

**GÖRÜNTÜ İŞLEME TEKNOLOJİSİ VE YAPAY SİNİR
AĞLARININ GIDA ÜRÜNLERİNDE BAZI KALİTE
ÖZELLİKLERİNİN BELİRLENMESİNDE
KULLANILMASI**

Hasan Murat VELİOĞLU

Doktora Tezi

Gıda Mühendisliği Anabilim Dalı

1.Danışman: Prof. Dr. Şefik KURULTAY

2.Danışman: Prof. Dr. İsmail Hakkı BOYACI

2010

T.C.
NAMIK KEMAL ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

DOKTORA TEZİ

GÖRÜNTÜ İŞLEME TEKNOLOJİSİ VE YAPAY SİNİR AĞLARININ
GIDA ÜRÜNLERİNDE BAZI KALİTE ÖZELLİKLERİNİN BELİRLENMESİNDE
KULLANILMASI

Hasan Murat VELİOĞLU

GIDA MÜHENDİSLİĞİ ANABİLİM DALI

1.DANIŞMAN: Prof. Dr. Şefik KURULTAY
2.DANIŞMAN: Prof. Dr. İsmail Hakkı BOYACI

TEKİRDAĞ-2010

Her hakkı saklıdır

EK 3

Prof. Dr. Şefik KURULTAY danışmanlığında, Hasan Murat VELİOĞLU tarafından hazırlanan bu çalışma aşağıdaki jüri tarafından Gıda Mühendisliği Anabilim Dalı'nda Doktora tezi olarak kabul edilmiştir.

Juri Başkanı : Prof. Dr. Erdoğan KÜÇÜKÖNER *İmza :*

Üye : Prof. Dr. Şefik KURULTAY (Danışman) *İmza :*

Üye : Prof. Dr. İsmail Hakkı BOYACI (İkinci Danışman) *İmza :*

Üye : Doç. Dr. İsmail YILMAZ *İmza :*

Üye : Yrd. Doç. Dr. Levent COŞKUNTUNA *İmza :*

Fen Bilimleri Enstitüsü Yönetim Kurulunun tarih ve sayılı
kararıyla onaylanmıştır.

Doç. Dr. Fatih KONUKÇU
Enstitü Müdürü

ÖZET

Doktora Tezi

GÖRÜNTÜ İŞLEME TEKNOLOJİSİ VE YAPAY SİNİR AĞLARININ GIDA ÜRÜNLERİNDE BAZI KALİTE ÖZELLİKLERİNİN BELİRLENMESİNDE KULLANILMASI

Hasan Murat VELİOĞLU

Namık Kemal Üniversitesi
Fen Bilimleri Enstitüsü
Gıda Mühendisliği Anabilim Dalı

1.Danışman : Prof. Dr. Şefik KURULTAY
2.Danışman : Prof. Dr. İsmail Hakkı BOYACI

Bu çalışmada, görüntü işleme teknolojisi ve yapay sinir ağları kullanarak üç farklı gıda maddesinin bazı kalite özellikleri belirlenmeye çalışılmıştır. Çalışmanın ilk bölümünde, 3 faktörlü merkezi kompozit deney tasarımı ile hamburger köftelerinde pişme sonrası yağ, su ve boyut kaybına ürün bileşiminde bulunan yağ (% 15-30), su (% 10-20) ve tekstüre soya proteini (% 3-9) oranlarının etkisi incelenmiştir. Hamburger köftelerinin boyut küçülmesinin belirlenmesinde görüntü işleme teknolojisi kullanılmıştır. Yağ ve su kaybının azaltılmasında tekstüre soya proteini (TSP) en önemli faktör olarak belirlenmiştir. Yağ ve su oranlarının, boyut küçülmesi ve su kaybı için elde edilen model eşitliklerde doğrusal etkileri önemli ($P < 0,05$) bulunmuştur. Boyut küçülmesine yağ, su ve TSP oranları da doğrusal olarak etki etmiştir. Yağ kaybı için oluşturulan model doğrusal ve ikinci dereceden olduğu halde, su kaybı için elde edilen model tam ikinci derecedendir. Boyut küçülmesi, yağ kaybı ve su kaybı için elde edilen model eşitliklerin R^2 değerleri sırasıyla 0,954, 0,969 ve 0,964 olarak belirlenmiştir.

Çalışmanın ikinci bölümünde, domates salçasının rengini CIE L^* , a^* , b^* formatında belirlemek ve üründeki siyah benekleri sayarak boyutlarına göre sınıflandırmak amacıyla görüntü işleme sistemine (GİS) yapay sinir ağları (YSA) entegre edilmiştir. GİS'nin siyah benekleri sayma ve sınıflandırmadaki etkinliği elde edilen sonuçların çıplak gözle kontrolör tarafından yapılan sonuçlarla karşılaştırılmasıyla belirlenmiştir. Renk ölçümünde ise YSA entegre edilmiş GİS sisteminin kolorimetre ile uyum içinde olduğu görülmüş olup, iki analiz arasındaki R değerleri L^* , a^* , b^* ve a^*/b^* için sırasıyla 0,889, 0,958, 0,907 ve 0,987 olarak belirlenmiştir. Daha sonra tüm sistem grafiksel kullanıcı arayüzüne (GKA) adapte edilerek domates salçası sektöründe çalışmakta olan deneyimsiz kişilerin dahi kullanabileceği bir program haline getirilmiştir. Klasik metotlarla yaklaşık 5 dakika sürmekte olan bir domates salçası numunesinin renk tayini, siyah benek sayımı ve sınıflandırması işlemlerinin GKA kullanıldığında 20-25 saniye içerisinde tamamlandığı belirlenmiştir.

Çalışmanın son kısmında 82 adet kuru incir örneğinde aflatoksin B1 ve toplam aflatoksin (B1, B2, G1, G2) analizi HPLC yöntemi ile yapılmıştır. Örneklerin her birinden 365 nm UV ışık altında yüksek çözünürlüklü görüntüler de alınarak görüntü işleme teknolojisi kullanılarak aflatoksin içeren örnekler belirlenmeye çalışılmıştır. Görüntülerin RGB (Red, Green, Blue) histogramları yazılan algoritma ile elde edilerek yeşil (G) ve mavi (B) renk yoğunlukları ile örneğin aflatoksin içermesi arasında bağıntı araştırılmıştır. Oluşturulan yapay sinir ağına RGB değerleri girdi olarak verilmiş ve aflatoksin var/yok (1/0) şeklinde çıktı alınmıştır. Ağın performansı eğitim verileri için $R=0,766$, validasyon verileri için $R=0,962$ ve test verileri için $R=0,899$ olarak belirlenmiştir. Görüntü işleme ve yapay sinir ağlarının kombinasyonundan oluşan yöntem aflatoksin içeren örnekleri belirlemede başarılı bulunmuştur.

Çalışma sonuçları görüntü işleme teknolojisi, yapay sinir ağları ve cevap yüzeyi yönteminin gıda mühendisliği uygulamalarında başarı ile kullanılabileceğini göstermiştir.

Anahtar kelimeler: Görüntü işleme teknolojisi, Yapay sinir ağları, Cevap yüzeyi yöntemi, Hamburger köftesi, Domates salçası, Kuru incir, Aflatoksin

2010 , 79 sayfa

ABSTRACT

Ph.D. Thesis

DETERMINATION OF SOME QUALITY PROPERTIES OF FOODS USING IMAGE PROCESSING TECHNOLOGY AND ARTIFICIAL NEURAL NETWORKS

Hasan Murat VELİOĞLU

Namık Kemal University
Graduate School of Natural and Applied Sciences
Department of Food Engineering

1.Supervisor : Prof. Dr. Şefik KURULTAY
2.Supervisor : Prof. Dr. İsmail Hakkı BOYACI

In this study, it was aimed to use image processing technology and artificial neural networks in determination of some quality properties of three different food products. In the first part of the study, a three-factor central composite design was adopted to determine the interactive effects of fat (15-30%), water (10-20%) and textured soy protein (3-9%) content on the shrinkage, fat loss and moisture loss of hamburger patties after cooking. Image processing was used to estimate the shrinkage of hamburger patties. Textured soy protein (TSP) content was found to be the most important factor for minimizing fat and moisture loss. Both fat and water content were found to be significantly effective ($P < 0.05$) in the model for shrinkage and moisture loss in linear form. The changes in shrinkage due to fat, water and TSP content were also in linear form. The model for fat loss was in linear and quadratic form, whereas the model for moisture loss was in full quadratic form. The models for shrinkage, fat loss and moisture loss had the R-square values of 0.954, 0.969 and 0.964, respectively.

In the second part of the study, an artificial neural network (ANN) integrated computerized inspection system (CIS) was developed to determine tomato paste color in CIE L^* , a^* , and b^* color format and the number and size of dark specks which exist in the product. The usability of CIS in the determination of the number and the size of dark specks in tomato paste were investigated by comparing the results of CIS and human inspector. In the color evaluation of the tomato paste, strong correlations (R) were found between the results estimated from ANN-integrated CIS and those obtained from colorimeter (0.889, 0.958, 0.907 and 0.987 for L^* , a^* , b^* and a^*/b^* , respectively). Whole system is adapted to a graphical user interface (GUI) for use of non-skilled person working in tomato paste sector. While classical methods need approximately 5 minutes, GUI needs 20-25 seconds to determine, count and classify the dark specks and to measure the product color.

In the last part of the study, aflatoxin B1 and total aflatoxin (B1, B2, G1, G2) quantity of 82 fig samples were determined with HPLC method. Also it was aimed to find out the samples including aflatoxin using image processing technology with the images of fig samples that were captured under 365 nm UV light. The relationship between the existence of aflatoxin and the intensity values of red (R), green (G) and blue (B) intensities of image histograms were investigated. An artificial neural network was designed to find the samples that include aflatoxin according to the RGB data used as input of the ANN. The performance (R) of the ANN for training, validation and testing data sets were 0.766, 0.962 and 0.899, respectively. The combined method of image processing and ANN was found appropriate for determination of samples that include aflatoxin.

The results of the present work showed that the image processing technology, artificial neural networks and the response surface methodology can be successfully used in food engineering applications.

Keywords: Image processing technology, Artificial neural networks, Response surface methodology, Hamburger patty, Tomato paste, Dried fig, Aflatoxin

2010, 79 pages

TEŐEKKÖR

Bu alıőmanın her aőamasında destek ve yardımlarını esirgemeyen deęerli danıőman hocalarım Prof. Dr. őefik KURULTAY ve Prof. Dr. İsmail Hakkı BOYACI'ya, laboratuvar analizleri sırasında sonsuz desteklerini gördüğüm mesai arkadaşlarım Araőtırma Görevlileri Gülnaz ELİKYURT, Kadir Gürbüz GÜNER ve Yüksek Lisans öęrencisi Duygu KORUCU'ya, tezimi maddi olarak destekleyen NKUBAP'a ve son olarak, yaptığım alıőmalar sırasında yardımlarını, desteęini ve sabrını esirgemeyen eőim ve mesai arkadaşım Araőtırma Görevlisi Serap DURAKLI VELİOęLU'na ve aileme en içten teőekkürlerimi sunarım.

SİMGELER ve KISALTMALAR DİZİNİ

Simgeler

α	Alfa
β	Beta
L^*	Beyazlık
a^*	Kırmızılık
b^*	Sarılık
g	Gram
μg	Mikrogram
μl	Mikrolitre
nm	Nanometre
R	Korelasyon katsayısı
R^2	Regresyon katsayısı

Kısaltmalar

ANOVA	Varyans analizi
AOAC	Association of Analytical Communities
CIE	Commission Internationale d'Eclairage
GİT	Görüntü İşleme Teknolojisi
HPLC	Yüksek performanslı sıvı kromatografisi
JPEG	Joint Photographic Experts Group
Matlab	Matrix Laboratory
RGB	Red, Green, Blue
TSP	Tekstüre Soya Proteini
USDA	Amerikan Tarım İdaresi
UV	Ultraviyole
YSA	Yapay Sinir Ağı

İÇİNDEKİLER	Sayfa No
ÖZET	i
ABSTRACT	ii
TEŞEKKÜR	iii
SİMGELER ve KISALTMALAR DİZİNİ	iv
İÇİNDEKİLER	v
ŞEKİLLER DİZİNİ	vii
ÇİZELGELER DİZİNİ	viii
1. GİRİŞ	1
2. KAYNAK ÖZETLERİ	3
2.1. Matlab Programı	3
2.2. Görüntü İşleme Teknolojisi	3
2.2.1. Görüntü işleme teknolojisinin gıda mühendisliği alanında uygulamaları	6
2.3. Yapay Sinir Ağları	9
2.3.1. Yapay sinir ağlarının gıda mühendisliği alanında uygulamaları	14
2.4. Cevap Yüzeyi Yöntemi	16
2.4.1. Cevap yüzeyi yönteminin gıda mühendisliği alanında uygulamaları	18
2.5. Hamburger Köftesinde Pişme Sonrası Oluşan Fiziksel Değişimler	20
2.6. Domates Salçasının Görsel Kalite Özellikleri	21
2.7. Kurutulmuş İncirlerde Aflatoksin Varlığı	24
3. MATERYAL VE YÖNTEM	27
3.1. Cevap Yüzeyi Yöntemi ve Görüntü İşleme Teknolojisi Kullanarak Köftelerde Fiziksel Kalite Özelliklerine Ürün Bileşenlerinin Etkilerinin Araştırılması	27
3.1.1. Hamburger köftesi	27
3.1.2. Görüntülerin alınması	30
3.1.3. Görüntü işleme	30
3.1.4. Kimyasal analizler	31
3.1.5. Matematiksel ve istatistiksel analizler	32
3.2. Domates Salçasında Görsel Kalite Özelliklerinin Görüntü İşleme Teknolojisi ve Yapay Sinir Ağları ile Belirlenmesi	33
3.2.1. Domates salçası	33
3.2.2. Kullanılan cihazlar	33
3.2.3. Siyah benek analizi	33
3.2.3.1. Örnek hazırlama, görsel sayım ve ölçüm	33

3.2.3.2. Görüntü alma	34
3.2.3.3. Görüntü segmentasyonu, siyah benek sayımı ve çap belirleme	34
3.2.3.4. Renk ölçümü için örnek hazırlama	36
3.2.3.5. L^* , a^* , b^* ölçümü	36
3.2.3.6. Görüntü alma ve işleme	36
3.2.3.7. Yapay sinir ağı dizaynı	36
3.3. Kuru İncirlerde Aflatoksin Tayini	37
3.3.1. Kuru incir	37
3.3.2. HPLC yöntemi ile aflatoksin tayini	38
3.3.3. Görüntü işleme teknolojisi ile aflatoksin tayini	39
3.3.3.1. Görüntü alma	39
3.3.3.2. Görüntülerin işlenmesi	39
3.3.3.3. Yapay sinir ağı tasarımı	40
4. ARAŞTIRMA BULGULARI VE TARTIŞMA	41
4.1. Hamburger Köftelerinin Fiziksel Kalite Özelliklerine Ürün Bileşenlerinin Etkileri	41
4.1.1. Sonuçlar	41
4.1.2. Boyut küçülmesi	42
4.1.3. Yağ kaybı	46
4.1.4. Su kaybı	48
4.2. Domates Salçasında Görsel Kalite Özelliklerinin Belirlenmesi	50
4.2.1. Siyah beneklerin belirlenmesi, çap ölçümü ve sınıflandırılması	50
4.2.2. Renk ölçümü	54
4.2.3. Grafıksel kullanıcı arayüzü tasarımı	58
4.3. Kuru İncirlerde Aflatoksin Varlığının Belirlenmesi	60
4.3.1. HPLC ile aflatoksin analizi	60
4.3.2. İncir görüntülerinin işlenmesi	61
4.3.3. Yapay sinir ağı ile aflatoksin tespiti	63
5. SONUÇ VE ÖNERİLER	65
5.1. Hamburger Köftelerinde Yağ, Su ve Boyut Kaybının Belirlenmesi	65
5.2. Domates Salçasında Renk ve Siyah Benek Belirlenmesi	65
5.3. Kuru İncirde Aflatoksin Belirlenmesi	66
KAYNAKLAR	67
EKLER	73
ÖZGEÇMİŞ	79

ŞEKİLLER DİZİNİ

Sayfa No

Şekil 2.1. Görüntü alma sistemi bileşenleri	5
Şekil 2.2. Biyolojik sinir hücresi	11
Şekil 2.3. Temel yapay sinir ağı bileşenleri	11
Şekil 2.4. Yapay sinir ağı çalışma prensibi	12
Şekil 2.5. Transfer fonksiyonları: (a) eşik değer fonksiyonu, (b) doğrusal fonksiyon, (c) sigmoid fonksiyonu	13
Şekil 2.6. (a) AFB ₁ , (b) AFB ₂ , (c) AFG ₁ ve (d) AFG ₂ 'nin kimyasal yapıları	25
Şekil 3.1. Hamburger köftesi üretim akım şeması	29
Şekil 3.2. Salçada siyah benek ve renk tayininde kullanılan algoritma	35
Şekil 4.1. Çiğ (a, b) ve pişmiş (c, d) hamburger köftesi örneklerinin orijinal (a,c) ve işlenmiş (b, d) görüntüleri.	41
Şekil 4.2. Bağımsız değişkenlerin (yağ, su, TSP) boyut küçülmesi üzerine etkisi	45
Şekil 4.3. Bağımsız değişkenlerin (yağ, su, TSP) yağ kaybı üzerine etkisi	47
Şekil 4.4. Bağımsız değişkenlerin (yağ, su, TSP) su kaybı üzerine etkisi	49
Şekil 4.5. Orijinal görüntü (a), segmente edilmiş görüntü (b), siyah-beyaz görüntü (c)	51
Şekil 4.6. Görüntü işleme ve klasik analiz ile belirlenen siyah benek sayısı ve çapları	53
Şekil 4.7. Yapay sinir ağının a*/b* için yaptığı tahminlere ait eğitim (a), validasyon (b), test (c) verisi grafikleri	57
Şekil 4.8. Grafikselleştirilmiş kullanıcı arayüzü tasarımı	59
Şekil 4.9. 365 nm UV ışık altında kuru incir görüntüsü	61
Şekil 4.10. Laboratuvar ortamında aflatoksin ilave edilen 10 adet ve aflatoksinsiz (kontrol) bir adet kuru incir örneği.	62

ÇİZELGELER DİZİNİ

Sayfa No

Çizelge 3.1. Kullanılan bileşenlerin deney aralıkları	27
Çizelge 3.2. Merkezi kompozit deney tasarımı	28
Çizelge 4.1. Deneysel sonuçlar	42
Çizelge 4.2. Boyut küçülmesi (BK), yağ kaybı (YK) ve su kaybı (SK) için denenen modellerin önem faktörleri ve R^2 değerleri	43
Çizelge 4.3. Rastgele seçilen 10 örnek için görüntü işleme (Gİ) ve klasik analiz (KA) ile siyah benek belirleme, sayım ve çap ölçümü sonucu elde edilen veriler	54
Çizelge 4.4. L^* , a^* , b^* ve a^*/b^* değerleri için sinir ağından elde edilen eğitim (E), validasyon (V) ve test (T) sonuçlarına ait regresyon katsayısı (R), grafik eğimi ve kesme noktası değerleri.	56
Çizelge 4.5. Piyasadan sağlanan kuru incirlerin RGB değerleri ve aflatoksin miktarları (ppb)	60
Çizelge 4.6. Laboratuvar ortamında elde edilen aflatoksinli örneklerin RGB yoğunluk değerleri	63

1. GİRİŞ

Bilgisayarlı görüntüleme sistemlerinin tarım ve gıda alanında kullanımı son dönemde oldukça önem kazanmıştır. Özellikle kalite kontrolü, standartlara uygunluk ve ürünün market değerinin artırılması amaçlarıyla görüntü işleme sistemleri sanayide kullanım alanı bulmaktadır. Bilgisayarlı görüntülemenin gıda maddelerinin renk yoğunluğu, renk dağılımı, görsel kusurları, boyutları ve şekli gibi görsel özelliklerinin objektif olarak belirlenmesinde başarıyla uygulandığı görülmektedir (Omid ve ark. 2010).

Benzer şekilde, son yıllarda, bilgisayarlar ve bilgisayar sistemleri insan hayatının vazgeçilmez bir parçası haline gelmiştir. Teknolojinin gelişmesi izlendiğinde, önceleri sadece elektronik veri transferi yapmak ve karmaşık hesaplamaları gerçekleştirmek üzere geliştirilen bilgisayarların zaman içerisinde büyük miktarlardaki verileri filtreleyerek özetleyebilen ve mevcut bilgileri kullanarak olaylar hakkında yorumlar yapabilen nitelikler kazandığı görülmektedir (Öztemel 2006).

Bilgisayar teknolojisinin gelişmesine paralel bir süreç izleyen yapay zeka, hem bilişsel sistemleri simule etmeyi (akılcı/insan gibi düşünme) hem de “akıllı” sistemler yapılandırmayı (akılcı/insan gibi davranma) kendine amaç edinmiş bir bilimsel disiplindir. Her iki çabanın da ortak yönü, bilginin akılcı ve insanda olduğu gibi işlenmesinin ilkelerini araştırıp bulmaktır. Burada bilgi kavramıyla kastedilen, öncelikle onun gündelik dildeki anlamıdır. Bu amaca hizmet eden temel teknik araç, sıkı bir biçimselleştirme gerektiren ama çıkarımları aracılığıyla örneksel gerçekleştirmeler sağlayan bilgisayardır (Görz ve Nebel 2005).

Yapay zeka bilimi kapsamında üzerinde en fazla çalışılan konulardan biri de yapay sinir ağlarıdır. Yapay sinir ağları, örneklerden olaylar arasındaki ilişkileri öğrenerek daha sonra hiç görmediği örnekler hakkında öğrendikleri bilgileri kullanarak karar veren sistemlerdir (Öztemel 2006). Bu sistemlerin diğer teknolojik uygulamalarla kombine şekilde kullanılması sonucu çok etkili otomasyon sistemleri tasarlanabilmektedir.

Ülkemizde üretilen, tüketilen, ihraç ve ithal edilen tarım ve gıda ürünlerinde genelde sıkıntı yaşanan alanlardan bazıları; üretimde standardizasyon, kalite kontrolündeki yetersizlikler, yapılan analizlerin zaman alıcı ve işgücüne bağımlı oluşu, hem üretimde hem de kalite

kontrolünde insan faktöründen kaynaklanan problemler ve basit analizlerde kullanılan cihazların bile yüksek maliyete sahip ithal cihazlar oluşudur.

Otomasyonun arttığı, bilgisayar ve akıllı sistemlerin dahil edildiği üretim süreçlerinin başarıları ile ilgili örnek gösterilen bir çok sektör ve ülke mevcuttur. Ülkemizde de sanayiden bu yönde bir talep olduğu, ancak otomasyon sistemlerinin yüksek maliyetlerinden dolayı tercih edilemediği gerçeği görülmektedir. Bu alanda ülkesel bazda üniversiteler ve araştırma kuruluşlarının çalışmaları her geçen gün artmakta olup, gıda ve tarım başta olmak üzere her türlü sanayinin kullanabileceği etkin ve maliyet avantajına sahip sistemlere ihtiyaç vardır.

Bu çalışmada; ekonomik olarak gelişmiş ülkelerde uzun yıllardır kullanılan ve ülkemizde de son yıllarda önem kazanmaya başlayan görüntü işleme teknolojisi ve/veya yapay sinir ağları ile oluşturulan sistemlerin bazı gıda maddelerinin kalite özelliklerinin belirlenmesinde kullanım olanakları araştırılmıştır.

2. KAYNAK ÖZETLERİ

2.1. Matlab Programı

MATLAB, çok yönlü bir teknik hesaplama ortamı olarak matematiksel işlemler, veri analizi ve işleme, görselleştirme ve kuvvetli bir programlama dili yapısı gibi gereksinimlerin bir birleşimidir (Anonim 2009a).

MATLAB, bilimsel çalışmalar ve mühendislik alanında kullanılabilecek matris esaslı bir sistemdir. Programlamaya çok yatkın olan MATLAB ile karmaşık sayısal problemler herhangi bir program yazmaksızın kolaylıkla çözülebilmektedir. MATLAB adı İngilizce Matrix Lab-oratory (Mat-ris Lab-oratuarı) kelimelerinden elde edilmiş bir kısaltmadır.

Bu çalışmada gıdaların görüntülerinin alınarak işlenmesinde Matlab programı ve içerisinde bulunan Görüntü İşleme Araç Kutusu (Image Processing Toolbox) kullanılmıştır. Görüntü işleme araç kutusu sahip olduğu bir çok özellik sayesinde;

- Uzaysal görüntü değişimi
- Yapısal işlemler
- Komşu ve blok piksel işlemleri
- Doğrusal filtreleme ve filtre tasarımları
- Dönüşümler
- Görüntü analizi ve iyileştirme
- Görüntü kaydetme
- Netleştirme,

gibi bir çok konuda görüntü işleme uygulamalarında kullanılabilmektedir (Anonim 2009b). Bu tez kapsamında da bu özelliklerin bir çoğu kullanılarak görüntü analizleri yapılmıştır.

2.2. Görüntü İşleme Teknolojisi

1960'lı yıllarda ortaya çıkan bilgisayarlı görüntüleme sistemleri, tıbbi tanı uygulamaları, fabrika otomasyonu, uzaktan izleme, adli uygulamalar, otonom araçlar ve robotik alanında her

geçen gün artan bir ivmeyle kullanılmaya başlanmıştır (Brosnan ve Sun 2004). Bilgisayarlı görüntüleme ile fiziksel objeler, görüntüleri kullanılarak, açık ve anlamlı bir şekilde tanımlanabilmektedir (Ballard ve Brown 1982).

Gıda endüstrisinde bazı kalite değerlendirmeleri halen eğitilmiş kontrolörler tarafından manuel olarak yapılmakta ve bu değerlendirmeler objektiflikten uzak olmanın yanında sıkıcı, zahmetli, maliyetli ve doğal olarak güvenilirliği şüpheli olarak kabul edilmektedir. Objektif, tutarlı ve rasyonel ölçüm sonuçlarına olan talep bilgisayar tabanlı görüntü işleme tekniklerinin gerekliliğini arttırmıştır. Son yıllarda bilgisayar destekli görüntü işleme teknikleri hızla gelişmiş ve gıdaların boyut, şekil, renk ve yapı özelliklerini sayısal olarak belirlemede yaygın olarak kullanılmaya başlanmıştır. Elde edilen doğru ve tutarlı sonuçlardan dolayı görüntü işleme sistemleri gıda kalite değerlendirmesinde her geçen gün daha önemli rol oynamakta ve manuel değerlendirmelerin yerini almaktadır. Bu sistemler uygulamada esneklik sağlamakta ve bu özellikleri ile insanlar tarafından yapılan görsel değerlendirmelerin yerini almaktadır (Du ve Sun 2004).


