

**YOĞURTLARIN DEPOLAMA ESNASINDA MİKROBİYAL VE KİMYASAL
DEĞİŞİMLERİNİN BİLGİSAYARLI GÖRÜNTÜLEME SİSTEMİYLE
BELİRLENMESİ VE ELDE EDİLEN VERİLERİN YAPAY SİNİR
AĞLARIYLA DEĞERLENDİRİLMESİ**

Aytül BAYRAKTAR SOFU

**Yüksek Lisans Tezi
GIDA MÜHENDİSLİĞİ ANABİLİM DALI
ISPARTA, 2006**

T.C
SÜLEYMAN DEMİREL ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

YOĞURTLARIN DEPOLAMA ESNASINDA MİKROBİYAL VE KİMYASAL
DEĞİŞİMLERİNİN BİLGİSAYARLI GÖRÜNTÜLEME SİSTEMİYLE
BELİRLENMESİ VE ELDE EDİLEN VERİLERİN
YAPAY SINIR AĞLARIYLA DEĞERLENDİRİLMESİ

Aytül BAYRAKTAR SOFU

YÜKSEK LİSANS TEZİ
GIDA MÜHENDİSLİĞİ ANABİLİM DALI

ISPARTA, 2006

İÇİNDEKİLER

İÇİNDEKİLER	i
ÖZET	iii
ABSTRACT	iv
TEŞEKKÜR	v
SİMGELER DİZİNİ	vi
ŞEKİLLER DİZİNİ	vii
ÇİZELGELER DİZİNİ	ix
1. GİRİŞ	1
2. KAYNAK BİLGİSİ	4
2.1. Yoğurt tanımı	4
2.1.1. Yoğurdun Bileşimi	4
2.1.2. Yoğurdun Besin Değeri	5
2.1.3. Yoğurt Muhafaza Yöntemleri	6
2.1.4. Yoğurtla İlgili Çalışmalar	7
2.2. Bilgisayarlı Görüntüleme Sistemi	10
2.2.1. Bilgisayarlı Görüntüleme Sistemi Tanımı	10
2.2.2. Görüntünün Sayısallaştırılması	11
2.2.3. Bilgisayarlı Görüntüleme Sistemiyle Renk Analizi	11
2.2.4. Bilgisayarlı Görüntüleme Sistemi ile İlgili Çalışmalar	14
2.3. Yapay Sinir Ağları	19
2.3.1. Biyolojik Sinir Hücresi	20
2.3.2. Yapay Sinir Hücresi	22
2.3.3. Yapay Sinir Ağının Yapısı ve Çalışması (Kara kutu benzetmesi)	26
2.3.3.1. Eğitim	28
2.3.3.2. Kullanma	29
2.3.4. YSA'ların Yapılarına Göre Sınıflandırılması	29
2.3.4.1. İleri Beslemeli Ağlar	29
2.3.4.2. Geri Beslemeli Ağlar	30
2.3.5. YSA'ların Öğrenme Algoritmalarına Göre Sınıflandırılması	31
2.3.5.1. Danışmanlı Öğrenme (Supervised Learning)	31
2.3.5.2. Danışmansız Öğrenme (Unsupervised Learning)	31

2.3.5.3.	Takviyeli öğrenme (Reinforcement learning).....	32
2.3.6.	YSA'ların Özellikleri, Üstünlükleri ve Mühendislik Uygulamaları.....	33
2.3.7.	Yapay Sinir Ağları ile İlgili Çalışmalar	34
3.	MATERYAL VE YÖNTEM	37
3.1.	Materyal	37
3.2.	Yöntem.....	37
3.2.1.	Kimyasal analiz ve örnek hazırlama	37
3.2.2.	Mikrobiyolojik analiz.....	37
3.2.3.	Bilgisayarlı Görüntü Sistemi (Machine Vision)	38
3.2.3.1.	Donanım (Hardware)	38
3.2.3.2.	Yazılım (Software).....	40
3.2.4.	Yapay Sinir Ağlarıyla Verilerin Modellenmesi	41
3.2.5.	Verilerin İstatistiksel Analizi	43
4.	ARAŞTIRMA BULGULARI ve TARTIŞMA.....	44
4.1.	Yoğurt Örneklerinin Kimyasal ve Mikrobiyolojik Sonuçları	44
4.2.	Bilgisayarlı Görüntüleme Sistemi Kullanılarak Veri Elde Edilmesi	48
4.2.1.	Görüntülerin Elde Edilmesi	48
4.2.2.	Görüntü histogramları:.....	54
4.2.3.	Geliştirilen Yapay Sinir Ağları Modelleri	63
5.	SONUÇ	70
6.	KAYNAKLAR	72
	ÖZGEÇMİŞ	87

ÖZET

Yoğurtların Depolama Esnasında Mikrobiyal ve Kimyasal Değişimlerinin Bilgisayarlı Görüntüleme Sistemiyle Belirlenmesi ve Elde Edilen Verilerin Yapay Sinir Ağlarıyla Değerlendirilmesi

Fermente bir süt ürünü olan yoğurt ülkemizde ve dünya da önemli bir besin kaynağı olarak tüketilmektedir. Yoğurdun kalite kriterlerinden olan kimyasal ve mikrobiyolojik yapısı yoğurdun depolama ve raf ömrü süresini belirlemektedir. Depolama esnasında, fizyolojik, kimyasal ve mikrobiyolojik nedenlerle yoğurtta meydana gelen renk, koku, tekstür değişimleri, tüketici tarafından bu ürünün seçiminde göz önünde bulundurulmuş önemli kalite kriterleridir.

Gıda ürünlerinde hızlı ve objektif kalite kriterlerinin belirlenmesinde ve yüksek kalite ve güvenlik standartları tahminlerinde kesin sonuçlara olan ihtiyaç artmaktadır. Bu çalışmada; yoğurtlarda raf ömrü süresinin belirlenmesinde, gıdalardaki morfolojik, kompozisyonel ve renk değişikliklerinin hızlı, otomatik ölçülebilmesini sağlayan, görüntüyü dijital forma dönüştürebilen, bilgisayarlı görüntüleme sistemi (BGS) ile yoğurdun renk analizi yapılarak sayısal veriler elde edilmiştir. Daha sonra, elde edilen veriler geleneksel yöntemlerin ve klasik modellemelerin yetersiz kaldığı sınıflandırma, kümeleme, duyu-veri işleme, çok duyulu makine gibi alanlarda beynin bazı fonksiyonlarını özellikle öğrenme yöntemlerinden benzetim yolunu kullanan, başarılı sonuçların elde edilmesini sağlayan Yapay Sinir Ağları (YSA) ile modellenmiştir.

Çalışmada ilk olarak, yoğurt örneklerinin laboratuvar ortamında 1. 7. ve 14. günlerinde pH tayini ve mikrobiyel analizleri yapılmıştır. Eş zamanlı olarak depolama esnasında meydana gelen renk değişimlerini gözlemek amacıyla görüntü analizi de yapılarak bilgisayarlı görüntüleme sisteminde görüntünün sayısallaştırılması sağlanmış ve bu verilerle YSA kullanılarak yoğurt raf ömrü süresi tahmin modelleri geliştirilmiştir. Yoğurdun raf ömrü tahmin modeli; bir gizli tabakalı, sigmoid aktivasyon fonksiyonuyla geri beslemeli ağ (backpropagation) kullanılarak oluşturulmuştur. YSA modelinin girdi parametreleri olarak, pH, toplam mikroorganizma, maya küf, koliform değerleri ve bilgisayarlı görüntüleme sistemi kullanılarak elde edilen renk analiz değerleri, çıktı parametresi olarak da raf ömrü süresi değeri kullanılmıştır. Geliştirilen modelin performansını değerlendirmek için modelin sonuçları laboratuvar çalışması sonucu elde edilen verilerle karşılaştırılmış ve yüksek determinasyon katsayısı (R^2) 0.9996 olarak yüksek bir değer elde edilmiştir.

Bu çalışmada, geliştirilen YSA modelinin, doğrusal olmayan çok değişkenli analiz yapabilmesi, paralellik özelliği göstermesi, hız konusunda oldukça büyük üstünlük sağlaması, daha az parametreye gereksinim duyma özelliğinden dolayı raf ömrü süresi hesaplarında kullanılabileceği gösterilmiştir. Ayrıca, modelin formüle edilmesiyle marketten alınan yoğurt örneklerinin etiketinde belirtilen gün sayısını kontrol edilebilmesi, literatürde veri tabanı oluşturularak, hem üretici firmanın ürün kalitesini geliştirmesini hem de tüketicinin güvenli besin tüketmesini sağlayacağı düşünülmektedir.

ANAHTAR KELİMELER:

Bilgisayarlı görüntüleme sistemi, yapay sinir ağları, yoğurt, raf ömrü

ABSTRACT**Determination and Quantification of Microbiological and Chemical Changes in Yogurt Using Machine Vision System and Evaluation of Collected Data Using Neural Network System During Storage**

Yogurt is a semi-solid fermented milk product, now consumed in our country and most parts of the world. Changes in physical, chemical and microbiological structure of yogurt determine the storage and shelf life of the product. Alteration of these properties causes color, aroma and texture deterioration in yogurt which are considered as important quality criteria by the consumers.

There is an increasing demand on fast, reliable, and objective techniques to determine shelf life of the food products with high quality and safety standards. In this study, the color analysis data was obtained by using machine vision system for prediction of shelf life of yogurt. Machine vision system provides automated, rapid, reproducible results to determine morphological, compositional and color changes in food by converting images into numerical form. Obtained data was modelled with artificial neural network (ANN) which is a mathematical algorithm which has the capability of relating the input and output parameters, learning from examples through iteration, without requiring a prior knowledge of the relationships of the process parameters.

In this study, microbial counts and pH values of yogurt during storage were determined at day 1, 7, and 14. Simultaneously, image processing of yogurt was digitized with using machine vision system to determine color changes during storage and obtained data was modelled with ANN for prediction shelf life of yogurt. Neural network models were developed using backpropagation networks with single hidden layer and sigmoid activation functions. While the input variables of the network were pH, total aerobic, yeast, mold and coliform counts, and color analysis values obtained with machine vision system, output variable was storage time of the yogurt during shelf life (Day 1, 7, 14). The modelling results showed that there was an excellent agreement between the experimental data and predicted values, with a high determination coefficient (R^2) 0.9996.

Our results showed that the developed model was able to analyse non-linear multi variant data with very good performance, less parameters and shorter calculation time suggesting that the model might have alternative method to control expiration date of yogurt shown in labeling and provide consumers to safer food supply. As a result, the ANN seems to find application in the quality analysis of yogurt

KEY WORDS:

Machine vision, neural network, yogurt, shelf life

TEŐEKKÖR

Tez konusunun belirlenmesinde, gerek teorik ve gerekse deneysel alıőmalarda yōn gōsteren ve yardımlarını esirgemeyen, tezimin her aőamasında gōsterdiđi yakın alaka sebebiyle tez danıőmanım Yrd. Do. Dr. F.Yeőim EKİNCİ KİTİŐ'e, őükranlarımı arz ederim.

Tez alıőmalarımın deneysel aőamalarda desteđini hep hissettiđim ve yardımlarını esirgemeyen Yrd. Do. Dr. Necla DEMİR ve Yrd.Do.Dr.Serdal TERZİ'ye yardımlarından ötürü tüm arkadaşlarıma ve SDÜ Araőtırma Projeleri Yōnetim Birimi'ne teőekkör ederim.

Tüm eđitim hayatım desteklerini esirgemeyen aile fertlerime ve eőime teőekkörü bir bor bilirim.

Tezimi rahmetli babam Nevzat BAYRAKTAR'a ithaf ediyorum.

Aytöl BAYRAKTAR SOFU

SİMGELER DİZİNİ

Σ	: Toplam fonksiyonu
Fmax	: Ölçümlerdeki maksimum değer
Fmin	: Ölçümlerdeki minimum değer
R^2	: Determinasyon katsayısı
MSE	: Ortalama Kareysel Hata
net	: Hücrede toplanan girdinin tümü
tm	: Toplam mikroorganizma
m-k	: Maya-küf miktarı
kb	: Koliform bakteri
r1	: Renk değeri bir
r2	: Renk değeri iki
r3	: Renk değeri üç
r4	: Renk değeri dört
r5	: Renk değeri beş
r6	: Renk değeri altı
r7	: Renk değeri yedi
r8	: Renk değeri sekiz
r9	: Renk değeri dokuz
r10	: Renk değeri on
r11	: Renk değeri onbir
r12	: Renk değeri oniki
YSA	: Yapay Sinir Ağları
BGS	: Bilgisayarlı Görüntü Sistemi

ŞEKİLLER DİZİNİ

Şekil 2.1. Bilgisayarlı Görüntüleme Sistemi (Luzuriaga, 1997; Demir, 2002).....	11
Şekil 2.2. Biyolojik sinir sisteminin blok gösterimi.....	20
Şekil 2.3. Biyolojik Sinir Hücresi ve Bileşenleri (Sağiroğlu vd., 2003).....	21
Şekil 2.4. p girdili n çıktılı bir yapay nöronun blok diyagram gösterimi (a) ve detaylı gösterimi (b) (Sağiroğlu vd., 2003; Öztemel, 2003).....	23
Şekil 2.5. Sigmoid (tanh) aktivasyon fonksiyonu (Öztemel, 2003).....	25
Şekil 3.1. Sony DFW-V500 marka digital kamera	38
Şekil 3.2. Görüntü analizi düzeneği çizim görünüşü	39
Şekil 3.3. Görüntü analizi düzeneği görünüşü	39
Şekil 3.4. Seçilen Yapay Sinir Ağı Model	42
Şekil 3.5. Model kurulum şeması.....	42
Şekil 3.6. Verilerin değerlendirilme şekli	43
Şekil 4.1. Birinci (1) gün normal yoğurt.....	49
Şekil 4.2. Yedinci (7) gün normal yoğurt	49
Şekil 4.3. Ondördüncü (14) gün normal yoğurt	50
Şekil 4.4. Birinci (1) gün light yoğurt.....	50
Şekil 4.5. Yedinci (7) gün light yoğurt	51
Şekil 4.6. Ondördüncü (14) gün light yoğurt.....	51
Şekil 4.7. Yedinci (7) gün ışık uygulanmış normal yoğurt.....	52
Şekil 4.8. Ondördüncü (14) gün ışık uygulanmış normal yoğurt.....	52
Şekil 4.9. Yedinci (7) gün ışık uygulanmış light yoğurt.....	53
Şekil 4.10. Ondördüncü (14) gün ışık uygulanmış light yoğurt.....	53
Şekil 4.11. Normal yoğurt renk histogramı.....	56
Şekil 4.12. Normal yoğurtlarda önemli renk bloklarının % toplam alandaki 1., 7. ve 14. günlerdeki değişimleri.....	57
Şekil 4.13. Light yoğurt renk histogramı	57
Şekil 4.14. Light yoğurtlarda önemli renk bloklarının % toplam alandaki 1., 7. ve 14. günlerdeki değişimleri.....	58
Şekil 4.15. Işıklı normal yoğurt renk histogramı	59
Şekil 4.16. Işıklı normal yoğurtlarda önemli renk bloklarının % toplam alandaki 1., 7. ve 14. günlerdeki değişimleri.....	60

Şekil 4.17. Işıklı light yoğurt renk histogramı	61
Şekil 4.18. Işıklı light yoğurtlarda önemli renk bloklarının % toplam alandaki 1., 7. ve 14. günlerdeki değişimleri.....	62
Şekil 4.19. Seçilen modele ait ağ yapısı.....	65
Şekil 4.20 Yapay Sinir Ağlarının Eğitim Performansı.....	66
Şekil 4.21. Yapay Sinir Ağları Eğitim Seti ve Deneysel Sonuçların Karşılaştırılması Gün Sayısı (GS)	66
Şekil 4.22. Yapay Sinir Ağları Test Seti ve Deneysel Sonuçların Karşılaştırılması Gün Sayısı (GS)	67
Şekil 4.23.Yapay Sinir Ağları Modeli ile Test Seti ve Deneysel Sonuçlarının zaman serisi. Gün Sayısı (GS).....	67

ÇİZELGELER DİZİNİ

Çizelge 2.1. Yoğurdun bileşimi (Anonim, 2001).....	5
Çizelge 2.2. Türk Gıda Kodeksi'nde bildirilen Yoğurt, Süzme Yoğurt, Torba Yoğurdu ve Ayrana Ait Mikrobiyolojik Değerler (Anonim, 2001).....	9
Çizelge 2.3. Biyolojik sinir sistemi ile YSA'ların benzer özellikleri (Sağiroğlu vd., 2003; Öztemel, 2003).....	22
Çizelge 2.4. Aktivasyon fonksiyonları (Öztemel, 2003).....	25
Çizelge 4.1. Yoğurt örneklerinin pH analizi sonuçları.....	44
Çizelge 4.2. Yoğurt örneklerinin mikrobiyel analiz sonuçları	46
Çizelge 4.3. Yoğurt örneklerinin depolama günlerine göre istatistiksel olarak değerlendirilmesi.....	48
Çizelge 4.4. Yoğurt örneklerinden elde edilen renk blokları	55
Çizelge 4.5. Gizli tabakadaki nöron sayılarının korelasyon ve performans değerleri	63

1. GİRİŞ

Ülkemizde önemli bir besin kaynağı olarak tüketilen yoğurt fermente bir süt ürünüdür. Toplumumuzun beslenmesinde yoğurt tüketiminin önemli bir yere sahip olduğu, yoğurt ve yoğurt ürünlerinin uzun yıllardan beri Türkler tarafından yapılmış olduğu bilinmektedir. Yoğurt bileşenleri açısından insan için gerekli besin maddelerini dengeli olarak bulundurur.

Yoğurt üretiminde kullanılan çiğ sütün kalitesinin ülkemizde halen iyileştirilememiş olması ürünler için de büyük problem oluşturmaktadır. Kötü kalitedeki ham maddeden iyi kalite ürün elde etmek bu sektörde mümkün değildir. Bu durumda üretilen ürünlerin standardize edilememesi gibi problemlerin yanı sıra işletmelerin standartlarda belirtilen değerleri sağlayabilmeleri zordur. Özellikle mikrobiyolojik, kimyasal ve duyuşal yönden çeşitli problemlerle karşılaşabilmektedir. Mikrobiyolojik olarak küf problemi özellikle fermente süt ürünlerinde öne çıkan bir problem olarak göze çarpmaktadır. Ambalaj üzerinde belirtilmiş raf ömrü içerisinde küflenme çoğunlukla tüketicinin de dikkatini çeken bir sorundur.

Gıdalar çok karmaşık ve heterojen yapıya sahip olduklarından gıda analizlerinde çok çeşitli yöntemlerin kullanılması gerekmektedir. Bu amaçla kullanılan başlıca yöntemler fiziksel, kimyasal, enstrümental, duyuşal, enzimatik, mikrobiyolojik, makroskopik, histolojik, serolojik, parazitolojik, teknolojik olmak üzere sıralanabilir. Gıdalarda uygulanan analizler temelde mikrobiyolojik muayeneler ve kimyasal analizlerdir. Mikrobiyolojik analiz kapsamında özellikle ürünün koliform, toplam bakteri ve maya küf içeriğinin belirlenmesi kalite açısından önemlidir. Bunun yanı sıra ürünlerin farklı mikroorganizma içerikleri de farklı mikrobiyolojik yöntemlerle belirlenebilmektedir. Kimyasal analiz dahilinde gıdalarda bir çok analiz uygulanmakta olup bunların bir çoğu gıdanın besin değeri ile ilgili olmaktadır. Gıda analizleri gıdanın kalite kontrolü ile ilgili olup gerek işletmeci gerekse tüketici açısından önem teşkil etmektedir.

Yoğurtlarda depolama sırasında meydana gelen mikrobiyolojik ve kimyasal değişimlere, düşük pH ve sıcaklıkta gelişebilen küf ve mayalar neden olmaktadır.

Fermente st rnleri dk pH'lı rnler olduėu iin patojen mikroorganizmaların geliimini destekler (Muir ve Banks, 2000). Meydana gelen bu deėiimler klasik analiz yntemlerine alternatif olarak sayısal grnt ileme yntemi ile de belirlenebilmektedir. Bu yntem doėru tanımlayıcı deėerlerin elde edilmesi (Sapirstein, 1995), hızlı ve objektif olması (Lefebvre vd., 1993; Gerrard vd., 1996; Liu vd., 1997), insanları sıkıcı ve zaman alıcı ilemlerden kurtarması (Ni vd., 1997), istikrarlı, etkili ve dk maliyetli olması (Lu vd., 2000), yksek maliyetli igc gerektiren pek ok ilemin otomatize edilebilir (donanım gelitirilebilir) olması (Gunasekaran, 2001), nesnelerin oėu kez yapıları bozulmadan analizine imkan saėlaması, srekli ve sonradan analize imkan saėlayacak Őekilde verilerin saklanması (Tarbell ve Reid, 1991) gibi avantajlarıyla alternatif bir yntem olarak kullanılmaktadır.

Bunun yanı sıra yaam bilimleri ve bilgisayar bilimlerinin keiimin de yer alan bir ara disiplin veya biyolojik bilginin analizi ve ilenmesi ile ilgilenen bir bilim dalı olarak biyoenformatik (bioinformatics), gıda bilimi ve endstrisinde eitli Őekillerde uygulamalarla kendisini gstermeye balamıtır. Yapay zeka, yapay sinir aėları (neural networks), bulanık mantık (fuzzy logic) genetik algoritmalar ve bilgisayar yazılımları geleneksel bilgi edinme yolları ile sınırlanmadan verilerin toplanması, ynetimi - eriimi ve analizi-yorumu daha hızlı bir Őekilde gelitirilmi modeller zerinde alıma yapılmasını saėlamaktadır.

Yapay zeka teknolojisinin uygulama alanlarında kullanılan modern mhendislik yntemlerinden birisi olan yapay sinir aėları insan beyninin varsayılan alıma prensiplerini model olarak gelitirilmi sistemleridir. Birbiri ile paralel olarak alıan birbirine bilgi gnderen ve bilgi alan proses elemanlarının (yapay sinir hcrelerinin) hiyerarik organizasyonundan oluşur. Yapay sinir hcreleri bir aė Őeklinde birbirlerine baėlanmıtır. Aradaki baėlantıların bir deėeri (aėırlıėı) vardır. Bir sinir hcresinin sahip olduėu bilgi bu baėlantı deėerleri ile gsterilir. Zeki davranı ve ėrenme yeteneėi bu baėlantı deėerlerinin kullanılması ile ortaya ıkar.

Bu alıřmada gıdaların raf mr alıřmalarında alternatif olarak ampirik metodların temelini oluřturan yntemler olan bilgisayarlı grntleme analizi ve yapay sinir ađları metodları kullanılarak marketten alınan yođurt numunelerinde depolama srecinde meydana gelen kimyasal ve mikrobiyel deđiřimleri izlenerek yođurdun raf mr sresi tahmin modeli geliřtirilmesi amalanmıřtır.

