

**BAKLİYATLARDA FİZİKSEL KALİTE KRİTERLERİNİN
BELİRLENMESİ AMACIYLA
GÖRÜNTÜ ANALİZ SİSTEMİ GELİŞTİRİLMESİ**

**DEVELOPMENT OF IMAGE PROCESSING SYSTEM
FOR PHYSICAL QUALITY EVALUATION OF LEGUMES**

YUSUF SERHAD ÇAKMAK

Hacettepe Üniversitesi

Lisansüstü Eğitim Öğretim ve Sınav Yönetmeliğinin

Gıda Mühendisliği Anabilim Dalı İçin Öngördüğü

YÜKSEK LİSANS TEZİ

olarak hazırlanmıştır.

2011

Fen Bilimleri Enstitüsü Müdürlüğü'ne,

Bu çalışma jürimiz tarafından **GIDA MÜHENDİSLİĞİ ANABİLİM DALI'nda YÜKSEK LİSANS TEZİ** olarak kabul edilmiştir.

Başkan :.....
Prof.Dr. Hamit KÖKSEL

Üye (Danışman) :.....
Prof.Dr. İsmail Hakkı BOYACI

Üye :.....
Prof.Dr. Mehmet MUTLU

Üye :.....
Doç.Dr. Ali TOPCU

Üye :.....
Yrd.Doç.Dr. Benat KOÇKAR

ONAY

Bu tez Hacettepe Üniversitesi Lisansüstü Eğitim-Öğretim ve Sınav Yönetmeliği'nin ilgili maddeleri uyarınca yukarıdaki jüri üyeleri tarafından/...../..... tarihinde uygun görülmüş ve Enstitü Yönetim Kurulunca/...../..... tarihinde kabul edilmiştir.

Prof.Dr. Adil DENİZLİ
Fen Bilimleri Enstitüsü Müdürü

BAKLİYATLARDA FİZİKSEL KALİTE KRİTERLERİNİN BELİRLENMESİ AMACIYLA GÖRÜNTÜ ANALİZ SİSTEMİ GELİŞTİRİLMESİ

Yusuf Serhad ÇAKMAK

ÖZ

Bakliyatların sınıflandırma ve fiyatlandırması için görsel özelliklerden faydalanılmaktadır. Çalışma kapsamında öncelikle kalite kriterleri belirlenmiş daha sonra örnekleri bu kalite kriterleri ile değerlendirecek görüntü analiz sistemi (GAS) geliştirilmiştir.

Nohut ve fasulye örneklerinin çap ve boy değerleri GAS ile ölçülmüş ve renk kusurlu, kırık ve buruşuk taneler belirlenerek kusurlu tane oranı hesaplanmıştır.

Ayrıca hektolitre ağırlığı ve bin tane ağırlığı gibi ölçümleri gerçekleştirebilmek ve mühendislik hesaplarında faydalanılmak üzere nohut örneklerinin hacim ölçümleri de gerçekleştirilmiştir.

GAS'nin başarısının değerlendirilmesi için GAS ile yapılan boyut ölçümleri kumpasla, hacim ölçümleri ise taşıma kabı yöntemiyle tekrarlanarak sonuçlar karşılaştırılmış, R^2 değerleri nohut en, boy ve hacim ölçümleri için sırasıyla; 0.928, 0.933 ve 0.954 olarak, eğim değerleri ise sırasıyla; 0.998, 0.958 ve 0.993 olarak hesaplanmıştır. Fasulye en ve boy ölçümleri için R^2 değerleri sırasıyla 0.915 ve 0.923, eğim değerleri ise sırasıyla 0.997 ve 0.987 olarak hesaplanmıştır.

Renk kusurlu tanelerin belirlenmesinde sistemin başarısı nohut ve fasulye için sırasıyla % 94.4 ve % 91.8, buruşuk tanelerin belirlenmesinde % 96.0 ve % 86.1, kırık tanelerin belirlenmesinde ise % 93.0 ve % 95.9 olarak hesaplanmıştır.

Bu çalışma kapsamında bakliyat ürünlerinin boyutlandırması ve yapay sinir ağları yardımıyla görsel kusurların belirlenmesi için bir GAS geliştirilmiştir. Doğruluğu ve tutarlılığı yüksek sonuçlar üreten GAS zaman ve işgücü gerektiren uygulamalara iyi bir alternatif olmakta ve nesnel sonuçlar üretmesiyle insana bağımlılığı ortadan kaldırmaktadır.

Anahtar kelimeler: Bakliyat, görsel kalite, yapay sinir ağları, görüntü analiz sistemleri.

Danışman: Prof. Dr. İsmail Hakkı Boyacı, Hacettepe Üniversitesi, Gıda Mühendisliği Bölümü, Gıda Mühendisliği Anabilim Dalı

DEVELOPMENT OF IMAGE PROCESSING SYSTEM FOR PHYSICAL QUALITY EVALUATION OF LEGUMES

Yusuf Serhad ÇAKMAK

ABSTRACT

Visual properties are used in classification and pricing of legumes. Within the scope of this study, quality criteria of legumes are determined and image processing system (IPS) which will evaluate samples in terms of the criteria has been developed.

Width and length values of chickpea and bean samples were measured by IPS, colour defected, wrinkled and broken grains were determined to calculate defected grain ratio.

Besides, volume computations of chickpea samples were realised for determining hectolitre weight and thousand grain weights and also for technical computations.

To determine performance of IPS, IPS results were compared with calliper results and volume computation results were compared with water displacement results. R^2 values were determined for chickpeas in width, length and volume measurements as 0.928, 0.933 and 0.954 respectively and slope values as 0.998, 0.958 and 0.993 respectively. For beans, R^2 values were determined as 0.915 and 0.923, slope values were also determined as 0.997 and 0.987 respectively.

Performance of system were determined for chickpea and bean samples as 94.4% and 91.8% in determining colour defected grains, 96.0% and 86.1% in wrinkled grains, 93.0% and 95.9% in broken grains.

In conclusion, within the scope of the study an IPS which is used for grading and determination of visual defects by using artificial neural networks is developed. IPS is a good alternative to practises that requires time and labour force with its accurate and precise results and surpasses with its objectivity so it will eliminate the human dependency.

Keywords: Legume, visual quality, artificial neural networks, Image processing systems.

Advisor: Prof. Dr. İsmail Hakkı BOYACI, Hacettepe University, Department of Food Engineering, Food Engineering Section

TEŐEKKÜR

Bu alıőmanın planlanması, yrtlmesi ve sonulandırılmasında bilgisi ve deneyimi ile bana yol gsteren, karőılaőtıđım sorunların zmnde yardımlarını esirgemeyen deđerli danıőmanım Sayın Prof.Dr. İsmail Hakkı Boyacı'ya,

Deneysel alıőmalarımda ve karőılaőtıđım sorunların zmnde desteđini esirgemeyen ve felsefesiyle aydınlatan Dr. Deniz Baő'a,

Bu tezin hazırlanmasında bana her trl alıőma olanađını sađlayan Hacettepe niversitesi Gıda Mhendisliđi Blm'ne ve tm personeline,

San-Tez Ar-Ge Programı, 00122.STZ.2007-1 kodlu proje kapsamında finansman sađlayan T.C Bilim, Sanayi ve Teknoloji Bakanlıđı, Bilim ve Teknoloji Genel Mdrlđ'ne,

Numune temini konusunda desteklerini esirgemeyen, İhracatı Birlikleri Tohumculuk ve Araőtırma Sanayi ve Ticaret A.Ő.'den Sayın Dr. İsmail Ksmenođlu'na,

ve en deđerli zamanlarından aldıđım sevgili eőime teőekkrlerimi sunuyorum.

İÇİNDEKİLER DİZİNİ

Sayfa

ÖZ	i
ABSTRACT	ii
TEŞEKKÜR	iii
İÇİNDEKİLER DİZİNİ	iv
ŞEKİLLER DİZİNİ	vi
ÇİZELGELER DİZİNİ	viii
SİMGE VE KISALTMALAR DİZİNİ	ix
1.GİRİŞ	1
2.GENEL BİLGİLER	4
2.1.Görüntü Analiz Sistemleri	4
2.2.Görüntü Analiz Sistemlerinin Aşamaları	5
2.2.1. Görüntünün elde edilmesi	5
2.2.1.1. Aydınlatma	6
2.2.1.2. Görüntü yakalama.....	7
2.2.1.3. Sayısallaştırıcı ve bilgisayar	8
2.2.2.Görüntünün analiz edilmesi	8
2.2.2.1 Ön işleme	8
2.2.2.2 Algılama ve segmentasyon	8
2.2.2.3.İleri işlemler	9
2.3.Yapay Sinir Ağları	10
2.3.1.YSA hücresi	10
2.3.2.YSA tasarımı	13
2.3.3.Ağ modeli	13
2.3.4.Ağ mimarisi	13
2.3.5.Ağın eğitilmesi	14
2.4. GAS'nin Gıda Alanında Kullanımı	15
2.5. Nohut Ve Fasulye İçin Görsel Kalite Kriterleri.....	16
3.DENEYSEL ÇALIŞMALAR	19
3.1.Materyal	19
3.2.Metot	19
3.2.1. Görüntünün elde edilmesi	19
3.2.2. Görüntünün işlenmesi	19
3.2.3. Segmentasyon	20
3.2.4. Nicel değerlendirmeler	20
3.2.4.1. En ve boy ölçümler	20
3.2.4.2. Hacim ölçümleri.....	21
3.2.5. Nitel değerlendirmeler	24
3.2.5.1. Renk kusurlu taneleri belirleme	25
3.2.5.2. Buruşuk tane belirleme	27
3.2.5.3. Kırık tane belirleme	27
4.SONUÇLAR VE TARTIŞMA	30
4.1. Görüntünün Elde Edilmesi	30
4.2. Segmentasyon	30
4.3. Nicel Değerlendirmeler	30
4.3.1 Çap ve boy ölçümleri.....	30
4.3.2 Hacim ölçümleri	35

İÇİNDEKİLER DİZİNİ (devam ediyor)

	<u>Sayfa</u>
4.4. Nitel Değerlendirmeler	37
4.4.1. Renk kusurlu tane belirleme	38
4.4.2. Buruşuk tane belirleme	43
4.4.3. Kırık tane belirleme	49
KAYNAKLAR	56
EK	61
ÖZGEÇMİŞ	65

ŞEKİLLER DİZİNİ

	<u>Sayfa</u>
Şekil 2.1. Bir GAS'nin temel parçaları	7
Şekil 2.2. Yapay sinir hücresinin temel yapısı	11
Şekil 2.3. Çeşitli Aktivasyon Fonksiyonlarının grafikte ifadesi, a) eşik değeri, b) lineer ve c) sigmoid fonksiyonları	12
Şekil 2.4. YSA Mimarisi	14
Şekil 3.1. Örnek görüntüsünün ölçümler için doğru konumlandırılması, a) Yanlış konumdaki örnek, b) Döndürülmüş örnek	21
Şekil 3.2. Disk yöntemiyle iki boyutlu bir görüntüden üç boyutlu cismin oluşturulması, a) Dikdörtgenlerden oluşan iki boyutlu ve b) silindirlere oluşan üç boyutlu görüntüler	22
Şekil 3.3. Hacim ölçümleri için tanenin pozisyonunun etkisi, a) Yanlış ve b) doğru pozisyondaki taneleri temsil eden silindirlere	23
Şekil 3.4. Görüntünün dikdörtgen elementlerden oluşmasının disk yönteminde neden olduğu hesap hataları, a) dikdörtgen elementlerden oluşan bir görüntü ve b) yamuk elementlerden oluşan bir görüntü	24
Şekil 3.5. Çevreyi temsil eden pikseller ve ağırlık merkezine olan öklid uzaklıkları (d)	29
Şekil 4.1. Görüntü elde edilmesi için tasarlanan sistem; Canoscan 4400F tarayıcı (a), nohut ve fasulye örnekleri için tasarlanan örnek çekmeceleri (b), Bileşenlerin toplandığı kapalı kutu (c)	31
Şekil 4.2. RGB formundaki örnek görüntüsü (a), İkili görüntü (b)	32
Şekil 4.3. Nohut örneklerinin GAS ile yapılan çap ölçümlerinin kumpasla yapılan ölçümlerle karşılaştırılması.	33
Şekil 4.4. Nohut örneklerinin GAS ile yapılan boy ölçümlerinin kumpasla yapılan ölçümlerle karşılaştırılması.	33
Şekil 4.5. Fasulye örneklerinin GAS ile yapılan çap ölçümlerinin kumpasla yapılan ölçümlerle karşılaştırılması	34
Şekil 4.6. Fasulye örneklerinin GAS ile yapılan boy ölçümlerinin kumpasla yapılan ölçümlerle karşılaştırılması	34
Şekil 4.7. Konum düzeltmelerinin hacim hesaplamaları açısından önemi	35
Şekil 4.8. Nohut örneklerinin GAS ile yapılan hacim ölçümlerinin, taşıma kabı yöntemiyle yapılan ölçümlerle karşılaştırılması	36
Şekil 4.9. İyi renkli (a), kabul edilebilir renkli (b) ve renk kusurlu (c) nohut tanelerine ait moment değerleri ve histogramları.	39
Şekil 4.10. İyi renkli (a), kabul edilebilir renkli (b) ve renk kusurlu (c) fasulye tanelerine ait moment değerleri ve histogramları.	41
Şekil 4.11. Buruşuk (a) ve pürüzsüz (b) tanelerin yüzey dokularının grafiksel ifadesi.	44
Şekil 4.12. Pürüzsüz (a) ve buruşuk (b) nohut tanelerinin filtre edilmiş görüntülerine ait moment değerleri ve histogramları.	45
Şekil 4.13. Pürüzsüz (a) ve buruşuk (b) fasulye tanelerinin filtre edilmiş görüntülerine ait moment değerleri ve histogramları.	47
Şekil 4.14. Bütün ve kırık nohut tanelerine ait moment değerleri ve histogramlar.	49

ŞEKİLLER DİZİNİ (devam ediyor)

Sayfa

Şekil 4.15. Bütün ve kırık fasulye tanelerine ait moment değerleri ve histogramlar.	50
Şekil 4.16. MatLab programıyla oluşturulan kullanıcı ara yüzü	54

ÇİZELGELER DİZİNİ

	<u>Sayfa</u>
Çizelge 2.1. Nohut ve fasulye tanelerinin kusurlu tane oranlarına göre kalite sınıflandırması	18
Çizelge 4.1. Tüm ölçüm sonuçlarının tutarlılık ve doğrulukları	37
Çizelge 4.2. Ölçüm sonuçları ile gerçek değerlerin istatistiksel karşılaştırılmasına ait p değerleri.	37
Çizelge 4.3. Renk kusurlu tanelerin belirlenmesinde kullanılan ağın tasarımı ve eğitimine ait parametreler.	38
Çizelge 4.4. Nohut örneklerinin renklerine göre sınıflandırılmasında GAS'nin başarısı	40
Çizelge 4.5. Fasulye örneklerinin renklerine göre sınıflandırılmasında GAS'nin başarısı	43
Çizelge 4.6. Buruşuk tanelerin belirlenmesinde kullanılan ağın tasarımı ve eğitimine ait parametreler	46
Çizelge 4.7. Nohut örneklerinin yüzey morfolojisine göre sınıflandırılmasında GAS'nin başarısı	48
Çizelge 4.8. Fasulye örneklerinin yüzey morfolojisine göre sınıflandırılmasında GAS'nin başarısı	48
Çizelge 4.9. Kırık tanelerin belirlenmesinde kullanılan ağın tasarımı ve eğitimine ait parametreler	51
Çizelge 4.10. Nohut örneklerinin tane bütünlüğüne göre sınıflandırılmasında GAS'nin başarısı	51
Çizelge 4.11. Fasulye örneklerinin tane bütünlüğüne göre sınıflandırılmasında GAS'nin başarısı	52

SİMGELER VE KISALTMALAR DİZİNİ

A_i	Ağ girdisi
α	Örnek konumunun yatayla yaptığı açı
b	Sabit sayı
bpp	Piksel başına bit
CCD	Kamera türü
Ç	Ağ çıktısı
D	Öklid uzaklığı
DSY	Doğru sınıflandırma yüzdesi
G_i	Girdi ağırlığı
GAS	Görüntü analiz sistemi
GKA	Grafiksel kullanıcı ara yüzü
HKO	Hata kareleri ortalaması
JPEG	Görüntü dosya türü
ml	mililitre
mm	milimetre
Π	Pi sayısı
R^2	Regresyon katsayısı
RGB	Renk uzayı
YSA	Yapay sinir ağı

I. GİRİŞ

Gıdaların görsel kalite kriterlerine göre değerlendirilmesi özellikle işlenmemiş ürünler için büyük önem taşımaktadır. Ürünün üreticiden alınıp tüketimine kadar geçen süreçte görsel kalite kriterleri ürünün fiyatlandırılmasında belirleyici faktör olmaktadır. Ürün alım merkezlerinde konunun uzmanı kişilerce ürünün görsel özellikleri incelenmekte, bu incelemeler sonucunda sınıflandırılmakta ve üreticiye ücret ödenmektedir. Görsel kalite kriterleri boyutsal ve renksel kalite kriterleri olarak genel olarak iki gruba ayrılmakla birlikte bu kriterler üründen ürüne büyük değişiklikler arz etmektedir.

Özellikle taneli ürünlerde; tane büyüklüğü, tanenin eni ve boyu, belirgin bir şekle sahip olması, boyutsal özelliklerin homojen olması, belirgin boyutsal kusurların olması (kırık tane, yenmiş tane vb.), bin tane veya hektolitre ağırlığı ürünün fiyatlandırılmasında önemli kriterler arasında yer almaktadır. Aynı şekilde renksel özellikler; ürünün renk değerleri, renk dağılımı, renk homojenliği, karakteristik renk profillerinin olması, renk kusurlarının (küflenmiş tane, sararmış tane, dönmeli tane vb.) olması ürün fiyatlandırılmasında önem arz etmektedir. Belirtilen kalite kriterlerinin saptanmasında otomasyon ürünlerinin kullanılması ve bu ürünlerin yaygınlaşması gerek üreticilerin ve gerekse ürün alım merkezlerinin ihtiyaçlarına büyük ölçüde cevap verecek, üretici-alım merkezi arasında yaşanan anlaşmazlıkların ortadan kaldıracak ve en önemlisi bu analizlerin yapılmasında gerekli olan işgücünün önemli ölçüde azaltılmasına imkân sağlayacaktır.

Görüntü işleme, özellikle sayısal görüntü kaydının yaygınlaşmasıyla günümüzde önemini giderek artırmaktadır. Görüntü işleme birçok alanda olduğu gibi gıda teknolojisinde de kullanım alanı bulmakta ve hızlı, etkin ve kolay uygulanabilir olmasından dolayı görüntü işleme teknolojisi araştırmacıların ve uygulayıcıların ilgisini çekmektedir (Du and Sun, 2004).

Birçok gıda ürünü tüketiciler tarafından görsel özelliklerine göre değerlendirilmekte dolayısıyla ürünün fiyatının belirlenmesinde görsel kalite öncelikli önem taşımaktadır (Du and Sun, 2006).

Genellikle ürün görsel özelliklerinin belirlenmesi insan gözüyle yapılmakta ve bu yolla ürün fiyatlandırılmaktadır. Fakat insan duyuları kolaylıkla yanılgıya

düşebilmekte ve standartlardan uzaklaşabilmektedir. Bu problemler görüntü işleme teknolojisi kullanılarak geliştirilen görüntü analiz sistemleriyle (GAS) ortadan kaldırılmaya çalışılmaktadır. GAS genellikle 5 ana bölümden oluşmaktadır. Bunlar ışık kaynağı, görüntü üreten sensor (kamera, tarayıcı vb.), görüntü yakalama kartı, bilgisayar ve yazılımdır. GAS ile birçok farklı gıdanın farklı görsel ve boyutsal kalite kriteri ölçümüne ilişkin çalışmalar literatürde mevcuttur (Fernandez et al., 2005; Kılıç et al., 2007a; Kılıç et al., 2007b; Utku and Köksel, 1998). GAS ile bakliyat gibi küçük taneli gıda örnekleri üzerinde yapılan çalışmalar örneğin en, boy, alan gibi boyutsal özelliklerinin yüksek doğruluklarla ölçülebildiğini göstermektedir (Ilgathinathane et al., 2009; Durmuş et al., 2010). Buna ek olarak bakliyat ve hububatlarda kullanılan bin tane ağırlığı ve hektolitreye ağırlığı gibi ürün yoğunluğu ve hacmi hakkında bilgi veren kalite kriterleri de bu boyutsal veriler kullanılarak ölçülebilmektedir. Hacimsel, boyutsal ve ağırlıksal kalite kriterlerinin yanı sıra örneklerin renksel özelliklerini ölçmek ve renksel ve boyutsal özelliklerine göre örnekleri sınıflandırmak mümkün olabilmektedir (Kılıç et al., 2007a; Kılıç et al., 2007b; Utku and Köksel, 1998).