Görüntü işleme;

1. Görüntü bilgilerinin insan tarafından daha iyi anlaşılması,
 2. Görüntülerin otonom makinelerin algılaması için daha uygun hale getirilmesi
- amaçları için görüntünün yapısının değiştirilmesi işlemlerini kapsamaktadır (McAndrew 2004).

Gıda endüstrisinde bilgisayarlı görüntüleme uygulamalarında kullanılan en önemli veri görüntü özellikleri olarak da tanımlanan ve gıda kalitesinin bir indikatörü sayılan görsel özelliklerdir. Bu özellikler gıdanın kalitesi ile ilgili tanımlamalar yapmaya yardımcı olmakta ve önemli bir anlam taşımaktadır. Bilgisayarlı görüntüleme, bir bilgisayar sistemi ile elde edilen gıda görüntüleri her bir elemanı bir piksel olan matrisler şeklinde depolanır, işlenir ve görüntülenir. Piksellerin her biri gıda görüntüsünün ve dolayısıyla gıdanın görsel özellikleri hakkında bilgi taşımaktadır. Piksellerin sahip olduğu bu bilgilerin dışında, görüntü özellikleri verdiği bilgiler açısından 4 sınıfa ayrılabilir: Renk, boyut, şekil ve yapı. Renk, piksellerin yoğunluğu olarak tanımlanırken, boyut piksel sayısını ifade eder. Normalde herhangi bir maddenin boyut özellikleri hacmi ile yani üç boyutlu olarak algılanıp değerlendirilirken, görüntü işleme teknolojisinde tek veya iki boyut kullanılmaktadır. Gıda ürününün görüntü sınırları ise şekil hakkında bilgi verir. Yapıyı piksellerin birbiri arasında ve komşu pikseller

arasındaki bağıllık veya piksel yoğunluğundaki deęişimler belirlemektedir (Zheng ve ark. 2006).

Görüntü işleme sistemleri genel olarak 5 bileşenden oluşmaktadır: Işık kaynağı, görüntü alıcı (kamera, fotoğraf makinesi veya tarayıcı), sinyal çevirici (analog verileri dijital verilere çeviren kısım, günümüz bilgisayarlarında halihazırda bulunmaktadır), donanım (bilgisayar) ve yazılım (Bu çalışmada Matlab® R2007b paket programı ve görüntü işleme araç kutusu kullanılmıştır) (Wang ve Sun 2002). Bu çalışmada kullanılan sistemin bileşenleri Şekil 2.1’de verilmiştir.



Şekil 2.1. Görüntü alma sistemi bileşenleri.

Görüntü işleme teknolojisinde kullanılan genel metodoloji sırasıyla; görüntünün elde edilmesi, görüntünün ön işlenmesi, görüntünün kısımlara ayrılması (segmentasyon), ölçüm ve yorumlama aşamalarından oluşmaktadır (Zhang 2006).

Görüntünün elde edilmesi için kullanılan cihazlar kamera, dijital fotoğraf makinesi veya tarayıcı olabilmektedir. Alınan görüntüler bilgisayar ortamına aktarılarak depolanmakta ve sonrasında hazır bir paket programda yazılan algoritma ile işlenmektedir. Algoritma yazımında C++ gibi programlar kullanılabilir veya bu çalışmada yapıldığı gibi Matlab® programı kullanılarak hazır algoritmalara analizi yapılacak ürüne özgü eklemeler yapılarak

kullanışlı hale getirilebilir. Yapılan tüm görüntü analizi aşamaları ve kullanılan algoritmalar çalışmanın metot bölümünde açıklanmıştır.

2.2.1. Görüntü işleme teknolojisinin gıda mühendisliği alanında uygulamaları

Bilgisayarlı görüntüleme ve görüntü işleme teknolojisinin gıda ürünlerinin önemli bazı kalite özelliklerinin belirlenmesinde kullanımı, yöntemin hızlı, doğru ve objektif sonuçlar vermesi sebebiyle her geçen gün artmaktadır. Son yıllarda bu konuda yapılan bilimsel çalışmalar da bu teknolojinin gıdaların sınıflandırılması ve görsel kalitesinin belirlenmesinde sağlayabileceği faydaları ortaya koymaktadır.

Brosnan ve Sun (2004) tarafından görüntü işleme teknolojisi kullanılarak farklı gıda ürünlerinde sınıflandırma ve bazı kalite özelliklerinin belirlenmesine yönelik yapılan çalışmalar derlenmiştir. Bu derlemede, ekmek, kek, kurabiye gibi fırıncılık ürünlerinde boyut, renk, iç gözenek yapısı, şekil kusurları ve ürün hacmi gibi özelliklerin farklı araştırmacılar tarafından görüntü işleme teknolojisi ile belirlendiği bildirilmiştir. Aynı derlemede bildirildiğine göre; patates, mantar, lahana, bezelye ve brokoli gibi bir çok sebze, elma, armut, şeftali, domates, portakal, fındık, fıstık, badem, üzüm, çilek gibi bir çok meyvenin sınıflandırılması ve hatalı olanların ayrılması işleminde görüntü işleme teknolojisi kullanılmış ve renk, boyut, yüzeydeki kusurlar, şekil bozuklukları gibi özellikler sayısal olarak belirlenmiştir. Bu çalışmaların bir çoğunda elde edilen sonuçlar, insanlar tarafından yapılan ayırma ve sınıflandırma işlemi ile makineler tarafından yapılan işlem arasında % 80 ile % 98 arasında korelasyon göstermiştir.

Kılıç ve ark. (2007) tarafından yapılan çalışmada kuru fasulyelerin sınıflandırılması ve hasar görmüş ya da standart dışı tanelerin ayrılması işleminde görüntü işleme teknolojisi kullanılmıştır. Çalışmada elde edilen görüntüler kullanılarak fasulyelerin boyut ve renk özellikleri analiz edilmiştir. Bu sonuçlar yardımı ile objektif ve hızlı bir şekilde ayırma sağlanmış ve elde edilen sonuçlar kontrolörler tarafından yapılan kalite belirleme ve hatalı tanelerin ayrılması şeklinde özetlenebilecek sınıflandırma ile % 90,6 korelasyon sağlamıştır.

Görüntü işleme teknolojisi et ve et ürünlerinde de kalite özelliklerinin belirlenmesinde başarıyla kullanılmaktadır. Bu konuda son yıllarda yapılan çalışmalardan bazıları aşağıda özetlenmiştir.

Du ve Sun (2006a) tarafından yapılan çalışmada domuz jambonlarda oluşan gözenekler ve hava deliklerinin proses süresi, ürünün su içeriği ve yapısı ile olan ilişkisi görüntü işleme teknolojisi kullanılarak belirlenmeye çalışılmıştır. Araştırma materyali olarak kullanılan jambonlardan disk şeklinde dilimler alınarak siyah zemin üzerinde görüntüleri elde edilmiştir. Görüntü alma işleminde yüksek kalitede çekim yapabilen bir kamera, görüntülerin depolanması ve daha sonra işlenmesi için bilgisayar ve fotoğraflamanın standart koşullarda yapılabilmesi için dizayn edilmiş ve florasan lambalarla aydınlatılmış bir kabin kullanılmıştır. Elde edilen görüntüler daha önceki bölümlerde verilen görüntü işleme yöntemleri kullanılarak (segmentasyon, maskeleme, kontrast ayarı vb) bilgisayar ortamında yazılan algoritmalar ile üç aşamada analiz edilerek sayısal verilere çevrilmiştir. Çalışmanın sonucunda porozite, gözenek sayısı, gözenek boyutları ve bu boyutların dağılımı gibi verilerin proses süresi, ürünün su içeriği ve yapısı ile ilişkisi ortaya konmaya çalışılmıştır.

Du ve Sun (2006b) diğer bir çalışmada bilgisayarlı görüntülemeyi kullanarak elipsoidal şekle sahip olan jambonun yüzey alanı ve hacmini yaklaşık olarak tahmin etmeye çalışmışlardır. Üretilen 9 jambon örneğinin yüksek kalitede görüntüleri alınmış ve daha sonra bu görüntüler C++ ve Matlab ortamında oluşturulan algoritmalar yardımı ile segmentasyon, kirlilik azaltma, kenar belirleme işlemlerinden geçirilmiştir. Yine bilgisayar ortamında çap, uzunluk ve genişlikler ölçülerek kısımlandırma ve türevlendirme metodları ile hacimler belirlenmiştir. Bu işlemlere paralel olarak gerçekleştirilen basit hacim ölçme yönteminde ise jambon örneği su dolu bir kaba bırakılarak taşan su hacminden ürün hacmi belirlenmiştir. Her iki yöntem karşılaştırıldığında bilgisayarlı ölçüm ile klasik ölçüm arasında ortalama hataların kısımlandırma metodu ile yapılan hesaplamada % 1,79, türevlendirme metodu ile yapılan hesaplamada % 4,51 olduğu belirlenmiş ve bilgisayarlı hacim ve alan ölçümünün elipsoidal şekilli ürünlerde kullanılabilirliği ispatlanmaya çalışılmıştır.

Tan (2004) tarafından yayımlanan derlemede; araştırmacı ve ekibi tarafından Missouri Üniversitesi Biyoloji Mühendisliği Bölümü'nde görüntü işleme teknolojisi kullanılarak etlerin kalite değerlendirmesinin yapıldığı çalışmalar özetlenmiştir. Araştırmacılar bilgisayarlı görüntüleme ile çiğ ette renk, kas içi yağ dağılımı, olgunluk ve yapı gibi kalite özelliklerinin karakterizasyonu, duyu skor ve derecelerin tahmini ve pişmiş etin gevrekliğinin tahmini üzerine çalışmalar yapmışlardır. Çiğ et rengi ve kas içi yağ dağılımının görüntü işleme ile belirlenmesi ve et örneklerinin sınıflandırılmasında USDA kalite kriterleri karşılaştırma

amaçlı kullanılmıştır. Eğitimli panelistlerin yaptığı değerlendirme ve bilgisayar değerlendirmesi arasındaki korelasyon katsayısı 0,75 olarak bulunmuştur. Karkas olgunluğunun belirlenmesinde ise görüntü işleme yöntemi panelist değerlendirmeleri ile % 75 uyumlu bulunmuştur.

Jackman ve ark. (2008) araştırma materyali olarak kullandıkları, kesimi ve olgunlaştırılması pilot tesiste gerçekleştirilen, 32 genç danadan elde edilen *longissimus dorsi* kas grubuna ait biftekleri görüntü işleme teknolojisi ile analiz etmişlerdir. Renk, kas içi yağ dağılımı ve yüzey yapısının et olgunlaşmasının farklı günlerinde ve iki farklı görüntüleme tekniği ile incelendiği çalışmada bilgisayarlı görüntülemenin klasik duyuşal değerlendirmelerle uyum içerisinde olduğu, ancak yapay sinir ağıları yönteminin de kullanılması ile sonuçların daha da tutarlı ve anlamlı bir hal alacağı vurgulanmıştır.

Görüntü işleme teknolojisi kullanarak gıdaların bazı kalite özelliklerinin belirlenmesinde en önemli sorunlardan bir tanesi alınan görüntünün kalitesi ve bu görüntünün işlenmesi sırasında uygulanan yöntemlerin görüntü kalitesini ne kadar arttırabildiğidir. Yapılan çalışmalarda alınan görüntülerin kalitesini en iyi duruma getirebilmek için farklı metotlar kullanılmakta ve çalışmalar bu yöne doğru kaymaktadır.

Du ve ark. (2008) tarafından yapılan çalışmada *longissimus dorsi* kas grubundan alınan parça etlerde kas içi yağ dağılımının belirlenmesine çalışılmıştır. Daha önce yapılan benzer çalışmalardan farklı olarak, görüntü işlemede yeni algoritmalar denenmiş ve analizi yapılan görüntülerin daha anlamlı hale getirilmesine çalışılmıştır. Bu çalışmada da kas içinde dağılmış halde bulunan yağın yoğunluğu ve miktarı görüntü işleme ile belirlenerek ekstraksiyon yöntemi ile elde edilen sonuçlarla karşılaştırılmıştır. Yaklaşık % 85'lik bir korelasyona ulaşılan bu çalışma da görüntü işleme teknolojisinin kullanılabilirliği yönünden olumlu olarak değerlendirilmiştir.

Del Moral ve ark. (2007) yaptıkları çalışmada farklı türlere (domuz, dana, koyun ve güvercin) ait etlerin kas içi bağ doku miktarlarını, etlerin mikroskobik görüntülerini kullanarak, görüntü işleme teknolojisi ile belirlemeye ve bu değerlerle etlerin gevreklikleri arasında bir korelasyon bulmayı denemişlerdir. Kas içi bağ doku miktarının artması ile etin tüketilebilirliğinin azaldığı olgusundan yola çıkarak yaptıkları bu çalışmada mikroskobik görüntülerin işlenmesi

sonucu farklı tür hayvan etlerinin kas içi yağ dokusu miktarlarının değişimini ortaya koymuşlardır.

Deniz ürünlerinin bazı kalite özelliklerinin belirlenmesinde de görüntü işleme teknolojisinin başarıyla uygulanabileceğini gösteren çalışmalar mevcuttur. Somon balığı filetosunun görüntüsü kullanılarak balığın yağ içeriğinin belirlenmesi çalışmasında; Stien ve ark. (2007) et parçası üzerindeki kas ve yağın oluşturduğu kontrasttan faydalanarak toplam yağ oranı ile görüntüden elde edilen sonuçlar arasında yüksek bir korelasyona ($R=0,84$) ulaşmışlardır. Bu çalışmanın dayandığı temel fikir; filetonun yüzey görüntüsünde kırmızı renkli kas dokusu ile çizgi şeklinde dağılmış, nispeten açık renkli ve büyük oranda yağ içeren myocommata bölgeleri arasındaki kontrastın görüntü analizi yöntemleri ile artırılarak toplam yağ içeriği ile doğrusal ilişkisi olan açık renkli kısımların sayılmasıdır. Bir başka çalışmada materyal olarak 983 adet gökkuşuğu alabalığı kullanılmıştır (Stien ve ark. 2006). Balıkların yenilebilir kısımlarından alınan kesitlerin görüntüleri analiz edilerek yağ yüzdesi, et rengi ve kas parçasındaki morfolojik kısımların dağılım oranları belirlenmeye çalışılmıştır. Yapılan bu çalışma ile balıkların kalite yönünden sınıflandırılması amaçlanmış ve manuel yapılan değerlendirmeler ile bilgisayarlı görüntüleme ile elde edilen sonuçlar arasında morfolojik segmentasyon, sırt yağı oranı ve kırmızı kas dağılımı için R^2 değerleri sırasıyla 0,97, 0,95 ve 0,91 olarak belirlenmiştir.

Sonuç olarak tüm bu çalışmalar görüntü işleme teknolojisinin farklı gıda maddelerinin görsel kalite özelliklerini belirleme, bu özellikleri kullanarak bazı kantitatif sonuçlara ulaşma gibi amaçlarla gıda mühendisliği alanında başarı ile kullanılabilmesini göstermektedir. Bu çalışmanın birinci bölümünde çiğ ve pişmiş hamburger köftelerinin boyutları, ikinci bölümünde domates salçasında siyah benekler ve renk değeri, son bölümde ise aflatoxin içeren kuru incirlerin 365 nm UV ışık altındaki floresans ışımaları görüntü işleme teknolojisi ile kalitatif olarak belirlenmeye çalışılmıştır.

2.3. Yapay Sinir Ağları

Yazılı insanlık tarihi incelendiğinde temelleri yüzyıllar önce atılmış olan iki düşünce dikkat çekmektedir. Bunlardan ilki, yapay insan yaratma miti, yani ikinci bir insan türünün yaratılması düşüncesi, diğeri ise insana özgü akıl yetilerinin makineleştirilmesi düşüncesidir.

Bu iki hedefe ulaşmaya çalışan insanoğlu köklerini Antik Çağ'dan alan uzun bir gelişim tarihinin geçici bir doruk noktasına “Yapay Zeka” projesi ile ulaşmıştır (Görz ve Nebel 2005).

Günümüzde bilgisayarlar hem olaylar hakkında karar verebilmekte hem de olaylar arasındaki ilişkileri öğrenebilmektedir. Matematiksel olarak formülasyonu kurulamayan ve çözülmesi mümkün olmayan problemler sezgisel yöntemler yolu ile bilgisayarlar tarafından çözülebilmektedir. Bilgisayarları bu özelliklerle donatan ve bu yeteneklerinin gelişmesini sağlayan çalışmalar yapay zeka çalışmaları olarak bilinmektedir (Öztemel 2006).

Yapay zekanın esas amacı insanların davranışlarının ve sezgisel yeteneklerinin bilgisayarlara kazandırılmasıdır. Bilgiyi kullanmak ve işlemek insana ait özellikler olup bilgisayarlara bu karakteristikleri kazandırmak yapay zeka araştırmalarının hedefi olarak düşünülebilir.


Bir programın ya da sistemin zeki ya da akıllı olarak kabul edilebilmesi için, en azından aşağıdaki özelliklerden bazılarını sağlayabilmesi gerekir;

- Karar verme
- Algılama
- Öğrenme
- Problem çözme
- Muhakeme
- Şekil ya da resim tanıma
- Doğal dil anlama

Yapay zeka bilimi kapsamında üzerinde en fazla çalışılan konulardan biri de yapay sinir ağlarıdır. Yapay sinir ağları, örneklerden olaylar arasındaki ilişkileri öğrenerek daha sonra hiç görmediği örnekler hakkında öğrendikleri bilgileri kullanarak karar veren sistemlerdir (Öztemel 2006).

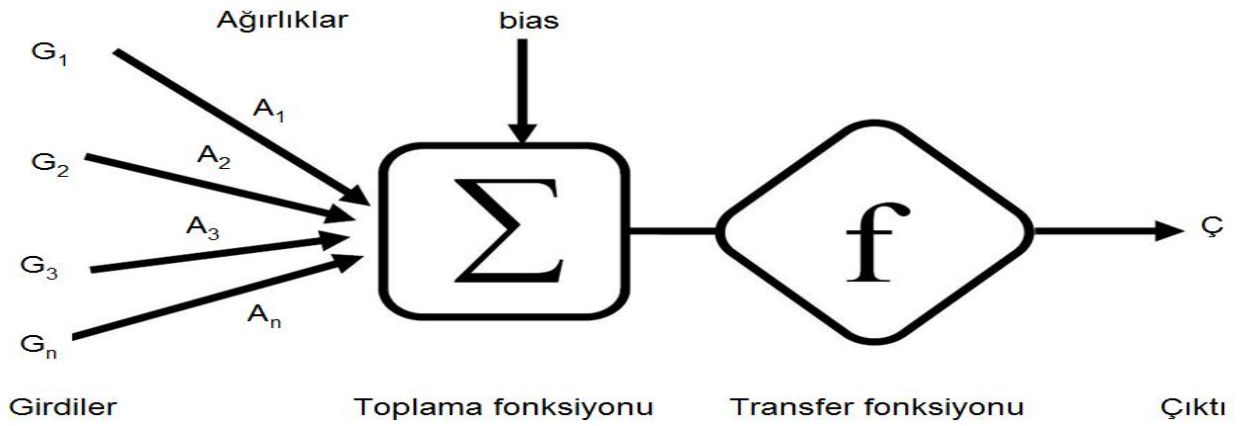
Yapay sinir ağları, nöron ismi verilen hesaplama elemanlarının paralel bir şekilde çalışmasından meydana gelir. Bu elemanlar Şekil 2.2'de bir hücresi gösterilen biyolojik sinir sistemlerinden esinlenerek tasarlanmıştır. Belirli bir fonksiyonu

gerçekleştirmek için bir sinir ağı, elemanlar arasındaki bağlantıların (ağırlıkların) değerleri ayarlanarak eğitilebilir.



Şekil 2.2. Biyolojik sinir hücresi

Biyolojik sinir ağlarının sinir hücreleri olduğu gibi yapay sinir ağlarının da yapay sinir hücreleri vardır. Yapay sinir hücreleri mühendislik biliminde proses elemanları olarak da adlandırılmaktadır (Öztemel 2006).



Şekil 2.3. Temel yapay sinir ağı bileşenleri


Şekil 2.3’de yapay sinir hücresinin basitleştirilmiş yapısı görülmektedir. Girdiler dış dünyadan alınan bilgileri, ağırlıklar hücreye gelen bilginin önemini ve yapay sinir hücresi üzerindeki etkisini gösterir. Hücreye gelen net girdinin hesaplanmasında toplama fonksiyonu kullanılır. Bias bir sabittir ve aktivasyon fonksiyonunun eşik değeri olarak da adlandırılır. Son olarak transfer fonksiyonu net girdinin işlenmesi ve çıktı olarak verilmesini gerçekleştirir.

Genelde, sinir ağları eğitilerek belirli bir girişe karşılık verilen arzu edilen çıkışı elde ederler. Bu durum Şekil 2.4’de verilmiştir. Ağın çıkışı arzu edilen hedefe ulaşıncaya kadar çıkış ile hedef karşılaştırılarak ağın eğitimi (ağırlık değerlerinin ayarlanması) gerçekleştirilir. En basit tanımıyla yapay sinir ağları, karmaşık matematiksel bağlantılar için bilinen en iyi eğri uydurma tekniklerinden birisidir (Neural Network Toolbox, Mathworks Inc.).



Şekil 2.4. Yapay sinir ağı çalışma prensibi

Yapay sinir ağlarının tasarımında, mevcut verilerle en doğru çıktıları elde etmek için, kullanılan transfer fonksiyonu ve eğitim fonksiyonu büyük önem taşımaktadır. Yapay sinir ağları tasarımında sıklıkla kullanılan transfer fonksiyonları Şekil 2.5’te verilmiştir.



Şekil 2.5. Transfer fonksiyonları: (a) eşik değer fonksiyonu, (b) doğrusal fonksiyon, (c) sigmoid fonksiyonu

Yapay sinir ağlarında proses elemanlarının bağlantılarının ağırlık değerlerinin belirlenmesi işlemine ağıın eğitilmesi denir. Başlangıçta bu ağırlık değerleri rastgele olarak atanır. Yapay sinir ağları kendilerine örnek gösterildikçe bu ağırlık değerlerini değiştirirler.

Ağıın eğitimi tamamlandıktan sonra öğrenip öğrenmediğini (performansını) ölçmek için yapılan denemelere ise ağıın test edilmesi denmektedir. Test etmek için ağıın öğrenme sırasında görmediği örnekler kullanılır. Ağ öğrenme sırasında belirlediği ağırlık değerleri ile çıktılar üretir. Bu çıktılar doğruluk derecesi ağıın performansını belirler (Öztemel 2006).

Yapay sinir ağı uygulamaları temel olarak şu sınıflara ayrılabilir:

- **Tahmin (prediction):** Uygulanan giriş değerlerinden bazı çıkış değerleri bulunmaya çalışılır. Hava durumu tahmini, kanser riskini belirleme buna örnek olarak verilebilir.
- **Sınıflandırma (classification):** Giriş değerleri kullanılarak sınıflandırma yapılır. Arıza sınıflandırma, karakter tanıma, hastalık teşhis etme bunlara örnek olarak verilebilir.
- **Veri ilişkilendirme (data association):** Bu sınıflandırmaya benzer bir yaklaşım gibi görünse de buna ilave olarak hatalı olan verileri tanımlar. Örnek olarak taranan bir dokümandaki karakterleri algılamamın yanında tarayıcının düzgün olarak çalışmadığını da algılayabilir.

- **Veri yorumlama (data conceptualization):** Giriş verisindeki gruplar arasındaki ilişkileri analiz etme işlemidir. Bir veri tabanındaki birbirine benzeyen verileri gruplandırma buna örnek olarak verilebilir.
- **Veri filtreleme (data filtering):** Giriş sinyalleri içerisindeki uygun olmayan verilerin ayıklanmasını sağlar. Bir telefon sinyali içerisinde bulunan gürültüyü ayıklama, bir resim üzerindeki parazitleri temizleme buna örnek olarak verilebilir (Sağiroğlu ve ark. 2003).

2.3.1. Yapay sinir ağlarının gıda mühendisliği alanında uygulamaları

Yapay sinir ağları paralel olarak çalışan basit elementlerden oluşmakta ve biyolojik sinir sistemini taklit etmektedir. Yapay sinir ağları son yıllarda farklı gıda proseslerinin optimizasyonunda, mikrobiyal aktivitenin tahmin edilmesinde ve bazı gıdaların görsel özelliklerinin belirlenmesinde kullanılmıştır.

Gonçalves ve ark. (2005) tarafından konserve gıdalara uygulanan ısı işlemin modellenmesinde yapay sinir ağları kullanılmıştır. Proses süresi ile beraber belirli t_i , t_{i-1} ve t_{i-2} zamanlarındaki otoklav ve soğuk nokta sıcaklıkları ağa girdi olarak verilmiştir. Ağdan elde edilen çıktı ise t_{i+1} anındaki soğuk nokta sıcaklığıdır. Ağın eğitiminde deneysel olarak otoklavda elde edilen zaman/sıcaklık veri seti kullanılmıştır. Çalışmada zamana bağlı geri yayımlı ve Jordan ağları kullanılmıştır. Ağların genelleme yetenekleri kıyaslandığında % 2,2 ortalama bağıl hata veren zamana bağlı geri yayımlı ağ daha başarılı bulunmuştur.

Torreçilla ve ark. (2005) yüksek basınçlı gıda prosesinde işlenen gıda örneğinin yüksek basınç altında ulaşacağı maksimum ve minimum sıcaklıklar ve ısısal dengeye ulaşılması için gereken zamanı yapay sinir ağları ile tahmin etmeye çalışmışlardır. Yapay sinir ağının eğitiminde veri olarak; uygulanan basınç, basınç artış hızı, ayarlanan sıcaklık, yüksek basınç kabini sıcaklığı ve ortam sıcaklığı kullanılmıştır. Araştırmacılar eğitim sonrası ağın yüksek bir başarı ile tahmin yapabildiğini ve gıda proseslerinin modellenmesinde yapay sinir ağlarının kullanımının uygun olduğunu belirtmişlerdir.

Movagharnjad ve Nikzad (2007) domatesin kurutulmasını modelledikleri çalışmada yapay sinir ağları ve farklı matematiksel eşitlikleri karşılaştırmışlardır. Kurutma prosesinde kullanılan ısıtıcının gücü ve hava akım hızı gibi değişkenleri kullanarak gerçekleştirdikleri

çalışma sonucunda yapay sinir ağlarını denenen tüm matematiksel eşitliklerden daha doğru sonuç verdiğini belirlemişlerdir.

Razmi-Rad ve ark. (2007) buğday unu hamurunun farinografik özellikleri ile unun protein içeriği, yaş gluten, sedimentasyon değeri ve düşme sayısı arasındaki korelasyonu belirlemeye yönelik yaptıkları araştırmada yapay sinir ağı kullanmışlardır. Ağın çıktıları olarak farinograf özelliklerinden; su tutma, hamur gelişim süresi, hamur stabilite süresi, 10 ve 20. dakikalardan sonraki hamur yumuşama derecesi ve valorimetrik değer elde edilmiştir. Geri yayımlı eğitim algoritması kullanılan çok katmanlı yapay sinir ağının girdiler ve çıktılar arasındaki en iyi bağıntıyı kurduğu belirlenmiştir. Çalışma sonucunda unun kimyasal özellikleri bilindiğinde elde edilecek hamurun farinografik özelliklerinin yapay sinir ağı ile yüksek bir doğrulukla belirlenebileceği belirtilmiştir.

Tripathy ve Kumar (2009) tarafından yapılan bir çalışmada, gıdaların güneşte kurutulması yapay sinir ağı ile modellenmiştir. Önemli iklimsel değişkenlerden solar radyasyon yoğunluğu ve çevre hava sıcaklığının girdi olarak verildiği yapay sinir ağından silindirik olarak dilimlenmiş patateslerin ulaştığı sıcaklık çıktı olarak alınmıştır. En uygun ağın belirlenmesi amacıyla yapılan denemeler sonunda en az hata ile tahmin yapabilen ağın 4 nöronlu, transfer fonksiyonu olarak 'logsig' ve 'trainrp' geri yayılım algoritmasının kullanıldığı ağın başarılı olduğu belirtilmiştir. Yapay sinir ağının ürettiği sonuçlar ile analitik ısı difüzyonu modeli ve istatistikî modellerin ürettiği sonuçlar karşılaştırılmış ve gıda maddesinin şeklinden bağımsız olarak yapay sinir ağının en doğru sonuçları verdiği bildirilmiştir.

Garcia-Gimeno ve ark. (2005) tarafından yapılan bir çalışmada sıcaklık, pH, tuz seviyesi ve sodyum nitrit seviyesinin *Leuconoctoc mesenteroides* in gelişme hızı, lag süresi ve maksimum popülasyon yoğunluğuna etkisi aerobik ve anaerobik şartlar altında yapay sinir ağı ile belirlenmesine çalışılmıştır. Yapay sinir ağı ile yapılan tahminlerde ağın gelişme hızı için % 2,82, lag süresi için % 6,05 ve maksimum popülasyon yoğunluğu için % 10 standart hata ile sonuç verdiği belirlenmiş ve mikrobiyal gelişmenin modellenmesinde aynı çalışmada kullanılan cevap yüzeyi yönteminden daha başarılı olduğu belirtilmiştir.

Yin ve Ding (2009) tarafından yapılan bir çalışmada toplam bakteri sayısı ve basil sayısı görüntü işleme teknolojisi ile belirlenmiş ve bu değerler her birinde 5 nöron bulunan iki gizli

katmana sahip yapay sinir ağına veri olarak beslenerek toplam koliform bakteri sayısı tahmin edilmeye çalışılmıştır. Yöntemde kullanılan ağın verdiği cevaplar ve yapılan deneysel çalışmaların sonuçları arasındaki korelasyon katsayısı 0,9716 olarak belirlenmiş olup, ağın tahmin yeteneği denenilen diğer modellerden (doğrusal regresyon, ikinci dereceden polinomal regresyon ve polinomal yüzey analizi) daha başarılı bulunmuştur.

Yapay sinir ağları gıda maddelerinin renklerinin ölçümünde de kullanılmaktadır. Kılıç ve ark. (2007) tarafından yapılan çalışmada; sıvı yağların renk değerleri spektrofotometreden elde edilen absorbans verileri kullanılarak yapay sinir ağları ile $L^*a^*b^*$ formatında tahmin edilmeye çalışılmıştır. Ağın ürettiği veriler ile deneysel olarak elde edilen veriler arasında korelasyon katsayıları L^* , a^* ve b^* için sırasıyla 0,989, 0,984 ve 0,996 olarak bulunmuştur.

Yapay sinir ağlarının gıda proseslerinde renk ölçümü için kullanıldığı bir başka çalışmada Valadez-Blanco ve ark. (2007) ekstrüzyon işlemi sırasında gıda maddesinde oluşan renk değişimini ve ekstrüderdeki rengin ürün son rengine etkisini araştırmışlardır. Çalışmada araştırmacılar ekstrüder içerisinde spektrofotometre ile ölçtükleri ürün rengini son ürün rengi ile ilişkilendirebilmek amacıyla birçok yapay sinir ağı denemişler ve sonuç olarak çok katmanlı, ileri beslemeli ve üç gizli nöron içeren yapay sinir ağı tasarımının girdi olarak spektrofotometre sonuçlarını alarak çıktı olarak son ürün rengini kabul edilebilir bir doğrulukla verdiğini belirtmişlerdir.

Daha önceki bölümlerde de vurgulandığı gibi yapay sinir ağları kendisine verilen girdilerden, model hakkında önceden herhangi bir bilgi olmadan ve modelin karmaşıklığından bağımsız olarak, çıktılar oluşturmaya çalışmakta olup, bu çalışmanın ikinci bölümünde salça görüntüsünün R, G ve B değerleri girdileri, L^* , a^* , b^* ve a^*/b^* değerleri ise çıktıları meydana getirmektedir. Üçüncü bölümde ise kuru incir görüntülerinin R, G ve B değerleri girdileri, incirde aflatoksin varlığı/yokluğu çıktıyı meydana getirmektedir.

2.4. Cevap Yüzeyi Yöntemi

Herhangi bir proses sonucunda elde edilen çıktı veya çıktılara, girdilerin etkisinin incelenebilmesi için her bir girdinin en alt ve en üst değerleri ve bu değerler arasında alabileceği ara değerlerin tek tek araştırılması gerekmektedir. Prosesin detaylı şekilde

incelenebilmesi için tasarlanan deneyler girdilerin olabilecek her seviyesi için fikir vermeli ve herhangi bir deney noktası ihmal edilmeden proses modellenmelidir.

Cevap yüzeyi yöntemi, sonucu birden fazla değişken tarafından etkilenen problemlerin ya da proseslerin modellenmesi, analiz edilmesi ve sonucun optimizasyonu için kullanılan matematiksel ve istatistiksel tekniklerin birleşimi olarak tanımlanmaktadır. Bir örnekle açıklamak gerekirse; herhangi bir prosesin veriminin (y) maksimize edilmesi için gerekli olan sıcaklık (x_1) ve basınç (x_2) değerlerinin belirlenmesini hedefleyen bir çalışmada verimi sıcaklık ve basınç değerlerinin fonksiyonu olarak,

$$y = f(x_1, x_2) + \varepsilon \quad (1)$$

şeklinde yazabiliriz. Burada ε sonuçtaki olası hatayı göstermektedir. Eğer araştırılan proses çıktısı $E(y) = f(x_1, x_2) = \eta$, şeklinde ifade edilirse, cevap yüzeyi;

$$\eta = f(x_1, x_2) \quad (2)$$

olacaktır (Montgomery 2001).

Görüldüğü gibi, cevap yüzeyi yöntemi değişkenlerin sonuca olan etkisini analiz etmenin ötesinde prosesin değişkenlerle ilişkisini ortaya koyan matematiksel modeller de oluşturmaktadır.

Cevap yüzeyi yöntemi ile yapılacak olan bir çalışmayı üç aşamada planlamak mümkündür. İlk aşamada çalışılacak prosesi etkileyen bağımsız değişkenlerin ve bu değişkenlerin bulunabileceği değer aralıklarının belirlenmesi gerekir. İkinci aşamada deneysel tasarımın seçilmesi ve elde edilen model eşitliğin doğrulamasının yapılması gerekir. Son olarak da optimum noktaların bulunması amacı ile model eşitlikler kullanılarak cevap yüzeyi grafiği ve kontor grafiğinin çizimi yapılır (Baş ve Boyacı 2007).

Birçok proseste çıktılar ve bağımsız değişkenler arasındaki ilişki başlangıçta belirsizdir. Bu yüzden, bağımsız değişkenler belirlendikten sonra, çıktı ile değişkenleri birbiri ile ilişkilendiren fonksiyonel ilişkinin doğru tanımlanması gerekir. Genelde ilk olarak düşük dereceli polinomal bağıntıların denenmesi ile başlayan modelleme süreci, eğer proses

doğrusal bir fonksiyonla tanımlanabilirse birinci dereceden modelin proses için uygun olduğu kararı ile sonuçlandırılır ve çıktı ile değişkenler arasındaki bağıntı,

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_k x_k + \varepsilon \quad (3)$$

şeklinde verilir.

Eğer prosesi tanımlayan fonksiyon daha yüksek dereceli ise ikinci dereceden modelin kullanılması düşünülür ve bağıntı,

$$y = \beta_0 + \sum_{i=1}^k \beta_i x_i + \sum_{i=1}^k \beta_{ii} x_i^2 + \sum_{i>j} \beta_{ij} x_i x_j + \varepsilon \quad (4)$$

şeklinde yazılır (Montgomery 2001). Buradaki β_0 , β_i , β_{ii} ve β_{ij} sırasıyla kesme noktası, doğrusal, ikinci derece ve interaksiyon katsayılarının regresyon katsayılarını, x_i ve x_j ise bağımsız değişkenleri göstermektedir (Baş ve Boyacı 2007).

Sonuç olarak yöntemin uygulanmasıyla elde edilen model eşitlik kullanılarak yüzey grafikleri çizilmekte, bağımsız değişkenlerin çıktıya olan etkileri ve ulaşılmak istenen optimum çıktı bu grafikler ve eşitlikler yardımı ile belirlenebilmektedir.

2.4.1. Cevap yüzeyi yönteminin gıda mühendisliği alanında uygulamaları

Son 20 yılda cevap yüzeyi yöntemi gıda bilimi ve teknolojisi alanında geniş çapta uygulama alanı bulmuştur. Yöntem sayesinde basit empirik modeller kullanarak sistem modellenenilmekte, sistemin cevabını etkileyen çok sayıda değişken bir arada ve eşzamanlı olarak incelenebilmekte ve prosesin işlem parametrelerindeki değişime verdiği cevap en az sayıda deneme yapılarak en iyi şekilde tanımlanabilmektedir (Koç ve Kaymak-Ertekin 2010). Gıda mühendisliği alanında son yıllarda cevap yüzey yönteminin kullanıldığı çalışmalar aşağıda özetlenmiştir.

Panda ve ark. (2010) tarafından yapılan çalışmada; *Monascus* cinsi küflerden katı ortam fermentasyonu ile lovastatin adlı bir metabolit üretimi cevap yüzeyi yöntemi ile modellenmiş, optimize edilen proses koşullarında fermentasyonun 14. gününde 2,83 mg/g üretim belirlenmiştir. Çalışmada sıcaklık, zaman, inokulum hacmi ve pH modelin faktörleri olarak seçilmiş olup üretilen lovastatin miktarı cevap olarak ölçülmüştür. Sıcaklık aralığı 25-35°C,

zaman aralığı 10-18 gün, inokulum hacmi aralığı 3-7 ml ve pH aralığı ise pH 5-7 olarak deney dizaynı yapılmış ve toplamda 29 deney yapılarak proses modellenmiştir.

Boran ve Regenstein (2009) yaptıkları çalışmada, sazan balığı derisinden jelatin ekstraksiyon parametrelerini modellemede cevap yüzeyi yöntemi kullanmışlardır. Çalışmada kullanılan deney dizaynı 4 faktörlü, 5 seviyeli ve 6 merkezi noktaya sahiptir. Faktör olarak seçilen, ekstraksiyon sıcaklığı, asit konsantrasyonu, asit ön işlem süresi ve su/deri oranına karşılık cevap olarak jelatin geri kazanım miktarı, elde edilen jelatinin jel gücü ve viskozitesi ölçülmüştür. Çalışmada 30 noktada deney yapılmış ve faktörler -1 ve +1 arasına normalize edilerek kullanılmıştır. Her bir cevap için modelin verdiği cevaplar ve deneysel olarak belirlenen cevaplar karşılaştırılarak istatistiksel analizler gerçekleştirilmiştir.

Aliaa ve ark. (2010) tarafından beyaz pitaya meyvesinden enzimatik yöntemle meyve suyu eldesi üzerine yapılan çalışmada cevap yüzeyi yöntemi kullanılmıştır. Ham halde oldukça bulanık ve viskoz olan meyve suyunun pektinaz enzimi ile berraklaştırılması işleminde, makarasyon süresi (20-100 dakika aralığında), reaksiyon sıcaklığı (30-50°C aralığında) ve enzim konsantrasyonu (% 0,01-0,1 aralığında) bağımsız değişkenler (faktörler) olarak seçilmiştir. Meyve suyu verimi, viskozitesi, berraklığı ve rengi ise prosesten elde edilen cevaplar olarak belirlenmiş olup 17 noktada deneyler gerçekleştirilerek prosesin modellenmesi ve optimizasyonu gerçekleştirilmiştir.

Cevap yüzeyi yöntemi et ürünleri üretim proseslerinde de optimizasyon ve modelleme amaçlı olarak bir çok araştırmacı tarafından kullanılmıştır. Hsu ve Yu (1999) düşük yağ içeren emülsifiye köftelerin kalite özelliklerine fosfat, su, yağ ve tuzun etkilerini araştırdıkları çalışmada bu yöntemi kullanmışlardır. Söz konusu çalışmada bağımsız değişken olarak seçilen bu dört faktörün tek tek ve interaksiyon halinde köftelerde pişirme kaybı, yağ oranı, Hunter b^* değeri ve tekstür özelliklerine önemli şekilde etki ettiği belirlenmiş ve arzu edilen özelliklere sahip köfte üretimi için hangi girdinin ne seviyede ilave edilmesi gerektiği ortaya konmuştur.

Gujral ve ark. (2002) keçi etinden üretilen patelerin yapısal ve pişme özelliklerine bileşimindeki sıvı yumurta, yağ ve tekstüre soya proteininin etkilerini inceledikleri çalışmada cevap yüzeyi yönteminden yararlanmışlardır. Araştırma sonucunda soya proteininin patelerde yapışkanlık, delinme kuvveti, geri ekstrüzyon kuvveti ve sertlik üzerine en fazla etkiye sahip

olduğu bulunmuştur. Diğer yandan çignenebilirlik, sakızsızlık, sıkılık gibi özelliklerin yağ oranı ile daha fazla bağlantılı olduğu belirlenmiş olup sıvı yumurtanın ise patelerin sululuğunu, boyut ve pişme kaybını büyük oranda etkilediği vurgulanmıştır. Duyusal testler de dikkate alınarak ortaya konan modelde R² değeri 0,9'un üzerinde bulunmuş olup, yöntemin istenen özellikte pate üretiminin modellenmesi için başarı ile kullanılabildiği gösterilmiştir.

Hsu ve Chung (2000) yaptıkları çalışmada, geleneksel bir köfte çeşidinin tekstürel özellikleri üzerine 4 farklı gamın karşılıklı etkileşimlerini yüzey cevap yöntemi ile incelemiştir. Sonuçların yüzey grafikleri ile desteklendiği bu çalışmada her bir gamın tek tek ve beraber etkileri araştırılmış ve üretilen köftelerde sadece Konjac gam ve curdlan gamın etkileşim içinde olduğu belirtilmiştir. Bunun dışında üründe yapışkanlık, çignenebilirlik, pişme kaybı ve renk değerlerinin nasıl etkilendiği anlaşılmaya çalışılmış olup, yüzey cevap yöntemi başarı ile kullanılmıştır.

Bu çalışmalara benzer şekilde, Desmond ve ark. (1998) tarafından düşük yağlı burgerlerin fiziksel ve duyusal özelliklerine tapyoka nişastası, yulaf kepeği ve peynir altı suyu proteininin etkisi, Hsu ve Chung (1998) tarafından emulsifiye köftelere proses faktörlerinin etkisi, Jakobsen ve Bertelsen (2000) tarafından taze ette renk stabilitesi ve yağ oksidasyonuna sıcaklık, depolama süresi ve modifiye atmosfer bileşiminin etkisi cevap yüzeyi yönteminin başarı ile uygulandığı çalışmalar olarak literatürde mevcuttur.

2.5. Hamburger Köftesinde Pişme Sonrası Oluşan Fiziksel Değişimler

Türkiye'de et ve et ürünleri genelde küçük kasap dükkanlarında kuşbaşı veya kıyma şeklinde satılmakta olup, tüketicilerin büyük bir çoğunluğu eti kıyma şeklinde satın almayı tercih etmektedir. Buna bağlı olarak da ülkemizde köfte, burger, kebab gibi kıymadan hazırlanmış et ürünlerinin tüketimi oldukça fazladır (Yılmaz ve Dağlıoğlu 2003, Ulu 2004, 2006).

Tüketiciler kıymadan hazırlanmış et ürünlerinden özellikle köftelerde renk, yapı ve tat gibi kalite özelliklerinin yanında, pişme sonrası boyut küçülmesi, yağ kaybı ve su kaybını da satın alma tercihlerinde dikkate almaktadır. Endüstriyel üretim yapan firmaların ürettikleri köftelerin boyutlarının standardizasyonuna önem vermeleri gerekmektedir. Hazır gıda sektöründe köfteler pişirildikten sonra genelde hamburger ekmeğinin içerisinde tüketime sunulmakta ve çoğunlukla yuvarlak şekilli olan bu iki parça ekmeğin içerisinde köftenin

boyutu ve görüntüsü tüketiciler için önem taşımaktadır. Pişirildikten sonra düzgün şekilli olmayan ve ekmek yüzeyini tam kaplamayan ürünlerin hazır gıda sektöründe kabul görmesi mümkün olmamaktadır.

Köftelerde pişme sonrası boyut küçülmesinin belirlenmesini amaçlayan çalışmalarda genelde çiğ ve pişmiş köfteler arasındaki çap farkı kullanılmaktadır (Modi ve ark. 2003, Serdaroğlu ve Değirmencioğlu 2004, Serdaroğlu ve ark. 2005, Ulu 2006). Ancak pişme sonrası köfte şekli tam bir daire olarak kabul edilemeyeceğinden ve çap ölçümünün hangi iki nokta arasında yapılacağı göreceli bir kavram olduğundan dolayı bu şekilde belirlenen boyut küçülmesi gerçek değeri yansıtmada yetersiz kalmaktadır.

Godsalve ve ark. (1977) tarafından ortaya konan modele göre, pişirme sırasında kas proteinleri denatüre olmakta ve su tutma kapasiteleri azalarak yapılarındaki protein ağının sıkışmasına yol açmaktadır. Sıkışan protein ağı lifler arasındaki suya mekanik bir kuvvet uygulamakta ve sonuçta et yüzeyine su çıkışı meydana gelmektedir. Dışarıya çıkan bu sıvı genel olarak pişme kaybı olarak tanımlanmaktadır.

İşlem görmemiş kas eti ile köfte arasında yapısal ve bileşimden kaynaklanan farklar olsa da köftelerde pişme sonrası oluşan boyut küçülmesinin açıklanmasında bu modele benzer olarak su kaybı ve yağ kaybının önemli rol oynadığı düşünülmektedir. Birçok araştırmacı tarafından köfte, burger ve patty gibi et ürünlerinin toplam kalitesi üzerine katkı maddelerinin etkileri (Hsu ve Chung 2000, 2001, Gujral ve ark. 2002, Modi ve ark. 2003, Yılmaz 2005, Serdaroğlu 2006) ve pişirme koşullarının etkileri (Hsu ve Chung 1998, Jakobsen ve Bertelsen 2000) araştırılmıştır. Taze etin pişme sonrası boyut küçülmesinin incelendiği araştırmalar da literatürde mevcuttur (Zheng ve ark. 2006, Kong ve ark. 2008).

Bu çalışmada hamburger köftesinde pişme sonrası görülen boyut, su ve yağ kaybına içeriğinde bulunan su, yağ ve tekstüre soya proteinin etkileri görüntü işleme teknolojisi ve cevap yüzeyi yöntemi ile belirlenmeye çalışılmıştır.

2.6. Domates Salçasının Görsel Kalite Özellikleri

Domates insan beslenmesinde büyük öneme sahip bir gıda maddesidir. Çok değişik iklim ve coğrafyalarda yetişebilen domates dünyanın hemen her yerinde üretilip tüketilmektedir. Son

verilere göre dünyada yılda 100,7 milyon ton domates üretilmektedir. Türkiye, Amerika Birleşik Devletleri, İtalya ve İspanya dünya domates üretiminde ilk sıralarda yer alan ülkelerdir (Jumah ve ark. 2004). Mevsime çok bağımlı bir ürün olan domates, fiziksel, kimyasal ve mikrobiyolojik bozulmalara oldukça açıktır. Bu nedenle dünyada üretilen domatesin büyük bir kısmı uzun süre kullanılabilmesi amacıyla domates salçasına işlenmekte ve bu şekliyle çorbalar, soslar ve ketçap gibi bir çok gıdanın üretiminde katkı maddesi veya hammadde olarak kullanılmaktadır (Sanchez ve ark. 2003). Domates salçası üretim prosesinde domateslerden elde edilen pulpun kuru madde oranı genelde çoklu evaporasyon sistemleri kullanılarak % 30-32 seviyesine çıkarılır (Simpson ve ark. 2008). Üretim prosesinde domatesten pulp eldesinde ve daha sonraki pulpun konsantre edilmesi aşamalarında ürün sıcaklığa maruz kalmaktadır. Kullanılan yöntemlere ve proses aşamalarına

göre değişmekle beraber ürün en az 60°C (evaporasyon aşamasında) ve en çok 140°C (süper-

hot break işlemi) sıcaklıkları görebilmektedir (Cemeroğlu, 2009). Domates salçası üretiminin yapılabilmesi için kullanılan ısıtma işlemi eğer kontrolsüz şartlarda gerçekleştirilir veya gereğinden fazla sıcaklık uygulanırsa üründe yanık koku, koyu renk ve yanma sonucu oluşan siyah benekler ortaya çıkabilmektedir.

Domates salçasında siyah benekler genelde proses sırasında uygulanan yüksek sıcaklık sonucu veya üründe bulunan küflerden dolayı ortaya çıkmaktadır. Ne sebeple olursa olsun siyah beneklerin sayısı ve büyüklükleri domates salçası için çok önemli bir kalite kriteri olarak kabul edilmektedir. Dünyada bir çok ülkenin domates salçası ve diğer domates ürünleri için kabul ettiği standartlar bulunmakla beraber, siyah benekler tüm ülkelerde salça için bir kalite kriteridir. Codex Alimentarius Komisyonu ve Birleşik Devletler Konserve Domates Salçası Sınıflandırma Standartlarında siyah beneklerin bulunmasını bir kalite kusuru olarak tanımlarken, Birleşik Devletlerin diğer standartlarında siyah beneklerin çapı ve boyutları da değerlendirmeye alınmaktadır (Anonim 1977; Anonim 1994; Anonim 2004). Türk Standartları Enstitüsü tarafından yayınlanan Domates Salçası ve Püresi Standardında domates salçası için kalite özellikleri tanımlanmıştır. Diğer birçok fiziksel, kimyasal ve mikrobiyolojik kriterlerle birlikte 1 gram domates salçasında bulunabilecek siyah benek sayısı en fazla 2 adetle sınırlanmıştır (Anonim 2008). Bunun yanında Dünya ve Türkiye’de birçok domates

salçası üreticisi ve alıcısı firma siyah beneklerin sayısı ve boyutları için kendi kriterlerini belirlemiş durumdadır.

Salçada bulunan siyah beneklerin sayısı ve boyutları klasik olarak görsel analizle belirlenmektedir ancak bu yöntem analizi yapan kişiye, analizin yapıldığı ortama bağlı olarak oldukça subjektif ve hatalı sonuçlar verebilmekte olup bunun yanında özellikle kumpas ya da mikrometre kullanılarak beneklerin çapının ölçülmesi zahmetli ve uzun süre gerektiren bir analizdir.

Birçok gıda maddesinde olduğu gibi, domates salçası için de, renk çok önemli bir kalite kriteri olarak kabul edilmektedir. Kodeks Alimentarius Komisyonu ve Birleşik Devletler standartları rengi domates salçası ve konsantratları için önemli bir kalite kriteri olarak belirlemiştir (Anonim 1994; Anonim 2004). Türk Standartlarına göre ise domates salçasının CIE (Commission Internationale d'Eclairage) renk değeri a^*/b^* olarak en az 1,8 olmalıdır (Anonim 2008). Domates salçası için arzu edilen renk sarı ve kırmızı arası ama kırmızıya çok yakın bir renktir. Bu rengi en iyi tanımlayan değer ise üçlü renk düzleminde a^*/b^* değeridir. $L^*a^*b^*$ uluslar arası bir renk ölçüm standardıdır ve 1976 yılında CIE tarafından kabul edilmiştir (Joshi 2002). Birçok farklı renk ölçüm sistemi bulunsa da insan renk algısına çok yakın olması ve çok düzenli bir dağılım göstermesi nedeniyle gıdaların renk ölçümünde en çok kullanılan sistem $L^*a^*b^*$ renk sistemidir. Renk ölçümünde Minolta kromometresi, Hunter Lab kolorimetresi ve Dr Lange kolorimetresi gibi cihazlar sıklıkla kullanılmaktadır (Leon ve ark. 2006). Ancak bu cihazlarla gıda maddelerinde renk ölçümü; fazla miktarda numuneye ihtiyaç olması (yaklaşık 10-13 ml) ve/veya cihazların çok pahalı olması ya da pahalı az kullanımlık ölçüm kapları gerektirmesi gibi sebeplerle dezavantajlı kabul edilmektedir (Bicanic ve ark. 2006; Kılıç ve ark. 2007). Diğer taraftan bir gıda görüntüsünün detaylı olarak incelenebilmesi ve renk değerinin tüm gıdayı temsil edecek şekilde hesap edilebilmesi için gıda görüntüsünü oluşturan tüm piksellerin değerinin hesaplanması gerekmektedir ancak halihazırda kullanılan kolorimetreler sadece birkaç santimetrekare alanda $L^*a^*b^*$ değeri ölçebilmektedir (Leon ve ark. 2006).