Literatrde daha nce yapılmıř bilgisayarlı grntleme analizi ve yapay sinir ađları kullanılarak gıdalarda derecelendirme, sınıflandırma vb. alıřmalar sunulmuřtur.

2. KAYNAK BİLGİSİ

2.1. Yoğurt tanımı

Yoğurt homojenize edilmiş sütlerin *Streptococcus salivarius* subsp. *thermophilus* ve *Lactobacillus delbrueckii* subsp. *bulgaricus*'un etkisi ile laktik asit fermentasyonu sonucu elde edilen, yoğurt kültürlerini canlı olarak ihtiva eden, katı kıvamlı, hafif ekşi ve hoş giden aroması olan dayanıklı bir süt ürünüdür (Anonim, 1989).

Yoğurdun ilk kez nerede yapıldığı bilinmemekle beraber bir Türk buluşu olduğu ve binlerce yıldır Türkler ve Türk kültürü altında kalmış ülkelerde yapıldığı arkeolog ve tarihçilerin bulguları ışığında ispat edilmiştir (Kurt, 1999). Yoğurt, Ortadoğu ve Balkanların geleneksel bir ürünüdür. Bununla birlikte, dünyanın diğer bölgelerinde ve Avrupa tüketimi son yıllarda artmaya başlamıştır (Tamime ve Deeth, 1980).

2.1.1. Yoğurdun Bileşimi

Yoğurt, bileşimi yönünden süte fazla benzeyen bir süt ürünüdür. Diğer süt ürünlerinde süten bileşimine katılan maddelerin miktarında, süte göre büyük bir değişiklik görülmesine rağmen yoğurttaki değişiklik pek fazla değildir, sütle yoğurdun bileşim farkı, yoğurdun ve kullanılan hammaddenin çeşidine göre: genellikle kuru madde ve süt şekerinde kendini gösterir. Süten işlenmesi sırasında pişirilmesi veya konsantre süt ürünleri ile takviyesi sonucunda, yoğurdun kuru maddesi ve onu meydana getiren maddelerde şeker hariç, genellikle %5-10 oranında bir yükselme olur. Fermentasyon sonunda şekerin bir kısmı parçalandığından yoğurdun sadece şeker oranında bir azalma meydana gelir.

Buna karşılık şekerin parçalanması sonucu meydana gelen süt asidi miktarı yaklaşık 5 kat artmaktadır. Yoğurdun bileşimiyle ilgili veriler çok farklılık gösterir. Çünkü kullanılan hammadde ve işleme tekniğinin değişikliği birkaç değişik bileşimde yoğurtla karşı karşıya bırakmaktadır. Genel olarak şöyle bir bileşim tablosu verilebilir;

Çizelge 2.1. Yoğurdun bileşimi (Anonim, 2001)

Bileşim	Miktar
Su	% 80-86
Kuru Madde	% 14-20
Yağ	% 2-8
Protein	% 4-8
Süt Şekeri	% 2-5
Mineral Madde	% 0,8-1,2
Asitlik	0,9

2.1.2. Yoğurdun Besin Değeri

Yoğurt, sütten üretilen bir üründür ve bileşimi süte oldukça benzemektedir (Shahani ve Chandan, 1979). Üretiminde uygulanan zenginleştirme işlemi ve fermantasyon sırasında meydana gelen değişmelerle birlikte bileşiminde bazı farklılıklarda bulunmaktadır (Renner ve Saldamlı, 1983). Yoğurt proteinlerinin biyolojik değeri fermantasyon nedeniyle artmaktadır ve yoğurt proteinleri süt proteinlerine göre daha kolay sindirilebilmektedir (Shahani ve Chandan, 1979).

Yoğurt yapımı sırasında sütün bileşimini etkileyen faktörler; yağ ve kuru madde standardizasyonları ile ısı işlemidir. Süte göre protein ve kuru madde oranı yüksek, laktoz oranı ise düşüktür (Çağlar ve Çakmakçı, 1999). Sütün bileşenlerinin sindirilebilirliği fermantasyon ile artmaktadır (Shahani ve Chandan, 1979). Isıl işlem sırasında vitamin kayıpları olsa da yoğurt bakterilerinin faaliyeti sonucu B grubu vitaminleri sentezlenmektedir (Shahani ve Chandan, 1979; Çağlar ve Çakmakçı, 1999).

Laktik asit bakterilerinin fermantasyon sırasında ürettikleri metabolitler nedeniyle yoğurdun antimikrobiyel, antikarsinojenik ve terapötik etkileri de artmaktadır (Shahani ve Chandan, 1979). Terapötik kelimesi, sağlığı koruyucu ve tedavi edici anlamında kullanılmaktadır (Çağlar ve Çakmakçı, 1999). Laktik asit fermentasyonu esnasında süt bileşenlerinde görülen kimyasal değişmeler şöyle sıralanabilir: laktoz içeriği azalır, yüksek miktarda laktik asit oluşur, serbest peptit, amino asit ve yağ

asitleri miktarı artar, bazı vitaminlerde azalma ve artışlar meydana gelmektedir. Yoğurdun kalori değeri, laktozun laktik aside dönüşmesine bağlı olarak %3-4 oranında azalmaktadır. Ancak laktoz intoleransı olan insanlar tarafından rahatlıkla tüketilebilen bir ürün niteliğini kazanmaktadır.

Yoğurt, bağırsak sistemi enfeksiyonlarına karşı bağışıklığı artırır, diyareyi önler, bağırsak kanserini önler, hiperkolesterolemiyi önler, laktozun değerlendirilmesini artırır, sindirim sistemi rahatsızlıklarını önler, bağırsak mukozasını stabilize eder (Kailasapathy ve Rybka, 1997).

İnsan sağlığı açısından yoğurdun yararları şunlardır;

- Besin değeri süte göre daha yüksektir,
- Önemli bir protein, yağ, vitamin, ve mineral madde kaynağıdır,
- Fermentasyon sırasında laktozun bir kısmı hidrolize olduğu için sütü sindirmekte güçlük çekenler tarafından (laktoz intoleransı) daha rahat tüketilmektedir,
- Sindirimi daha kolay olduğu gibi sindirim sistemini düzenleyici etkiye de sahiptir,
- Yoğurt bakterileri antigonistik etkilerinden dolayı intestinal patojen ve saprofit organizmaların gelişimini inhibe etmektedir. Kolestolü düşürücü etkiye sahip olduğu belirtilmektedir.

2.1.3. Yoğurt Muhafaza Yöntemleri

Yoğurt bilinen en eski fermente süt mamüllerinden birisidir. Yoğurda işlenecek süt 85-90 °C'de 15-30 dakika süre ile pastörize edildikten sonra 42-43 °C'ye soğutulurarak % 2 oranında *Lactobacillus bulgaricus* ve *Streptococcus thermophilus*'dan oluşan starter kültür ilave edilir. 3 saat içerisinde pH 5 civarına düşer. Uygun koşullarda üretilen yoğurt 5 °C'de üç haftaya kadar muhafaza edilebilir. Ancak bu süre içinde asit üretimi yavaşta olsa devam eder ve keskin asit tat meydana gelir. Yoğurtta asitliğin artmasını önlemek için inkübasyondan sonra *L. bulgaricus* ve *S. thermophilus*'u öldürmek amacıyla ısıl işlem uygulanabilir. Uygun ekipman ve

aseptik ambalajlama yöntemi ile ısısal işlem uygulamak suretiyle yoğurdun raf ömrünü uzatmak mümkündür (Rasic ve Kurman, 1978).

2.1.4. Yoğurtla İlgili Çalışmalar

Geleneksel süt ürünlerinden olan yoğurt, içerdiği besin maddeleri yönünden mükemmel bir gıda maddesidir. Ancak yoğurdun dayanıklılık süresi sınırlıdır. Yoğurdu dayanıklı hale getirmek amacıyla pişirme, suyunu ayırıp kurumaddeyi arttırma, muhafazası sırasında hava ile teması önleme gibi çeşitli yöntemler geliştirilmiştir (Yöney, 1987; Çağlar vd., 1997; Uysal ve Gön, 1998). Yoğurdun belli bir süre muhafazasında; aseptik üretim, biostabilizasyon, gaz verme, kimyasal koruma, pastörizasyon, dondurma, kurutma ve HF/UHFR çok yönlü frekans metodu gibi tekniklerden yararlanılmaktadır (Basic ve Kurman, 1978).

Hammadde olan çiğ sütün kalitesi, yağ ve kurumadde standardizasyonu, homojenizasyon ve ısısal işlem uygulamalarında seçilen normlar, kullanılacak kültür, inokulum miktarı, fermantasyonun gerçekleşeceği sıcaklık, yoğurt oluşumunu takiben gereği şekilde soğuma ve depolama, yoğurt üretiminde kaliteyi etkileyen en önemli faktörler arasında bulunmaktadır (Bertelsen, 1964). Yoğurdun muhafazası sırasında bir çok değişiklik meydana gelir. Bu değişikliklerin nedeni mikrobiyolojik ve kimyasal olabilir.

Konsantre yoğurtlar ülkemizde ‘Torba Yoğurdu’, ‘Süzme Yoğurt’ ‘Kış Yoğurdu’, ‘Pişmiş Yoğurt’ veya ‘Pişirilmiş Yoğurt’, ‘Tuzlu Yoğurt’, Mısır’da ‘Leben Zeer’, Lübnan ve bazı Arap ülkelerinde ‘Labneh’ ve ‘Labane Anbaris’ adıyla bilinmektedir (Tamime ve Robinson, 1978; Atamer vd., 1988; Uysal, 1993; Şahan ve Say, 1998).

Al-Kadamany vd., (2002) konsantrasyon yoğurtlarda (labneh) yaptıkları çalışmada depolama sırasında pH’ın azalmasıyla asitliğin ve asit üreten mikroorganizmalarda bir artış görüldüğü ayrıca depolama sıcaklığına paralel bir şekilde maya-küf gelişiminin arttığını görmüşlerdir. Al-Kadamany vd., (2002) raf ömrü tespitinde mikroorganizma sınıflandırmasında duyu analizi parametreleri kapsamlı olarak

kullanılmışlardır. Farklı sıcaklıklarda maya-küf gelişimini tesbit ederek konsantrasyon yoğurtlarda raf ömrünün 7-10 gün olduğunu savunmaktadırlar.

Bakteriyel konsantrasyona depolama süresi, son fermantasyon, pH, bakteri birliği ve inkübasyon sıcaklığı etki etmektedir. Son pH bakteriyel konsantrasyonunu önemli bir şekilde etkilemektedir (Be'al, vd., 1989). Yoğurt konsantrasyon pH 4.4'den pH 4.8 yükseldiğinde *L. bulgaricus*'un asidik ortama daha toleranslı olduğu görülmüş *S. thermophilus*'un ise pH 4.8'de gelişimini durdurduğu görmüşlerdir. pH 4.8 ve 4.4 arasındaki konsantrasyonlar *S. thermophilus* sayısında hafif bir azalmaya sebep olur. *L. bulgaricus*'un (Be'al, vd., 1989) düşük pH konsantrasyonlarına toleransının yüksek olduğunu bulmuşlardır.

Akalın vd., (1998) çalışmalarında inkübasyon ve yoğurdun muhafazası sırasında örneklerin pH değerlerinin devamlı bir şekilde azaldığını görmüşlerdir. Yoğurda işlenecek sütte yaklaşık 6.7 olan pH değeri, inkübasyonun 1 saatinden 6.1'e, 3. saatinde ise 4.8'e düşmüştür. Yoğurtta titre edilebilir asitlik de beklendiği gibi sütün inkübasyonu ve yoğurdun muhafaza edilmesi sırasında % 0.40'dan başlayarak % 1.4'e kadar artış göstermiştir. Bu yükselme bazı araştırmacılar tarafından da elde edilmiştir (BavilacQua ve Califano, 1989; Fernandez-Garcia ve Mcgregor, 1994). On dört gün sonunda belirlenen pH ve titre edilebilir asitlik değerleri yoğurdun tüketilebilirlik sınırları içinde bulunmuştur.

Depolama süresinin de bakteriyel konsantrasyona çok güçlü bir etkisi vardır. Son asitlenme özellikle 7 ve 21 günler arasında % 75'den % 40'lara düşmektedir. Bu düşüş, *S. thermophilus* ve düşük pH'ın *L. bulgaricus*'a etkisi aynı şekilde Laye vd., (1993), fakat Kneifel vd., (1993) ve Barrantes vd., (1994) ise bu değişmelerin depolama süresinde bakteriyel konsantrasyona etkisinin olmadığını bulmuşlardır.

Mayalar yoğurtlarda genellikle mayamsı tat ve gaz oluştururlar. Oluşan gaz kapalı ambalajlarda bombaja neden olabilir. Küfler genellikle yoğurt yüzeyinde gelişerek beyaz veya mavi bir film oluştururlar. Yoğurtlarda gelişen küflerin lipolitik aktivitesi sonucu ransit bozulma, proteolitik aktivite sonucu ise peynirimsi acı lezzet gözlenebilir. *Geotricum candidum* (*Oidium lactis*) yüzeyde beyaz-sarımsı film

oluşturarak ransit ve proteolitik bozulmaya neden olur. Bunların dışında yoğurt bakterileri depolama koşullarına bağlı olarak asitliğin yükselmesine ve ekşimeye neden olur (Rasic ve Kurman, 1978).

Pastörize süt ve mamülleri insan sağlığı açısından risk oluşturmaz. Yasalarla öngörülen minimum pastörizasyon işlemi çiğ sütte bulunabilecek tüm patojen mikroorganizmaları öldürebilecek düzeydedir. Çeşitli araştırmacılar sütte bulunabilecek patojen mikroorganizmalardan *Mycobacterium tuberculosis*, (*M.bovis*, *Mavium*, *M.fortuitum*) *Salmonella typhi* ve diğer *Salmonella* türleri, *Shigella paradysenteria*, patojenik *Escherichia coli*, *Streptococcus pyogenes*, *Corynebacterium diphtheria*, *Brucella (B.abortus, B.suis, B.melitensis)*, *Staphylococcus aureus*, *Coxiella burnetti* ve onkogenik (tümör oluşturan) virüslerin uygulanan standart pastörizasyon işlemi ile tamamen öldüğünü belirtmişlerdir.

Fermentasyon sonrası pH'nın 3.8-4.2 civarına düşmesi nedeniyle yoğurtta patojen bakteriler için olumsuz bir ortam oluşmakta ve bu mikroorganizmalar yoğurtta canlılıklarını sürdürmemektedirler. Nitekim bu konuda yapılan bir çalışmada 7.2 °C'de 24 saat depolanan yoğurtta *E.coli* ve *Enterobacter earogenes*'in hızla öldüğü saptanmıştır (Rasic ve Kurman, 1978).

Aşağıdaki çizelgede ülkemizde yoğurt için uygulanan mikrobiyolojik kriterler verilmiştir. Bu kriterler yoğurtta bulunmasına izin verilen maksimum mikroorganizma yada mikroorganizmaların ve/veya toksinlerinin izin verilen düzeylerini gösterir.

Çizelge 2.2. Türk Gıda Kodeksi'nde bildirilen Yoğurt, Süzme Yoğurt, Torba Yoğurdu ve Ayran Ait Mikrobiyolojik Değerler (Anonim, 2001)

	N	c	m	M
Koliform*	5	2	9	95
<i>E. coli</i> *	5	0	<3	-
Maya, (kob/ml)	5	2	1.0X10 ¹	1.0X10 ²
Küf (kob/ml)	5	2	1.0X10 ¹	1.0X10 ²

(*) En Muhtemel Sayı tablosuna göre (/g)


- n; Analize alınacak numune sayısı.
 c; "M" değeri taşıyabilecek en fazla numune sayısı.
 m; (n - c) sayıdaki numunede bulunabilecek en fazla değer.
 M; "c" sayıdaki numunede bulunabilecek en fazla değer.

Çoğu gıda ürünlerinin raf ömrü tesbitindeki anahtar faktör duyuşal analizlerdir. Hayatta kalma sürelerinin tesbit analizi (Kleinbaum, 1996; Klein ve Moeschberger, 1997; Meeker ve Escobar, 1998; Go'mez, 2004) istatistiksel bir bilim dalı olup klinik çalışmalarda, epidemiyoloji, kalite, biyoloji, sosyoloji ve kalite güvenliđi çalışmalarda kullanılmaktadır. Hough vd., (2003) bu konuda çalışmışlar Hough, vd., (2004) bu metodolojiyi kullanarak kalite kontrol şartlarını uygulayabilecekleri duyuşal parametreleri hesaplamışlardır.

2.2. Bilgisayarlı Görüntüleme Sistemi

2.2.1. Bilgisayarlı Görüntüleme Sistemi Tanımı

Bilgisayarlı görüntüleme sistemi (BGS); bilgisayarın görsel sensörler yoluyla elde edilen veriyi "anlayabilmesini" amaçlayan araştırma alanıdır (Baxes, 1994). Sistem genellikle 5 basit parçadan oluşur; aydınlanma, bir kamera, bir görüntü sayısallaştırıcı, bilgisayar donanımı ve yazılımı şekilde görülmektedir (Şekil 2.1.) (Luzuriaga, 1997; Demir, 2002; Wang ve Sun, 2002a). Fotografik görüntü piksel denilen küçük elementlere bölünerek sayısallaştırılır. Her element fotografik görüntüdeki bilgiye üç ana renk (RGB: R: Kırmızı, G: Yeşil, B: Mavi) bazında sahiptir. BGS fotografik görüntüdeki her rengin miktarını ve varolan bütün renklerin tanımını yapabilmektedir. Bu sistem her bireysel elemente (piksel) bakıp o element hakkındaki renk bilgisini alabilmektedir. Bunlarla birlikte, farklı boyut, şekil, tekstür, ve renklerdeki örnekleride analiz edebilmektedir (Demir, 2002). Görüntünün sayısallaştırılması, kameradaki görüntünün optik-elektrik mekanizma ile elektriksel sinyallere dönüştürülmesiyle sağlanmaktadır (Yaman vd., 2001).



Şekil 2.1. Bilgisayarlı Görüntüleme Sistemi (Luzuriaga, 1997: Demir, 2002).

2.2.2 Görüntünün Sayısallaştırılması

Sayısal görüntü elde edildikten sonra, diğer adım ön işleme işlemidir. Bu aşamada, alınan görüntü bir sonraki aşamada hatasız ve kolay işlenebilmesi için daha belirgin ve anlaşılır hale getirilir. Bu işlemlerden bazıları:

- Görüntüyü belirginleştirmek,
- Görüntüde bulunan kirlilikleri filtrelemek ve
- Görüntü üzerindeki yapısal bozuklukları yok etmek veya azaltmaktadır.

Görüntünün sayısallaştırılması, kameradaki görüntünün optik-elektrik mekanizma ile elektriksel sinyallere dönüştürülmesi işlemidir. Mercekte oluşan görüntü kameranın sensörleri üzerine odaklanır. Bu ışık elemanları üzerinde ışığın durumuna göre elektrik sinyalleri üretilir. Bu sinyaller bilgisayar ortamına görüntü aktarılmasında kullanılan analog sinyallerdir (Luzuriaga, 1997).

2.2.3. Bilgisayarlı Görüntüleme Sistemiyle Renk Analizi

Renk kriteri gıdaların değerlendirilmesi açısından en önemli kalite faktörlerinden birisidir (Tijskens ve Evelo, 1994). Gıdaların rengi enstrümantal, kimyasal ve gözlemsel olarak belirlenebilmektedir. Ancak rengin enstrümantal olarak belirli standartlara göre belirlenmesi daha sağlıklı olmaktadır. Gözlemsel olarak renk

belirlenmesi renk pigmentlerine daha duyarlı farklı aletlerin kullanımı ile aşılabilmektedir (Weatherall ve Lee, 1991). Renk ve renk farklılığının enstrümental olarak genellikle, uluslararası l'Eclairage komisyonu (CIE) tarafından geliştirilen yönteme göre değerlendirilmesi yaygın bir hale gelmiştir. Bu yöntem, "1976 CIE L*, a*, b*, CIELAB üç nokta ölçüm yöntemi" olarak da bilinmektedir (MacDougall, 1984). Bu üç nokta ölçüm yönteminde L*/L, ışık geçirgenlik değerini, 0 (geçirgenlik yok) ve 100 (tamamen geçirgen), a*/a kırmızılık (-a*/a, yeşillik) ve b*/b sarılık (-b*/b, mavilik) değerlerini belirtmektedir (Bakker vd., 1986).

BGS'de görüntü, iki boyutlu ışık şiddeti fonksiyonunun sayısal olarak kullanımından elde edilir. Bu fonksiyon $f(x,y)$ şeklinde gösterilir (Baxes, 1994). Burada x ve y kartezyen koordinatları, (x,y) noktasındaki f'in sayısal değeri ise parlaklık değeri veya görüntünün ilgili noktadaki gri seviye değeridir. Bir sayısal görüntü, satır ve sütun indisleri görüntü içerisinde herhangi bir noktayı tanımlayan elemanlardan meydana gelmiş bir matris olarak göz önüne alınabilir. Bu matrisin her bir elemanının sayısal değeri, kendisine karşılık gelen noktalardaki gri seviye değerine eşittir. Bu sayısal dizinin veya matrisin her bir elemanına görüntü elemanı, resim elemanı veya piksel (*pixel=picture element*) denir (Haralick ve Shapiro, 1993).

Spektrumdaki bütün renkler ana renkler olarak adlandırılan kırmızı (R), yeşil (G) ve mavi (B)'den oluşmaktadır. Eklemeli renk uzayı (*additive color space*) adı verilen bu mantıkta görüntü, piksellere ait ışığı yayan RGB renk değerlerinin karışımından oluşmaktadır. Her bir piksel 0-255 arasında değişen yansıma yada parlaklık değerine sahiptir. RGB bileşenlerinin her biri tek başına 255 değeri alır, diğer iki bileşen 0 değeri alırsa ilgili duruma göre R (kırmızı), G (yeşil) yada B (mavi) oluşur (Demir, 2002).

Her üç bileşenin 0 değer alması durumunda siyah, aynı şekilde her üç bileşenin de 255 değeri alması durumunda ise beyaz oluşur. RGB bileşenlerinin farklı oranlarda bir araya gelmesi ile diğer renkler ve tonları oluşur. En yaygın kullanılan renk uzayı RGB renk uzayı olup, bunun dışında CMY (*Cyan, Magenta, Yellow; subtractive color space*), HSB (*Hue, Saturation, Brightness*), HSL (*Hue, Saturation, Lightness*),

HSV (*Hue and Saturation Value*) ve HSI (*Hue and Saturation Intensity*) renk uzayları da bulunmaktadır (Baxes, 1994).

Sayısal görüntünün tamamı, belirli bir hat yada ilgi duyulan poligonal bir alan için (*ROI: Region of Interest veya AOI: Area of Interest*) parlaklık histogramı veya RGB bileşenleri için renk histogramları çıkarılabildiği gibi bu bölgelere ait ortalama değerler ve standart sapmalar da ilgili yazılımlarla kolaylıkla elde edilebilir. Görüntü üzerinde 0-255 arasında değere sahip piksellerden eşikleme (*thresholding*) yardımıyla, sadece belli değerler arasında veya dışında kalanlar ortaya çıkarılabilir (Baxes, 1994).

Görüntü histogramı, görüntünün her bir noktasındaki piksellerin tespiti ile bu piksellerin sayısının ne olduğunu gösterir. Bu sayede histogram üzerinden görüntü ile ilgili çeşitli bilgilerin çıkartılması sağlanır. Eşikleme işlemi, görüntü işlemenin önemli işlemlerinden birisidir ve görüntü üzerindeki piksel değerlerinin belirli bir değere göre atılması ve yerine diğer değer/değerlerin yerleştirilmesi işlemidir (Yaman, 2000).

İki farklı sayısal görüntü arasında matematiksel işlemler (toplama, çıkarma, çarpma, bölme vb.) yapma şansı da bulunmaktadır. Örneğin (çıkarma işleminin kullanımında) hayvanların bulunduğu bir mekâna ait görüntüden, boş mekân görüntüsü çıkarıldığında hayvanların görüntüsünü verir ki, belirli zaman dilimlerinde bu şekilde hayvan görüntülerinin elde edilmesi ve değerlendirilmesi, davranış incelemelerinde kullanılabilir bir durumdur (Baxes, 1994).

Uzunluk ve özellikle alan belirlemeleri arkaplan/zemin ile ilgilenilen nesne arasında yeterli kontrast/zıtlık mevcutsa otomatik olarak yapılabileceği gibi manuel olarak da uygulanabilir. Ham sayısal görüntülerde alan ve uzunluk gibi ölçümler piksel cinsinden hesaplanabilir. Bu ölçümlerin metrik sisteme göre yapılabilmesi için, görüntü üzerinde yer alan ve metrik sistem karşılıkları bilinen referans noktalarının yazılım aracılığıyla tanımlanmaları gerekir (*spatial calibration*) (Yaman, 2000).

2.2.4. Bilgisayarlı Görüntüleme Sistemi ile İlgili Çalışmalar

Sayısal görüntü işleme ve sayısal görüntü analiz yöntemleri son yıllarda bir çok alanda olduğu gibi gıda alanında da yer almaya başlamıştır. BGS, istatistiksel değerlendirmelere olanak sağlayan sayısal verilere dönüştürülebilen görüntü formunda datalar oluşturduğu için gıdalardaki morfolojik ve kompozisyonel değişikliklerin ölçülebilmesini sağlar. Bu tür veriler, gıdaların dokusu ve yapısı da dahil olmak üzere duyu özellikler arasındaki ilişkileri anlayabilmek açısından çok önemlidir (Kaptan, 1999).

Gıdaların fiziksel görüntüleri özellikle renk içeriği ile ürünün kalitesini etkilemektedir (Francis ve Clydesdale, 1975; Luzuriaga, 1997). Gıda endüstrisinde renk analizinin üç sebebi bulunmaktadır. Birincisi renk gıdanın iyi veya kötü bir ürün olduğunun göstergesidir. İkincisi depolama tekniklerinin gelişiminde renk analizlerinin kullanımınıdır. Depolama süresinde görülen renk değişikliği ürünün raf ömrü süresince iyi bir renk görüntüsü sürdürebilmesi açısından çok önemlidir. Üçüncü ve çok önemli son sebep ise yarı çiğ olarak üretilen ürünlerin satın alınmasındaki ölçüt olan görselliklerdir. Gıdaların renk ölçümleri yüzeyden ışığın yansımaya dayananıdır. Görsel değerlendirme basit ve hızlı olmasının yanında gıdanın görünümü ve renginin hızlı bir şekilde algılanmasını sağlar. Gıdadaki rengin ve görünümün algılanması kişiden kişiye değişmekle beraber spesifik bir rengin miktarını ya da yoğunluğunu tanımlamak görsel olarak zordur. Homojen renk ve yüzeylere sahip gıdaların renk ölçümlerinde yaygın olarak spektrofotometre ve tristimulus kolorimetre kullanılmaktadır (Luzuriaga, 1997). Kolorimetre ile ölçülen renk XYZ veya $L^*a^*b^*$ skalalarında tek bir değer olarak tanımlanmaktadır. Fakat, tanımlanan tek değer homojen olmayan ve farklı renkleri içeren gıdalarda var olan gerçek renklerin bilgisini yeterli derecede vermez. Ortalama bir renk değeri elde edebilmek için gıda örnekleri küçük parçalara bölünüp blendırdan geçirilerek homojen bir karışım elde edilir. Fakat gıda orijinal renk ve görüntüsünü kaybedebileceğinden bu durum çoğu örnekler için uygun olmamaktadır (Luzuriaga, 1997). Bu dezavantajlarından dolayı geleneksel yöntemlerle yapılan sınıflandırma ve tasnif etmeye alternatif, insan yerine kullanılan sistemler geliştirilmiştir. Mikrobilgisayarlar, yapay zeka sistemleri ve bilgisayarlı görüntüleme sistemi kısa

sürede, yüksek hızda performans göstermektedirler (Luzuriaga, 1997; Abdullah, vd., 2003).

Son yıllarda geliştirilen BGS ziraatta ve gıda endüstrisinde artan şekilde kullanılmaya başlanmıştır. Uygulamalar genellikle elma gibi meyvelerin otomatik olarak sınıflandırılmasında (Leemans vd, 1998; Tao ve Wen, 1999; Yang, 1993) ya da ayva, kayısı, muz v.b. gibi dilimlenmiş meyvelerin işlenmesi sırasında renk değişimlerinin gözlenmesi gibi kalite değerlendirmelerinde kullanılmaktadır (Han vd., 1992; Demir vd., 2000; Demir vd., 2001; Demir vd., 2002). Yapılan çalışmalar geliştirilerek, sebzelerin raf ömrünü uzatmak için kullanılan çeşitli kontrollü ve modifiye atmosferlerde depolanmaları sırasındaki kalite değişimlerinin monitörlenmesi konularında da çalışmalar yapılmaya başlanmıştır (Rigney vd., 1992; Demir vd., 2001; Demir vd., 2002).

Gerrard vd., (1996) sığır etlerinde mermerleşme derecesi ve renk tanımlama üzerinde çalışmışlar, Li vd., (1997) et gevrekliğinin görüntü tekstür analizi yardımıyla belirlenebileceğini göstermişlerdir. Benzer şekilde sığır ve domuz etlerinde ve hatta kıymada yağ tayini, mermerleşmenin belirlenmesi, MLD alanının hesaplanması ile ilgili çok sayıda araştırma yapılmış, yöntemin başarıyla uygulanabilir olduğu, bulguların fiziksel ve kimyasal analiz sonuçlarıyla büyük ölçüde ilişkili olduğu gösterilmiştir (Newman 1984; Kuchida vd. 1991; Shackelford vd., 1998; Shiranita vd., 1998; Basset vd., 2000; Kuchida vd. 2000; Karnuah vd., 2001; Cannell vd., 2002; Teira vd., 2003).

Park vd., (1996) ile Park ve Chen (2001) gri skala yoğunluk değeri, Fourier güç - spektrumu ve fraktal analiz yardımıyla etlik piliç karkaslarında tümörlü, kusurlu (yaralanma / berelenme) olanların normal karkaslardan ayırt edilebileceğini ve sinir ağları (neural network) ile oluşturulan tasnif sisteminde (kullanılan modele göre değişen ölçülerde) % 91-97 düzeyinde doğrulukla ayırım yapılabildiğini, aynı şekilde Chao vd., (2002) da piliçlerde deri tümörlerinin hiper ve multi-spektral yöntemlerle elde edilen sayısal görüntülerden belirlenebileceğini göstermişlerdir.

Yud-Ren Chen vd., elma suyu yapımında çeşitli sebeplerle elmanın dış yüzeyine bulaşmış fekal olan patojen *Escherichia coli* O157:H7'nin, farklı ışıklar altında elmanın ezme işlemi esnasında, karışıma geçmesini bilgisayarlı görüntüleme sistemi kullanarak incelemişler ve tarımsal ürünlerde çürüme ve kesmede oluşan lekelenmelerdeki fekal bulaşmayı farklı dalga boyundaki ışıkları kullanarak tesbit edebileceklerini göstermişlerdir.

Scott (1994) çalışmasında, ekmek ve somunlardaki bozulmaları BGS analizi ile tesbit etmiştir. Sapirstein (1995) ise ekmek ve kek kırıntılarının iç yapısını incelemiş ve tahıllarda parlaklık analizi ile birbirine olan benzerliklerini, hücre genişliği ve hücre yoğunluğunu tespit ederek sistemi kısa zamanda geliştirip fırınlarda ekmek yapımında teknik olarak gerekli miktarların ölçümünde daha kesin ve güvenilir bir sistem olarak BGS kullanmıştır.

Davidson vd., (2001) çikolata cipslerinin hamur olarak pişirme işlemi sırasında üst yüzeyde meydana gelen renk-matlık ve şekil-büyükölük gibi fiziksel özelliklerini belirlemede sayısal görüntü analizini kullanmışlar ve tüketiciler için elde ettikleri verilerle dört bulanık mantık (fuzzy) model geliştirmişlerdir.

Abdullah vd., (2000) ise çöreklerde otomatik görsel denetim sistemini geliştirmişlerdir. 200 çörekte görüntüleme sistemi kullanılarak karanlık ve ışıklı ortamlarda çöreklerde sınıflandırılmamış ve ön sınıflandırma parametreleriyle sınıflandırma algoritması kullanmışlardır. Doğru sınıflandırma görsel denetimle karşılaştırıldığında % 96 ön sınıflandırmada % 79 sınıflandırılmamış çörekde başarı sağlanmıştır.

Tao vd., (1995a) çalışmalarında patatesleri şekillerine göre derecelendirerek ayırmışlar ve laboratuvar çalışmasıyla BGS'yi karşılaştırarak % 89 sonuca ulaşmışlardır. Patatesleri derecelendirerek ayırmada bilgisayarlı görüntüleme sisteminde HSI (hue, saturation, and intensity) renk sistemi kullanılmış iyi ve solgun patateslerin arasındaki ayrımı % 90'lık doğrulukla tahmin edilmiştir. Wooten vd.,

(2000) ise tatlı patatesleri ürüne göre ayırmada bilgisayarlı görüntüleme sistemini kullanmışlardır.

Heinemann vd., (1994) marketlerde satılan mantardaki istenmeyen renk değişimini derecelendiren bir sistem oluşturmuşlardır. Vizhanyo ve Tillett (1998) ise renk görüntü analizi ile mekanik olarak zarar gören, hastalık nedeniyle ve bakteri kontaminasyonu (Vizhanyo ve Felfoldi, 2000) sonucu oluşan mantardaki renk değişimini tanımlamışlardır. Bu metodu kullanarak Van Loon (1996), mantarları hastalıklı ve hastaliksız olarak sınıflandırma yapmıştır. Reed vd., (1995) kamera kullanarak mantarları şekillerine göre sınıflandırmışlardır. Hayashi vd., (1998) lahanaları baş büyüklüklerine göre sınıflandırma ve tanımda üç görüntü analizi algoritması kurmuşlardır.

Tollner vd., (1999) tatlı soğanların X ışını kullanarak iç bozulmalarını tahmin etmişler ve buldukları değerleri sınıflandırmada kullanmak için yapay sinir ağları ile modellendirmişlerdir.

Leemans vd., (1998) golden cinsi elmalarda kesimleme etkisini incelemek için bir renk modeli geliştirmişlerdir. Tao ve Wen (1999), elmaları şekillerinin küreselliklerine göre sınıflandırma sistemi geliştirmişlerdir. Yang (1993) ise elmalarda yüzey özellikleri konusunda çalışmış, elmalardaki şekil bozukluklarına göre sınıflandırmada buldukları değerleri yapay sinir ağlarında modellemiş ve % 96.6 başarı sağlamıştır.

Yang (1994; 1996) bitki tanımlamasında gövde ve kaliks bozukluklarının bilgisayarlı görüntüleme sistemi ile belirlenmesini çalışmışlardır. Heinemann vd., (1995) ve Tao vd., (1995b) golden cinsi elmada satürasyon ve yoğunluğu benzer bir sistem kullanarak renk kriterlerine göre sınıflandırmışlardır.

Steinmetz vd., (1999) elmanın şeker içeriğini tahmin etmişler, Paulus ve Schrevens (1999) ise elmanın genleşme prosedürünü şekil analizi ile incelemişlerdir. Ying vd.,

(1999) armudu şekillerine göre, Dewulf vd., (1999) ise sertliğine göre tanımlama yapmışlardır.

Singh ve Delwiche (1994) çekirdekli meyvelerdeki bozulmaların tahmininde tek renkli kamera ile kızıl ötesi ışık, Han vd., (1992) ise X-ışını teknolojisini kullanmışlardır. Kim ve Schatzki (2000) ise X-ışını teknolojisini 198 şeftalide deneyerek % 98 başarı sağlamışlardır. Ayrıca Kim ve Schatzki (2000) elmalarda 2 boyutlu X-ışını teknolojisi ile çekirdek içindeki su miktarını da belirlemişlerdir.

Morimoto vd., (2000) domatesleri şekillerine göre derecelendirmede ürün kalitesini belirlemede bilgisayarlı görüntüleme sistemini kullanmışlardır. Kondo vd., (2000) portakalın asit ve şeker içeriğine göre tanımlamada, Ruiz vd., (1996)'da portakal çiçeklerinde kaliks ve gövde alanlarına göre üreticilerin kullanabileceği bir sistem geliştirmişlerdir.

Pearson ve Toyofuku (2000) karışık kuru yemişleri şekillerine ve renklerine göre Ghazanfari vd., (1996); Pearson ve Slaughter, (1996) ise antepfistıklarını, Kim ve Schatzki, (2001) X ışını kullanarak bademleri ayırmak ve sınıflandırmak için bilgisayarlı görüntüleme sistemi kullanmışlardır.

Okamura vd., (1993) kuru üzümü görüntü özelliklerine, buruşukluk ve kenar şekillerine göre derecelendirmişlerdir. Nagata vd., (1997) ve Cao vd., (1999) çilekleri şekilleri ve büyüklüklerine göre $L^*a^*b^*$ renk modeli kullanarak tanımlamışlardır.

Wang ve Sun (2001, 2002a, 2002b, 2002c) Cheddar ve Mozzarella peynirlerinde farklı pişirme şartlarında erime ve esmerleşme özelliklerini incelemişlerdir. Ni ve Gunasekaran (1995) peynir parçalarının yapısını inceleyerek peynirin tüm yapısını tahmin etmek için BGS kullanmışlardır.

Sun (2000) çok farklı pizza çeşitinde görüntü kalitesi analizi yapmış ve bulanık mantık modellemesi ile kalite kriterlerini belirlemiştir. Yin ve Panigrahi (1997) da kızarmış patates (cips) iç tekstürünü değerlendirmede kullanmışlardır.

Zayas vd., (1996) buğdayı fiziksel özelliklerine Uthu (2000) ise buğday çeşitlerini birim boyutlarına göre sınıflandırmada kullanmışlardır. Majumdar ve Jayas (2000a, 2000b, 2000c, 2000d) tahılları morfoloji, renk ve tekstürlerine göre üçlü sınıflandırmada kullanmışlardır. Panigrahaia vd., (1998), mısırın iki şekil özelliğine göre (kırık ve bütün) sınıflandırmışlardır. Ni vd., (1997) mısırdaki aynı şekilde modelleme yapmışlardır. Diğer bir çalışmada Liu ve Paulsen, (1997); Ng vd., (1997) mısırın renk unsuru olarak beyazlığına ve küflenmesine bakarak bozulma süresini tahmin etmişlerdir.

Wan vd., (2000) pirinç değirmeninde uygulanması gerekli hızlı ve kesin kalite kriterlerine uygun model geliştirmişlerdir. Cardarelli vd., (1999) karanlık alan çalışmasıyla pirinç şekil pürüzlülüğüne göre iç bozulmayı tahmin için BGS kullanmışlardır.

2.3. Yapay Sinir Ağları

İnsan beyni bilinen en gizemli ve karmaşık hesaplayıcıdır. Yapay sinir ağları (YSA), insan beyninin işleyişini taklit ederek yeni sistem oluşturmaya çalışan yaklaşımlardır. İstisnasız tüm YSA yapılarının esin kaynağı biyolojik sinir ağlarının işleyiş yöntemidir (Sağiroğlu vd., 2003).

Yapay zeka, insanlar tarafından yapıldığında zeka olarak adlandırılan davranışların bilgisayar tarafından taklit edilmesidir. Bugün bu davranışlar, karar verme, problem çözme, yorumlama, planlama, kontrollü sistematik olarak sınıflama, tanıma vb. ile sınırlıdır (Sağiroğlu vd., 2003).

Yapay sinir sistemlerinin karakteristik özellikleri şu şekilde sıralanabilir:

1. Nümerik bilgiler yerine sembolik bilgileri işlerler.
2. Belirli algoritmalar kullanarak problemleri çözmek yerine sezgisel ve tecrübeye dayalı yaklaşımlarla problemleri çözerler.
3. Eksik ve belirsiz bilgileri işleyebilme özelliğine sahiptirler.
4. Bilinen teknikler ile matematiksel modeli kurulamayan problemlerle uğraşırlar.
5. Öğrenebilme yetenekleri vardır.


6. Hata yapabilirler.

Geleneksel programlama yöntemleri ile çözülemeyen birçok problem YSA ile çözülebilmektedir. YSA'nın kullanımı iki temel durumda etkili olmaktadır:

- Geniş veri takımlarının yorumlanması istenen incelemelerde,
- Giriş ve çıkış verileri belli, fakat bu veriler arasındaki ilişkilerin iyi bilinmediği lineer olmayan (nonlinear) durumlardadır (Sağiroğlu vd., 2003).

2.3.1. Biyolojik Sinir Hücresi


Biyolojik sinir sistemi, merkezinde sürekli olarak bilgiyi alan, yorumlayan ve uygun bir karar üreten beynin (merkezi sinir ağı) bulunduğu 3 katmanlı bir sistem olarak açıklanır. Alıcı sinirler (receptor) organizma içerisinden ya da dış ortamlardan algıladıkları uyarıları, beyne bilgi ileten elektriksel sinyallere dönüştürür. Tepki sinirleri (effector) ise, beyinin ürettiği elektriksel darbeleri organizma çıktısı olarak uygun tepkilere dönüştürür. Şekil 2.2'de bir sinir sisteminin blok gösterimi verilmiştir (Sağiroğlu vd., 2003).



Şekil 2.2. Biyolojik sinir sisteminin blok gösterimi

Merkezi sinir ağında bilgiler, alıcı ve tepki sinirleri arasında ileri ve geri besleme yönünde değerlendirilerek uygun tepkiler üretilir. Bu yönüyle biyolojik sinir sistemi, kapalı çevrim denetim sisteminin karakteristiklerini taşır. Merkezi sinir sisteminin temel işlem elemanı, sinir hücresidir (nöron) ve insan beyinde yaklaşık 10 milyar sinir hücresi olduğu tahmin edilmektedir. Sinir hücresi; hücre gövdesi, dendritler ve aksonlar olmak üzere 3 bileşenden meydana gelir. Dendritler, diğer hücrelerden aldığı bilgileri hücre gövdesine bir ağaç yapısı şeklinde ince yollarla iletir. Aksonlar ise elektriksel darbeler şeklindeki bilgiyi hücreden dışarı taşıyan daha uzun bir yoldur. Aksonların bitimi, ince yollara ayrılabilir ve bu yollar, diğer hücreler için

dendritleri oluşturur. Şekil 2.3’de görüldüğü gibi akson-dendrite bağlantı elemanı sinaps’dır (Sağiroğlu vd., 2003).



Şekil 2.3. Biyolojik Sinir Hücresi ve Bileşenleri (Sağiroğlu vd., 2003)

Sinapsa gelen ve dendrit’ler tarafından alınan bilgiler genellikle elektriksel darbelerdir ancak, sinapsdaki kimyasal ileticilerden etkilenir. Belirli bir sürede bir hücreye gelen girişlerin değeri, belirli bir eşik değerine ulaştığında hücre bir tepki üretir. Hücrenin tepkisini artırıcı yöndeki girişler uyarıcı, azaltıcı yöndeki girişler ise önleyici girişler olarak söylenir ve bu etkiyi sinaps belirler (Sağiroğlu vd., 2003).

İnsan beyninin 10 milyar sinir hücresinden ve 60 trilyon sinaps bağlantısından oluştuğu düşünülürse, son derece karmaşık ve etkin bir yapı olduğu anlaşılır. Diğer taraftan bir sinir hücresinin tepki hızı, günümüz bilgisayarlarına göre oldukça yavaş olmakla birlikte duyuşsal bilgileri son derecede hızlı değerlendirebilmektedir. Bu nedenle insan beyni; öğrenme, birleştirme, uyarılma ve genelleştirme yeteneği nedeniyle son derece karmaşık, doğrusal olmayan ve paralel dağılmış bir bilgi işleme sistemi olarak tanımlanabilir (Sağiroğlu vd., 2003).


2.3.2. Yapay Sinir Hücresi


YSA'lar insan beyninin aktivitesi örnek alınarak geliştirilmeye çalışılmıştır ve aralarında yapısal olarak benzerlikler vardır. Biyolojik sinir ağlarının sinir hücreleri olduğu gibi yapay sinir ağlarının da yapay sinir hücreleri vardır. YSA'lar birbirine bağlı doğrusal ve/veya doğrusal olmayan birçok elemandan oluşurlar. Biyolojik sinir sistemi ile yapay sinir sistemi arasındaki benzerlikler Çizelge 2.3'de verilmiştir (Sağiroğlu vd., 2003).

Çizelge 2.3. Biyolojik sinir sistemi ile YSA'ların benzer özellikleri (Sağiroğlu vd., 2003; Öztemel, 2003).

Biyolojik Sinir Sistemi	Yapay Sinir Ağlar
Nöron	Yapay Nöron (İşlemci Eleman)
Dendrit	Toplama Fonksiyonu
Hücre Gövdesi	Transfer Fonksiyonu
Aksonlar	Yapay Nöron Çıkışı
Sinapslar	Ağırlıklar

Bir yapay nöron temel olarak girdiler, ağırlıklar, toplama fonksiyonu, transfer fonksiyonu ve çıktı olmak üzere beş kısımdan oluşmaktadır. Şekil 2.4'de p girdili n çıktılı bir yapay nöronun blok diyagram gösterimi (a) ve detaylı gösterimi (b) verilmiştir (Sağiroğlu vd., 2003; Öztemel, 2003).