Görüntü analiz sistemleri ile gıda kalitelerinin saptanması üzerine yapılan bir derlemede 1996-2003 yılları arasında yüze yakın makalenin yayınlandığı rapor edilmektedir (Brosnan and Sun, 2004). Aynı çalışmada konunun çeşitli alanlara uygulanabilir olması ve uygulandığı alanda büyük avantajlar sağlaması nedeniyle hızlı bir şekilde yaygınlaştığı ifade edilmektedir. GAS ile ilgili çalışmalar arasında hububatların sınıflandırılması, domuz etinin incelenmesi, mısır tanesi beyazlığının ölçülmesi ve sınıflandırılması, fıstığın sınıflandırılması, fırıncılık ürünlerinin kalitelerinin değerlendirilmesi, elma kalitesinin incelenmesi, badem kalitesinin incelenmesi ve balık ve tavukta kemiklerin saptanması gibi çalışmalar yer almaktadır (Brosnan and Sun, 2004).

Son yıllarda istatistiksel öğrenme, genetik algoritma, bulanık mantık ve yapay sinir ağları gibi öğrenme temelli teknolojiler farklı alanlarda ve gıda alanında kullanılmaya başlanmıştır. İnsan beynini taklit eden ve bilgisayara insan gibi düşünmenin öğretildiği yapay sinir ağları (YSA) ilk zamanlarda elektronik alanında yoğun bir şekilde kullanılmış, insansız uçak teknolojisinin geliştirilmesinde önemli rol oynamıştır. Özellikle son yıllara elektronik uygulamalarının harici konularda da kullanılmaya başlanmıştır. Yapay sinir ağlarının GAS'leri ile birleştirilerek gıdaların

incelenmesi, kalitelerinin saptanması ve sınıflandırılması konusu özellikle son yıllarda yoğun araştırılan konulardan bir tanesidir. Bu iki teknolojinin birlikte kullanılması üzerine yapılan yoğun arařtırmalar, arařtırma sonuçlarının kısa sürede hayatımıza gireceğini göstermektedir. YSA ve GAS birlikte kullanıldığı çalışmalar arasında hububatların, fındıkların, sebzelerin meyvelerin ve etlerin sınıflandırılması ve/veya kalitelerin incelenmesi çalışmaları yer almaktadır (Brosnan and Sun, 2004; Lou and Nakai, 2001; Warnes et al., 1998).

Nohut ve fasulye sırasıyla % 19.3 ve % 23.4 protein içerikleriyle iyi birer protein kaynağı olmakta ve tüketilmektedir (USDA, 2011). Tüm dünyada 1991 ve 2009 yılları arasında nohut üretiminin 8115542 tondan 10461215 tona yükselerek % 29 arttığı, fasulye üretiminin ise 1678563 tondan 20698984 tona yükselerek % 23.3 arttığı görülmektedir. Ülkemiz açısından bakıldığında ise 1991 ve 2009 yılları arasında ülkemiz nohut üretiminin ortalama 560000 ton civarında, fasulye üretiminin ise 180000 ton civarında olduğu, nohut ve fasulye üretim miktarlarının 2009 yılında sırasıyla tüm dünya üretiminin % 5.4 ve % 0.9'unu oluşturduğu görülmektedir. Türkiye'nin 2009 yılında tüm dünyada elde edilen bakliyat üretim değerinden nohut ile 523 milyon ABD doları ve fasulye ile 290 milyon ABD doları pay aldığı görülmektedir (FAO, 2011).

Bu çalışma kapsamında görüntü analiz teknolojisi ve yapay sinir ağıları kullanılarak fasulye ve nohut görsel kalite kriterlerine göre sınıflandırılmış ayrıca fiziksel özellikleri ölçülmüştür. Çalışma kapsamında ayrıca bu amaçla saha uygulamalarında kullanılabilir bir prototip üretilmiştir.

II. GENEL BİLGİLER

2.1. Görüntü Analiz Sistemi

Görüntü analiz sistemleri bir problemi çözmek ya da bir görevi yerine getirmek üzere görüntülerden bilgi çıkarımı yapabilen sistemlerdir. GAS fiziksel nesnelerin görüntülerinden faydalanarak anlamlı, açık ve net tanımlamalar çıkarmaktadır (Ballard and Brown, 1982). Görüntü işleme tekniklerini temel alan GAS, nesnelerin dijital görüntülerinden hızlı, zarar vermeden ve temas olmadan kalite değerlendirmesi yapmak için nicel veri üreten yeni bir teknolojidir.

İlk kez 1960'larda ortaya çıkışından sonra 1970'lerin sonuna doğru üzerinde yoğun çalışılan GAS, çok çeşitli problemlerin çözümünde yardımcı olarak geniş bir alanda kullanım imkânı bulmuştur. Tıbbi tanısal görüntüleme, fabrika otomasyonu, uzaktan algılama, adli bilimler, otonom vasıtalar ve robot kılavuzluğu gibi çeşitli alanlara yayılan uygulamalar bunlardan bazılarıdır.

Kesin ve tanımlayıcı veri üretme, insana bağımlılığı azaltarak hızlı ve nesnel sonuç verme, birçok emek yoğun işlemi otomatikleştirme, tutarlı, etkin ve düşük maliyetli olma, diğer görsel kalite değerlendirmesi yapan aygıtlardan farklı olarak sadece belirli bir kısımdan değil, bütün yüzeyden alınan görüntüyü değerlendirerek daha doğru sonuç verme gibi avantajları olan GAS'nin aynı zamanda yapısı düzgün olmayan alanlardan görüntü almanın zor olması, yapay aydınlatmaya gerek duyması ve her ürün için kullanılabilecek bir GAS tasarlanmasının mümkün olamaması gibi dezavantajları da vardır (Brosnan and Sun, 2004).

Son yirmi yıldan bu yana GAS çeşitli gıdaların ve tarım ürünlerinin nesnel olarak ölçülmesi ve değerlendirilmesinde kullanılmaktadır. Bilgisayarlardaki gelişmeler ve görüntü işleme teknikleri ve yazılımlarında ortaya çıkan hızlı gelişim ile birlikte, GAS'nin uygulanma alanı çeşitli ve işlenmiş gıdaların kalite değerlendirmesine kadar genişlemiştir. Son yıllarda, özellikle görüntü analiz araştırmaları dikkatleri üzerine toplamış ve bu durum geniş bir aralıktaki gıda ve tarım ürününün kalite kontrolü, sınıflandırılması ve değer biçilmesi alanlarında hızla artan bilimsel ve teknolojik gelişmelerle sonuçlanmıştır. Gıda maddeleri ve tarımsal ürünlerin değerlendirilmesinde görüntüler, insan beynindeki kavramları temsil ederek tartışmasız en çok tercih edilen yöntemlerdir. Gıda maddelerini etkileyen kalite faktörlerinin birçoğu görsel inceleme ve görüntü analiziyle belirlenebilmektedir.

Dijital görüntüleme sistemlerinin hızla gelişmesi, bilgisayar ve diğer dijital aygıtların fiyatlarının hızla düşmesi insana bağımlılığı ortadan kaldırırken rutin olarak tekrarlanan gıda maddelerinin kalitesinin değerlendirilmesi işlemleriyle beraber kalite güvence görevlerinin yerine getirilmesinde görüntü analizi ideal bir yöntem durumuna gelmektedir (Sun, 2007).

2.2. Görüntü Analiz Sistemlerinin Aşamaları

Görüntü analiz sistemlerinin yapısı uygulama alanına doğrudan bağlıdır. Basit ölçüm problemleri ya da kusur belirleme gibi uygulamalar tek başına cihazlardan oluşurken bazı makine sistemlerinin kumanda edilmesi ya da veritabanları gibi karmaşık sistemlerde GAS bir alt sistem olarak görülmektedir. Temelde birçok GAS de tipik basamaklar, bir donanım yardımıyla görüntünün elde edilmesi, bir yazılımla görüntünün işlenmesi ve elde edilen verilerin istenilen uygulamada kullanılması olarak gösterilmektedir.

2.2.1. Görüntünün elde edilmesi

Sayısal görüntü, basitçe fiziki varlığı olan bir nesneden elde edilen görüntünün sayılarla ifade edildiği matris ya da matrisler olarak tanımlanabilmektedir. Bilgisayarlarda bilgi depolanmasını anlamak için *bit* kavramı üzerinde durmak gerekir. Bilgisayarlar gerçekleştirdikleri işlemleri yerine getirirken elektriksel olaylardan hareketle devrenin açık ya da kapalı olma durumuna göre 0 veya 1 değerlerini esas almaktadır. 0 ve 1 değerlerinin her biri bit (*binary digits*) olarak adlandırılır ve bu değerlerin farklı kombinasyonları harfleri, karakterleri, sayıları vb. ifade eder. İkili sayı sistemini kullanmakla bilgisayarlar verileri hızlı ve güvenli bir şekilde depolayıp işleyebilmektedir (Shannon, 1948).

Piksel kelimesi İngilizce *picture* (*pix*) ve *element* kelimelerinden türetilmiştir. Piksel en küçük adreslenebilir görüntü elementidir ve görüntünün en küçük parçasıdır. Pikseller iki boyutlu matrisler halinde dizilmiştir ve her piksel görüntüden bir numune olarak değerlendirilebilir. Bu açıdan bir görüntünün ne kadar çok pikselle tanımlandığı görüntüsü alınan cisim ne kadar iyi temsil ettiğini göstermektedir. Çözünürlük basitçe dijital bir görüntünün ne kadar bilgi içerdiğinin ölçütüdür. Bir dijital görüntüdeki belli boyutun kaç pikselle ifade edildiği şeklinde de ifade edilen çözünürlüğün artması dijital görüntünün daha detaylı bilgi içermesi anlamına gelmektedir (Myler and Weeks, 1993).

Bir piksel tarafından temsil edilen farklı renk sayısı *piksel başına bit* (bpp) değerine bağlıdır. 1 bpp'lik bir görüntü piksel başına bir bit bilgi içermektedir ve her piksel 1 ya da 0 olarak ifade edilmektedir. Bir piksele eklenecek her bit renk sayısını ikiye katlamaktadır (Gonzalez and Woods, 2008).

Renk uzayı, renkleri ifade etmek için sayısal değerlerin kullanıldığı sistemlerdir. *Kırmızı-yeşil-mavi (RGB)* ve *Açıklık-a-b (L*a*b)* gibi renk uzayları günümüzde kullanımda olsa da, GAS görüntü yakalamada genellikle *RGB* renk uzayını kullanır. *RGB* renk uzayı, İngilizcedeki '*Red*' '*Green*' '*Blue*' kelimelerinin baş harflerinden ismini almaktadır ve en sık kullanılan renk uzaylarından biridir. Işığı temel alarak, doğadaki tüm renklerin kodları bu üç temel renge referansla belirtilir. Her renk % 100 oranında karıştırıldığında beyaz ve % 0 oranında karıştırıldığında siyah elde edilir (Tkalčič and Tasič, 2003). Her pikselin 8 bpp bilgi içermesi nedeniyle 256 farklı renk değeri oluşmakta ve böylece *RGB* formatında her renk eksenini (R, G ve B) 256 ya bölünmektedir. İntensite değeri 0 ile 255 arasında değişmektedir (Sun, 2007).

Özetle bir görüntü, bilgisayarda her pikselin adresleri ve bu adreslere ait RGB intensite değerleri olarak kodlanmıştır. Görüntünün elde edilmesi için ışık kaynağı, görüntü yakalama aygıtı ve sayısallaştırıcı olmak üzere üç temel bileşen gerekmektedir (Şekil 2.1).


2.2.1.1. Aydınlatma

Birçok görsel uygulamada, doğru ve kaliteli aydınlatma sonuç üzerinde önemli etkiye sahiptir. Aydınlatma GAS'nin önemli bir parçası olarak kabul edilmektedir. Uygun aydınlatma stratejisini belirlemek henüz bir sorun olarak önemini korumakla birlikte yinede birkaç temel kuraldan bahsedilebilmektedir. Yeterli derecede aydınlatma sağlamak için genel olarak üç alanda bilgiye sahip olmak gerekmektedir. Bunlar aydınlatma elemanının GAS'indeki önemi, ışığın görüntü alınacak yüzeydeki davranışı ve istenilen özellikleri ortaya çıkarabilecek aydınlatma tekniğidir. Geleneksel olarak en çok kullanılan aydınlatıcılar flüoresan ve akkor lambalardır. Gün ışığıyla elektrikli aydınlatıcılar karşılaştırıldığında aralarında her bir dalga boyunda yayılan enerji miktarları açısından fark olduğu görülmektedir. Işık şiddetinin olması gerekenden az olmasının muhtemel olumsuz etkileri; sinyal gürültü oranının yetersiz olması, elektriksel gürültünün (elektrik

akımının girişim yapmasından dolayı oluşan) artması ve en önemlisi görüntü alanı derinliğindeki (üzerinde odaklama yapılan cismin önünde ve arkasında oluşan netlik sahası) önemli kayıplar olarak sıralanabilmektedir. Çevreden gelen ışığın girişim yapmasının etkileri de aynen yetersiz aydınlatma gibi olmaktadır. Akkor lambalar, dalga boyunun artmasıyla yayılan enerji miktarında artış gösterirken, flüoresan lambalar belirli dalga boylarında keskin pikler yapmaktadır. Bu durum flüoresan lambaların belirli dalga boylarında daha şiddetli aydınlatma yapacağı anlamına gelmektedir. Ayrıca flüoresan ışık yansıdığı yüzeyden daha düzenli bir dağılım sağladığı için akkor lambalarda olduğu gibi, ışığın yayılması için kullanılan optik gereçlere ihtiyaç duymaz. Tüm bu nedenlerden dolayı flüoresan lambalar GAS'inde akkor lambalara göre daha kullanışlı hale gelmektedir (Sun, 2007).

2.2.1.2. Görüntü yakalama

Temel görüntü yakalama aygıtları; kameralar ve tarayıcılardır. Günümüzde kullanılan CCD kameralar, bölümlendirilmiş kutucukları arasında elektrik yüklerinin hareketini dijital değerlere çevirirler. 1970'lerde icat edilmesinden sonra görüntü yakalama aygıtları arasında baskın hale gelen CCD yaygın olarak kullanılmaktadır. Düşük gürültü değerleri, yüksek duyarlılıkları ve geniş dinamik aralıkları (ölçülebilen en çok ve en az ışık şiddeti değerleri arasındaki oran) nedeniyle çok çeşitli gıda mühendisliği uygulamalarında CCD kameralar iyi birer seçenek olmuştur (Mendozaa et al., 2006; Igathinathane et al., 2009; Sun, 2007).



Şekil 2.1. Bir GAS'nin temel parçaları.

Bilgisayar bilimlerinde tarayıcılar resimleri, metinleri, el yazılarını ya da herhangi bir nesneyi optik olarak tarayarak dijital görüntüye çeviren aygıtlardır. En sık rastlanan türleri düz yatak tarayıcılarıdır. Düz yatak tarayıcılar cam bir panel, bu panel altında bir matris oluşturacak şekilde hareket eden bir optik kısım ve flüoresan lambadan oluşmaktadır. Optik kısım bir CCD kamera ve RGB formatında görüntü oluşturmak için kırmızı, yeşil ve mavi filtreler içermektedir. Prensip olarak flüoresan lambadan yayılan ışığın taranan nesneden yansımalarının CCD kamera tarafından kaydedilmesi şeklinde çalışmaktadırlar. Bir avantaj olarak, düz yataklı tarayıcılar harici bir aydınlatma kaynağına ihtiyaç duymazlar ve bu yönüyle CCD kameralara üstünlük sağlarlar.

2.2.1.3. Sayısallaştırıcı ve bilgisayar

Sayısallaştırıcılar dış ortamdan alınan analog sinyallerin dijital verilere çevrilmesini gerçekleştirmektedir. Kameralar fotonları sürekli elektrik sinyallerine çevirirken, sayısallaştırıcılar bu analog sinyalleri dijital bilgilere çevirmektedir (Sun, 2007). Günümüzde dijital kameralar, tarayıcılar vb. sayısallaştırıcıları da içermekte ve dijital bilgi üretebilmektedir. Dijital formdaki görüntüler bilgisayarda depolanmakta ve analiz edilmektedir.

2.2.2. Görüntünün analiz edilmesi

2.2.2.1. Ön işleme

Görüntünün işlenmesini kolaylaştırmak için, gürültülerin giderilmesi, karşıtlığın artırılması, işlem yükünün azaltılması için görüntünün yeniden boyutlandırılması gibi işlemler ön işlemler olarak adlandırılmaktadır.

2.2.2.2. Algılama ve segmentasyon

Görüntünün ileri aşamalarda kullanılacak nokta ya da veri setlerinin belirlenmesi için algılama/segmentasyon basamağı gelmektedir. Segmentasyon genel olarak görüntüleri piksellerin benzer karakteristik gösterdiği çeşitli bölgelere ayırmak olarak tanımlanır. Nesnelerin boyutlarının ölçülmesi ve sınıflandırılması gibi ileri aşamalarda yapılacak hesaplama işlemleri segmentasyon işlemine bağımlı olduğu için segmentasyon önemli bir işlemdir. Bu yüzden uygun segmentasyon tekniğini geliştirmek için üstün çabalar sarf edilmektedir. Birçok segmentasyon tekniği geliştirilmiş olsa da eşikleme temelli segmentasyon, bölge temelli segmentasyon,

gradyan temelli segmentasyon ve sınıflandırma temelli segmentasyon gıda endüstrisinde kullanılan en yaygın tekniklerdir (Sun, 2007).

Eşikleme temelli segmentasyon işleminde görüntü piksel değerlerinden çıkarılan histogram bir eşik değeri kullanılarak ikiye (iki düzeyli eşikleme), ya da görüntünün karakteristiğine bağlı olarak birden fazla eşik değeri kullanılarak ikiden fazla bölgeye (çok düzeyli eşikleme) ayrılmaktadır. Teorik olarak eşikleme düzeyi görüntüdeki nesne sayısına göre arttırılabilir ancak bu durum işlem yükünü arttıracığından eşikleme işlemini kullanışsız hale getirecektir. Pratikte en çok iki ya da üç düzeyli eşikleme kullanılmaktadır. İki düzeyli eşikleme işleminde eşik değerden küçük intensite değerine sahip pikseller arka plan olarak algılanırken eşik değerden büyük intensite değerine sahip pikseller nesne olarak kabul edilir (Sun, 2007).

2.2.2.3. İleri işlemler

Segmente edilen görüntü daha küçük bir veri seti anlamına gelmektedir. Algılanan nesne üzerine yoğunlaşarak ileri düzeyde işlemler yapılabilir. Nesnenin pozisyonunun belirlenmesi, boyutlarının ölçülmesi ve farklı kategorilere sınıflandırılması bu işlemlere örnek olarak verilebilir. Nesnelerin boyut ölçümleri vb. işlemler daha kolay prosedürlerle belirlenebilse de sınıflandırma işlemleri daha karmaşık prosedürler gerektirmektedir.

Genel olarak sınıflandırma, nesnelerin ölçülen özelliklerinin daha önce belirlenen değerlerle karşılaştırılması ve farklı gruplara ayrılmasını ifade etmektedir. Görüntü işleme teknikleri ile gıdaların görüntüleri boyut, şekil, renk vb. özellikleri ile nicel olarak karakterize edilebilir. Bu özellikler nesnel değerlendirme ve sınıflandırma işlemi için hazırlanan algoritmalarda eğitim veri setini oluşturmaktadırlar. Güçlü yazılımlarla desteklendiğinde GAS, sınıflandırma işleminde insanın düşünme işleminin yapay olarak simüle edildiği bir mekanizma sağlamakta ve karmaşık sonuçları kesin, çabuk ve tutarlı şekilde üretmektedir. Sınıflandırma işlemleri için kullanılagelen teknikler içinden yapay sinir ağları (YSA) ve istatistiksel yaklaşımlar yaygın kullanılan yöntemlerdir. Bulanık mantık ve karar ağacı da sınıflandırma amacıyla kullanılmaktadır. Tüm bu sınıflandırma yöntemlerinin ortak amacı insan karar verme davranışını simüle etmektir (Sun, 2007).

2.3. Yapay Sinir Ağları


Yapay sinir ağları, insan beyin fonksiyonları ile elde edilmiş verilerden faydalanarak olayları öğrenebilen ve tepki geliştirebilen bilgisayar programlarıdır. İnsan beynine ait mekanizmalara benzer yaklaşımlarla çalışan YSA fonksiyon kestirimleri, doğrusal olmayan sistem modelleme, optimizasyon, sınıflandırma, görüntü tanıma ve doğrusal olmayan sinyal işleme gibi konularda başarılı şekillerde uygulanmaktadır. YSA'nın doğrusal olmayan, çok boyutlu, gürültülü, karmaşık, kesin olmayan, eksik, kusurlu, hata olasılığı yüksek sensor verilerinin olması ve problemin çözümü için özellikle bir matematik modelin ve algoritmanın bulunmaması hallerinde yaygın olarak kullanıldıkları görülmektedir (Öztemel, 2003).