Daha önceki bölümlerde belirtildiği üzere bir görüntüyü oluşturan piksellerin bilgisayar ve uygun bir yazılım kullanılarak değiştirilmesi veya geliştirilmesi sonucu bu görüntünün insan ve otonom makineler tarafından daha iyi algılanabilmesini sağlamaya görüntü işleme teknolojisi denmektedir (McAndrew 2004). Görüntü işleme teknolojisi birçok gıdanın görsel


özelliklerini doğru, hızlı ve objektif bir şekilde belirlemede kullanılmaktadır (Briones ve Aguilera 2005; Du ve Sun 2006; Stien ve ark. 2006; Zheng ve ark. 2006; Kılıç ve ark. 2007; Aguirre ve ark. 2009). Görüntü işleme teknolojisinin salçada siyah benek sayısının belirlenmesi ve siyah beneklerin boyutlarına göre sınıflandırılmasında başarılı şekilde kullanılabileceği düşünülmektedir.

Görüntü işleme teknolojisi ve yapay sinir ağlarının bir arada kullanılması bilgisayarlı görüntü analizi için çok güçlü bir araç olarak düşünülmektedir. Bu çalışmada aynı anda hem salçada bulunan siyah beneklerin sayılarak sınıflandırılması hem de salçanın renk değerinin L^* , a^* , b^* ve a^*/b^* formatında belirlenmesi amaçlanmış olup çalışma sonuçlarının domates salçası üretimi ve kalite kontrolü alanında çalışan profesyonellere yardımcı olacağı düşünülmektedir.


2.7. Kurutulmuş İncirlerde Aflatoksin Varlığı

Aflatoksinler, 1960'da İngiltere'de bir tavuk çiftliğinde 100.000'den fazla hindinin ölümüne yol açan bir hastalığın araştırılması sırasında ortaya çıkmıştır. Hastalığa hayvan yemlerine katılan yarfıstığı unlarındaki küflerin neden olduğu saptanmış, yapılan araştırmalarda bu küfün *Aspergillus flavus* olduğu tanımlanmış ve bu ürettiği toksin de aflatoksin olarak adlandırılmıştır. Daha sonraki çalışmalar ile *A.flavus* ve *A.parasiticus* başta olmak üzere diğer bazı küf türlerinin de aflatoksin üretebildiği belirtilmişse de son bulgulara göre sadece *A.flavus* ve *A.parasiticus* aflatoksin üreten küflerdir (Ünlütürk ve Turantaş 1998).


Aflatoksinler difuranokumarin yapısında bileşikler olup doğada 18 farklı türevinin bulunduğu belirtilmektedir (Jay 1992). Bunlar arasında doğada en sık rastlanılanları AFB₁, AFB₂, AFG₁ ve AFG₂'dir. "B" ve "G" harfleri metabolitlerin ince tabaka kromatografisi plakalarında UV ışığı altında verdikleri mavi (blue) ve yeşil (green) floresans renklerini göstermektedir (Kabak 2007). Şekil 2.6'da bu dört aflatoksinin kimyasal yapıları verilmiştir.




(a)



(b)



(c)



(d)

Şekil 2.6. AFB₁ (a), AFB₂ (b), AFG₁ (c) ve AFG₂ (d)'nin kimyasal yapıları.

Doğadan birçok aflatoksin çeşidi izole edilmiş olmasına rağmen, sadece aflatoksin B1, B2, G1 ve G2 gıda bulaşanı olarak önemli kabul edilmektedir ve bu 4 çeşit arasında aflatoksin B1 en önemli akut toksisite kaynağı olarak kabul edilmektedir (Karaca ve Nas 2006).

Yer fıstığı, mısır, pamuk tohumu, incir gibi bazı ürünlerde *A. flavus* grubu küflerin gelişmesi sonucu ürettiği metabolit nedeniyle, UV ışığı altında üründe parlak yeşil-sarı bir floresans meydana gelmektedir (Scott 1998; Doyle ve ark. 1997). Bu floresansla, ürünün aflatoksin içeriği arasında sıkı bir ilişki bulunmuş ve floresanslı tanelerin ayırımı ile aflatoksinlerin ortamdaki uzaklaştırılması sağlanmıştır. Ülkemizde bu yöntem kuru incir ihracatındaki dar boğazın aşılmasında etkili olmuştur (Çoksöyler 1994; Özkaya ve ark. 1999). Diğer yandan, UV ışığı altında aflatoksinlerin yanı sıra *A. flavus* grubu küflerin oluşturduğu kojik asidin de parlak yeşilimsi bir floresansa neden olduğu bildirilmiştir (Scott 1998).

Ülkemizde üretilen incirlerde aflatoksin varlığı ile ilgili ilk vaka 1973 yılında Danimarka'ya ihraç edilen kuru incirlerimizde ortaya çıkmıştır. Akabinde 1986-1987 yıllarında yine İsviçre ve Almanya'ya ihraç edilen kuru incirlerde aflatoksine rastlanmış ve partiler geri çevrilmiştir. Bu olay üzerine Tarım ve Köyişleri Bakanlığınca başlatılan proje kapsamında incirlerin gerçekten yüksek düzeyde aflatoksin ve diğer bir mikotoksin olan okratoksini içerdiği belirlenmiştir (Tunail 2000).

Ülkemizde yapılan son düzenlemelerde kuru inciri de kapsayan, “fındık, antepfıstığı gibi sert kabuklu meyveler, yer fıstığı, yağlı tohumlar, kuru meyveler ve bunlardan üretilen işlenmiş gıdalar” için maksimum aflatoksin limiti, toplam aflatoksin (B1+B2+G1+G2) için 10 ppb olarak belirlenmiştir (Anonim 2009).

Kuru incirlerde aflatoksin tayini genel olarak bu çalışmada da kullanılmış olan HPLC metodu ile yapılmakta ancak var/yok tayini için aflatoksinlerin floresans özelliklerinin de bir çok ticari işletmede kullanıldığı bilinmektedir.

İhracatta önemli bir ürün olan incirlerde aflatoksin nedeniyle önemli ekonomik kayıplar yaşanmaktadır. Türkiye'deki kuru incir işletmelerinde uzun yıllardan beri işleme bandı üzerine yerleştirilen UV lambalarla parlak yeşilimsi sarı ışıma veren ve aflatoksin kontaminasyon riski olan meyveler seçilerek uzaklaştırılmaktadır.

Belirli dalga boyuna sahip UV ışık altından geçirilen incirlerde ışıma miktarına bağlı olarak aflatoksin varlığı saptanmaya çalışılmakta olup, bu işlem halen manuel olarak hareketli bantlarda çalışan işçiler tarafından yapılmaktadır. İnsan gözünün renk ayırt ederken karşılaşılabileceği zorluklar (ortam ışıklandırması, konsantrasyon, görme problemleri vb) göz önüne alındığında yapılan ayırımın bazı durumlarda objektiflikten uzaklaşabileceği ve hatalı sonuçlar doğurabileceği düşünülmektedir.

Bu çalışmada ülkemizin önemli bir ihraç ürünü olan kuru incirlerde aflatoksin varlığının hızlı ve objektif şekilde saptanması amacıyla görüntü işleme teknolojisi ve yapay sinir ağları kullanılmıştır.

3. MATERYAL ve YÖNTEM

3.1. Cevap Yüzeyi Yöntemi ve Görüntü İşleme Teknolojisi Kullanarak Köftelerde Fiziksel Kalite Özelliklerine Ürün Bileşenlerinin Etkilerinin Araştırılması

Görüntü işleme teknolojisinin taze et ve et ürünlerinin bazı özelliklerinin belirlenmesinde kullanılmasına ilişkin literatür örnekleri önceki bölümlerde detaylı olarak verilmiştir.

Bu çalışmada deneysel tasarım, tezin önceki bölümlerinde hakkında geniş bilgi verilen, cevap yüzey yöntemi kullanılarak yapılmıştır. Köfte bileşimine giren yağ, su ve TSP miktarlarının boyut küçülmesi, su kaybı ve yağ kaybı üzerindeki birleşik etkilerinin ortaya konmasında cevap yüzeyi yönteminin uygulanabilirliği test edilmiştir.

3.1.1. Hamburger köftesi

Denemesi yapılacak köftelerin bileşimindeki yağ, su ve TSP oranları cevap yüzeyi yöntemi kullanılarak belirlenmiştir. Kullanılan bileşenlerin deney aralıkları kodlanmış ve kodlanmamış değerler üzerinden Çizelge 3.1’de verilmiştir.

Çizelge 3.1. Kullanılan bileşenlerin deney aralıkları.

Değişkenler	Semboller	Kodlanmış değişken seviyeleri				
		$-\alpha$ (-1,682)	-1	0	1	$+\alpha$ (1,682)
Yağ (%)	X ₁	9,9	15,0	22,5	30,0	35,1
Su (%)	X ₂	6,6	10,0	15,0	20,0	23,4
TSP (%)	X ₃	1,0	3,0	6,0	9,0	11,0

Üç faktörlü merkezi birleşik tasarım modeli ile 6 tanesi merkez deney noktalarında olmak üzere 20 farklı deneme tamamen rastgele sıralama ile yapılmıştır. Her bir deneme noktasında ikiye üretim gerçekleştirilmiştir. Deney tasarımı Çizelge 3.2’de verilmiştir.

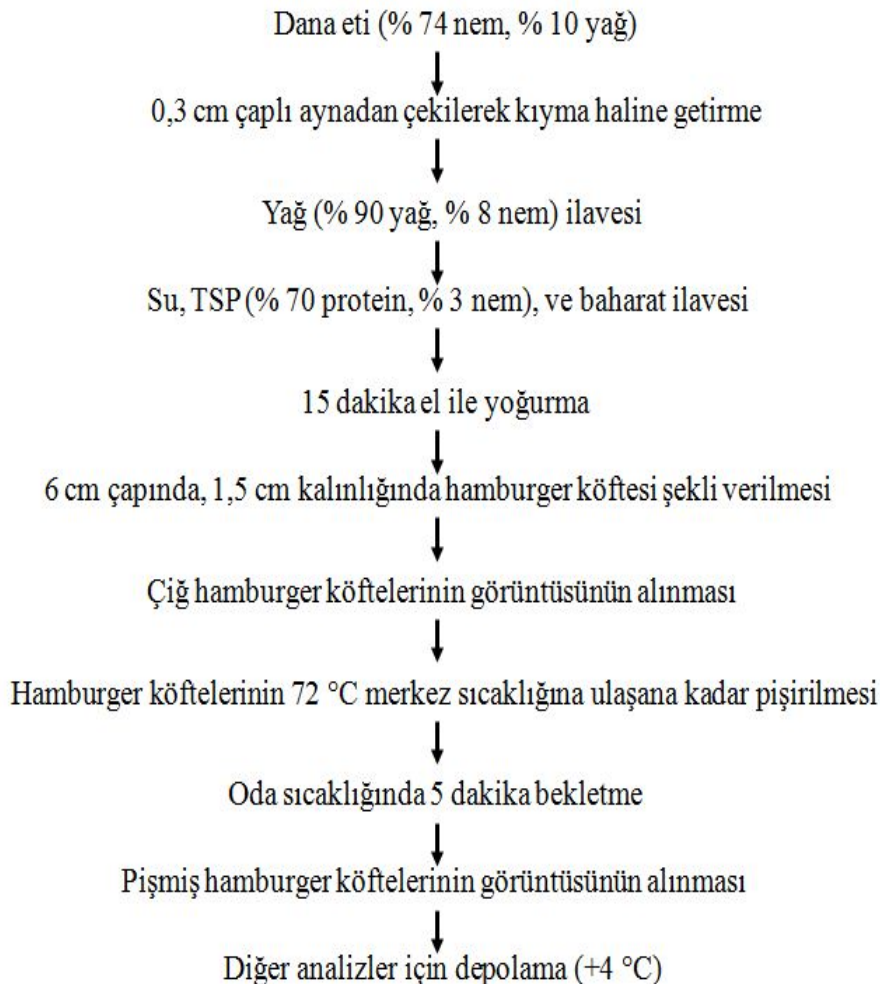
Çizelge 3.2. Merkezi kompozit deney tasarımı.

Deney sırası	Yağ (%)	Su (%)	TSP (%)	Et (%)	Baharat (%)
1	15	20	9	53	3
2	30	10	3	54	3
3	30	10	9	48	3
4*	22,5	15	6	53,5	3
5*	22,5	15	6	53,5	3
6	22,5	6,5	6	62	3
7	15	20	3	59	3
8*	22,5	15	6	53,5	3
9	15	10	3	69	3
10	15	10	9	63	3
11	35	15	6	41	3
12*	22,5	15	6	53,5	3
13	22,5	15	11	48,5	3
14	22,5	15	1	58,5	3
15*	22,5	15	6	53,5	3
16	30	20	9	38	3
17*	22,5	15	6	53,5	3
18	22,5	23,5	6	45	3

19	10	15	6	66	3
20	30	20	3	44	3

*Merkezi deney noktaları

Dana eti, yağ, baharatlar ve diğer katkıları yerel bir et ürünleri firmasından temin edilmiştir. Her bir köfte örneği 3 kg'lık partiler halinde üretilmiştir. Et (% 74 su, % 10 yağ) kıyma haline getirilmiş ve yağ (% 90 yağ, % 8 su), su, TSP (% 70 protein, % 3 su) ve baharatlarla (% 0,4 kimyon, % 0,4 kırmızı biber, % 0,3 kara biber, % 0,2 soğan tozu, % 0,2 yenibahar ve % 1,5 tuz) karıştırılarak tüm bu bileşenleri istenen oranlarda içeren 3 kg'lık köfte hamurları hazırlanmıştır. Her bir porsiyon 15 dk el ile yoğrularak homojen hale getirilmiştir. Bir gün boyunca +4°C'de dinlendirilen hamur, manuel köfte şekillendirme makinesi ile yaklaşık 6 cm çapında, 1,5 cm kalınlığında ve 50-60 g ağırlığında köfteler haline getirilmiştir. Çiğ halde görüntüsü alınan köfteler, önceden ısıtılmış Teflon tavada her iki tarafı sırasıyla 3 dk, 1 dk ve 15 s pişirilmiştir. Yaklaşık 5 dk beklendikten sonra pişmiş halde görüntüleri alınan köfte örnekleri yapılacak diğer analizler için +4°C'de muhafaza edilmiştir. Köfte örneklerinin üretim akım şeması Şekil 3.1'de verilmiştir.



Şekil 3.1. Hamburger köftesi üretim akım şeması.

3.1.2. Görüntülerin alınması

Görüntülerin elde edilmesinde kullanılan tarayıcı (HP Scanjet 3400C), dışarıdan gelebilecek ışığın engellenmesi amacıyla ışık almayan bir kutu içine yerleştirilmiştir. Çiğ ve pişmiş köfte örnekleri direk olarak tarayıcının tablası üzerine konularak 200 points/inch çözünürlükte taranmış ve görüntüler JPEG (Joint Photographic Experts Group) formatında kaydedilmiştir. Kaydedilen görüntülerin boyutu 1900 x 1900 pikseldir. Tarama sırasında görüntü arka planı ve örnek arasındaki kontrastı arttırmak için beyaz arka plan kullanılmıştır. Stien ve ark. (2006) tarafından yapılan çalışmaya uygun olarak tarayıcının üzerinde orijinal olarak mevcut olan beyaz tarayıcı iç kapağı kalibrasyon için kullanılmış ve tüm çalışma boyunca aynı şekilde kalibre edilmiştir. Her örneğin görüntüsü alındıktan sonra tarayıcının üzeri ve iç kapağı yağ çözücü ile temizlenmiş, böylece görüntüyü bozacak herhangi bir kalıntı bulunması engellenmiştir.

3.1.3. Görüntü işleme

Kullanılan sistem: Görüntülerin depolanması ve işlenmesinde Intel Core 2 CPU, T7200 2.00 GHz işlemcili, 2 GB Ram ve Nvidia GeForce GO 7400 ekran kartına sahip kişisel bilgisayar kullanılmıştır. Görüntü işleme ve diğer ileri işlemler Windows Vista Professional ortamında yapılmış olup bu işlemler sırasında Matlab 7.5.0 (The Mathworks, Natick, MA) programı ile oluşturulan algoritma (Ek-1) kullanılmıştır.

Görüntü Segmentasyonu: Segmentasyon 5 ana aşamada yapılmıştır. Bu aşamalar:

- Matlab “edge” fonksiyonu ve “sobel” operatörü kullanılarak arka plan üzerinde köfte belirlenmiştir. Bu işlem ile eşik değeri hesaplandıktan sonra, “edge” fonksiyonu

yeniden kullanılarak segmentasyonu yapılmış köfte görüntüsünü içeren iki renkli maske elde edilmiştir.

- Örnek görüntüsünün sınırlarında bulunan boşlukların ortadan kaldırılması amacıyla yapılan genişletme/açma (dilation) işleminde Matlab “strel” fonksiyonu ile oluşturulan doğrusal yapısal eleman kullanılmıştır. Açma işlemi “imdilate” fonksiyonu ile oluşturulan yatay yapısal elemanın kullanımı ile bitirilmiştir.
- Örnek görüntüsünün içerisinde bulunan boşlukların doldurulmasında dairesel yapısal eleman kullanan “imfill” fonksiyonu kullanılmış ve boşlukları doldurulmuş (gap-filled) iki renkli görüntü elde edilmiştir.
- Örnek sınırlarına yapışık bulunan nesnelerin giderilmesi için görüntünün temizlenmesi gerekmiş olup, “imclearborder” fonksiyonu ayarlanan 5 değeri ile kullanılmıştır (bu değer tüm örnekler için başarı ile çalışmıştır).
- Pürüzsüzleştirme (smoothing) işlemi doğal bir görüntü elde edilmesi için gerekli olmuştur. Bu işlem “strel” fonksiyonu ile oluşturulan kristal yapısal elemanını kullanan “imerode” fonksiyonunun iki kez kullanılması ile gerçekleştirilmiştir.

Boyut Küçülmesinin Ölçümü: Boyut küçülmesi bir önceki aşamada elde edilen segmentasyonu yapılmış iki renkli görüntü ile belirlenmiştir. Görüntü 1900 x 1900 matriks büyüklüğünde, siyah (arka plan) ve beyaz (örnek) olmak üzere iki renk bölgesi içermektedir. Matlab ile yazılan algoritma ile beyaz pikseller sayılarak örnek boyutu olarak kaydedilmiştir. Çiğ ve pişmiş örnek görüntüleri tek algoritma ile aynı anda analiz edilmiş ve bu algoritma iki boyutu (çiğ ve pişmiş) oranlayarak boyut küçülmesini yüzde olarak hesaplamıştır. Boyut küçülmesinin hesaplanmasında kullanılan eşitlik (Eşitlik 5) şu şekildedir:

$$\text{Boyut Küçülmesi (\%)} = \frac{(\text{Çiğ köfte alan} - \text{Pişmiş köfte alan})}{\text{Çiğ köfte alan}} \times 100 \quad (5)$$

Daireye yakın şekle sahip olan bazı köfte örneklerinde boyut küçülmesi geleneksel metodla da belirlenmiş ve sonuçlar bizim yöntemimizle elde edilen sonuçlar ile karşılaştırılmıştır. Modi ve ark. (2003) tarafından da kullanılan klasik metodla boyut küçülmesinin belirlenmesinde alan yerine, çiğ ve pişmiş köftelerin çapları kullanılmaktadır.

3.1.4. Kimyasal analizler

Örneklerin ve hammaddelerin su, protein ve yağ içeriklerinin belirlenmesinde AOAC (1990) da tanımlanan yöntemler kullanılmıştır. Su ve yağ kayıpları Eşitlik 6 ve 7 kullanılarak belirlenmiştir.

$$\text{Su Kaybı (\%)} = \frac{(M_1 - M_2)}{M_1} \times 100 \quad (6)$$

M_1 : Çiğ örneğin su içeriği (%)

M_2 : Pişmiş örneğin su içeriği (%)

$$\text{Yağ Kaybı (\%)} = \frac{(F_1 - F_2)}{F_1} \times 100 \quad (7)$$

F_1 : Çiğ örneğin yağ içeriği (%)

F_2 : Pişmiş örneğin yağ içeriği (%)

3.1.5. Matematiksel ve istatistiksel analizler

İkinci dereceden tam polinomal eşitlik (Eşitlik 8) tüm deneysel verilere uygulanmış ve model eşitliğinin katsayıları belirlenmiştir. Deneysel modelde cevaplara bağlı sonuçlar şu şekilde gösterilmektedir:

$$R = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \beta_3 X_3 + \beta_{11} X_{11} + \beta_{22} X_{22} + \beta_{33} X_{33} + \beta_{12} X_{12} + \beta_{13} X_{13} + \beta_{23} X_{23} \quad (8)$$

B_0 , B_i , B_{ii} ve B_{ij} sırasıyla kesim noktası, doğrusal, kare ve etkileşim katsayılarını göstermektedir. X_1 , X_2 ve X_3 kodlanmış bağımsız değişkenlerdir. Modelin doğrulanması ANOVA (Varyans analizi) ile yapılmış ve tüm faktörlerin önemi belirlenmiştir. Modellerin son doğrulamaları da cevap yüzey grafikleri çizilerek yapılmıştır. İstatistiksel analizler Minitab 15.1.30.0 (Minitab Inc. 2009) paket programının deneme sürümü kullanılarak gerçekleştirilmiştir.

3.2. Domates Salçasında Görsel Kalite Özelliklerinin Görüntü İşleme Teknolojisi ve Yapay Sinir Ağları ile Belirlenmesi

3.2.1. Domates Salçası

Bu çalışmada kullanılmak üzere yerel marketlerden 9 farklı konserve domates salçasından ikişer adet olmak üzere 18 adet salça örneği satın alınmıştır. Dokuz adet salça örneği 5 dakika boyunca 100 °C'de ısıtılarak renginin koyulaşması ve siyah benekler oluşması sağlanmıştır. Dokuz adet orijinal, 9 adet ısıtılmış ve bu 18 örneğin 1/1 oranında karıştırılması ile elde edilen 81 yeni örnek ile analizlerde kullanılacak 99 salça örneği elde edilmiştir. Örnekler analizler yapılmaya kadar +4°C buzdolabı sıcaklığında saklanmış olup tüm örnekler aynı gün içinde analiz edilmiştir. Kullanılan salça örnekleri en az 200 g'lık orijinal ambalajlı olarak satın alınmış ve tüm analizler üç kez tekrar edilmiştir.

3.2.2. Kullanılan cihazlar

Görüntü alma ve işleme sistemi; ofis tipi tarayıcı (Scan 8800F, Canon Inc., Japonya) ve kişisel bilgisayardan (Intel® Core™ 2 CPU, T7200 2.00 GHz işlemci, 2 GB Ram ve Nvidia GeForce GO 7400 grafik kartı) oluşmaktadır. Görüntü işleme, yapay sinir ağları tasarımı ve diğer ileri işlemler için Windows Vista™ Profesyonel ortamında Matlab® 7.5.0 (The Mathworks, Natick, MA) yazılımı ile geliştirilen orijinal algoritmalar (Ek-2) kullanılmıştır. Salçanın renk ölçümü için Hunter-Lab tristimulus kolorimetre (D25LT, Hunter Associates Laboratory, Reston, Virginia, USA) kullanılmıştır.

