



**SES SİNYALLERİNİ KULLANARAK YUMURTA
KABUĞUNDAKİ ÇATLAKLARIN TESPİTİ**

YÜKSEK LİSANS TEZİ

Zekeriya BALCI

Danışman

Dr. Öğr. Üyesi İsmail YABANOVA

Elektrik-Elektronik Mühendisliği Anabilim Dalı

Haziran 2018

AFYON KOCATEPE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

YÜKSEK LİSANS TEZİ

SES SİNYALLERİNİ KULLANARAK YUMURTA KABUĞUNDAKİ
ÇATLAKLARIN TESPİTİ

Zekeriya BALCI

Danışman
Dr. Öğr. Üyesi İsmail YABANOVA

ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

Haziran 2018

TEZ ONAY SAYFASI

Zekeriya BALCI tarafından hazırlanan “SES SİNYALLERİNİ KULLANARAK YUMURTA KABUĞUNDAKİ ÇATLAKLARIN TESPİTİ” adlı tez çalışması lisansüstü eğitim ve öğretim yönetmeliğinin ilgili maddeleri uyarınca 25/06/2018 tarihinde aşağıdaki jüri tarafından **oy birliği** ile Afyon Kocatepe Üniversitesi Fen Bilimleri Enstitüsü **Elektrik-Elektronik Mühendisliği Anabilim Dalı’nda YÜKSEK LİSANS TEZİ** olarak kabul edilmiştir.

Danışman : Dr. Öğrt. Üyesi İsmail YABANOVA

Başkan : Prof. Dr. Ahmet ALTUNCU
Dumlupınar Üniversitesi,
Mühendislik Fakültesi

Üye : Prof. Dr. Hasan ÇİMEN
Afyon Kocatepe Üniversitesi,
Teknoloji Fakültesi

Üye : Dr. Öğrt. Üyesi İsmail YABANOVA
Afyon Kocatepe Üniversitesi,
Teknoloji Fakültesi

İmza



Afyon Kocatepe Üniversitesi
Fen Bilimleri Enstitüsü Yönetim Kurulu’nun
...../...../..... tarih ve
..... sayılı kararıyla onaylanmıştır.

.....
Prof. Dr. İbrahim EROL
Enstitü Müdürü

BİLİMSEL ETİK BİLDİRİM SAYFASI
Afyon Kocatepe Üniversitesi

Fen Bilimleri Enstitüsü, tez yazım kurallarına uygun olarak hazırladığım bu tez çalışmada;

- Tez içindeki bütün bilgi ve belgeleri akademik kurallar çerçevesinde elde ettiğimi,
- Görsel, işitsel ve yazılı tüm bilgi ve sonuçları bilimsel ahlak kurallarına uygun olarak sunduğumu,
- Başkalarının eserlerinden yararlanılması durumunda ilgili eserlere bilimsel normlara uygun olarak atıfta bulunduğumu,
- Atıfta bulunduğum eserlerin tümünü kaynak olarak gösterdiğimi,
- Kullanılan verilerde herhangi bir tahrifat yapmadığımı,
- Ve bu tezin herhangi bir bölümünü bu üniversite veya başka bir üniversitede başka bir tez çalışması olarak sunmadığımı

beyan ederim.

25/06/2018

İmza
Zekeriya BALCI

ÖZET
Yüksek Lisans Tezi

**SES SİNYALLERİNİ KULLANARAK YUMURTA KABUĞUNDAKİ
ÇATLAKLARIN TESPİTİ**

Zekeriya BALCI

Afyon Kocatepe Üniversitesi

Fen Bilimleri Enstitüsü

Elektrik-Elektronik Mühendisliği Anabilim Dalı

Danışman: Dr. Öğr. Üyesi İsmail YABANOVA

Yumurta üretim çiftliklerinde yumurtaların taşınması, sınıflandırılması, belirli ölçütlere göre ayrılması gibi birtakım süreçler, yumurta sanayisi için üretilmiş makineler tarafından gerçekleştirilmektedir. Yumurtaların bu makinelerdeki işlem süreçlerinde veya fiziksel dış etmenlere maruz kalması sonucu, yumurta kabuğunda çatlaklar ve kırıklar oluşabilmektedir. Oluşan çatlak veya kırık bölgeler yumurtayı hastalık yapıcı mikro organizmalara karşı savunmasız bırakabilmektedir. Bundan dolayı çatlak veya kırık yumurtaların sağlam yumurtalardan ayrıştırılma işlemi, gerek gıda güvenliği gerekse ekonomik kayıplardan ötürü bir gereklilik arz etmektedir.

Bu araştırmada, destek vektör makinaları ve yapay sinir ağı gibi yapay zekâ yöntemleri ile birlikte yumurta kabuğunda herhangi bir zarara sebep olmayacak şekilde uygulanan mekanik etki sonucu yumurta kabuğundan elde edilen akustik sinyaller kullanılarak yumurta çatlak tespiti yapılmıştır. Uygulanan yöntemler neticesinde çatlak tespit işlemi doğruluk değerleri yapay sinir ağı için 0,99, destek vektör makinaları için 1 olarak elde edilmiştir. Ayrıca LABVIEW ortamında geliştirilen program ile gerçek zamanlı olarak çatlak tespiti yapılmıştır.

2018, viii + 53 sayfa

Anahtar Kelimeler: Akustik sinyal, çatlak tespiti, yumurta kabuğu, DVM, YSA

ABSTRACT
M.Sc. Thesis

DETECTION OF CRACKS IN EGG SHELL USING SOUND SIGNALS

Zekeriya BALCI

Afyon Kocatepe University

Graduate School of Natural and Applied Sciences

Department of Electrical and Electronics Engineering

Supervisor: Asst. Prof. İsmail YABANOVA

In egg production farms, some processes such as the transport of eggs, their classification and their separation according to certain criteria are carried out by the machines produced for the egg industry. Cracks and cracks can form in the eggshell as a result of the eggs being exposed to the processing process or physical external factors in these machines. Cracked or broken areas can make the egg vulnerable to disease-causing microorganisms. Therefore, the separation of cracked or broken eggs from intact eggs is a necessity for both food safety and economic losses

In this study, eggs cracks were detected by using support vector machines and artificial neural network artificial intelligence methods and acoustic signals obtained from egg shell. As a result of the methods applied, the accuracy of crack detection was 0,99 for artificial neural network and 1 for support vector machines. In addition, crack detection has been done in real time with the interface program developed in LABVIEW environment.

2018, viii + 53 pages

Keywords: Acoustic signal, Crack detection, Eggshell, SVM, ANN

TEŞEKKÜR

Bu araştırmanın konusu, deneysel çalışmaların yönlendirilmesi, sonuçların değerlendirilmesi ve yazımı aşamasında yapmış olduğu büyük katkılarından dolayı tez danışmanım Sayın Dr. Öğr. Üyesi İsmail YABANOVA'ya, her konuda öneri ve eleştirileriyle yardımlarını gördüğüm hocalarıma ve tez kapsamında teknik desteklerinden ötürü Balı IŞILDAR'a teşekkür ederim.

Yüksek lisans sürecinde her türlü fedakârlıkları ile beni destekleyen aileme teşekkür ederim.

Zekeriya BALCI
AFYONKARAHİSAR, 2018

İÇİNDEKİLER DİZİNİ

Sayfa

ÖZET	i
ABSTRACT	ii
TEŞEKKÜR	iii
İÇİNDEKİLER DİZİNİ	iv
KISALTMALAR DİZİNİ	v
ŞEKİLLER DİZİNİ	vi
ÇİZELGELER DİZİNİ	vii
RESİMLER DİZİNİ	viii
1. GİRİŞ	1
2. LİTERATÜR BİLGİLERİ	3
2.1 Ses Sinyali İşleme ve Görüntü İşleme Üzerine Yapılan Çalışmalar	3
3. MATERYAL ve METOT	12
3.1 Deneysel Düzenekler ve Çevresel Cihazlar	12
3.1.1 CompactRIO (cRIO)	12
3.1.2 Yumurta Destek ve Mekanik Etki Ünitesi	13
3.1.3 İşlemsel Yükselteç ve Sürücü Devresi	15
3.1.4 Yazılım	16
3.2 Makine Öğrenme	16
3.2.1 Yapay Sinir Ağları	17
3.2.1.2 Yapay Sinir Ağlarının Yapısı ve Temel Elemanları	18
3.2.1.3 Çok Katmanlı Yapay Sinir Ağları	20
3.2.2 Destek Vektör Makinaları	27
3.2.2.1 Doğrusal Destek Vektör Makinaları	28
3.2.2.2 Doğrusal Olmayan Destek Vektör Makinaları	30
4. BULGULAR	32
4.1 Verilerin Elde Edilmesi ve Analizi	32
4.2 Sınıflandırma Yöntemlerinin Uygulanması	38
5. TARTIŞMA VE SONUÇ	45
6. KAYNAKLAR	47
ÖZGEÇMİŞ	53

KISALTMALAR DİZİNİ

Kısaltmalar

ADC	Analog Dijital Çevrim
AML	Analytics and Machine Learning Toolkit
Compact RIO	cRIO
DA	Doğru Akım
DVM	Destek Vektör Makineleri
DVVT	Destek Vektör Veri Tanımlaması
MÖ	Makine Öğrenme
MT	Manyetostriktif Transdüser
NI	National Instruments
YSA	Yapay Sinir Ağı

ŞEKİLLER DİZİNİ

Sayfa

Şekil 3.1 Basit bir yapay sinir ağı örnek şeması.	18
Şekil 3.2 Yapay sinir hücresi modeli.....	19
Şekil 3.3 Çok katmanlı YSA modeli.	22
Şekil 3.4 Veri sınıflarını ayırabilecek doğrular (a) ve veri sınıflarını en iyi ayırabilecek doğru (b) için temel DVM yapısı.	28
Şekil 3.5 Doğrusal DVM için en uygun ayırıştırıcı düzlem ve destek vektörleri.	29
Şekil 3.6 Doğrusal olmayan veri uzayının çekirdek fonksiyonu yardımı ile daha yüksek boyuta dönüştürülmesi.	30
Şekil 4.1 Sağlam ve çatlak yumurtalara ait cevap sinyalleri.	33
Şekil 4.2 Yumurta cevap sinyali grafiği.	35
Şekil 4.3 Sadece yumurta sinyaline ait veri grafiği.	36
Şekil 4.4 Sağlam yumurta ve çatlak yumurtanın farklı noktalarından alınan sinyal grafikleri.	38
Şekil 4.5 YSA eğitim arayüzü görünümü.	39
Şekil 4.6 DVM eğitim arayüzü görünümü.	40
Şekil 4.7 Gerçek zamanlı olarak sağlam yumurta için YSA tahmin sonucu.	42
Şekil 4.8 Gerçek zamanlı olarak çatlak yumurta için YSA tahmin sonucu.	43

ÇİZELGELER DİZİNİ

Sayfa

Çizelge 3.1 Yaygın olarak kullanılan çekirdek fonksiyonları 31

Çizelge 4.1 Performans değerlerinin bağıntılarında kullanılan etiket ve açıklamaları. . 41



RESİMLER DİZİNİ

Sayfa

Resim 3.1 Sistem bileşenleri genel görünümü.	12
Resim 3.2 CompactRIO.	13
Resim 3.3 Yumurta destek ünitesi ve mekanik etki ünitesi deney düzeneği.	14
Resim 3.4 Yumurtaya çarpma durumu (a), başlangıç durumu (b).	15
Resim 3.5 Sinyal kuvvetlendirici ve kontrol devresi.	15
Resim 3.6 LABVIEW arayüz programı.	16
Resim 4.1 Guruplara ait yumurta örnekleri.	32
Resim 4.2 Mikro çatlak bulunan yumurtanın baskı uygulanmamış durumdaki görseli.	33
Resim 4.3 Mikro çatlak bulunan yumurtanın baskı uygulanmış durumdaki görseli.	34
Resim 4.4 Çatlak bölge ve uzağındaki bir noktanın görseli.	37

1. GİRİŞ

Yumurta ucuz bir besin kaynağı olmasına karşın sunduğu zengin içerikli besin değerlerinden ötürü insanlar için en değerli besin kaynaklarından birisi olmasının yanı sıra günlük beslenmede en çok tüketilen besinler arasındadır. Yumurta tüketiminin artması ile yumurta üretim çiftlikleri için birçok yumurta toplama ve ayırma makinaları geliştirilmiştir. Yumurtaların toplanması, taşınması, ağırlığına göre sınıflandırılması, kir, kan, kırık ve çatlak gibi bir takım kriterlere göre ayrıştırılması bu makinelerin işlemleri arasındadır. Bu makinelerde belirli işlemlerden geçerken, paketleme ve taşıma gibi işlem süreçlerinde yumurta kabuğu bir takım mekanik etkilere maruz kalabilmekte bu etkilerin sonucu olarak yumurta kabuğunda kırıklar ve çatlaklar oluşabilmektedir. Yumurta kabuğunda oluşabilecek çatlak veya kırıklar yumurtayı hastalık yapıcı bakterilere karşı savunmasız bırakmaktadır. Bununla birlikte bakteri bulaşmış bir yumurta besin kaynağının güvenilirliğini ortadan kaldırarak hem insan sağlığına zarar verebilir hem de ekonomik kayıplara yol açabilmektedir. Belirtilen bu sebeplerden ötürü çatlak yumurtaların tüketiciye ulaşmadan üretim aşamasında sağlam yumurtalardan ayrıştırılma işlemi gerek gıda güvenliği gerekse ekonomik kayıplardan ötürü bir gereklilik arz etmektedir. (Li *et al.* 2012, Strnková *et al.* 2013, Sun *et al.* 2013)

Gerçekleştirilen bu tez çalışmasında yumurta çatlaklarından oluşabilecek olumsuzlukları gidermek amacıyla çatlak yumurtaların tespit edilmesi hedeflenmiştir. Tez çalışmasında geliştirilen sistem, veri toplama ve kontrol bileşenleri ile yazılım ortamından oluşmaktadır. Mekanik sistem, yumurtayı destekleyen makara biçimindeki yumurta destek ünitesi, yumurtaya zarar vermeyecek şekilde tasarlanmış ve yumurtaya çarpma yöntemiyle akustik sinyallerin oluşturulması için mekanik etki ünitesinden oluşmaktadır. Veri toplama ve kontrol bileşenleri, mekanik etki ünitesini sürmek ve yumurtadan elde edilen sinyallerin kuvvetlendirilmesi için kontrol ve yükselteç kartı, analog dijital çevirim işlemi için ve kontrol kartı ile bilgisayar arası sinyal aktarımını gerçekleştirmesi amacıyla National Instruments (NI) firması tarafından üretilen cRIO donanımından ve bilgisayardan oluşmaktadır. Yazılım ortamı ise LABVIEW uygulama geliştirme programından oluşmaktadır.

Yumurta örneklerinden alınan akustik sinyaller kullanılarak sınıflandırma işlemlerini gerçekleştirmek amacıyla yapay zekâ yöntemlerinden Destek Vektör Makinaları (DVM) ve Yapay Sinir Ağı (YSA) incelenerek uygulanmıştır. Çalışma kapsamında 200 adet yumurtanın 100 tanesi DVM ve YSA eğitim aşamasında geri kalan 40 çatlak, 60 sağlam yumurta örneği ise oluşturulan DVM ve YSA modellerinin tekrar test işlemleri için kullanılmıştır. DVM ve YSA yapay zekâ yöntemlerinin eğitim işlemleri için doğruluk değerleri sırası ile 1 ve 0,99 değerlerinde gerçekleşmiştir. Ayrıca eğitim aşamasında oluşturulan DVM ve YSA yapıları daha önce görmedikleri 40 çatlak 60 sağlam yumurta örneği ile tekrar performansı test edilmiştir ve her iki yöntem de tüm örnekleri doğru olarak sınıflandırdığı görülmüştür.

Çatlak yumurtalar için çatlak bölgenin uzağından alınan sinyaller de incelenmiştir. İncelenen sinyaller neticesinde çatlak bölgeden uzaklaştıkça sinyal örnekleri çatlak yumurta sinyalinden uzaklaşarak sağlam yumurta sinyaline benzediği görülmüştür. Gerçekleştirilen tez çalışması ile gözle görülemeyen mikro çatlaklar da her iki yönteminde başarılı bir şekilde sınıflandırdığı görülmüştür. Ayrıca tez kapsamında gerçek zamanlı olarak ve yapay zekâ yönteminin dinamik olarak seçilebileceği bir yazılım geliştirilmiştir. Bu yazılım gerçek zamanlı olarak yumurtaları başarılı bir şekilde sınıflandırdığı görülmüştür

2. LİTERATÜR BİLGİLERİ

2.1 Ses Sinyali İşleme ve Görüntü İşleme Üzerine Yapılan Çalışmalar

Yumurta kabuğunda, işlem süreçlerinde veya yapısal etmenler sonucunda oluşabilecek çatlakların tespiti için bu tezde, yumurta kabuğunda herhangi bir zarara neden olmayacak şekilde hafif bir mekanik etki sonucu oluşan akustik sinyaller analiz edilmiştir. Bu bağlamda akustik sinyal işleme, ses sinyallerinin işlenmesi, görüntü işleme yardımıyla tespit işlemlerini ve algoritmalarını içeren literatür incelenmiştir. İncelenen literatür neticesinde akustik sinyal işleme, ses sinyallerinin işlenmesi ve görüntü işleme yöntemleri sonucunda farklı alanlarda tespit işlemleri gerçekleştirilmiş olup yumurta kabuğu çatlak tespitinde de akustik sinyal işleme ve görüntü işleme yöntemleri üzerine yoğunlaştığı görülmüştür (Wang *et al.* 2016).

De Ketelaere, Coucke ve De Baerdemaeker gerçekleştirdikleri çalışmada yumurta kabuğuna uyguladıkları zarara neden olmayacak biçimde mekanik etki sonucu oluşan akustik sinyalleri analiz ederek çatlak tespiti yapmayı amaçlamışlardır. De Ketelaere ve arkadaşları yumurtanın ekvatorial bölgesinden elde ettikleri akustik sinyallerin güç spektrumlarını incelediklerinde sinyalin tekrarlı olduğunu ve rezonans frekansının 3 kHz ile 6 kHz arasında olduğunu fakat çatlak yumurtanın güç spektrumunda ise homojen bir dağılımın olmadığını ve spektrumda, mekanik etki noktasının çatlak bölgeye olan uzaklığının belirleyici bir etkisi olduğunu belirtmişlerdir. Yumurta kabuğundaki çatlak tespiti için Pearson korelasyon katsayısı yöntemini kullanmışlar ve uyguladıkları metod ile %90 doğruluk derecesinde çatlak tespiti işlemini gerçekleştirdiklerini belirtmişlerdir (De Ketelaere *et al.* 2000).

De Aguiar, Bianchi, Serni ve Lançonni çalışmalarında metallerde taşlama esnasında oluşan ısı kaynaklı hasarları incelemeyi amaçlamışlardır. Oluşturdukları deneysel düzeneklerinde ABNT 1045 ve VC131 çelik türlerini taşlama işlemine tabi tutmuşlar ve taşlama işlemi sürecinde oluşan akustik sinyalleri bilgisayar ortamına aktararak farklı teknikler ile bu sinyalleri işlemişlerdir. De Aguiar ve arkadaşları gerçekleştirdikleri bu çalışma neticesinde uyguladıkları yöntemler ile taşlama esnasında metaller üzerinde

oluşan yanmaları tespit etmişlerdir (DE Aguiar *et al.* 2002).

Bechou ve arkadaşları gerçekleştirdikleri çalışmada mikro elektronik malzemelerin yüzey montajı ve geçirdikleri işlem süreçlerinde oluşan kusurları ultrasonik mikroskop kullanarak oluşan akustik sinyalleri analiz etmeye çalışmışlardır. Gerçekleştirilen bu çalışmada Bechou ve arkadaşlarının rapor ettiğine göre geliştirdikleri yöntem sayesinde lehim malzemesi içerisindeki boşluk veya oyulma mevcut ise yeterli bir doğruluk ile tespitinin gerçekleştirilebileceğini belirtmişlerdir. (Bechou *et al.* 2003).

Lin, Zhao, Chen, Cai ve Zhou gerçekleştirdikleri çalışmada silindir şeklinde yumurta destek ünitesi, mekanik etki çubuğu, sinyal güçlendirici, bilgisayar, verileri analiz etmek ve işlemek için yazılımdan oluşan deneysel düzenekleri ile yumurta kabuğundaki mevcut çatlakları tespit etmeyi amaçlamışlardır. Lin ve arkadaşları çalışmalarında çatlak tespiti işlemi için Destek Vektör Veri Tanımlaması (DVVT) yöntemini kullanmışlar ve uyguladıkları metot ile %90 doğruluk derecesi ile çatlak tespiti yapmışlardır. Lin ve arkadaşları çalışmaları neticesinde DVVT algoritmasının eğitim verilerinin sayısının dengesiz olduğu durumlarda etkili bir yöntem olduğunu belirtmişlerdir (Lin *et al.* 2009).

Deng ve arkadaşları gerçekleştirdikleri çalışmada yumurta kabuklarındaki çatlakları yumurta yüzeyine zarar vermeyecek seviyede mekanik etki sonucu oluşan akustik sinyalleri kullanarak Destek Vektör Makinaları (DVM) yöntemini kullanarak tespit etmeye çalışmışlardır. Yumurtanın sabitlendiği destek ünitesi, yumurtaya mekanik etki için ip ile asılmış ahşap boncuk, işlemsel yükselteç, bilgisayar ve yazılımdan oluşan deneysel düzenekleri ile verileri analiz edip uyguladıkları metot neticesinde %98.77 doğruluk derecesi ile yumurta kabuğu üzerindeki mevcut çatlakları tespit etmişlerdir. (Deng *et al.* 2009)

Deng, Xiaoyan, Chen ve Xie gerçekleştirdikleri çalışmada yumurta çatlaklarını tespit etmek için yumurtaya uyguladıkları mekanik etki sonucu oluşan akustik sinyalleri analiz etmişlerdir. Akustik sinyallerin analizlerinde akustik işaretlere dalgacık dönüşümü uygulayıp özellik çıkarımı işlemini gerçekleştirmişlerdir ve elde ettikleri sinyal öz niteliklerini çoklu kombinasyonlar halinde DVM'na veri girişi olarak sağlayıp sistemi

DVM algoritmasını eğitmişlerdir. Eğittikleri DVM ile çatlak tespiti işlemini gerçekleştirmeye çalışmışlardır. Deng ve arkadaşları uyguladıkları metod neticesinde %98.9 doğruluk oranı yumurta kabuğu çatlağı tespiti yaptıklarını belirtmişlerdir. (Deng *et al.* 2010)

Zhao, Wang, Lu ve Jiang çalışmalarında yumurta kabuğu çatlakları için örüntü tanımlama çalışmasını temel bileşen analizi ve doğrusal ayırmacılık analizi yöntemleriyle gerçekleştirmeye çalışmışlardır. Maksimum frekans değeri ve maksimum genlik değerlerini kullanarak örüntü tanımlama işlemini gerçekleştirmişlerdir. Deneysel düzenekleri ise silindir biçiminde yumurta destek ünitesi, yumurtaya zarar vermeyecek şekilde tasarlanan mekanik etki modülü, piezoelektrik sensör, sinyal kuvvetlendirici, sistem kontrolü ve analizi için yazılım ile bilgisayardan oluşmaktadır. Zhao ve arkadaşları uyguladıkları yöntem sonucunda baskın frekans değeri sağlam yumurtada daha düşük olduğunu fakat aynı tepe frekans değerlerinin genlikleri benzer olduğunu belirtmişler. Dinamik frekans cevabı ve maksimum genlik değerleri kullanılarak temel bileşen analizi ve doğrusal ayırmacılık analizi yöntemleri yardımıyla yumurta kabuğu çatlağı sınıflandırma işlemi gerçekleştirilebileceği sonucuna varmışlardır (Zhao *et al.* 2010).

Zhao, Li, Ge ve Tong çalışmalarında elektrik güç sistemleri için güç elemanının çalışma durumunu ve arıza sınıfını akustik sinyal işleme yönteminin kullanarak akıllı tespit yöntemi geliştirmeye çalışmışlardır. Zhao ve arkadaşları arıza türü belirlemek için güç sistemi elemanlarından akustik sinyal toplayarak veri tabanı oluşturmuşlar. Ardından geliştirdikleri yöntem ve algoritma ile çalışma sürecinde güç elemanlarından aldıkları sinyalleri oluşturdukları veri merkezindeki referans sinyallerle karşılaştırarak güç elemanının çalışma durumunu ve varsa arıza türünü tespit etmeye çalışmışlardır (Zhao *et al.* 2010).

Manik gerçekleştirdiği çalışmada sualtı akustik sinyal işleme yöntemiyle balık tespiti, tanıma ve miktarını belirlemeyi amaçlamıştır. Akustik sinyallerin analizi için sürekli dalgacık dönüşümü uygulamış ve geliştirdiği yöntem neticesinde balıkların sınıflandırma işlemi akustik veri ve sürekli dalgacık dönüşümü kullanılarak gerçekleştirilebilir olduğunu belirtmiştir (Manik 2011).

Fang ve Youxian yumurta kabuğu çatlaklarını belirlemek için arka planı siyah olacak şekilde tasarladıkları ortamda yumurtayı bir ışık kaynağı vasıtası ile aydınlatıp yumurtayı da yüz yirmi derecelik açılarla döndürerek görüntüler almışlar ve çektikleri görüntülerin analizi için makine görme yöntemini uygulamışlardır. Çatlakları belirlemek için çeşitli görüntü işleme yöntemleri uygulayarak gerçekleştirdikleri çalışma için en uygun görüntü işleme yöntemi morfolojik (yapısal) görüntü işleme yöntemi olduğunu belirtmişlerdir. Çalışmaları neticesinde geliştirdikleri yöntem ile %88 doğruluk oranı ile çatlak %87 doğruluk oranı ile sağlam yumurta tespiti gerçekleştirdiklerini bildirmişlerdir (Fang *et al.* 2011).

Li, Dhakal ve Peng yumurta kabuğunda oluşan gözle görülemeyen mikro çatlakları tespit etmek için, yumurtaya vakum kuvveti uygulayıp mikro çatlağı genişletip görünür kılabilen bir kap düzeneği, imge almak için kamera, ışık kaynağı, basınç ölçüm cihazı ve bilgisayardan oluşan deneysel düzeneği hazırlamışlardır. Yumurtayı tasarladıkları kaba alıp 18 kPa değerindeki vakum kuvvetine tabi tutup varsa yumurta üzerindeki mikro çatlakları belirginleştirmişler bu vakum değerinde yumurtadan imge almışlar ve çeşitli görüntü işleme teknikleri uygulayıp çatlak bulunan yumurtayı tespit etmişlerdir. Çalışma sonucunda 200 tane yumurta üzerinde gerçekleştirdikleri çalışma ile çatlak tespiti işleminin %100 doğruluk ile tespit ettiklerini belirtmişlerdir. Fakat sistemin tek bir yumurta için tasarlandığını, ışık kaynağının doğru ayarlanamadığında iyi sonuç alınamadığını ve endüstriyel işletmeler için sistemin hızının yeterli seviyede olmadığını belirtmişlerdir (Li *et al.* 2012).

Li ve arkadaşları gerçekleştirdikleri çalışmada yumurta çatlaklarını tespit etmeyi amaçlamışlardır. Deneysel düzenekleri yumurta destek ünitesi, zarara sebep olmayacak şiddette mekanik etki düzeneği, mikrofona, ses kartı ve bilgisayardan oluşmaktadır. Deneysel düzenekleri vasıtasıyla yumurtalardan aldıkları akustik sinyallere dalgacık dönüşümü uygulayıp bu sinyallerin enerji değerlerini hesaplamışlar. Hesaplamaları neticesinde çatlak ve sağlam yumurta sinyallerinin enerji değerleri arasında önemli farklar olduğunu belirterek bu farklar aracılığıyla çatlak ve sağlam yumurta ayrımının yapılabileceğini öne sürmüşlerdir. Ayrıca yumurtanın ekvatorial bölgesinden aldıkları sinyalleri incelediklerinde, sağlam yumurtanın enerji değerleri kırık yumurtaninkinden

büyük olduğunu fakat enerjinin homojen dağılmadığını gözlemlemişler. Yumurtanın oval uç bölgesinden aldıkları sinyallerde ise kırık yumurtaninkine sağlam yumurtaninkinden yüksek, sivri uç bölgesinden alınan sinyallerin enerji değerleri incelendiğinde ise kırık yumurtanın sinyallerinin enerji değerlerinin sağlam yumurtaninkinden küçük olduğunu gözlemlemişlerdir ve her bölge için enerji dağılımı bir tanımlama göstergesi olarak kullanılabilir fikrini belirtmişlerdir. Uyguladıkları yöntem ile %95 doğruluk ile çatlak tespiti yapmışlardır (Li *et al.* 2012).

Strnkova ve Nedomova, yumurtayı sabitlemek için poliüretan malzemeden yapılmış silindir biçiminde destek ünitesi, yumurtaya mekanik etki uygulamak için alüminyum malzemeden imal edilmiş bir çubuk ve yumurta kabuğu üzerindeki titreşimleri ölçmek için lazer titreşim metresinden oluşan deneysel düzenek hazırlayarak sağlam ve çatlak yumurtaların, uygulanan mekanik etkiye karşı verdiği cevap sinyalinin zaman uzayında ve frekans uzayında incelemişlerdir. Frekans boyutunda sağlam yumurtaların mekanik tepki analizinde tepe genlik frekans değerlerinin arasında büyük farklar olduğunu, çatlak yumurtaların frekans cevabında ise tepe değerlerdeki frekanslar ise homojen olmayan bir dağılım sergilediğini aynı zamanda aralarındaki farkın çok büyük olmadığını gözlemlemişler. Uygulanan mekanik etki çatlak noktasından çok uzakta ise sağlam yumurta ile çatlak yumurtanın frekans cevabının benzer olduğunu belirtmişlerdir. Gerçekleştirilen çalışma ile bir yumurtanın mekanik bir etkiye verdiği tepki sinyalinin analizi yardımı ile sağlam ve çatlak ayrımı yapılabilir sonucuna ulaşmışlardır (Strnková and Nedomová, 2013).

Kandal, Kakar ve Verma kara araçlarını sınıflandırmak için gerçekleştirdikleri çalışmada otoyoldan aldıkları akustik verilerin zaman uzayında özelliklerini çıkartarak veri tabanı oluşturmuşlardır. Daha sonra bu verileri araç türüne göre sınıflandırarak özellik matrisi oluşturmuşlardır. Araç sınıfı tespiti için yapay sinir ağı yöntemini kullanmışlardır. Geliştirdikleri yöntem algılama ve veri toplama, segmentasyon, özellik çıkarımı ve sınıflandırma bölümlerinden oluşmaktadır. Uyguladıkları yöntem sınıflandırma işlemini, otomobil için %57, tır için %57, bisiklet için ise %60 genel doğruluk oranı ile saptamıştır. Sınıflandırma işleminin verimi özellik çıkarımı ve veri tabanının büyüklüğüne bağlı olduğunu belirtmişlerdir (Kandpal *et al.* 2013).

Sun ve arkadaşları gerçekleştirdikleri çalışma ile gerçek zamanlı yumurta çatlak tespitini, akustik rezonans analizi yöntemini kullanarak uygulamaya çalışmışlardır. Ayrıca yumurta kabuğuna mekanik etki noktası, konveyör sisteminin hızını, etki yoğunluğu ve yumurta kütesinin etkilerini elde ettikleri akustik sinyalin frekans uzayında araştırmışlardır. Deneysel düzenekleri yumurtayı taşıyıcı silindir biçiminde yumurta destek ünitesi, yumurtaya zarar vermeyecek şekilde tasarlanan mekanik etki modülü, mikrofon, sinyal düzenleyici devre, dijital sinyal işleyici ve bilgisayardan oluşmaktadır. Çatlak yumurta tespiti için kalibrasyon modeli yöntemini kullanmışlardır. Uyguladıkları yöntem ile her bir yumurtanın frekans uzayındaki cevabından beş adet öznelik verisi çıkardılar ve bu öznelik değerlerini kritik değerle tek tek karşılaştırıp karar verme işlemini gerçekleştirdiler. Eğer, üç ve daha fazla öznelik sayı değeri kritik değerden büyük ise yumurtanın sağlam olduğuna değilse çatlak olduğuna karar verilmiştir. Sun ve arkadaşları uyguladıkları yöntem neticesinde sağlam yumurtaları %100 doğruluk, çatlak yumurtaları ise %96.1 doğruluk derecesi ile tespit etmişlerdir. Sınıflandırma işlemi 10ms'nin altında gerçekleştiğini, çalışmaları sonucu gerçek zamanlı çatlak tespitinin tatmin edici seviyelere ulaşması için yumurtaya çoklu sayılarda mekanik etki uygulanması ve analiz edilmesi gerektiğini belirtmişlerdir (Sun *et al.* 2013).

Omid ve arkadaşları gerçekleştirdikleri çalışmalarında yumurta kusurlarının ve boyutlarının tespiti ile birlikte sınıflandırma işlemini gerçekleştirmeye çalışmışlardır. Deneysel düzenekleri ortam gürültüsünden yumurta yüzeyini soyutlamak için kübik bir kutu, halojen ışık kaynağı ve kameradan oluşmaktadır. Yumurtalardan aldıkları görüntüleri işlemek ve değerlendirmek için makine görme tekniği ile birlikte bulanık mantık algoritmalarını kullanmışlardır. Omid ve arkadaşları gerçekleştirdikleri çalışma sonucunda uyguladıkları yöntem ile yumurta boyut ayrımında %95 doğruluk, çatlak tespitinde %94.5 doğruluk, kırık tespitinde %98 doğruluk ve genel başarı oranı olarak %95.4 doğruluk oranı ile tespit ettiklerini belirtmişlerdir (Omid *et al.* 2013).

Fang ve arkadaşları yumurta kabuğu üzerindeki çatlakları belirlemek için polarize ışık tekniğini kullanmışlar. Yumurta yüzeyine sodyum lambadan oluşan aydınlatıcı kaynak ile aydınlatıp yansıyan ışınları farklı açılarda bilgisayar ortamına alarak analiz etmişlerdir. Uyguladıkları yöntem sonucunda yumurta yüzeyindeki çatlakları elde

ettikleri imge verisini analiz ederek belirlemişlerdir (Fang *et al.* 2013).

Hacıoğlu tez çalışmasında bireylerde uyku durumunu (uykulu/uykusuz) tespit etmek için ses verilerinden özellik çıkarımı işlemini gerçekleştirip bunları makine öğrenme yöntemiyle geliştirdiği algoritmaya giriş verisi olarak uygulamıştır. Eğittiği bu algoritma ile bireylerden alınan ses sinyallerinden kişinin uyku durumunu tespit etmeyi amaçlamıştır. Hacıoğlu geliştirdiği yöntem ile tezinde belirttiği literatür taban seviye başarı oranlarına göre ilk seviye için %56 ikinci seviye için %74'lük doğruluk derecesi elde etmiştir (Hacıoğlu 2014).

Öztürk ve Gangal beyaz yumurtalarda kir ve çatlak tespiti için görüntü işleme tekniklerini kullanarak kırık ve kir tespiti yapmışlardır. Yumurtadan aldıkları görüntüyü ilk önce arka plandan ayrıştırıp daha sonra bir maske uygulayıp belirlenen eşik değerle karşılaştırarak kirli olup olmadığına karar vermişlerdir. Eğer yumurta birinci işlemde geçerse yani temiz olarak belirlenirse ikinci işleme tabi tutuluyor ikinci işlemde ise kenar belirleme yöntemi ile yumurta ve çatlak bölge kenarları tespit edilmiştir. Kenar belirleme işleminin ardından belirlenen eşik değere göre yumurtanın çatlak olup olmadığına karar verilmiştir. Uyguladıkları yöntem ile kusurlu ve temiz %93, kirli %92 ve çatlak yumurta sınıflandırmasını %88 doğruluk oranı ile tespit ettiklerini belirtmişlerdir (Öztürk ve Gangal 2014).

Attar ve Fathi yaptıkları çalışmada yumurtaya farklı frekanslarda sinyaller göndererek yumurta kabuğunun, yumurta akı ve sarısının akustik sinyal rezonans değerlerini ve aynı zamanda yumurta kabuğu rezonans frekansı ile kabuk sağlamlığı arasındaki ilişkiyi araştırmışlardır. Yumurtanın farklı materyallerden oluştuğu için farklı rezonans değerlerine ulaştıklarını belirterek yumurta kabuğunun rezonans frekans değerinin 200 Hz ile 1,5 kHz arasında olduğunu saptamışlardır. Yaptıkları çalışma neticesinde yumurta kabuğu sağlamlığı ile yumurta kabuğu akustik rezonans frekansı arasında bir ilişki olduğunu belirtmişlerdir (Attar and Fathi 2014).

Kovac̃ ve arkadaşları gerçekleştirdikleri çalışmada paslanmaz çeliğin, akustik emisyon yöntemi kullanarak gerilimli yenim çatlaklarının tespiti ve bu çatlakların karakteristik

özelliklerini araştırmayı amaçlamışlardır. Uyguladıkları yöntem neticesinde akustik emisyon sinyali yardımı ile gerilim yemim çatlaklarının tespiti otomatik olarak yapılabileceği ve karakterize edilebileceği sonucuna varmışlardır. (Kovaċ *et al.* 2015).

Lu ve arkadaşları çalışmalarında Manyetostriktif Transdüser (MT) kullanarak oluşturdukları deneysel düzenekleri ile yumurta çatlaklarını tespit etmeye çalışmışlardır. Deneysel prosedürleri, yumurtayı MT üzerine koyup ardından bilgisayar kontrolü ile MT'ye 1 kHz ile 14 kHz frekans değerleri arasında titreşim sinyalleri üreterek, yumurta ile transdüser arasındaki etkileşim sonucu akustik titreşim sinyalleri oluşturmuşlar. Daha sonra bu sinyalleri mikrofon aracılığıyla bilgisayar ortamına analiz için almışlardır. Yumurtadan alınan sinyallere dalgacık dönüşümü uyguladıktan sonra Burg güç spektrumu kullanılarak özellik çıkarımı işlemi gerçekleştirilmiş. Daha sonra DVM sınıflandırma yöntemi ile yumurta sınıflandırma işlemini gerçekleştirmişlerdir. Test verileri kullanılarak % 98 doğruluk ile ayırım işlemini gerçekleştirmişlerdir (Lu *et al.* 2015).

Jin, Xie ve Ying çalışmalarında merdivene benzeyen altı kademedan oluşan bir platform, bu platforma entegre edilmiş mikrofon, işlemsel yükselteç ve bilgisayardan oluşan deneysel düzenekleri ile bu platform üzerinden yuvarladıkları yumurtaların yuvarlanırken oluşturduğu akustik sinyalleri analiz ederek çatlak tespiti yapmaya çalışmışlardır. Jin ve arkadaşları çalışmalarında yumurta çatlaklarından elde ettikleri sinyallerine Mahalanobis uzaklık yöntemini uygulamışlardır. Uyguladıkları yöntem sayesinde yumurta kabuklarındaki mevcut çatlakları %90 doğruluk derecesi ile tespit ettiklerini belirtmişlerdir (Jin *et al.* 2015).

Yoo ve arkadaşları gerçekleştirdikleri çalışmada otomotiv gövde parçalarında meydana gelen çatlakları akustik emisyon sinyali metodunu kullanarak tespit etmeye çalışmışlardır. Laboratuvar ortamında geliştirdikleri sistemi gerçek üretim hattına uygulayıp sistemin başarılı bir şekilde baskı esnasında oluşan çatlakları gerçek zamanlı olarak tespit ettiğini ve bu işlemlerin bir saniyede içerisinde gerçekleştiğini belirtmişlerdir (Yoo *et al.* 2016).

Wang ve diğerleri farklı çiftliklerden kahverengi ve beyaz yumurta toplayarak bu


yumurtaların mekanik etki sonucu oluřturdukları akustik sinyalin, frekans ve zaman uzayında özelliklerini çıkararak bunlar arasındaki ilişkileri arařtırmıřlar. Yumurtalardan aldıkları akustik sinyalleri kullanarak çıkardıkları özellikleri yapay zekâ algoritmasına eğitim verisi olarak girmiřler ve özellik çıkarılmıř durum ile çıkarılmamıř durumdaki verilerin yapay zekâ tarafından ayırım sonuçlarını irdelemiřlerdir. Analizleri neticesinde özellik çıkarımının, özellik çıkarılmamıř durumdaki sinyalden, yapay zekâ algoritmasının ayırım sonucunda kayda deęer bir fark olmadığını ve çatlak ayırımında yumurta yüzeyine uygulanan mekanik etki noktası, çatlak bölgeden ne kadar uzak ise o derece ayırım iřleminin bařarısı düřtüğünü belirtmiřlerdir. Kırmızı ve beyaz yumurtaların akustik özellikleri arasında bir farkın olmadığını gözlemlemiřlerdir (Wang *et al.* 2016).



3. MATERYAL ve METOT

3.1 Deneysel Düzenekler ve Çevresel Cihazlar

Bu bölümde tez çalışmasında faydalanan materyallerden ve özelliklerinden bahsedilecektir. Deneysel sistem Resim 3.1’de görüldüğü gibi besleme kaynağı, işlemsel yükselteç ve kontrol devresi, CompactRIO (cRIO), mekanik etki ve yumurta destek ünitesi, verileri toplamak, analiz etmek ve görselleştirmek için yazılım ve bilgisayardan oluşmaktadır.



Resim 3.1 Sistem bileşenleri genel görünümü.

3.1.1 CompactRIO (cRIO)

CompactRIO (Resim 3.2) endüstriyel control sistemleri için National Instruments tarafından üretilen gerçek zamanlı endüstriyel kontrolördür. cRIO kompakt ve konfigüre edilebilir giriş çıkış modüllerinin (reconfigurable IO Modules (RIO)) İngilizce

kısaltılmasıyla isimlendirilmiştir (İnt.Kyn.4). Endüstrideki bir çok sisteme entegre edilebilir esnek bir cihaz olmakla birlikte modüler birimleri sayesinde geniş bir kontrol, analiz ve manipüle olanağı sağlar (İnt.Kyn.1). Bu çalışmada cRIO verilerin toplanması, kontrol kartı tetikleme sinyalinin üretilmesi, analog verinin dijital veriye çevrilerek bilgisayar ortamına gönderilmesi işlemleri için kullanılmıştır. ADC işlemleri için NI-9215 analog giriş modülü, dijital giriş çıkış işlemleri için NI-9375 giriş çıkış modülü kullanılmıştır.

cRIO'nun teknik özellikleri aşağıda verilmiştir.

- +19V DA ile 30V DA arası çalışma gerilimi.
- 400 MHz işlemci hızı.
- 256 MB dahili hafıza.
- Xilinx Spartan-3 2M FPGA.
- Ethernet ve RS232 haberleşme desteği.
- 8 adet modüler modüler birim.




Resim 3.2 CompactRIO.

3.1.2 Yumurta Destek ve Mekanik Etki Ünitesi


Yumurta destek ünitesi (Resim 3.3), yumurtanın oturacağı silindirik şeklindeki plastikten yapılmış malzemeden oluşmaktadır. Mekanik etki ünitesi (Resim 3.3) ise, dışı iletken malzeme ile sarılmış boru şeklinde birinci kısım ve içerisinde birinci kısımdan daha küçük çapta boru şeklinde hareketli ikinci kısımdan oluşmaktadır. İkinci kısım içerisinde

gömülmüş olarak mikrofon, mıknatıs ve metal bilye bulunmaktadır.



Resim 3.3 Yumurta destek ünitesi ve mekanik etki ünitesi deney düzeneği.


Mekanik etki ünitesinin çalışma prensibini kısaca açıklayacak olursak, birinci kısım üzerinde sarılı iletken malzemeye enerji uygulandığı zaman bir manyetik alan oluşur. Bu manyetik alan ikinci kısımda gömülü olarak bulunan mıknatısa bir itme kuvveti uygular, uygulanan kuvvet neticesinde ikinci kısım hareket eder ve yumurta üzerine çarpar (Resim 3.4 (a)). Çarpışma sonucu akustik ses sinyalleri oluşur. İkinci kısım içerisindeki mikrofon vasıtası ile bu sinyaller alınır ve ardından birinci kısım üzerinde sarılı iletkenlere ters yönde gerilim uygulanarak ters yönde manyetik kuvvet oluşturularak çekme kuvveti oluşturulur ve ikinci kısım başlangıç durumuna getirilir (Resim 3.4 (b)).



Resim 3.4 Yumurtaya çarpma durumu (a), başlangıç durumu (b).

3.1.3 İşlemsel Yükselteç ve Sürücü Devresi


Akustik sinyallerin kuvvetlendirilmesi ve mekanik etki ünitesinin kontrolü için Resim 3.5’de görülen devre tasarlanmıştır. Mekanik etki ünitesinin kontrolü için L293D sürücü entegresi, sinyal kuvvetlendirici için ise LM358N entegresi kullanılmıştır. Devrenin tasarımı Proteus 8.6 ortamında gerçekleştirilmiş olup çizim ortamındaki görüntüsü ve imal edilmiş görüntüsü Resim 3.5’de verilmiştir.



Resim 3.5 Sinyal kuvvetlendirici ve kontrol devresi.

3.1.4 Yazılım

Verilerin bilgisayar ortamına alınması, alınan verilerin görselleştirilmesi, kontrol ve tetikleme sinyali için LABVIEW ortamında program yazılmıştır (Resim 3.6). LABVIEW NI firması tarafından nesne tabanlı geliştirme ortamı olarak piyasaya sürülmüştür. LABVIEW endüstrideki proses kontrollerinde ve veri toplama uygulamalarında yaygın olarak kullanılmıştır (Kutlu ve Turan 2010).



Resim 3.6 LABVIEW arayüz programı.

3.2 Makine Öğrenme

İnternet servislerinin genişlemesi ve teknolojiye yaşanan gelişmeler neticesinde büyük veri kaynakları oluşmaya başladı. Bilim insanları ve araştırmacılar bu veri kümelerini analiz etmek ve işlemek için birçok araştırma yürütmüş ve yöntem araştırmışlardır. Makine öğrenme (MÖ) büyük veri setleri için uygunluğu ve tahmin edebilme yetenekleri sayesinde hızla yayılarak birçok alanda bilim adamları ve araştırmacılar tarafından uygulanmıştır (Chicco 2017).

Makine öğrenme bilgisayarların veya sayısal sinyal işleme yeteneğine sahip sistemlerin

elde edilen veri kümelerini öğrenmesi ve bu veri kümelerini kullanarak verinin sahip olduğu özellikler yardımıyla doğru ve akılcı kararlar verebilme yetisi olarak tanımlanabilir. Başka bir tanım olarak ise bir problemi çözmek veya karar çıktısına ulaşmak için önceden veri ile desteklenmiş, insan gibi öğrenme ve veriler ışığında bir karar verme mekanizmasını taklit eden sistemler olarak da belirtilebilir. MÖ bir yapay zekâ disiplini ve MÖ yöntemlerinin temelinde geleceğe dair tahmin çıkarımında bulunmaları istenmektedir (Yarmatov 2017).

MÖ yöntemlerinin kullanıldığı bazı uygulama alanları aşağıda örnek olarak verilmiştir.

- Robotlu elektrik süpürgesi
- Engelli insanlar için asistan uygulaması
- Resimlerde örüntü tanımlama
- Sürücüsüz otomobiller
- Yüz, iris ve parmak izi tanımlama sistemleri
- Şüpheli tespit sistemleri

Gerçekleştirilen bu tez çalışmasında MÖ disiplinlerinden yapay sinir ağları ve destek vektör makinaları yöntemleri kullanılarak sınıflama işlemleri yapılmaya çalışılmıştır. Takip eden bölümlerde YSA ve DVM yöntemleri teorilerinden bahsedilecektir.


3.2.1 Yapay Sinir Ağları

Yapay sinir ağlarını, insanın öğrenme, öğrenilen bilgiyi saklayabilme ve daha önce tecrübe edilmemiş bir girdi hakkında geçmişe dayalı veriler ışığında tahminde bulunabilme gibi yeteneklerini taklit edebilecek biyolojik sinir ağından esinlenilerek oluşturulan program veya bilgisayar yapıları şeklinden tanımlayabiliriz (Öztemel 2006, Yangın 2017, Sezer 2017).

Yapay sinir ağları, bir birine paralel olarak bağlanmış ve paralel işlem yapabilen proses elemanları, öğrenme sürecinde elde edilen bilginin saklandığı ve bir değere sahip bağlantılardan oluşan hiyerarşik yapılardır (Şekil 3.1). Bir YSA önceden hazırlanmış giriş değerleri ve sonuç değerleri bilinen veri kümeleri aracılığıyla eğitilir. Eğitim esnasında

insan öğrenmesinin bir yansıması olan YSA'lar veriler aracılığıyla öğrenilen bilgi değerini bağlantılar aracılığıyla saklar. Öğrenme işleminin ardından genelleme, çıkarsama yeteneği kazandırılmış YSA sistemine bir giriş veri seti uygulanarak giriş setine karşılık tahminde bulunması beklenir (Öztemel 2006, Yangın 2017).

YSA'ları, matematiksel ifadesi zor ve karmaşık problem türlerine uygulanabilirliği, örnekleri kullanarak öğrenmesi ve harici bir bilgi ihtiyacının olmayışı, doğrusal olmayan problemler için diğer yöntemlere göre daha iyi performans gösterebilmesi, hataya karşı toleranslı yapısı sayesinde eksik bilgi ile çalışabilmesi, değişen problem şartlarına karşı esnek bir yapıya sahip olması, tasarımındaki kolaylık, uygulama maliyetinin düşük olması ve gerçek zamanlı problem çözümleri için uygun bir yöntem olması gibi birtakım avantajlara sahiptir (Aksakal 2017, Yangın 2017, Sezer 2017). YSA, belirtilen bu avantajlar ışığında tez çalışmasında sınıflandırma yöntemi olarak kullanılmıştır.



Şekil 3.1 Basit bir yapay sinir ağı örnek şeması (Öztemel 2006).

3.2.1.1 Yapay Sinir Ağlarının Yapısı ve Temel Elemanları


Yapay sinir ağları sinir hücrelerinin bir araya gelmesiyle oluşmaktadır. Yapay sinir ağını

oluşturan bu küçük yapılar yapay sinir hücresi veya proses elemanı olarak da isimlendirilebilmektedir. Şekil 3.2’de yapay sinir hücresi modeli görülmektedir. Her yapay sinir hücresinin (proses elemanı) beş temel elemanı vardır (Öztemel 2006).

1) Girdiler (Girişler): Girdiler yapay sinir hücresine gelen verilerdir. Bu veriler dış dünyadan veya yapay sinir ağı yapısına bağlı olarak bir başka sinir hücresi tarafından da gelebilir.

2) Ağırlıklar: Ağırlıkların içerdikleri değer ile giriş verisi çarpılarak toplama fonksiyonuna ve oradan toplam olarak aktivasyon fonksiyonuna iletilirler. Girdilerin çıkış üzerindeki etkisi ilişkili oldukları ağırlıkların sayısal değerine bağlıdır.

3) Toplama Fonksiyonu: Giriş değerlerinin ilişkili oldukları ağırlık değerleri ile çarpıldıktan sonra çarpım değerlerinin toplandığı ve net değer hesaplandığı fonksiyon birimidir. Hücrelere gelen girdileri hesaplamak için birçok fonksiyon olmasına rağmen uygulamada yaygın olarak kullanılan ağırlıklı toplam fonksiyonudur (Öztemel 2006).



Şekil 3.2 Yapay sinir hücresi modeli (Sezer 2017).

$$NET = \sum_{i=1}^n X_i * w_i \quad (3.1)$$

Net değerlerin hesaplanmasında kullanılan ağırlıklı toplam fonksiyonu, bağıntı (3.1)’de

verilmiştir (Öztemel 2006, Aydemir 2017). Burada X girdi değerlerini, W ağırlıkları n ise hücreye gelen girdi sayılarını temsil etmektedir. Toplama fonksiyonu seçiminde genel geçer bir kural olmadığı için tasarımcılar deneme yanılma yöntemi ile sistem için en uygun fonksiyonu belirlemeye çalışırlar. Sinir ağında bulunan hücrelerdeki toplama fonksiyonlarının hepsi aynı tür olabileceği gibi farklı tür fonksiyonlarda seçilebilir bu seçim tamamen tasarımcının tercihinine ve deneme yanılma sonuçlarına bağlıdır.

4) Aktivasyon Fonksiyonu: Toplama fonksiyonunda hesaplanan net değer, hücre çıkışı hesaplaması için aktivasyon fonksiyonuna iletilir ve bu fonksiyon aracılığıyla hücre çıkışı hesaplanır. Çok katmanlı ağlarda fonksiyon seçiminde fonksiyonun türevi alınır bir fonksiyon olması gerekmektedir. Toplama fonksiyonundaki gibi ağ tasarımı aktivasyon fonksiyonunun hücrelerde kullanım kombinasyonları için bir kural yoktur tamamen tasarımcının denemelerine ve elde edilen sonuçlara göre şekillenmektedir. Çok katmanlı ağ yapılarında yaygın olarak kullanılan sigmoid aktivasyon fonksiyonu, bağıntı 3.2’de verilmiştir.

$$F(NE\text{T}) = \frac{1}{1 + e^{-NE\text{T}}} \quad (3.2)$$

Bağıntı 3.2’de toplama fonksiyonu tarafından elde edilen NET girdi değerleri yardımıyla hesaplama işlemi gerçekleştirilmektedir. Bu tez çalışmasında aktivasyon fonksiyonu olarak sigmoid fonksiyon kullanılmıştır, fakat sigmoid fonksiyonun dışında aktivasyon fonksiyonları da kullanılmaktadır (Öztemel 2006, Sezer 2017).

5) Hücre Çıktısı: Hücre çıktısı NET değerinin aktivasyon fonksiyonunda işlem görmesi sonucu üretilen çıktı değeridir. Bu değer dış dünyaya veya diğer hücre girişlerine gönderileceği gibi hücre bu değeri kendisine giriş olarak da gönderebilir.

3.2.1.3 Çok Katmanlı Yapay Sinir Ağları


Fiziksel dünyamızda karşılaştığımız problemlerin çoğunluğu doğrusal olmayan problemlerden oluşmaktadır. Doğrusal olmayan problemleri, doğru çizgisi veya doğrusal çizgilerle ayıramadığımız veri kümeleri içeren problemler olarak tanımlayabiliriz.

Doğrusal olmayan problemlere çözüm üretmek veya matematiksel olarak formüle etmek zor ve çoğunlukla imkânsız olabilmektedir.

XOR probleminden yola çıkarak doğrusal olmayan problemlerin çözülebilmesi için Rumelhart ve arkadaşları çok katmanlı yapay sinir ağlarını geliştirmişlerdir. Rumelhart ve arkadaşlarının geliştirdikleri bu model hata yayma modeli veya geriye yayılım modeli olarak da adlandırılmaktadır. Çok katmanlı yapay sinir ağları sınıflandırma, tanıma ve genelleme yapabilme yeteneği gerektiren mühendislik problemleri için çözüm üretebilme yeteneği, bu ağa olan ilgiyi giderek arttırmıştır. Çok katmanlı YSA’larda çıktı değeri ile giriş değeri arasındaki hatayı en aza indirme mantığına dayanan Delta öğrenme kuralı yöntemi kullanılmaktadır (Öztemel 2006, Taşkiran 2016).

Çok katmanlı YSA yapısı benzetim şeması Şekil 3.3’de görülmektedir. Şekil 3.3’de görüldüğü üzere bu ağlar üç katmandan oluşan ağlardır. Bu katmanlar, giriş verilerini herhangi bir işleme tabi tutmadan ara katmanlara iletmekle görevli giriş katmanı, giriş katmanından alınan giriş verilerini işleyerek çıktı katmanına iletmekle görevli ara katmanından ve dış dünyaya çıktı verisi sağlamak için ara katmandan gelen işlenmiş giriş verilerini işleyerek işleminden geçtiği son katman olan çıkış katmanından oluşmaktadır.

Çok katmanlı YSA’ya uygulanan giriş verileri, giriş katmanı ve ara katman üzerinden geçerek çıktı katmanına geçer ve çıktı katmanında giriş verilerine karşılık sistemin çıktı verisi dış dünyaya sunulur. Şekil 3.3’de verilen çok katmanlı YSA modelinde G giriş verilerini, E sinir hücresinin (nöronların) çıkışının sıfır olmasını önlemek amacıyla eklenen eşik değerleri ve Ç çıktı değerlerini temsil etmektedir.



Şekil 3.3 Çok katmanlı YSA modeli (Öztemel 2006, Sezer 2017).

Çok katmanlı YSA yapıları öğretmenli öğrenme prosedürlerine göre çalışırlar. Bu prosedüre göre ağlara giriş verileri ile birlikte giriş verilerine karşılık gelen çıkış verileri de gösterilir. Bu ağların eğitimi için en küçük kareler yöntemi kullanılmaktadır. Giriş verileri uygulanan ağı, uygulanan girişe karşılık gelen çıkış verisini üretmesi istenir. Eğitim sürecinde uygulanan giriş verilerine karşılık üretilen çıkış verisinin, gerçekte beklenen çıkış verisine göre hata payı hesaplanarak hatanın ağı bağlantılarına yayılması suretiyle ağı bağlantı değerlerinin güncellenmesi yapılır ve bu sayede ağı performansı iyileştirilmeye çalışılır. Çok katmanlı ağların eğitiminde kullanılan “Delta Kuralı” ileri doğru hesaplama ve geriye doğru hesaplama olmak üzere iki aşamadan oluşmaktadır (Öztemel 2006).

a. İleri Doğru Hesaplama

İleri doğru hesaplamada ilk olarak veri setindeki giriş verileri ($X_1, X_2, \dots, X_n$) giriş katmanına uygulanır. Daha önceki bölümlerde belirttiğimiz gibi bu katmanda giriş verileri üzerinde herhangi bir işlem gerçekleştirilmez. Giriş katmanındaki bir proses elemanının çıktısı,

$$\zeta_k^i = X_k \quad (3.3)$$

bağıntı 3.3 aracılığıyla belirlenir (Öztemel 2006, Aydemir 2017). Giriş verilerinin ara katmana iletilirken bağlı oldukları bağlantıların ağırlıkları ile çarpılması sonucu elde edilen NET girdi,

$$NET_j^a = \sum_{k=1}^n w_{kj} \zeta_k^i \quad (3.4)$$

bağıntı 3.4 yardımıyla hesaplanır (Öztemel 2006, Aydemir 2017). Bağıntı 3.4’de bulunan w_{kj} k . giriş verisi elemanını j . ara katman proses elemanına (nörona) bağlayan bağlantının ağırlık değerini temsil etmektedir. Hesaplanan net girdi yardımıyla ara katmanda bulunan proses elemanlarının çıktısı NET girdinin aktivasyon fonksiyonundan geçirilmesi ile hesaplanır. Çok katmanlı YSA’larda yaygın olarak sigmoid fonksiyonu kullanıldığı için bağıntı örneğinde sigmoid aktivasyon fonksiyonu seçilmiştir. NET değer kullanılarak j . ara katman çıktısı,

$$\zeta_j^a = \frac{1}{1 + e^{-(NET_j^a + E_j^a)}} \quad (3.5)$$

bağıntı 3.5 yardımıyla hesaplanır (Öztemel 2006, Aydemir 2017). Bağıntı 3.5’de bulunan E_j^a ifadesi j . ara katman proses elemanına bağlanan ve değeri sabit “1” olan eşik değerini ifade etmektedir. Yukarıdaki işlem akış hesaplamaları tüm proses elemanları tarafından gerçekleştirilir. Ara katman ve çıkış katmanı proses elemanları, gelen NET bilgileri aktivasyon fonksiyonundan geçirerek bir çıktı değeri üretirler ve çıktı katmanında (ζ_1 , ζ_2 , ... ζ_n) çıktı değerlerinin hesaplanması ile ağırlık ileri hesaplama işlemi bitirilmiş olunur.

b. Geriye Doğru Hesaplama

Ağırlık ileri doğru hesaplaması sonucunda YSA giriş verilerine karşılık çıktı veri seti üretir. Üretilen çıkış değerleri beklenen (B_1 , B_2 , ... B_n) veri değerlerinden çıkarılması ile hata (H_n) değeri hesaplanır. Hesaplanan hata değeri düşürülmek amacı ile her iterasyonda

hata ağ bağlantılarına yayılarak ağ bağlantı ağırlık değerleri güncellenmeye çalışılır. