\text{Katılık} = \frac{A_{ROI}}{A_C} \quad (4-4)$$

$A_{ROI}$  , ilgi alanının alanı;  $A_C$  , dışbükey kabuğun alanıdır.

### **Yuvarlaklık (Roundness):**

Literatürde en sık kullanılan şekil özneliği tanımlayıcılarından biridir (Math Works Inc., 2011). Biçim katsayısı şu şekilde ifade edilmektedir:

$$F = \frac{4\pi A_{ROI}}{P_{ROI}^2} \quad (4-5)$$

$A_{ROI}$  , ilgi alanının alanı;  $P_{ROI}$  ilgi alanının çevresidir.

### **İkincil eksenin ana eksene oranı (Elongation):**

İkincil eksen uzunluğunun ana eksen uzunluğuna oranıdır. Bu özellik literatürde kullanılan boy-en oranının (aspect ratio) tersidir (Math Works Inc., 2011). Şu şekilde ifade edilmektedir:

$$AR = \frac{D_{min}}{D_{max}} \quad (4-6)$$

$D_{min}$ , ikincil eksen uzunluğu;  $D_{max}$  , ana eksen uzunluğudur.

### Dikdörtgensellik (Rectangularity):

Nesnenin bölgesinin alanının, ana ve ikincil eksen uzunluklarının çarpımına oranı olarak hesaplanır (Math Works Inc., 2011). Dikdörtgensellik şu şekilde ifade edilmektedir:

$$R = \frac{A_{ROI}}{D_{max} \times D_{min}} \quad (4-7)$$

$A_{ROI}$  , ilgi alanının alanı;  $D_{min}$ , ikincil eksen uzunluğu;  $D_{max}$  , ana eksen uzunluğudur.

### Şekil faktörü 1 (Shape factor 1) :

Bu özellik literatürde kullanılan Dikdörtgensellik (Rectangularity) gibidir sadece çevrenin etkisi değiştirilmiştir (Symons ve ark, 1988). Şekil faktörü 1 şu şekilde ifade edilmektedir:

$$F = \frac{4\pi A_{ROI}}{P_{ROI}} \quad (4-8)$$

$A_{ROI}$  , ilgi alanının alanı;  $P_{ROI}$  ilgi alanının çevresidir.

### Şekil faktörü 2 (Shape factor 2) :

Ana eksen uzunluğunun çevreye oranıdır (Symons ve ark, 1988). Şekil faktörü 2 şu şekilde ifade edilmektedir:

$$AR = \frac{D_{max}}{P_{ROI}} \quad (4-9)$$

$D_{max}$ , ana eksen uzunluğu;  $P_{ROI}$  ilgi alanının çevresidir.

### Şekil faktörü 3 (Shape factor 3) :

Nesnenin bölgesinin alanının, ikinci eksen uzunlukların karesinin oranı olarak hesaplanır (Symons ve ark, 1988). Şekil faktörü 3 şu şekilde ifade edilmektedir:

$$R = \frac{A_{ROI}}{D_{max}^2} \quad (4-10)$$

$A_{ROI}$  , ilgi alanının alanı;  $D_{max}$  ,ana eksen uzunluğudur.



#### Şekil faktör 4 (Shape factor 4) :

Bu özellik literatürde kullanılan bir özelliktir (Symons ve ark, 1988). Şekil faktörü 4 şu şekilde ifade edilmektedir:

$$R = \frac{A_{ROI}}{\frac{D_{max}}{2} \times \frac{D_{max}}{2} \times \pi} \quad (4-11)$$

$A_{ROI}$  , ilgi alanının alanı;  $D_{max}$ , ana eksen uzunluğudur.

#### Şekil faktör 5 (Shape factor 5) :

Bu özellik literatürde kullanılan yuvarlaklık (roundness) gibidir sadece ana ve ikincil eksen etkisi değiştirilmiştir (Symons ve ark, 1988). Şekil faktörü 5 şu şekilde ifade edilmektedir:

$$R = \frac{A_{ROI}}{\frac{D_{min}}{2} \times \frac{D_{max}}{2} \times \pi} \quad (4-12)$$

$A_{ROI}$  , ilgi alanının alanı;  $D_{min}$ , ikincil eksen uzunluğu;  $D_{max}$  ,ana eksen uzunluğudur.

#### Şekil faktör 6 (Shape factor 6) :

Nesnenin çevresinin uzunluğunun karesini, alana oranıdır. (Symons ve ark, 1988). Şekil faktörü 6 şu şekilde ifade edilmektedir:

$$AR = \frac{P^2}{A_{ROI}} \quad (4-13)$$

$A_{ROI}$  , ilgi alanının alanı;  $P_{ROI}$  ilgi alanının çevresidir.

### 4.2.4 Renk Özelliklerinin Belirlenmesi ve Çıkartılması

Sayısal görüntü işleme teknikleri kullanılarak her bir taneye ait renk bilgileri elde edilmiştir. Siyah beyaz resimde objelerin koordinatları tespit edilerek orijinal resimde obje bölgelerinde bulunan piksellerin renk bilgileri elde edilebilir.

Renk belirleme algoritmasının oluşturulması sırasında RGB, HSV, HSI , NTSC ve Lab renk modelleri ile çalışılmıştır. Diğer renk modelleri de renk farklılıkları konusunda fikir vermekle birlikte, algoritmadaki işlem süreleri göz önüne alındığında RGB , NTSC ve Lab daha uygun çıkmıştır.

Piksellere ait ortalama renk değerleri eşitlik 4.14'e göre, standart sapma miktarları eşitlik 4.15'e göre, varyans eşitlik 4.16'a göre, çarpıklık eşitlik 4.17'e göre ve basıklık eşitlik 4.18'e göre hesaplanır.

$$\mu = \frac{1}{N} \sum_{i=1}^N X_i \quad (4.14)$$

$$\sigma = \sqrt{V} \quad (4.15)$$

$$V = \frac{1}{N-1} \sum_{i=1}^N (X_i - \mu)^2 \quad (4.16)$$

$$s = \frac{\frac{1}{N-1} \sum_{i=1}^N (X_i - \mu)^3}{\sigma^3} \quad (4.17)$$

$$k = \frac{\frac{1}{N-1} \sum_{i=1}^N (X_i - \mu)^4}{\sigma^4} \quad (4.18)$$

#### 4.2.5 Doku Özelliklerinin Belirlenmesi ve Çıkartılması

Tanelerin doku özelliklerinin belirlenmesi ve çıkarılması işlemlerinde 5 ana kriterden yararlanılmıştır. Bunlar sırasıyla;

##### **Kontrast**

Denklem (4.19)'de görülen kontrast denkleminde i ve j satır-sütun indislerini, N matrisin boyutunu, P ise indislerin belirttiği GDOM elemanını gösterir.

$$kontrast = \sum_{i,j=0}^{n-1} P(i,j) \times |i - j|^2 \quad (4.19)$$

Kontrast denklemi incelendiğinde  $i$  ve  $j$ . nin eşit olduğu durumlarda kontrast değeri 0 olur. Yani matrisin köşegeni kontrast göstermez. Bunun sebebi bu değerlerin gösterdiği komşu piksellerin benzer olmasıdır. Köşegenden uzaklaştıkça  $i-j$  farkı artacağı için kontrast değerinin arttığı görülür.

### **Homojenlik (Homogeneity)**

Homojenliğe ters fark momenti de (Inverse Difference Moment) denir. Homojenlik denklemi incelendiğinde (4.20) kontrast ve farklılık ağırlıklarının aksine homojenlik ağırlıkları köşegenden uzaklaştıkça üssel olarak azalır.

$$Homojenlik = \sum_{i,j=0}^{n-1} \frac{P(i,j)}{1+|i-j|} \quad (4.20)$$

### **Korelasyon**

Korelasyon diğer doku ölçümlerinden farklı bir ölçümdür. Korelasyon diğerlerinden bağımsızdır ve başka bir dokunun ölçümleri ile kombinasyon sağlamak için kullanılabilir. Korelasyon büyük pencereler içinde kullanılabilir. Dokuda düzenli olarak aynı objeler varsa pencere büyüklüğü tanımlanabilir. Fakat pencere büyüklüğü bir objeyi alacak şekilde olmalıdır. Korelasyon -1 ile +1 arasında bir değer alır. -1 veya +1 olması tam negatif veya pozitif uyum olduğunu gösterir. Sabit görüntüler için korelasyon tanımsızdır (Ünsalan, 1998).

$$Korelasyon = \sum_{i,j=0}^{n-1} \frac{(i-\mu_i)(j-\mu_j)P(i,j)}{\sigma_i \sigma_j} \quad (4.21)$$

### **Enerji**

Enerji (Bir örneklilik - Uniformity) her  $P_{ij}$  değerini ağırlık olarak alırlar. Düzgün sıralı matrislerde yüksek değerde enerji ölçülebilir.

$$Enerji = \sum_{i,j=0}^{n-1} P(i,j)^2 \quad (4.22)$$

## Entropi

Entropi içerik bilgisinin veren bir ölçüdür. Özelliksiz, geniş boşluklar az içerik bilgisine sahiptir. Dağınık alanlar ise daha fazla içerik bilgisi verir.

$$Entropi = \sum_{i,j=0}^{n-1} P(i,j)(-\ln P(i,j)) \quad (4.23)$$

### 4.2.6 Özelliklerin Seçiminde Sınıflandırma Modeli

Nesneleri, birbirlerinden ayırt edilmesini sağlayacak doğru özelliklerin seçilmesi büyük önem taşımaktadır. Seçilen özneliğin uygunluğu, her bir tane için farklılık göstermesine ve aynı tane içinde benzer sonuçlar vermesine göre ölçümlenir. Kullanılan özellik sayısının çok az veya çok fazla olması başarı oranını düşürmektedir. Gereğinden az özellik kullanılması, tanelerin birbirlerinden ayırt edilebilmesi için gereken veri miktarına ulaşamamasına neden olmaktadır. Gereğinden fazla özellik kullanılması ise, öğrenme sürecinde kullanılan veri miktarının artmasına bağlı olarak tane türlerinin birbirleriyle karıştırılmasına neden olmaktadır. Farklı özelliklerin birlikte veya ayrı ayrı kullanılması da başarı oranını etkilemektedir. Kullanılan 2 özellik, özellik vektörüne arka arkaya eklendiklerinde sonucu kademe kademe arttırmalarına rağmen, ilk eklenen özellik, özellik vektöründen çıkartıldığında başarı oranı daha da artabilmektedir. Buradan da anlaşılacağı üzere, özellikler, birbirlerinin sonuca olan olumlu etkisini azaltabilmektedir.

Özetle, çalışma sırasında özelliklerin seçimi birçok önemli amaca hizmet eder: (1) gereksiz özellikleri hesaplama yükünü azaltır (2) sınıflandırma algoritmalarının performansını artırır, ve (3) bellek ve depolama taleplerini azaltır.

Bu çalışmada, buğday ve diğer taneler arasında en iyi parametrelerini belirlemek için buğday ve diğer taneler arasında tek tek SPSS ile kademeli Lineer Diskriminant Analizi (stepwise Linear Discriminant Analysis) yapılmıştır. Bu uygulama genellikle nicel ve nitel değişkenler ile karakterize grupları sınıflandırmak için kullanılır. Prediktörleri çok olduğunda, stepwise yöntem modelde kullanılacak en iyi değişkenlerin otomatik seçiminde yararlı olabilir.