3.2.3. Siyah benek analizi

3.2.3.1. Örnek hazırlama, görsel sayım ve ölçüm

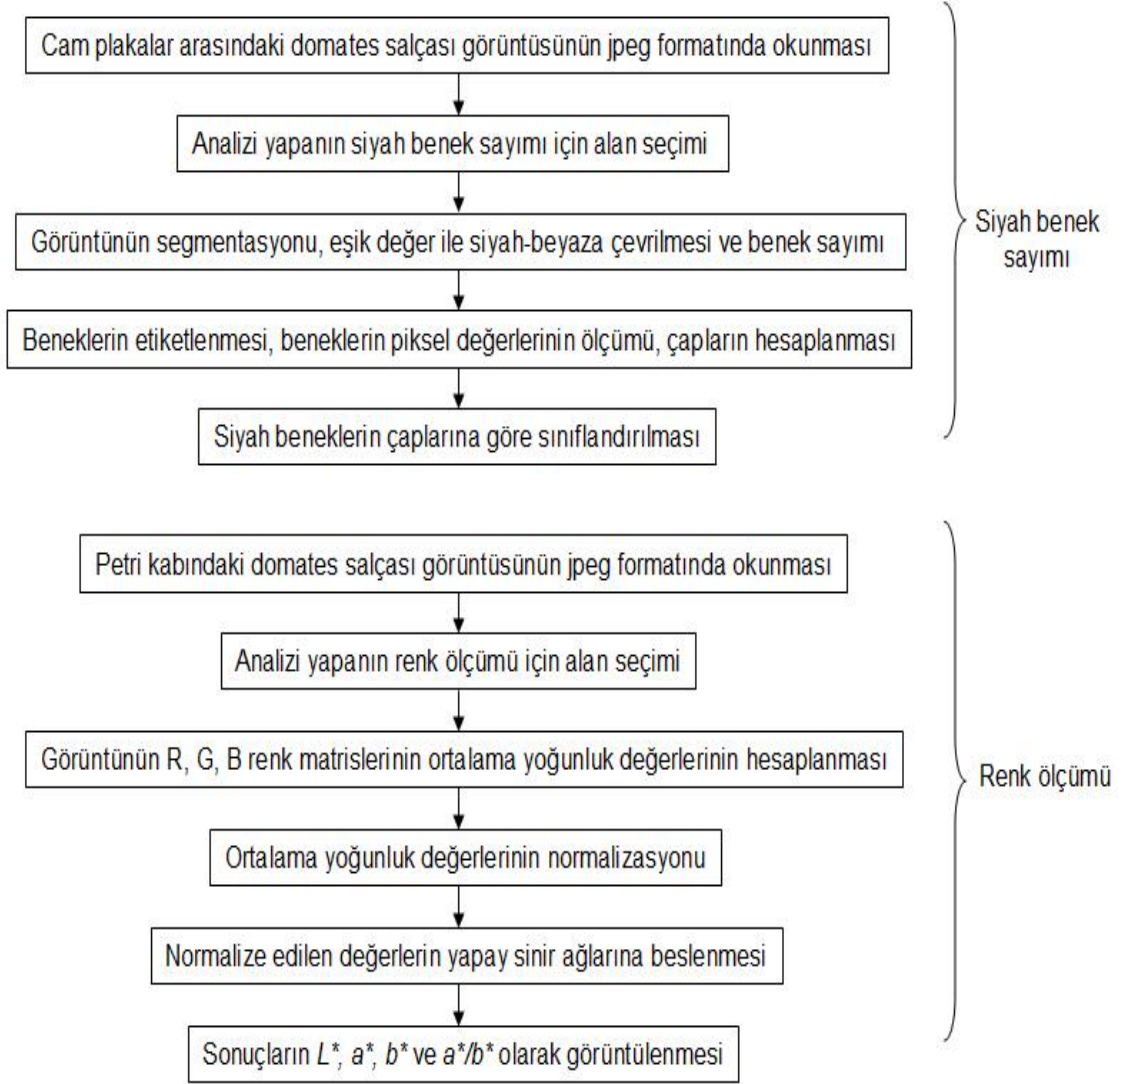
Görsel analiz Türk Standartları'nda (Annonim, 2008) tanımlanan metoda göre yapılmıştır. Bu analiz için 1 g salça örneği $10 \times 10 \times 0,8$ (cm \times cm \times cm) (en \times boy \times kalınlık) ölçülerinde cam üzerine tartılmış ve aynı boyutlara sahip ikinci cam ilkinin üzerine kapatılmıştır. İki cam arasındaki salça örneği hava kabarcıklarının oluşmamasına dikkat edilerek bastırılarak yayılmış olup beyaz zemin üzerinde çıplak gözle analiz yapılmıştır. Bir gram domates salçasındaki tüm görünür siyah benekler, arka alan ve siyah parçacıklar arasındaki kontrastı arttırmak için kullanılan, beyaz zemin üzerinde sayılmıştır. Her bir siyah beneğin çapı kumpas ile ölçülmüş ve siyah benekler çaplarına göre sınıflandırılmıştır. Analizler ikişer tekerrür olarak yapılmış olup, her analizden sonra cam plakalar yağ çözücü ile temizlenmiştir.

3.2.3.2. Görüntü alma

Aralarında salça örneği olan camlar direkt olarak tarayıcıya yerleştirilmiştir. Tarayıcı dışarıdan gelen ışığı engellemek için ışık almayan bir kutu içerisinde çalıştırılmış ve 600 dpi çözünürlükte örnek görüntüleri alınmıştır. Alınan görüntüler 5096×7008 piksellik JPEG (Joint Photographic Experts Group) formatında dosyalarda saklanmıştır. Görüntü alma işlemi sırasında camların arka tarafında beyaz bir zemin kullanılarak kontrast artırılmış ve siyah beneklerin daha iyi belirlenmesi amaçlanmıştır. Stien ve ark. (2006) tarafından belirtildiği gibi, tarayıcı orjinal olarak kapağında bulunan beyaz yüzey kullanılarak kalibre edilmiş ve tüm görüntü alma işlemlerinde bu kalibrasyon kullanılmıştır. Tarayıcı cam yüzeyi her bir taramadan sonra yağ çözücü ve kağıt havlu ile temizlenmiştir.

3.2.3.3. Görüntü segmentasyonu, siyah benek sayımı ve çap belirleme

Siyah beneklerin segmentasyonu, sayımı, çap ölçümü ve sınıflandırılması için Şekil 3.2'de görülen algoritma Matlab ortamında kodlanmıştır. Renkli görüntü alınmasından sonra RGB imaj elde edilmiştir. RGB imaj, kırmızı (Red), yeşil (Green) ve mavi (Blue) olmak üzere üç matristen oluşan ve her bir matriste bu renklerin yoğunluk değerlerini içeren bir görüntüdür (Mery ve Pedreschi 2006).



Şekil 3.2. Salçada siyah benek ve renk tayininde kullanılan algoritma.

Taranan görüntüden salça örneğinin bulunduğu kısım yazılan algoritma kullanılarak kesilmiştir. Elde edilen bu yeni görüntüdeki tüm matrisler incelenmiş ve R matrisindeki kontrast oranının siyah beneklerin tespit edilmesine olanak sağladığı belirlenmiştir. R matrisinden elde edilen bu yeni görüntü J görüntüsü olarak tanımlanmıştır. J görüntüsündeki siyah beneklerin arka plandan ayrılabilmesi için t eşik değeri ile global eşikleme yapılmıştır. Bu yöntemde belirlenen t değerinden daha küçük renk yoğunluğuna sahip pikseller beyaz,

büyük olanlar siyah olarak değiştirilmiş ve sonuçta K olarak kodlanan siyah-beyaz imaj elde edilmiştir. Bu amaçla aşağıdaki Eşitlik 9 kullanılmıştır.

$$K(x, y) = \begin{cases} 1 & \text{if } J(x, y) < t \\ 0 & \text{else} \end{cases} \quad (9)$$

Bu siyah-beyaz K görüntüsündeki beyaz pikseller ve piksel grupları salçada bulunan siyah benekleri temsil etmekteyken, siyah pikseller ise arka planı oluşturmaktadır. Bu beyaz piksel gruplarının oluşturduğu şekiller çaplarının ölçülebilmesi için daire olarak kabul edilmiş ve alanları ve çapları basit daire alan formülü ile hesaplanmıştır. Siyah benekler çaplarına göre 0-0,2, 0,2-1, 1-2 ve >2mm şeklinde sınıflandırılmıştır.

3.2.3.4. Renk ölçümü için örnek hazırlama

Yaklaşık 20 g domates salçası örneği standart Petri kabına konulmuş ve hızlı bir şekilde kolorimetre ile L^* , a^* , b^* değerleri belirlenmiştir. Bu işlemin hemen ardından Petri kabı içindeki örneklerin görüntüleri tarayıcı ile alınarak kaydedilmiştir. Görüntü alımında siyah benek için görüntü almada kullanılan prosedür uygulanmıştır.

3.2.3.5. L^* , a^* , b^* ölçümü

Bu ölçümde kullanılan kolorimetre, cihazla beraber bulunan siyah ve beyaz seramikler kullanılarak kalibre edilmiştir. Petri kaplarına hava kabarcığı oluşmayacak şekilde konan salça örneklerinin renk değeri kolorimetre ile ölçülmüştür. Ölçümler 6 kez tekrarlanmış olup hesaplamalarda bu 6 ölçümün ortalamaları kullanılmıştır.

3.2.3.6. Görüntü alma ve işleme

İçerisinde salça örneği olan Petri kabı görüntüsü direkt olarak tarayıcıda alınmıştır. Elde edilen RGB görüntü 600 dpi çözünürlükte JPEG formatında 2387×2387 piksel olarak kaydedilmiştir Şekil 3.2’de verilen algoritma ile renk tayini yapılmıştır. Öncelikle RGB imajda bulunan salça örneğinin bulunduğu kısım 1250×1250 piksel olarak kesilmiş ve kaydedilmiştir. Bu kısım tüm salça görüntüsünün yaklaşık % 60’ını temsil etmektedir. Sonra kare şeklindeki bu görüntü kodlanmış olan algoritma yardımı ile analiz edilmiş ve görüntüyü

oluşturan tüm piksellerin ortalama R, G, B değeri sonraki aşamada oluşturulan yapay sinir ağına girdi olarak verilmek üzere belirlenmiş ve saklanmıştır.

3.2.3.7. Yapay sinir ağı dizaynı

R, G, B matrislerinin ortalama yoğunluk değerleri aşağıdaki formüle göre -1 ve +1 arasına normalize edilmiştir.

$$x_{ni} = \frac{(x_i - (x_{\max} + x_{\min})/2)}{((x_{\max} - x_{\min})/2)} \quad (10)$$

Bu formülde x_{ni} , x_i , x_{\min} ve x_{\max} sırasıyla normalize edilmiş, gerçek, minimum ve maksimum değerleri ifade etmektedir.

Normalizasyon sonrası elde edilen 3 yoğunluk değeri ve bu değerlerin kareleri oluşturulan yapay sinir ağları için 6 adet girdi verisi olarak kullanılmıştır. Matlab Neural Network Toolbox kullanılarak *net-l*, *net-a*, *net-b* ve *net-a/b* şeklinde kodlanan 4 farklı yapay sinir ağı dizayn edilmiştir. Tüm ağlar ileri beslemeli yapay sinir ağıdır ve girdi katmanında 6 nöron, gizli katmanda 6 nöron ve çıktı katmanında da 1 nöron bulunmaktadır. Girdi katmanındaki 6 nöron normalize edilmiş yoğunluk değerleri ve bunların karelerine, çıktı katmanındaki 1 nöron ise her bir ağ için L^* , a^* , b^* ve a^*/b^* değerlerine karşılık gelmektedir. Girdi katmanı ile gizli katman arasında ve gizli katman ile çıktı katmanı arasındaki transfer fonksiyonu 'logsig' olarak seçilmiştir. Ağların eğitiminde ağırlık ve bias değerlerini Levenberg-Marquardt optimizasyonu ile ayarlayan 'trainlm' fonksiyonu kullanılmıştır. Yüz domates salçası örneğinin 59 tanesinden elde edilen veriler ağların eğitiminde, 20 veri ağların validasyonunda ve son 20 veri de ağların test edilmesinde kullanılmıştır. Ağın eğitimi çıktılar ve hedefler arasındaki hata kareleri ortalamasını minimize etmeyi amaçlayarak yapılmıştır. Eğitimi tamamlanan ağlar daha sonraki aşamalarda kullanılmak üzere *mat* uzantılı olarak kaydedilmiştir.

3.3. Kuru İncirlerde Aflatoksin Tayini

3.3.1. Kuru incir

Kuru incirde aflatoksin varlığını arařtırmaya ynelik olarak toplam 82 adet kuru incir rneęi toptan ve perakende satıř noktalarından, her bir rnekten 200'er gram olacak řekilde tedarik edilmiřtir. Uygulanacak yntemin daha saęlıklı sonu vermesi ve doęrulanması amacıyla aflatoksin iermedięi bilinen bir kuru incir rneęine de hazır toplam aflatoksin standardı, rneklerde 2, 4, 6, 8 ve 10 ppb olacak řekilde, belirli konsantrasyonlarda ilave edilerek toplam 10 adet aflatoksin ieren rnek iki set halinde hazırlanmıřtır. Alınan rnekler HPLC analizleri ve grnt alma iřlemleri yapılına kadar +4°C'de ve ıřıksız ortamda muhafaza edilmiřtir.

3.3.2. HPLC yntemi ile aflatoksin tayini

Aflatoksin analizi AOAC (2000)'nin 999.07 nolu metodu kullanılarak HPLC ile yapılmıřtır. HPLC (Shimadzu – HPLC 10Avp, Japonya) cihazında aflatoksin analizi řu kořullarda alıřılmıřtır;

- HPLC kolonu: C18, 150x4 mm, 4,6 µm por apı
- Dedektr: RF-10AXL floresan dedektr
- mobil faz: su, asetonitril, metanol [6+2+3 (v+v+v)]
132 mg KBr + 385 µl % 65 HNO₃
- akıř hızı: 1ml/dk

Mobil fazın hazırlanmasında kullanılan kimyasallardan asetonitril, Lab – Scan Analytical Sciences (Polonya), metanol, distile su ve % 65'lik nitrik asit Merck (Almanya) firmalarından temin edilmiřtir.

PBS (Fosfat Tamponlu Tuz) zeltisinin hazırlanması

0,2 g potasyum dihidrojen fosfat (Merck, Almanya), 0,2 g potasyum klorr (Merck, Almanya), 1,16 g di-sodyum hidrojen fosfat dodecahydrate (Merck, Almanya) ve 8 g sodyum klorr (Merck, Almanya) 0,9 l distile suda (Merck, Almanya) zndrlmřtir. 0,1 mol/l HCl (Merck, Almanya) veya 0,1 mol/l NaOH (Merck, Almanya) kullanılarak pH 7,4'e ayarlanmıřtır. Distile su ile 1 L'ye tamamlanmıřtır.

Ekstraksiyon ve filtrasyon

Aflatoksin analizi iin alınan incir rneklerinden 25 g tartılarak paralayıcıya aktarılmıřtır. Her bir rneęin zerine 125 ml ekstraksiyon solventi metanol -saf su (80:20) karıřımı ile 2 g NaCl ilave edilerek paralayıcı yaklařık 3 dk maksimum hızda alıřtırılarak, rneęin

parçalanması ve karışması sağlanmıştır. Parçalayıcıdan çıkan ekstrakt Whatman No.1 filtre kâğıdından süzölmüştür.

İmmünoaffinite kolon safhası

Filtratın 5 ml'si erlenmayere aktararak üzerine 5 ml PBS çözeltilisi ilave edilmiş ve iyice karışması sağlanmıştır. Bu karışım 10 ml'lik enjektöre aktarılmıştır. Enjektörün ucuna immünoaffinite kolon (R – Biopharm Rhone Ltd., İskoçya) takılıp karışım, 1 damla/saniye sabit hızla kolondan geçirilmiştir. Bu işlemi takiben kolondan 2 kez yaklaşık 2 damla/saniye sabit hızla 10 ml saf su geçirilerek kolonun yıkanması sağlanmıştır.

Elüsyon

Kolona 1 ml metanol aktarılıp yerçekimi ile vialde akması sağlanmıştır. Ardından 1 ml saf su kolondan benzer şekilde geçirilmiştir. Vialde toplanan eluat tek kullanımlık, steril, 0,45 µm'lik porlara sahip şırınga ucu filtreden (Sartorius, Almanya) geçirilmiştir. Böylelikle vialde toplam 2 ml hacimli, berrak görünümlü eluat elde edilmiştir.

HPLC'ye aflatoksin B₁ ve toplam aflatoksin standartlarının (Sigma, Almanya) her birinden 20 µl enjekte edilmiştir. Ardından belirli konsantrasyonlarda hazırlanmış standart karışımları enjekte edilerek kalibrasyon eğrisi elde edilmiştir. Daha sonra örnekler enjekte edilerek örneklerde aflatoksin tayini yapılmıştır.

3.3.3. Görüntü işleme teknolojisi ile aflatoksin tayini

3.3.3.1. Görüntü alma

Püre haline getirilerek petri kabına ince bir tabaka halinde yayılan incir numunelerinin görüntüleri daha önceki bölümlerde açıklanan ve kullanılan görüntü alma sisteminde alınmıştır. Görüntü alma sisteminde Schneider lense sahip Samsung NV24HD 10.2 MP yüksek çözünürlüklü kamera kullanılmıştır. Sistemin ışıklandırılmasında Philips marka 4 adet 365 nm UV floresan kullanılmıştır. Elde edilen görüntüler JPEG formatında bilgisayar ortamına kaydedilmiştir.

3.3.3.2. Görüntülerin işlenmesi

Elde edilen görüntüler Matlab programı Image Processing Toolbox yardımı ile işlenmiş ve her bir örnek görüntüsünün RGB histogramları elde edilmiştir. Histogramlarda gözlenen mavi ve yeşil renklerin yoğunluk değerleri (intensity) yine Matlab ortamında yazılan algoritma yardımı ile otomatik olarak belirlenerek, Matlab Neural Network Toolbox ile oluşturulan yapay sinir ağına girdi olarak verilmek üzere depolanmıştır.

3.3.3.3. Yapay sinir ağı tasarımı

Bu aşamada Matlab Neural Network Toolbox ile girdi katmanında 3 nöron, gizli katmanda 6 nöron ve çıktı katmanında 1 nöron bulunan ileri beslemeli yapay sinir ağı oluşturulmuştur. Girdi katmanındaki 3 nöron örnek görüntülerinin kırmızı (R), yeşil (G) ve mavi (B) yoğunluk (intensity) değerlerine, çıktı katmanındaki bir nöron ise aflatoksin var/yok (1/0) sonucuna karşılık gelmektedir. Ağın verdiği cevap 0'a yakın ise örnekte aflatoksin yok, 1'e yakınsa aflatoksin var sonucu elde edilmeye çalışılmıştır. Transfer fonksiyonu olarak 'logsig' seçilmiş olup eğitimde 'trainlm' fonksiyonu kullanılmıştır. 82 örnekten elde edilen R, G ve B veri setlerinin 58 tanesi ağın eğitiminde, 12 tanesi ağın validasyonunda ve 12 tanesi ağın test edilmesinde kullanılmıştır.

4. ARAŞTIRMA BULGULARI ve TARTIŞMA


4.1. Hamburger Köftelerinin Fiziksel Kalite Özelliklerine Ürün Bileşenlerinin Etkileri

4.1.1. Sonuçlar

Çalışmanın yöntem bölümünde çiğ ve pişmiş köftelerin yüzey alanını otomatik olarak ölçmeye yarayan metot detaylı olarak anlatılmıştır. Şekil 4.1’de örneklerin orijinal ve işlenmiş görüntüleri verilmiştir. Bu aşamadaki kritik nokta orijinal görüntüden işlenmiş görüntüye geçerken piksel kaybının yaşanmaması ve görüntü boyutlarının birebir aynı kalmasıdır. Şekil 4.1 incelendiğinde bunun başarıyla gerçekleştirildiği anlaşılmaktadır. Bu durum aynı zamanda daha önceki bölümlerde belirtilen klasik yöntemle bazı örnek (dairesel şekilli olan örnekler) çapları ölçülerek doğrulanmış olup, iki yöntemin sonuçları arasında yaklaşık % 2’lik bir fark belirlenmiştir.



a



b



c



d

Şekil 4.1. Çiğ (a, b) ve pişmiş (c, d) hamburger köftesi örneklerinin orijinal (a, c) ve işlenmiş (b, d) görüntüleri.

4.1.2. Boyut küçülmesi

Gıda maddelerinin şekli ve buna bağlı olarak boyu veya çapı işlenme sırasında büyük ölçüde değişime uğramakta olup çap veya boy ölçümüne dayalı uzunluk belirleme yöntemleri yanlış sonuç verebilmektedir (Zheng ve ark. 2006). Mevcut çalışmada çiğ ve pişmiş köfte örneklerinin yüzey alanı doğrudan segmente edilmiş görüntüdeki pikseller sayılarak hesaplanmıştır. Boyut küçülmesi oranları da bu piksel ölçümleri kullanılarak belirlenmiştir. Yağ, su ve TSP miktarlarının köftelerde boyut küçülmesine etkili olduğu anlaşılmıştır. Çizelge 4.1’de görüldüğü gibi bağımsız değişkenler olan yağ, su ve TSP miktarlarının seçilen aralıklarda değiştirilmesi sonucu boyut küçülmesi % 30,73 ile % 55,23 arasında değişmiştir.

Çizelge 4.1. Deneysel sonuçlar.

Deney sırası	Boyut küçülmesi (%)	Su kaybı (%)	Yağ kaybı (%)
1	34,70	9,20	8,35
2	52,16	15,35	27,66
3	42,70	8,10	14,67
4	41,68	14,98	30,76
5	42,85	15,01	28,75
6	40,89	10,01	24,54
7	44,67	18,66	23,18
8	46,20	14,67	30,43
9	35,87	14,49	22,96
10	31,42	8,14	10,41
11	52,53	14,39	28,98
12	43,58	13,34	30,63
13	38,21	5,45	3,25
14	49,24	21,01	28,27
15	43,58	14,66	29,10
16	49,01	10,88	14,43

17	43,58	15,44	29,60
18	48,51	18,75	27,54
19	30,73	13,48	17,80
20	55,23	21,62	31,47

Serdaroğlu ve Değirmencioğlu (2004) tarafından yapılan çalışmada, yağ miktarının köftelerde boyut küçülmesini etkilediği ve içerikte bulunan yağ miktarının % 20'den % 5'e indirilmesi sonucu boyut küçülmesinin önemli biçimde azaldığı belirtilmiştir. Bizim çalışmamızda boyut küçülmesini yağ, su ve TSP içeriklerine bağlı olarak tahmin edebilecek bir eşitlik ortaya konmuştur. Çizelge 4.2'de en uygun modelin belirlenmesi amacıyla denemesi yapılmış doğrusal, ikinci dereceden ve tam ikinci dereceden modellere ait sonuçlar verilmiştir.

Çizelge 4.2. Boyut küçülmesi (BK), yağ kaybı (YK) ve su kaybı (SK) için denenen modellerin önem faktörleri ve R² değerleri.

Cevap	Denenen Model											
	Doğrusal			Doğrusal+Kareler			Doğrusal+İlişkiler			Tam ikinci derece		
	BK	YK	SK	BK	YK	SK	BK	YK	SK	BK	YK	SK
Sabit	*	*	*	*	*	*	*	*	*	*	*	*
Yağ (Y)	*	**	**	*	*	**	*	**	**	*	*	*
Su (S)	*	**	*	*	**	*	*	**	*	*	**	*
TSP	*	*	*	*	*	*	*	*	*	*	*	*
Y*Y				**	*	**				**	*	**
S*S				**	*	**				**	*	**
TSP*TSP				**	*	*				**	*	*
Y*S							**	**	**	**	**	**
Y*TSP							**	**	**	**	**	**
S*TSP							**	**	*	**	**	*
R ²	0,95	0,54	0,93	0,96	0,97	0,94	0,95	0,44	0,94	0,95	0,97	0,96

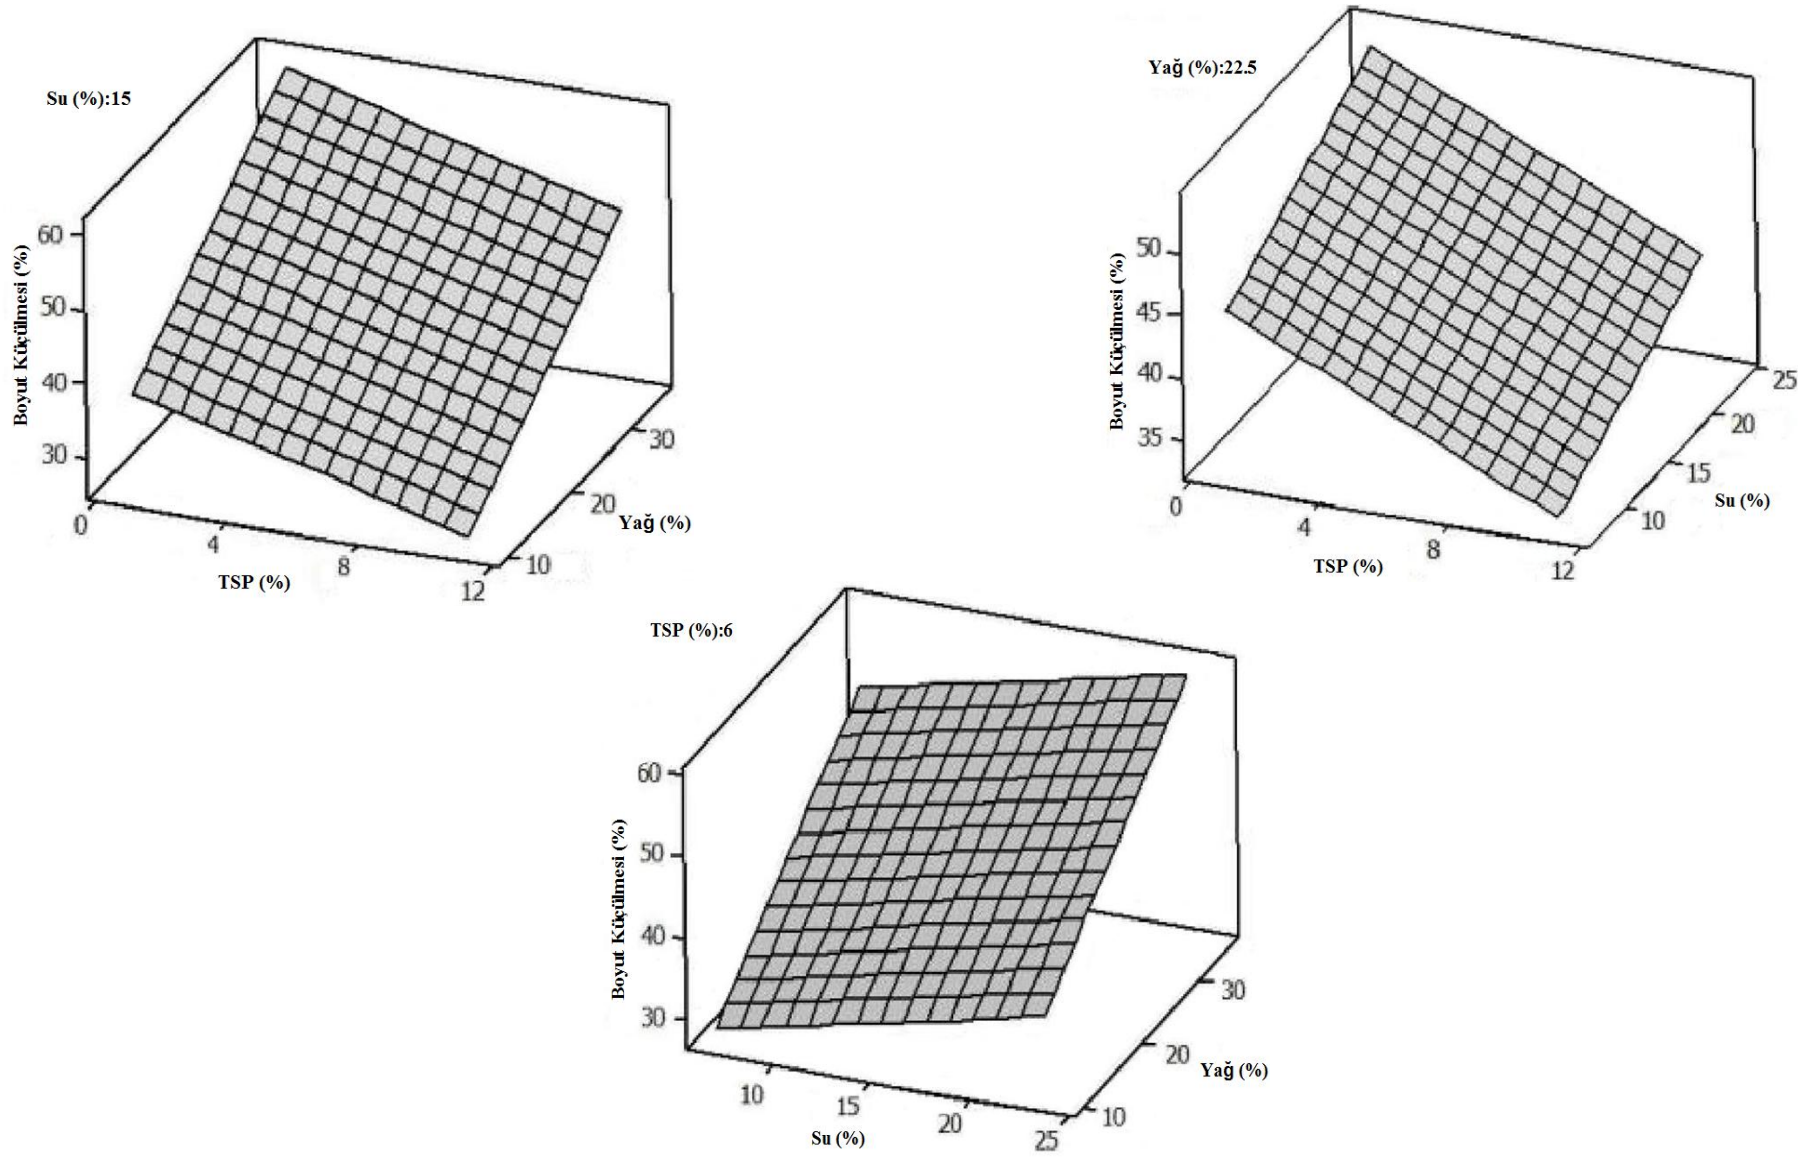
*: önemli (P < 0,05), **: önemli değil (P > 0,05)

Deneysel verilerin farklı modellerde (doğrusal, ikili faktöriyel ve üssel) denenmesi ve sonuçların varyans analizlerinin incelenmesi ile boyut küçülmesinin bağımsız değişkenler ile doğrusal bir şekilde ilişkili olduğu belirlenmiştir (Eşitlik 11).

$$\text{Boyut küçülmesi (\%)} = 43,366 + 6,523*Y + 2,511*S - 3,563*TSP \quad (11)$$

Ortaya konan model istatistiksel olarak önemsiz ($P > 0,05$) uyum eksikliği değerine sahiptir ve bu durum deneysel verilerle model eşitlik arasında uyum olduğunu göstermektedir. Model eşitlik $0,954 R^2$ değerine sahiptir ve bu eşitlik kullanılarak içerikteki yağ, su ve TSP oranlarından boyut küçülmesi tahmininin başarıyla yapılabileceği anlaşılmaktadır. Bağımsız değişkenlerin boyut küçülmesi üzerine etkisi Şekil 4.2’de verilmiştir.

Beklendiği gibi, yağ ve su miktarları boyut küçülmesi üzerine pozitif etki yaparken TSP miktarı negatif etki yapmaktadır. Model eşitlikte yağ, su ve TSP için bulunan etki katsayıları sırasıyla 6,523, 2,511 ve $-3,563$ ’tür. Bu model eşitlik yağ, su ve TSP miktarlarının bilinmesi durumunda boyut küçülmesinin tahmin edilmesini sağlayarak istenen son ürün özelliklerine ulaşmada üreticilere faydalı olacaktır.



Şekil 4.2. Bağımsız değişkenlerin (yağ, su, TSP) boyut küçülmesi üzerine etkisi.



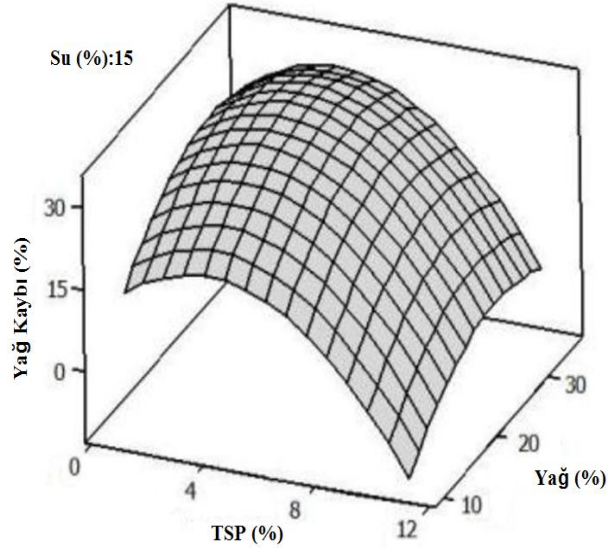
4.1.3. Yağ kaybı

Denemelerin yapıldığı bağımsız değişken değerleri aralığında yağ kaybı % 3,25 ile % 31,47 arasında değişmiştir. Köfte de dahil olmak üzere et ürünlerinin tamamında son ürünün içerdiği yağ miktarının sabit olması, partiler arası değişimin olmaması istenir. Ana formülde bulunan maddelerin miktarlarından yola çıkarak son ürünün pişme sonrası yağ kaybını tahmin edebilecek bir model eşitliğin geliştirilmesi bu alanda çalışan ve/veya üretim yapan kişi ve firmalara avantaj sağlayabilecektir. Bu amaç doğrultusunda araştırmamızda çığ üründeki yağ, su ve TSP oranlarından son ürünün yağ kaybını tahmin edebilen bir model eşitlik geliştirilmiştir.

Yağ kaybı üzerine TSP ve yağ içeriği doğrusal ve ikinci dereceden etki gösterirken ($P < 0,05$), su içeriği sadece ikinci dereceden etkili olmuştur. Etkileşim değerlerinin hiçbirinin etkili olmadığı belirlenmiştir ($P > 0,05$). İstatistiki olarak önemli bulunan katsayılar kullanılarak Eşitlik 12'de gösterilen model belirlenmiştir.

$$\text{Yağ kaybı (\%)} = 29,948 + 3,084*Y - 7,285*TSP - 2,737*(Y)^2 - 1,799*(S)^2 - 5,435*(TSP)^2 \quad (12)$$

Model eşitlik uyum eksikliği değeri önemsiz bulunmuş olup ($P > 0,05$), bu durum deneysel sonuçlar ile model eşitliğin verdiği sonuçlar arasında uyumsuzluk bulunmadığını göstermektedir. Modelin tahmin yeteneği yüksek R^2 (0,969) değeri ile oldukça başarılı bulunmuştur. Şekil 4.3. a, b ve c bağımsız değişkenlerin yağ kaybı üzerine etkisini göstermektedir. TSP miktarı $-7,285$ katsayısı ile yağ kaybı üzerindeki en önemli faktör olarak bulunmuştur ve TSP miktarındaki artışla yağ kaybı önemli ölçüde azalmaktadır. Model eşitlikte yağ miktarının ikinci dereceden etkisi beklenmedik şekilde negatif yönde önemli bulunmuştur. Yağ miktarının çok fazla artması ile yağ kaybı azalmaya başlamaktadır. Bu durum köfte içerisinde bulunan aşırı yağın pişme sırasında köfte yüzeyi ve yüzeyin hemen altında bir film tabaka oluşturarak yağ salınımını engellemesi ile açıklanabilir. Benzer bir sonuç Tornberg ve ark. (1989) tarafından da rapor edilmiş olup, aşırı yağ içeren köftelerde yağ globülleri arasındaki mesafenin azaldığı ve globüllerin bir arada durma eğilimine girerek dışarı yağ sızmasının önüne geçtiği belirtilmektedir.






Şekil 4.3. Bağımsız değişkenlerin (yağ, su, TSP) yağ kaybı üzerine etkisi.

4.1.4. Su kaybı

Deneme yapılan bağımsız değişken değer aralıklarında pişme sonrası su kaybı % 5,45 ile % 21,62 arasında bulunmuştur. Su kaybının pişmiş köftelerde görünüm ve yapıyı önemli şekilde etkilediği bilinmektedir. Bir çok araştırmada ürünün sululuğu önemli bir duyu kalite kriteri olarak ele alınmakta olup ürün toplam kalitesini etkilemektedir (Yılmaz 2005, Serdaroğlu 2006). Boyut küçülmesi ve yağ kaybında olduğu gibi su kaybı için de bağımsız değişkenlere bağlı model eşitlik geliştirilmiştir (Eşitlik 13).

$$\text{Su kaybı (\%)} = 14,699 + 0,512*Y + 2,122*S - 4,392*TSP - 0,619*(TSP)^2 - 0,826*S*TSP \quad (13)$$

Model eşitlikte uyum eksikliği değerinin önemsiz bulunması deneysel sonuçlar ile tahmin edilen sonuçların uyumlu olduğunu göstermektedir. R^2 değeri 0,964 bulunmuş olup, model eşitlikten elde edilen sonuçlar gerçek sonuçlara çok yakındır. Şekil 5 su kaybı üzerine yağ, su ve TSP miktarlarının etkisini göstermektedir ve köftelerde su kaybı model eşitliği yağ, su ve TSP miktarlarından tam ikinci dereceden katsayılarla etkilenmektedir (Çizelge 4.2. ve Şekil 4.4). Su kaybı üzerine en önemli etki $-4,392$ katsayısı ile TSP miktarından kaynaklanmaktadır. İçerikteki su miktarının artması da, beklendiği gibi, $2,122$ katsayısı ile pozitif olarak su kaybını etkilemektedir.

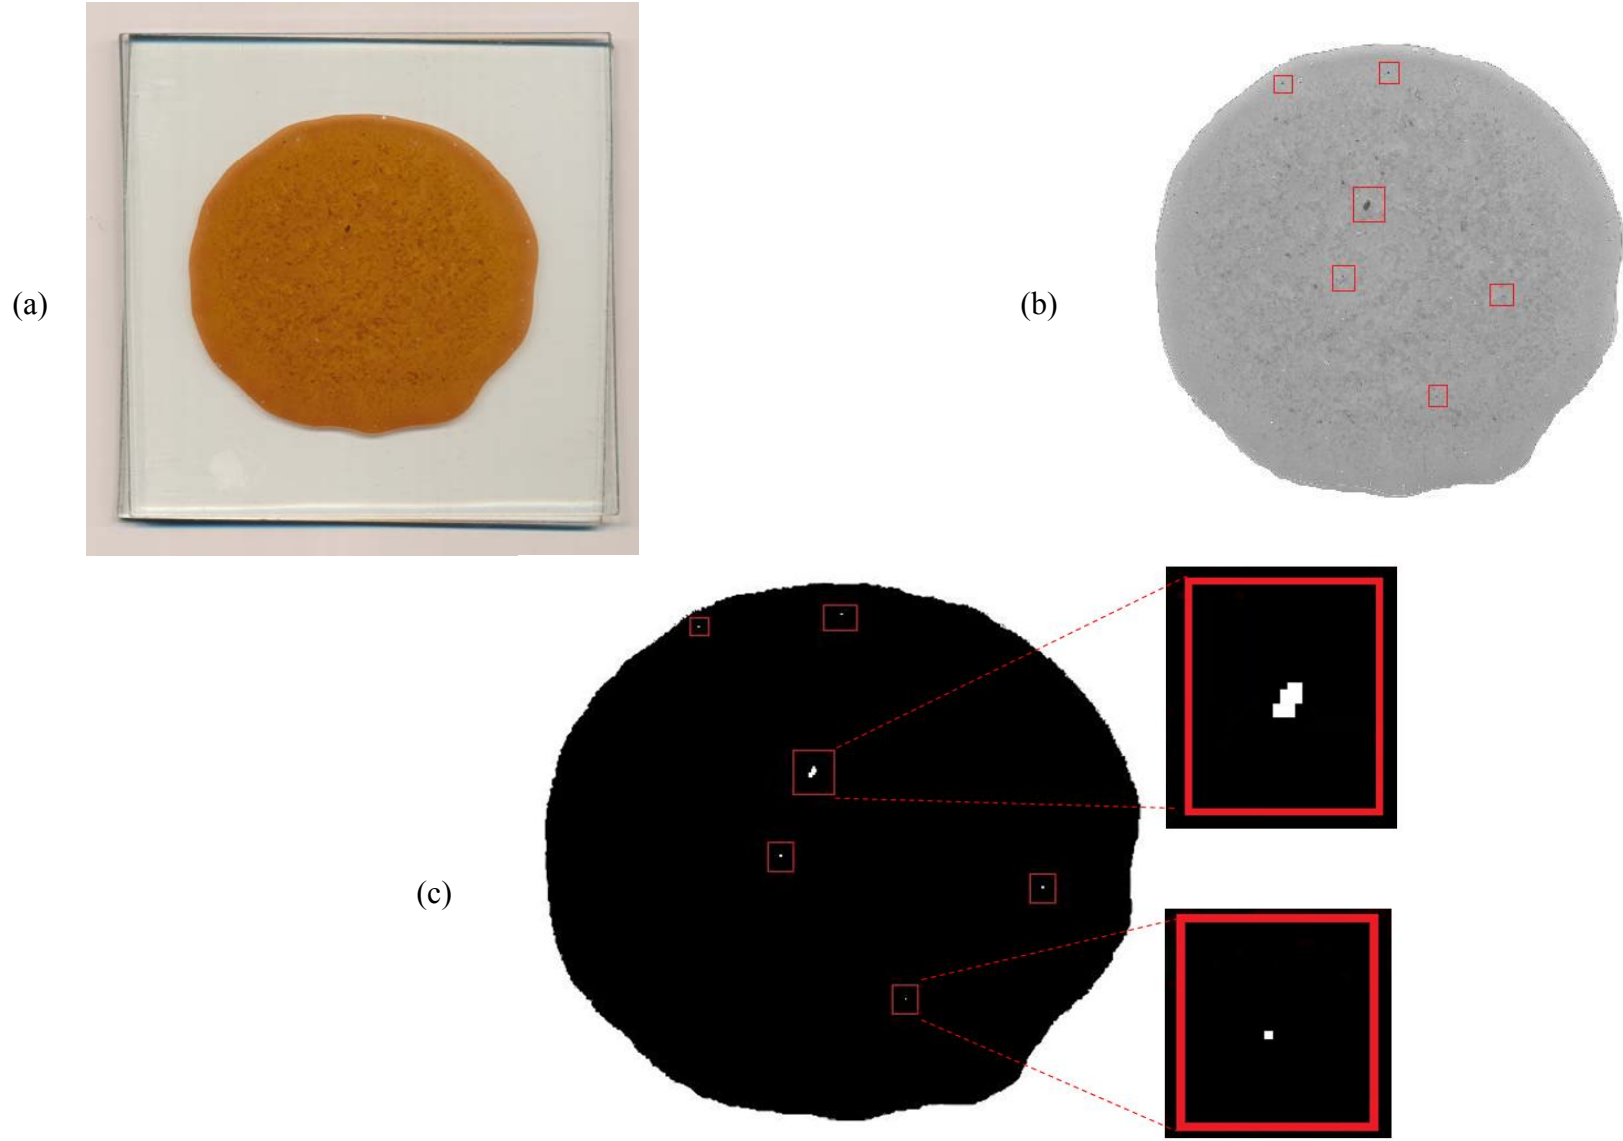


Şekil 4.4. Bağımsız değişkenlerin (yağ, su, TSP) su kaybı üzerine etkisi.

4.2. Domates Salçasında Görsel Kalite Özelliklerinin Belirlenmesi

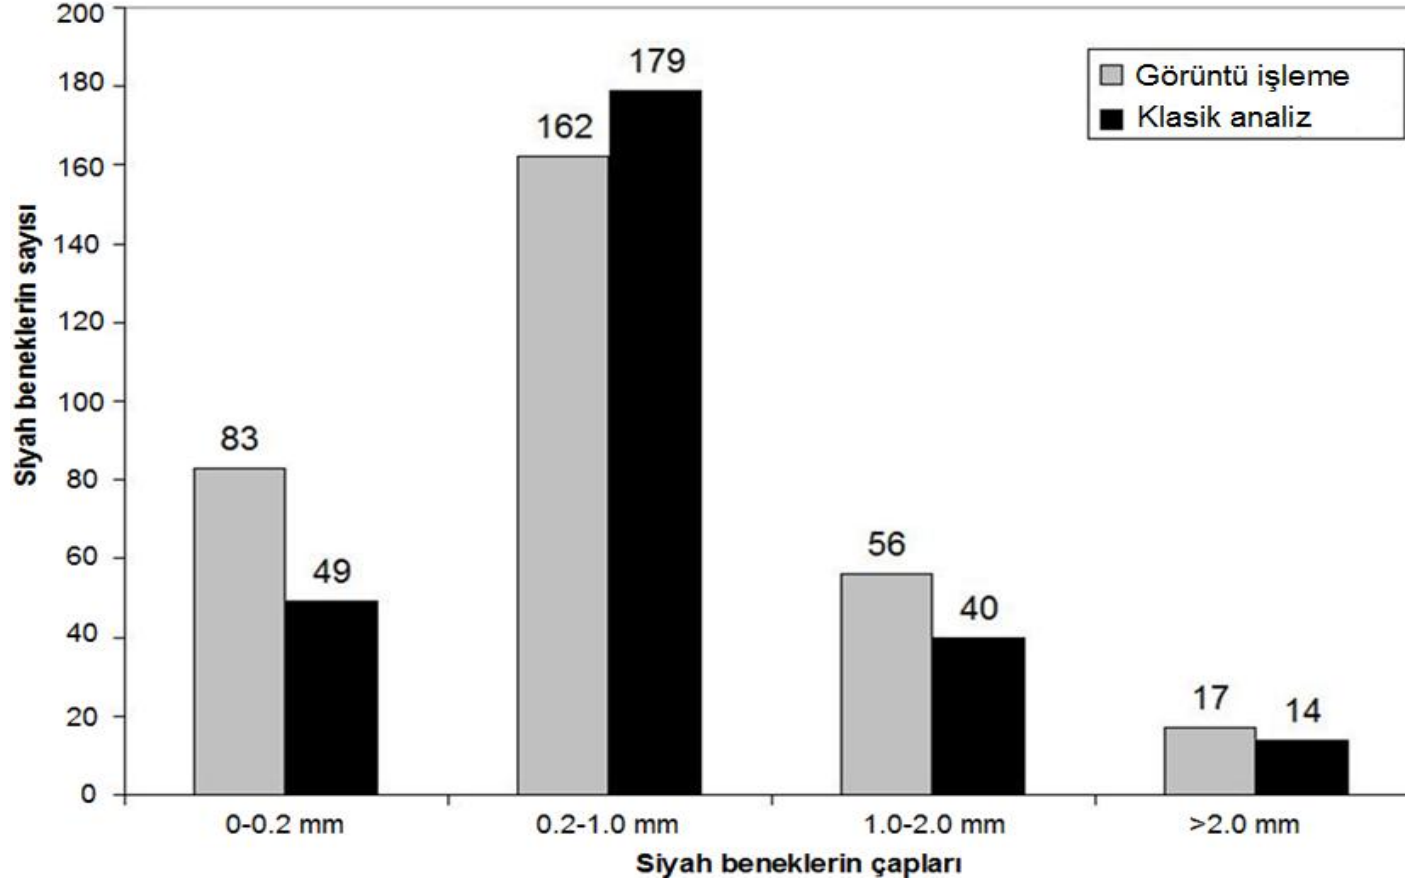
4.2.1. Siyah beneklerin belirlenmesi, çap ölçümü ve sınıflandırılması

Bir gram domates salçasındaki siyah benekler görüntü işleme sistemi ve çıplak gözle belirlenmiştir. Şekil 4.5. a'da iki cam arasındaki domates salçası örneğinin orijinal görüntüsü verilmiştir. Salçadaki siyah benekler ve arka plan arasındaki en yüksek kontrast görüntünün R (kırmızı) matrisinde belirlenmiş olup, segmente edilmiş R matrisi görüntüsü Şekil 4.5.b'de verilmiştir. Son olarak belirli bir eşik değeri kullanılarak segmente edilmiş görüntüden global eşik yaklaşımı ile siyah-beyaz görüntü elde edilmiştir (Şekil 4.5.c). Siyah-beyaz görüntüdeki beyaz piksel yığınları benekleri temsil ederken, siyah kısım arka planı oluşturmaktadır. Gözle yapılan sayımda görece küçük siyah beneklerin belirlenememesi ve sayımı yapan kişinin domates kabuğundan kaynaklanan koyu kırmızı ve kahverengi parçacıkları da siyah benek olarak teşhis etmesi gibi zorluklar meydana çıkmaktadır. Görüntü işleme yöntemi ile siyah benek sayımında en kritik nokta kullanılan cam plakaların her bir ölçüm öncesi çok dikkatli temizlenmesi ve herhangi bir siyah toz veya benzer parçacığın cama yapışmasının önlenmesidir.



Şekil 4.5. Orijinal görüntü (a), segmente edilmiş görüntü (b), siyah-beyaz görüntü (c).

Siyah beneklerin çapları bir uzman tarafından kumpas yardımı ile tek tek ölçülerek kaydedilmiştir. Çaplar aynı zamanda görüntü işleme sistemi ile de otomatik olarak belirlenmiştir. Şekil 4.6'da sonuçlar verilmiştir. Bu çalışmada kullanılan algorithmada tüm siyah benekler dairesel şekilli olarak kabul edilmiş olup benekleri temsil eden piksellerin toplam alanı hesaplanmıştır. Çıplak gözle yapılan analizde hem çapı 0,2 mm'den küçük siyah beneklerin teşhisinde hem de tüm siyah beneklerin çapının doğru bir şekilde ölçülmesinde zorluklar yaşanmıştır. Çizelge 4.2'de analizi yapılan 99 salça örneğinden rastgele seçilen 10 tanesi için görüntü işleme ve çıplak gözle yapılan siyah benek analiz sonuçları verilmiştir. Sonuçlar özellikle küçük siyah beneklerin bilgisayar tarafından doğru bir şekilde belirlendiğini ancak çıplak gözle yapılan sayımda bazılarının belirlenemediğini göstermektedir. Ancak yine Çizelge 4.3'de bilgisayar ve çıplak gözle yapılan ölçüm sonuçlarında toplamda 23 siyah benek teşhis edildiği görülmektedir. Şekil 4.6'da bilgisayar tarafından çapları 0-0,2 mm arasında daha fazla siyah benek belirlendiği görülmektedir. Siyah beneklerin şekilleri her zaman tam bir daire olmamasına karşın yasal mevzuat gereği çap ölçümü zorunludur (Anonim 1994, Anonim 2008). Şekil 4.6'da görüldüğü gibi çapları 0.2 mm'den büyük olan siyah beneklerin sayısı her iki yöntemle de hemen hemen aynı belirlenmiştir (233 ve 235). Belirli çap aralıklarındaki siyah benek sayılarının iki yöntemde farklı olmasının sebebi çıplak gözle yapılan ölçümlerde benek çapının doğru belirlenememesidir. Bunlara ilaveten bilgisayar çıplak gözle yapılan ölçümlerden çok daha hızlı sonuç vermektedir ve görüntü işleme teknolojisinin uygun bir algoritma ile kullanıldığında domates salçasında siyah benek analizi için çok etkili bir araç olabileceği anlaşılmaktadır.



Şekil 4.6. Görüntü işleme ve klasik analiz ile belirlenen siyah benek sayısı ve çapları.

Çizelge 4.3. Rastgele seçilen 10 örnek için görüntü işleme (Gİ) ve klasik analiz (KA) ile siyah benek belirleme, sayım ve çap ölçümü sonucu elde edilen veriler.