(b)

Şekil 2.4. p girdili n çıktılı bir yapay nöronun blok diyagram gösterimi (a) ve detaylı gösterimi (b) (Sağiroğlu vd., 2003; Öztemel, 2003).

Bu şekilde; x girdileri, y çıktısı, F fonksiyonu, p nöron girdi sayısını, n çıktı sayısını w ise ağırlıkları ifade etmektedir.

Girdiler: Bir yapay sinir hücresine (proses elemanına) dış dünyadan gelen bilgilerdir. Bu bilgiler kullanılarak ağırlık eğitimi sağlanır. Yapay sinir hücresine dış dünyadan olduğu gibi başka hücrelerden veya kendi kendisinden de bilgiler gelebilir.

Girdiler p elemanlı sütun vektörü olarak gösterilir;

$$X = [x_1, \dots, x_p]^T \quad (2.1)$$

Ağırlıklar: Ağırlıklar bir yapay hücreye gelen bilginin önemini ve hücre üzerindeki etkisini gösterir. Ağırlıklar, girdi ile toplama noktaları arasındaki bağlantılara karşılık gelir. Ağırlıkların büyük ya da küçük olması önemli veya önemsiz olduğu anlamına gelmez. Sinapslar, ağırlıklar diye adlandırılan ayarlanabilir parametreler olarak karakterize edilirler. Ağırlıklar, p elemanlı satır vektörü olarak düzenlenir.

$$W = [w_1, \dots, w_p] \quad (2.2)$$

Toplama fonksiyonu: Bu fonksiyon, bir hücreye gelen net girdiyi hesaplar. Bunun için değişik fonksiyonlar kullanılmaktadır. En yaygın olanı ağırlıklı toplamı bulmaktır. Burada her gelen girdi değeri kendi ağırlığı ile çarpılarak toplanır. Böylece ağa gelen net girdi bulunmuş olur.

Sinapslardan ve dendritlerden geçen girdi işaretleri, toplam post-sinaptik aktiviteyi tanımlayan aktivasyon potansiyeli olarak toplanır. Aktivasyon potansiyeli girdi işaretlerinin ve ağırlıklarının lineer toplamı olarak şekillenmiştir. Yani, ağırlıklar ile girdi vektörlerinin çarpımıdır.

Bu çarpım;

$$v = \sum_{i=1}^p w_i x_i = xw = [w_1 w_2 \dots w_p] \begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_p \end{bmatrix} = wx^T \quad (2.3)$$

ile ifade edilir.

Aktivasyon fonksiyonu: Bu fonksiyon, hücreye gelen net girdiyi işleyerek hücrenin bu girdiye karşılık üreteceği çıktıyı belirler. Aktivasyon potansiyeli, çıktı işaretini üreten bir aktivasyon fonksiyonundan $F(v)$ geçirilir ve çıktı değeri

$$y = F(v) \quad (2.4)$$


fonksiyonundan elde edilir. Aktivasyon fonksiyonu, aktivasyon potansiyelini çıktı işaretinin standart değerleri için normalize eden bir fonksiyondur. Toplama fonksiyonunda olduğu gibi aktivasyon fonksiyonu olarak da çıktıyı hesaplamak için değişik formüller kullanılmaktadır.

Yaygın olarak kullanılan çok katmanlı algılayıcı (Multilayer Perceptrons) modelinde genellikle aktivasyon fonksiyonu olarak sigmoid fonksiyon kullanılmaktadır. Çıktı değerlerine sigmoid bir aktivasyon değeri uygulanırsa, sonuçta çıktı değeri;

$$y = F(v) = \frac{1}{1 + e^{-v}} \quad (2.5)$$

ile bulunur.

Sigmoid Aktivasyon Fonksiyonu: Şekil 2.5’de grafiği verilen çift yönlü sigmoid (tanh) fonksiyonu, türevi alınabilir, sürekli ve doğrusal olmayan bir fonksiyon olması nedeniyle doğrusal olmayan problemlerin çözümünde kullanılan YSA’larında tercih edilir (Sağiroğlu vd., 2003).



Şekil 2.5. Sigmoid (tanh) aktivasyon fonksiyonu (Öztemel, 2003).

Uygulamalarda, doğrusal fonksiyon (linear function), basamak fonksiyonu (step function), kutuplamalı basamak fonksiyonu, parçalı doğrusal fonksiyon ve en yaygın olarak da sigmoid ve tanjant hiperbolik fonksiyonlar kullanılmaktadır. Çizelge 2.4’de kullanılan aktivasyon fonksiyonlarından bazıları verilmiştir (Öztemel, 2003).

Çizelge 2.4. Aktivasyon fonksiyonları (Öztemel, 2003).

Aktivasyon Fonksiyonu	Açıklama
Lineer Fonksiyon (Doğrusal fonksiyon) $F(\text{net}) = \text{net}$	Gelen girdiler olduğu gibi hücrenin çıktısı olarak kabul edilir.
Step fonksiyonu (Basamak fonksiyon) $F(\text{net}) = \begin{cases} 1 & \text{if } \text{net} > \text{eşikdeğer} \\ 0 & \text{if } \text{net} \leq \text{eşikdeğer} \end{cases}$	Gelen net girdi değerinin belirlenen bir eşik değerinin altında veya üstünde olmasına göre hücrenin çıktısı 0 veya 1 değerini alır.
Sinüs Fonksiyonu $F(\text{net}) = \sin(\text{net})$	Öğrenilmesi düşünülen olayların sinüs fonksiyonuna uygun dağılım gösterdiği durumlarda kullanılır.
Eşik Değer Fonksiyonu	Gelen bilgilerin 0 veya 1’den büyük ya da küçük olmasına göre değerler alır. 0 ile 1 arasında da değerler alabilir. Tanımlanan bu

$F(\text{net}) = \begin{cases} 0 & \text{if } \text{net} \leq 0 \\ \text{net} & \text{if } 0 < \text{net} < 1 \\ 1 & \text{if } \text{net} \geq 1 \end{cases}$	aralığın dışında değer almaz.
Hiperbolik Tanjant Fonksiyonu $F(\text{net}) = \frac{e^{\text{net}} + e^{-\text{net}}}{e^{\text{net}} - e^{-\text{net}}}$	Gelen net girdi değerinin tanjant fonksiyonundan geçirilmesi ile hesaplanır.

Çıktılar: Aktivasyon fonksiyonu tarafından belirlenen çıktı değeridir. Bir işlemci elemanın çıktı değeri diğer işlemci elemanlarına girdi veya ağına çıktı değeri olabilir. Üretilen çıktı dış dünyaya da gönderilebilir.

Transfer veya aktivasyon fonksiyonları öğrenme eğrisi olarak da adlandırılmaktadır. Aktivasyon fonksiyonları bir YSA'da nöronun çıkış genliğini, istenilen sınır değerler arasında sınırlar. Bu değerler çoğunlukla [0,1] veya [-1,1] arasındadır. Ayrıca, yapay sinir ağına bir kutuplama (bias) değeri uygulanarak aktivasyon fonksiyonu artırılabilir.

2.3.3. Yapay Sinir Ağının Yapısı ve Çalışması (Kara kutu benzetmesi)


Yapay sinir hücreleri bir araya gelerek yapay sinir ağlarını oluştururlar. Sinir hücrelerinin bir araya gelmesi rastgele olmaz. Genel olarak hücreler üç katman halinde ve her katman içinde paralel şekilde bir araya gelerek ağı oluştururlar (Öztemel, 2003).

Bu katmanlar aşağıda belirtilmiştir;

Girdi katmanı: Bu katmandaki proses elemanları dış dünyadan bilgileri alarak ara katmanlara transfer etmekle sorumludurlar. Bazı ağlarda bilgi katmanında herhangi bir bilgi işleme olmaz.

Ara katmanlar: Girdi katmanından gelen bilgiler işlenerek çıktı katmanına gönderilir. Bilgilerin işlenmesi ara katmanlarda gerçekleştirilir. Bir ağ içinde birden fazla ara katman bulunabilir.

Çıktı katmanı: Bu katmandaki proses elemanları ara katmandan gelen bilgileri işleyerek ağıın girdi katmanından sunulan girdi seti için üretilmesi gereken çıktıyı üretirler. Şekil 2.6’da bu üç katmanın her birinde bulunan proses elemanları ve katmanlar arası ilişkiler bir yapay sinir ağı olarak verilmistir (Öztemel, 2003).



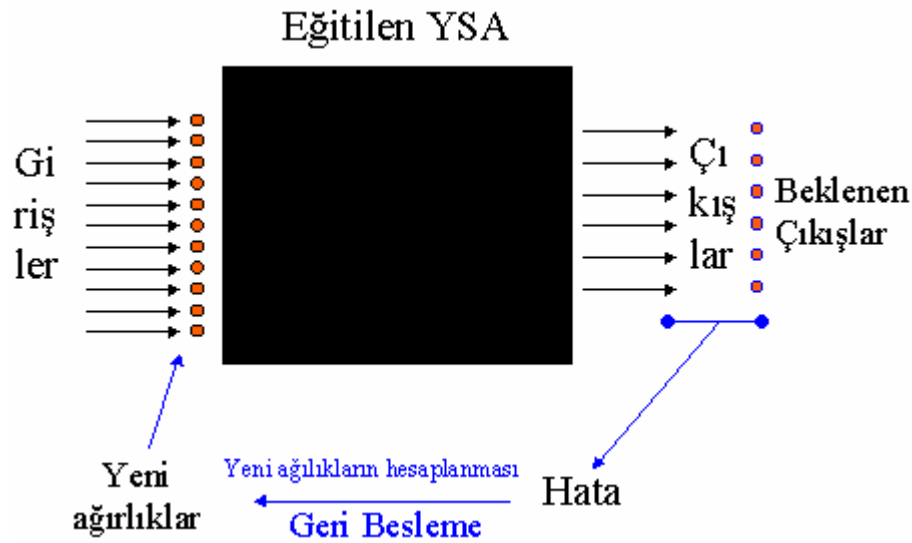
Şekil 2.6. Bir yapay sinir ağı modeli (Öztemel, 2003).

Şekildeki yuvarlaklar proses elemanlarını göstermektedir. Her katmanda birbirine paralel elemanlar söz konusudur. Proses elemanlarını birbirine bağlayan çizgiler ise ağıın bağlantılarını göstermektedir. Proses elemanları ve bağlantıları yapay sinir ağını oluştururlar. Bu bağlantıların ağırlık değerleri öğrenme sırasında belirlenmektedir (Öztemel, 2003).

Yapay sinir ağlarının genel çalışma prensibi, bir girdi setini alarak onları çıktı setine çevirmek olarak açıklanabilir. Bunun için ağıın kendisine gösterilen girdiler için doğru çıktıları üretecek hale gelmesi (yani eğitilmesi) gerekmektedir. Ağa sunulacak girdiler öncelikle bir vektör haline getirilir, bu vektör ağına gönderilir ve ağı bu vektör için gerekli çıktı vektörünü üretir. Ağıın parametre değerleri doğru çıktıyı üretecek şekilde düzenlenir. Bir yapay sinir ağı, herhangi bir girdi vektörünü nasıl dönüştürdüğü konusunda bir bilgi vermez. Mühendislik açısından bakıldığında yapay sinir ağları “kara kutu” gibi görülebilir. Kara kutu, dışarıdan bilgileri alıp, dışarıya ürettiği çıktıları vermektedir. İçeride ne olduğu ise bilinmemektedir. Diğer bir

değişle yapay sinir ağının sonuçları nasıl oluşturduğunu açıklama yeteneği yoktur. Bu durum ağa olan güveni sarsmakla birlikte başarılı uygulamalar yapay sinir ağlarına olan ilgiyi sürekli artırmaktadır (Öztemel, 2003).

Yapay sinir ağlarının iki türlü çalışma şekli vardır. Biri eğitme diğeri kullanma aşamasıdır. Bir yapay sinir ağlarının kullanılabilmesi için önce eğitilmesi gerekir (Şekil.2.7).



Şekil 2.7. Yapay Sinir Ağlarının Çalışma Şekli (Öztemel, 2003).

2.3.3.1. Eğitme

Eğitme aşamasında yapay sinir ağlarının içindeki düğümlerin (node) birbirine bağlantı yüzdelerini gösteren ve ağırlık (weight) diye tabir edilen değerler hesaplanır. Bu aşamada genellikle kullanılan algoritma geriye yayılma yada geriye yansıma (Back Propagation) algoritmasıdır. Geriye yayılma algoritmasının özü; ilerleme sonucunda ortaya çıkan hatanın, geriye doğru yansıtılarak, ağırlıkların daha doğru sonuçlar verecek şekilde değiştirilip yeniden hesaplanarak düzeltilmesidir.

Eğitme aşamasında ağırlıkların hesaplanabilmesi için yapay sinir ağlarına girişler ve karşılık gelen çıkışlar verilir. Yapay sinir ağları için öğrenme bu giriş ve çıkış verileri arasında bir çeşit bağlantı kurmak diye de tanımlanabilir. Eğitme aşamasında hesaplanan bu ağırlık değerleri daha sonra sadece girişlerin verilir çıkışların

hesaplanmasının istenildiği kullanma aşamasında işe yararlar. Eğitim aşamasının bir basamağı hem ilerleme hem de geri yayılma safhalarını içerirken, kullanma aşamasında sadece ilerleme işlemi uygulanır. Zaten gerçek sonuçlar bilinmediğinden hatanın hesaplanıp geri yansıtılması mümkün değildir.

2.3.3.2. Kullanma


Kullanma aşamasındaki algoritma eğitim aşamasına göre daha basittir. Dolayısıyla yapay sinir ağları kullanma aşamasında eğitim aşamasına göre daha hızlı çalışırlar. Yani bir kere tam manasıyla eğitilmiş olan bir yapay sinir ağları eğitim aşamasında güçlükler çıkarmış olsa da, kullanma aşamasında özellikle hız açısından o kadar sorun çıkarmaz. Eğitimde de bahsedildiği gibi, kullanma aşamasında girişlere karşılığı istenen değerler konulur. Eğitim aşamasında hesaplanan ağırlık değerleri bu aşamada, sadece giriş değerlerinin verilip çıkışların yapay sinir ağları tarafından hesaplanmasında kullanılır.

2.3.4. YSA'ların Yapılarına Göre Sınıflandırılması

Yapay sinir ağları, yapılarına göre, ileri beslemeli (feedforward) ve geri beslemeli (feedback) ağlar olmak üzere iki şekilde sınıflandırılırlar.

2.3.4.1. İleri Beslemeli Ağlar

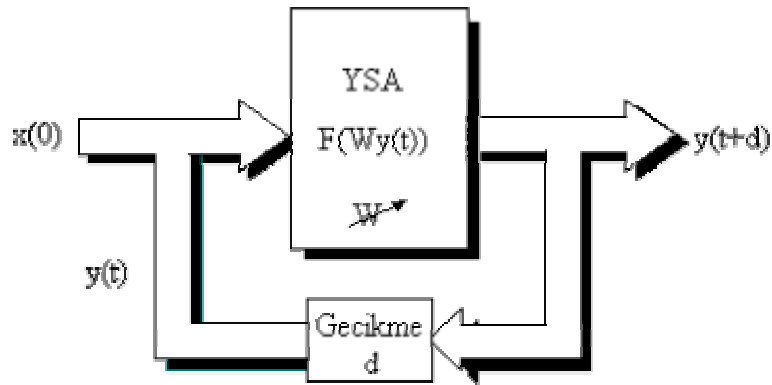
İleri beslemeli bir ağda işlemci elemanlar (İE) genellikle katmanlara ayrılmışlardır. İşaretler, giriş katmanından çıkış katmanına doğru tek yönlü bağlantılarla iletilir. İE'ler bir katmandan diğer bir katmana bağlantı kurarlarken, aynı katman içerisinde bağlantıları bulunmaz. Şekil 2.8'de ileri beslemeli ağ için blok diyagram gösterilmiştir. İleri beslemeli ağlara örnek olarak çok katmanlı perseptron (Multi Layer Perseptron-MLP) ve LVQ (Learning Vector Quantization) ağları verilebilir (Öztemel, 2003).



Şekil 2.8. İleri beslemeli ağ için blok diyagram (Öztemel, 2003).

2.3.4.2. Geri Beslemeli Ağlar

Genellikle gıda alanlarında yapılan analizlerin değerlendirilmesinde YSA modeli oluşturulurken geri beslemeli ağlar (back propagation) yaygın olarak kullanılan yöntemdir (Eerikainen vd., 1993). Geri beslemeli sinir ağı, çıkış ve ara katlardaki çıkışların, giriş birimlerine veya önceki ara katmanlara geri beslendiği bir ağ yapısıdır. Böylece, girişler hem ileri yönde hem de geri yönde aktarılmış olur. Şekil 2.9'da bir geri beslemeli ağ görülmektedir. Bu çeşit sinir ağlarının dinamik hafızaları vardır ve bir andaki çıkış, hem o andaki hem de önceki girişleri yansıtır. Bundan dolayı, özellikle önceden tahmin uygulamaları için uygundur. Bu ağlar çeşitli tipteki zaman-serilerinin tahmininde oldukça başarı sağlamışlardır. Bu ağlara örnek olarak Hopfield, SOM (Self Organizing Map), Elman ve Jordan ağları verilebilir (Öztemel, 2003).




Şekil 2.9: Geri beslemeli ağ için blok diyagram (Öztemel, 2003).

2.3.5 YSA'ların Öğrenme Algoritmalarına Göre Sınıflandırılması

Öğrenme; gözlem, eğitim ve hareketin doğal yapıda meydana getirdiği davranış değişikliği olarak tanımlanmaktadır. O halde, birtakım metot ve kurallar, gözlem ve eğitime göre ağdaki ağırlıkların değiştirilmesi sağlanmalıdır. Bunun için genel olarak üç öğrenme metodundan ve bunların uygulandığı değişik öğrenme kurallarından söz edilebilir. Bu öğrenme kuralları aşağıda açıklanmaktadır (Öztemel, 2003).

2.3.5.1. Danışmanlı Öğrenme (Supervised Learning)

Bu tip öğrenmede, YSA'ya örnek olarak bir doğru çıkış verilir. İstenilen ve gerçek çıktı arasındaki farka (hataya) göre İE'ler arası bağlantıların ağırlığı en uygun çıkışı elde etmek için sonradan düzenlenebilir. Bu sebeple danışmanlı öğrenme algoritmasının bir "öğretmene" veya "danışmana" ihtiyacı vardır. Şekil 2.10'da danışmanlı öğrenme yapısı gösterilmiştir. Widrow-Hoff tarafından geliştirilen delta kuralı ve Rumelhart ve McClelland tarafından geliştirilen genelleştirilmiş delta kuralı veya geri besleme (back propagation) algoritması danışmanlı öğrenme algoritmalarına örnek olarak verilebilir (Öztemel, 2003).




Şekil 2.10: Danışmanlı öğrenme yapısı (Öztemel, 2003).

2.3.5.2. Danışmansız Öğrenme (Unsupervised Learning)

Girişe verilen örnekten elde edilen çıkış bilgisine göre ağ sınıflandırma kurallarını kendi kendine geliştirmektedir. Bu öğrenme algoritmalarında, istenilen çıkış


değerinin bilinmesine gerek yoktur. Öğrenme süresince sadece giriş bilgileri verilir. Ağ daha sonra bağlantı ağırlıklarını aynı özellikleri gösteren desenler (patterns) oluşturmak üzere ayarlar. Şekil 2.11’de danışmansız öğrenme yapısı gösterilmiştir. Grossberg tarafından geliştirilen ART (Adaptive Resonance Theory) veya Kohonen tarafından geliştirilen SOM (Self Organizing Map) öğrenme kuralı danışmansız öğrenmeye örnek olarak verilebilir (Öztemel, 2003).



Şekil 2.11. Danışmansız öğrenme yapısı (Öztemel, 2003).

2.3.5.3. Takviyeli öğrenme (Reinforcement learning)

Bu öğrenme kuralı danışmanlı öğrenmeye yakın bir metottur. Denetimsiz öğrenme algoritması, istenilen çıkışın bilinmesine gerek duymaz. Hedef çıktıyı vermek için bir “öğretmen” yerine, burada YSA’ya bir çıkış verilmemekte fakat elde edilen çıkışın verilen girişe karşılık iyiliğini değerlendiren bir kriter kullanılmaktadır. Şekil 2.12’de takviyeli öğrenme yapısı gösterilmiştir. Optimizasyon problemlerini çözmek için Hinton ve Sejnowski’nin geliştirdiği Boltzmann kuralı veya GA takviyeli öğrenmeye örnek olarak verilebilirler (Öztemel, 2003).



Şekil 2.12. Takviyeli öğrenme yapısı (Öztemel, 2003).

2.3.6. YSA'ların Özellikleri, Üstünlükleri ve Mühendislik Uygulamaları

Yapay sinir ağlarının karakteristik özellikleri uygulanan ağ modeline göre değişmektedir. Bütün modeller için geçerli olan genel karakteristikler aşağıdaki gibi sıralanabilir;

- Yapay sinir ağları makine öğrenmesini gerçekleştirirler,
- Programları, çalışma şekli bilinen programlama yöntemlerine benzememektedir,
- Bilgi saklanır,
- Yapay sinir ağları örnekleri kullanarak öğrenirler,
- Yapay sinir ağlarının güvenle çalıştırılabilmesi için önce eğitilmeleri ve performanslarının test edilmesi gerekmektedir,
- Görülmemiş örnekler hakkında bilgi üretebilirler,
- Algılamaya yönelik olaylarda kullanılabilirler,
- Şekil ilişkilendirme (örüntü) ve sınıflandırma yapabilirler,
- Örüntü tanımlama gerçekleştirebilirler,
- Kendi kendini organize etme ve öğrenebilme yetenekleri vardır,
- Eksik bilgi ile çalışabilmektedirler,
- Hata toleransına sahiptirler,
- Belirsiz, tam olmayan bilgileri işleyebilmektedirler,
- Tedrici bozulma gösterirler,
- Dağınık belleğe sahiptirler,
- Sadece sayısal bilgiler ile çalışabilmektedirler.

Yapay sinir ağları klasik sistemlere göre aşağıda verilen üstünlüklere sahiptir.

- Doğrusal olmama,
- Öğrenme,
- Genelleme yapma,
- Adaptasyon,
- Veri işleme,
- Hataya ve gürültüye karşı duyarlılık ve tolerans,
- Donanım,
- Hazır paket programlar.

YSA uygulamaları temel olarak tahmin, sınıflandırma, veri ilişkilendirme, veri yorumlama ve veri filtreleme olarak sınıflandırılabilir:

- Tahmin (Prediction): Uygulanan girdi değerlerinden bazı çıktı değerleri bulunmaya çalışılır.
- Sınıflandırma (Classification): Girdi değerleri kullanılarak sınıflandırma yapılır.
- Veri ilişkilendirme (Data Association): Sınıflandırmaya benzer bir yaklaşım gibi görünse de ilave olarak hatalı olan veriyi tanımlar.
- Veri yorumlama (Data Conceptualization): Girdi verisinde mevcut gruplar arasındaki ilişkileri analiz etme işlemidir.
- Veri filtreleme (Data Filtering): Girdi sinyalleri içerisindeki uygun olmayan verilerin ayıklanmasını sağlar.