Stepwise sınıflandırma modeli, başlangıçta hiçbir değişkeni ele almaz ve sürecin her aşamasında model içinde ve dışında değişkenler sırasıyla değerlendirilir. Aslında, stepwise yöntemi hiçbir değişkeni olmayan bir model ile başlar ve her adımda, büyük F değerine sahip olan değişken modele eklenir. Diskriminant analizinde yer alan katsayıların ve bulunan diskriminant fonksiyonlarının anlamlılığının testinde Wilk's Lambda değeri kullanılmaktadır. Wilk's Lambda değeri sıfır ile bir arasında değer alır. Bu değer ne kadar küçük olursa ve sıfıra yaklaşırsa, modelin ayırt edicilik gücü o kadar artar (Akgül ve Çevik, 2003, 415).

Bu çalışmada, seçilen değişkenler üzerinde Wilk's Lambda testi yapılmıştır. Wilks lambda sınıf merkezleri ayrılığını gösteren bir ölçüsü olarak Diskriminant Faktör Analizi ile özel olarak kullanılan bir istatistik değerdir. Çok değişkenli analizlerinde Wilk's Lambda'nın etkisi, ANOVA'da kullanılan Fisher's F değeri (tek değişkenli) gibidir.

#### **4.2.7 Yapay Sinir Ağları (Neural Network) ile Taneleri Tanıma**

Resimlere ait nitelikler ile lineer bir denklem oluşturulamaması ve Yapay Sinir Ağlarının (YSA) literatürde özellikle lineer olmayan sistemlerde kullanılması nedeniyle, tez çalışmasında Çok Katmanlı Perseptron (ÇKP) YSA modeli kullanılmıştır.

Bu çalışmada buğday ve diğer taneler arasında en iyi parametreleri SPSS analizi ile bulduktan sonra, bütüm taneler için tek tek ileri beslemeli ve danışmanlı bir ağ modeli olan ÇKP, eğitilmiş ve test işlemleri gerçekleştirilmiştir. YSA'yı eğitmek için ileri beslemeli geriye yayılım algoritması ve giriş parametrelerinin verileri için hem gizli katmanda hem de çıkış katmanında sigmoid transfer fonksiyonları kullanılmıştır. Gizli katmandaki nöron sayısı, toplam giriş verileri içindeki, onaylama (validation) ve test verilerinin oranları değiştirilerek en uygun ağ mimarisi deneysel olarak belirlenmeye çalışılmıştır.

Bir ağ modelinde giriş, gizli ve çıkış olmak üzere toplam üç katman bulunmakla birlikte, problemin özelliklerine göre gizli katmandaki nöron sayısını attırabilmek mümkündür. Çok az nöron sayısı öğrenme oranını düşürdüğü gibi

çok fazla düğüm veya katman sayısı da hem öğrenmeyi yavaşlatmakta, hem de bazı durumlarda öğrenmeyi zorlaştırmaktadır. Bu sayılar öğrenilmesi istenen bağlantıya bağlıdır, ancak henüz nasıl belirleneceklerine dair kesin bir yöntem yoktur. Gizli katman sayısının belirlenmesinde kesin bir kural olmadığı için deneme yoluyla en iyi performansı veren gizli katman sayısı tespit edilmiştir. Denemeler sonucunda en iyi sonucu verdiği için dolayı iki gizli katman kullanılmıştır.

Modellemelerde 1000 iterasyon yapılmıştır. Bu çalışmada buğday kalitesinin YSA ile modellenmesi için her tane türü için 300 veri seti toplam 1800 adet deney veri seti kullanılmıştır. Girdi parametreleri; morfoloji , renk ve doku çıkış parametreleri ise tanelerin sayısını oluşturmaktadır. Çalışmada bir ve iki gizli katman kullanılmış ve bu gizli katmanda 1'den 150'ye kadar nöronlar denenerek çeşitli YSA modelleri geliştirilmiştir. Oluşturulan modellerde farklı oranlarda (% 60, % 65 ve % 70) eğitim verileri, farklı oranlarda (% 10, % 15 ve % 20) onaylama verileri ve farklı oranda (% 10, % 15 ve % 20) test verileri kullanılmıştır. Modellemelerde çıktı olarak tanelerin sayısı kullanılmıştır. Geliştirilen bu modellerden en uygun sonucu veren ağ yapısının gizli katmanlarında birinci katmanda 100 ve ikinci katmanda 30 nöron bulunmaktadır. Oluşturulan modelde, verilerin % 60'i eğitim verileri olarak ,% 20 onaylama verileri, kalan % 20'lik kısmı da test verileri olarak kullanılmıştır.

En iyi yapay sinir ağı modeli determinasyon katsayısı ( $R^2$ ) ve ortalama karesel hata (MSE) değerlerine göre belirlenmiştir. Determinasyon katsayısının 1'e ve ortalama karesel hatanın da 0'a yakınlığı tahmin modellerinin yeterliliğini göstermektedir. Ancak bu yöntemler hatanın dağılımı hakkında herhangi bir bilgiye yer vermemektedirler. Bu nedenle bu çalışma için diğer global metotlara ilaveten modelin performansını daha etkili değerlendirmek için ortalama mutlak hata (OMH) yöntemi kullanılmıştır.

Determinasyon katsayısının 1'e yakın olması durumu X ve Y gibi rastgele iki değişkenlerinin arasında doğrusal bağımlılığın kuvvetlendiğini göstermektedir.

$$R^2 = \left[ \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{N S_x S_y} \right]^2 \quad (4.24)$$

Seride gözlenen ve tahmin edilen veri değerlerinin farkının toplanıp, toplam veri sayısına bölünmesiyle elde edilen değerdir. İstenen değer ile YSA modelinin üretmiş olduğu çıktı arasındaki hatayı karesel olarak gösteren parametredir. Bu değerın sıfıra yakın olması, tahmin edilen değerın kuvvetli biçimde doğruya yakınsadığını göstermektedir.

$$OKH = \frac{1}{N} \sum_{i=1}^n (R_0 - R_{YSA})^2 \quad (4.25)$$

Seride gözlenen ve tahmin edilen veri değerlerinin farkının, gözlenen değere bölündükten sonra herbir sonuç için yüzde olarak toplanmasıyla elde edilen değerdir. İstenen değer ile YSA modelinin sonucu arasındaki hatayı mutlak olarak göstermekte olup, bu değerın sıfıra yakın olması YSA modelinin üretmiş olduğu sonucun istenen değere kuvvetli biçimde yaklaştığını göstermektedir.

$$OMH = \sum_{i=1}^n \left| \frac{(R_0 - R_{YSA})}{R_0} \times 100 \right| \quad (4.26)$$





## 5. ARAŞTIRMA BULGULARI ve TARTIŞMA

### 5.1. Kırık Tane Analizleri

Kırık tane ve buğday ayırımında SPSS Diskriminant Analiz sonuçları Ek-2’de verilmiştir. Kombine edilmiş özelliklerin SPSS Diskriminant Analiz sonuçları ve hata payları Çizelge 5.1’de verilmiştir. Ek-2 incelendiğinde, kırık tanelerin ayırımında morfolojik özelliklerin arasında büyük eksen (major axis) ve renk özellikleri (colour features) arasında Lab renk uzayında a ortalaması (amean) diğer özelliklere göre daha etkili olduğu bulunmuştur.

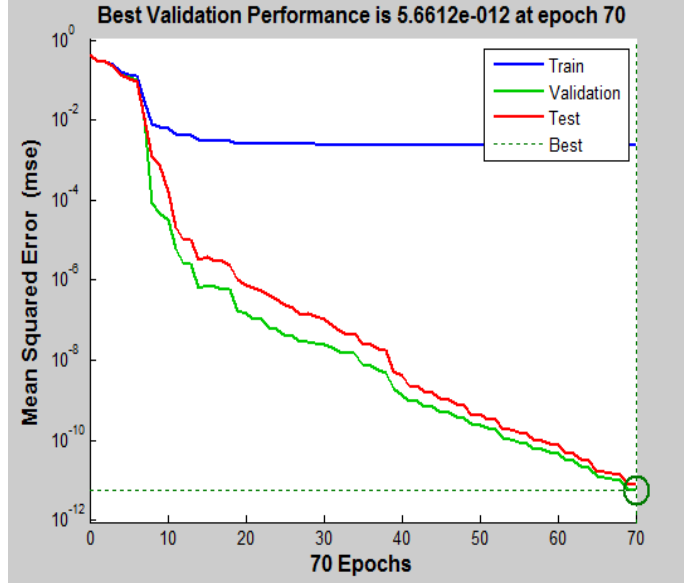
Tek başına özellik olarak morfolojik özelliklerinden “büyük eksen” ve renk özelliklerinden de “amean”ın Wilk’s Lambda değerleri Ek-2’de görüldüğü gibi sırasıyla 0.151 ve 0.47 bulunmuştur. Kırık tanelerin şekilleri bazen buğday taneleri ile aynı olduğu için sadece morfolojik özellikleri kırık tane ayırımında yeterince iyi sonuçlar vermemiştir. Kırık taneler kırıldığı yerde her zaman renk değişimi olduğundan kırık tanelerin ayırımında morfolojik özelliklerin yanında renk özelliklerinden de yararlanarak özellikle kırık tanelerin belirlenmesinde başarı oranı arttırılmaya çalışılmıştır.

Çizelge 5.1’de görüldüğü gibi, büyük eksen ve faktor5 kullanılmasıyla Wilk’s Lambda değeri 0.151’den 0.123’e ve hata payı da % 3.2’den % 2’ye düşürülmüştür. Daha başarılı sonuç için bir ileri aşamada ise 3 özelliğin; büyük eksen, faktor 5 ve amean kullanılması ile 3.adımda hata payı sıfıra düşürülülerek  $R^2$  değeri 1 olmuştur. Bu nedenle, son analiz çizelgesinde kırık tane özelliğinin belirlenmesinde 3 özellik sırasıyla büyük eksen, faktor5 ve amean seçilmiştir (Çizelge 5.6). Bu 3 özelliğin kullanımıyla kırık tanelerin sağlam buğdaydan kolaylıkla ayırt edilebildiğini gösteren grafikler Ek-5’de verilmiştir.

**Çizelge 5.1.** Kırık tane ve buğday ayırımında diskriminant analiz sonuçları.


combined features in the Analysis					
Step		Tolerance	F to Remove	Wilks' Lambda	YSA hata oranı (%)
1	majoraxis	1,000	3353,730	0,151	3,2
2	majoraxis	,994	1016,245	,123	2
	factor5	,994	139,377		
3	majoraxis	,993	752,402	,112	0
	factor5	,993	131,948		
	amean	,997	55,363		
4	majoraxis	,091	167,992	,104	-
	factor5	,955	83,876		
	amean	,997	52,090		
	perimeter	,092	44,356		
5	majoraxis	,037	226,906	,094	-
	factor5	,947	59,918		
	amean	,997	43,974		
	perimeter	,051	110,200		
	Eccentricity	,318	64,690		
6	majoraxis	,036	251,559	,088	-
	factor5	,932	68,685		
	amean	,940	21,319		
	perimeter	,048	134,058		
	Eccentricity	,308	79,078		
	Imean	,834	40,272		

En iyi yapay sinir ağı modeli determinasyon katsayısı ( $R^2$ ) ve ortalama karesel hata (MSE) değerlerine göre belirlenmiştir. Test amacıyla farklı örnekler sisteme giriş olarak verilmiş ve çıkış değerleri gözlemlenmiştir. Sonuç ile beklenen değerler karşılaştırılarak, sistemin çalışma performansı hatalara bakılarak hesaplanmıştır. Hataların ortalama kareler toplamı metoduyla bulunmuştur. Değerler için, eğitim işlemi süresince YSA (3:1:2) modeline ait iterasyonla MSE'deki azalma Şekil 5.1'de görülmektedir. Iterasyon sayısı 70'e ulaştığında ortalama karesel hata (MSE)  $5.66 \times 10^{-12}$  olarak bulunmuştur. MSE'nin sıfır olması ağın çıktısıyla istenen çıktı arasında fark olmadığı yani hatasız olduğunu ifade etmektedir. Bu modelin performansı Şekil 5.1'de gösterilmiştir. Modelin performansı tek gizli katmanda 0'a çok yakın sonuç verdiği için gizli katmanda ikinci tabaka denenmemiştir.



Şekil 5.1 Kırk tane için YSA'nın eğitim, durdurma ve test performansı.

Çalışma sonuçlarından deneysel değerler ile tahmin edilen değerler arasındaki korelasyon ilişkisinin kabul edilebilir düzeyde olduğu bulunmuştur. Şekil 4.6'daki veriler incelendiğinde oluşturulan YSA'nın iyi sonuçlar ortaya koyduğu regresyon değerinin 1'e ulaştığı ve test sonuçlarına göre ağın ürettiği çıktılar ile gerçek değerler arasında fark olmadığı görülmektedir (Şekil 5.2).



Şekil 5.2. Kırk taneler için YSA ve deneysel sonuçların karşılaştırılması.

## 5.2. Yabancı Otların Analizleri

Buğdayın kalitesinde yabancı ot miktarı oldukça önemli bir yer tutmaktadır. Yabancı ot oranı arttıkça kalite hızlı bir şekilde düşmektedir. Yabancı otların içinde, Cumhuriyet 75 buğday tohumlarında en çok rastlanan ve ayrımı zor olan yabancı hardal ve yabancı yulaf bu araştırmada ele alınmıştır.

### 5.2.1 Yabancı Hardal Analizleri


Yabancı hardal ve buğday ayrımında SPSS Diskriminant Analiz sonuçları Ek-3'de verilmiştir. Kombine edilmiş özelliklerin SPSS Diskriminant Analiz sonuçları ve hata payları Çizelge 5.2'de verilmiştir. Ek-3 incelendiğinde, yabancı hardal tanelerin ayrımında morfolojik özelliklerin arasında büyük eksen (major axis) ve renk özellikleri (colour features) arasında NTSC renk uzayında doygunluğun ortalaması (Qmean) diğer özelliklere göre daha etkili olduğu bulunmuştur.

Tek başına özellik olarak morfolojik özelliklerinden “büyük eksen” ve renk özelliklerinden de “Qmean”ın Wilk’s Lambda değerleri Ek-3’de görüldüğü gibi sırasıyla 0.019 ve 0.067 bulunmuştur. Çizelge 5.2’de görüldüğü gibi, büyük eksen kullanılmasıyla hata payı sıfır ve  $R^2$  değeri 1 olmuştur. Buğday ve yabancı hardal ayrımında sadece morfolojik özellikleri yeterince iyi sonuçlar verdiği için, renk özelliklerine gerek kalmamıştır. Bu nedenle, son analiz çizelgesinde yabancı hardal tanelerin özelliğinin belirlenmesinde sadece büyük eksen seçilmiştir (Çizelge 5.6). Bir özelliğin kullanımıyla yabancı hardal tanelerin sağlam buğdaydan kolaylıkla ayırt edilebildiğini gösteren grafik Ek-5’de verilmiştir.

**Çizelge 5.2** Yabani hardal ve buğday ayırımında diskriminant Analiz sonuçları.


combined features in the Analysis					
	Step	Tolerance	F to Remove	Wilks' Lambda	YSA hata oranı (%)
1	majoraxis	1,000	30542,863	0,019	0
2	majoraxis	1,000	2090,276	0,015	-
	Qmean	1,000	169,241		
3	majoraxis	,925	416,272	0,012	-
	Qmean	,995	151,680		
	elongation	,921	144,108		
4	majoraxis	,142	11,891	0,01	-
	Qmean	,958	71,536		
	elongation	,424	285,177		
	EquivDiameter	,147	114,432		
5	majoraxis	,053	241,583	0,007	-
	Qmean	,958	41,216		
	elongation	,050	618,451		
	EquivDiameter	,060	464,425		
	Eccentricity	,100	321,977		
6	majoraxis	,007	152,966	0,006	-
	Qmean	,931	53,650		
	elongation	,050	452,497		
	EquivDiameter	,002	106,285		
	Eccentricity	,090	388,484		
	minoraxis	,004	50,834		

Yabani hardalın buğdaydan ayrılması işleminde, eğitim işlemi süresince YSA (1:1:2) modeline ait iterasyonla MSE'deki azalma Şekil 5.3'de görülmektedir. MSE değerinin  $1.45 \times 10^{-7}$  çıkması YSA'nın deneysel olarak bulunan sonuçlara çok yakın tahminlerde bulunduğunu ispatlamaktadır. Kırık tanede olduğu gibi, modelin performansı tek gizli katmanda 0'a çok yakın sonuç verdiği için, gizli katmanda ikinci tabaka denenmemiştir.



Şekil 5.3 Yabancı hardal için YSA'nın eğitim, durdurma ve test performansı.

Şekil 5.4'deki veriler incelendiğinde oluşturulan YSA'nın iyi sonuçlar ortaya koyduğu görülmektedir. Test kümesi sonuçlarına göre ağın ürettiği çıktılar ile gerçek değerler arasında fark olmadığı görülmektedir.



Şekil 5.4 Yabancı hardal için YSA ve deneysel sonuçların karşılaştırılması.

### 5.2.2 Yabancı Yulaf Analizleri

Yabancı yulaf ve buğday ayırımında SPSS Diskriminant Analiz sonuçları Ek-3'te verilmiştir. Kombine edilmiş özelliklerin SPSS Diskriminant Analiz sonuçları ve hata payları Çizelge 5.3'de verilmiştir. Ek-3 incelendiğinde, yabancı yulaf ayırımında morfolojik özelliklerin arasında ikincil eksenin ana eksene oranı


(Elongation) ve renk özellikleri (colour features) arasında NTSC renk uzayının I değerlerinin ortalamasının (Imean) diğer özelliklere göre daha etkili olduğu bulunmuştur.

Tek başına özellik olarak morfolojik özelliklerinden “İkincil eksenin ana eksene oranı” ve renk özelliklerinden de “Imean”in Wilk’s Lambda değerleri Ek-3’de görüldüğü gibi sırasıyla 0.115 ve 0.245 bulunmuştur. Yabani yulaf tanelerin Şekilleri bazen buğday taneleriyle aynı olduğu için sadece morfolojik özellikleri yabani yulaf ayırımında yeterince iyi sonuçlar vermemiştir. Çizelge 5.3’de görüldüğü gibi, Elongation ve Imean kullanılmasıyla Wilk’s Lambda değeri 0.115’den 0.095’e ve hata payı da % 3’den % 1’e düşürülmüştür. Daha başarılı sonuç için bir ileri aşamada ise 3 özelliğin; Elongation, Imean ve Ivar kullanılması ile 3. Stepte hata payı sıfıra düşürülerek Wilk’s Lambda değeri 0.077 olmuştur. Bu nedenle, son analiz çizelgesinde yabani yulaf özelliğinin belirlenmesinde 3 özellik sırasıyla Elongation, Imean ve Ivar seçilmiştir (Çizelge 5.6). Bu 3 özelliğin kullanımıyla yabani yulaf tanelerin sağlam buğdaydan kolaylıkla ayırt edilebildiğini gösteren grafikler Ek-5’de verilmiştir.

**Çizelge 5.3** Yabani yulaf ve buğday ayırımında diskriminant Analiz sonuçları.

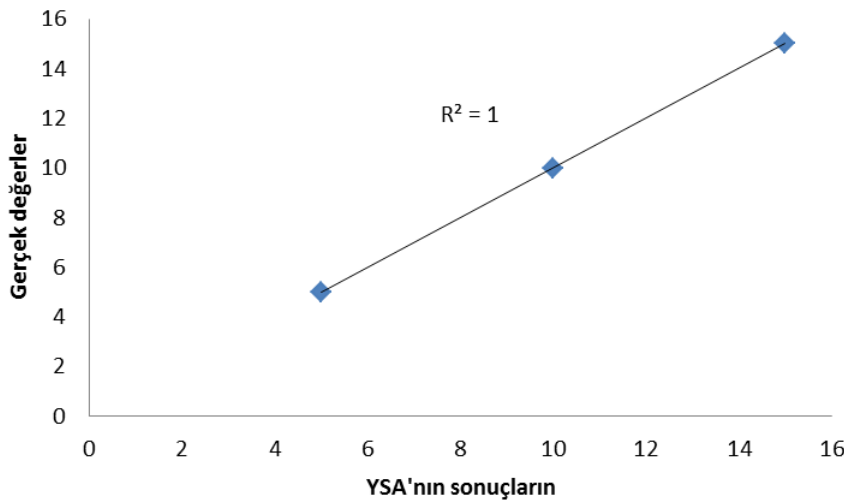
combined features in the Analysis					
Step		Tolerance	F to Remove	Wilks' Lambda	YSA hata oranı
1	elongation	1,000	4609,645	0,115	3
2	elongation	,978	948,786	,095	1
	Imean	,978	126,767		
3	elongation	,978	590,461	,077	0
	Imean	,559	282,843		
	Ivar	,566	135,460		
4	elongation	,966	332,895	,065	-
	Imean	,515	353,887		
	Ivar	,143	245,631		
	bBstd	,191	110,208		
5	elongation	,059	142,963	,059	-
	Imean	,509	355,216		
	Ivar	,141	260,267		
	bBstd	,189	114,544		
	Eccentricity	,058	63,024		
6	elongation	,010	231,225	,050	-
	Imean	,509	268,979		
	Ivar	,140	231,209		
	bBstd	,189	100,529		
	Eccentricity	,017	186,055		
	factor6	,088	111,952		

Yabani yulafın buğdaydan ayrılması işleminde, eğitim işlemi süresince YSA (3:1:2) modeline ait iterasyonla MSE'deki azalma Şekil 5.5'de görülmektedir. 32 iterasyona ulaşıldığında ortalama karesel hata  $1.99 \times 10^{-9}$  olarak bulunmuştur. Modelin performansı tek gizli katmanda 0'a çok yakın sonuç verdiği için gizli katmanda ikinci tabaka denenmemiştir.



Şekil 5.5 Yabani yulaf için YSA'nın eğitim, durdurma ve test performansı.

Şekil 5.6'deki veriler incelendiğinde oluşturulan YSA'nın iyi sonuçlar ortaya koyduğu görülmektedir. Test kümesi sonuçlarına göre ağın ürettiği çıktılar ile gerçek değerler arasında fark olmadığı görülmektedir.



Şekil 5.6 Yabani yulaf için YSA ve deneysel sonuçların karşılaştırılması.



### 5.3. Diğer Hububat Analizleri

#### 5.3.1. Mısır Analizleri


Mısır ve buğday ayırımında SPSS Diskriminant Analiz sonuçları Ek-4’de verilmiştir. Kombine edilmiş özelliklerin SPSS Diskriminant Analiz sonuçları ve hata payları Çizelge 5.4’de verilmiştir. Ek-4 incelendiğinde, mısır tanelerin ayırımında morfolojik özelliklerin arasında küçük eksen (minoraxis) ve renk özellikleri (colour features) arasından Lab renk uzayında a ortalaması (amean) diğer özelliklere göre daha etkili olduğu bulunmuştur.

Tek başına özellik olarak morfolojik özelliklerinden “küçük eksen” ve renk özelliklerinden de “amean”in Wilk’s Lambda değerleri Ek-4’de görüldüğü gibi sırasıyla 0.033 ve 0.072 bulunmuştur. Çizelge 5.4’de görüldüğü gibi, küçük eksen kullanılmasıyla hata payı sıfır ve  $R^2$  değeri 1 olmuştur. Kırık tanede olduğu gibi, buğday ve mısır ayırımında sadece morfolojik özellikleri yeterince iyi sonuçlar verdiği için renk özelliklerine gerek kalmamıştır. Bu nedenle, son analiz çizelgesinde mısır tanelerin özelliğinin belirlenmesinde sadece küçük eksen seçilmiştir (Çizelge 5.6). Bir özelliğin kullanımıyla mısır tanelerin sağlam buğdaydan kolaylıkla ayırt edilebildiğini gösteren grafiği Ek-5’de verilmiştir.

**Çizelge 5.4** Mısır ve buğday ayırımında diskriminant Analiz sonuçları


combined features in the Analysis					
Step		Tolerance	F to Remove	Wilks' Lambda	YSA hata oranı (%)
1	minoraxis	1,000	17493,438	0,033	0
2	minoraxis	,994	1396,482	,022	-
	amean	,994	320,588		
3	minoraxis	,989	860,441	,017	-
	amean	,850	463,410		
	Iskewness	,854	168,844		
4	minoraxis	,982	702,583	,014	-
	amean	,740	602,208		
	Iskewness	,593	300,913		
	Qmean	,684	112,592		
5	minoraxis	,977	648,105	,013	-
	amean	,578	715,188		
	Iskewness	,593	260,696		
	Qmean	,683	93,323		
	Gmedian	,722	60,041		
6	minoraxis	,661	626,544	,012	-
	amean	,563	748,388		
	Iskewness	,591	217,309		
	Qmean	,680	95,558		
	Gmedian	,717	63,660		
	Eccentricity	,655	38,902		

Mısırın buğdaydan ayrılması işleminde, eğitim işlemi süresince YSA (1:1:2) modeline ait iterasyonla MSE'deki azalma Şekil 5.7'de görülmektedir. 32 iterasyona ulaşıldığında MSE değerinin  $9.28 \times 10^{-8}$  çıkması YSA'nın deneysel olarak bulunan sonuçlara çok yakın tahminlerde bulunduğunu ispatlamaktadır.



Şekil 5.7 Mısır için YSA'nın eğitim, durdurma ve test Performansı

Şekil 5.8'deki veriler incelendiğinde oluşturulan YSA'nın iyi sonuçlar ortaya koyduğu görülmektedir. Test kümesi sonuçlarına göre ağın ürettiği çıktılar ile gerçek değerler arasında fark olmadığı görülmektedir.



Şekil 5.8 Mısır için YSA ve deneysel sonuçların karşılaştırılması

### 5.3.2 Arpa Analizleri

Morfolojik ve renk özellikleri buğday ve arpa için genellikle bir birine benzemektedir. Bu nedenle, buğday ile arpanın ayrımı çok zordur. Sonuçlar, sadece renk ve morfolojik özelliklerin arpanın buğdaydan ayrılması işleminde yeterli olmadığı görülmüştür. Ancak bu iki özelliklerin yanında doku özelliklerinin de göz önüne alınmasıyla kabul edilebilir sonuçlar elde edilmiştir. Bu nedenle, buğday ve arpa ayrımında morfolojik, renk ve doku özelliklerinin kombinesi dikkate alınmıştır.


Arpa ve buğday ayrımında SPSS Diskriminant Analiz sonuçları Ek-4'de verilmiştir. Kombine edilmiş özelliklerin SPSS Diskriminant Analiz sonuçları ve hata payları Çizelge 5.5'de verilmiştir. Ek-4 incelendiğinde, arpa tanelerin ayrımında morfolojik özelliklerden büyük eksen (major axis), renk özellikleri (colour features) arasında Lab renk uzayında b standart sapması (bstd), doku özelliklerinde ise gray level değerlerinde enerji değeri (GEnergy) diğer özelliklere göre daha etkili olduğu bulunmuştur.

Deney tasarımı, değişik koşullarda bağımsız değişkenlerin bağımlı değişkeni nasıl etkilediğini araştırmak için, arpa ve buğday ayrımında gerekli tasarımları hazırlayan ve çözümlenmelerini veren bir tekniktir. Test oranı 0.1, 0.15 ve 0.2, onaylama oranı (validation) 0.1, 0.15 ve 0.2, gizli katmanda nöron sayısı 1'den 20'ye kadar, gizli katman ise 1 ve 2 olarak seçilerek farklı Yapay Sinir Ağları kurulmuştur. Arpa ve buğday ayrımı için Yapay Sinir Ağları ile tahmin edilen değerler ve gerçek değerler arasındaki hata oranı Çizelge 5.5'de verilmiştir.

Çizelge 5.5'de görüldüğü gibi, büyük eksen ve amean kullanılmasıyla Wilk's Lambda değeri 0.522'den 0.358'e ve hata payı da %8'den %6'ye düşürülmüştür. Daha başarılı sonuç için ileri aşamalarda 14 özelliği kullanılması ile 14. adımda hata payı % 0.2 düşürülerek Wilk's Lambda değeri 0.14'e ulaşılmıştır. Bu değerden sonrası sete eklenecek parametre sayısı hata oranını değiştirmemektedir. Verilerin daha kolay şekilde anlamlandırılması parametre sayısı ile ilgili olduğu için en az hata oranının olduğu 14 nolu deney gurubu ele alınmıştır. Step 14 Yapay Sinir Ağında, 0.2 test oranı, 0.1 onaylama oranı, 1 gizli

katman ve bu gizli katmanda 10 nöron sayısı buğday ayrımı için iyi sonuçlar vermiştir. Bu nedenle, son analiz çizelgesinde arpa özelliğinin belirlenmesinde 14 özellik seçilmiştir (Çizelge 5.6). Bu 14 özelliğın kullanımıyla arpa tanelerin sağlam buğdaydan kolaylıkla ayırt edilebildiğini gösteren grafikler Ek-5’de verilmiştir.


Arpanın buğdaydan ayrılması işleminde, eğitim işlemi süresince YSA (14:10:2) modeline ait iterasyonla MSE’deki azalma Şekil 5.9’de görülmektedir. Ortalama karesel hatası ise 31 iterasyona ulaşıldığında 0.012 olarak bulunmuştur.



Şekil 5.9 Arpa için YSA'nın eğitim, durdurma ve test performansı



Çalışma sonuçlarından deneysel değerler ile tahmin edilen değerler arasındaki korelasyon ilişkisinin diğer özellikler dikkate alındığında (sıfır hatada bulunmuştur) kabul edilebilir düzeyde olduğu bulunmuştur. Şekil 5.10'deki veriler incelendiğinde oluşturulan YSA'nın iyi sonuçlar ortaya koyduğu görülmektedir. Test kümesi sonuçlarına göre ağın ürettiği çıktılar ile gerçek değerler arasında fark çok az olduğu görülmektedir.



Şekil 5.10 Arpa için YSA ve deneysel sonuçların karşılaştırılması

#### 5.4 Son Analizler

Sonuçlarda görüldüğü gibi, sadece renk ve morfolojik özelliklerinin kullanılarak buğday'ın kırık tane, yabancı otlardan (yabani hardal, yabani yulaf) ve diğer hububatlardan (mısır ve arpa) ayırt edilmesinin başarılı olmadığı bulunmuştur. Ancak bu iki özellik grubuna bir doku özelliği katıldığında kabul edilebilir sonuçlara ulaşılmıştır. Nitekim Çizelge 5.6. incelendiğinde, buğdayın diğer 5 türden başarılı bir şekilde ayırt edilebilmesi için toplam 18 özelliğin seçilmesi gerekliliği ortaya çıkmaktadır.

**Çizelge 5.6** Son analizde seçilmiş özellikler

	yabani hardal	mısır	kırık	yabani yulaf	arpa	Karışık
buğday	Majoraxis	minoraxis	majoraxis	Elongation	majoraxis	majoraxis
			Factor5	Imean	Amean	Amean
			amean	Istd	Qstd	Qstd
					avar	avar
					Istd	Istd
					perimeter	perimeter
					Factor4	Factor4
					Ykurtosis	Ykurtosis
					Bmean	Bmean
					Lkurtosis	Lkurtosis
					Ikurtosis	Ikurtosis
					Qmean	Qmean
					Bvar	Bvar
					GEntropy	GEntropy
						Factor5
						elongation
						Imean
						Minoraxis

Deney tasarımı Çizelge 5.7.'de verilmiştir. Deney tasarımı için test oranı 0.1, 0.15 ve 0.2, onaylama (validasyon) oranı 0.1, 0.15 ve 0.2, gizli katmanda nöron sayısı 1'den 150'ye kadar, gizli katman ise 1 ve 2 olarak ele alınmış ve kurulan 80 adet YSA yapısı seçilmiştir. Eğitimde ileri beslemeli prensip tercih edilmiştir. Ağın eğitimi esnasında, ağırlıklar eğitim seti üzerinden belirlenmekte, belirlenen bu ağırlıklar aynı anda durdurma seti üzerine aktarılmaktadır. Bu çalışma esnasında durdurma setinin MSE değerinin artış gösterdiği noktada ağ eğitimi kesilmektedir. Böylece ağda aşırı öğrenme riski ortadan kaldırılmış olmaktadır. Ağın eğitiminin durduğu andaki ağırlıklar, o ağ için en iyi ve son ağırlık olarak kaydedilmektedir. Veri setlerinde çıktı katmanı sabit tutulmuştur. Ağın performansını ölçmek amacıyla gizli katman tek veya çift seçilmiş, bu katmanlardaki düğüm sayıları da değiştirilmiştir (Çizelge 5.7).

Çizelge 5.7 Kurulan bazı ağların topolojisi

Ağ NO	Ağ yapısı			
	Gizli katman	Test oranı	onaylama oranı	Gizli katmanda nöron sayısı
1	1	10	20	1
2	1	10	20	2
3	1	10	20	3
4	1	10	20	4
5	1	10	20	5
6	1	10	20	6
7	1	10	20	7
8	1	10	20	8
9	1	10	20	9
10	1	10	20	10
11	1	10	20	15
12	1	10	20	20
13	1	10	20	30
14	1	10	20	50
15	1	10	20	100
16	1	10	20	150
17	1	15	15	1
18	1	15	15	2
19	1	15	15	3
20	1	15	15	4
21	1	15	15	5
22	1	15	15	6
23	1	15	15	7
24	1	15	15	8
25	1	15	15	9
26	1	15	15	10
27	1	15	15	15
28	1	15	15	20
29	1	15	15	30
30	1	15	15	50
31	1	15	15	100
32	1	15	15	150
33	1	20	20	1
34	1	20	20	2
35	1	20	20	3
36	1	20	20	4
37	1	20	20	5
38	1	20	20	6
39	1	20	20	7
40	1	20	20	8

Ağ NO	Ağ yapısı				
	Gizli katman	Test oranı	onaylama oranı	Gizli katmanda nöron sayısı	
41	1	20	20	9	
42	1	20	20	10	
43	1	20	20	15	
44	1	20	20	20	
45	1	20	20	30	
46	1	20	20	50	
47	1	20	20	100	
48	1	20	20	150	
49	2	20	20	1	1
50	2	20	20	2	2
51	2	20	20	3	3
52	2	20	20	4	4
53	2	20	20	5	5
54	2	20	20	6	6
55	2	20	20	7	7
56	2	20	20	8	8
57	2	20	20	9	9
58	2	20	20	10	10
59	2	20	20	20	20
60	2	20	20	30	30
61	2	20	20	50	50
62	2	20	20	100	100
63	2	20	20	150	150
64	2	20	20	7	4
65	2	20	20	8	6
66	2	20	20	8	7
67	2	20	20	9	7
68	2	20	20	9	8
69	2	20	20	10	9
70	2	20	20	20	10
71	2	20	20	30	10
72	2	20	20	30	20
73	2	20	20	50	10
74	2	20	20	50	20
75	2	20	20	50	30
76	2	20	20	50	40
77	2	20	20	100	10
78	2	20	20	100	30
79	2	20	20	100	40
80	2	20	20	100	50

Gerçek değer ile ağ üzerinden tahmin edilen değer arasındaki hata oranı, en iyi ağlar için Çizelge 5.8 de, seçilmiş bazı gerçek değer-tahmin değer verileri ise Çizelge 5.9 'da verilmiştir.



Çizelge 5.8 incelendiğinde en iyi performansı 78 no'lu ağ vermiştir. Ancak sonuçların tümü incelendiğinde, ağların performansları arasında büyük farklar olmadığı görülebilmektedir. Tek gizli katmanlı ve iki gizli katmanlı ağ yapıları arasında da büyük farklar tespit edilememiştir.

**Çizelge 5.8** Sinir ağları tahmin değerlerinin hata oranları

Ağ No	9 Tekerrürde Ağların Tahmin Ettiği Değerlerin Hata Oranları						
	Buğday	Arpa	Hardal	Kırık	Mısır	Yulaf	Toplam
1	8,22	2,00	2,00	2,00	0,22	2,00	16,44
2	90,00	57,44	9,67	18,89	6,00	2,00	184,00
3	19,33	16,44	0,56	0,11	1,11	3,56	41,11
4	4,22	4,33	0,11	0,00	0,11	0,00	8,78
5	4,89	4,11	0,00	0,11	0,00	0,67	9,78
6	7,11	5,22	0,00	0,56	0,44	1,78	15,11
7	6,56	6,56	0,00	0,00	0,00	0,00	13,11
8	4,67	4,33	0,00	0,00	0,00	0,33	9,33
9	6,44	5,56	0,00	0,00	0,00	0,89	12,89
10	5,33	4,44	0,00	5,00	0,00	3,00	17,78
11	5,44	5,33	0,00	0,11	0,00	0,00	10,89
12	7,33	7,22	0,00	0,00	0,00	0,11	14,67
13	4,33	4,22	0,00	0,00	0,00	0,11	8,67
14	3,89	3,44	0,00	0,00	0,00	0,44	7,78
15	3,56	2,89	0,00	3,00	0,00	3,00	12,44
16	4,33	3,78	0,00	0,00	0,00	0,56	8,67
17	90,00	2,00	29,78	55,11	2,00	2,00	180,89
18	90,00	2,00	64,67	1,89	0,00	25,44	184,00
19	23,56	21,78	0,00	0,22	0,67	0,89	47,11
20	4,44	3,78	0,00	0,44	0,00	0,00	8,67
21	5,22	4,44	0,00	0,00	0,00	0,78	10,44
22	4,89	4,67	0,00	0,00	0,00	0,22	9,78
23	4,56	4,78	0,00	0,00	0,00	0,22	9,56
24	6,89	7,00	0,00	0,44	0,56	0,00	14,89
25	5,56	5,44	0,00	0,22	0,00	0,33	11,56
26	5,00	5,00	0,00	0,00	0,00	0,00	10,00
27	4,67	4,78	0,00	0,22	0,00	0,11	9,78
28	3,78	3,56	0,00	0,00	0,00	0,22	7,56
29	4,11	3,56	0,00	0,00	0,00	0,56	8,22
30	4,22	4,11	0,00	0,00	0,00	0,11	8,44
31	3,67	3,89	0,00	0,00	0,22	0,00	7,78
32	4,67	4,78	0,00	0,22	0,00	0,11	9,78
33	90,00	2,00	96,00	2,00	0,00	2,00	192,00
34	21,56	10,22	7,11	0,11	3,67	0,44	43,11
35	6,00	4,00	0,22	3,00	2,00	0,78	16,00
36	4,89	4,44	0,00	0,11	0,11	0,44	10,00
37	5,44	4,33	0,11	0,33	0,11	0,78	11,11
38	5,22	4,33	0,00	0,56	0,11	0,44	10,67
39	7,67	7,00	0,00	0,22	0,00	0,89	15,78
40	6,33	5,44	0,00	0,11	0,00	0,78	12,67

**Çizelge 5.8** Sınır ağları tahmin değerlerinin hata oranları (Devam)

Ağ No	9 Tekerrürde Ağların Tahmin Ettiği Değerlerin Hata Oranları						
	Buğday	Arpa	Hardal	Kırık	Mısır	Yulaf	Toplam
41	4,11	4,00	0,00	0,00	0,00	0,11	8,22
42	4,22	4,00	0,00	0,44	0,56	0,33	9,56
43	5,00	4,89	0,00	0,00	0,00	0,11	10,00
44	6,33	5,78	0,00	0,00	0,00	0,56	12,67
45	4,56	4,33	0,00	0,11	0,00	0,11	9,11
46	4,11	4,22	0,00	0,11	0,00	0,00	8,44
47	5,56	5,67	0,00	0,22	0,00	0,11	11,56
48	5,00	4,89	0,00	0,00	0,00	0,11	10,00
49	90,33	2,00	40,33	2,00	56,00	2,00	192,67
50	4,78	5,44	2,00	2,00	2,00	3,78	20,00
51	19,33	14,78	4,44	0,00	0,00	0,11	38,67
52	10,67	8,89	0,11	1,56	0,44	0,56	22,22
53	5,44	6,00	0,00	0,00	1,33	0,78	13,56
54	5,44	6,56	0,00	0,00	0,22	0,89	13,11
55	6,67	6,56	0,00	0,00	0,00	0,11	13,33
56	4,44	4,33	0,00	0,00	0,00	0,11	8,89
57	5,89	6,00	0,00	0,89	1,00	0,00	13,78
58	89,67	50,89	12,44	3,11	19,44	3,78	179,33
59	4,78	4,67	0,00	0,00	0,00	0,11	9,56
60	4,67	4,78	0,00	0,11	0,00	0,00	9,56
61	4,56	5,67	0,00	0,89	2,00	0,00	13,11
62	5,33	5,56	0,00	0,22	0,00	0,00	11,11
63	4,22	4,11	0,00	0,00	0,00	0,11	8,44
64	4,22	4,00	0,00	0,00	0,11	0,11	8,44
65	7,33	7,11	0,00	0,11	0,22	0,33	15,11
66	4,11	4,11	0,00	0,00	0,00	0,00	8,22
67	5,33	5,33	0,00	0,00	0,00	0,00	10,67
68	4,56	4,56	0,00	0,00	0,00	0,00	9,11
69	4,22	4,33	0,00	0,11	0,00	0,00	8,67
70	7,44	7,44	0,00	0,00	0,00	0,00	14,89
71	6,11	6,22	0,00	0,11	0,00	0,00	12,44
72	4,33	4,22	0,00	0,00	0,00	0,11	8,67
73	4,67	4,44	0,00	0,00	0,00	0,22	9,33
74	4,44	4,44	0,00	0,00	0,00	0,00	8,89
75	4,67	4,78	0,00	0,11	0,00	0,00	9,56
76	4,00	4,00	0,00	0,00	0,00	0,00	8,00
77	4,33	3,89	0,00	0,00	0,00	0,44	8,67
78	3,11	3,22	0,00	0,11	0,00	0,00	6,44
79	3,56	3,56	0,00	0,00	0,00	0,00	7,11
80	4,78	4,78	0,00	0,00	0,00	0,00	9,56


Çizelge 5.9 Bazı seçilmiş deney noktaları için gerçek-tahmin değer performansı

Ağ No	Gerçek değerler						3 Tekerrürde Ağın Tahmin Ettiği Değerlerin Ortalaması					
	buğday	arpa	mısır	hardal	kırık	yulaf	Buğday	Arpa	Hardal	Kırık	Mısır	Yulaf
1	85	3	3	3	3	3	97,0	0,0	0,0	0,0	3,0	0,0
2	85	3	3	3	3	3	0,0	54,3	15,3	21,0	9,3	0,0
3	85	3	3	3	3	3	70,3	16,3	4,0	2,7	0,7	6,0
4	85	3	3	3	3	3	81,7	6,3	3,0	3,0	3,0	3,0
5	85	3	3	3	3	3	81,3	6,0	3,0	3,3	3,0	3,3
6	85	3	3	3	3	3	79,0	7,7	3,0	4,0	2,0	4,3
7	85	3	3	3	3	3	78,7	9,0	3,0	3,0	3,0	3,3
8	85	3	3	3	3	3	81,0	6,7	3,0	3,0	3,0	3,3
9	85	3	3	3	3	3	79,7	7,7	3,0	3,0	3,0	3,7
10	85	3	3	3	3	3	79,7	6,7	3,0	4,0	3,0	3,7
11	85	3	3	3	3	3	80,3	7,3	3,0	3,3	3,0	3,0
12	85	3	3	3	3	3	78,7	9,3	3,0	3,0	3,0	3,0
13	85	3	3	3	3	3	80,3	7,7	3,0	3,0	3,0	3,0
14	85	3	3	3	3	3	81,7	6,0	3,0	3,0	3,0	3,3
15	85	3	3	3	3	3	81,0	6,0	3,0	3,7	3,0	3,3
16	85	3	3	3	3	3	81,0	6,7	3,0	3,0	3,0	3,3
17	85	3	3	3	3	3	0,0	0,0	39,0	61,0	0,0	0,0
18	85	3	3	3	3	3	0,0	0,0	64,0	5,0	3,0	28,0
19	85	3	3	3	3	3	64,7	22,0	3,0	3,0	3,3	4,0
20	85	3	3	3	3	3	81,3	6,3	3,0	3,3	3,0	3,0
21	85	3	3	3	3	3	80,0	7,3	3,0	3,0	3,0	3,7
22	85	3	3	3	3	3	81,0	6,7	3,0	3,0	3,0	3,3
23	85	3	3	3	3	3	81,3	6,7	3,0	3,0	3,0	3,0
24	85	3	3	3	3	3	78,7	10,0	3,0	3,3	2,0	3,0
25	85	3	3	3	3	3	79,0	8,7	3,0	3,0	3,0	3,3
26	85	3	3	3	3	3	80,0	8,0	3,0	3,0	3,0	3,0
27	85	3	3	3	3	3	81,3	6,7	3,0	3,0	3,0	3,0
28	85	3	3	3	3	3	80,7	7,0	3,0	3,0	3,0	3,3
29	85	3	3	3	3	3	81,0	6,3	3,0	3,0	3,0	3,7
30	85	3	3	3	3	3	81,7	6,0	3,0	3,0	3,0	3,3
31	85	3	3	3	3	3	80,7	8,0	3,0	3,0	2,3	3,0
32	85	3	3	3	3	3	81,3	6,7	3,0	3,0	3,0	3,0
33	85	3	3	3	3	3	0,0	0,0	97,0	0,0	3,0	0,0
34	85	3	3	3	3	3	66,0	12,3	9,0	3,3	5,7	3,7
35	85	3	3	3	3	3	79,7	6,3	3,3	6,7	0,0	4,0
36	85	3	3	3	3	3	81,0	6,7	3,0	3,3	2,7	3,3
37	85	3	3	3	3	3	80,0	6,3	3,0	4,0	3,0	3,7
38	85	3	3	3	3	3	79,7	7,0	3,0	4,3	2,7	3,3
39	85	3	3	3	3	3	78,0	9,3	3,0	3,0	3,0	3,7
40	85	3	3	3	3	3	79,3	8,0	3,0	3,0	3,0	3,7

Çizelge 5.9 Bazı seçilmiş deney noktaları için gerçek-tahmin değer performansı (Devam)

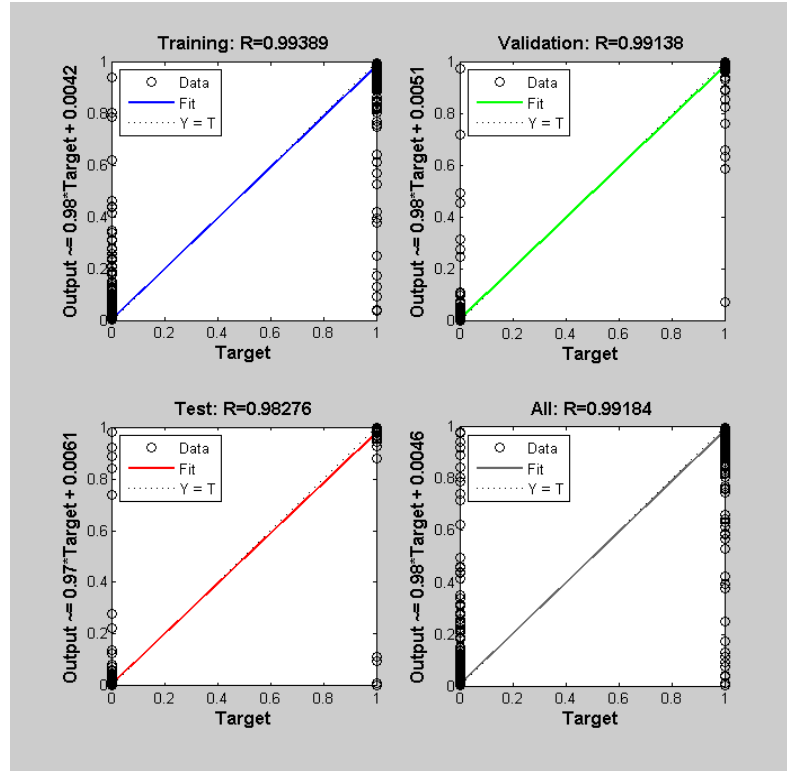
Ağ No	Gerçek değerler						3 Tekerrürde Ağın Tahmin Ettiği Değerlerin Ortalaması					
	buğday	arpa	mısır	hardal	kırık	yulaf	Buğday	Arpa	Hardal	Kırık	Mısır	Yulaf
41	85	3	3	3	3	3	81,0	7,0	3,0	3,0	3,0	3,0
42	85	3	3	3	3	3	81,3	6,7	3,0	3,7	2,0	3,3
43	85	3	3	3	3	3	79,3	8,3	3,0	3,0	3,0	3,3
44	85	3	3	3	3	3	79,3	8,0	3,0	3,0	3,0	3,7
45	85	3	3	3	3	3	80,7	7,0	3,0	3,0	3,0	3,3
46	85	3	3	3	3	3	81,0	7,0	3,0	3,0	3,0	3,0
47	85	3	3	3	3	3	80,0	7,7	3,0	3,0	3,0	3,3
48	85	3	3	3	3	3	79,3	8,3	3,0	3,0	3,0	3,3
49	85	3	3	3	3	3	0,0	0,0	43,0	0,0	57,0	0,0
50	85	3	3	3	3	3	80,7	10,7	0,0	0,0	0,0	8,7
51	85	3	3	3	3	3	69,0	15,3	6,3	3,0	3,0	3,3
52	85	3	3	3	3	3	75,7	10,0	3,3	4,7	2,3	4,0
53	85	3	3	3	3	3	80,7	8,3	3,0	3,0	1,3	3,7
54	85	3	3	3	3	3	80,0	9,7	3,0	3,0	2,3	2,0
55	85	3	3	3	3	3	79,0	9,0	3,0	3,0	3,0	3,0
56	85	3	3	3	3	3	81,3	6,7	3,0	3,0	3,0	3,0
57	85	3	3	3	3	3	80,0	8,0	3,0	5,0	1,0	3,0
58	85	3	3	3	3	3	0,0	48,7	15,3	6,0	22,3	7,7
59	85	3	3	3	3	3	81,0	7,0	3,0	3,0	3,0	3,0
60	85	3	3	3	3	3	80,7	7,3	3,0	3,0	3,0	3,0
61	85	3	3	3	3	3	80,7	9,3	3,0	4,0	0,0	3,0
62	85	3	3	3	3	3	79,3	8,7	3,0	3,0	3,0	3,0
63	85	3	3	3	3	3	80,3	7,3	3,0	3,0	3,0	3,3
64	85	3	3	3	3	3	80,7	6,7	3,0	3,0	3,3	3,3
65	85	3	3	3	3	3	78,7	9,3	3,0	3,3	2,3	3,3
66	85	3	3	3	3	3	81,3	6,7	3,0	3,0	3,0	3,0
67	85	3	3	3	3	3	80,7	7,3	3,0	3,0	3,0	3,0
68	85	3	3	3	3	3	80,3	7,7	3,0	3,0	3,0	3,0
69	85	3	3	3	3	3	81,0	7,0	3,0	3,0	3,0	3,0
70	85	3	3	3	3	3	77,0	11,0	3,0	3,0	3,0	3,0
71	85	3	3	3	3	3	79,3	8,7	3,0	3,0	3,0	3,0
72	85	3	3	3	3	3	81,0	6,7	3,0	3,0	3,0	3,3
73	85	3	3	3	3	3	80,7	7,3	3,0	3,0	3,0	3,0
74	85	3	3	3	3	3	82,0	6,0	3,0	3,0	3,0	3,0
75	85	3	3	3	3	3	79,3	8,7	3,0	3,0	3,0	3,0
76	85	3	3	3	3	3	82,0	6,0	3,0	3,0	3,0	3,0
77	85	3	3	3	3	3	80,0	7,3	3,0	3,0	3,0	3,7
78	85	3	3	3	3	3	82,0	6,0	3,0	3,0	3,0	3,0
79	85	3	3	3	3	3	81,7	6,3	3,0	3,0	3,0	3,0
80	85	3	3	3	3	3	80,3	7,7	3,0	3,0	3,0	3,0

Buğday'ın diğer tanelerden ayrımı için en iyi yapının, 0.2 test oranlı, 0.2 onaylama oranı, çift katmanlı,; birinci katmanda 100 ve ikinci katmanda 30 düğümlü ağ yapısı olduğu belirlenmiştir (Şekil 5.11).




Şekil 5.11 Son analiz YSA'nın yapısı

Gizli katmandaki düğüm sayısı arttıkça, ağın diğer parametrelerine de bağlı da olarak az miktarda iyileşme görülmüştür. 78 no'lu ağın korelasyon değeri(R), eğitim için 0.993, onaylama için 0.991, test için 0.982 ve genel korelasyon ise 0.992 olarak hesaplanmıştır (Şekil 5.12). MSE değeri ise 54 devirde, eğitim için 0.0016, test için 0.0038 ve onaylama için 0.0023 bölünmüştür (Şekil 5.13).




Şekil 5.12 Son analiz YSA'nın eğitim, durdurma ve test korelasyon değerleri



Şekil 5.13 Son analiz YSA'nın eğitim, durdurma ve test performansı

Şekil 5.14 incelendiğinde, ortalama sapmaların oldukça düşük, dağılımının daha çok insan gözünün fark edemediği toleranslar içinde olduğu söylenebilir. Sapmalar daha çok 0-0.1 aralığında gözlenmiştir. Bazı noktalar dışında çıktılarda 1 değerinin üzerinde bir sapma olmamıştır.



Şekil 5.14 Son analiz YSA'nın gerçek değer ile tahmin edilen değerler arasındaki ortalama sapma

Elde edilen ortalama hata oranı buğday için 3.11, arpa için 3.22, kırık taneler için 0.11 ve diğer taneler için (mısır, yabancı yulaf ve yabancı hardal) sıfır hata değeri bulunmuştur.

## 6. SONUÇ VE ÖNERİLER

Araştırma sonuçlarına göre buğdayın kırık tane, yabancı otlardan (yabani hardal, yabani yulaf) ve diğer hububatlardan (mısır ve arpa) ayırt edilmesinde hata oranı buğday için 3.11, arpa için 3.22, kırık taneler için 0.11 ve diğer taneler için (mısır, yulaf ve yabani hardal) sıfır hata değeri bulunması oldukça iyi bir veri olarak görülmektedir.

Ancak araştırmada Cumhuriyet 75 buğdayının arpa'ya çok yakın bir morfolojik yapı göstermesi nedeniyle hata payı sadece arpa tohumlarının buğdaydan ayırt edilmesinde yaşanmıştır. Kırık tanelerin belirlenmesinde hata oranı 0.11 ile sıfıra yaklaşırken mısır, yabani yulaf ve yabani hardalın ayırt edilmesinde sıfır hata ile % 100 başarı elde edilmiştir. Her ne kadar başarı oranı tatmin edici olsa bile yazar, buğdayın arpadan ayırt edilmesinde daha etkili ek morfolojik özelliklerin kullanılmasıyla hatanın minimum düzeye indirilebileceğini düşünmektedir.

Bu araştırmada Cr kanalının diğer kanallara göre kullanılması başarıyı oldukça arttırdığı görülmüştür. Özellik sayısının arttırılması sinir ağlarında başarıyı ve sonuç elde etme süresini olumsuz etkilediğinden, araştırmada başarı oranını arttırmak ve süreyi kısaltmak amacıyla SPSS de diskriminant analizi yapılmıştır. Sonuçlarda görüldüğü gibi sadece morfolojik özelliklerin kullanılmasıyla başarı oranı % 80 olurken renk ve doku özelliklerinin de eklenmesi ile başarı oranı bu araştırmada % 97'e çıkarılmıştır.

Aydınlatmanın segmentasyonda oldukça önemli olduğu ortaya çıkmıştır. Araştırmada kullanıldığı gibi aydınlatmada dairesel florasan lambanın kullanılmasının tohum kalitesinin belirlenmesinde başarıyı arttıracığı unutulmamalıdır. Sadece buğday değil aynı zamanda diğer hububatlarda da kalite belirlenmesinde veya ürün temizleme makinalarında görüntü algılama başarıyla kullanılabilir.





**KAYNAKLAR DİZİNİ**

- Ayata, M., Yalçın, M. ve Kirişçi, V.**, 1997, Toprak-alet ilişkilerinin görüntü işleme sistemi ile incelenmesi. Tarımsal Mekanizasyon 17. Ulusal Kongresi Bildiri Kitabı, Tokat s. 267-274.
- Bacci, L., Colucci, R. and Novaro, P.**, 2002, Durum wheat quality evaluation software. Proceedings of the World Congress of Computers in Agriculture and Natural Resources, pp. 49-55, Brazil.
- Bebis, G., Egbert, D. and Shah, M.**, 2003, Review of Computer Vision Education. IEEE Transactions on Education, 46, February.
- Chelappa, R. and Sawchuk, A.**, 1985, Digital image processing and analysis, Volume 2, Digital Image Analysis, IEEE Computer Society Press.
- Cichocki, A.**, 1993, and Unbehaven R., Neural Networks for Optimization and signal Processing, John Wiley and Sons, Gb. Stuttgart, pp.39-40.
- Dalen, G.V.**, 2004, Determination of the size distribution and percentage of broken kernels of rice using flatbed scanning and image analysis. Food research International, 37 (2004), 51-58.
- Draganova T., Daskalov P. and Tsonev R.**, 2003, Model of Software System for automatic corn kernels Fusarium (spp.) disease diagnostics. Latest Trends On Computers, 54(3): 19-28.
- Erhardt A.**, 2000, Theory and Applications of Digital Image Processing, University of Applied Sciences, 54s.
- Elçi, Ş., Kolsarıcı, Ö. ve Geçit, H.H.**, 1994, Tarla bitkileri (2. Baskı). Ankara Üniversitesi Ziraat Fakültesi, Yayın No: 1385, Ders Kitabı: 399, 239 s. Ankara.
- El-Faki M.S., Zhang N. and Peterson D.E.**, 2001, Weed detection using color machine vision. American Society of Agricultural Engineers, 43(6): 1969-1978.

**KAYNAKLAR DİZİNİ (Devam)**

**Food and Agriculture Organization (FAO)**, 2011, Wheat production.

<http://www.fao.org>

**Göknur-Dursun, İ.**, 2001. Bazı taneli ürünlerin izdüşüm alanlarının görüntü işlemeyle belirlenmesi. Tarım Bilimleri Dergisi, 7(3): 102-107

**Gonzales, R.C. and Woods, R.E.**, 2008, *Digital Image Processing*, Pearson Prentice Hall, U.S.A., ISBN: 0-13-168728-8.

**Haralick, R.M., Shanmugan, K. and Dinstein, I.**, 1973, Textural Features for Image Classification., IEEE Transactions on Systems, Man and Cybernetics vol.3.

**Haralick, R.M.**, 1979, Statistical and Structural Approaches to Texture., Proceedings of IEEE, vol.67.

**Kün, E.**, 1983, Serin İklim Tahılları. Ankara Üniversitesi Ziraat Fakültesi, Yayın No: 875, Ders Kitabı: 240, 130 s., Ankara.

**Leemans, V., Magein, H. and Destain, M. F.**, 1999, “Defect Segmentation On ‘Jonagold’ Apples Using Colour Vision and A Bayesian Classification Method”, Computers and Electronics in Agriculture, 23: 43–53.

**Luo, X., Jayas, D. S. and Symons, S. J.**, 1999, “Comparison Of Statistical and Neural Network Methods For Classifying Cereal Grains Using Machine Vision”, Transactions of the ASAE, 42: 413–419.

**Miller, W. M.**, 1992, “Classification Analyses of Florida Grapefruit Based On Shape Parameters”, In Food Processing Automation II—Proceeding of the FPAC Conference, St. Joseph, Michigan, ASAE: 339–347.

**Neuman M.R., Sapirstein H.D., Shwedyk E. and Bushuk W.**, 2009, Wheat grain colour analysis by digital image processing II.wheat class discrimination. Journal of Cereal Science, 10(3): 183-188.

**KAYNAKLAR DİZİNİ (Devam)**

- Niblack, W.**, 1986, An introduction to image processing. Prentice-Hall International.
- Orta Doğu Teknik Üniversitesi**, 1999, Görüntü İşleme. <http://www.bilten.metu.edu.tr/Image Processing>.
- Otsu, N.**, 1979, A Threshold Selection Method from Gray-Level Histogram, IEEE Trans. On Systems, Man, and Cybernetics SMC-9, pp. 62--66, Jan, 1979.
- Paliwal J., Visen N.S., Jayas D.S. and White N.D.G.**, 2003, Cereal grain and dockage identification using machine vision. Biosystems Engineering, 85(1): 51-57.
- Philipp I. and Rath T.**, 2002, Improving plant discrimination in image processing by use of different colour space transformations. Computers and Electronics in Agriculture, 35: 1-15.
- Paliwal, J., Visen, N. S. and Jayas, D. S.**, 2001, "Evaluation of Neural Network Architectures For Cereal Grain Classification Using Morphological Features", Journal of Agricultural Engineering Research, 79: 361–370.
- Raudys S., Baykan Ö.K., Babalık A., Denisov V. and Bielskis A.**, 2007, "Classifiers Fusion in Recognition of Wheat Varieties", Multiple Classifier Systems, 62–71.
- Symons, S.J. and Fulcher, R.G.**, 1988 a. Determination of wheat kernel morphological variation by digital image analysis, I Variation in eastern Canadian milling quality wheats. J. Cereal Sci. 8, 211–218.
- Shahin, M.A., ve Symons, S.J.**, 2005, Seed sizing from images of non-singulated grain samples. Canadian Biosystems Engineering/Le Génie des Biosystèmes au Canada, 47, 3.49-3.55.
- Sağiroğlu Ş., Beşdok E. ve Erler M.**, 2003, "Mühendislikte Yapay Zeka Uygulamaları-1: Yapay Sinir Ağları", Ufuk Yayınevi, Kayseri.

**KAYNAKLAR DİZİNİ (Devam)**

- Türk Standartları Enstitüsü (TSE)**, 1978, Türk buğday standartları. Türk Standartları Enstitüsü Yayınları, Ankara.
- Ünsalan, C.**, 1998, Pattern Recognition Methods for Texture Analysis Case Study: Steel Surface Classification., MSc Thesis, Bogazici Univ., Inst. For Graduate Studies in Pure and Applied Sciences, Istanbul, Türk
- Young, I.T., Gerbrands, J.J. and Van vliet L.J.**, 1998, *Fundamentals of Image Processing*, Delft University of Technology, Netherlands, ISBN 90-75691-01-7.
- Yılmaz, İ.**, 2002, Renk Sistemleri, Renk Uzayları Ve Dönüşümler. Selçuk Üniversitesi Jeodezi ve Fotogrametri Mühendisliği Öğretiminde 30. Yıl Sempozyumu, Konya.
- Zayas, I.Y., Martin, C.R., Steele, J.L. and Katsevich, A.**, 1996, Wheat classification using image analysis and crush force parameters. Transaction of the ASAE, 39 (6), 2199-2204.

**ÖZGEÇMİŞ**

1982 Zanjan doğumlu olan Abbas MASOUMI; 2001 yılında İran Ardabil Üniversitesi Ziraat Fakültesi'nde üniversite öğrenimine başladı. Lisans öğrenimi sonunda, 2011 yılında Ege Üniversitesi Fen Bilimleri Enstitüsü Tarım Makinaları Anabilim Dalı'nda yüksek lisans çalışmasına başladı.

## **EKLER**

EK 1 Segmentasyon sonuçları

EK 2 Spss diskriminant analiz sonuçları (kırık dane)


EK 3 Spss diskriminant analiz sonuçları (yabancı madde)

EK 4 Spss diskriminant analiz sonuçları (diğer hububat)

EK 5 Tohumların özellik değerlerinin gösterimi



EK-1 segmentasyon sonuçları (kırmızı kanalda)





EK-1 segmentasyon sonuçları (Yeşil Kanalda)

64




29



24



67




21



14



97



69



41



EK-1 segmentasyon sonuçları (Mavi Kanalda)

53



47



0



67




24




0




84




74



0



EK-1 segmentasyon sonuçları (Cr Kanalda)



## EK-2 Diskriminant analiz sonuçları (kırık dane)

### Kırık Dan Ve Buğday Ayrımında Diskriminant Analiz Sonuçları

morphological features in the Analysis				
	Step	Tolerance	F to Remove	Wilks' Lambda
1	majoraxis	1,000	3353,730	0,151
2	majoraxis	,994	1016,245	,012
	factor5	,994	139,377	
3	majoraxis	,091	188,560	,114
	factor5	,956	87,334	
	perimeter	,092	47,579	
4	majoraxis	,037	258,108	,101
	factor5	,948	60,966	
	perimeter	,051	121,672	
	Eccentricity	,318	73,102	
5	majoraxis	,037	266,298	,099
	factor5	,626	15,525	
	perimeter	,050	125,580	
	Eccentricity	,314	62,857	
	Solidity	,614	13,028	
6	majoraxis	,008	3,372	,095
	factor5	,458	35,479	
	perimeter	,013	0,562	
	Eccentricity	,054	62,346	
	Solidity	,475	30,639	
	factor4	,019	24,833	
7	majoraxis	,472	80,460	,095
	factor5	,646	59,673	
	Eccentricity	,095	137,227	
	Solidity	,554	40,319	
	factor4	,075	155,004	

colour features in the Analysis				
	Step	Tolerance	F to Remove	Wilks' Lambda
1	lkurtosis	1,000	675,258	0,47
2	lkurtosis	,999	348,058	,344
	amean	,999	218,999	
3	lkurtosis	,206	262,353	,307
	amean	,935	267,641	
	bBskewness	,202	71,901	
4	lkurtosis	,201	280,562	,268
	amean	,598	391,267	
	bBskewness	,182	115,838	
	Qmean	,600	86,469	
5	lkurtosis	,139	30,611	,228
	amean	,312	526,938	
	bBskewness	,182	100,902	
	Qmean	,283	203,437	
	lvar	,256	102,828	
6	lkurtosis	,139	26,061	,208
	amean	,270	630,797	
	bBskewness	,173	127,644	
	Qmean	,278	216,972	
	lvar	,253	110,070	
	askewness	,727	57,306	
7	lkurtosis	,136	15,732	,197
	amean	,260	673,697	
	bBskewness	,172	104,585	
	Qmean	,263	248,705	
	lvar	,240	132,070	
	askewness	,714	66,047	
	Ykurtosis	,877	33,850	

### EK-3 Diskriminant analiz sonuçları (yabani hardal)

#### Yabani Hardal Ve Buğday Ayrımında Diskriminant Analiz Sonuçları

morphological features in the Analysis				
	Step	Tolerance	F to Remove	Wilks' Lambda
1	majoraxis	1,000	30542,863	0,019
2	majoraxis	,926	640,120	,015
	elongation	,926	161,481	
3	majoraxis	,146	28,193	,011
	elongation	,428	411,149	
	EquivDiameter	,153	199,797	
4	majoraxis	,054	320,867	,007
	elongation	,050	774,044	
	EquivDiameter	,061	667,710	
	Eccentricity	,100	366,140	
5	majoraxis	,007	144,332	,007
	elongation	,050	593,014	
	EquivDiameter	,002	93,275	
	Eccentricity	,090	424,491	
	minoraxis	,004	38,451	
6	majoraxis	,006	236,391	,006
	elongation	,030	54,258	
	EquivDiameter	,001	195,310	
	Eccentricity	,074	108,399	
	minoraxis	,002	119,594	
	area	,029	88,606	

colour features in the Analysis				
	Step	Tolerance	F to Remove	Wilks' Lambda
1	Qmean	1,000	8281,402	0,067
2	Qmean	1,000	1989,535	,055
	lkurtosis	1,000	129,629	
3	Qmean	,992	1676,831	,050
	lkurtosis	,119	133,819	
	lskewness	,119	62,613	
4	Qmean	,744	1651,511	,046
	lkurtosis	,116	152,416	
	lskewness	,118	70,698	
	Gskewness	,733	55,376	
	Rskewness	,733	55,376	
5	Qmean	,723	1620,708	,041
	lkurtosis	,114	168,667	
	lskewness	,115	85,218	
	Gskewness	,537	112,457	
	Rskewness	,712	64,559	
	Qstd	,712	64,559	
6	Qmean	,712	1094,678	,040
	lkurtosis	,108	192,404	
	lskewness	,113	95,069	
	Gskewness	,532	119,282	
	Rskewness	,669	81,286	
	Qstd	,828	26,174	
	Qstd	,828	26,174	

### EK-3 Diskriminant Analiz sonuçları (yabani yulaf)

Yabani Yulaf ve buğday ayırımında Diskriminant Analiz sonuçları

morphological features in the Analysis				
	Step	Tolerance	F to Remove	Wilks' Lambda
1	elongation	1,000	4609,645	0,115
2	elongation	,060	206,481	,105
	Eccentricity	,060	57,530	
3	elongation	,010	385,668	,080
	Eccentricity	,017	258,753	
	factor6	,089	185,713	
4	elongation	,009	493,984	,066
	Eccentricity	,011	438,564	
	factor6	,016	283,574	
	roundness	,013	127,988	
5	elongation	,009	368,237	,061
	Eccentricity	,011	416,594	
	factor6	,016	294,155	
	roundness	,013	155,564	
	minoraxis	,719	48,833	
6	elongation	,002	139,045	,059
	Eccentricity	,011	414,857	
	factor6	,015	322,116	
	roundness	,011	182,481	
	minoraxis	,703	56,697	
	factor3	,002	21,540	
7	elongation	,002	94,184	,058
	Eccentricity	,011	412,035	
	factor6	,015	329,984	
	roundness	,011	183,161	
	minoraxis	,010	14,197	
	factor3	,002	15,640	
	ConvexArea	,013	8,459	

colour features in the Analysis				
	Step	Tolerance	F to Remove	Wilks' Lambda
1	lmean	1,000	1840,320	0,245
2	lmean	,566	3287,513	,125
	lvar	,566	355,986	
3	lmean	,526	1973,608	,102
	lvar	,145	783,528	
	bBstd	,193	305,721	
4	lmean	,494	2130,227	,093
	lvar	,137	866,390	
	bBstd	,186	339,277	
	Yskewness	,924	57,781	
5	lmean	,263	1019,990	,087
	lvar	,113	933,547	
	bBstd	,165	397,914	
	Yskewness	,904	39,249	
	Qmean	,457	39,207	
6	lmean	,175	861,077	,082
	lvar	,080	854,794	
	bBstd	,146	458,496	
	Yskewness	,880	24,229	
	Qmean	,426	57,007	
	lskewness	,550	37,148	
7	lmean	,147	345,606	,780
	lvar	,062	283,152	
	bBstd	,140	315,501	
	Yskewness	,878	25,139	
	Qmean	,380	25,755	
	lskewness	,086	52,758	
	lkurtosis	,067	27,109	

## EK-4 Diskriminant analiz sonuçları (Mısır)

Çizelge 4.2. Mısır ve buğday ayırımında Diskriminant Analiz sonuçları

morphological features in the Analysis				
	Step	Tolerance	F to Remove	Wilks' Lambda
1	minoraxis	1,000	17493,438	0,033
2	minoraxis	,954	15889,824	,030
	factor5	,954	52,408	
3	minoraxis	,301	81,220	,029
	factor5	,949	55,858	
	factor1	,301	33,372	
4	minoraxis	,233	16,354	,027
	factor5	,805	91,575	
	factor1	,051	77,033	
	area	,088	47,386	
5	minoraxis	,225	5,350	,024
	factor5	,510	168,763	
	factor1	,013	142,145	
	area	,025	119,882	
	factor2	,112	68,926	
6	minoraxis	,182	29,299	,022
	factor5	,506	126,377	
	factor1	,013	129,862	
	area	,010	185,297	
	factor2	,069	137,614	
	EquivDiameter	,014	64,037	

colour features in the Analysis				
	Step	Tolerance	F to Remove	Wilks' Lambda
1	amean	1,000	7729,384	0,072
2	amean	,858	3334,822	,041
	lskewness	,858	449,869	
3	amean	,767	289,692	,030
	lskewness	,602	783,921	
	lmean	,547	224,965	
4	amean	,764	174,468	,023
	lskewness	,381	1150,302	
	lmean	,225	441,106	
	lvar	,392	161,869	
5	amean	,749	189,600	,021
	lskewness	,319	1360,075	
	lmean	,210	512,161	
	lvar	,085	192,497	
	bBstd	,121	72,310	
6	amean	,740	197,352	,019
	lskewness	,278	1488,793	
	lmean	,190	587,839	
	lvar	,014	138,673	
	bBstd	,120	78,119	
	lstd	,020	44,168	

### EK-4 Diskriminant Analiz sonuçları (Arpa)

Arpa ve buğday ayırımında Diskriminant Analiz sonuçları


morphological features in the Analysis				
	Step	Tolerance	F to Remove	Wilks' Lambda
1	majoraxis	1,000	552,786	0,52
2	majoraxis	,649	93,921	,478
	roundness	,649	51,663	
3	majoraxis	,086	49,505	,391
	roundness	,072	186,854	
	factor2	,098	133,688	
4	majoraxis	,060	64,960	,381
	roundness	,044	172,699	
	factor2	,072	144,812	
	Solidity	,536	14,631	
5	majoraxis	,016	36,038	,378
	roundness	,040	174,538	
	factor2	,032	32,461	
	Solidity	,502	18,106	
	area	,013	4,874	

colour features in the Analysis				
	Step	Tolerance	F to Remove	Wilks' Lambda
1	bstd	1,000	531,188	0,53
2	bstd	,975	215,767	,404
	amean	,975	185,317	
3	bstd	,968	212,251	,356
	amean	,968	183,872	
	Rkurtosis	,982	80,350	
4	bstd	,929	241,868	,303
	amean	,853	235,494	
	Rkurtosis	,953	96,388	
	Bstd	,822	47,768	
5	bstd	,835	301,191	,302
	amean	,636	311,304	
	Rkurtosis	,931	110,913	
	Bstd	,733	78,640	
	Rmean	,673	54,632	
6	bstd	,835	284,233	,292
	amean	,636	288,766	
	Rkurtosis	,792	55,153	
	Bstd	,657	97,313	
	Rmean	,635	67,444	
	Yskewness	,675	19,064	


texture features in the Analysis				
	Step	Tolerance	F to Remove	Wilks' Lambda
1	GEnergy	1,000	285,178	0,67
2	GEnergy	,842	83,063	,588
	BEnergy	,842	80,664	
3	GEnergy	,479	,025	,501
	BEnergy	,735	137,664	
	grayContrast	,568	100,694	
4	BEnergy	,999	200,754	,501
	grayContrast	,999	198,393	
5	BEnergy	,741	248,446	,470
	grayContrast	,998	191,721	
6	BEntropy	,741	36,999	,445
	BEnergy	,653	293,306	
	grayContrast	,996	168,334	
	BEntropy	,740	36,971	
7	grayEntropy	,855	32,737	,439
	BEnergy	,645	263,202	
	grayContrast	,837	172,294	
	BEntropy	,740	36,749	
	grayEntropy	,852	30,284	
	RHomogeneity	,828	8,145	



## EK-5 Tohumların Özellik Değerlerinin Gösterimi




Yabani hardal Ve Buğday Tohumlarının Büyük Aksen Değerleri




Mısır Ve Buğday Tohumlarının Küçük Aksen Değerleri

## EK-5 (Devam) Tohumların Özellik Değerlerinin Gösterimi




**Kırık Dane Ve Buğday Tohumlarının Büyük Aksin Değerleri**




**Kırık Dane Ve Buğday Tohumlarının Factor 5 Değerleri**

## EK-5 (Devam) Tohumların Özellik Değerlerinin Gösterimi




**Kırık Dane Ve Buğday Tohumlarının Amean Değerleri**




**Yabani yulaf Ve Buğday Tohumlarının Elongation Değerleri**

## EK-5 (Devam) Tohumların Özellik Değerlerinin Gösterimi




**Yabani yulaf Ve Buğday Tohumlarının Imean Değerleri**




**Yabani yulaf Ve Buğday Tohumlarının I Standart Sapma Değerleri**

## EK-5 (Devam) Tohumların Özellik Değerlerinin Gösterimi




Arpa Ve Buğday Tohumlarının Major Axis Değerleri




Arpa Ve Buğday Tohumlarının Amean Değerleri

## EK-5 (Devam) Tohumların Özellik Değerlerinin Gösterimi




Arpa Ve Buğday Tohumlarının Qstd Değerleri




Arpa Ve Buğday Tohumlarının Avar Değerleri

## EK-5 (Devam) Tohumların Özellik Değerlerinin Gösterimi




Arpa Ve Buğday Tohumlarının Istd Değerleri

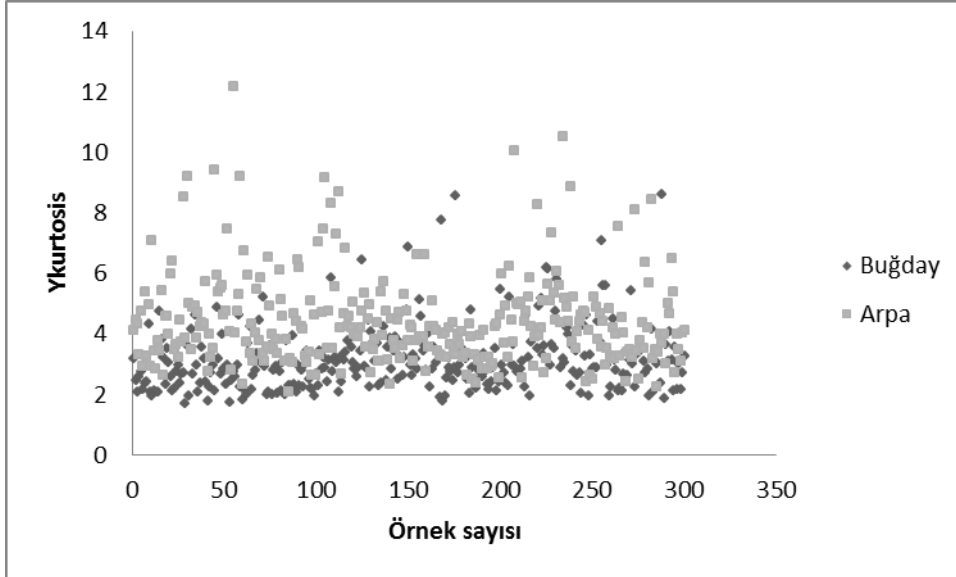


Arpa Ve Buğday Tohumlarının Çevre Değerleri

## EK-5 (Devam) Tohumların Özellik Değerlerinin Gösterimi




Arpa Ve Buğday Tohumlarının Factor4 Değerleri




Arpa Ve Buğday Tohumlarının Ykurtosis Değerleri




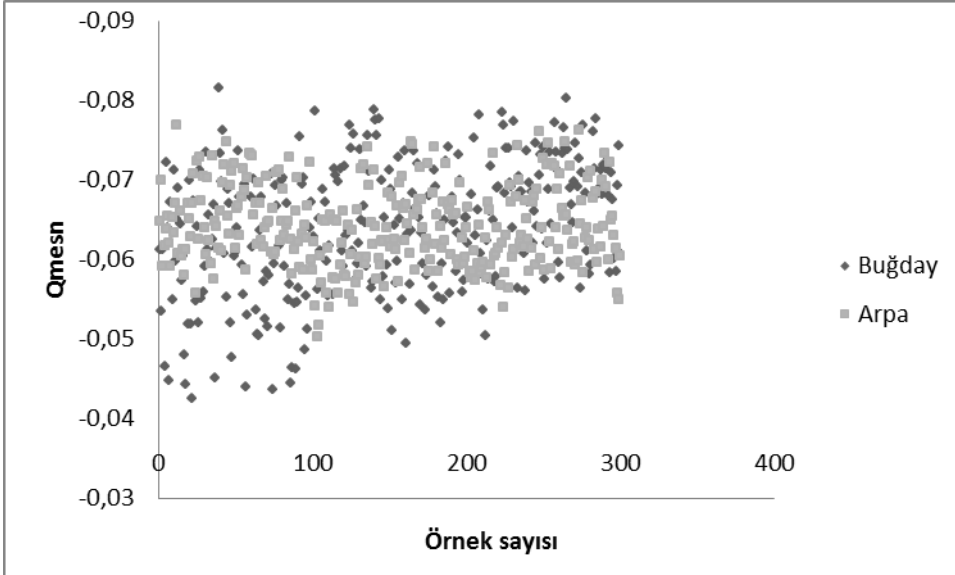
### EK-5 (Devam) Tohumların Özellik Değerlerinin Gösterimi




Arpa Ve Buğday Tohumlarının Bmean Değerleri




Arpa Ve Buğday Tohumlarının Lkurtosis Değerleri

**EK-5 (Devam) Tohumların Özellik Değerlerinin Gösterimi****Arpa Ve Buğday Tohumlarının İkurtosis Değerleri****Arpa Ve Buğday Tohumlarının Qmean Değerleri**

### EK-5 (Devam) Tohumların Özellik Değerlerinin Gösterimi



Arpa Ve Buğday Tohumlarının Bstd Değerleri



Arpa Ve Buğday Tohumlarının Gray Entropy Değerleri