Örnek No	Belirli çap aralığındaki siyah beneklerin sayısı								Toplam	
	0-0,2 mm		0,2-1 mm		1-2 mm		>2 mm		KA	Gİ
	KA	Gİ	KA	Gİ	KA	Gİ	KA	Gİ		
1	0	2	2	2	0	0	0	0	2	4
2	1	3	0	1	1	0	0	0	2	4
3	0	2	1	1	1	1	0	0	2	4
4	0	2	3	2	0	1	0	0	3	5
5	2	3	4	3	0	1	0	0	6	7
6	0	1	0	0	2	1	0	1	2	3
7	0	1	0	0	0	0	0	0	0	1
8	1	4	7	5	0	2	1	1	9	12
9	0	2	1	1	0	0	0	0	1	3
10	0	2	0	0	0	0	0	0	0	2
Toplam	4	22	18	15	4	6	1	2	27	45

4.2.2. Renk ölçümü

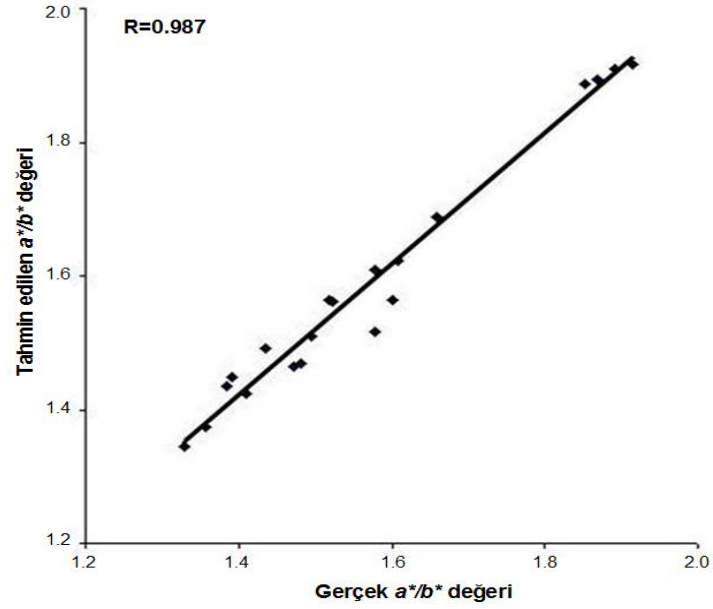
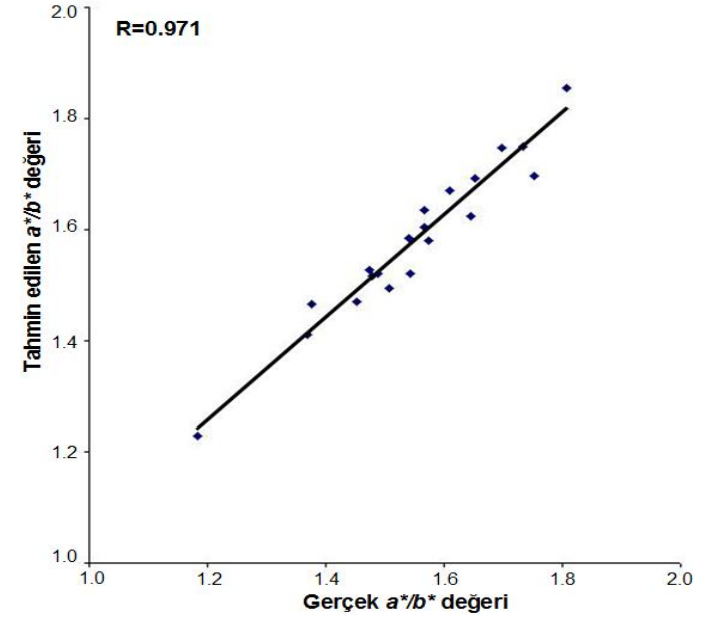
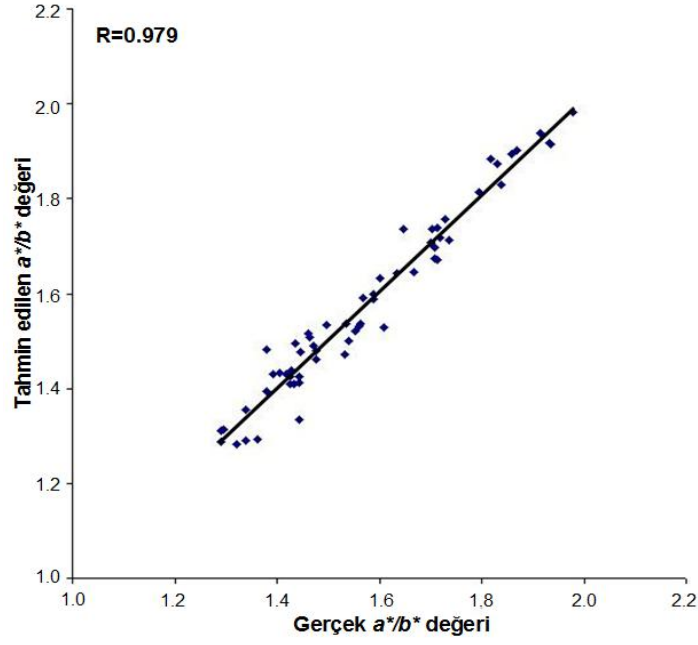
Önceki bölümlerde vurgulandığı üzere yapay sinir ağlarının tahmin yetenekleri gıda kontrol sistemlerinde son yıllarda sıklıkla kullanılmaktadır. Bu çalışmada, yapay sinir ağları domates salçasının L^* , a^* , b^* ve a^*/b^* değerleri için çok iyi tahminler üretmiştir. Eğitilen ağların performansları gerçek L^* , a^* , b^* ve a^*/b^* değerleri ile tahmin edilen L^* , a^* , b^* ve a^*/b^* değerleri karşılaştırılarak incelenmiştir. Eğitimde kullanılan veri setleri için regresyon katsayıları (R) L^* , a^* , b^* ve a^*/b^* için sırasıyla 0,896, 0,981, 0,911 ve 0,979 olarak belirlenmiştir. Eğitilen ağların validasyonunda kullanılan veri setleri için regresyon katsayıları L^* , a^* , b^* ve a^*/b^* için sırasıyla 0,918, 0,941, 0,878 ve 0,971 olarak belirlenmiştir. Son olarak ağların test edilmesi amacıyla kullanılan veri setleri için regresyon katsayıları L^* , a^* ,

b^* ve a^*/b^* için sırasıyla 0,889, 0,958, 0,907 ve 0,987 olarak belirlenmiş olup ağların yüksek bir doğrulukla tahmin yapabildiği anlaşılmıştır. Tüm sonuçlar Çizelge 4.4'te verilmiştir.

Domates salçasının rengi sarı ile kırmızı arasında ama daha çok kırmızıya yakındır. Üç boyutlu renk uzayında a^*/b^* değeri sarıdan kırmızıya geçişi tanımlamakta olup yüksek a^*/b^* değerleri salçanın daha kırmızı olduğunu göstermektedir. Domates ürünlerinin rengi ile ilgili yapılan bir çok çalışmada a^* , b^* veya bu iki değer kombinasyonlarından oluşan değerler kullanılmıştır (Rodrigo ve ark. 2007, Patras ve ark. 2009, Adekunte ve ark. 2010). Bu çalışmada da yapay sinir ağının a^*/b^* değeri için yaptığı tahminler oldukça yüksek regresyon katsayılarına sahip olup, yöntemin domates salçasında renk ölçümü için çok etkili olduğunu göstermektedir (Şekil 4.7).

Çizelge 4.4. L^* , a^* , b^* ve a^*/b^* değerleri için sinir ağından elde edilen eğitim (E), validasyon (V) ve test (T) sonuçlarına ait regresyon katsayısı (R), grafik eğimi ve kesme noktası değerleri.

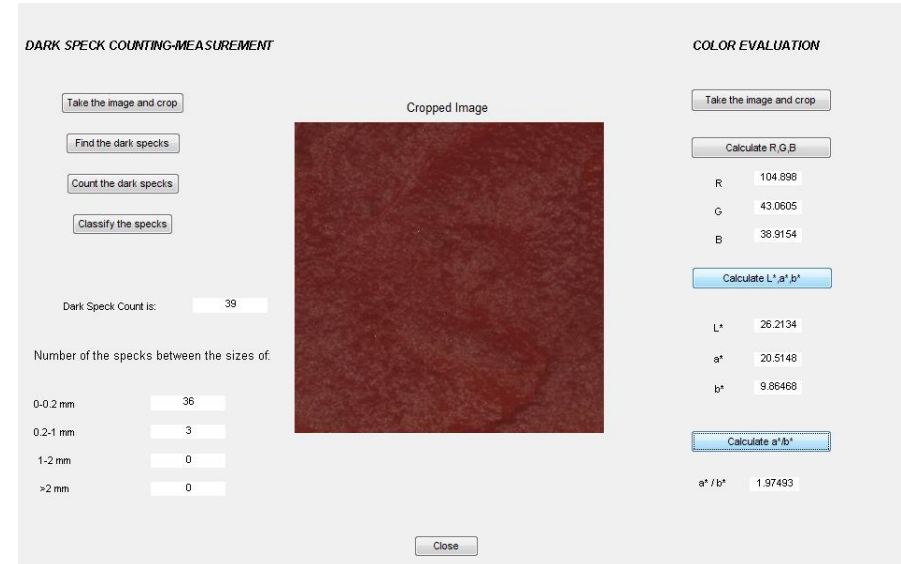
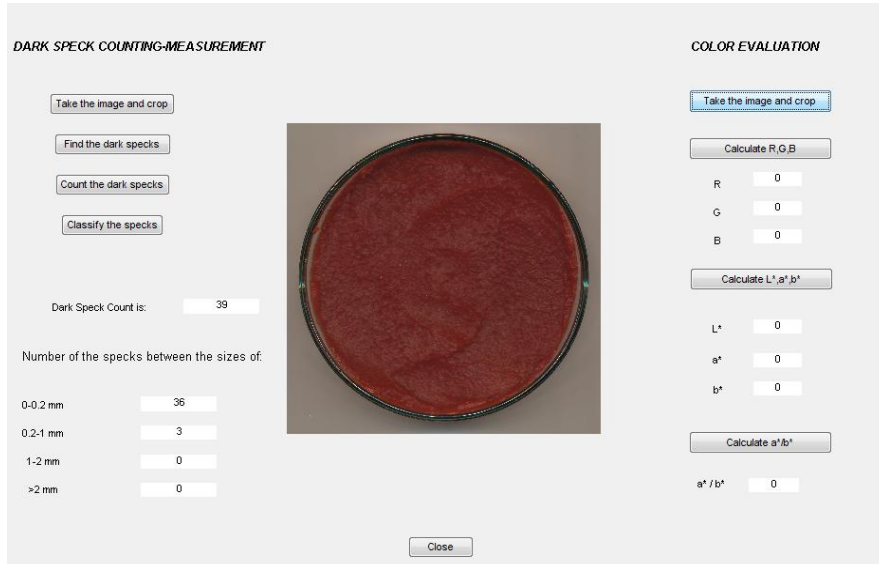
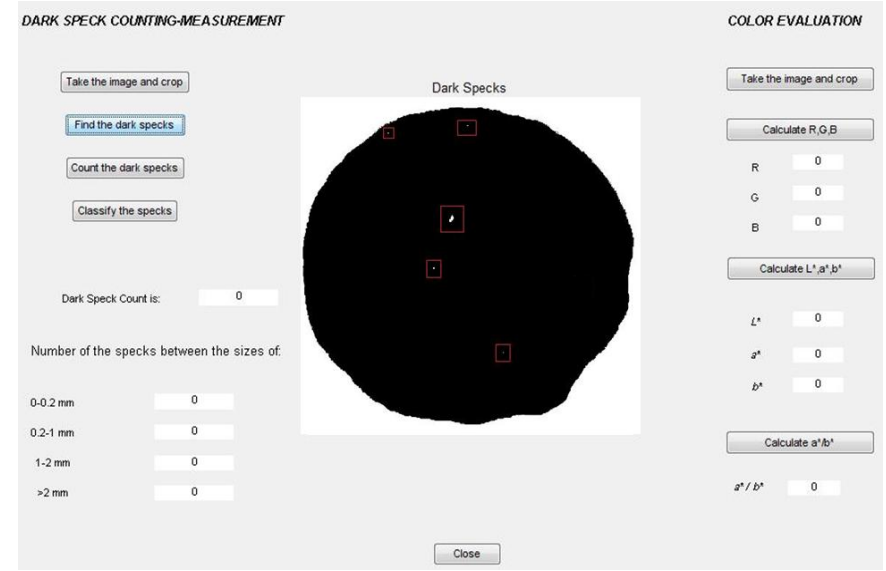
	L^*			a^*			b^*			a^*/b^*		
	E	V	T	E	V	T	E	V	T	E	V	T
R	0,896	0,918	0,889	0,981	0,941	0,958	0,911	0,878	0,907	0,979	0,971	0,987
Eğim	1,105	1,176	0,945	1,003	1,036	1,061	1,014	0,942	0,918	1,017	0,922	0,978
Kesme noktası	-2,657	-4,914	+1,162	-0,035	-0,695	-0,992	-0,153	+0,687	+0,644	-0,025	+0,149	+0,052



Şekil 4.7. Yapay sinir ağının a*/b* için yaptığı tahminlere ait eğitim (a), validasyon (b), test (c) verisi grafikleri.

4.2.3. Grafiksel kullanıcı arayüzü tasarımı

Üretimde otomasyon son yıllarda bir çok gıda üretim prosesinde kullanılmaya başlanmıştır. Kullanıcı dostu otomatik proses kontrol üniteleri, yapay zekanın adapte edildiği makineler ve bilgisayarlı kalite kontrol sistemleri endüstriyel üretimde son dönemde kullanım alanı bulan uygulamalardır. Bu çalışmada Matlab ortamında yazılmış olan algoritmanın tamamı grafiksel kullanıcı arayüzüne adapte edilmiştir. Böylece domates salçasının kalite kontrolünde görevli olan kişinin yapacağı siyah benek tayini ve renk analizi için bilgisayar ortamında herhangi bir komut yazmasına ya da sistemin çalışma şekli hakkında detaylı bilgi edinmesine gerek kalmadan analizi yapabilmesi hedeflenmiştir. Grafiksel kullanıcı arayüzü temelde basit bir grafiksel ekrandır. Şekil 4.8’de görüldüğü gibi ekranın sol bölümünde salçada siyah benek analizinin yapılabilmesi, sağ bölümde ise renk analizinin yapılabilmesi mümkündür. Sistemde salça görüntüsü tarayıcıdan bilgisayara aktarıldıktan sonra tasarlanan arayüz üzerindeki butonlar kullanılarak önce siyah benekler belirlenmekte, sayılmakta ve çaplarına göre sınıflandırılmaktadır. Bu işlem bittikten sonra, ekranın sağ tarafındaki butonlar kullanılarak yine taranmış olan salça görüntüsü üzerinde çalışılmaya başlanmakta olup, önce görüntünün ortalama R, G, B değerleri elde edilmekte ve sonrasında birbirinden bağımsız çalışan 4 farklı yapay sinir ağı yine butonlarla aktive edilerek L^* , a^* , b^* ve a^*/b^* sonuçları ekrana yansıtılmaktadır. Laboratuvar ortamında yapılan denemelerde çıplak gözle yapılan siyah benek sayımı ve Hunter Lab ile renk ölçümü bir salça numunesi için örnek hazırlama süresi hariç yaklaşık 5 dakika sürmektedir. Tüm bu işlemler bu çalışmada tasarlanan sistemle yapıldığında 20-25 saniyede bitirilmekte olup sistemin hızı grafiksel kullanıcı arayüzü ile çok tatmin edici bir seviyeye çıkmıştır.



Şekil 4.8. Grafiksel kullanıcı arayüzü tasarımı

4.3. Kuru İncirlerde Aflatoksin Varlığının Belirlenmesi

4.3.1. HPLC ile aflatoksin analizi


Analizi yapılan 82 örnekten 65 tanesinde aflatoksin seviyesi tespit edilebilir limitlerin altında olup, 17 örnekte ise aflatoksin belirlenmiştir. Örneklerin içerdiği aflatoksin miktarları ve RGB değerleri ile aflatoksin içermeyen örneklere ait ortalama RGB değerleri Çizelge 4.5’de verilmiştir. Aflatoksin belirlenebilirlik limiti 0,01 ppb, geri kazanım oranı % 97 olarak belirlenmiştir.

Çizelge 4.5. Piyasadan sağlanan kuru incirlerin RGB değerleri ve aflatoksin miktarları (ppb).

<i>Örnek No</i>	<i>Aflatoksin B₁ (ppb)</i>	<i>Toplam Aflatoksin (ppb)</i>	<i>R</i>	<i>G</i>	<i>B</i>
1	1,13	2,25	4,66	101,90	204,04
2	1,16	3,11	3,67	99,92	195,01
3	0,42	0,42	4,02	111,20	187,20
4	2,11	2,78	5,88	100,09	161,78
5	1,92	3,00	4,44	95,87	200,22
6	3,40	7,22	2,10	95,09	198,98
7	1,32	2,19	6,90	102,54	156,80
8	2,45	4,00	10,10	103,98	133,09
9	5,37	9,80	3,30	110,45	188,09
10	5,26	9,76	4,32	81,45	205,88
11	4,16	4,16	5,50	90,00	140,40
12	6,23	10,02	9,03	97,20	156,90
13	4,13	7,22	1,10	78,21	134,44
14	5,55	8,04	1,34	120,32	207,09
15	1,02	1,02	4,55	80,90	195,90
16	3,44	3,90	5,21	103,47	194,77
17	3,12	4,78	2,20	100,76	166,89
Kontrol (ortalama)	-	-	8,66	84,22	141,04


4.3.2. İncir görüntülerinin işlenmesi

Piyasadan sağlanan 82 örnek ve laboratuarda aflatoksin ilave edilerek elde edilen 10 örnekten alınan görüntüler Matlab ortamında işlenmiştir. Şekil 4.9’da 1750 x 1000 piksel boyutundaki görüntülerden bir örnek verilmiştir.



Şekil 4.9. 365 nm UV ışık altında kuru incir görüntüsü.

Elde edilen görüntülerin RGB değerleri Matlab ortamında yazılan algoritma ile belirlenmiş ve kaydedilmiştir. Genel olarak aflatoksin içeren örneklerin mavi ve yeşil renk yoğunlukları aflatoksin içermeyen örneklere göre daha fazladır. Görüntüsü işlenen 65 temiz örnek ve 17 aflatoksinli örnek ele alındığında 65 örnekten 57’sinde mavi ve yeşil renk değerinin diğer 17 örnekten daha düşük olduğu belirlenmiştir. Benzer şekilde laboratuvar ortamında yapay olarak elde edilen aflatoksinli incir örneklerinin mavi ve yeşil renk yoğunluğunun kontrol olarak kullanılan temiz örnekten daha fazla olduğu belirlenmiştir. Bu örneklerin UV ışık altındaki görüntüleri Şekil 4.10’da verilmiştir.



Şekil 4.10. Laboratuarda aflatoksin ilave edilen 10 adet ve aflatoksinsiz (kontrol) bir adet kuru incir örneği.

Gözle yapılan kontrolde bu örnekler arasındaki fark kolayca anlaşılmasına karşın görüntüler analiz edildiğinde RGB değerlerinin ayrımı kolaylaştırabilecek özellikte olduğu görülmektedir. Çizelge 4.6'da bu 11 örnek için elde edilen RGB değerleri verilmiştir.

Çizelge 4.6. Laboratuvar ortamında elde edilen aflatoksinli örneklerin RGB yoğunluk değerleri.

<i>Örnek No</i>	<i>R (Kırmızı)</i>	<i>G (Yeşil)</i>	<i>B (Mavi)</i>
1	1,15	113,99	218,91
2	13,05	114,49	191,12
3	9,02	103,96	187,92
4	4,71	112,05	202,36
5	4,21	109,19	199,97
6	8,19	110,61	196,74
7	28,47	114,74	172,95
8	8,29	103,36	191,91
9	4,7	101,22	191,09
10	6,19	97,89	184,86
Kontrol (Temiz)	11,16	87,75	138,09

4.3.3. Yapay sinir ağı ile aflatoksin tespiti

Görüntülerden elde edilen RGB verileri metot bölümünde yapısı tanımlanan ileri beslemeli yapay sinir ağına verilerek çıktı olarak aflatoksin var/yok sonucuna ulaşılmaya çalışılmıştır. Yapay sinir ağına beslenen 82 verinin 58 tanesi eğitim, 12'ser tanesi ise validasyon ve test amacı ile kullanılmış olup, ağın performansı elde edilen sonuçların gerçek verilerle uygunluğu regresyon katsayısı (R) kontrol edilerek ortaya konmuştur. Buna göre elde edilen yapay sinir ağının başarısı eğitim verileri için $R=0,766$, validasyon verileri için $R=0,962$ ve test verileri için $R=0,899$ şeklinde belirlenmiştir.

Çizelge 4.5 ve Çizelge 4.6 incelendiğinde genel olarak aflatoksin içeren örneklere ait görüntülerin G ve B değerlerinin aflatoksin içermeyen örneklere göre daha yüksek olduğu görülmektedir. Aflatoksin içerdiği belirlenen 17 örnekten elde edilen görüntülerin G ve B değerleri incelendiğinde 3 örnek için G değeri ve yine 3 örnek için B değerinin aflatoksin içermeyen 65 örnekten elde edilen görüntülerin ortalama G ve B değerlerinden daha düşük olduğu görülmektedir (Çizelge 4.5). Benzer şekilde aflatoksin içermeyen 65 örnek içerisinde de G ve B değeri aflatoksin içeren örneklerden daha yüksek olan görüntüler elde edilmiştir. Aflatoksin içeriği ile G ve B değerleri arasında doğrusal bir ilişki olmadığı anlaşılmakta olup, bu çalışmada olası bir ilişkiyi ortaya koymak amacıyla yapay sinir ağı kullanılmıştır. Yapay sinir ağlarının çalışma ve sonuç verme mantığı dikkate alındığında ağa verilen RGB değerleri sadece belirli bir değerden yüksek ise örnekte aflatoksin var, eğer düşük ise aflatoksin yok şeklinde sonuç vermediği bilinmektedir. Ancak elde edilen ağa ait R değerleri görüntülerin analizi sonucu elde edilen RGB değerlerinin, örnekte bulunan aflatoksin miktarı ile ilişkili olduğunu, ortaya çıkan beklenmedik sonuçların ise örnek hazırlama sırasında homojenizasyonun iyi yapılamaması, görüntü alımı sırasında UV floresanda meydana gelmiş olabileceği düşünülen ışık şiddeti dalgalanmaları gibi sebeplerden meydana geldiği düşünülmektedir.

5. SONUÇ ve ÖNERİLER

5.1. Hamburger Köftelerinde Yağ, Su ve Boyut Kaybının Belirlenmesi

Köftenin yağ, su ve TSP içeriği pişme sonrası boyut küçülmesi, yağ kaybı ve su kaybını etkilemektedir. Araştırmada geliştirilen modeller kullanılarak istenen son ürün özelliklerine ulaşmak mümkün olacaktır. Bu modellerle ayrıca boyut küçülmesi, yağ kaybı ve su kaybına en çok etki eden faktörleri ve bu faktörlerin etki katsayılarını ortaya koymada oldukça başarılı bulunmuştur. Yağ kaybı ve su kaybında en önemli faktör olarak TSP miktarı bulunmuş olup etki katsayıları sırasıyla $-7,285$ ve $-4,392$ 'dir. Bunun yanında pişme sonrası boyut küçülmesine ürünün yağ içeriği $6,523$ katsayısı ile en fazla etki eden faktör olarak belirlenmiştir. Yağ kaybı için belirlenen model ayrıca göstermiştir ki ürüne yapılan aşırı yağ ilavesi belli bir miktardan sonra yağ kaybını azaltıcı etki göstermektedir.

5.2. Domates Salçasında Renk ve Siyah Benek Belirlenmesi

Siyah beneklerin sayısı ve boyutları domates salçası için önemli kalite kriterleridir. Rutin uygulamada bu fiziksel analiz çıplak gözle yapılmakta olup, insan faktörü devreye girdiği için bir çok hatayı da beraberinde getirmektedir. Bu çalışmada görüntü işleme teknolojisinin çok hassas bir belirleme yeteneği olduğu görülmüş olup, otomasyonun uygulandığı sistemlerde rahatlıkla kullanılacağı anlaşılmıştır. Bunun yanında salçada renk tayininin yapılabilmesi için gereken laboratuvar cihazlarının hem pahalı oluşu hem de bu cihazların renk ölçümünü bir kaç santimetrekarelik bir alanda yapıyor oluşu, bu çalışmada tasarlanan sistemin avantajlarını ortaya koymaktadır. Oldukça yüksek bir başarı ile L^* , a^* , b^* ve a^*/b^* tahmininin sadece ofis tipi bir tarayıcı, bilgisayar ve uygun bir yazılım ile yapılabilmesi bu analizleri rutin olarak yapması gereken üreticilerin ve konunun uzmanlarının ihtiyaçlarına cevap verebilecektir.

Çalışmanın sonuçları görüntü işleme ve yapay sinir ağları ile elde edilen verilerin Hunter Lab ve görsel analiz ile elde edilen verilerle tutarlı olduğunu göstermiştir. Rutin yöntemlerle kıyaslandığında ilk hali ile de daha hızlı sonuç veren görüntü işleme ve yapay sinir ağlarının grafiksel kullanıcı arayüzüne aktarılması sistemin etkinliğini arttırmıştır. Bir numune için

gereken süreler kıyaslandığında yeni sistemin ihtiyaç duyduğu sürenin (20-25 s) klasik yöntemin ihtiyaç duyduğu süreden (5 dk) yaklaşık 12-15 kat daha az olduğu görülmektedir. Bu haliyle, geliştirilen sistem domates salçası üreticileri, kontrolörleri ve denetmenleri tarafından kullanılmaya uygundur ve arayüzün sağladığı kullanım kolaylığı sayesinde analizler, konu hakkında hiç bilgisi olmayan kişiler tarafından dahi yapılabilir.

5.3. Kuru İncirde Aflatoksin Belirlenmesi

Aflatoksin içeriği ülkemizde üretilen kuru incirler için önemli bir problem olarak görülmekte olup; gerek ülkemiz gerekse yabancı ülkeler aflatoksin için sınır değerleri çok düşük seviyelerde belirlemiştir. Son düzenlemelerde kuru incirde bulunmasına izin verilen toplam aflatoksin seviyesi 10 ppb olarak belirlenmiştir. HPLC ile aflatoksin analizi yüksek doğrulukta sonuç vermesine karşın, oldukça fazla zaman alan ve kullanılan kimyasallar ve işgücü düşünüldüğünde pahalı bir yöntem olarak kabul edilmektedir. Kuru incir üretimi yapılan tesislerde aflatoksin içeren incirlerin en baştan ayrılabilmesi için hızlı bir yöntem olarak kalitatif sonuç veren UV ışık altında gözle ayırma yöntemi sıklıkla kullanılmakta olup, bu yöntemin kontrolü yapan kişinin algısına bağlı olarak hatalı sonuç verme ihtimali bulunmaktadır. Bu çalışmada, görüntü işleme teknolojisi ve yapay sinir ağlarının beraber kullanıldığı bir sistemin üretim hattına ilave edilmesi ile en azından aflatoksin var/yok teşhisinin insandan kaynaklanan hatalara fırsat vermeden yapılabileceği ortaya konmuştur. Daha fazla sayıda örnekle çalışılarak yöntemin geliştirilebilmesi durumunda görüntüden miktar tayini yapılabilmesinin mümkün olabileceği ve ileride bu yönde çalışmalar yapılmasının faydalı olacağı düşünülmektedir.

KAYNAKLAR

Adekunte A.O, Tiwari B.K, Cullen P.J, Scannell A.G.M, Donnell C.P.O (2010). Effect of sonication on colour, ascorbic acid and yeast inactivation in tomato juice. Food Chemistry, doi:10.1016/j.foodchem.2010.01.026.

Aguirre L, Frias J.M, Barry-Ryan C, Grogan H (2009). Modelling browning and brown spotting of mushrooms (*Agaricus bisporus*) stored in controlled environmental conditions using image analysis. Journal of Food Engineering, 91:280-286.

Aliaa A.R.N, Mazlina M.K.S, Taip F.S, Abdullah A.G.L (2010). Response surface optimization for clarification of white pitaya juice using a commercial enzyme. Journal of Food Process Engineering, 33:333-347.

Anonim (1977). United States Standards for Grades of Canned Tomato Paste, (42 FR 41843), United States Department of Agriculture.

Anonim (1994). United States Standards for Grades of Tomato Sauce, (59 FR 52624), United States Department of Agriculture.

Anonim (2004). Proposed draft revised Codex Standard for processed tomato concentrates. Codex Alimentarius, Joing FAO/WHO Food Standards Programme Codex Committee on Processed Fruits and Vegetable, 22nd Session, Washington DC Metro Area, U.S.A.

Anonim (2008). Domates Salçası ve Püresi Standardı, TS 1466, Türk Standartları Enstitüsü, Ankara.

Anonim 2009a. <http://www.figes.com.tr/urunler/matlab/matlab.php>.

Anonim 2009b. Image processing toolbox, Mathworks.

Anonim 2009c. Gıda Maddelerindeki Bulaşanların Maksimum Limitleri Hakkında Tebliğde Değişiklik Yapılması Hakkında Tebliğ, Tebliğ No: 2009/22.

AOAC (1990). Official methods for the analysis (15th ed.). Arlington, Washington, DC: Association of Official Analytical Chemists.

Ballard D.A, Brown C.M (1982). Computer vision. Englewood Cliffs, NJ, USA: Prentice-Hall.

Baş D, Boyacı İ.H (2007). Modeling and optimization I: Usability of response surface methodology. Journal of Food Engineering, 78:836-845.

Bicanic D, Vrbic I, Cozijnsen J, Lemic S, Doka O (2006). Sensing the heat of tomato products red: The new approach to the objective assessment of their color. Food Biophysics 1(1):14-20.

Boran G, Regenstein J.M (2009). Optimization of gelatin extraction from silver carp skin. Journal of Food Science, 74(8):432-441.

Briones V, Aguilera J.M (2005). Image analysis of changes in surface color of chocolate. *Food Research International*, 38:87-94.

Brosnan T, Sun D-W (2004). Improving quality inspection of food products by computer vision-a review. *Journal of Food Engineering*, 61:3-16.

Çoksöyler N (1994). Türkiye’de mikotoksin problemi. II. Gıda Mühendisliği Kongresi, 21-23 Eylül, Gaziantep, s.234-239.

Del Moral F.G, O’Valle F, Masseroli M, Del Moral R.G (2007). Image analysis application for automatic quantification of intramuscular connective tissue in meat. *Journal of Food Engineering*, 81:33-41.

Desmond E.M, Troy D.J, Buckley D.J (1998). The effects of tapioca starch, oat fibre and whey protein on the physical and sensory properties of low-fat beef burgers. *Lebensmittel-Wissenschaft und- Technologie*, 31:653-657.

Doyle M.P, Beuchat L.R, Montville T.J (1997). *Food Microbiology Fundamentals and Frontiers*, ASM Press, Washington D.C. p768.

Du C-J, Sun D-W (2004). Recent developments in the applications of image processing techniques for food quality evaluation. *Trends in Food Science & Technology*, 15:230-249.

Du C-J, Sun D-W (2006a). Automatic measurement of pores and porosity in pork ham and their correlations with processing time, water content and texture. *Meat Science*, 72:294-302.

Du C-J, Sun D-W (2006b). Estimating the surface area and volume of ellipsoidal ham using computer vision. *Journal of Food Engineering*, 73:260-268.

Du C-J, Sun D-W, Jackman P, Allen P (2008). Development of a hybrid image processing algorithm for automatic evaluation of intramuscular fat content in beef *M.longissimus dorsi*. *Meat Science*, 80:1231-1237.

Garcia-Gimeno R.M, Hervas-Martinez C, Rodriguez-Perez R, Zurera-Cosano G (2005). Modelling the growth of *Leuconostoc mesenteroides* by artificial neural networks. *International Journal of Food Microbiology*, 105:317-332.

Godsalve E.W, Davis E.A, Gordon J (1977). Water loss rates and temperature profiles of dry cooked bovine muscle. *Journal of Food Science*, 42(4):1038-1045.

Gonçalves E.C, Minim L.A, Coimbra J.S.R, Minim V.P.R (2005). Modeling sterilization process of canned foods using artificial neural networks. *Chemical Engineering and Processing*, 44:1269-1276.

Görz G, Nebel B (2005). *Yapay Zeka. İnkılap Kitapevi, İstanbul.*

Gujral H.S, Kaur A, Singh N, Sodhi N.S (2002). Effect of liquid whole egg, fat and textured soy protein on the textural and cooking properties of raw and baked patties from goat meat. *Journal of Food Engineering*, 53:377-385.

- Hsu S.Y, Chung H.-Y (1998). Effects of processing factors on qualities of emulsified meatball. *Journal of Food Engineering*, 36:337-347.
- Hsu S.Y, Chung H.-Y (2000). Interactions of konjac, agar, curdlan gum, κ -carrageenan and reheating treatment in emulsified meatballs. *Journal of Food Engineering*, 44:199-204.
- Hsu S.Y, Chung H.-Y (2001). Effects of κ -carrageenan, salt, phosphates and fat on qualities of low fat emulsified meatballs. *Journal of Food Engineering*, 47:115-121.
- Hsu S.Y, Yu S.H (1999). Effects of phosphate, water, fat and salt on qualities of low-fat emulsified meatball. *Journal of Food Engineering*, 39:123-130.
- Jackman P, Sun D-W, Du C-J, Allen P, Downey G (2008). Prediction of beef eating quality from colour, marbling and wavelet texture features. *Meat Science*, 80:1273-1281.
- Jakobsen M, Bertelsen G (2000). Colour stability and lipid oxidation of fresh beef. Development of a response surface model for predicting the effects of Temperature, storage time, and modified atmosphere composition. *Meat Science*, 54:49-57.
- Jay J.M (1992). *Modern Food Microbiology*. Fourth Edition, Chapman & Hall, London, 701p.
- Joshi P (2002). Color measurement of foods by color reflectance. In D. MacDougall (Ed), *Color in Food: Improving Quality*, pp 21-30, CRC Pres, Washington DC.
- Jumah R, Banat F, Al-Asheh S, Hammad S (2004). Drying kinetics of tomato paste. *International Journal of Food Properties*, 7(2):253-259.
- Kabak B (2007). Bazı Mikotoksinlerin Detoksifikasyonunda *Lactobacillus* ve *Bifidobacterium* Suşlarının Kullanımı, Doktora Tezi, ÇÜ, FBE.
- Karaca H, Nas S (2006). Aflatoxins, patulin and ergosterol contents of dried figs in Turkey. *Food Additives and Contaminants*, 23(5):502-508.
- Kılıç K, Boyacı İ.H, Köksel H, Küsmenoğlu A (2007). A classification system for beans using computer vision system and artificial neural networks. *Journal of Food Engineering*, 78:897-904.
- Kılıç K, Onal-Ulusoy B, Boyacı İ.H (2007). A novel method for color determination of edible oils $L^*a^*b^*$ format. *European Journal of Lipid Science and Technology*, 109:157-164.
- Koç B, Kaymak-Ertekin F (2010). Yanıt yüzey yöntemi ve gıda işleme uygulamaları. *Gıda*, 35(1):63-70.
- Kong F, Tang J, Lin M, Rasco B (2008). Thermal effects on chicken and salmon muscles: Tenderness, cook loss, area shrinkage, collagen solubility and microstructure. *LWT-Food Science and Technology*, 41(7):1210-1222.

Leon K, Mery D, Pedreschi F (2006). Color measurement in $L^*a^*b^*$ units from RGB digital images. *Food Research International*, 39:1084-1091.

McAndrew A (2004). An introduction to digital image processing with Matlab. Notes for SCM2511 image processing 1, Semester 1, School of Computer Science and Mathematics Victoria University of Technology, USA.

Mery D, Pedreschi F (2006). Advances in image and video segmentation, Chapter XVI Segmentation in Food Images, Idea Group Inc., USA.

Modi V.K, Mahendrakar N.S, Rao D.N, Sachindra N.M (2003). Quality of buffalo meat burger containing legume flours as binders. *Meat Science*, 66:143-149.

Montgomery D.C (2001). Design and analysis of experiments, chapter 11, pp:427-510, John Wiles & Sons Inc., NewYork.

Movagharnejad K, Nikzad M (2007). Modeling of tomato drying using artificial neural network. *Computers and Electronics in Agriculture*, 59:78-85.

Omid M, Khojastehnazhand M, Tabatabaeefar A (2010). Estimating volume and mass of citrus fruits by image processing technique. *Journal of Food Engineering*, 100:315-321.

Özkaya Ş, Taydaş E.E, Başaran A, Avcı B, Hızlı S (1999). Tarım ve Köyişleri Bakanlığı Ankara İl Kontrol Laboratuvarı Aflatoksin Analiz Kurs Notları, 7-14 Ağustos, Ankara.

Öztemel E (2006). Yapay sinir ağları. Papatya Yayıncılık, İstanbul.

Panda B.P, Javed S, Ali M (2010). Optimization of fermentation parameters for higher lovastatin production in red mold rice through co-culture of *Monascus purpureus* and *Monascus ruber*. *Food Bioprocess Technology*, 3:373-378.

Petras A, Brunton N, Da-Pieve S, Butler F, Downey G (2009). Effect of thermal and high pressure processing on antioxidant activity and instrumental colour of tomato and carrot purees. *Innovative Food Science and Emerging Technologies*, 10(1):16-22.

Razmi-Rad E, Ghanbarzadeh B, Mousavi S.M, Emam-Djomeh Z, Khazaei J (2007). Prediction of rheological properties of Iranian bread dough from chemical composition of wheat flour by using artificial neural networks. *Journal of Food Engineering*, 81:728-734.

Rodrigo D, Van-Loey A, Hendrickx M (2007). Combined thermal and high pressure colour degradation of tomato puree and strawberry juice. *Journal of Food Engineering*, 79(2):553-560.

Sağiroğlu Ş, Erler M, Beşdok E (2003). Mühendislikte yapay zeka uygulamaları 1/Yapay sinir ağları. Ufuk Kitap, Kayseri.

Sanchez M.C, Valencia C, Ciruelos A, Latorre A, Gallegos C (2003). Rheological properties of tomato paste: Influence of the Addition of tomato slurry. *Journal of Food Science*, 68(2):551-554.

Scott P.M (1998). Industrial and farm detoxification processes for mycotoxins. *Revue Med. Vet.*, 149(6):543-548.

Serdaroglu M (2006). Improving low fat meatball characteristics by adding whey powder. *Meat Science*, 72:155-163.

Serdarođlu M, Deđirmenciođlu Ö (2004). Effects of fat level (5%, 10%, 20%) and corn flour (0%, 2%, 4%) on some properties of Turkish type meatballs (koefte). *Meat Science*, 68:291-296.

Serdaroglu M, Yildiz-Turp G, Abrodimov K (2005). Quality of low-fat meatballs containing Legume flours as extenders. *Meat Science*, 70:99-105.

Simpson R, Almonacid S, Lopez D, Abakarov A (2008). Optimum design and operating conditions of multiple effect evaporators: Tomato paste. *Journal of Food Engineering*, 89:488-497.

Stien L.H, Kiessling A, Manne F (2007). Rapid estimation of fat content in salmon fillets by colour image analysis. *Journal of Food Composition and Analysis*, 20:73-79.

Stien L.H, Manne F, Fuohonene K, Kause A, Rungruangsak-Torrisen K, Kiessling A (2006). Automated image analysis as a tool to quantify the colour and composition of rainbow trout (*Oncorhynchus mykiss* W.) cutlets. *Aquaculture*, 261:695-705.

Tan J (2004). Meat quality evaluation by computer vision. *Journal of Food Engineering*, 61:27-35.

Tornberg E, Olsson A, Persson K (1989). A comparison in fat holding between hamburgers and emulsion sausages. In *Proceedings of the 35th international congress on meat science and technology* (pp. 753-757), Denmark, Kopenhagen.

Torrecilla J.S, Otero L, Sanz P.D (2005). Artificial neural networks: a promising tool to design and optimize high-pressure food processes. *Journal of Food Engineering*, 69:299-306.

Tripathy P.P, Kumar S (2009). Neural network approach for food Temperature prediction during solar drying. *International Journal of Thermal Sciences*, 48:1452-1459.

Tunail N (2000). *Funguslar ve Mikotoksinler. Gıda Mikrobiyolojisi ve Uygulamaları, Genişletilmiş 2. Baskı, Ankara Üniversitesi Ziraat Fakültesi Gıda Mühendisliği Bölümü yayını, s:522, 3. Bölüm, 13. Kısım, Sim Matbaası, Ankara.*

Ulu H (2004). Effect of wheat flour, whey protein concentrate and soya protein isolate on oxidative processes and textural properties of cooked meatballs. *Food Chemistry*, 87:523-529.

Ulu H (2006). Effects of carrageenan and guar gum on the cooking and textual properties of low fat meatballs. *Food Chemistry*, 95:600-605.

Ünlütürk A, Turantaş F (1998). *Gıda Mikrobiyolojisi, Ege Üniversitesi Yayınları, 1.baskı, İzmir.*

Valadez-Blanco R, Viridi A.I.S, Balke S.T, Diosady L.L (2007). In-line colour monitoring during food extrusion: Sensitivity and correlation with product colour. *Food Research International*, 40:1129-1139.

Wang H-H, Sun D-W (2002). Correlation between cheese meltability determined with a computer vision method and with Arnott and Schreiber. *Journal of Food Science*, 67(2):745-749.

Yilmaz I (2005). Physicochemical and sensory characteristics of low fat meatballs with added wheat bran. *Journal of Food Engineering*, 69:369-373.

Yılmaz İ, Dağlıoğlu O (2003). The effect of replacing fat with oat bran on fatty acid composition and physicochemical properties of meatballs. *Meat Science*, 65:819-823.

Yin Y-G, Ding Y (2009). A close to real-time prediction method of total coliform bacteria in foods based on image identification technology and artificial neural network. *Food Research International*, 42:191-199.

Zhang Y-J (2006). *Advances in image and video segmentation*, Idea Group Inc.

Zheng C, Sun D.-W, Du C.-J (2006). Estimating shrinkage of large cooked beef joints during air-blast cooling by computer vision. *Journal of Food Engineering*, 72:56-62.

Zheng C, Sun D-W, Zheng L (2006). Recent developments and applications of image features for food quality evaluation and inspection: A review. *Trends in Food Science and Technology*, 17:642-655.

EKLER

Ek-1. Hamburger köftesinde boyut kaybını belirlemede kullanılan algoritma

```
clear all;
close all;

I1 = imread('cigornek.jpg'); %Çiğ köfte görüntüsü yükleniyor.
I2=rgb2gray(I1);
figure, imshow(I2), title('1raw meatball');
text(size(I2,2),size(I2,1)+15, ...
      'Meatball 1 raw', ...
      'FontSize',7,'HorizontalAlignment','right');
I3=adapthisteq(I2);
I=imadjust(I3);
[junk threshold] = edge(I, 'sobel');
fudgeFactor = .18;
BWs = edge(I,'sobel', threshold * fudgeFactor);
se90 = strel('line', 3, 90);
se0 = strel('line', 3, 0);
BWsdil = imdilate(BWs, [se90 se0]);
BWdfill = imfill(BWsdil, 'holes');
BWnobord = imclearborder(BWdfill,4);
seD = strel('diamond',10);
BWfinal = imerode(BWnobord,seD);
BWfinal = imerode(BWfinal,seD);
figure, imshow(BWfinal), title('Segmented Raw Meatball Image');

d=0;
for i=1:1900
    for j=1:1900
        if BWfinal(i,j)==1
            d=d+1;
        end
    end
end
end
d;

L1 = imread('pismisornek.jpg'); %Pişmiş köfte görüntüsü yükleniyor.
L2=rgb2gray(L1);
figure, imshow(L2), title('1cooked meatball');
text(size(L2,2),size(L2,1)+15, ...
      'Meatball 1 cooked', ...
      'FontSize',7,'HorizontalAlignment','right');
L3=adapthisteq(L2);
L=imadjust(L3);
[junk threshold] = edge(L, 'sobel');
fudgeFactor = .18;
BWsL = edge(L,'sobel', threshold * fudgeFactor);
Lse90 = strel('line', 3, 90);
Lse0 = strel('line', 3, 0);
BWsLdil = imdilate(BWsL, [Lse90 Lse0]);
BWdLfill = imfill(BWsLdil, 'holes');
BWLnobord = imclearborder(BWdLfill, 4);
LseD = strel('diamond',10);
BWLfinal = imerode(BWLnobord,LseD);
BWLfinal = imerode(BWLfinal,LseD);
figure, imshow(BWLfinal), title('Segmented Cooked Meatball Image');
```

```
e=0;
for i=1:1900
    for j=1:1900
        if BWLfinal(i,j)==1
            e=e+1;
        end
    end
end
end
e;
Shrinkage=100*(d-e)/d;
Shrinkage
```

Ek-2. Domates salçasında siyah benek sayımı, sınıflandırılması ve renk ölçümü amaçlı GUI tasarımını içeren algoritma

```
clear all;
close all;
function varargout = analiz(varargin)
gui_Singleton = 1;
gui_State = struct('gui_Name',       mfilename, ...
                  'gui_Singleton',   gui_Singleton, ...
                  'gui_OpeningFcn', @analiz_OpeningFcn, ...
                  'gui_OutputFcn',  @analiz_OutputFcn, ...
                  'gui_LayoutFcn',   [], ...
                  'gui_Callback',    []);
if nargin && ischar(varargin{1})
    gui_State.gui_Callback = str2func(varargin{1});
end
if nargin
    [varargout{1:nargout}] = gui_mainfcn(gui_State, varargin{:});
else
    gui_mainfcn(gui_State, varargin{:});
end
function analiz_OpeningFcn(hObject, eventdata, handles, varargin)
imshow('siyahbenek.jpg');
handles.output = hObject;
guidata(hObject, handles);
function varargout = analiz_OutputFcn(hObject, eventdata, handles)
varargout{1} = handles.output;
function axes1_CreateFcn(hObject, eventdata, handles)
imshow('siyahbenek.jpg');
function pushbutton1_Callback(hObject, eventdata, handles)
I = imread('siyahbenek.jpg'); %Siyah beneklerin sayılacağı salça görüntüsü
yükleniyor.
imshow(I);
waitforbuttonpress
point1 = get(gca,'CurrentPoint')
rect = [point1(1,1) point1(1,2) 1700 1700];
[r2] = dragrect(rect);
K = imcrop(I, rect);
imshow(K),title('Cropped Image');
handles.mystuff.K=K;
guidata(gcbo, handles);
function pushbutton2_Callback(hObject, eventdata, handles)
K=handles.mystuff.K;
x=1701;
y=1701;
for i=1:x;
for j=1:y;
if K(i,j,1)<100;
K(i,j,:)=255;
else
K(i,j,:)=0;
end
end
end
I1=im2bw(K);
[labeled,NUM] = bwlabel(I1,4);
NUM;
A = regionprops(labeled,'Area');
Areas = cat(1, A.Area);
```

```

imshow(labeled),title('Dark Specks');
handles.mystuff.I1=I1;
guidata(gcbo, handles);
function pushbutton3_Callback(hObject, eventdata, handles)
I1=handles.mystuff.I1;
[labeled,NUM] = bwlabel(I1,4);
handles.metricdata.NUM=NUM;
DSC=handles.metricdata.NUM;
set(handles.DSC,'String', DSC);
handles.mystuff.I1=I1;
guidata(gcbo, handles);
function pushbutton4_Callback(hObject, eventdata, handles)
I1=handles.mystuff.I1;
[labeled,NUM] = bwlabel(I1,4);
A = regionprops(labeled,'Area');
Areas = cat(1, A.Area);
counters=0;
counterm=0;
counterl=0;
counterxl=0;
q=1;
for p=1:NUM;
    if A(p,q).Area<18;
        counters=counters+1;
    else
        if A(p,q).Area<436 && A(p,q).Area>17;
            counterm=counterm+1;
        else
            if A(p,q).Area<1744 && A(p,q).Area>435;
                counterl=counterl+1;
            else
                if A(p,q).Area>1743;
                    counterxl=counterxl+1;
                end
            end
        end
    end
end
handles.metricdata.counters=counters;
small=handles.metricdata.counters;
set(handles.small,'String',small);
handles.metricdata.counterm=counterm;
medium=handles.metricdata.counterm;
set(handles.medium,'String',medium);
handles.metricdata.counterl=counterl;
large=handles.metricdata.counterl;
set(handles.large,'String',large);
handles.metricdata.counterxl=counterxl;
xlarge=handles.metricdata.counterxl;
set(handles.xlarge,'String',xlarge);
function pushbutton5_Callback(hObject, eventdata, handles)
display 'ANALYSIS COMPLETED';
close (gcbf);
function pushbutton5_CreateFcn(hObject, eventdata, handles)
function edit1_Callback(hObject, eventdata, handles)
function edit1_CreateFcn(hObject, eventdata, handles)
if ispc && isequal(get(hObject,'BackgroundColor'),
get(0,'defaultUicontrolBackgroundColor'))
    set(hObject,'BackgroundColor','white');
end
function edit2_Callback(hObject, eventdata, handles)

```

```

function edit2_CreateFcn(hObject, eventdata, handles)
if ispc && isequal(get(hObject,'BackgroundColor'),
get(0,'defaultUicontrolBackgroundColor'))
    set(hObject,'BackgroundColor','white');
end
function edit3_Callback(hObject, eventdata, handles)
function edit3_CreateFcn(hObject, eventdata, handles)
if ispc && isequal(get(hObject,'BackgroundColor'),
get(0,'defaultUicontrolBackgroundColor'))
    set(hObject,'BackgroundColor','white');
end
function edit4_Callback(hObject, eventdata, handles)
function edit4_CreateFcn(hObject, eventdata, handles)
if ispc && isequal(get(hObject,'BackgroundColor'),
get(0,'defaultUicontrolBackgroundColor'))
    set(hObject,'BackgroundColor','white');
end
function edit5_Callback(hObject, eventdata, handles)
function edit5_CreateFcn(hObject, eventdata, handles)
if ispc && isequal(get(hObject,'BackgroundColor'),
get(0,'defaultUicontrolBackgroundColor'))
    set(hObject,'BackgroundColor','white');
end
function pushbutton6_Callback(hObject, eventdata, handles)
I = imread('renkolcum.jpg'); %Renk ölçümünün yapılacağı salça görüntüsü
yükleniyor.
imshow(I);
waitforbuttonpress
point1 = get(gca,'CurrentPoint')
rect = [point1(1,1) point1(1,2) 1250 1250];
[r2] = dragrect(rect);
K = imcrop(I, rect);
imshow(K),title('Cropped Image');
handles.mystuff.K=K;
guidata(gcbo, handles);
function pushbutton7_Callback(hObject, eventdata, handles)
K=handles.mystuff.K;
val1=mean2(K(:,:,1));
val2=mean2(K(:,:,2));
val3=mean2(K(:,:,3));
handles.metricdata.val1=val1;
R=handles.metricdata.val1;
set(handles.R,'String',R);
handles.metricdata.val2=val2;
G=handles.metricdata.val2;
set(handles.G,'String',G);
handles.metricdata.val3=val3;
B=handles.metricdata.val3;
set(handles.B,'String',B);
handles.metricdata.R=R;
handles.metricdata.G=G;
handles.metricdata.B=B;
guidata(gcbo, handles);
function pushbutton8_Callback(hObject, eventdata, handles)
R=handles.metricdata.R;
G=handles.metricdata.G;
B=handles.metricdata.B;
RN=(R-(111.779+69.7431)/2)/((111.779-69.7431)/2);
GN=(G-(52.3392+36.815)/2)/((52.3392-36.815)/2);
BN=(B-(48.6147+29.3286)/2)/((48.6147-29.3286)/2);
RNN=RN^2;

```



```

GNN=GN^2;
BNN=BN^2;
load netab2.mat; %a/b değerini tahmin eden yapay sinir ağı yükleniyor.
X=sim(netab2,[RN GN BN RNN GNN BNN]');
handles.metricdata.X=X;
aabb=handles.metricdata.X;
set(handles.aabb,'String',aabb);
function pushbutton9_Callback(hObject, eventdata, handles)
R=handles.metricdata.R;
G=handles.metricdata.G;
B=handles.metricdata.B;
RN=(R-(111.779+69.7431)/2)/((111.779-69.7431)/2);
GN=(G-(52.3392+36.815)/2)/((52.3392-36.815)/2);
BN=(B-(48.6147+29.3286)/2)/((48.6147-29.3286)/2);
RNN=RN^2;
GNN=GN^2;
BNN=BN^2;
load neta.mat; %a değerini tahmin eden yapay sinir ağı yükleniyor.
Y=sim(neta,[RN GN BN RNN GNN BNN]');
handles.metricdata.Y=Y;
aa=handles.metricdata.Y;
set(handles.aa,'String',aa);
load netb.mat; %b değerini tahmin eden yapay sinir ağı yükleniyor.
Z=sim(netb,[RN GN BN RNN GNN BNN]');
handles.metricdata.Z=Z;
bb=handles.metricdata.Z;
set(handles.bb,'String',bb);
load netl.mat; %L değerini tahmin eden yapay sinir ağı yükleniyor.
ZZ=sim(netl,[RN GN BN RNN GNN BNN]');
handles.metricdata.ZZ=ZZ;
LL=handles.metricdata.ZZ;
set(handles.LL,'String',LL);

```

ÖZGEÇMİŞ

1979 yılında Keşan'da doğdu. 1997 yılında Keşan Lisesi'ni bitirdikten sonra Hacettepe Üniversitesi Mühendislik Fakültesi Gıda Mühendisliği Bölümü'nden 2001 yılında mezun oldu. 2001-2004 yılları arasında et ürünleri üreten firmalara katkı maddeleri, makineler, kılıflar gibi ürünler sağlayan özel bir firmada çalıştı. 2004-2005 yılları arasında Tarım ve Köyişleri Bakanlığı Edirne Tarım İl Müdürlüğü Kontrol Şubesi'nde Gıda Kontrolörü olarak hizmet yaptı. 2005 yılında Trakya Üniversitesi Tekirdağ Ziraat Fakültesi Gıda Mühendisliği Bölümü'nde Araştırma Görevlisi olarak göreve başladı. 2006 yılında yüksek lisansını tamamladı ve Namık Kemal Üniversitesi Ziraat Fakültesi Gıda Mühendisliği Bölümü'ne Araştırma Görevlisi olarak atandı. 2009 yılından beri Namık Kemal Üniversitesi Teknik Bilimler MYO Et ve Ürünleri Teknolojisi Programı'nda Öğretim Görevlisi ve Program Danışmanı olarak çalışmaktadır.