2.3.1. YSA hücresi

Beynimizde bulunan milyarlarca sinir hücresi bir araya gelerek belirli bir fonksiyonu yerine getirmek üzere bir sinir ağı oluşturmaktadır. Beynimizde 10^{10} adet sinir hücresi ve bunlar arasında 6×10^{13} 'ten fazla bağlantı olduğu düşünülmektedir. Biyolojik sinir ağları olaylar arasındaki ilişkileri beş duyu organında gelen bilgilerle geliştirdiği algılama mekanizmasını kullanarak öğrenmektedir. Sinir hücreleri *çekirdek*, *soma*, *akson*, *dendirt* ve *snaps* yapılarından oluşmaktadır. Sinir hücreleri arasında bilgi iletimi *akson* ve *dendirtler* arasında *snaps* bağlantısıyla gerçekleşmektedir. *Snapslar* fiziksel bağlantılar olmayıp elektriksel iletimle bilgi aktarırlar ve *neurotransmitter* olarak adlandırılan, sinir hücreleri arasında ya da başka bir hücre ile sinir hücresi arasındaki iletişimi sağlayan kimyasallar vasıtasıyla iletişimi gerçekleştirmektedir. Her ne kadar YSA biyolojik sinir ağlarından ilham alınarak geliştirilmiş olsa da, aslında YSA nörobiyolojik modellerden çok matematik ve istatistiksel modellerle benzerlik göstermektedir (Öztemel, 2003; Jha, 2011).

Yapay sinir ağları her biri ağın temel yapı taşı olan, birbirine bağlı proses elemanlarından oluşur. YSA hücresi olarak da tanımlanan proses elemanları beş bileşenden oluşmaktadır;

Girdiler (G); bir proses elemanına dışarıdan gelen bilgilerdir. Bu bilgiler ağın öğrenmesi istenilen örneklerden elde edilen bilgiler olabileceği gibi bir elemana başka bir proses elemanından da bilgi gelebilmektedir.



Şekil 2.2. Yapay sinir hücresinin temel yapısı: G; girdiler, A; ağırlıklar ve Ç; çıktılar

Ağırlıklar (A); proses elemanına gelen bilginin önemini belirten değerlerdir. Şekil 2.2’de gösterilen Ağırlık1, Girdi1’in proses elemanına olan etkisini göstermektedir.

Toplama fonksiyonu (Σ); ağırlıklandırılmış girdi değerlerini kullanarak hücreye giren net girdiyi hesaplar. Genel olarak toplama fonksiyonunun çalışması girdilerin ağırlıkları ile çarpılarak ağırlıklandırılmış girdilerin toplanması esasına dayanmaktadır. Formülle ifade edersek;


$$Net = \sum_{i=1}^n Ai \times Gi + b \quad (2.1)$$

Aktivasyon fonksiyonu (f); hücreye gelen net girdiyi işleyerek hücrenin bu girdiye karşılık oluşturacağı çıktıyı sonlu bir değerle sınırlayan fonksiyondur. Şekil 2.2’de görülen b sabiti, bias veya aktivasyon fonksiyonunun eşik değeri olarak adlandırılmaktadır ve aktivasyon fonksiyonunun net girdisini artırmak ya da azaltmak yönünde bir etkiye sahiptir. Toplama ve aktivasyon fonksiyonu olarak çeşitli fonksiyonlar kullanılabilir. Aktivasyon fonksiyonunu A ile ifade edersek;

$$A = f(\sum_{i=1}^n Ai \times Gi + b) \quad (2.2)$$

Çeşitli aktivasyon fonksiyonları içinden uygun olanı kullanıcı tarafından belirlenmelidir. Bunlar, eşik değer fonksiyonu, lineer fonksiyon ve sigmoid fonksiyonlarıdır.

Şekil 2.3’ten görüleceği gibi eşik değer fonksiyonu hücrenin çıktı değeri 0’dan küçükse sıfır, 0 ile 1 arasında ise net çıktı değerini, 1’den büyükse 1 çıktı değerini vermektedir. Sürekli çıkışlar gerektiği zaman çıkış katmanındaki aktivasyon fonksiyonu lineer olarak seçilmektedir.



Şekil 2.3. Çeşitli Aktivasyon Fonksiyonlarının grafiklerle ifadesi, a) eşik değeri, b) lineer ve c) sigmoid fonksiyonları.

Doğrusal olmadığı için türevlenmesi mümkün olan sigmoid transfer fonksiyonu geri yayınlımlı ağlar için uygun hale gelmektedir ve çok katmanlı ağ mimarilerinde sıklıkla kullanılmaktadır. Sigmoid transfer fonksiyonu Eşitlik 2.3 ile ifade edilmektedir;

$$f(Net) = \frac{1}{1+e^{-\sum A_i x G_i}} \quad (2.3)$$

Türevlenebilir hiperbolik tanjant sigmoid fonksiyonu ise -1 ile 1 arasında çıktı değerleri üretmektedir ve Eşitlik 2.4 ile gösterilebilir;

$$f(Net) = \frac{e^{Net} - e^{-Net}}{e^{Net} + e^{-Net}} \quad (2.4)$$

Bunlardan başka sadece 0 ve 1 olarak çıktı veren basamak ve sinüs fonksiyonları da kullanılmaktadır. Kullanıcı üretmek istediği çıktılara göre bunlardan birini seçmektedir.

Hücrenin çıktısı (Ç); aktivasyon fonksiyonu tarafından belirlenir. Bir hücrenin birden çok girdisi olabilmesine rağmen tek bir çıktı değeri olabilmektedir (Haykin, 1999; Öztemel, 2003).

2.3.2. YSA tasarımı

YSA kullanım amacına göre çeşitli şekillerde oluşturulmaktadır. Ağ tasarımının doğru yapılması ağın doğru ve tutarlı çıktılar üretebilmesi için önemlidir. Eğitim sürecinde ağ performansının yetersiz olması nedeniyle yeniden ağ tasarımı gerekebilmektedir. Doğruluğu ve tutarlılığı en yüksek sonuçları üreten ağı belirleyebilmek teorik olarak maksimum sayıda ağ mimarisini denemeyi gerektirmekte ancak bu işlem çok fazla zaman ve işgücü gerektirmektedir. Ağ tasarlanması aşağıdaki adımları içermektedir;

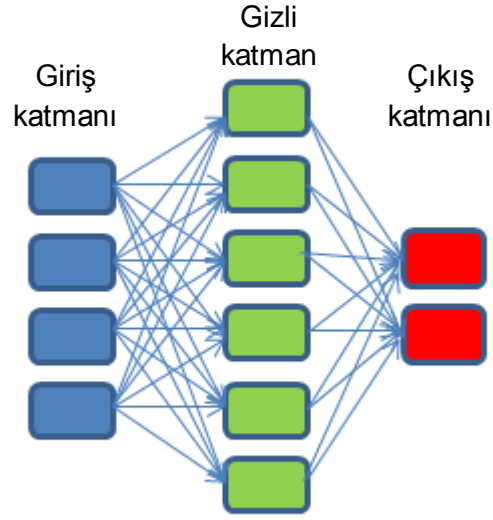
- ✓ Katman sayısı ve katmanlardaki nöron sayılarının belirlenmesi
- ✓ Proses elemanlarının aktivasyon fonksiyonları vb. seçilmesi
- ✓ Öğrenme algoritmasının ve eğitim parametrelerinin seçimi
- ✓ Eğitim ve test veri setlerinin oluşturulması (Kılıç, 2007).

2.3.3. Ağ modeli

Proses elemanlarının birbirine bağlanması sonucu oluşan ağ yapısı, proses elemanlarına ait aktivasyon ve toplama fonksiyonları, öğrenme kuralı ve öğretim stratejisi ağ modelini belirlemektedir. Çeşitli ağ modelleri arasından hatanın geriye yayıldığı *çok katmanlı algılayıcılar* sıklıkla kullanılmaktadır. Çok katmanlı, geriye yayınlı algılayıcılarda iki ayrı aşamada hesaplama yapılır. Bunlardan ileri doğru hesaplama aşamasında çıktılar hesaplanırken geriye doğru hesaplama aşamasında ise ağırlıklar değiştirilmektedir (Kılıç, 2007; Öztemel, 2003).

2.3.4. Ağ Mimarisi

Yapay sinir ağları proses elemanlarının bir araya gelerek oluşturduğu üç katmandan oluşmaktadır. Bunlar dış dünyadan gelen bilgilerin alındığı *giriş katmanı*, bilgilerin işlendiği *gizli katmanlar* ve çıktıları üreten *çıkış katmanıdır*. Şekil 2.4'te de görüldüğü gibi her katmandaki paralel proses elemanları birbiriyle ve diğer katmanlarla bağlantılıdır ve proses elemanlarına ait ağırlık değerleri öğrenme sırasında hesaplanmaktadır (Jha, 2011; Öztemel, 2003).



Şekil 2.4. YSA mimarisi

2.3.5. Ağın eğitilmesi

YSA eğitim süreci belirli girdi ve çıktı değerlerinden faydalanarak ağırlıkların hesaplanması işlemidir. Rastgele atanan ağırlık değerleri ile başlayan süreç her bir örneğe ait çıktı değerleri eğitim için kullanılan çıktı değerleriyle karşılaştırılarak en doğru sonucu bulana kadar iteratif olarak devam etmektedir. Eğitim sırasında üç gruba ayrılan verilerin bir kısmı eğitim, bir kısmı da geçерleme (validasyon) amacıyla kullanılmaktadır. Hesaplanan ağırlık değerleri geçерleme verileri ile karşılaştırılarak doğruluğu sınanmakta ve ağırlık hesaplanması bu yönde yönlendirilmektedir. Bu işlemden sonra test için ayrılan veri seti kullanılarak elde edilen çıktılar test için verilen çıktı değerleri ile karşılaştırılmaktadır. Test sonuçları sadece ağın performansını göstermektedir ve performansın düşük olması durumunda geçерleme işleminde olduğu gibi eğitim işlemine devam edilmemektedir. Ağın eğitimi sırasında, ağ performansını belirlemede çeşitli istatistiksel değerler kullanılabilir. Bunlardan, çalışma kapsamında kullanılan Hata kareler ortalaması (HKO), Eşitlik 2.5'teki gibi hesaplanmaktadır (Kılıç, 2007; Öztemel, 2003).

$$HKO = \frac{1}{n} \sum (x_{i,gerçek} - x_{i,tahmin edilen})^2 \quad (2.5)$$

2.4. GAS'nin Gıda Alanında Kullanımı

Gıda endüstrisi açısından bakılacak olursa; GAS numunelerin, otomatik, çabuk, nesnel, düşük maliyetli olarak ve zarar verilmeden analiz edilebilmesini sağlarken deneyimli bir personele gerek duymamaktadır. Sayısal görüntünün alınıp kaydedilmesinden sonra örnek detaylıca incelenebilmekte ve analiz sonuçları gibi görüntü de kayıt altına alınabilmektedir. Bu avantaj analiz edilen kitleden numune saklama gerekliliğini ortadan kaldırdığı gibi alınan görüntülerin kalıcı olması defalarca ya da farklı şekillerde, farklı zamanlarda analiz edilebilmelerine de imkân sağlamaktadır (Kılıç et al., 2007a; Brosnan and Sun, 2002).

GAS'nin hammaddeden paketlenmiş son ürüne kadar geniş bir uygulama alanı vardır. Bunlardan bazıları hammaddelerin değerlendirilmesi, boylanması ve sınıflandırılması (meyve, sebze ve hububatlar), çeşitli gıda işlemlerinin proses kontrolü (fırınlama, kavurma), işlenmiş gıdaların proses kontrolü ve paketlenmiş son ürünlerin zarar verilmeden analiz edilmesi olarak verilebilir (Çakmak and Boyacı, 2011).

Gıda maddelerinin kalitesinin değerlendirilmesi ve fiyatlandırılmasında görsel özellikler önem arz etmektedir. Bu durum GAS'ni gıda maddelerinin görsel kalitesinin değerlendirilmesinde kullanışlı kılmaktadır. Gıda maddelerinin görsel kalitelerinin değerlendirilmesi ve sınıflandırılması alanında yapılan GAS uygulamaları; tarımsal gıdaların renk değerlerinin ölçülmesi (Mendozaa et al., 2006; León et al., 2006), fasulyelerin kalitelerine göre sınıflandırılması (Kılıç et al., 2007a), arpa örneklerinin varyetelerine göre sınıflandırılması (Zapotocznya et al., 2008), buğday tanelerinin fiziksel özelliklerinin belirlenmesi (Demirbaş ve Dursun, 2007), meyve örneklerinde kusurların görüntü analizi ile belirlenmesi (Blasco et al., 2007; Xing et al., 2007), tarım ürünlerinin hacim ve yüzey alanlarının belirlenmesi (Rashidi et al., 2007; Koç, 2007; Wang and Nguang, 2007), tahıl tanelerinin boyutlarının ölçülmesi (Igathinathane et al., 2009), patates cipsinde renk ölçümü (Pedreschi et al., 2006), buğday örneklerinin sınıflandırılması (Utku and Köksel, 1998; Manickavasagana et al., 2008; Sapirstein et al., 1987), elma yüzeyindeki kusurların tespit edilmesi (Leemans et al., 1999), kirazların şekil analizi (Beyera et al., 2002) ve pizza içeriğinin değerlendirilmesi (Sun and Brosnan, 2003), yabani ot tohumlarının belirlenmesi (Granitto et al., 2002), olarak sıralanabilmektedir.

Özellikle bakliyatlar üzerine yapılan çalışmalara örnek verilmek istendiğinde ise; farklı türlerdeki bakliyat örneklerinin boyutsal özelliklerinin belirlenmesi (Durmuş et al., 2008), yerel mercimek türlerinin tanımlanması (Venoraa et al., 2007), küflenmiş soya fasulyelerinin ayrılması (Wigger et al., 1988), ot-baklagil karışımında baklagil miktarının belirlenmesi (Himstedt et al., 2009), zor pişen fasulye tanelerinin ayırt edilmesi (Laurent et al., 2010), mercimek türlerinin şekilsel ve geometrik özelliklerinin karakterize edilmesi (Durmuş et al., 2008) gibi çalışmalar sıralanabilmektedir.

Çalışmaların geneline bakıldığında iki konu üzerinde odaklanıldığı görülmektedir. Bunlardan birisi boyut ve şekil özellikleri üzerinden sınıflandırma yapmak diğeri ise renk bakımından değerlendirme yapmak ve kusur belirlemektir.

Boyutlarına göre sınıflandırma işleminin GAS ile yapılması çalışmaları, zaman ve emek gerektiren elek analizlerine alternatif oluşturmak üzere hububatlar üzerinde yoğunlaşmaktadır. Ne var ki fiyatlandırma ve kalite değerlendirmesi konusunda boyut analizine gerek duyulan bakliyatlar üzerine hububatlar kadar fazla çalışmaya rastlanılamamaktadır.

Bunlardan başka literatürde rastlanan çalışmalarda görsel kusur olarak çoğunlukla kötü renkli kısımlar ele alınmaktadır. Ancak bakliyatların kalite değerlendirmesinde kırık ve buruşuk tanelerinde kusurlu kabul edilmesi, GAS ile görsel kalite belirleme çalışmalarının büyük bir açığıdır.

Bir diğeri konu ise literatürdeki çalışmaların boyut ya da görsel kalite değerlendirmesine iyi bir arka plan oluştursa da, görsel ve boyutsal değerlendirmeleri bir arada yaparak bir numunenin kalitesi hakkında son sözü söyleyebilecek toplanmış bir sistemin eksikliğidir.

2.5. Nohut Ve Fasulye İçin Görsel Kalite Kriterleri

Nohut (*Cicer arietinum*), baklagiller (*Fabaceae*) familyasının *Faboideae* alt familyasına ait *Cicer* cinsinden bir baklagil türüdür. Çeşitli renklerde olabildiği gibi genellikle krem, açık sarı renge sahip tohumlara sahiptir. Nohut fiyatlandırması dane boyutu ve kusurlu tane oranı üzerinden yapılmaktadır. Tanımlanmış üç görsel kusur, danelerin buruşuk, kırık ve renk kusurlu olmasıdır. Kırık taneler nohut tanelerinin iki veya daha fazla parçaya bölünmesi ile oluşan ve 5 mm göz

açıklığına sahip elek üstünde kalan taneler olarak tanımlanırken, renk kusurlu taneler iyi gelişmemiş, sert yapılı, koyu renkli piç tanelerle küflenmiş, çürümüş, lekelenmiş, böcek veya diğer zararlılar tarafından çıplak gözle görülebilecek kadar yenmiş veya delinmiş taneler olarak tanımlanmaktadır.

Boyutlarına göre ise 9 milimetre göz açıklığına sahip eleğin üstünde kalan daneler *çok iri*, 9 mm'lik elekten geçen ancak 8 mm'lik eleğin üstünde kalanlar *iri*, 8 mm'lik elekten geçip 5 mm'lik elek üstünde kalanlar *orta* ve 5 mm'lik elekten geçen taneler *elek altı* olarak nitelendirilir. Bu boyutsal sınıflandırmalardan sonra nohut, kalitesine göre ise Çizelge 2.1'de gösterildiği gibi iki sınıfa ayrılmaktadır (Anonim, 2008a).

Fasulye (*Phaseolus vulgaris*), baklagiller (*Fabaceae*) familyasının *Phaseolus* cinsinden Orta Amerika menşeli, bir yılda yetişen otsu bir bitki türüdür. Nohut için belirtilen görsel kusurlar ve Çizelge 2.1'de (Anonim, 2008b'den değiştirilerek) belirtilen kalite sınıflandırması fasulye için de geçerli olmakla birlikte fasulye boyutlandırması farklıdır. Göz açıklığı 8 mm olan elek üstünde kalan taneler *büyük*, göz açıklığı 8 mm olan elekten geçen ancak 6 mm'lik elek üstünde kalan taneler *orta*, göz açıklığı 6 mm olan elekten geçen ancak 5 mm olan elek üstünde kalan taneler *küçük* ve 5 mm'lik elekten geçen taneler *elek altı* olarak nitelenmektedir (Anonim, 2008b).

Bu bilgiler ışığında çalışma kapsamında nohut ve fasulyelerin çap (en) ve boylarının ölçülmesine yönelik çalışmalarla birlikte hububat ve bakliyatların değerlendirilmesinde kullanılan hektolitre ağırlığı hesaplanması ya da konservecilikte kullanılacak hacim bilgisinin hesaplanması çalışması da gerçekleştirilmiştir.

Boyutsal ölçümlerden sonra örneklerin renklerine göre iyi, *kabul edilebilir* ve *renk kusurlu* olarak üç gruba, yüzey morfolojisine göre *buruşuk* ve *pürüzsüz* olarak iki gruba ve dane bütünlüğüne göre *kırık* ve *bütün* olarak iki gruba ayrılarak tasnif edilmesi gerçekleştirilmiştir.

Çizelge 2.1. Nohut ve fasulye tanelerinin kusurlu tane oranlarına göre kalite sınıflandırması.

Özellikler	Sınıflar	
	Sınıf I	Sınıf II
	kütlece, %, en çok	kütlece, %, en çok
Kalbur altı miktarı	1	3
Bozuk tane miktarı	1	3
Kırık tane miktarı	1	3

III. DENEYSEL ÇALIŞMALAR

3.1. Materyal

Farklı boyutlardaki taneler, kusurlu taneler ve elek altı taneleri de içermesi için elekten ya da herhangi bir işlemde geçirilmemiş, tarladan geldiği şekliyle bekleyen nohut ve fasulyelerden örnekler alınmıştır. Çalışma kapsamında örneklerin boyut ve görsel kalitesine göre değerlendirmesi yapılacağı için örnek seçiminde fasulye ve nohut örneklerinin farklı fiziksel özelliklerde olmasına dikkat edilmiştir. Çalışmada kullanılan 2008 yılı hasadına ait nohut ve fasulye örnekleri İhracatçı Birlikleri Tohumculuk ve Araştırma Sanayi Ticaret A.Ş.'den temin edilmiştir.

3.2. Metot

Çalışma kapsamında bakliyat örneklerinden görüntü almayı kolaylaştıracak bir donanım ve numunelerin boyutsal olarak sınıflandırılmasının yanında, renk kusurları, kırık tane ve buruşukluk gibi görsel kusurları da belirleyebilecek bir yazılım tasarlanmıştır. Bu bölümde tez kapsamında gerçekleştirilen aşamalar detaylı olarak sunulmuştur.

3.2.1. Görüntünün elde edilmesi

Tarayıcıların harici bir aydınlatma gerektirmeme avantajı göz önünde bulundurularak görüntü yakalamada Canon-Canoscan 4400F (Çin) düz yatak tarayıcı kullanılmıştır. Örneklerin üzerine yerleştirileceği kısım çekmece formunda tasarlanmıştır. Örnek çekmecesi alüminyum plaka üzerine örneklerin ayrı ayrı yerleşmelerini sağlamak üzere 12 mm çapında 5 mm derinliğinde 216 (18x16) adet kuyucuk açılarak üretilmiştir. Fasulye örnekleri için tasarlanan örnek çekmecesinde ise ölçüleri 14 mm ve 20 mm olan ve derinlikleri yine 5 mm olan 136 (17x8) adet kuyucuk açılmıştır. Segmentasyon işlemini kolaylaştırmak için renk karışıklığını artırmak ve gölgelerin elimine edilmesini sağlamak üzere çekmeceler mat siyah renge boyanmıştır. Dış ortamdan gelecek ışık girişimini engellemek üzere tarayıcı ve örnek çekmecesi kapalı, karanlık bir kutu içine yerleştirilmiştir.