YSA'lar elektrik ve elektronik mühendisliği, sistem kontrol mühendisliği, bilgisayar mühendisliği, kimya mühendisliği, gıda bilimi, teknolojisi ve mühendisliği, inşaat ve yapı mühendisliği, imalat ve makine mühendisliği, harita mühendisliği ve uygulamalarında problemlerin çözümünde yaygın olarak kullanılmaktadırlar (Elmas, 2003; Öztemel, 2003; Sağıroğlu vd. 2003).

2.3.7. Yapay Sinir Ağları ile İlgili Çalışmalar

Günümüzde, teknolojik gelişmeler ve bununla bağlantılı olarak daha mükemmeli arayan müşteri talepleri beraberinde daha karmaşık sistem ve yaklaşımları zorunlu hale getirmiştir. Bu karmaşık sistemlerle ilgili problemleri çözmek geleneksel mühendislik yöntemleriyle çoğu zaman mümkün olmamaktadır. Bu noktada uzman bilgisini öğrenebilen, karmaşık eşleştirmeleri yapabilen ve doğrusal olmayan problemleri daha hızlı ve yüksek doğrulukta çözebilen akıllı sistemler ya da modern mühendislik yöntemleri (bulanık mantık, genetik algoritmalar, yapay sinir ağları), geleneksel yöntemlere alternatif olmaya başlamıştır (Öztemel, 2003).

Özellikle çok parametrelili ve girdi-çıkıtı ilişkileri doğrusal olmayan (non-linear) sistemler üzerinde çalışırken; insan beyninin özellikle öğrenme kabiliyetini taklit etme felsefesine dayanan yapay sinir ağı yapılarının kullanımı oldukça başarılı sonuçlar vermektedir.

Bugün yapay sinir ağları; oldukça fazla girdi-çıkıtı verilerine sahip kaotik sistemlerin denetiminden, robot uygulamalarına, borsa ve işletme yönetiminden tıp alanına, savunma sanayinden elektronik ve haberleşme sistemlerine, görüntü ve ses işlemeden optimizasyon ve sinyal işlemeye kadar birçok alanda başarı ile uygulanmaktadır (Öztemel, 2003).

Genel olarak yapay sinir ağları (YSA); tahmin, sınıflandırma, veri ilişkilendirme, veri kavramsallaştırma ve veri süzme gibi işlemleri yapabilmektedir (Öztemel, 2003).

Gıda endüstrisinde kalite ve kontrol kapasitelerinin artırılmasında bilgisayarlı görüntüleme analizi, elektronik burun ve elektronik dil analizinden elde edilen multivariate datanın analiz uygulamalarında yapay sinir ağları, bulanık mantık ve genetik algoritma işlemleri kullanılarak modellenmeleri başarılı bir şekilde uygulanmaktadır (Ying vd., 2003; Demir, 2002; Luzuriaga, 1997).

Endüstriyel ekmek mayası fermantasyonunda yapay sinir ağı ile biyokütle kestirimi (Karakuzu, 2003), gıdaların kurutulmasında parametre optimizasyonu ve kestirimi için genetik algoritma ve adaptif ağ tabanlı bulanık sonuçlandırma sistemlerinin uygulanması (Erentürk, 2003), fast food'ların duyu özelliklerinin belirlenmesi (Sayeed vd., 1995), bütün mısır tanelerinin kırılmış olanlardan ayrılarak sınıflandırılması (Liao vd., 1993), hamurun rheolojik özelliklerinin belirlenmesi (Ruan vd., 1995), antosiyonin içeriklerinin belirlenerek şarapların sınıflandırılması (Fang vd., 1998), gıdaların kuruması sırasında gözeneklerin tahmininde, gıdalarda ısı prosesi değerlendirilmesine, gıdalarda görünür gözeneklilik, sıcaklık ve nem içeriğine göre ısı geçirgenliği tahmini, yoğurt fermantasyonunda kızıl ötesi

spektrometre(NIRS) (Cimander, 2001), elektronik burun (electronic nose-EN) ve biyoreaktör problemleriyle ölçümlerden elde edilen verilerle yapay sinir ağları ile galaktoz, laktat ve laktoz içeriklerine göre proses modellemesi, gıdalardaki antioksidanları spektrometrik farklı kinetik belirleyicilerin modellenmesi, gıda ürünlerinin donma süresinin tahmini uygulamalarında yapay sinir ağları kullanılmıştır.

Mikrobiyal çalışmalarda ise mikrobiyel gelişmenin belirlenmesi (Jeyamkondan vd., 1991), *Listeria monocytogenes* yaşam süresinin tahmini (Lou, 2000), *Escherichia coli O157:H7* yaşam-ölüm ve gelişme-gelişme durumlarının tahmini (Yu, 2005), donmuş gıdalarda bakteri gelişiminin tahmini, yoğurttaki *Streptococcus salivarius* subsp. *thermophilus* ve *Lactobacillus delbrueckii* subsp. *bulgaricus* elde edilen bakteri popülasyon değerleri verileri ile agar ekim yapılarak elde edilen verileri modellenerek bakteri popülasyonu tahmini (Talon, 2002), globular proteinlerin ikincil yapılarının tahmini, idrar yolu iltihaplanmalarında kanserli hücrelerin kanser olmayan tümörler ile karşılaştırılması, bakterilerin duyuşal özelliklerine bağılı olarak internal ve eksternal sinyallerinin tahmini, adaptasyon karakterlerinin belirlenmesi, bakteri hücreleri arasında olan iletişimin belirlenmesi uygulamalarında yapay sinir ağları kullanılmıştır.

3. MATERYAL VE YÖNTEM

3.1. Materyal

Çalışmada, tek ticari markanın 15 tane light, 15 tane normal yoğurt örnekleri kullanılmıştır. Bu çalışma 3 tekerrürlü ve 2 paralelli olmak üzere yapılmıştır. Yoğurt örneklerindeki ürünü dış ortamdan korumak için şeffaf plastik kapağın altında bulunan jelatinin alüminyum veya plastik olması ışığın ürünle temasını etkilediği gözönünde bulundurularak, ışığın etkisinin ölçülmesi amacıyla örnekler floresans ışık uygulanarak ve ışısız ortamda ± 4 °C'de olmak üzere üzerinde belirtilen raf ömrü süresi olan 14 gün süreyle saklanmıştır.

3.2. Yöntem

3.2.1. Kimyasal analiz ve örnek hazırlama

pH tayini:

Bütün ürünlerin pH değerleri İnoLab (WTW, Measurement System, FL, USA) pH metre kullanılarak ölçülmüştür.

Yağ tayini:

Yoğurt örnekleri için 20 gr yoğurt örneği 20 ml saf su ile sulandırılarak karıştırılmış, süt bütirometresine 10ml H₂SO₄ (d=1,82) den konularak üzerine bu karıştırılan yoğurt örneğinden 11 ml ilave edilmiştir. Üzerine 1 ml amil alkol ilavesinden sonra ağzı tıpayla kapatılarak karıştırılmış ve santrifüjde 5 dak. süreyle tutulmuştur. Bütirometrede okunan değer 2 ile çarpılarak yağ oranı yüzde olarak bulunmuştur. Tüm numuneler için analizler Anonymous (1990)'a göre yapılmıştır.

3.2.2. Mikrobiyolojik analiz

Yoğurt örneklerinin mikrobiyolojik özelliklerinin belirlenmesi amacıyla ön denemelere göre belirli sayıda dilüsyon hazırlanarak toplam bakteri, maya küf ve koliform bakteri miktarları incelenmiştir (Anonymous, 1990).

Toplam Aerobik Mezofilik Bakteri: Yoğurt örneklerinden çeşitli dilüsyonlar hazırlanarak Plate Count Agar (PCA) üzerine ekim yapılmıştır. 30°C 'deki 48 saat inkübasyondan sonra petriyelerdeki koloniler sayılarak örneklerdeki toplam mikroorganizma sayısı belirlenmiştir.

Maya küf içeriği: Yoğurt örneklerinden çeşitli dilüsyonlar hazırlanarak Patates Dekstroz Agar (PDA)'a ekim yapılmıştır. 25°C'de 5 gün süre ile inkübe edilmiştir. İnkübasyondan sonra petri kutularında sayım yapılmış ve maya-küf miktarı tespit edilmiştir.

Koliform bakteri içeriği: Hazırlanan çeşitli dilüsyonlardan Violet Red Bile Agar (VRB Agar)'a ekim yapılmıştır. 37°C'de 2 gün inkübe edilmiştir. İnkübasyon sonunda koloniler sayılmış ve koliform bakterilerin sayısı bulunmuştur.

3.2.3. Bilgisayarlı Görüntü Sistemi (Machine Vision)

3.2.3.1. Donanım (Hardware)


Etrafı %100 temiz bezle kuşatılmış bir ışık kutusu kullanılmıştır. Kutunun altında ve üstünde Lumichrome 1XX 6500°K CRI 98 full spektrum floresans lamba bulunmaktadır. Kutu kapaklı olduğundan dolayı dışarıdan gelen ışık izole edilebilmektedir. Üst tarafta CCD-DFW-V500 Sony (Japonya) marka digital bir video kamera içeren sistem bulunmaktadır (Luzuriaga vd., 1997), (Şekil 3.1).




Şekil 3.1. Sony DFW-V500 marka digital kamera

Yoğurt örnekleri 1., 7. ve 14. günde 64 bit renk, 640x 480 piksel özellikleri olan digital kamera ile görüntülenmiştir. Kameranın lensi fokus uzunluğu 12X, kutusunun

alt yüzeyinden 49,5 cm yukarisına gelecek şekilde ayarlanmiştir. Kamera ile bilgisayar arasındaki bağlantı yüksek performans gösteren IEEE1394-1995 Firewire ağ bağdaştırıcı ile gerçekleşmektedir. 64 bit 640x 480 piksel özelliğinde görüntü alabilmek için görüntü yakalayıcı kullanılmaktadır. Görüntü fotoğraf çekimi kullanılarak beyaz zeminli bir düzenek altında gerçekleşmiştir. Görüntü eldesi sırasında bilimsel olarak önceden düzenlenip standardize edilmiş 24 ayrı renk içeren karelerin bulunduğu renk kontrol kartı (GretagMachbeth, New Windsor, NY, USA) örneklerin daha sonra kalibrasyonu için ışık kutusu içinde kullanılmaktadır.



Şekil 3.2. Görüntü analizi düzeneği çizim görünüşü



Şekil 3.3. Görüntü analizi düzeneği görünüşü

3.2.3.2. Yazılım (Software)

Görüntüleme sırasında görüntüden bilginin alınması için kullanılan renk analiz programı görüntülerde parlaklık, kontrast, hue ya da doygunluk üzerinde değişiklik yapabilme imkanı vermiştir. Kullanılan nesnenin yakalanan görüntüsündeki ayarlar mümkün olduğunca görüntüdeki nesnenin orijinal rengine yakın hale getirilmiştir. Ayarlar daha sonraki çekimlerde kullanılmak üzere kaydedilmiştir. (doygunluk=60, kontrast=0.33, parlaklık=0.41 ayarlar 0 ila 255 arasında düzenlenmiştir). Görüntü bmp olarak kaydedilmiştir. Deney sırasında çekilen yoğurt resimleri kamera S-Video kablosuyla AMD G3 3000 mhz 1 GB RAM 256 MB ekran kartına sahip bilgisayara aktarılmıştır. Ön işleme işleminde görüntüyü belirginleştirmek, görüntüde bulunan kirlilikleri filtrelemek ve görüntü üzerindeki yapısal bozuklukları yok etmek veya minimize etmek amacıyla adobe photoshop programı kullanılarak temizlenmiştir. Temizleme sırasında görüntünün arka fonu da temizlenmiş ve görüntüler bmp olarak tekrar kaydedilmiştir. Her bir denemeden alınan yoğurt örneğinden Color expert programı (Borland International, Inc., 1994) kullanılarak renk datası elde edilmiştir. Program görüntüdeki her piksele bakar ve RGB değerlerini okur ve bu değerleri 4096 renk bloklarına çevirir. L*a*b* renk sistemi kullanılarak ortalama renk değeri de ölçülmüştür. Kamera ayarlarında ve ışıpta meydana gelebilecek değişikliklerden dolayı yoğurt örneğindeki okunan renk değeri gerçek değerinden farklı olabileceğinden renk kalibrasyonu yapılmıştır. Renk kontrol kartı referans olarak kullanılmış orijinal yoğurt örneğine göre renk kartından ortalama değerler hesaplanmış ve bir tanesi temel alınarak kalibrasyon buna göre yapılmıştır. Kalibrasyon için renk analiz yazılım programındaki kalibrasyon metodu kullanılmıştır. Kalibrasyonla düzeltilmiş görüntüler aynı yazılım programı ile analiz edilmiştir. Program otomatik olarak datayı Microsoft excel formatında (xls) vermektedir. Program bir nxm renk data matrisini oluşturmaktadır. n= renk bloklarının sayısı ve m=görüntüdeki örnek sayısını ifade etmektedir. Renk verisi yoğurt örneğinin toplam alanının renk bloklarıyla % olarak ifadesidir. Program aynı zamanda örneklerin L*a*b* değerlerinin ortalaması ve standard sapmasını da hesaplamaktadır. Grafikselleştirme de histogram formunda verilmektedir. Renk bloklarından alınan yoğurdun toplam alanının %1'inden yukarıda olan sayısal değerler grafikselleştirme sunumunda ve YSA'larının analizinde kullanılmıştır. Böylece


örnekteki en önemli renkler basitleştirilerek analiz için kullanılmıştır. Grafiksel sunumda renk blok sayıları X ekseninde ve yoğurt örneklerinin % alanı da Y ekseninde gösterilmiştir. Grafikler Windows Metafile formatında kaydedilmiştir. 4096 renk bloklarını tanımlayıcı liste Color Expert Software (Borland International, Inc., 1994)'de sunulmuştur. Bu tanıttıcı listede her renk bloğunun merkezindeki RGB değeri, ilgili $L^*a^*b^*$ değeri, NBS renk isimleri, ve bloğun rengini temsilen boyanmış dikdörtgen bir kutucuk bulunmaktadır (Luzuriaga vd., 1997; Demir, 2002).

3.2.4. Yapay Sinir Ağlarıyla Verilerin Modellenmesi

Doğrusal olmayan çok değişkenli analiz yapabilmesi, paralel yapılı olması ve örüntü tanıma özelliğinden dolayı bu çalışmada YSA kullanılmıştır. Örüntü tanıma; ses, görüntü harf vb. örüntülerin (pattern) yani küçük parçaların bir araya gelmesi ile, insan duyu organlarına (kulak, göz vb.) anlam ifade eden verilerin bilgisayar tarafından da aynı anlamı temsil edecek şekilde işlenmesi veya incelenmesidir. En kolay ve rahat anlaşılır örüntü tanıma şekillerinin başında görüntü tanıma gelir. Çünkü en azından karşımızda gözle görünür bişeyler vardır. Bir örüntüyü bilgisayara tanıtmaya çalışırken üzerinde çeşitli işlemler (kenar tespiti, histogram eşitleme, domain değiştirme vb.) yapmamız gerekir. Bu işlemler için çalışmada bilgisayarlı görüntüleme sistemi kullanılarak farklı işlem uygulanmış yoğurt örneklerinden alınan renk dataları analiz için kullanılmıştır.


YSA'yı eğitmek için ileri beslemeli geriye yayılım algoritması ve giriş parametrelerinin verileri pozitif değerler olduğu için sigmoid aktivasyon fonksiyonu kullanılmıştır. Modellemelerde 10000 iterasyon yapılmıştır. Parametreler farklı sayı değerlerine sahip oldukları için normalize edilmiştir. Böylece veriler 0-1 sayı değerleri arasına indirgenmiş ve aynı zamanda değişkenler boyutsuz hale getirilerek aralarındaki benzerliğin rastgele seçilmiş olma etkisi de ortadan kaldırılmıştır. Girdi parametrelerini renk analizi ile elde edilen veriler ve deney çalışması sonucunda elde edilen pH, mikrobiyolojik değişiklik verileri oluşturmaktadır. Bu çalışmada oluşturulan yapay sinir ağları modelinde giriş katmanında 16 adet sinir hücresi bulunmaktadır. Çalışmada tek gizli katman kullanılmış ve bu gizli katmanda 1'den 20'ye kadar nöronlar denenerek çeşitli YSA modelleri geliştirilmiştir.

Modellemelerde çıktı olarak raf ömrü gün sayısı değerleri kullanılmıştır. Geliştirilen bu modellerden en uygun sonucu veren ağ yapısının gizli katmanında 5 nöron bulunmaktadır. En uygun sonucu veren modelin ağ yapısı Şekil 3.4'de gösterilmektedir.



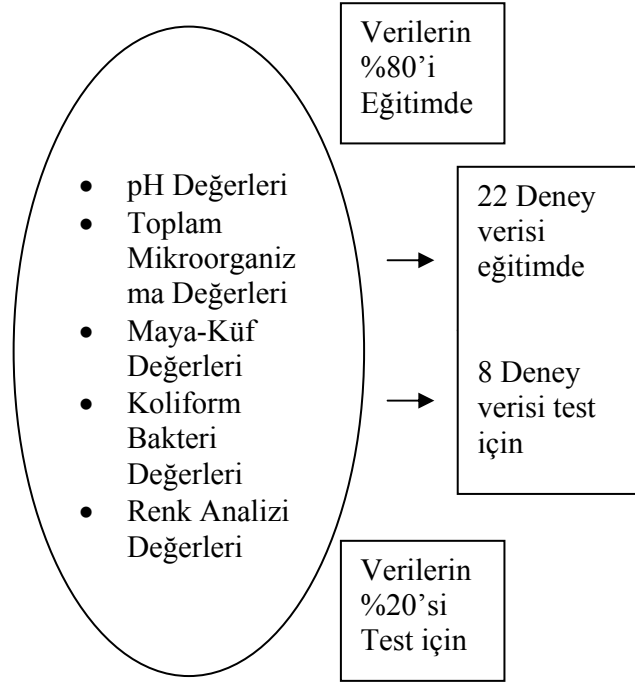
Şekil 3.4. Seçilen Yapay Sinir Ağı Model

Örneklere ait girdi parametrelerinde bulunan verilerin modellenmesi akım şemasında sunulmaktadır (Şekil 3.5.).



Şekil 3.5. Model kurulum şeması

Oluşturulan modelde verilerin %80'i eğitim verileri olarak kalan %20'lik kısmı da test verileri olarak kullanılmıştır (Şekil.3.6).



Şekil 3.6. Verilerin değerlendirilme şekli

3.2.5. Verilerin İstatistiksel Analizi

Depolama günlerinin (1, 7, 14), yoğurt örneklerine (light, normal, ışık uygulanmış light, ışık uygulanmış normal) etkisi SAS istatistik programı kullanılarak parametrelerin ortalamaları ve standart sapmaları ile belirlenmiştir. Gruplara göre verilen parametrik değerler, ortalama \pm standart sapma ANOVA analizi yapılarak gösterilmiştir. Anlamlı bulunan grupların anlamlılık düzeyleri Duncan düzeltmesi ile değerlendirilmiş ve istatistiki analizde anlamlılık düzeyi $p < 0.05$ olarak alınmıştır.

4. ARAŞTIRMA BULGULARI ve TARTIŞMA

4.1. Yoğurt Örneklerinin Kimyasal ve Mikrobiyolojik Sonuçları

Çalışmada ilk olarak, yoğurt örneklerinin laboratuvar ortamında görüntü analizinin yapıldığı 1. 7. ve 14. günlerinde pH tayini ve mikrobiyel analizleri yapılmıştır. pH analizlerinin sonuçları Çizelge 4.1.'de verilmiştir.

Çizelge 4.1. Yoğurt örneklerinin pH analizi sonuçları

Gün Sayısı	Yoğurt Örnekleri	pH
1. gün	Light 1	4,40
	Light 2	4,40
	Light 3	4,43
	Normal 1	4,12
	Normal 2	3,84
	Normal 3	3,78
7. gün	Light 1	4,18
	Light 2	4,16
	Light 3	4,15
	Normal 1	3,77
	Normal 2	3,74
	Normal 3	3,78
	Işıklı Light 1	4,07
	Işıklı Light 2	4,08
	Işıklı Light 3	4,14
	Işıklı Normal 1	3,75
	Işıklı Normal 2	3,71
	Işıklı Normal 3	3,75
14. gün	Light 1	4,29
	Light 2	4,30
	Light 3	4,28

	Normal 1	3,83
	Normal 2	3,86
	Normal 3	3,90
	Işıklı Light 1	4,15
	Işıklı Light 2	4,16
	Işıklı Light 3	4,18
	Işıklı Normal 1	3,79
	Işıklı Normal 2	3,78
	Işıklı Normal 3	3,82

Örneklerin pH değerlerinde light yoğurt ile normal yoğurt arasında farklılık görülmüştür. Çizelge 4.1'de görüldüğü gibi light yoğurtla yapılan çalışmada pH değeri 1. günde 4.40, 14 günde ise 4.29'düşmüştür. Aynı şekilde normal yoğurtta pH değeri 1.günde 4.12'den 14. günde 3.83'e düşmüştür. Depolama esnasında yoğurtta pH düşüşü beklenen bir durumdur. Akalın vd., (1998) nin yaptıkları çalışmalarında inkübasyon ve yoğurdun muhafazası sırasında örneklerin pH değerlerinin yoğurda işlenecek sütte yaklaşık 6.7' den, inkübasyonun 1 saatinde 6.1'e, 3. saatinde ise 4.8'e düştüğünü görülmüştür. Aynı çalışmada, yoğurtta titre edilebilir asitlik de beklendiği gibi sütün inkübasyonu ve yoğurdun muhafaza edilmesi sırasında % 0.40'dan başlayarak % 1.4'e kadar artış göstermiştir. On dört gün sonunda belirlenen pH ve titre edilebilir asitlik değerleri yoğurdun tüketilebilirlik sınırları içinde bulunmuştur. Bu yükselme bazı araştırmacılar tarafından da elde edilmiştir (BavilacQua ve Califano, 1989; Fernandez-Garcia ve Mcgregor, 1994).

Örneklerdeki yağ miktarı normal yağlı yoğurtta % 3.8 az yağlı light yoğurtta % 1 bulunmuştur. TS 1330 (1989)'a göre yoğurtlarda yağ miktarı tam yağlı yoğurtlarda en az % 3.8, az yağlı yoğurtlarda %1.5'dan az, yağlı yoğurtlarda ise en az %3 olması gerekmektedir. Buna göre incelenen örneklerdeki yağ miktarları TSE'ye uygun olduğu bulunmuştur.

Çizelge 4.2. Yoğurt örneklerinin mikrobiyel analiz sonuçları

Gün Sayısı	Yoğurt Örnekleri	Toplam Aerobik Mezofilik Bakteri (kob/g)	Maya-Küf (kob/g)	Koliform Bakteri (kob/g)
1. gün	Light 1	2.60×10^4	2.60×10^3	3.40×10^4
	Light 2	3.15×10^4	2.05×10^3	3.50×10^3
	Light 3	2.65×10^4	1.45×10^3	2.25×10^3
	Normal 1	4.50×10^2	1.50×10^3	1.25×10^1
	Normal 2	7.50×10^2	5.00×10^3	0.85×10^1
	Normal 3	5.00×10^2	5.00×10^3	1.30×10^1
7. gün	Light 1	6.50×10^4	6.00×10^3	1.00×10^5
	Light 2	1.70×10^5	4.00×10^3	1.50×10^5
	Light 3	1.25×10^5	5.00×10^4	3.00×10^5
	Normal 1	1.00×10^2	<1	<1
	Normal 2	1.50×10^2	<1	<1
	Normal 3	3.00×10^2	<1	<1
	İşıklı Light 1	3.80×10^5	1.50×10^3	1.00×10^5
	İşıklı Light 2	2.70×10^5	1.00×10^3	1.00×10^5
	İşıklı Light 3	3.20×10^5	2.00×10^3	3.00×10^5
	İşıklı Normal 1	<1	<1	<1
	İşıklı Normal 2	5.00×10^3	<1	<1
	İşıklı Normal 3	3.00×10^2	<1	<1
14. gün	Light 1	4.30×10^6	5.90×10^5	<1
	Light 2	1.20×10^6	3.90×10^5	<1
	Light 3	1.00×10^5	3.40×10^5	<1
	Normal 1	<1	<1	<1
	Normal 2	<1	<1	<1
	Normal 3	<1	<1	<1
	İşıklı Light 1	1.40×10^6	<1	3.40×10^5
	İşıklı Light 2	3.50×10^5	<1	4.50×10^5
	İşıklı Light 3	8.00×10^5	<1	2.95×10^5
	İşıklı Normal 1	<1	<1	<1
	İşıklı Normal 2	<1	<1	<1
	İşıklı Normal 3	<1	<1	<1

Yoğurt örneklerindeki mikrobiyolojik değişiklikler çizelge 4.2.'de gösterilmiştir. İncelenen light yoğurtta; toplam aerobik mezofilik bakteri miktarı 1. gün ile 7. gün arasında istatikselsel olarak önemli bir değişim göstermemesine rağmen (2.60×10^4 kob/g'den 6.50×10^4 kob/g) 14. günde mikroorganizma miktarı 4.30×10^6 kob/g'ye yükselmiştir. Benzer şekilde Atasoy vd., (2003) Şanlıurfa piyasasında satışa sunulan yoğurtlarda yaptıkları araştırmada en düşük, en yüksek ve ortalama toplam aerobik mezofilik bakteri (TAMB) sayılarını sırasıyla 5.50×10^5 kob/g, 2.40×10^7 kob/g,

5.33×10^6 kob/g bulmuşlardır. Maya-küf analizinde benzer şekilde 1. ve 7. günler arasında farklılık yokken 14. günde maya küf miktarı 2.60×10^3 kob/g'den 5.90×10^5 kob/g artış gözlenmiştir. Yapılan birçok çalışmada; yoğurdun asitlik düzeyinin, istenmeyen bakterilerin gelişmesini sınırlandırmasına karşın, maya ve küflerin nispeten yüksek asitlikte gelişebileceğini ve yoğurdun bozulmasında önemli rol oynadığı belirtilmiştir (Koçhisarlı ve Ergül, 1987; Akyüz ve Coşkun, 1990; Şahan vd., 1998a; Dayısoylu vd., 1998; Kırdar ve Gün, 2002; Atasoy vd., 2003). Koliform bakteri analizinde, 1. günden 7. güne (3.40×10^4 kob/g den 1.00×10^5 kob/g) bir artış gözlenmiştir. Işık uygulanmış light yoğurtta ışıksız ortamda depolanan light yoğurtta benzer şekilde istatistiksel olarak önemli bir artış gözlenmiş, toplam mikroorganizma değeri 1. günde 2.60×10^4 kob/g, 7. günde 3.80×10^5 kob/g, ve 14. günde 1.40×10^6 kob/g değerleri bulunmuştur. Koliform bakteri analizinde ise, 1. günde 3.40×10^4 kob/g, 7. günde 1.00×10^5 kob/g, 14. günde 3.40×10^5 kob/g olarak günlere bağlı olarak bir artış gözlenmiştir. Koçhisarlı ve Ergül (1987), Akyüz ve Coşkun (1990), Tayar vd., (1993) ve Şahan vd., (1998a) yaptıkları araştırmalarda tüketime sunulan yoğurtların benzer şekilde koliform grubu bakteri sayılarının 2.1×10^2 kob/g ile 4.2×10^6 kob/g arasında değiştiğini, ortalama değerinin ise 5.5×10^5 kob/g olduğunu saptamışlar ve bu yoğurtların koliform grubu bakteri içeriği bakımından tüketilmesinin sağlık için zararlı olabileceğini bildirmişlerdir.

Mikrobiyel gelişmenin light yoğurtta daha çok olduğu görülmüştür. Mikrobiyolojik analizlerde normal yoğurt TSE standartlarına uygun bir şekilde bulunmuştur. Light yoğurtta, *E. coli* varlığı tespit edilmemesine rağmen koliform miktarı 10'un üstünde belirlenmiş ve standarda uygunluk göstermemiştir. Yoğurt standardına (TS 1330) göre yoğurdun bir gramında 10'dan çok koliform bakteri, 100'den çok maya ve küf olmamalı, *E. coli* ise bulunmamalıdır (Anonim, 1989). Yoğurda işlenecek süte ısı işlem uygulanması ve yoğurtta yüksek asitlik nedeniyle koliform grubu bakteri bulunma olasılığı diğer süt ürünlerine göre daha düşüktür. Yoğurt örneklerinde koliform mikroorganizma bulunması, gerekli hijyen önlemleri alınmadan üretim yapıldığını veya pazarlama/depolama sırasında kontaminasyon olduğunu göstermektedir. Bu durum, üretim ve pazarlama sırasında hijyen kurallarına dikkat

edildiğinde koliform açısından standartlara uygun ürün elde etmenin mümkün olduğunu göstermesi bakımından önemlidir.

Bununla birlikte, ürünün ambalaj ve paketlenme, depolama ortamı ve ürün standartlarının herhangi birisinin TSE'ye uygun olmaması durumunda söz konusu olduğu düşünülmektedir. Mikrobiyolojik sonuçlar bu süreçteki standartlara uygunluk göstermekle birlikte yeni Gıda Kanunu paralelinde bu yıl içinde çıkacak yeni tüzüğe AB'ye uyum paralelinde gıda güvenliği açısından koliform bakteri varlığına izin verilmeyeceğini düşünülmektedir.

Çizelge 4.3. Yoğurt örneklerinin depolama günlerine göre istatistiksel olarak değerlendirilmesi

Gün Sayısı	Yoğurt Örnekleri	Top.Mez.Bak. log(kob/g)		Maya-Küf log(kob/g)		Koliform Bak. log(kob/g)		pH	
		Ort.	SD.	Ort.	SD.	Ort.	SD.	Ort.	SD.
1	Light	3.43±0.07 ^a		3.45±0.45 ^a		2.58±2.11 ^a		4.41±0.01 ^a	
	Normal	1.72±0.16 ^b		1.07±1.19 ^b		1.26±1.01 ^b		3.91±0.16 ^b	
	Işıklı Light	3.43±0.07 ^a		3.45±0.45 ^a		2.58±2.11 ^a		4.41±0.01 ^a	
	Işıklı Normal	1.72±0.16 ^b		1.07±1.19 ^b		1.26±1.01 ^b		3.91±0.16 ^b	
7	Light	5.04±0.19 ^c		2.96±1.47 ^c		5.20±0.24 ^c		4.16±0.01 ^c	
	Normal	1.95±0.99 ^d		0.00±0.00		0.00±0.00		3.76±0.01 ^b	
	Işıklı Light	5.48±0.15 ^e		2.65±1.32 ^c		2.93±2.44 ^a		4.09±0.03 ^e	
	Işıklı Normal	1.15±1.27 ^d		-		-		3.73±0.02 ^d	
14	Light	5.12±2.55 ^a		5.63±0.11 ^d		-		4.29±0.00 ^c	
	Normal	-		-		-		3.86±0.03 ^b	
	Işıklı Light	5.85±0.28 ^a		5.54±0.11 ^e		2.98±2.48 ^a		4.16±0.01 ^c	
	Işıklı Normal	-		-		-		3.79±0.01 ^d	


^{abcde}: Aynı sütundaki ortalamaların farklı üst indisleri aralarındaki istatistiksel önemli farklılığı göstermektedir. Çalışma 3 tekerrürlü 2 paralellidir (P < 0,05).

-: Veri yoktur.


4.2. Bilgisayarlı Görüntüleme Sistemi Kullanılarak Veri Elde Edilmesi

4.2.1. Görüntülerin Elde Edilmesi


Yoğurt örneklerinin 1., 7., ve 14. günde digital kamera kullanılarak BGS'de alınan görüntüleri Şekil 4.1, 4.2, 4.3, 4.4, 4.5, 4.6, 4.7, 4.8, 4.9, 4.10'da gösterilmiştir.




Şekil 4.1. Birinci (1) gün normal yoğurt




Şekil 4.2. Yedinci (7) gün normal yoğurt




Şekil 4.3. Ondördüncü (14) gün normal yoğurt




Şekil 4.4. Birinci (1) gün light yoğurt




Şekil 4.5. Yedinci (7) gün light yoğurt




Şekil 4.6. Ondördüncü (14) gün light yoğurt




Şekil 4.7. Yedinci (7) gün ışık uygulanmış normal yoğurt



Şekil 4.8. Ondördüncü (14) gün ışık uygulanmış normal yoğurt



Şekil 4.9. Yedinci (7) gün ışık uygulanmış light yoğurt



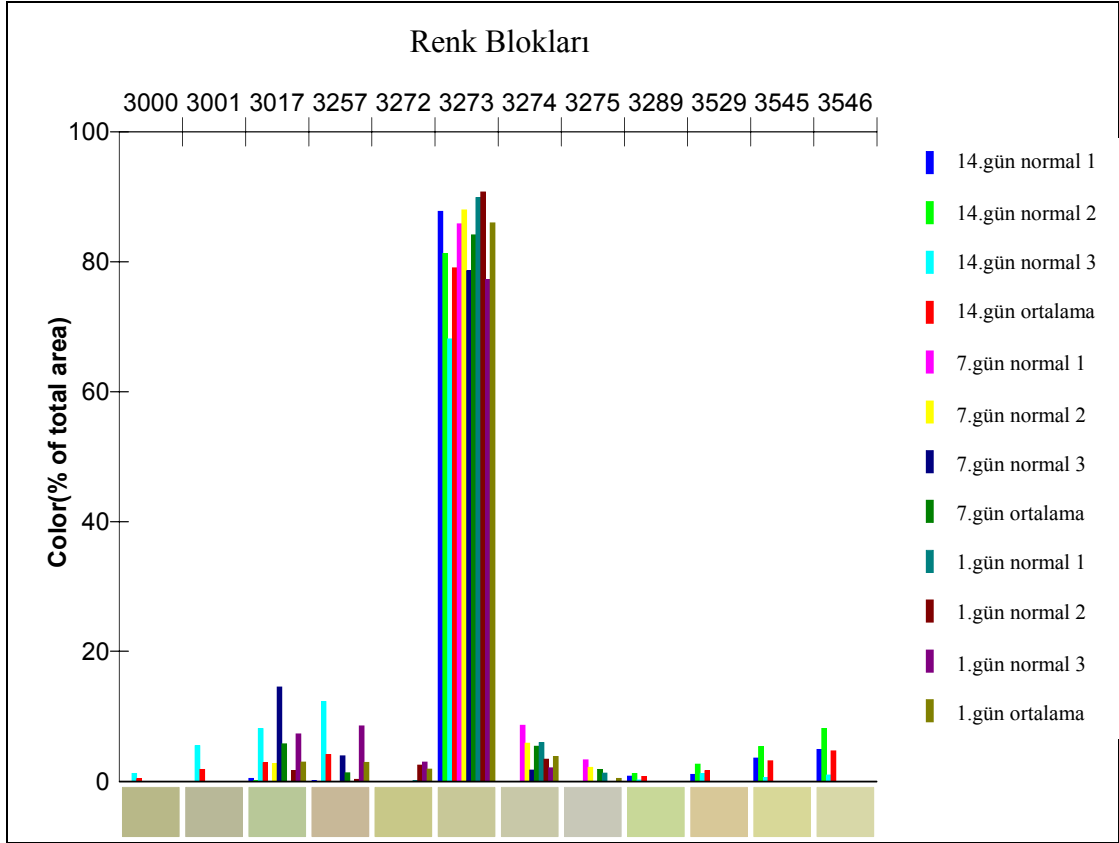
Şekil 4.10. Ondördüncü (14) gün ışık uygulanmış light yoğurt

4.2.2. Görüntü histogramları:

Işıklı ve ışısız ortamda buzdolabı sıcaklığında (4-7 °C) depolanan yoğurt örneklerinde depolama sırasında meydana gelen renk değışiklikleri incelenmiştir. Depolama sırasında yapılan çekimlerde normal yoğurtların analizinde kullanılan 4096 renk blok verisinden, 1. gün için normal yoğurtta 6 renk verisi, 7. gün için 4 renk blok verisi ve 14. gün için 12 renk blok verisi alınmıştır. Light yoğurtta 2 renk verisi 1. gün, 2 renk blok verisi 7. gün ve 9 renk blok verisi ise 14. gün için alınmıştır. Işıklı normal yoğurtta, 2 renk blok verisi 7. gün ve 11 renk blok verisi ise 14. gün için alınmıştır. Işıklı light yoğurtta 2 renk blok verisi 7. gün ve 12 renk blok verisi ise 14. gün için alınmıştır. Farklı ışık ortamında depolanan yoğurt örneklerinin renk analizleri toplam alanlarının %1'inden daha yüksek seviyede elde edilmiştir. Elde edilen renk blokları Çizelge 4.4'de verilmiştir. Yoğurtların normal, light, ışıklı ve ışısız uygulamalarından elde edilen renk profilleri histogramlarda gösterilmiştir (Şekil 4.11, 4.13, 4.15, 4.17). Renk profilleri birbirinden farklı görülmesine rağmen, blok numarası 3273 bütün uygulamalarda en çok yüzdeyi içeren renk olmuştur.


Çizelge 4.4 Yoğurt örneklerinden elde edilen renk blokları

Blok No	R	G	B	L	a	b	NBS isim	NBS blok no	renk	Doygunluk	Kontrast	Parlaklık
2727	168	168	120	64.79	-8.3	26.92	Açık sarımsı gri	106		60	0.4	0.25
3000	184	184	136	71.24	-8.32	26.54	Grimsi yeşilimsi sarı	105		60	0.36	0.33
3001	184	184	152	71.57	-5.87	17.73	Grimsi sarı yeşil	122		60	0.23	0.36
3016	184	200	136	75.99	-	17.27	Orta sarı yeşil	120		78.25	0.45	0.38
3017	184	200	152	76.28	-	14.91	Orta sarı yeşil	120		82.74	0.33	0.41
3256	200	184	136	72.7	-1.41	28.75	Grimsi sarı	90		41.75	0.45	0.38
3257	200	184	152	73.02	0.82	19.97	Grimsi sarı	90		37.26	0.33	0.41
3272	200	200	136	77.31	-	10.49	Grimsi yeşilimsi sarı	105		60	0.45	0.38
3273	200	200	152	77.59	-8.32	26.2	Grimsi yeşilimsi sarı	105		60	0.33	0.41
3274	200	200	168	77.93	-5.84	17.49	Açık sarı gri	121		60	0.21	0.45
3275	200	200	184	78.31	-3.07	8.74	Yeşilimsi gri	93		60	0.1	0.49
3289	200	216	152	82.27	-	17.18	Açık sarı yeşil	119		77.96	0.41	0.47
3529	216	200	152	79.03	-1.56	28.38	Grimsi sarı	90		42.04	0.41	0.47
3530	216	200	168	79.36	0.72	19.69	Grimsi sarı	90		37.49	0.31	0.51
3545	216	216	152	83.57	-	10.53	Soluk yeşilimsi sarı	104		60	0.41	0.47
3546	216	216	168	83.87	-8.31	25.88	Soluk yeşilimsi sarı	104		60	0.31	0.51
3547	216	216	184	84.21	-5.81	17.27	Soluk sarı yeşil	121		60	0.24	0.55



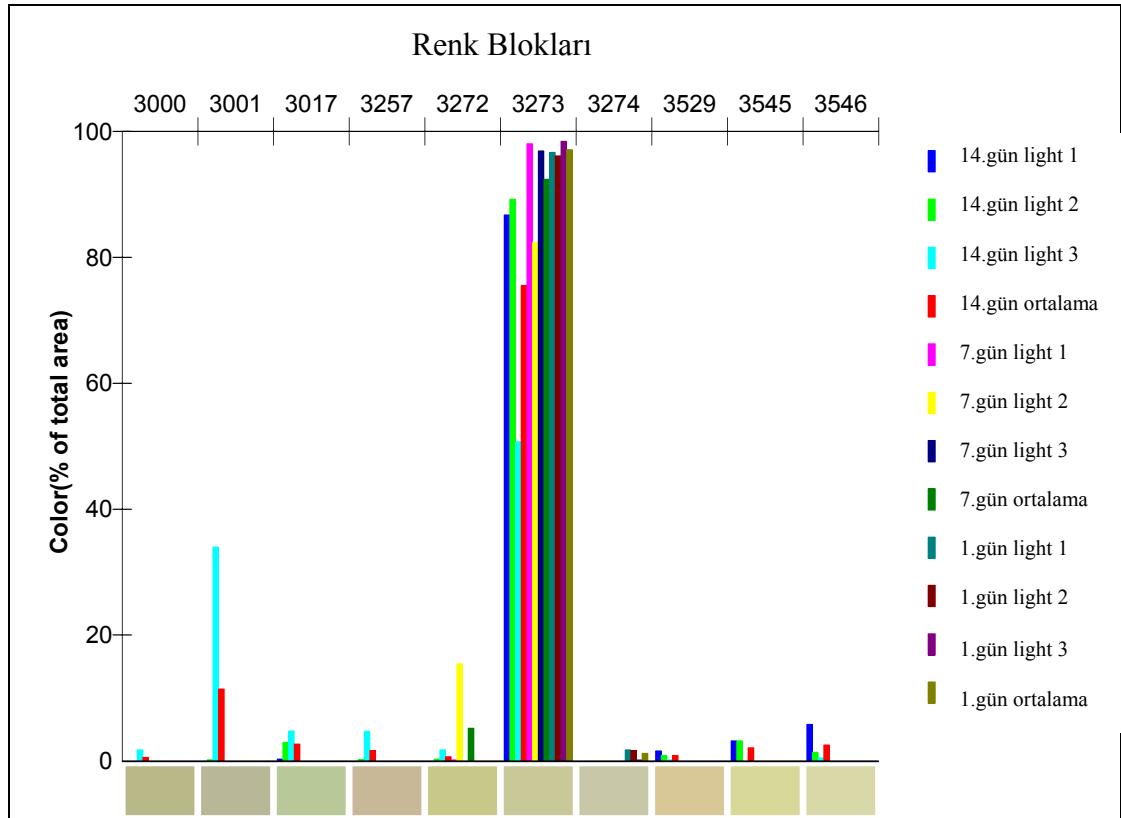
Şekil 4.11. Normal yoğurt renk histogramı

Normal yoğurta depolama başlangıcında en yüksek yüzdeli renk bloğu 3273 (R: 200, G: 200, B:152 değerleri toplam örnek alanının %80'nini içermektedir) olmasına rağmen, depolama sonunda 3257 (R: 200, G: 184, B:152 değerleri toplam örnek alanının %15'ini içermektedir), 3546 (R: 216, G: 216, B:168 değerleri toplam örnek alanının %14'ünü içermektedir) nolu renklerde artış, 3017 (R: 184, G: 200, B:152 değerleri toplam örnek alanın % 17'sini içermektedir.) nolu renkte ise azalış gözlenmiştir.




Şekil 4.12. Normal yoğurtlarda önemli renk bloklarının % toplam alandaki 1., 7. ve 14. günlerdeki değişimleri

Şekil 4.12’de görüldüğü gibi önemli renk bloklarının % toplam alandaki değerleri 1., 7. ve 14. günler de farklılık göstermektedir. Bu numaralar soluk yeşilimsi-sarı, açık-yeşil-sarı, grimsi-sarı ya da açık-grimsi-yeşil gibi renkleri temsil etmektedir; sarı-yeşil renginde azalma grimsi-sarı ve yeşildeki artış bozulma başlangıcının da göstergesi olmuştur.




Şekil 4.13. Light yoğurt renk histogramı

Normal yoğurtta olduğu gibi light yoğurtta da depolama başlangıcında en yüksek yüzdeli renk bloğu 3273 (R: 200, G: 200, B:152 değerleri toplam örnek alanının %80'nini içermektedir) olmuştur. Depolama sonlarına gelindiğinde ise 3001 (R: 184, G: 184, B:152 değerleri toplam örnek alanının %35'ini içermektedir), 3272 (R: 200, G: 200, B:136 değerleri toplam örnek alanının %17'sini içermektedir) ve 3000 (R: 184, G: 184, B:136 değerleri toplam örnek alanının %15'nini içermektedir) nolu renklerin artışı gözlenmiştir.




Şekil 4.14. Light yoğurtlarda önemli renk bloklarının % toplam alandaki 1., 7. ve 14. günlerdeki değişimleri

Şekil 4.14'da görüldüğü gibi önemli renk bloklarının % toplam alandaki değerleri 1., 7. ve 14. günlerde farklılık göstermektedir. Bu numaralar soluk-yeşilimsi-sarı, açık-yeşil-sarı, grimsi-sarı ya da açık-grimsi-yeşil gibi renkleri temsil etmektedir; sarı-yeşil renginde azalma grimsi-sarı ve yeşildeki artış normal yoğurda benzer şekilde bozulma başlangıcının da göstergesidir.




Şekil 4.15. Işıklı normal yoğurt renk histogramı

Normal ve light yoğurtlarda olduğu gibi floresans ışık altında depolanan normal yoğurtta depolama başlangıcında en yüksek yüzdeli renk bloğu 3273 (R: 200, G: 200, B:152 değerleri toplam örnek alanının %80'ini içermektedir) olmasına rağmen depolama sonlarında ise 3001 (R: 184, G: 184, B:152 değerleri toplam örnek alanının %19'unu içermektedir) nolu renklerin artışı, ve 3000 (R: 184, G: 184, B:136 değerleri toplam örnek alanının %17'sini içermektedir) 3257 (R: 200, G:184, B:152 değerleri toplam örnek alanının %10'unu içermektedir) 3546 (R: 216, G:216, B:168 değerleri toplam örnek alanının %17'sini içermektedir) nolu renklerin artışı gözlenmiştir.




Şekil 4.16. Işıklı normal yoğurtlarda önemli renk bloklarının % toplam alandaki 1., 7. ve 14. günlerdeki değişimleri

Şekil 4.16'da görüldüğü gibi önemli renk bloklarının % toplam alandaki değerleri 1., 7. ve 14. günlerde farklılık göstermektedir. Bu numaralar gri-yeşil-sarı, grimsi-sarı ya da grimsi-yeşil gibi renkleri temsil etmekte grimsi-sarı ve soluk-yeşilimsi-sarı renklerdeki artış ise ışık uygulanmamış normal yoğurtta olduğu gibi bozulma başlangıcının göstergesi olmuştur.



Şekil 4.17. Işıklı light yoğurt renk histogramı

Floresans ışık altında depolanan light yoğurtta depolama başlangıcında en yüksek yüzdeli renk bloğu 3273 (R: 200, G: 200, B:152 değerleri toplam örnek alanının %80'nini içermektedir) olmasına rağmen, depolama sonlarında ise 3546 (R: 216, G: 216, B:218 değerleri toplam örnek alanının %20'nini içermektedir), 3274 (R: 200, G: 200, B:168 değerleri toplam örnek alanının %17'sini içermektedir) ve 3000 (R: 184, G: 184, B:136 değerleri toplam örnek alanının %15'nini içermektedir) nolu renklerin artışı gözlenmiştir.



Şekil 4.18. Işıklı light yoğurtlarda önemli renk bloklarının % toplam alandaki 1., 7. ve 14. günlerdeki değişimleri

Şekil 4.18’de görüldüğü gibi önemli renk bloklarının % toplam alandaki değerleri 1., 7. ve 14. günlerde farklılık göstermektedir. Bu numaralar soluk açık-sarı-gri, soluk yeşilimsi-sarı, grimsi-sarı ya da grimsi-yeşil gibi renkleri temsil etmekte, ışık uygulanmış normal yoğurtta olduğu gibi soluk yeşilimsi-sarı renkteki artış bozulma başlangıcının da göstergesidir.

Yoğurt örneklerinin depolama süresince renk analizinden $L^*a^*b^*$ değerleri de alınmıştır. Bütün uygulamalar için $L^*a^*b^*$ değerleri söz konusu olduğunda çok büyük bir değişim her biri için gözlenememesine rağmen yoğurt gibi çok renk içermeyen bir üründe L^* (lightness) değeri çok az bir azalma göstermiş, a^* (yeşil-kırmızı) değerinde ve b^* (mavi-sarı) değerinde birinci gün hariç yedinci ve ondördüncü günde az bir artışa rastlanmıştır.

Görüntü fotoğraflarının adobe photoshop programıyla arka fonları temizlenerek $L^*a^*b^*$ değerleri tesbit edildikten sonra color expert version 7.0.1 software programı kullanılarak görüntü sayısallaştırılmıştır. Son aşamada sayısal forma dönüştürülen görüntü artık bilgisayar ortamına aktarılarak işlenecek hale getirilmiştir. Bu işlem için görüntü sensörü ve bu sensörün üretmiş olduğu sinyalleri dijital forma dönüştürebilecek sistemlere ihtiyaç vardır (Kondo vd., 2000). Bu çalışmada bu sistemlerden yapay sinir ağları kullanılmıştır.

4.2.3. Geliştirilen Yapay Sinir Ağları Modelleri

Gıda raf ömrü tahmin modelleri çalışmalarında bulanık mantık (fuzzy logic), genetic algoritma (genetic algorithm) vb., birçok regresyon analiz metodu. denenmiş en iyi performans gösteren tahmin sonuçları genellikle YSA ile elde edilmiştir (Doganis vd., 2005). Bu çalışmada da, birbirine paralel yapıda olmayan renk analiz verileri, pH ve mikroorganizma sayısal değerleri arasındaki ilişkileri ve yoğurdun raf ömrüne olan etkilerini incelemek için çoklu verilerin regresyon analizlerinde kullanılan YSA kullanılmıştır.


En iyi yapay sinir ağı modeli determinasyon katsayısı (R^2) ve ortalama karesel hata (MSE) değerlerine göre belirlenmiştir. Determinasyon katsayısının 1'e ve ortalama karesel hatanın da 0'a yakınlığı raf ömrü gün sayısı tahmin modellerinin yeterliliğini göstermektedir. Gizli katmanda 1'den 20'ye kadar nöronlar denenerek çeşitli YSA modelleri geliştirilmiştir. Geliştirilen YSA modelinde 16 tane giriş parametresi olduğu için 20 tane nöron denenmiş, determinasyon katsayısının 1'e yakın olduğu en iyi sonuç ve 10000 iterasyonu tamamlayarak en iyi performansı elde eden modeller dikkate alınarak YSA modelleri geliştirilmiştir. Geliştirilen bu modellere ait determinasyon katsayıları ve ortalama karesel hata değerleri Çizelge 4.4'de verilmiştir.

Çizelge 4.5. Gizli tabakadaki nöron sayılarının korelasyon ve performans değerleri

GİZLİ TABAKADAKİ NÖRON SAYISI	MSE	R^2
1	2.58608	0,8928
2	3.26711	0,6633
3	2.83637	0,997
4	3.88688	0,8994
5	1.41049	0,999
6	1.19408	0,935
7	4.58721	0,8912
8	6.54816	0,9214


9	7.59667	0,6281
10	4.55557	0,8185
11	1.13805	0,8086
12	1.30613	0,9739
13	1.73334	0,8952
14	1.01199	0,992
15	1.63529	0,6819
16	3.75031	0,4629
17	1.09603	0,8422
18	1.63529	0,7877
19	1.83138	0,1869
20	1.15206	0,9569

Çizelge 4.5’de görüldüğü gibi gerçek değerlerle model sonucu ulaşılan değerler arasındaki korelasyon katsayısı 14 nöronlu için 0,992, 3 nöronlu için 0,997 ve 5 nöronlu için 0,999 bulunmuştur. 1’e en yakın sonuç gizli tabakada 5 nöron bulunan modelde elde edilmiştir. Bu nedenle raf ömrü süresi tahmininde bu model seçilmiştir. Seçilen modele ait ağ yapısı Şekil 4.19’de bulunmaktadır.



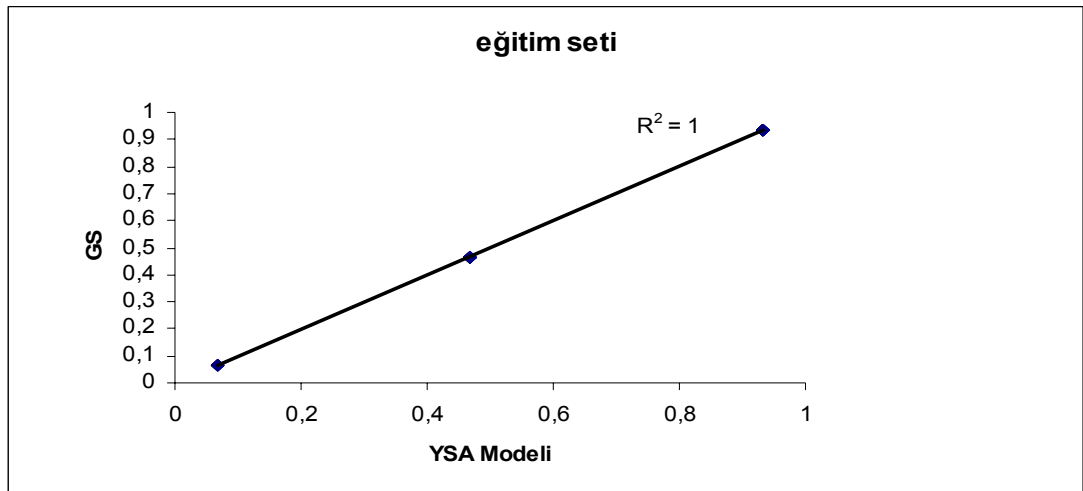
Şekil 4.19. Seçilen modele ait ağ yapısı

Seçilen model 10000 iterasyonun sonucunda 10^{-20} MSE performansına ulaşmış olup ortalama karesel hata değeri 0 değerine çok yaklaşmıştır. Bu modelin performansı Şekil 4.20’de gösterilmiştir. Modelin performansı tek gizli katmanda 1’e (0,9996) çok yakın sonuç verdiği için gizli katmanda ikinci tabaka denenmemiştir.




Şekil 4.20 Yapay Sinir Ağlarının Eğitim Performansı

Geliştirilen modelden elde edilen değerlerle gerçek değerler karşılaştırılarak regresyon ilişkisine bakıldığında eğitim setinin R^2 değerinin 1 olduğu görülmüştür (Şekil.4.21).




Şekil 4.21. Yapay Sinir Ağları Eğitim Seti ve Deneysel Sonuçların Karşılaştırılması
Gün Sayısı (GS)

Yapay sinir ağırları oluşturulan modeller hakkında verilen grafikler bu modellerin doğruluğunu göstermektedir. Geliştirilen modelden elde edilen değerlerle gerçek değerler karşılaştırılarak regresyon ilişkisine bakıldığında test setinin $R^2 = 0,9996$ olduğu görülmüştür(Şekil 4.22)



Şekil 4.22. Yapay Sinir Ağları Test Seti ve Deneysel Sonuçların Karşılaştırılması
Gün Sayısı (GS)



Şekil 4.23. Yapay Sinir Ağları Modeli ile Test Seti ve Deneysel Sonuçlarının zaman serisi. Gün Sayısı (GS)

Şekil 4.23'de YSA modelinden elde edilen değerlerle gerçek verilerin zaman serisi bulunmaktadır. Şekil 4. 23'den de görüldüğü gibi gerçek ve model tahmini bir nokta hariç tüm noktalarda örtüşmekte; sapma ve hatanın çok az olduğu görülmektedir.

Takahashi vd., (1998) kimyasal analizlerle elde ettikleri verilerle yoğurtlarda tat-lezzet tahmini için YSA ile model geliştirmişlerdir. Duyusal analize ihtiyaç duymadan geliştirdikleri modelde bu çalışmadaki gibi yüksek performans gerçekleşmiştir. YSA'nın yoğurtlarda tat-lezzet tahmini için YSA'nın kullanılabilirliğini göstermişlerdir.

Gerçekleştirilen YSA modelinin ileriki çalışmalarda yoğurt raf ömrü tahmin çalışmalarına temel oluşturması amacıyla modelin formülasyonu aşağıda verilmiştir. Burada $E1-6$ toplam fonksiyonunu ve $F1-5$ ve G denklemleri aktivasyon fonksiyonlarını göstermektedir. Aynı zamanda G gün sayısı çıktı değeridir.

$$E1=(pH*0,0617659) + (tm *2,8447) + (m-k*-3,3153)+(kb*0,266086) + (r1*-6,5044) + (r2*-2,7020) + (r3*0,2297) + (r4*0,2047) + (r5 * 0,0358) + (r6* -0,001795) + (r7*-0,0189) + (r8* -0,017515) + (r9* 0,68225) + (r10*-0,1956) + (r11*-0,7215) + (r12 *4,1088) -1,2609e-005 \quad (4,2)$$

$$F1 = \frac{1}{1 + e^{-E1}} \quad (4,3)$$

$$E2= E1=(pH*0,125175) + (tm *1,3841) + (m-k*-25,3261)+(kb *-2,096573) + (r1*-5,6961) + (r2*2,6693) + (r3*0,995) + (r4*0,6039) + (r5 *-0,04908) + (r6* -0,05308) + (r7*-0,0488) + (r8* -1,6521) + (r9* -6,0447) + (r10*-0,267) + (r11*-1,7577) + (r12 *-8,02148) 3,3044 \quad (4,4)$$

$$F2 = \frac{1}{1 + e^{-E2}} \quad (4,5)$$

$$E3=(pH*-10,9863) + (tm * -4,8707) + (m-k*2,5082)+(kb*0,0922) + (r1*-10,3972) + (r2*-2,7132) + (r3*-4,08124) + (r4*-0,6766) + (r5 * -0,7825) + (r6* -0,2004) + (r7*-0,3464) + (r8* 0,5861) + (r9* 18,9605) + (r10*13,5945) + (r11*1,0864) + (r12 *-15,69526) -2,5068 \quad (4,6)$$

$$F3 = \frac{1}{1 + e^{-E3}} \quad (4,7)$$

$$E4= E1=(pH*-0,017812045) + (tm *0,13228) + (m-k*-3,371)+(kb *-0,10783) + (r1*-8,6644) + (r2*-2,4376) + (r3*-0,11898) + (r4*-0,04318) + (r5*-0,0820) + (r6* -0,05122) + (r7*0,00975) + (r8* -0,14686) + (r9* 7,0256) + (r10*5,03388) + (r11*0,4698) + (r12*7,18328) 7,0396 \quad (4,8)$$

$$F4 = \frac{1}{1 + e^{-E4}} \quad (4,9)$$

$$E5=(pH*0,31354318) + (tm*30,0183) + (m-k*7,1545)+(kb*1,977713) + (r1*2,6794) + (r2*--3,3225) + (r3* 0,13549) + (r4*-0,0083) + (r5 * 0,5969) + (r6* 0,12248) + (r7*0,73401) + (r8* 0,7373) + (r9* -4,5281) + (r10*-1,49695) + (r11*1,2050) + (r12 *13,03948) 2,7726 \quad (4,10)$$

$$F5=\frac{1}{1+e^{-E5}} \quad (4,11)$$

$$E6=(F1*14,4456)+ (F2*-69,2291) + (F3*-16,3589) + (F4*-27,2027) + (F5*-30,7632) -0,13352 \quad (4,12)$$

$$Gün Sayısı (G)/15=\frac{1}{1+e^{-E6}} \quad (4,13)$$

Sonuç olarak YSA modelinin mevcut metotlara göre daha az parametreye ihtiyaç duyması, hesaplama süresinin az olması ve gün sayısı değerleri için oldukça iyi performans göstermesinden dolayı raf ömrü gün sayısı hesaplarında kullanılabilirliği görülmüştür.

5. SONUÇ

Yoğurdun raf ömrü içinde bulunduğu çevre şartlarına bağlı olarak değişir. Uygun olmayan şartlar yoğurdun renginde, tadında, besin değerinde kabul edilemez kayıplara ve yapısında değişikliklere neden olur. Yoğurt ambalajı üzerindeki son kullanma tarihi, gıdanın 4 °C veya 2 °C sıcaklıklarında saklanacağı dikkate alınarak yazılmaktadır. Eğer sıcaklık 10 °C ise, bu ürünlerin muhafaza edilebilirliği 4 kez azalır. Bu nedenle yoğurt bu sıcaklık koşullarında tutulmamışsa, son kullanım tarihinin bir önemi kalmayabilir. Bazen yoğurt paketten çıkarıldığında küflenmiş olabilir ancak gözle görülemez. Zaman içinde küf gelişimi görünür hale gelir.

Bu nedenle çalışmada, yukarıda belirtilen hususlar göz önüne alınarak; raftan alınan yoğurt örneklerinin etiketinde belirtilen gün sayısını kontrol edebilmek amacıyla bilgisayarlı görüntüleme sistemi kullanılarak elde edilen renk analiz sonuçları ile oluşturulan YSA modeli formülize edilmiştir.

Çalışmada ilk olarak, yoğurt örneklerinin kalite kontrol analizleri doğrultusunda laboratuvar ortamında 1. 7. ve 14. günlerinde pH tayini ve mikrobiyel analizleri yapılmış ve kimyasal ve mikrobiyolojik sonuçları belirlenmiştir. Eş zamanlı olarak görüntü analizi de yapılarak BGS ile görüntüler elde edilmiş ve görüntüler bilgisayara aktarılarak renk analizi yapılmıştır. Renk analizinden alınan % renk değişimleri her uygulama (normal, light, ışıklı normal, ışıklı light) için depolama süresince başarıyla monitörlenmiş, bozulma en çok ışıklı light örneğinde gözlenmiştir. Bütün uygulamalar için $L^*a^*b^*$ değerleri söz konusu olduğunda çok büyük bir değişim her biri için gözlenmemesine rağmen yoğurt gibi çok renk içermeyen bir üründe a^* (yeşil-kırmızı) değerinde ve b^* (mavi-sarı) değerinde birinci gün hariç yedinci ve ondördüncü günde az bir artışa rastlanmıştır. Renk analizi ile görüntünün sayısallaştırılması sonucu elde edilen veriler yapay sinir ağları ile modellenerek raf ömrü süresi tahmin modeli başarıyla oluşturulmuştur.

Bu çalışmada raf ömrü tespit çalışmalarına yeni bir teknik kazandırılması amaçlanarak, kullanımı kolay, laboratuvarda yürütülebilecek görüntü analizi programı kullanılmıştır. Bu sayede; pratik ölçüm teknikleri sağlama, görüntü yönetimi,

otomatik analiz, ve hızlı ve detaylı sonuç raporlarının eldesi gibi büyük-ölçekli kontrol uygulamaları elde edilmiştir. Bu yöntem gıdaların kalite değerlendirmelerinde sonuçlara olan güvenilirliği arttırmasının yanında maliyeti ve deneylerde harcanan zamanda azaltmaktadır.

Mevcut yöntemlere göre alternatif olarak YSA kullanılarak geliştirilen raf ömrü süresi modelinin, daha az parametreye gereksinim duyması, hesaplama süresinin az olması ve gün sayısı değerleri için oldukça iyi performans göstermesinden dolayı yoğurt raf ömrü süresinin hesaplanmasında kullanılabilirliği görülmüştür.

Çalışmanın literatürde bir veri tabanı oluşturması, hem üretici firmanın ürün kalitesini geliştirmesine katkısı, hem de tüketicinin güvenli besin tüketmesini sağlaması açısından üretici ve tüketiciye olumlu bir katkısı olacaktır.

İleride daha geniş bir veri tabanı ile süt ve süt ürünleri ya da diğer gıda alanlarında bu çalışmanın devamı önerilebilir,

6. KAYNAKLAR

Anonim, 1989, Yoğurt TS 1330, Türk Standartları Enstitüsü, Ankara.

Anonymous, 1990, Süt ve mamülleri analiz yöntemleri, Türkiye Süt Endüstrisi Genel Müdürlüğü, Ankara.

Anonim, 2001, Türk Gıda Kodeksi Fermente Sütler Tebliği, Tebliğ No: 2001/21 Türk Gıda Kodeksi, Resmi Gazete 03,09,2001 sayı 24512.

Abdullah, Z. M., Aziz, A. S., and Dos-Mohamed, A. M., 2000, Quality inspection of bakery products using a colour-based machine vision system, *Journal of Food Quality*, 23(1), 39–50.

Akalın, S., Kınık, Ö., ve Gönç S., 1998, Yoğurt üretimi ve Depolama Sırasında Organik Asitlerin Belirlenmesi, *Gıda Dergisi*, 23, 1 59-65.

Aktan, S., 2004b, Determining storage related egg quality changes via digital image analysis, *South African J. of Anim. Sci*, 34 (2), 70-74.

Aktan, S., 2004c, Sayısal görüntü analizi yardımıyla taze ve depolanmış yumurtalarda kalite özelliklerinin belirlenmesi, *Tavukçuluk Araştırma Dergisi*, 5 (2).

Aktan, S., 2004d, Bildircim yumurtalarında bazı iç ve dış kalite özellikleri ile aralarındaki ilişkilerin sayısal görüntü analizi ile belirlenmesi, *Hayvansal Üretim*.

Akyüz N. ve Coşkun, H., 1990, Van piyasasında satışa sunulan yoğurtların kimyasal, hijyenik ve mikrobiyolojik özellikleri ve bunların standartlara uygunluğu üzerine bir araştırma. *Yüzüncü Yıl Ü. Ziraat Fak. Dergisi*, 1(1), 71-79.

Al-Kadamanya, E., Khattarb, M., Haddadc, T., and Toufeili, I., 2003, Estimation of shelf-life of concentrated yogurt by monitoring selected microbiological

and physicochemical changes during storage, *Lebensm.-Wiss, U,-Technol*, 36 407–414.

Atamer, M., Sezgin, E., ve Yetişmeyen, A., 1988, Torba yoğurtlarının bazı niteliklerinin araştırılması, *Gıda Dergisi*, 13, 4 283-288.

Atasoy F. A., Türkoğlu H., ve Özer B. H., 2003, Şanlıurfa ilinde üretilen ve satışa sunulan süt, yoğurt ve urfa peynirlerinin bazı mikrobiyolojik özellikleri. *Harran Üniversitesi Ziraat Fakültesi Dergisi*, 7 (3-4):77-83.

Barni, M., Cappellini, V., and Mecocci, A., 1997, Colour-based detection of defects on chicken meat, *Image and Vision Computing*, 15: 549-556.

Barrantes, E., Tamime A. Y., D., Muir D., and Sword, A. M. 1994, The effect of substitution of fat by microparticulate whey protein on the quality of set-type natural yogurt, *J, Soc, Dairy Technol.*, 47:61–68.

Basset, O., Buquet, B., Abouelkaram, S., Delachartre, P., and Culioli, J., 2000, Application of texture image analysis for the classification of bovine meat, *Food Chemistry*, 69: 437-445.

Batchelor, M. and Searcy, S.W., 1989, Computer vision determination of stem/root joint on processing carrots, *Journal of Agricultural Engineering Research*, 43, 259–269.

Baxes, G.A., 1994, *Digital image processing, principles and applications*, 452 s, John Wiley & Sons, Inc., USA.

Be'al, C., Louvet P., and Corrieu G., 1989, Influence of controlled pH and temperature on the growth and acidification of pure cultures of *Streptococcus thermophilus* 404 and *Lactobacillus bulgaricus* 398, *Appl, Microbiol, Biotechnol*, 32:148–154.

Bertelsen, E., 1964, Incubation of milk and how it can be achieved good yoghurt, International Dairy Federation Bull., 3, 1-145 p.

Bevilacqua, A. E. and Califano, A. N., 1989, Determination of organic acids in dairy products by high performance liquid chromatography, J, Food Sci, 54(4) 1076-1079.

Bourne, M. C., 1982, Food texture and viscosity: Concept and measurement, (pp, 44–106), New York: Academic Press.

Cardarelli, A. J., Tao, Y., Bernhardt, J., L., and Lee, F. N., 1999, Nondestructive quantification of internal damage in rough rice caused by an insect and fungi, Research Series of Arkansas Agricultural Experiment Station, No, 468 (pp, 324–329).

Castelman, R. K., 1996, Digital image processing, Prentice hall, Englewood Cliffs, New Jersey, USA.

Çağlar, A., Çakmakçı, S., 1999, Yoğurdun insan sağlığı ve beslenmesindeki rolü ve önemi, III Milli Süt ve Süt Ürünleri Sempozyumu, Yoğurt, Milli Prodükktivite Merkezi Yayınları No: 548, Ankara, 205-220s.

Chao, K., Mehl, P.M., and Chen, Y.R., 2002, Use of hyperand multi-spectral imaging for detection of chicken skin tumors, Applied Engineering in Agriculture, ASAE, 18(1): 113-119.

Daley, W.D.R. and Babbitt, S.S., 1991, Machine vision: quality control by computer, Misset World Poultry, 7(4): 20-21.

Dayısoylu, K.S., Bakırcı, İ. ve Akyüz, N., 1998, Van piyasasında üretilen ve satışı sunulan yoğurtların çeşitli nitelikleri üzerine bir araştırma. Gıda Mühendisliği Kongresi, 16-18 Eylül, Gaziantep, 327-336.

- Davidson, V. J., Ryks, J., and Chu, T., 2001, Fuzzy models to predict consumer ratings for biscuits based on digital features, *IEEE Transactions on Fuzzy Systems*, 9(1), 62–67.
- Demir, N., Erdogdu, F. and Balaban, M.O., 2000, Machine Vision Quantification of Enzymatic Browning in Banana Slices Treated with Different Solutions, In *Proc'of IFT Annual Meeting Abstract Book*, P 63, 10th-14rd June.
- Demir, N., Odabasi, A.Z., and Balaban, M.O., 2001, Drying Rates and Browning Kinetics of Dried Apricots (*Prunus armenica* L.) Blanched and Treated with Different Solutions, In *Proc'of IFT Annual Meeting Abstract Book*, P 174, 23rd-27th June.
- Demir, N., Balaban, M.O., and Riad, G.S., 2001, Objective Quality Assessment of CA Stored Sliced Zucchini (*Cucurbita pepo* L, cv, Elite) Using Electronic Nose, Machine Vision and Instron, P 55, 23rd-27th June 2001.
- Demir, N., Ferraz, C.O., Sargent, S.A., and Balaban, M.O., 2002, Determination of Odor Changes in Bruised Blueberries During Storage Using An Electronic Nose, P 79, 15th-19th June 2002.
- Demir, N., Balaban, M.O., Brecht, J.K., Sims, C.A., and Gulay, M.S., 2002, Objective Quality Assessment of Modified Atmosphere Stored Zucchini (*Cucurbita pepo* L, cv, Elite) Slices Using Electronic Nose, Machine Vision, and Instron, P 181, 15th-19th June 2002.
- De Wet, L., Vranken, E., Chedad, A., Aerts, J.M., Ceunen, J., and Berckmans, D., 2003, Computer-assisted image analysis to quantify daily growth rates of broiler chickens, *British Poultry Science*, 44(4): 524-532,
- Doganis P., Alexandridis A., Patrinos P., and Sarimveis H., 2005, Time series sales forecasting for short shelf-life food products based on artificial neural networks and evolutionary computing. *Journal of Food Engineering*

- Edizel, M. F., Yüce A., Erel B., Sarıdaş H., Güneri İ., Kandemir M., Arda M., Büyükkşirin S., ve Gökçen S., 1997, Gıdalar için önerilen mikrobiyolojik limitler, T,C, Sağlık Bakanlığı İzmir Bölge Hıfzısıhha Enstitüsü Müdürlüğü, Yayın No: 1997/1, İzmir.
- Eerikainen T., Linko P., Linko S., Siimes T., and Y-H., 1993, Zhu Fuzzy logic and neural network applications in food science and technology Trends in Food Science & Technology Volume 4, Issue 8 , August 1993, Pages 237-242.
- Erçoşkun, A., 1987, Gıda Maddeleri Tüzüğü, İşçi Sağlığı ve İş Güvenliği Tüzüğü, Hema-Petek Sağlık Yayınları, Yayın No:2.
- Fernandez-Garcia, E. and Mcgregori, J.U., 1994, Determination of organics acids during the fermentation and cold storage of yoghurt, J, Dairy Sci, 77:2934-2939.
- Gerrard, D.E., Gao, X., and Tan, J., 1996, Beef marbling and colour score determination by image processing, J, Of Food Sci., 61(1):145-148.
- Ghazanfari, A., Irudayaraj, J., and Kusalik, A., 1996, Grading pistachio nuts using a neural network approach, Transactions of the ASAE, 39(6), 2319–2324.
- Go'mez, G., 2004, Ana' lisis de Supervivencia, 84-688-5607-X, Universitat Polite`cnica de Catalunya.
- Gunasekaran, S., 2001, Non-destructive Food Evaluation Techniques to Analyse Properties and Quality, Food Science and Technology Series, Marcel Dekker, New York, p, 105.
- Han, Y. J., Bowers, S. V., and Dodd, R. B., 1992, Nondestructive detection of split-pit peaches, Transactions of the ASAE, 35(6), 2063–2067.

- Hayashi, S., Kanuma, T., Ganno K., and Sakaue, O., 1998, Cabbage head recognition and size estimation for development of a selective harvester, In 1998 ASAE Annual International Meeting, Paper No, 983042, St, Joseph, Michigan, USA: ASAE.
- Heinemann, P.H., Hughes, R., Morrow, C.T., Sommer, H.J., Beelman, R.B., and Wuest, P.J., 1994, Grading of mushrooms using a machine vision system, Transactions of the ASAE, 37(5), 1671–1677.
- Hough, G., Garitta, L., and Sa´nchez, R., 2004, Determination of consumer acceptance limits to sensory defects using survival analysis, Food Quality and Preference, 15, 729–734.
- Hough, G., Langohr, K., Go´mez, G., and Curia, A., 2003, Survival analysis applied to sensory shelf life of foods, Journal of Food Science, 68, 359–362.
- Howarth, M.S. and Searcy, S.W., 1992, Inspection of fresh carrots by machine vision, In Food Processing Automation II Proceedings of the 1992 Conference , St, Joseph, Michigan, USA: ASAE.
- Kailasapathy, K. and Rybka, S., 1997, *L. acidophilus* and *Bifidobacterium* spp. – their therapeutic potential and survival in yogurt, The Australian Journal of Dairy Technology 52: 28-35.
- Kato, S., Nakagawa, T., Ohkawa, M., Muramoto, K., Oyama, O., Watanabe, A., Nakashima, H., Nemoto, T., and Sugitani, K., 2004, A computer image processing system for quantification of zebrafish behavior, Journal of Neuroscience Methods, 134: 1-7.
- Kırdar, S. ve Gün, İ., 2002, Burdur’da tüketilen süzme yoğurtların fiziksel, kimyasal ve mikrobiyolojik özellikleri. Gıda, 27 (1), 59-64.

- Kim, S. and Schatzki, T., 2001, Detection of pinholes in almonds through X-ray imaging, *Transactions of the ASAE*, 44(4), 997– 1003.
- Klein, J.P., and Moeschberger, M.L., 1997, *Survival analysis, techniques for censored and truncated data* (502p), New York: Springer-Verlag.
- Kleinbaum, D.G., 1996, *Survival analysis, a self-learning text* (324p), New York: Springer-Verlag.
- Kneifel, W., D, Jaros, and Erhard, F., 1993, Microflora and acidification properties of yogurt and yogurt-related products fermented with commercially available starter cultures, *Int, J, Food Microbiol*, 18:179–189.
- Kondo, N., Ahmada, U., Montaa, M., and Muraseb, H., 2000, Machine vision based quality evaluation of Iyokan orange fruit using neural networks, *Computers and Electronics in Agriculture*, 29(1–2), 135–147.
- Koçhisarlı, İ. ve Ergül, E., 1987,. Ankara piyasasında satılan yoğurt örneklerinin bazı kalite özellikleri üzerinde araştırmalar. *Gıda*, 12(3), 175-177.
- Kuchida, K., Suzuki, K., Yamaki, K., Shinohara, H., and Yamagishi, T., 1991, Prediction for chemical component of pork meat by personal computer color image analysis, *Anim, Sci, Tech*., 62:477–479.
- Kuchida, K., Kono, S., Konishi, K., Van Vleck, L,D., Suzuki, M., and Miyoshi, S., 2000, Prediction of crude fat content of longissimus muscle of beef using the ratio of fat area calculated from computer image analysis: Comparison of regression equations for prediction using different input devices at different stations, *J, Anim, Sci*, 2000, 78:799–803.
- Kurt, A., 1999, Yoğurdun tarihçesi ve yeryüzüne yayılışı, III, Milli Süt ve Süt Ürünleri Sempozyumu, Yoğurt, Milli Produktivite Merkezi Yayınları No: 548, Ankara, 23-25s.

- Laykin, S., Edan, Y., Alchanatis, V., Regev, R., Gross, F., Grinshpun, J., Bar, E., Fallik, E., and Alkalai, S., 1999, Development of a quality sorting machine vision and impact, In 1999 ASAE Annual International Meeting, Paper No, 993144, St, Joseph, Michigan, USA: ASAE.
- Laye, I.D, Karleskind, and Morr, C.V., 1993, Chemical, microbiological and sensory properties of plain non-fat yogurt, *J, Food Sci*, 58:991–995.
- Lefebvre, M., Gil, S., Brunet, D., Natonek, E., Baur, C., Gugeril, P., and Pun, T., 1993, Computer vision and agricultural robotics for disease control: the potato operation, *Computers and Electronics in Agriculture* 9, 85_/102.
- Leemans, V., Magein, H., and Destain, M.F., 1998, Defects segmentation on _Golden Delicious_ apples by using colour machine vision, *Computers and Electronics in Agriculture*, 20, 117–130.
- Liu, J. and Paulsen, M.R., 1997, Corn whiteness measurement and classification using machine vision, In 1997 ASAE Annual International Meeting, Paper No, 973045, St, Joseph, Michigan, USA: ASAE.
- Li, J., Tan, J., and Martz, F.A., 1997, Predicting beef tenderness from image texture features, 1997 ASAE annual international meeting technical papers, paper no, 973124, ASAE, 2950 Niles Road, St, Joseph, MI 49085- 9659, USA.
- Lu, J., Tan, J., Shatadal, P., and Gerrard, D.E., 2000, Evaluation of pork color by using computer vision, *Meat Science* 56, 57_/60.
- Luzuriaga D., Balaban M., and Yeralan S., 1997, Analysis of Visual Quality Attributes of White Shrimp by Machine Vision, *Journal of Food Science* Volume 62, No:1.

- Majumdar, S. and Jayas, D.S., 2000d, Classification of cereal grains using machine vision: IV, Combined morphology, colour, and texture models, Transactions of the ASAE, 43(6), 1689–1694.
- Meeker, W.Q. and Escobar, L.A., 1998, Statistical methods for reliability data (680p), New York: John Wiley & Sons.
- McFarlane, N.J.B., and Schofield, C.P., 1995, Segmentation and tracking of piglets in images, Machine Vision and Applications, 8(3): 187-193.
- McDonald, T. and Chen, Y.R., 1990, Separating connected muscle tissues in images of beef carcass rib eyes, Transactions of the ASAE, 33(6):2059-2065.
- Morimoto, T., Takeuchi, T., Miyata, H., and Hashimoto, Y., 2000, Pattern recognition of fruit shape based on the concept of chaos and neural networks, Computers and Electronics in Agriculture, 26, 171–186,
- Nagata, M., Cao, Q., Bato, P.M., Shrestha, B.P., and Kinoshita, O., 1997, Basic study on strawberry sorting system in Japan, In 1997 ASAE Annual International Meeting, Paper No, 973095, St, Joseph, Michigan, USA: ASAE.
- Newman, P.B, 1984, The use of video image analysis for quantitative measurement of fatness in meat: Part 2 Comparison of VIA, visual assessment and chemical fat estimation in a commercial environment, Meat Science, 10: 161–166.
- Ng, H.F., Wilcke, W.F., Morey, R.V., and Lang, J.P, 1997, Machine vision evaluation of corn kernel mechanical and mould damage, In 1997 ASAE Annual International Meeting, Paper No, 973047, S t, Joseph, Michigan, USA: ASAE.

- Ni, B., Paulsen, M.R., Liao, K., and Reid, J.F., 1997, Design of an automated corn kernel inspection system for machine vision, *Transactions of the ASAE*, 40(2), 491–497.
- Ni, H. and Gunasekaran, S., 1995, A computer vision system for determining quality of cheese shreds, In *Food Processing Automation IV Proceedings of the FPAC Conference*, St. Joseph, Michigan, USA: ASAE,
- Ni, B., Paulsen, M.R., Liao, K., and Reid, J.F., 1997, Design of an automated corn kernel inspection system for machine vision, *Transactions of the ASAE* 40 (2), 491_ /497.
- Okamura, N.K., Dewiche, M.J., and Thompson, J.F., 1993, Raisin grading by machine vision, *Transactions of the ASAE*, 36(2), 485– 491.
- Öztemel, E., 2003, *Yapay Sinir Ağları*, Papatya Yayıncılık 232s, İstanbul.
- Park, B., Chen, Y.R., Nguyen, M., and Hwang, H., 1996, Characterizing multi-spectral images of tumorous, bruised, skin-torn, and wholesome poultry carcasses, *Transactions of the ASAE*, 39(5): 1933-1941.
- Panigraha, S., Misra, M.K., and Willson, S., 1998, Evaluations of fractal geometry and invariant moments for shape classification of corn germplasm, *Computers and Electronics in Agriculture*, 20(1), 1–20.
- Pearson, T., and Toyofuku, N., 2000, Automated sorting of pistachio nuts with closed shells, *Applied Engineering in Agriculture*, 16(1), 91–94.
- Qui, W, and Shearer, S, A., 1992, Maturity assessment of Broccoli using the Discrete Fourier Transform, *Transactions of the ASAE*, 35(6), 2057–2062.
- Rasic, J.Lj., and J.A., Kurman, 1978, *Yogurt*, Staempfli + Cie AG, Berne, Switzerland.

- Reed, J.N., Crook, S., and He, W., 1995, Harvesting mushrooms by robot, In Science and cultivation of edible fungi (pp, 385–391), Rotterdam: Elliott, Balkema.
- Renner, E. ve Saldamlı, İ., 1983, Beslenme açısından fermente süt ürünleri, Gıda 8 (6):297-311.
- Ruiz, L, A., Molto, E., Juste, F., Pla, F., and Valiente, R., 1996, Location and characterization of the stem-calyx area on oranges by computer vision, Journal of Agricultural Engineering Research, 64, 165–172.
- Sağıroğlu, Ş., Beşdok, E., ve Erler, M., 2003, Mühendislikte Yapay Zeka Uygulamaları– I, Yapay Sinir Ağları. Ufuk Kitabevi.
- Sapirstein, H,D., 1995, Quality control in commercial baking: Machine vision inspection of crumb grain in bread and cake products, Food Processing Automation IV Proceedings of the FPAC Conference, ASAE, USA.
- Schatzki, T, F., Haff, R.P., Young, R., Can, I., Le, L.C., and Toyofuku, N., 1997, Defect detection in apples by means of X-ray imaging, Transactions of the ASAE, 40(5), 1407–1415.
- Scott, A., 1994, Automated continuous online inspection, detection and rejection, Food Technology Europe, 1(4), 86–88.
- Shahani, K.M. and Chandan, R.C., 1979, Nutritional and healthful aspects of cultured and culture containing dairy foods, Journal of Dairy Science 62 (10): 1658 – 1694.
- Shiranita, K., Miyajima, T., and Takiyama, R., 1998, Determination of meat quality by texture analysis, Pattern Recognition Letters, 19: 1319-1324.

- Shackelford, S.D., Wheeler, T.L., and Koohmaraie, M., 1998, Coupling of image analysis and tenderness classification to simultaneously evaluate carcass cutability, longissimus area, subprimal cut weights, and tenderness of beef, *Journal of Animal Science*, 76: 2631-2640.
- Singh, N. and Delwiche, M.J., 1994, Machine vision methods for defect sorting stonefruit, *Transactions of the ASAE*, 37(6), 1989– 1997.
- Steinmetz, V., Roger, J.M., Molto, E., and Blasco, J., 1999, Online fusion of colour camera and spectrophotometer for sugar content prediction of apples, *Journal of Agricultural Engineering Research*, 73, 207–216.
- Sun, D.-W., 2000, Inspecting pizza topping percentage and distribution by a computer vision method, *Journal of Food Engineering*, 44, 245–249.
- Şahan, N. ve Say, D., 1998, Hatay ilinde üretilen tuzlu yoğurtlar üzerine bir araştırma, *Geleneksel Süt Ürünleri 5, Süt ve Süt Ürünleri Sempozyumu (21-22 Mayıs 1998) Tekirdağ Milli Prodüktive Merkezi yayınları No: 621, Ankara 427 s.*
- Şahan, N., Akın, M.S., ve Atasoy, A.F., 1998, Şanlıurfa ilinde üretilen yoğurtların standarda uygunluğunun araştırılması. *Harran Üniversitesi Ziraat Fakültesi Dergisi*, 2(4), 117,126.
- Takahashi N., Hatamoto F., and Kawai N., 1998, Flavor estimation of plain yogurt using artificial neural network, *Journal of the japanese society for food science and technology-nippon shokuhin kagaku kogaku kaishi* 45 (7): 408-414.
- Tao, Y., Heinemann, P.H., Varghese, Z., Morrow, C.T., and Sommer, H.J., III 1995a, Machine vision for colour inspection of potatoes and apples, *Transactions of the ASAE*, 38(5), 1555–1561.

- Tao, Y. and Wen, Z., 1999, An adaptive spherical image transform for high-speed fruit defect detection, *Transaction of the ASAE*, 42(1), 241–246.
- Tamime, A, Y. and Robinson, R.K., 1978, Some aspects of the production of a concentrated yoghurt (Labneh) popular in the middle east, *Milchwissenschaft*, 33, 4 209-213.
- Tamime, A, Y. and Deeth H.C., 1980, Yoğurt: technology and biochemistry, *Journal of Food Protection* 43 (12):939-977.
- Tamime, A,Y. and Robinson, R.K., 1999, *Yogurt science and technology* (2nd Edition), CRC Pres, Boca Raton, FL.
- Tarbell, K.A. and Reid, J.F., 1991, A computer vision system for characterising corn growth and development, *Transactions of the ASAE* 34 (5), 2245_/2249.
- Tayar, M., Anar, Ş., ve Şen, C., 1993, Bursa'da tüketilen yoğurtların kalitesi. *Gıda*, 18(3), 203-205.
- Tollner, E.W., Shahin, M.A., Maw, B.W., Gitaitis, R.D., and Summer, D.R., 1999, Classification of onions based on internal defects using imaging processing and neural network techniques, In 1999 ASAE Annual International Meeting, Paper No, 993165, S t, Joseph, Michigan, USA: ASAE.
- TS 1330 Yoğurt Standartı, 1989, Türk Satandartları Enstitüsü, Ankara.
- Uthu, H., 2000, Application of the feature selection method to discriminate digitised wheat varieties, *Journal of Food Engineering*, 46(3), 211–216.
- Uysal, H.R., 1993, Vakum ve ultrafiltrasyonla koyulaştırılan sütlerden torba yoğurdu yapımı ve klasik yöntemle karşılaştırılması üzerine araştırmalar, *Doktora tezi*, İzmir, 158 s.

- Van der Sluis, W., 1991, A camera and PC can now replace the quality inspector, *Misset World Poultry*, 7(10): 29.
- Van Loon, P.C.C., 1996, Het bepalen van het ontwikkelingsstadium bij dechampignon met computer beeldanalyse, *Champignoncultuur*, 40(9), 347–353.
- Vizhanyo, T., and Felfoldi, J., 2000, Enhancing colour differences in images of diseased mushrooms, *Computers and Electronics in Agriculture*, 26, 187–198.
- Vizhanyo, T., and Tillett, R.D., 1998, Analysis of mushroom spectral characteristics, *Proceedings of AgEng'98 International Conference on Agricultural Engineering*, Paper No, 98-F08019981-7, Oslo, 24– 27 August 1998.
- Wan, Y.N., Lin, C.M., and Chiou, J.F., 2000, Adaptive classification method for an automatic grain quality inspection system using machine vision and neural network, In 2000 ASAE Annual International Meeting, Paper No, 003094, St, Joseph, Michigan, USA: ASAE.
- Wang, H.H. and Sun, D.W., 2001, Evaluation of the functional properties of cheddar cheese using a computer vision method, *Journal of Food Engineering*, 49(1), 47–51.
- Wang, H.H. and Sun, D.W., 2002a, Correlation between cheese meltability determined with a computer vision method and with Arnott and Schreiber, *Journal of Food Science*, 67(2), 745–749.
- Wang, H.H. and Sun, D.W., 2002b, Assessment of cheese browning affected by baking conditions using computer vision, *Journal of Food Engineering*, 56(4), 339–345.

- Wang, H.H. and Sun, D.W., 2002c, Melting characteristics of cheese: analysis of the effects of cheese dimensions using image processing techniques, *Journal of Food Engineering*, 52(3), 279–284.
- Wooten, J.R., White, J.G., Thomasson, J.A., and Thompson, P.G., 2000, Yield and quality monitor for sweet potato with machine vision, In 2000 ASAE Annual International Meeting, Paper No, 001123, St, Joseph, Michigan, USA: ASAE.
- Yang, Q., 1993, Classification of apple surface features using machine and neural networks, *Computers and Electronics in Agriculture*, 9, 1–12.
- Yang, Q., 1994, An approach to apple surface feature detection by machine vision, *Computers and Electronics in Agriculture*, 11, 249– 264.
- Yang, Q., 1996, Apple stem and calyx identification with machine vision, *Journal of Agricultural Engineering Research*, 63, 229– 236.
- Yin, H. and Panigrahi, S., 1997, Image processing techniques for internal texture evaluation of French fries, In 1997 ASAE Annual International Meeting, Paper No, 973127, St, Joseph, Michigan, USA: ASAE.
- Ying, Y.B., Jing, H.S., Ma, J.F., Zhao, Y., and Jiang, Y.Y., 1999, Shape identification of Huanghua pear using machine vision, *Transactions of the Chinese Society of Agricultural Engineering*, 15(1), 192–196.
- Zayas, I.Y., Martin, C.R., Steele, J.L., and Katsevich, A., 1996, Wheat classification using image analysis and crush force parameters, *Transactions of the ASAE*, 39(6), 2199–2204.

ÖZGEÇMİŞ

Adı Soyadı :Aytül Bayraktar SOFU

Doğum Yeri :Dinar / Afyon

Doğum Yılı :1975

Medeni Hali :Evli

Eğitim ve Akademik Durumu:

Lise :1988-1991 Dinar Lisesi

Lisans :1997-2002 Süleyman Demirel Üniversitesi Fen Edebiyat Fakültesi
Biyoloji Bölümü

Yabancı Dil : İngilizce

İş Deneyimi:

2003- Okutman, Süleyman Demirel Üniversitesi Rektörlük