3.2.2. Görüntünün işlenmesi

Görüntünün işlenmesinde MatLab *R2007b Version 7.5 (The MathWorks, Inc.*

Massachusetts, A.B.D.) programında oluşturulan kodlardan faydalanılmıştır. İlk olarak JPEG formatındaki dijital görüntünün MatLab formatına aktarılmıştır. Bu işlem MatLab *imread* komutuyla gerçekleştirilmiştir. Sonrasında görüntü MatLab ortamında üç boyutlu bir matris şeklinde bulunmaktadır. Bu matrisin en ve boy değerleri piksel adreslerini, derinliği ise R,G ve B formatları için üç katmanı içermektedir. Böylece her pikselin RGB intensite değerlerinden oluşan bir veri seti elde edilmiştir.

3.2.3. Segmentasyon

Segmentasyon işlemi için eşikleme yöntemi kullanılmıştır. Eşik değerinin hesaplanmasında *grayscale* formatındaki görüntüden faydalanılmıştır. Bu formatta her bir piksele ait RGB değerlerinin ortalaması alınarak iki boyutlu bir matris oluşturulmaktadır. MatLab *graythresh* komutuyla eşik değeri hesaplanmıştır. Hesaplanan eşik değerinden faydalanılarak görüntü MatLab *im2bw* fonksiyonu ile eşik değerinden büyük değerlerin 1, küçük değerlerin ise 0 ile ifade edildiği ikili bir hale çevrilmiştir. Bu görüntüde arka plan siyah, örnekler ise beyaz olarak görülmektedir. Daha sonra MatLab *bwareaopen* fonksiyonu ile belirli bir piksel değerinin altında kalan piksel alanları elimine edilerek arka plan üzerinde kalan kirlilikler ve MatLab *imfill* fonksiyonu ile de örnekler üzerinde kalan siyah kısımlar doldurularak görüntüler giderilerek ikili görüntü elde edilmiştir (MatLab Toolboxes Help Desk, 2005).

İkili görüntü elde edildikten sonra her bir örneği bireysel olarak değerlendirebilmek için örneklerin numaralandırılması MatLab *bwlabel* fonksiyonuyla gerçekleştirilmiştir. Bu aşamadan sonra her bir örnek bireysel olarak değerlendirilebilmektedir. Öncelikle MatLab *regionprops* fonksiyonuyla her bir örneğe ait piksel koordinatları, ağırlık merkezi ve piksel alanı değerleri bir matriste toplanmış ve ölçüm işlemine geçilmiştir.


3.2.4. Nicel değerlendirmeler

3.2.4.1. En ve boy ölçümleri

Boyutlandırma için yapılan elek analizlerini simüle edebilmek için tanelerin çaplarını ölçmek gerekmektedir. Bu işlem basitçe piksel sayımı şeklinde yapılabilir. Örnek görüntüsü ikil bir şekle çevrildikten sonra her satırdaki ve her sütundaki beyaz piksel toplamları hesaplanmıştır. Satır toplamları içinden en

büyük olan değer boy, sütun toplamaları içinden ise en büyük olan değer çap değerini vermektedir. Ancak bu yaklaşımın doğru sonuç verebilmesi için örneğin boyu doğrultusunda uzandığını Kabul ettiğimiz eksenin yatay pozisyonda olması gerekmektedir. Bu ayarlamayı yapmak için daha önce MatLab *regionprops* fonksiyonu ile oluşturulan, örneklere ait özellikleri içeren matristen *orientation* değeri alınır. Bu değer hesaplanırken örneğe en uygun elips uydurularak elipsin asal ekseninin yatayla yaptığı açı (α) hesaplanır (Şekil 3.1).

Bir sonraki aşama görüntünün α açısı kadar döndürülerek yatay bir pozisyona getirilmesidir. Bu işlem için MatLab *imrotate* komutu kullanılır. Çevrilen görüntüden piksel sayımıyla çap ve uzunluk değerleri elde edilir. (Matlab Toolboxes Help Desk, 2005). Görüntüdeki örneklere ait çap ve boy değerleri bir matriste toplanmıştır.




Şekil 3.1. Örnek görüntüsünün ölçümler için doğru konumlandırılması, a) Yanlış konumdaki örnek, b) Döndürülmüş örnek

3.2.4.2. Hacim ölçümleri

Hacim ölçümleri örneğe ait iki boyutlu görüntüden hacim değerini hesaplamayı içermektedir. Bu hesaplama için disk yönteminden faydalanılmıştır. Örneğe ait ikili bir görüntünün dikdörtgen elemanlardan oluştuğu düşünülürse, örneğin de her bir dikdörtgenin bir eksen etrafında döndürülmesiyle oluşan silindirik elemanlardan oluştuğu söylenebilmektedir (Şekil 3.2). Böylece her bir silindirin taban çapı Δy ve yüksekliği Δx olarak alınarak her silindirin hacmi Eşitlik (3.1) de gösterildiği gibi hesaplanmaktadır (Rashidi et al., 2007).

$$V_i = A_i \times \Delta x_i \quad (3.1)$$



Şekil 3.2. Disk yöntemiyle iki boyutlu bir görüntüden üç boyutlu cismin oluşturulması, a) Dikdörtgenlerden oluşan iki boyutlu ve b) silindirlere oluşan üç boyutlu görüntüler.

Eşitlikte ifade edildiği gibi her bir silindirin hacmi yüksekliği ve taban alanının çarpımına eşittir. Silindirin taban alanı ise Eşitlik (3.2) ifade edildiği gibi olduğuna göre;

$$A_i = \pi \times \left(\frac{\Delta y_i}{2}\right)^2 \quad (3.2)$$


silindirik elementlerin hacimleri Eşitlik (3.3) ile hesaplanmaktadır (Rashidi et al., 2007).

$$V_i = \pi \times \left(\frac{\Delta y_i}{2}\right)^2 \times \Delta x_i \quad (3.3)$$

Tüm cismin hacmi ise Eşitlik (3.4) ile ifade edilir.

$$V = \sum_{i=1}^n V_i \quad (3.4)$$

Tanenin pozisyonu hacim hesaplamalarında da önem taşımaktadır. Hacimlerin doğru hesaplanabilmesi için örneğe uydurulan elipsin asal ekseninin yatay ile paralel olması gerekmektedir. Şekil 3.3'de görüldüğü gibi örneğin iki boyutlu görüntüsünün farklı pozisyonlarda bulunması yanlış hacim ölçümlerine yol açmaktadır.




Şekil 3.3. Hacim ölçümleri için tanenin pozisyonunun etkisi, a) Yanlış ve b) doğru pozisyondaki taneleri temsil eden silindirler.

En-boy ölçümleri sırasında kullanılan döndürülmüş ikili görüntülerden faydalanarak yapılan hacim ölçümleri ile bu sorun çözülmektedir. İkinci bir ölçüm hatası ise ikili görüntünün pikseller yani kare elemanlarla ifade edilmesinden kaynaklanmaktadır. Dairesel bir görüntünün dikdörtgen elemanlarla temsil edilmesi Şekil 3.4a'da gösterilen kayıp alanlara neden olmaktadır. Bu sorun dikdörtgenlere ait Δx değerinin sonsuz küçüklükte olması ile aşılabilir. Ancak pratikte dijital bir görüntüde ifade edilebilecek en küçük uzunluk 1 piksel değerinde olabilmektedir. Büyük bir görüntüde bu hata önemsenmeyebilirse de nohut gibi küçük örneklerde anlamlı hatalara yol açabilmektedir. Bu sıkıntıyı gidermek için örnek görüntüsünün dikdörtgen yerine Şekil 3.4b'de görüldüğü gibi yamuk elementlerden oluştuğu varsayılmaktadır. Bir yamuğun bir eksen etrafında çevrilmesi ile oluşacak cisim bir kesik koni olacaktır.

Bu kesik konik elemanların hacimlerinin hesaplanarak toplanması ile örnek hacmi daha doğru olarak elde edilecektir. Kesik koni hacminin hesaplanmasında Şekil 3.4'te gösterilen ardışık dikdörtgenlere ait Δy değerleri kullanılır. Kesik koni hacminin hesaplanması için Eşitlik 3.5 den faydalanılır (<http://jwilson.coe.uga.edu/emt725/Frustum/Frustum.cone.html>).

$$V_i = \frac{\pi \times \Delta x_i}{3} (\Delta y_i^2 + \Delta y_{i+1}^2 + \Delta y_i \times \Delta y_{i+1}) \quad (3.5)$$

Hacim ölçümlerinin gerçek değerlerle karşılaştırılabilmesi için nohutların gerçek hacimleri su taşıma metodu ile ölçülerek GAS sonuçları ile karşılaştırılmıştır. Tamamen suyla doldurulan bir erlene nohut örneklerinin eklenmesi ile taşan suyun hacmi hassas ölçüm yapabilmek amacı ile 50 ml'lik bir büret ile ölçülmüştür.



Şekil 3.4. Görüntünün dikdörtgen elementlerden oluşmasının disk yönteminde neden olduğu hesap hataları, a) dikdörtgen elementlerden oluşan bir görüntü ve b) yamuk elementlerden oluşan bir görüntü.

Fasulye örneklerinin hacimleri sahip oldukları şekil nedeniyle hesaplanamamış, yalnızca nohut örneklerinin hacimleri küresel-elipsoidal şekilleri yardımıyla hesaplanmıştır.

3.2.5. Nitel değerlendirmeler

Segmente edilip ikili hale dönüştürülmüş ve örneklerin numaralandırıldığı görüntüden faydalanılarak JPEG formatındaki görüntüde örnekleri içeren piksel adresleri elde edilmektedir. n sayıda örnek içeren bir görüntüde, MatLab *find* fonksiyonu ile 1'den n 'e kadar örneklerin piksel adreslerini içeren n sayıda matris oluşturulup daha sonra her örneğe ait matristen adres bilgisi alınarak bu adresteki piksellerin R, G ve B değerleri orijinal görüntüden okunarak "3 × örneğe ait piksel sayısı" boyutlarında n tane matris oluşturulmaktadır.

3.2.5.1. Renk kusurlu taneleri belirleme

Elde edilen renk değerlerinden faydalanılarak örneklerin renk kalitesine karar vermek için istatistiksel bir yöntem olan *moment analiz*'nden faydalanılır. Moment analizi örnek piksellerine ait renk intensitesi dağılımlarından faydalanarak örneğin renk karakteristiğini belirlemek esasına dayanmaktadır (Mattson and Pandit, 2006).

Birinci moment değeri olan, dağılımın merkez noktası intensite değerlerinin ortalaması yoluyla Eşitlik 3.6'daki gibi hesaplanmaktadır.

$$\bar{X} = \frac{1}{N} \sum_{i=1}^N X_i \quad (3.6)$$

N=piksel sayısı, X=intensite değeri

İkinci merkezi moment değeri olan varyans veri setindeki intensite değerlerinin dağılımının homojenliği hakkında bilgi verir (Eşitlik 3.7). Varyans yerine varyansın karekökü olan *standart sapma* da kullanılabilir (Eşitlik 3.8). Homojen bir dağılımın standart sapmasının 0 olması beklenmektedir.

$$\bar{V} = \frac{1}{N-1} \sum_{i=1}^N (X_i - \bar{X})^2 \quad (3.7)$$

$$\sigma = \sqrt{\bar{V}} \quad (3.8)$$

Üçüncü merkezi moment değeri olan çarpıklık veri setindeki intensite dağılımının merkezine göre simetrisinin daha doğrusu simetrik olmamanın bir ölçütüdür ve Eşitlik 3.9'deki gibi hesaplanmaktadır.

$$\hat{S} = \frac{N \sum_{i=1}^N (X - \bar{X})^3}{(N-1)(N-2)\sigma^3} \quad (3.9)$$

Normal dağılım gibi simetrik bir dağılımda çarpıklık değerinin 0 olması beklenmektedir. Pozitif çarpıklık durumunda sağdaki kuyruk daha uzun olmakta, dağılımın kütlesi grafiğin sol tarafında yoğunlaşmaktadır. Negatif çarpıklık durumunda ise soldaki kuyruk daha uzun olmakta ve dağılımın kütlesi grafiğin sağ tarafında yoğunlaşmaktadır.

Dördüncü merkezi moment değeri olan basıklık dağılımının ince ve sivri mi yoksa kalın ve basık mı olduğunun ölçüsüdür (Eşitlik 3.10).

$$\hat{k} = \frac{N(N+1) \sum (X-\mu)^4 - \frac{3(N-1)}{N} \sigma^4}{(N-1)(N-2)(N-3)\sigma^4} \quad (3.10)$$

Basıklık değeri yüksek olan bir dağılım ortalama yakınında keskin bir pike sahipken düşük basıklık değerine sahip bir dağılımda ortalama yakınında daha yayvan bir tepe noktasına sahiptir (MatLab Toolboxes Help Desk, 2005).

Bir örneğin, her bir renk katmanına ait dörder moment değeri olmak üzere on iki veriden faydalanılarak *iyi*, *kabul edilebilir* ya da *renk kusurlu* gibi sonuçlar elde etmek amacıyla yapay sinir ağlarından faydalanılmıştır.

Bu ağın oluşturulmasında MatLab *nntool* aracından faydalanılmıştır. Tasarlanan ağdan beklenen görev on iki giriş verisinden bir çıkış verisi üretmesidir. Bu da YSA'nın giriş katmanında on iki, çıkış katmanında ise bir nöron bulunmasını gerektirmektedir. MatLab *nntool* aracında ağ yaratılması sırasında 11 farklı eğitim algoritması ve her katman için 3 farklı aktivasyon fonksiyonu seçmek, ayrıca istenildiği kadar gizli katman yaratmak ve bu katmanların nöron sayılarını belirlemek mümkündür.

Bu durumda tek gizli katmanlı bir sinir ağı tasarlandığında sadece eğitim algoritması ve aktivasyon fonksiyonu değiştirilerek 11 farklı eğitim algoritması, gizli katman için 3 farklı aktivasyon fonksiyonu ve çıkış katmanı için 3 farklı aktivasyon fonksiyonu kullanılarak 99 farklı ağ yaratılabilmektedir. Bu nedenle performansı en yüksek ağ mimarisini oluşturmak için birçok ağ oluşturularak performanslarını değerlendirmek zorunluluğu doğmaktadır. Bu işi gerçekleştirmek çok büyük zaman ve işgücü gerektirmektedir. Bu işi yine bilgisayar aracılığıyla gerçekleştirmek mümkündür. Belirtilen ağları tasarlayıp sınavacak MatLab kodları literatürde mevcuttur (Kılıç, 2007). Bu algoritma ile eğitim sürecinde kullanılacak verileri içeren matrislerdeki bilgilerden faydalanarak giriş katmanı ve çıkış katmanı nöron sayılarını belirlenmiş ve eğitim algoritması ve transfer fonksiyonları farklı 99 adet ağ oluşturularak performansları değerlendirilmiş, HKO değerleri bir matriste toplanmıştır. HKO değeri en düşük olan ağlara ait eğitim algoritması ve transfer fonksiyonları seçilerek oluşturulan ağ kalite değerlendirilmesinde kullanılmıştır.

3.2.5.2. Buruşuk tane belirleme

Buruşuk tanelerin belirlenmesinde, buruşukluklardan dolayı örnek görüntüsünde oluşan karanlık bölgelerden faydalanılmıştır. Buruşuk bir örnekten tarayıcı ile görüntü alındığında örnek yüzeyindeki girintiler koyu renkli-gölgeli, çıkıntılar ise açık renkli-aydınlık görünmektedir. Bu farklılık dijital görüntüden alınarak sayısal olarak anlamlandırıldığında buruşuk ve pürüzsüz taneleri ayırt etmek mümkün olmaktadır. Öncelikle örnek görüntüsü MatLab *rangefilt* komutuyla istatistiksel bir filtreden geçirilmektedir. Elde edilen sonuç yüzey dokusunun karakterize edilmesinde yardımcı olmaktadır. Bu şekilde piksellerin intensite değerlerinin lokal değişimleri hakkında bilgi elde edinilebilmektedir. Örneğin pürüzsüz bir yüzeye ait görüntüde herhangi bir piksele ait intensite değerleri ile bu pikselin komşuluğunda bulunan piksellerin intensiteleri arasındaki fark az olacağı için değişim de az olacaktır. Aynı şekilde komşu piksellerin intensite değerlerinin standart sapmaları da benzer bilgiyi sağlamaktadır. Filtreleme işlemi sonunda buruşuk yüzeylerden küçüklü büyüklü bir sayı dağılımı elde edilirken, pürüzsüz yüzeyden ise daha homojen değerler elde edilmektedir.

Bir örnek koyu renkli de olsa pürüzsüz olabilmekte ya da açık renkli ama buruşuk olabilmektedir. İstatistiksel filtreleme renk farkını ortadan kaldırarak sadece pikseller arasındaki intensite değişimlerini ele almaktadır. Bu yüzden buruşukluk değerlendirilmesinde renk tayininde olduğu gibi asıl görüntüyü değerlendirmek yerine filtreden geçirilmiş görüntü kullanılmaktadır. Yüzey morfolojisi ile ilgili bilgi veren ortalama, standart sapma, çarpıklık ve basıklık değerleri R,G ve B katmanları için elde edilerek her örneğe ait 12 adet veri üretilmiştir.

3.2.5.3. Kırık tane belirleme

Kırık tanelerin belirlenmesi konusunda uygulanan prosedür renk kusurlu ve buruşuk tanelerin belirlenmesinden farklı olarak renk ve renk dağılımından değil tanenin şeklinden faydalanılarak uygulanmaktadır. Kırık tane belirleme prosedüründe örüntü tanıma için kullanılan yaklaşımlardan biri olan *Otoregresif Model*den faydalanılmaktadır.

Bu modelin esası, cismin iki boyutlu görüntüsünde çevre ve merkezi temsil eden noktaların kullanımına dayanmaktadır. Algoritmanın ilk aşamasında görüntüdeki örneğin ağırlık merkezi hesaplanmaktadır. Daha sonraki aşamada nesnenin

çevresini oluşturan her bir noktanın merkeze göre öklid uzaklığı hesaplanmaktadır (Türkoğlu, 2003; Maoa and Jain, 1992).

Örneklerin çevrelerini temsil eden pikselleri belirlemek için MatLab *imclearborder* ve *bwperim* fonksiyonlarını içeren bir algoritma geliştirilmiştir. Bu fonksiyonlarla görüntü ve arka plana sınır teşkil eden pikseller belirlenerek sınır piksellerinin beyaz 1 ve geri kalan tüm piksellerin siyah 0 olarak kodlandığı bir ikili görüntü elde edilmektedir. Daha önce MatLab *regprops* fonksiyonu ile belirlenen merkez noktasının sınır piksellerinden her birine olan öklid uzaklıkları hesaplanarak her örneğe ait bir veri seti elde edilmektedir (Şekil 3.5). Bu verilerin dağılımı örneklerin şekillerini tanımlayabilecek karakteristik bilgiler verebilmektedir. Örneğin bir çember için elde edilen veri setindeki tüm veriler eşit olacaktır. Farklı geometrik şekiller için de yine karakteristik dağılımlar söz konusu olacaktır. Bu işlemler için Eşitlik (3.11)'den faydalanılmaktadır;

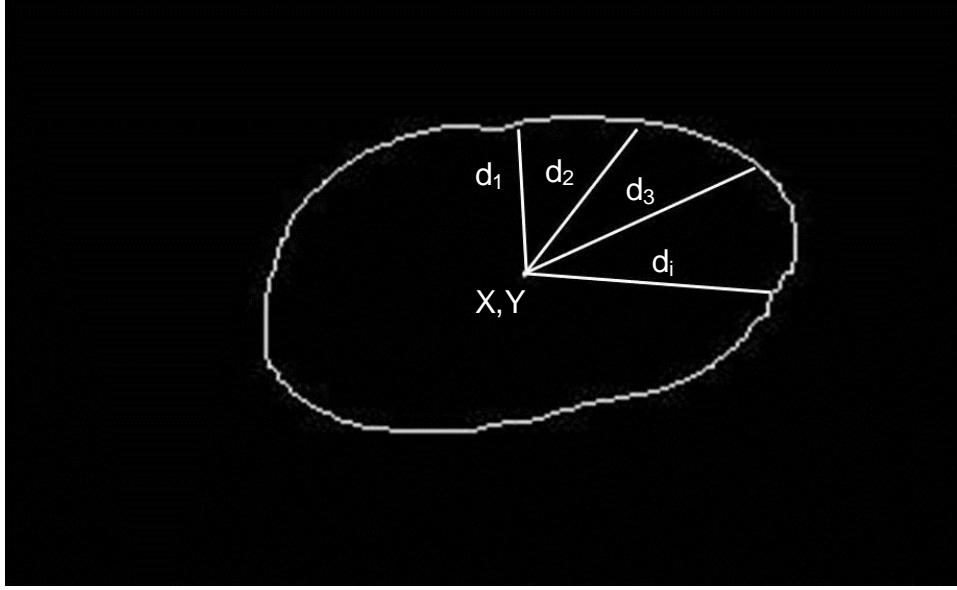
$$d_i = \sqrt{(x_i - X)^2 + (y_i - Y)^2} * \quad (3.11)$$

* X,Y ağırlık merkezinin koordinatları

Örneklerden elde edilen verilerin değerlendirilebilmesi ve karakteristiklerinin çıkarılabilmesi için yine moment analizinden faydalanılmıştır. Örneklere ait öklid uzaklıkları dağılımına ait moment değerleri hesaplanarak kırık ve bütün tanelerin karakteristiklerini ayırt etmek üzere tasarlanan YSA eğitiminde kullanılmıştır.

Hesaplanan dört moment değerinden, birinci moment değeri olan ortalama bu prosedürde kullanılmamıştır. Merkeze olan uzaklıkların ortalamaları ancak tanenin büyüklüğü hakkında bilgi verebilmektedir. Oysa tanenin şeklini tanımlayabilecek bilgiler bu uzaklıkların büyüklüğü değil dağılımı ile ilgilidir. Bu yaklaşımla her örneğin çevre piksellerinin ağırlık merkezine uzaklıklarını içeren veri setinden standart sapma, çarpıklık ve basıklık değerleri elde edilmiştir. Kırık ve bütün tanelerden elde edilen değerlerle, tasarlanan ağırlık eğitimi gerçekleştirilmiştir.

Renk kusurlu, buruşuk ve kırık tanelerin belirlenmesi için oluşturulan ve eğitilen ağların başarılarının sınanması için nohut ve fasulye örnekleri önce insan algısıyla sınıflandırılmış ve bu sınıflandırmalar temel alınarak eğitim gerçekleştirilmiş, son



Şekil 3.5. Çevreyi temsil eden pikseller ve ağırlık merkezine olan Öklid uzaklıkları (d)

olarak da örnekler GAS ile sınıflandırılarak sonuçlar karşılaştırılmış her ağ için *Doğru Sınıflandırma Yüzdesi* (DSY) hesaplanmıştır (Eşitlik 3.12).

$$DSY = \frac{|BGS\ Sonuçları - İnsan\ Sınıflandırması|}{İnsan\ Sınıflandırması} \times 100 \quad (3.12)$$

Bunların yanı sıra tüm nitel ve nicel değerlendirme sonuçları ile gerçek değerler arasında istatistiksel açıdan önemli bir fark olup olmadığının sınanması için *Microsoft Office Excell 2010 (Seattle, A.B.D.)* yazılımı yardımıyla veri setlerine bağımsız örneklem Student'ın t testi uygulanmıştır.

IV. SONUÇLAR VE TARTIŞMA

Bu çalışma kapsamında bakliyat örneklerinin görsel kalite değerlendirmesini gerçekleştirmek üzere yazılım ve donanım olarak iki temel kısımdan oluşan bir GAS tasarlanmıştır. Donanım yardımıyla elde edilen görüntüler işlenerek kalite değerlendirmesi gerçekleştirilmiştir.

4.1. Görüntünün Elde Edilmesi

Tarayıcı, ışık kaynağı, CCD aygıtı ve sayısallaştırıcıyı bir arada bulundurmaktadır. Bu da tarayıcıdan doğrudan sayısal görüntü alabilmemizi sağlamaktadır. Tarayıcı yazılımı yardımıyla standart parlaklık, kontrastlık ve çözünürlük değerlerinde görüntüler alınması sağlanmıştır. Tüm görüntüler 300 dpi çözünürlükte elde edilmiş ve JPEG formatında kaydedilmiştir (Şekil 4.1).

4.2. Segmentasyon



Çalışma kapsamında numune görüntülerinin arka plandan ayrılmasında eşikleme temelli segmentasyon işlemi kullanılmıştır. Yazılım tarafından hesaplanan eşik değeri ikili görüntüde örneklerden kayıp olması ya da görüntüde kirlilikler olması durumlarında değiştirilebilmektedir. İstenilen ikili görüntü elde edildikten sonra hesaplama işlemlerine geçilmiştir. Şekil 4.2'de elde edilen ikili görüntü gösterilmektedir.

4.3. Nicel Değerlendirmeler

GAS ile yapılan boyut ve hacim ölçümlerinin doğruluk ve kesinliklerinin değerlendirilebilmesi için örneklerin gerçek boyut değerleri ile GAS sonuçları karşılaştırılmıştır. Boy ve çap değerlerinin karşılaştırılması için kumpas ölçümlerine karşı GAS ölçümleri grafiğe alınarak aralarındaki ilişki incelenmiştir. Hacim ölçümlerine ait sonuçlar ise taşıma kabı yöntemiyle elde edilen gerçek değerlerle karşılaştırılmıştır .

4.3.1 Çap ve boy ölçümleri

Görüntüden elde ettiği ölçüm sonuçlarını piksel formatında üretmekte olan GAS'ne ait sonuçları kumpas ölçümleri ile karşılaştırabilmek için GAS ölçümlerinin metrik formatta olması gerekmektedir. Bu çevrim için görüntünün çözünürlük değerinden faydalanılmıştır. Görüntülerin üretildiği 300 dpi çözünürlük değerinden faydalanılarak bir pikselin kaç milimetreyi ifade ettiği hesaplanmıştır (Eşitlik 4.1)

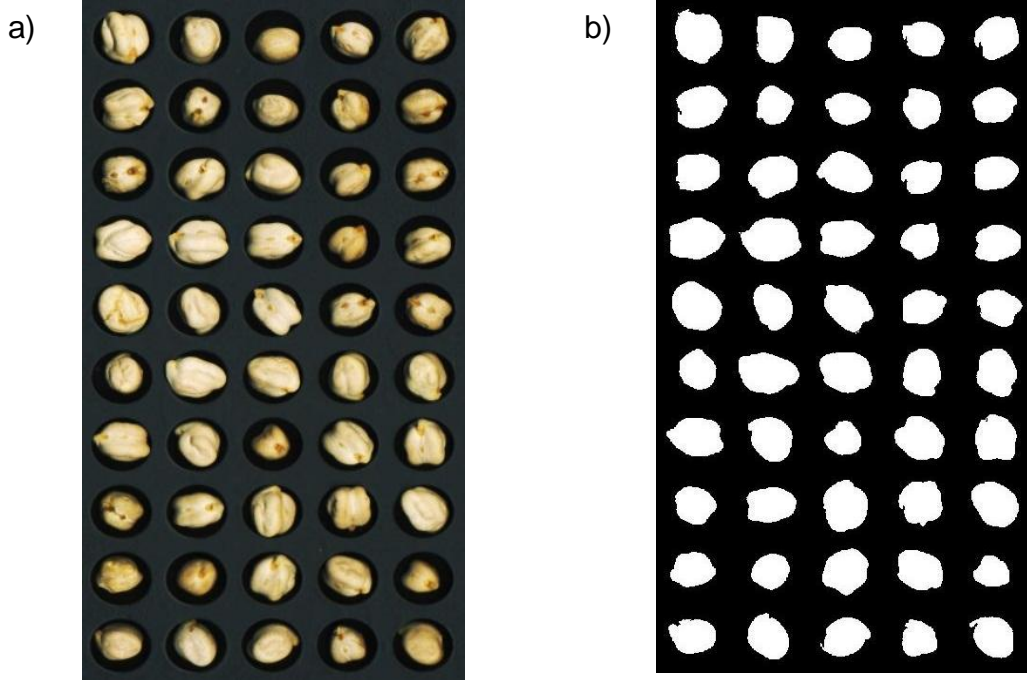


Şekil 4.1. Görüntü elde edilmesi için tasarlanan sistem; Canoscan 4400F tarayıcı (a), nohut ve fasulye örnekleri için tasarlanan örnek çekmeceleri (b), Bileşenlerin toplandığı kapalı kutu (c).

$$\frac{1 \text{ inç}}{300 \text{ piksel}} \times \frac{25.4 \text{ mm}}{1 \text{ inç}} = 0.0847 \text{ mm/piksel} \quad (4.1)$$

Hesaplanan çevirme faktörü MatLab kodlarına eklenerek GAS çıktılarının metrik formatta olması sağlanmıştır.

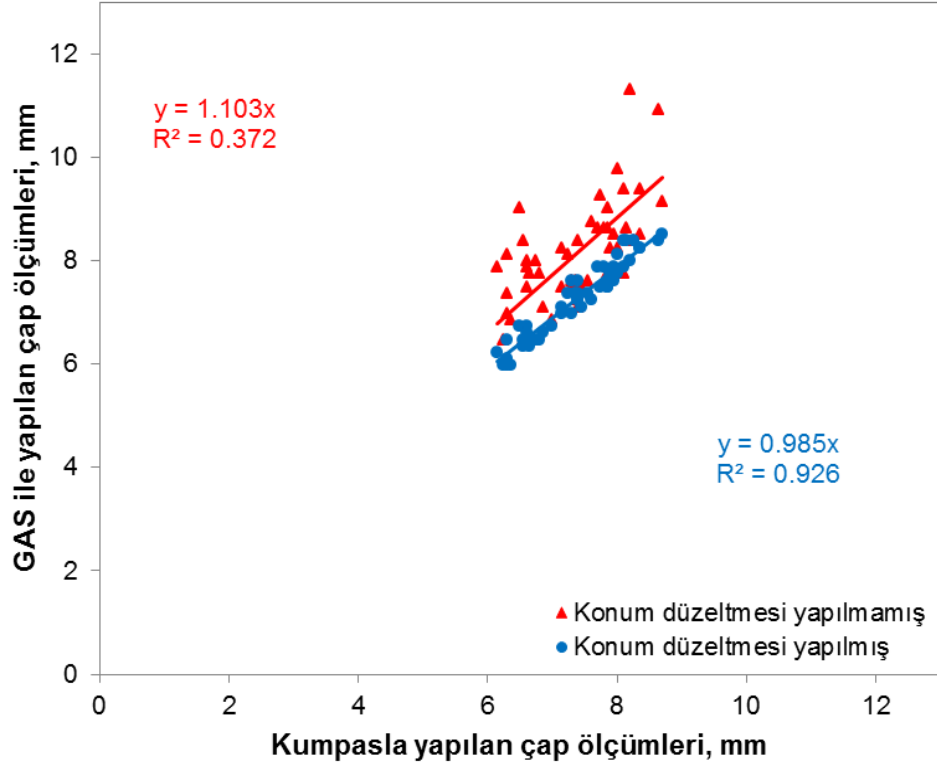
Elli adet nohut örneğinin ve 17 adet fasulye örneğinin kumpasla yapılan boyut ölçümleri ayrı ayrı kaydedilerek GAS yardımıyla elde edilen boyut ölçümleri ile




Şekil 4.2. RGB formundaki örnek görüntüsü (a), İkili görüntü (b).

karşılaştırılmıştır. Şekil 4.3 ve Şekil 4.4'te nohut ölçümlerine ait karşılaştırmalar görülmektedir. Çap ölçümlerinde konum düzeltmesinin yapılmadığı ve yapıldığı durumlarda eğim değerleri sırasıyla 1.103 ve 0.985, R^2 değerleri ise sırasıyla 0.372 ve 0.926 olarak hesaplandı. Boy ölçümlerinde ise konum düzeltmeli ve düzeltmesiz durumlara ait değerler eğim için sırasıyla 0.809 ve 0.943, R^2 için ise 0.325 ve 0.897 olarak hesaplandı. Konum düzeltmeli durumda eğim ve R^2 değerlerinin bire yakın olması konum düzeltmesinin önemini ortaya koymaktadır.

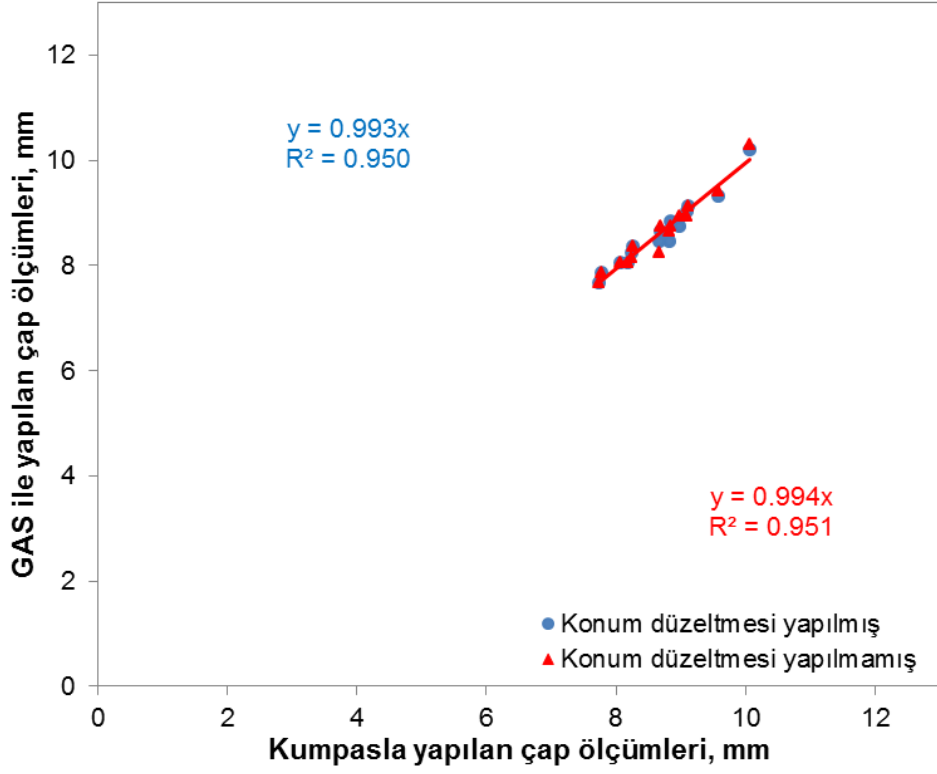
Fasulye örneklerinin GAS ile yapılan çap ve boy ölçümlerinin gerçek değerlerle karşılaştırılması Şekil 4.5 ve Şekil 4.6'da görülmektedir. Çap ölçümlerinin eğim değerleri konum düzeltmeli ve düzeltmesiz durumlarda sırasıyla 0.994 ve 0.993, boy ölçümlerinin ise sırasıyla 0.982 ve 0.987 olarak hesaplandı. R^2 değerlerinin ise düzeltmeli ve düzeltmesiz durumlarda çap ölçümleri için 0.952 ve 0.951, boy ölçümleri için de 0.913 ve 0.920 olduğu görüldü. Fasulye örnekleri tasarlanan örnek çekmecesine şekilleri dolayısıyla yatay konumda yerleşebilmektedir. Sonuçlar bu sebeple düzeltme yapıldığı ve yapılmadığı durumda birbirine çok yakın olmaktadır. Bu durum da yine örneklerin doğru konumlandırılmasının ölçüm sonuçlarının üzerindeki etkisini göstermektedir.



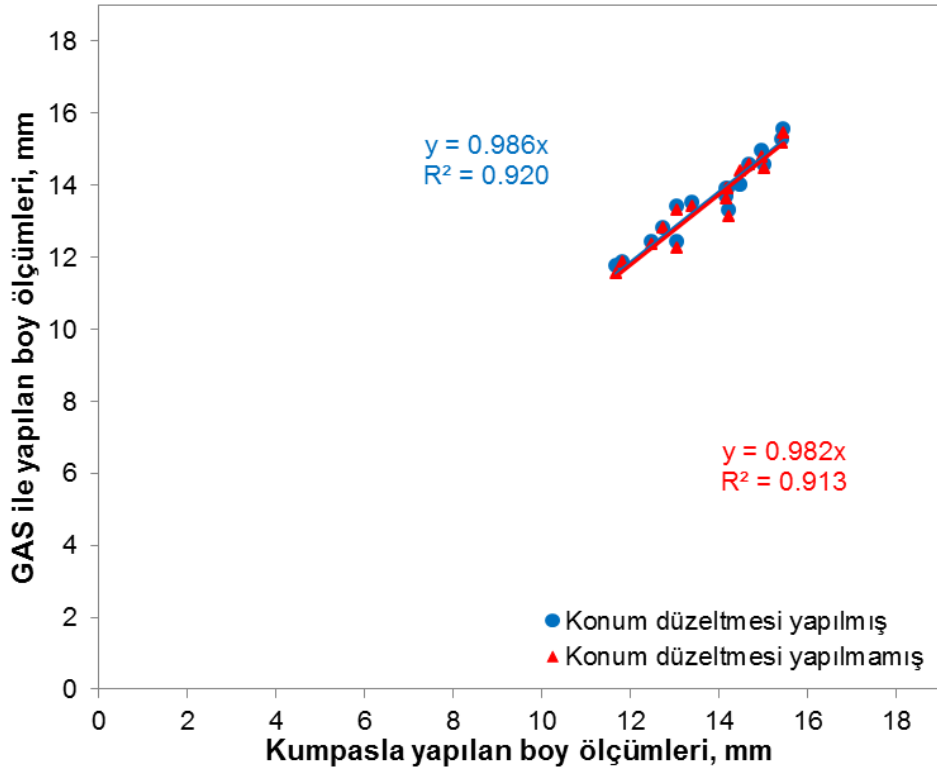
Şekil 4.3. Nohut örneklerinin GAS ile yapılan çap ölçümlerinin kumpasla yapılan ölçümlerle karşılaştırılması.



Şekil 4.4. Nohut örneklerinin GAS ile yapılan boy ölçümlerinin kumpasla yapılan ölçümlerle karşılaştırılması.



Şekil 4.5. Fasulye örneklerinin GAS ile yapılan çap ölçümlerinin kumpasla yapılan ölçümlerle karşılaştırılması.

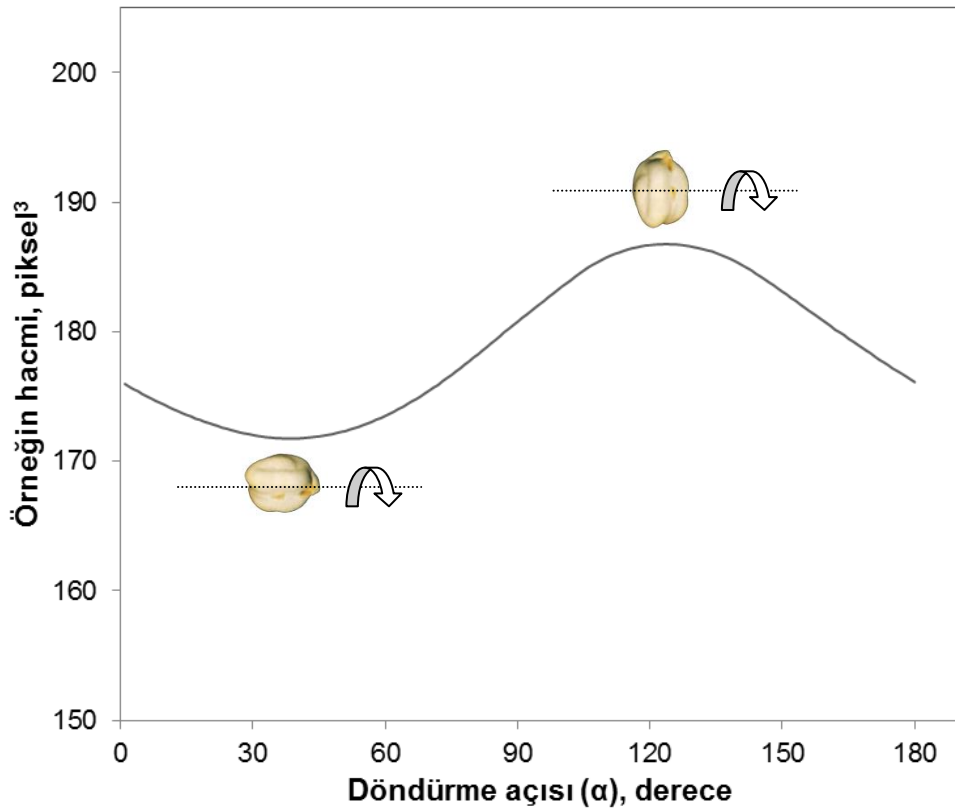


Şekil 4.6. Fasulye örneklerinin GAS ile yapılan boy ölçümlerinin kumpasla yapılan ölçümlerle karşılaştırılması .

4.3.2 Hacim Ölçümleri

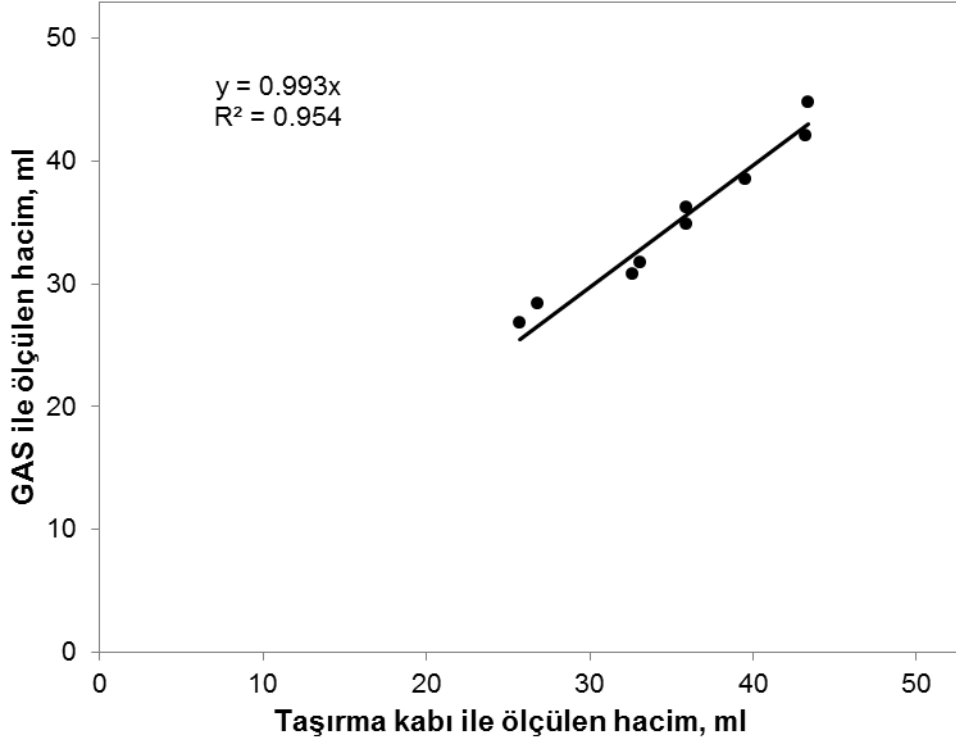
Hacim ölçümlerinin değerlendirilmesi için 100'er adet nohut içeren 9 örnek gurubunun toplam hacimleri GAS yardımıyla ölçülmüştür. Konum düzeltmesi ve konik elementler yaklaşımı hesaplamalar sırasında oluşabilecek hataları önlemek için kullanılmıştır. Şekil 4.7'de konum düzeltmesinin hacim hesaplarına etkisi görülmektedir.

GAS çıktıları *piksel³* (bütün boyutları 1 piksel olan kübik elemanlar) formatında olduğu için sonuçları *mililitre* olarak ifade etmekte kullanılacak bir çevirme faktörüne ihtiyaç duyulmaktadır. Çevirme faktörünün hesaplanabilmesi için ölçüleri bilinen kare, dikdörtgen ve daire şeklindeki iki boyutlu görüntülerin bir eksen etrafında döndürülmesi ile temsil edecekleri cisimlerin hacimleri hem analitik olarak hem de GAS yardımıyla elde edilmiş ve kalibre edilerek çevirme faktörü 2.36×10^{-6} ml/pixel³ olarak hesaplanmıştır. Çevirme faktörü MatLab kodlarına eklenerek GAS'nin *mililitre* formatında veri üretmesi sağlanmıştır. Daha sonra dokuz gurubun hacimleri taşıma kabı yöntemiyle de ölçülerek sonuçlar karşılaştırılmıştır.



Şekil 4.7. Konum düzeltmelerinin hacim hesaplamaları açısından önemi.

Gerçekleştirilen hacim ölçümlerinin gerçek değerlerle karşılaştırıldığı Şekil 4.8'de, eğim değerinin 0.993, R^2 değerinin ise 0.954 olarak hesaplandığı görüldü. Bu sonuçlar hesaplamalarda yapılan düzeltmelerin doğru sonuçlar üretmek yönündeki etkisini göstermektedir.



Şekil 4.8. Nohut örneklerinin GAS ile yapılan hacim ölçümlerinin, taşıma kabı yöntemiyle yapılan ölçümlerle karşılaştırılması.

Çizelge 4.1'de tüm boyutsal ölçümlerin değerlendirme sonuçları bir arada incelenmiştir. Eğim ve R^2 değerleri göz önüne alındığında konum düzeltmesinin yapılmaması boy ölçümlerinin gerçek ölçülerden eksik çap ölçümlerinin ise gerçek ölçülerden fazla olmasına yol açmaktadır. Bu durum tanelerde ölçülebilecek en uzun uzunluğun boy, en kısa olanının ise çap olması, dolayısıyla yanlışlıkların boy değerinin eksik, çap değerinin de fazla ölçülmesi olarak ortaya çıkacağı gerçeğiyle açıklanmaktadır. Örneklerin çap ve boy ölçümlerinin gerçek değerlerle karşılaştırılmasına ait eğim ve regresyon katsayıları göz önüne alındığında GAS'nin doğru ve tutarlı bilgiler ürettiği ve konum düzeltmelerinin hem çap hem de boy ölçümlerinde tutarlılık ve doğruluğu arttırdığı görülmektedir. Nohut örneklerine ait boy ölçümlerinin tutarlılık ve doğruluğunun çap ölçümlerine göre düşük olmasının nedeni nohutların boy ölçümleri sırasında tepe kısmında bulunan ve *buruncuk* (Anonim, 2008a) olarak tabir edilen çıkıntılıların kumpasla ölçüm

Çizelge 4.1. Tüm ölçüm sonuçlarının tutarlılık ve doğrulukları

		Nohut		Fasulye	
		Konum düzeltilmesiz	Konum düzeltilmeli	Konum düzeltilmesiz	Konum düzeltilmeli
Çap	Eğim	1.103	0.985	0.994	0.993
	R²	0.372	0.926	0.952	0.951
Boy	Eğim	0.809	0.943	0.982	0.987
	R²	0.325	0.897	0.913	0.920
Hacim*	Eğim		0.993		
	R²		0.954		

*Hacim ölçümleri için konum düzeltmesi ve konik elemanlar yaklaşımı ile elde edilen sonuçlar "konum düzeltilmeli" sütununda verilmiştir.

sırasında dâhil edilmesi ancak görüntü alırken karanlıkta kalabilmesi ve segmentasyon sırasında kaybedilmesi ya da tanenin duruş pozisyonuna bağlı olarak görüntüye dâhil olamamasıdır. Boyutlandırma elek analizinde olduğu gibi çap değerleri üzerinden yapıldığından boy ölçümünden gelecek hata kalite değerlendirmesinde etkili olmayacaktır.

Tüm nicel değerlendirme sonuçları ile gerçek değerler arasında istatistiksel açıdan önemli bir fark olup olmadığı % 95 güven düzeyinde Student'ın bağımsız örneklem t testi ile sınanmış ve sonuçlar Çizelge 4.2'de verilmiştir.

Çizelge 4.2. Ölçüm sonuçları ile gerçek değerlerin istatistiksel karşılaştırılmasına ait p değerleri.

	p değeri ($\alpha=0.05$)	
	Nohut	Fasulye
Çap	0.44	0.46
Boy	0.14	0.32
Hacim	0.47	----

Tüm p değerleri 0.05 ten büyük olduğu için % 95 güven düzeyinde ölçüm sonuçları ile gerçek değerler arasında anlamlı bir fark olmadığı görülmektedir.

4.4. Nitel Değerlendirmeler

Kusurlu tanelerin belirlenmesi görsel değerlendirmelerle yapıldığı için nitel değerlendirmeler olarak adlandırılmıştır. Renk kusurlu, buruşuk ve kırık tanelerin belirlenmesinde YSA'dan faydalanılmıştır.

4.4.1. Renk kusurlu tane belirleme

Renk kusurlu tanelerin belirlenmesi için kusurlu, kabul edilebilir ve iyi renkli tanelere ait intensite değerleri yazılım aracılığıyla elde edilmiş ve kullanılacak moment değerleri hesaplanmıştır. Şekil 4.9'da renk kusurlu, kabul edilebilir ve iyi renkli birer örneğe ait moment değerleri ve renk dağılımlarını karakterize eden histogramlar görülmektedir. Histogramlar ve moment değerleri incelendiğinde iyi renkli bir örneğe ait verilerin birinci moment olan ortalamanın sağında birikerek negatif çarpıklık verdiği görülmektedir. Bu durum iyi renkli tanelerin sahip olduğu yüksek intensite değerleri ile de tutarlıdır. Kötü renkli örnekte ise düşük intensite değerleri dolayısıyla sifira daha yakın çarpıklık görülmektedir.

Nohut örneklerinin kalite değerlendirmesinde kullanılacak ağ için farklı ağ mimarileri denenmiştir. Tasarlanan ağın giriş katmanı nöron sayısı 12, gizli katman nöron sayısı 10 ve çıkış katmanı nöron sayısı 1 olarak belirlenmiştir. HKO değeri 4.46×10^{-5} ile performansı en yüksek olan ağda eğitim algoritması olarak *trainscg*, gizli katman aktivasyon fonksiyonu *tansig* ve çıkış katmanı aktivasyon fonksiyonu olarak *purelin* belirlenmiştir. Ağın eğitimi 36'sı renk kusurlu 36'sı kabul edilebilir ve 36'sı iyi renkli olmak üzere 108 örnekle gerçekleştirilmiştir.


Fasulye için giriş katmanı nöron sayısı 12, gizli katman nöron sayısı 10 ve çıkış katmanı nöron sayısı 1 olan ağ fasulye örneklerine ait verilerle değerlendirilmiş ve performansının yetersiz olduğu görülmüştür. Bu nedenle gizli katman sayısı artırılarak nöron sayıları 12 ve 10 olan iki gizli katmana sahip yeni bir ağ tasarlanmıştır. HKO değeri 6.31×10^{-8} ile en düşük olan ağın gizli katman aktivasyon fonksiyonları her iki katman için de *tansig*, çıkış katmanı aktivasyon fonksiyonu

Çizelge 4.3. Renk kusurlu tanelerin belirlenmesinde kullanılan ağın tasarımı ve eğitimine ait parametreler.

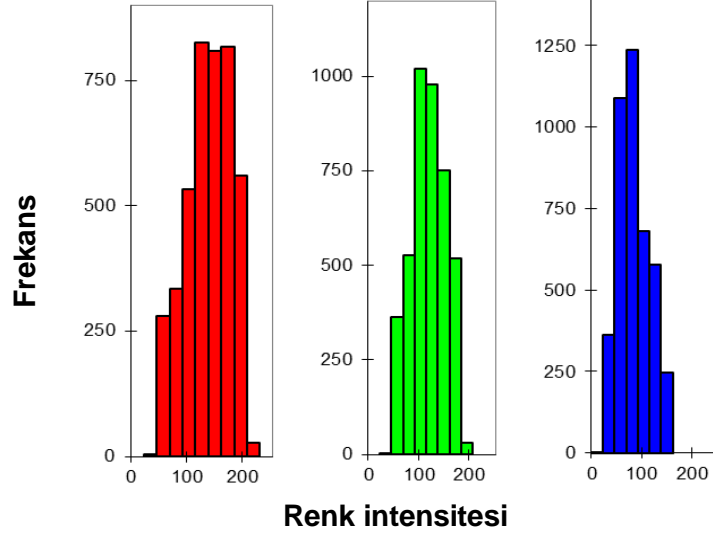
	Örnek sayısı	Gk sayısı	Gk nöron sayısı	Eğitim fonksiyonu	Transfer fonksiyonları		Adım Sayısı	HKO
					Gk	Çk**		
Nohut	108	1	12	<i>trainscg</i>	<i>tansig</i>	<i>purelin</i>	264	4.46×10^{-5}
Fasulye	121	2	12-10	<i>trainscg</i>	<i>tansig</i>	<i>purelin</i>	4148	6.31×10^{-8}

*Gk; gizli katman, **Çk; çıkış katmanı

a)




	R	G	B
Ortalama	166.969	144.816	106.677
Std. Sapma	42.710	35.978	30.571
Çarpıklık	-0.988	-0.817	-0.491
Basıklık	3.209	2.984	2.369



b)

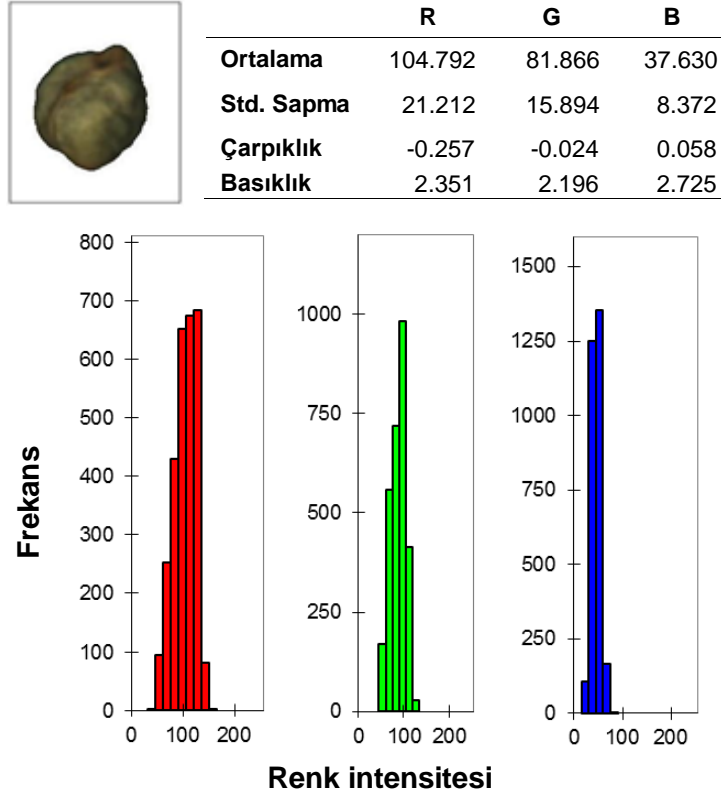


	R	G	B
Ortalama	142.275	117.852	76.016
Std. Sapma	33.551	24.881	16.479
Çarpıklık	-0.712	-0.661	-0.367
Basıklık	2.928	2.993	2.948



Şekil 4.9. İyi renkli (a), kabul edilebilir renkli (b) ve renk kusurlu (c) nohut tanelerine ait moment değerleri ve histogramları.

c)



Şekil 4.9. devam ediyor

purelin eğitim algoritması da *trainscg* olarak belirlenmiştir. Eğitim 24 renk kusurlu, 24 kabul edilebilir ve 73 iyi renkli toplam 121 örnekle gerçekleştirilmiştir. Çizelge 4.3'te ağların eğitimlerine ait parametreler verilmiştir.

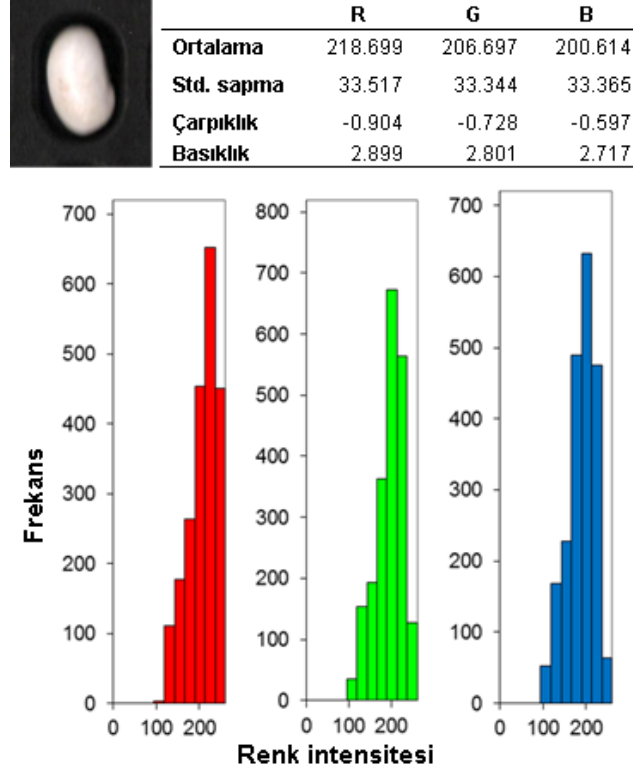
GAS'nin renklerine göre örnekleri ayırt etmekteki başarısını sınamak üzere 432 adet nohut örneği göz muayenesi ile ayrılarak 234'ü iyi, 126'sı kabul edilebilir ve 72'si renk kusurlu olarak sınıflandırılmıştır. Örnekler GAS ile de değerlendirildikten sonra sonuçlar karşılaştırılmıştır.

Çizelge 4.4. Nohut örneklerinin renklerine göre sınıflandırılmasında GAS'nin başarısı;

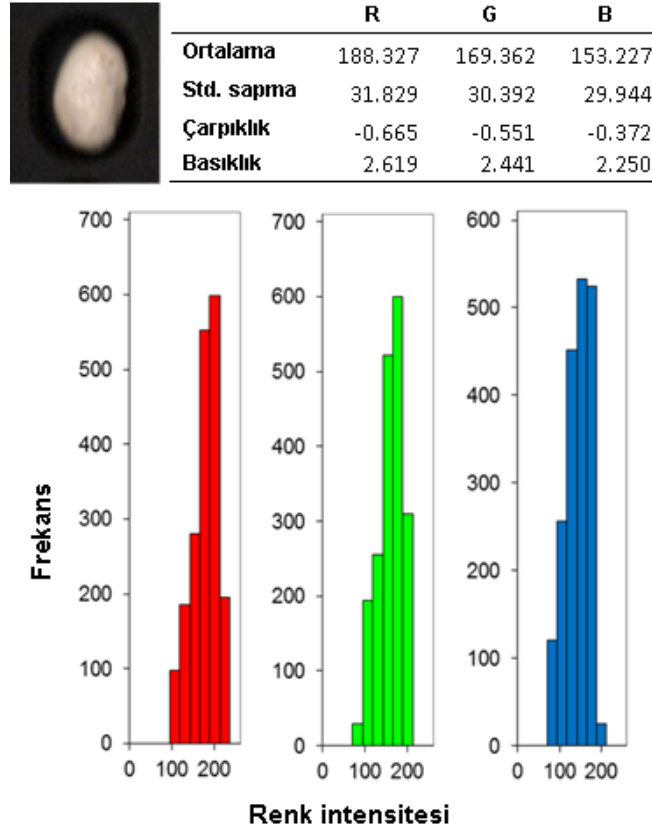
Gurup	Örnek sayısı (İnsan)	Örnek sayısı (GAS)	Standart Sapma	Doğru sınıflandırma yüzdesi (%)
A	234	238	2.8	98.3
B	126	114	8.5	89.5
C	72	80	5.7	90.0
Toplam				94.4

A; iyi, B; kabul edilebilir ve C; renk kusurlu.

a)

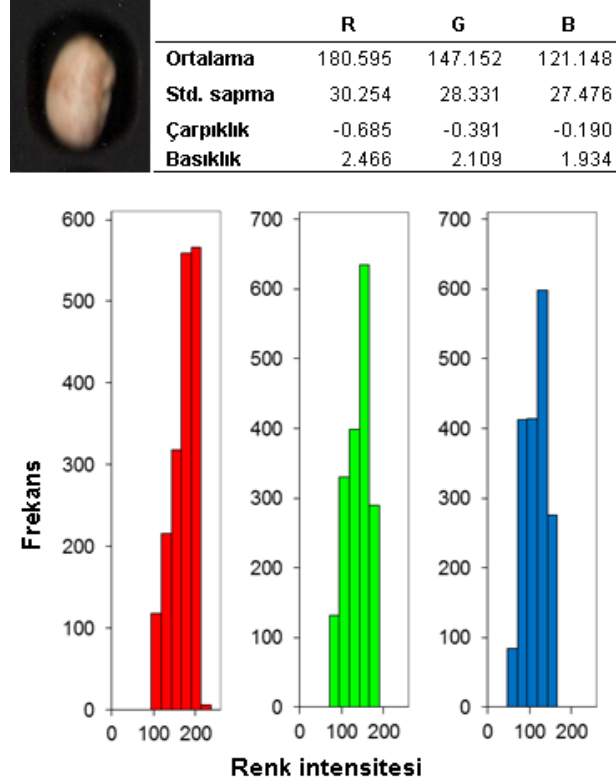


b)



Şekil 4.10. İyi renkli (a), kabul edilebilir renkli (b) ve renk kusurlu (c) fasulye tanelerine ait moment değerleri ve histogramları.

c)



Şekil 4.10. devam ediyor

Çizelge 4.4'den görülebileceği gibi GAS'nin başarısı iyi renkli örnekleri sınıflandırırken yüksektir ancak GAS kabul edilebilir ve renk kusurlu taneleri ayırt etmekte aynı başarıyı gösterememektedir. Bu hatanın asıl nedeni insan sınıflandırmasının doğru yapılamamasıdır. GAS bu ayrımı nicel verilerle yaparken insan nitel olarak yapmaktadır. Yani GAS'ni sınamak için oluşturulan örnek sınıflarının hatalı olması GAS'ni başarısız gibi göstermektedir. İnsanın kabul edilebilir ve renk kusurlu taneler arasında ayırım yaparken iki sınıf arasındaki sınırı net olarak ayırt edememesi hatanın asıl kaynağı olarak düşünülmektedir.

Fasulye örneklerinin her üç sınıf tane için elde edilen moment değerleri ve histogramları incelendiğinde nohut örneklerine benzer olarak ortalama değerlerinin iyi renkli örnekten renk kusurlu örneğe doğru gittikçe azaldığı, küçülen intensite değerleri dolayısıyla standart sapmaların küçüldüğü ve çarpıklık değerinin sağa çarpık yönden sola çarpık yöne doğru değiştiği görülmektedir. Basıklık değeri ise gittikçe azalmaktadır. Bahsedilen her üç moment değerinin iyi örnekten renk kusurlu örneğe doğru değişmesi tane renginin koyulaşması yani piksel intensitelerinin küçülmesiyle açıklanabilmektedir.

Fasulye örneklerini renklerine göre ayırt etmekte GAS'nin başarısını sınamak

üzere 122 adet fasulye örneği göz muayenesi ile ayrılarak 74'ü iyi, 22'si kabul edilebilir ve 26'sı renk kusurlu olarak sınıflandırılmıştır. GAS ile yapılan değerlendirmelerden sonra sonuçlar karşılaştırılmıştır.

Çizelge 4.5. Fasulye örneklerinin renklerine göre sınıflandırılmasında GAS'nin başarısı;

Gurup	Örnek sayısı (İnsan)	Örnek sayısı (GAS)	Standart Sapma	Doğru sınıflandırma yüzdesi (%)
A	74	79	3.5	93.7
B	22	15	4.9	90.0
C	26	23	2.1	86.9
			Toplam	91.8

A; iyi, B; kabul edilebilir ve C; renk kusurlu.


Çizelge 4.5'den görülebileceği gibi GAS'nin başarısı iyi renkli örnekleri sınıflandırırken yüksektir ancak GAS kabul edilebilir ve renk kusurlu taneleri birbirinden ayırt etmekte aynı başarıyı gösterememektedir.

Nohut ve fasulye örneklerinin renk kusurlarına göre değerlendirilmesine ait GAS sonuçları ile insan değerlendirmesine ait sonuçlar arasında istatistiksel açıdan önemli bir fark olup olmadığı % 95 güven düzeyinde Student'ın t testi ile karşılaştırılmıştır. p değerleri nohut için 0.49 fasulye için de 0.47 olarak hesaplanmış ve p değerlerinin 0.05 ten yüksek olması sonucu GAS sınıflandırması ile gerçek sınıflandırma arasında fark olmadığı kabul edilmiştir.

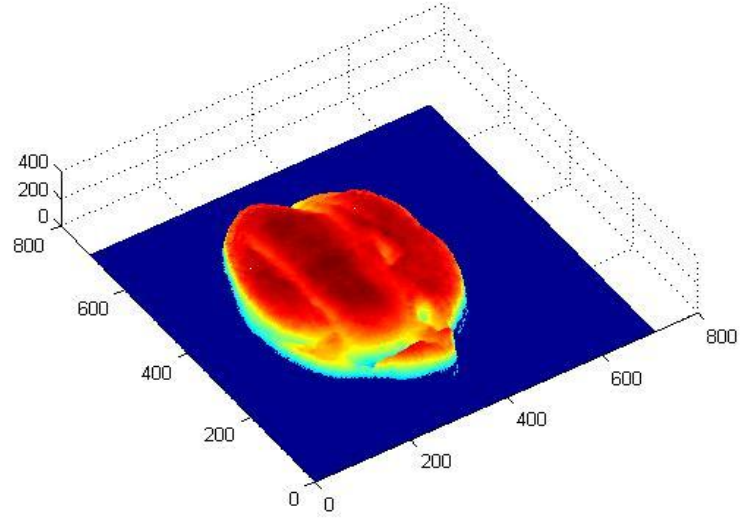
4.4.2. Buruşuk tane belirleme

Buruşuk ve pürüzsüz tanelerin ayırt edilmesinde örneğin yüzey morfolojisine bağlı olarak buruşuk ve pürüzsüz tanelerden alınan görüntünün farklılık göstermesinden yararlanılmıştır. Örneğe ait piksel intensitelerinin MatLab *mesh* komutu ile yüzey grafiği çizildiğinde buruşuk bir taneye ait intensite dağılımı ile pürüzsüz bir taneye ait intensite dağılımının farkı Şekil 4.11'de açıkça görülmektedir. Grafiklerde renklerin örneğin renk dağılımı ile bir ilişkisi yoktur ve yükseltiyi ifade etmektedir. Yükselti değerlerin 0 ile 255 arasında değişmesi ile renkler maviden kırmızıya değişmektedir. Böylece buruşuk bir taneye ait renkler homojen olmamakta, pürüzsüz bir yüzey ise tek renk görünmektedir. Farklı renkler yüzeydeki girinti ve çıkıntılara işaret etmektedir.

a)




b)




Şekil 4.11. Buruşuk (a) ve pürüzsüz (b) tanelerin yüzey dokularının grafiksel ifadesi.

Örneklere ait piksel intensiteleri filtre edildikten sonra elde edilen görüntüler, 12 moment değeri ve histogramlar Şekil 4.12’de gösterilmiştir. Filtreleme işleminden sonra pürüzsüz örneklerde homojen koyu renkli bir görüntü elde edildiği için veriler küçük değerler etrafında yoğunlaşmaktadır. Buruşuk bir örnekte girinti ve çıkıntılar açık renklerle görüldüğü için yüksek ve düşük intensite değerlerine sahip homojen olmayan görüntünün verileri normale daha yakın bir dağılım sergilemektedir. Fasulye tanelerinin pürüzsüz ve buruşuk olanlarının histogramları ve moment değerleri (Şekil 4.13) incelendiğinde ise filtre edilmiş görüntüde pürüzsüz tanelerin homojen bir koyu renk sergilemesinden dolayı ortalama ve

a)




	R	G	B
Ortalama	21.733	20.498	19.443
Std. Sapma	36.570	33.630	23.659
Çarpıklık	2.793	2.751	2.502
Basıklık	10.393	10.080	9.283




Renk intensitesi

b)



	R	G	B
Ortalama	99.633	93.514	75.095
Std. Sapma	61.672	49.366	39.076
Çarpıklık	0.563	0.961	0.947
Basıklık	2.443	3.511	3.633



Renk intensitesi

Şekil 4.12. Pürüzsüz (a) ve buruşuk (b) nohut tanelerinin filtre edilmiş görüntülerine ait moment değerleri ve histogramları.

standart sapma deęerleri buruřuk 6rneęe g6re k6ç6k olduęu, verilerin k6ç6k deęerlere yoęunlařmasından dolayı ise arpıklık ve basıklık deęerlerinin buruřuk taneye g6re daha b6y6k hesaplandıęı g6r6lmektedir. Moment deęerleri arasındaki bu anlamlı farklılık buruřuk tanelerin belirlenmesinde moment analizini uygulanabilir hale getirmektedir.

Bu farktan faydalanarak buruřuk ya da p6r6zs6z gibi bir sonu 6retmesi istenmekte olan giriř katmanı n6ron sayısı 12, gizli katman n6ron sayısı 10 ve ıkıř katmanı n6ron sayısı 1 olan YSA tasarlanmıřtır. Farklı aę mimarileri denenerek HKO deęeri 3.95×10^{-8} ile en d6ř6k olan aęın aktivasyon fonksiyonları gizli katman iin *tansig*, ıkıř katmanı iin ise *purelin* olarak seilmiřtir. Eęitim algoritması olarak *trainscg* algoritması kullanılmıřtır. Nohut iin aę eęitimi gerekleřtirilirken 63'6 p6r6zs6z 22'si buruřuk olmak 6zere 85 6rnek kullanılmıřtır. Fasulyelerin sınıflandırılması iin ise aę mimarisi deęiřtirilmeden fasulye 6rneklerine ait verilerle yeniden eęitim yapılmıř ve HKO deęeri 5.91×10^{-5} olarak hesaplanmıřtır. Fasulye 6rnekleri iin gerekleřtirilen eęitim s6recinde 68'i p6r6zs6z 39'u buruřuk olmak 6zere 107 6rnek kullanılmıřtır. Aę tasarımı ve eęitimlerine ait t6m parametreler izelge 4.6'da verilmiřtir.

izelge 4.6. Buruřuk tanelerin belirlenmesinde kullanılan aęın tasarımı ve eęitimine ait parametreler.

	6rnek sayısı	Gk sayısı	Gk n6ron sayısı	Eęitim fonksiyonu	Transfer fonksiyonları		Adım Sayısı	HKO
					Gk	k**		
Nohut	85	1	10	trainscg	tansig	purelin	1811	3.95×10^{-8}
Fasulye	107	1	10	trainscg	tansig	purelin	4148	5.91×10^{-5}


*Gk; gizli katman, **k; ıkıř katmanı

Aęlarını bařarısının sınanmasında g6z muayenesi ile ayrılarak 68'i p6r6zs6z ve 31'i buruřuk olarak sınıflandırılan 99 adet nohut 6rneęi kullanılmıř ve sonular karřılařtırılmıřtır (izelge 4.7).

a)



	R	G	B
Ortalama	15,192	14,751	14,676
Std. Sapma	22,377	21,372	20,535
Çarpıklık	3,211	3,302	3,316
Basıklık	15,321	16,258	16,475




Renk intensitesi

b)



	R	G	B
Ortalama	21,049	21,031	20,990
Std. Sapma	28,156	26,736	25,152
Çarpıklık	2,040	2,082	2,152
Basıklık	7,064	7,437	7,971



Renk intensitesi

Şekil 4.13. Pürüzsüz (a) ve buruşuk (b) fasulye tanelerinin filtre edilmiş görüntülerine ait moment değerleri ve histogramları.

Çizelge 4.7. Nohut örneklerinin yüzey morfolojisine göre sınıflandırılmasında GAS'nin başarısı;

Gurup	Örnek Sayısı (İnsan)	Örnek Sayısı (GAS)	Standart Sapma	Doğru Sınıflandırma Yüzdesi (%)
A	68	66	1.4	97.0
B	31	33	1.4	93.9
Toplam				96.0

A; pürüzsüz ve B; buruşuk

Çizelge 4.7'den anlaşıldığı gibi GAS pürüzsüz ve buruşuk nohut örneklerini ayırt etmekte başarı göstermektedir. Fasulye için oluşturulan ağın başarısı ise 51'i pürüzsüz ve 35'i buruşuk 89 adet fasulye değerlendirilmiş sonuçlar karşılaştırılmıştır.

Çizelge 4.8. Fasulye örneklerinin yüzey morfolojisine göre sınıflandırılmasında GAS'nin başarısı;

Gurup	Örnek Sayısı (İnsan)	Örnek Sayısı (GAS)	Standart Sapma	Doğru Sınıflandırma Yüzdesi (%)
A	51	57	4.2	89.5
B	35	29	4.2	79.3
Toplam				86.1

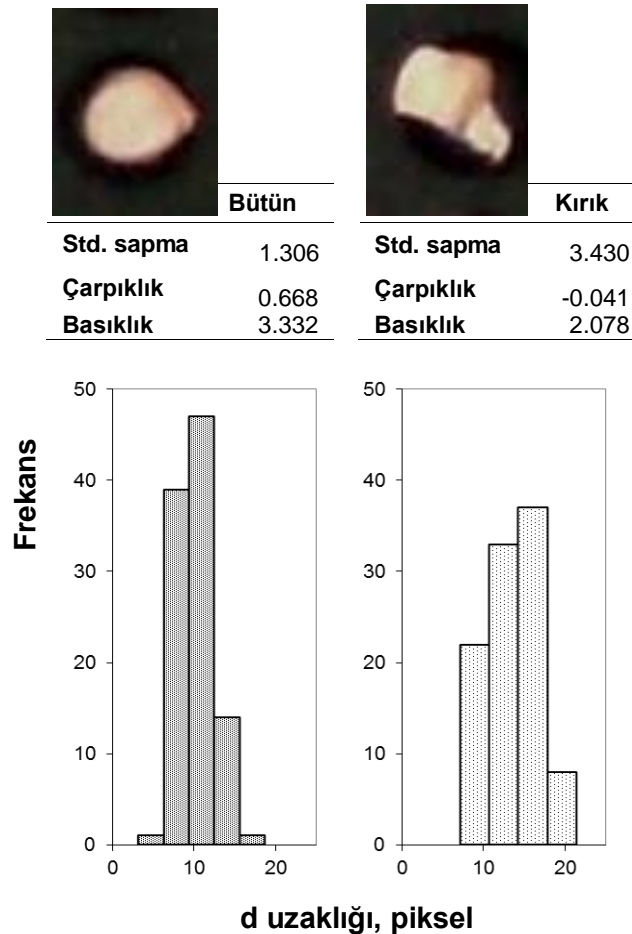
A; pürüzsüz ve B; buruşuk.

Çizelge 4.8'e göre fasulye örneklerinin yüzey morfolojisine göre sınıflandırılmasında GAS performansı nohut örneklerinde olduğu kadar yüksek değildir. Bunun yanında buruşuk örneklerin ayırt edilmesindeki başarı da pürüzsüz tanelerin ayırt edilmesinde olduğundan oldukça düşüktür. Bu durum buruşuk da olsa fasulye örneklerinin nohut örneklerine nispetle parlak yüzeyleri sayesinde buruşuk kısımlarının tarayıcı tarafından gönderilen ışığı yansıtarak yeterince gölgede kalmaması ve oluşturulan prosedüre göre ayırt edilememesi ile ilgilidir.



Tüm sonuçlar Student'in t testi ile karşılaştırılarak p değerleri nohut için 0.50 ve fasulye için 0.36 olarak hesaplanmıştır. Sonuçlar arasında istatistiksel olarak anlamlı bir fark olmadığına karar verilmiştir


4.4.3. Kırık tane belirleme

Kırık taneleri belirlemek için örneklerin çevrelerini belirleyen piksellerin ağırlık merkezine olan uzaklıkları ölçülerek bir matriste toplanmıştır. Bu veri setine ait moment değerleri (standart sapma, çarpıklık ve basıklık) hesaplanarak ağ eğitimlerinde kullanılmıştır. Şekil 4.14'de bütün ve kırık birer taneye ait moment değerleri ve veri dağılımına ait histogramlar gösterilmektedir. Kırık tanelere ait histogram incelendiğinde uzaklık değerlerinin homojen olmaması nedeniyle standart sapmanın büyük olduğu çarpıklık ve basıklık değerlerinin ise bütün taneye göre küçük olduğu görülmektedir. Fasulye örneklerinin moment değerleri ve histogramları incelendiğinde (Şekil 4.15) standart sapma ve basıklık değerlerinin değişimi nohut örneklerinde olduğu gibi olsa da çarpıklık değerinde tam tersi bir durum olduğu görülür. Bu durum nohut örneklerinin bütün olanlarına ait öklid uzaklıklarının homojen bir dağılım gösterirken fasulye örneklerinin ise kırık olanlarının daireye yakın bir şekilde olması ve öklid uzaklıklarının homojen dağılması ile çarpıklığın sıfıra yakın olması gerçeği ile açıklanabilmektedir.



Şekil 4.14. Bütün ve kırık nohut tanelerine ait moment değerleri ve histogramlar.

	Bütün		Kırık
Std. Sapma	2.598	Std. sapma	5.188
Çarpıklık	-0.498	Çarpıklık	0.053
Basıklık	2.790	Basıklık	1.554



Şekil 4.15. Bütün ve kırık fasulye tanelerine ait moment değerleri ve histogramlar.

Moment değerlerinin kırık ve bütün taneler arasında farklılık göstermesi kırık tanelerin moment analizi ile belirlenebileceğini ortaya koymaktadır. Örneklere ait 3 veriden faydalanarak kırık ya da bütün gibi bir sonuç üretmesi istenen ağ için farklı ağ mimarileri denenmiştir. Ağ performansının düşük olması nedeniyle gizli katman ve gizli katman nöron sayıları artırılarak giriş katmanı nöron sayısı 3, gizli katmanların nöron sayıları 24 ve çıkış katmanı nöron sayısı 1 olan bir YSA tasarlanmıştır. HKO değeri $5,10 \times 10^{-7}$ ile en düşük olan ağ mimarisinde gizli katmanların aktivasyon fonksiyonları *tansig*, çıkış katmanı aktivasyon fonksiyonu olarak ta *purelin* belirlenmiştir. Eğitim algoritması olarak *trainscg* algoritması kullanılmıştır. Nohut ve fasulye örneklerinin tane bütünlüğüne göre sınıflandırılması amacıyla oluşturulan ağın eğitimi, nohut için 23'ü kırık 101'i bütün

toplam 124 örnekle, fasulye için ise 23'ü kırık 56'sı bütün toplam 89 örnekle gerçekleştirilmiştir (Çizelge 4.9).

GAS'nin tane bütünlüğüne göre örnekleri ayırt etmekteki başarısını sınamak amacıyla 89'u bütün ve 25'i kırık 114 adet nohut örneği göz muayenesi ile sınıflandırılmış ve GAS sonuçları ile karşılaştırılmıştır (Çizelge 4.10).

Çizelge 4.9. Kırık tanelerin belirlenmesinde kullanılan ağız tasarımı ve eğitimine ait parametreler.

	Örnek sayısı	Gk sayısı	Gk nöron sayısı	Eğitim fonksiyonu	Transfer fonksiyonları		Adım Sayısı	HKO
					Gk	Çk**		
Nohut	124	2	24-24	trainscg	tansig	purelin	1190	$5,10 \times 10^{-7}$
Fasulye	89	2	24-24	trainscg	tansig	purelin	4951	$9,02 \times 10^{-6}$

*Gk; gizli katman, **Çk; çıkış katmanı

Çizelge 4.10'dan görüleceği gibi GAS'nin kırık taneleri ayırt etmekteki başarısı daha düşük görülmekte, kırık olmayan nohutlar kırık olarak değerlendirilebilmektedir. Bu hatanın nedeni tanenin bütün olsa da şekil itibarıyla diğerlerinden farklı olabilmesi ve kırık olarak değerlendirilmesidir.

Çizelge 4.10. Nohut örneklerinin tane bütünlüğüne göre sınıflandırılmasında GAS'nin başarısı;

Gurup	Örnek Sayısı (İnsan)	Örnek Sayısı (GAS)	Standart Sapma	Doğru Sınıflandırma Yüzdesi (%)
A	89	85	2.8	95.3
B	25	29	2.8	86.2
Toplam				93.0

A; bütün ve B; kırık.

Göz muayenesi ile 80'i bütün ve 17'si kırık olarak sınıflandırılan 97 adet fasulye örneği GAS ile de değerlendirildikten sonra sonuçlar karşılaştırılmıştır. Çizelge 4.11'de görüldüğü gibi fasulye örneklerinin sınıflandırılmasında kırık olmayan tanelerin nohut örneklerinde olduğu gibi kırık olarak değerlendirilmesi ve kırık tanenin ayırt edilmesindeki başarının düşmesi söz konusudur.

Sınıflandırma sonuçlarının insan sınıflandırması ile arasında istatistiksel açıdan önemli bir fark olmadığı nohut için 0.28 ve fasulye için 0.26 p değerlerinin hesaplandığı Student'in t testi ile ortaya konulmuştur.

Çizelge 4.11. Fasulye örneklerinin tane bütünlüğüne göre sınıflandırılmasında GAS'nin başarısı;

Gurup	Örnek Sayısı (İnsan)	Örnek Sayısı (GAS)	Standart Sapma	Doğru Sınıflandırma Yüzdesi (%)
A	80	78	1.4	97.4
B	17	19	1.4	89.5
Toplam				95.9

A; bütün ve B; kırık.

YSA'nın eğitimlerinin tamamlanıp başarılarının sınanmasından sonra yazılımın programlama dillerine yabancı bir kullanıcı tarafından da rahatça kullanılabilmesi için MatLab programı yardımıyla bir grafiksel kullanıcı ara yüzü (GKA) geliştirilmiş (Şekil 4.16) ayrıca MatLab programına bağımlı kalmadan çalışabilecek bir *uygulama* dosyası oluşturulmuştur.

GKA yardımıyla eşik değerinin değiştirilebilmesi önemli bir avantajdır. Yazılım tarafından hesaplanan değerler her zaman en uygun eşik değerini vermemekte, bu durum da örnek piksellerinden kayıplara ya da arka plan piksellerinde kirliliklere yol açmaktadır. Kullanıcı GKA yardımıyla eşik değerini istediği ikili görüntüyü elde edene kadar değiştirebilmekte her denemesinde ikili görüntüyü yeniden izleyerek karar verebilmektedir. Örneklerin örnek çekmecesine yerleştirilmesi 1 dakikadan daha az sürerken görüntünün alınarak işlenmesi ve sonuç üretilmesi 1 dakikayı bulmaktadır. Yaklaşık 2 dakikalık bir sürede örneğe ait boyut ve kalite değerlendirmesi tamamlanmaktadır.

Yazılım yardımıyla elde edilen çıktılar sayesinde GAS sadece kalite değerlendirmesinde işlevsel bir ürün olmakla kalmayıp ileriki çalışmalarda kullanılacak verileri elde etmekte de faydalı olacaktır.

Literatürde gıda maddelerinin görsel kusurlarının görüntü analizi ile belirlenmesi konusuna sıklıkla rastlanılmaktadır. GAS'nin başarısı hakkında fikir verecek çalışmalara bakıldığında Tao and Wen (1999) meyvelerdeki kusurları belirledikleri

çalışmalarında sonuçların doğruluğunu % 94, Tan et al (2000) domuz eti rengini değerlendirdikleri çalışmalarında doğruluğu % 90 olarak göstermiştir (Brosnan and Sun, 2004).

Kılıç et al (2007a) fasulye tanelerini görsel kusurlarına göre yapay sinir ağıları yardımıyla sınıflandırdıkları çalışmalarında tasarladıkları sistemin başarımını koyu renkli taneleri ayırt etmekte % 93.8, kabul edilebilir sarımtırak taneleri iyi renkli tanelerden ayırt etmekte % 74.5 olarak vermekte ve bu sonucu insan tarafından yapılan sınıflandırmalarda da sarımtırak ve beyaz taneler arasındaki farkı ayırt edememe gibi bir hatanın var olabileceği gerçeğine dayandırmaktadırlar.


Zapotocznya et al (2011) görüntü işleme ve yapay sinir ağlarını kullanarak şekil özelliklerine göre buğday türlerini değerlendirmekte ve geleneksel yöntemlerden çok daha hızlı olan sistemin % 100 doğrulukta sonuçlar ürettiğini ortaya koymaktadır.

Yine hububatların GAS ve YSA ile kalite değerlendirmesi için Lou and Nakai (2001) çok katmanlı bir YSA uygulaması gerçekleştirmiş buğday, arpa, çavdar ve yulaf örneklerinde altı tip kusuru sırasıyla % 96.2, % 98.4, % 97.4 ve % 98.5 ortalama doğruluk oranlarıyla (altı kusura ait sonuçların ortalaması) tespit etmiştir (Du and Sun, 2006). Dalen (2004) pirinç için önemli bir konu olan kırık tane oranını görüntü analizi ve istatistiksel motif tanımadan faydalanarak beş pirinç türünün hepsinde % 90'dan fazla doğrulukta tespit etmiştir.

Rashidi et al (2007) kivi meyvesinin hacmini görüntü analizi ve disk yöntemiyle belirleyerek % 95 güven düzeyinde GAS sonuçları ile su taşıma yöntemi sonuçları arasında istatistiksel olarak önemli bir fark olmadığını ortaya koymuştur.

Daha önce yapılan çalışmalar göz önüne alındığında GAS'nin ve YSA'nın doğruluğu yüksek sonuçlar ürettiği görülmektedir. Geçmiş çalışmalarla karşılaştırıldığında çalışma kapsamında oluşturulan GAS'nin renk kusurlarını tespit etmekte yeterince başarılı olduğu, iyi taneleri kabul edilebilir sarımtırak renkli tanelerden ayırt etmekte ise daha başarılı olduğu görülmektedir.

Buruşuk tanelerin belirlenmesi ile ilgili hububatlar için bir çalışmaya rastlanılmamıştır. Ancak bakliyalarda buruşuk tanelerin kusurlu taneler olduğu ve kalite sınıflandırmasında önem arz ettiği düşünülürse buruşuk tanelerin nohut ve



Şekil 4.16. MatLab programıyla oluşturulan kullanıcı ara yüzü.

fasulye için sırasıyla % 96.0 ve % 86.1 doğrulukta belirlenebilmesi literatüre önemli bir katkı sağlamaktadır. Kırık tane oranının tespiti, pirinç işlenmesinde önemli bir konu olduğu için literatürde daha çok bu konuya yönelik çalışmalara rastlanmaktadır. Çalışma kapsamında nohut örneklerinde % 93.0 ve fasulye örneklerinde % 95.9 doğrulukta kırık tane belirlenmesi gerçekleştirilerek literatürdeki çalışmalara bakliyatlarla yönelik katkıda bulunulmuştur.

Boyut ölçümlerinde de tutarlı ve doğru sonuçlar üreten GAS, elek analizi gibi zaman ve emek isteyen yöntemlere hızlı ve zahmetsiz bir alternatif olmaktadır.

Çalışma sonuçları GAS'nin nitel ve nicel değerlendirmelerde doğru, anlamlı ve tutarlı veriler ürettiği ve insanı simüle etmekte başarılı olduğunu açıkça ortaya koymaktadır. Tüm değerlendirmelerde zaman ve işgücü açısından büyük avantaj sağlamanın yanında nitel değerlendirmelerde de objektif sonuçlar üretmekle GAS üstünlüğünü göstermektedir.

Çalışma, üzerinde az çalışılan bakliyatların görüntü işleme ile değerlendirilmesi ve benzer konulara katkı sağlamanın yanında işgücü ve zamandan tasarruf sağlayacak bir cihazın geliştirilmesine de yol açmaktadır. Sistem bir ticari ürün haline getirilebilirse, hububatlarda kullanılan benzer ürünlerin yaygınlığını da göz önüne alırsak, bir eksikliği doldurmanın yanı sıra, dışa bağımlılığı ortadan kaldıracaktır.

KAYNAKLAR

- Anonim, 2008a, TS 142, Nohut. Ankara, Türk Standartları Enstitüsü
- Anonim, 2008b, TS 141, Kuru Fasulye, Ankara, Türk Standartları Enstitüsü
- Ballard, D.H. and Brown, C.M., 1982, Computer Vision, Prentice Hall Inc., New Jersey, 539s
- Beyera, M., Hahn, R., Peschela, S., Harza, M., Knoche, M., 2002, Analysing fruit shape in sweet cherry (*Prunus avium* L.), *Scientia Horticulturae* 96, 139-150
- Blasco, J., Aleixos, N., Gómez, J., Moltó, E., 2007, Citrus sorting by identification of the most common defects using multispectral computer vision, *Journal of Food Engineering* 83, 384–393
- Brosnan, T., and Sun, D. W., 2004, Improving quality inspection of food products by computer vision: a review, *Journal of Food Engineering* 61, 3–16
- Brosnan, T., and Sun, D. W., 2002, Inspection and grading of agricultural and food products by computer vision systems; a review, *Computers and Electronics in Agriculture* 36, 193-213
- Çakmak, Y.S., and Boyacı, İ.H., 2011, Quality evaluation of chickpeas using artificial neural network integrated computer vision system, *International Journal of Food Science and Technology* 46, 194-200
- Dalen, G., 2004, Determination of the size distribution and percentage of broken kernels of rice using flatbed scanning and image analysis, *Food Research International* 37, 51–58
- Demirbaş, H.Y., Dursun, İ., 2007, Buğday Tanelerinin Bazı Fiziksel Özelliklerinin Görüntü İşleme Tekniğiyle Belirlenmesi, *Ankara Üniversitesi Ziraat Fakültesi Tarım Bilimleri Dergisi* 13 (3), 176-185
- Du, C. J., and Sun, D. W., 2006, Learning techniques used in computer vision for food quality evaluation: a review. *Journal of Food Engineering*, 72, 39–55.
- Du, C. J., and Sun, D. W. 2004, Recent developments in the applications of image processing techniques for food quality evaluation. *Trends in Food Science and Technology*, 15, 230–249.
- Durmuş, E.F., Šárka, E., Bubníka, Z., Kadleca, P., 2010, Size properties of legume seeds of different varieties using image analysis, *Journal of Food Engineering* 99, 445-451

- Durmuş, E.F., Šárkaa, E., Bubníka, Z., 2008, Image Vision Technology for the Characterisation of Shape and Geometrical Properties of Two Varieties of Lentil Grown in Turkey, *Czech Journal of Food Sciences* 26, 109-116
- FAO, 2011, <http://faostat.fao.org/site/613/DesktopDefault.aspx?PageID=613#ancor>, <http://faostat.fao.org/site/567/DesktopDefault.aspx?PageID=567#ancor>.
- Fernandez, L., Castellero, C. and Aguilera, J. M., 2005, An application of image analysis to dehydration of apple discs. *Journal of Food Engineering*, 67, 185–193.
- Gonzalez, R.C. and Woods, R.E., 2008, *Digital Image Processing*, 3rd Edition, Pearson Prentice Hall, Jersey, 577s.
- Granitto, P.M., Navone, D.H., Verdes, P.F., Ceccatto, H. A., 2002, Weed seeds identification by machine vision, *Computers and Electronics in Agriculture* 33, 91-103
- Haykin, S., 1999, *Neural Networks, A comprehensive foundation*, 2nd Edition, Prentice Hall, Pearson Education, Delhi 823p
- Himstedt, M., Fricke, T., Wachendorf, M., 2009, Determining the Contribution of Legumes in Legume–Grass Mixtures Using Digital Image Analysis, *Crop Science* 49, 1910–1916
- Igathinathane, C., Pordesimo, L.O. and Batchelor, W.D., 2009, Major orthogonal dimensions measurement of food grains by machine vision using ImageJ, *Food Research International* 42, 76-84
- Jha, G.K., 2011, http://www.iasri.res.in/ebook/EBADAT/5-Modeling%20and%20Forecasting%20Techniques%20in%20Agriculture/5-ANN_GKJHA_2007.pdf
- Kılıç, K., Boyacı, İ.H., Köksel, H. and Küsmenoğlu, İ., 2007a, A classification system for beans using computer vision system and artificial neural networks, *Journal of Food Engineering* 78, 897–904
- Kılıç K., B. Önal-Ulusoy, M. Yıldırım, İ.H. Boyacı, 2007b, Scanner Based Color Measurement in L*a*b* Format with Artificial Neural Networks (ANN), *European Food Research and Technology* 226, 121-126.
- Kılıç, K., 2007, *Yapay Sinir Ağı Tasarımı: Eğitim Sürecinin Optimizasyonu Ve Gıda Mühendisliği Alanında Uygulanması*, Yüksek Lisans Tezi, Hacettepe Üniversitesi Fen Bilimleri Enstitüsü. Ankara, 79s
- Koç, A.B., 2007, Determination of watermelon volume using ellipsoid approximation and image processing, *Postharvest Biology and Technology* 45, 366–371

- Laurent, B., Ousman, B., Dzudie, T., Carl, M., Emmanuel, T., 2010, Digital camera images processing of hard-to-cook beans, *Journal of Engineering and Technology Research* 2, 177-188
- Leemans, V., Magein H., Destain, M.F., 1999, Defect segmentation on 'Jonagold' apples using colour vision and a Bayesian classification method, *Computers and Electronics in Agriculture* 23, 143-53
- León, K., Mery D., Pedreschi F., León, J., 2006, Color measurement in L*a*b* units from RGB digital images, *Food Research International* 39, 1084–1091
- Lou, W. and Nakai, S., 2001, Application of artificial neural networks for predicting the thermal inactivation of bacteria: a combined effect of temperature, pH and water activity. *Food Research International*, 34, 573–579.
- Manickavasagana, A., Sathya, G., Jayasa, D.S., White, N.D.G., 2008, Wheat class identification using monochrome images, *Journal of Cereal Science* 47, 518–527
- Maoa, J. and Jain, A.K., 1992, Texture classification and segmentation using multiresolution simultaneous autoregressive models, *Pattern Recognition* 25, 173-188
- Matlab Toolboxes Help Desk, 2005, <http://www.mathworks.com/access/helpdesk/help/helpdesk.html>.
- Mattson, S. G. and Pandit, S. M., 2006, Statistical moments of autoregressive model residuals for damage localisation. *Mechanical Systems and Signal Processing* 20, 627–645.
- Mendozaa, F., Dejmekb, P., Aguilera, J.M., 2006, Calibrated color measurements of agricultural foods using image analysis *Postharvest Biology and Technology* 41, 285–295
- Myler, R.H. and Weeks, A.R., 1993, *Computer imaging recipes in C*, Prentice Hall Inc., New Jersey, 284s
- Öztemel, E., 2003, *Yapay sinir ağları*, Papatya Yayıncılık, Ankara, 232s.
- Pedreschi, F., León, J., Mery, D., Moyano, P., 2006, Development of a computer vision system to measure the color of potato chips, *Food Research International* 39, 1092–1098
- Rashidi, M., Seyfi, K., Gholami, M., 2007, Determination Of Kiwifruit Volume Using Image Processing, *Asian Research Publishing Network, Journal Of Agricultural And Biological Science*, Vol. 2, 17-22

- Sapirstein, H.D., Neuman, M. E., Wright, H. Shwedyk, E., Bushuk, W., 1987, An instrumental system for cereal grain classification using digital image analysis, *Journal of Cereal Science* 6, 3-14
- Shannon, C.E., 1948, A Mathematical Theory of Communication, *Bell System Technical Journal*, 27, 379–423
- Sun, D.W., 2007, *Computer Vision Technology for Food Quality Evaluation*, Elsevier, Amsterdam, 600p
- Sun, D.W. and Brosnan, T., 2003, Pizza quality evaluation using computer vision, Part 2: Pizza topping analysis, *Journal of Food Engineering* 57, 91-95
- Sabliov, C. M., Boldor, D., Keener, K. M., Farkas B. E., 2002, Image Processing Method To Determine Surface Area And Volume Of Axi-Symmetric Agricultural Products, *International Journal Of Food Properties* Vol. 5, No. 3, 641–653
- Tan, F. J., Morgan, M. T., Ludas, L. I., Forrest, J. C., Gerrard, D.C., 2000, Assessment of fresh pork colour with colour machine vision, *Journal of Animal Science*, 78(12), 3078–3085.
- Tao, Y. and Wen, Z., 1999, An adaptive spherical image transform for high-speed fruit defect detection, *Transaction of the ASAE*, 42(1), 241ansac
- Tkalčič, M. and Tasič, J.F., 2003, http://ldos.fe.uni-lj.si/docs/documents/20030929092037_markot.pdf.
- Türkoğlu, İ., 2003, Örüntü Tanıma Sistemleri, Ders Notları, Fırat Üniversitesi Fen Bilimleri Enstitüsü, Elazığ, 53s.
- USDA, 2011, http://www.nal.usda.gov/fnic/foodcomp/cgi-bin/list_nut_edit.pl.
- Utku, H. and Köksel, H., 1998, Use of Statistical Filters in the Classification of Wheats by Image Analysis, *Journal of Food Engineering* 36, 385-394
- Venora, G., Grillo, O., Shahin, M.A., Symons, S.J., 2007, Identification of Sicilian landraces and Canadian cultivars of lentil using an image analysis system, *Food Research International* 40, 161-166
- Wang, T.Y. and Nguang, S.K., 2007, Low cost sensor for volume and surface area computation of axi-symmetric agricultural products, *Journal of Food Engineering* 79, 870–877
- Warnes, M. R., Glassey, J., Montague, G. A., Kara, B., 1998, Application of radial basis function and feedword artificial neural networks to the *Escherichia coli* fermentation process. *Neurocomputing*, 20, 67–82.

- Wigger, W.D., Paulsen, M.R., Litchfield, J.B., 1988, Classification of fungal-damaged soybeans using color-image processing, American Society of Agricultural Engineers 88, 3053
- Wilson, J., 2011, Volume of a Frustum of a Cone, The University of Georgia Mathematics Education.
<http://jwilson.coe.uga.edu/emt725/Frustum/Frustum.cone.html>
- Xing, J., Saeys, W., Baerdemaeker, J., 2007, Combination of chemometric tools and image processing for bruise detection on apples, Computers and Electronics in Agriculture 56, 1–13
- Zapotocznya, P., Zielinskaa, M., Nitab, Z., 2008, Application of image analysis for the varietal classification of barley: Morphological features, Journal of Cereal Science 48, 104–110

EK 1

Çalışma kapsamında kullanılan yazılımın MatLab kodları;

```
%ÖLÇÜMLER;
clear all
close all
I = imread('Jun1802.jpg');
level = graythresh(I);
bw = im2bw(I,level);
bw = imfill(bw,'holes');
bw = bwareaopen(bw,400);

[L,q] = bwlabeln(bw);
ori = regionprops(L, 'Orientation');
or =cat(1, ori.Orientation);
ala = regionprops(L, 'Area');
alan(1,:) =cat(1, ala.Area);
ss = regionprops(L, 'BoundingBox');
bbs =cat(1, ss.BoundingBox);

for i=1:n
    a1=round(bbs(i,1));
    a2=round(bbs(i,2));
    a3=a1+bbs(i,3);
    a4=a2+bbs(i,4);
    aa=L(a2:a4,a1:a3);
    an=-or(i);
    B = imrotate(aa,an);
    BB=im2bw(B);
    s = regionprops(B, 'BoundingBox');
    bb =cat(1, s.BoundingBox);
    en(i,1)=max(sum(BB))/7.874016
    boy(i,1)=max(sum(BB'))/7.874016;

    caplar=sum(BB);
    [e f]=size(B);

    for t=1:f-1
        diskler(t,1)=pi/3*((caplar(1,t)/2)^2+(caplar(1,t+1)/2)^2+(caplar(1,t)/2)
            *(caplar(1,t+1))/2);
    end

    hacim(i,1)=sum(diskler);
end
sum(hacim);
```


%NİTEL DEĞERLENDİRMELER

```
for i=1:n
v=i;
[r,c] = find(L==v);
rc = [r c];
[kk ll]=size(rc);

for x=1:kk;
AA1(x)=l(rc(x,1), rc(x,2),1);

AA2(x)=l(rc(x,1), rc(x,2),2);

AA3(x)=l(rc(x,1), rc(x,2),3);
end

AAA1=double(AA1);
AAA2=double(AA2);
AAA3=double(AA3);

%ortalama
ort(i,1)=mean(AAA1);
ort(i,2)=mean(AAA2);
ort(i,3)=mean(AAA3);

%Standart sapma
Std(i,1)=std(AAA1);
Std(i,2)=std(AAA2);
Std(i,3)=std(AAA3);

%Çarpıklık
Carpklk(i,1)=skewness(AAA1);
Carpklk(i,2)=skewness(AAA2);
Carpklk(i,3)=skewness(AAA3);
%Basıklık
Basklk(i,1)=kurtosis(AAA1);
Basklk(i,2)=kurtosis(AAA2);
Basklk(i,3)=kurtosis(AAA3);
end
for i=1:n
ortsap(i,:)=ort(i,:)-SeriOrt
end
for i=1:n
veri(1,i)=ort(i,1);
veri(2,i)=ort(i,2);
veri(3,i)=ort(i,3);
veri(4,i)=Std(i,1);
veri(5,i)=Std(i,2);
veri(6,i)=Std(i,3);
veri(7,i)=Carpklk(i,1);
```

```

veri(8,i)=Carpklk(i,2);
veri(9,i)=Carpklk(i,3);
veri(10,i)=Basklk(i,1);
veri(11,i)=Basklk(i,2);
veri(12,i)=Basklk(i,3);

end

load net;
Output1=sim(net,veri);

l=rangefilt(l);

A1(x)=l(rc(x,1), rc(x,2),1);
A2(x)=l(rc(x,1), rc(x,2),2);
A3(x)=l(rc(x,1), rc(x,2),3);
A1=double(A1);
A2=double(A2);
A3=double(A3);

A1=A1/255;
A2=A2/255;
A3=A3/255;
for i=1:n
input(i,1)=mean(A1);
input(i,2)=mean(A2);
input(i,3)=mean(A3);
input(i,1)=std(A1);
input(i,2)=std(A2);
input(i,3)=std(A3);
input(i,4)=skewness(A1);
input(i,5)=skewness(A2);
input(i,6)=skewness(A3);
input(i,7)=kurtosis(A1);
input(i,8)=kurtosis(A2);
input(i,9)=kurtosis(A3);
end
load net2
Output2=(sim(net2,input'))';

bw1 = bwareaopen(bw,400);

se90 = strel('line', 3, 90);
se0 = strel('line', 3, 0);

BWsdil = imdilate(bw, [se90 se0]);
BWdfill = imfill(BWsdil, 'holes');
BWnobord = imclearborder(BWdfill, 4);

BWoutline = bwperim(BWnobord);

```

```

Segout = BWdfill;
Segout(BWoutline) = 255;

[L,n]=BWLabel(BWoutline);

grainveri = regionprops(L,'basic');
for i=1:n
    Centers(i,:)=grainveri(i).Centroid;
end

for i=1:n
[r,c] = find(L==i);
rc = [r c];

[p,q]=size(rc);

for v=1:p
    hipotenuss(v,1)=(((rc(v,1)-Centers(i,2))^2+(rc(v,2)-Centers(i,1))^2))^0.5;
end

ort=mean(hipotenuss);
for v=1:p
    hipotenus(v,1)= hipotenuss(v,1);
end
statistical(i,1)=std(hipotenus);
statistical(i,2)=skewness(hipotenus);
statistical(i,3)=kurtosis(hipotenus);
end

load net3
Output3=sim(net3,statistical);

```

ÖZGEÇMİŞ

Adı Soyadı : Yusuf Serhad ÇAKMAK

Doğum Yeri : Malatya

Doğum Yılı : 1984

Medeni Hali : Evli

Eğitim ve Akademik Durumu:

Lise 1998.-2001 Malatya Fatih Lisesi

Lisans 2003-2007 Hacettepe Üniversitesi Gıda Mühendisliği Bölümü

Yabancı Dil: İngilizce

İş Tecrübesi:

2009'dan bu yana, Tarım ve Kırsal Kalkınmayı Destekleme Kurumu, Kontrol Uzmanı

Yayın;

Çakmak Y.S. and İ.H. Boyacı, Quality evaluation of chickpeas using artificial neural network integrated computer vision system, International Journal of Food Science and Technology, 2011.

Bildiri;

Çakmak Y.S., İ.H. Boyacı, Development of computer vision system,for quality evaluation of chickpeas,1st International Congress on Food Technology, Meeting Abstract Book, P658, November 03-06, 2010.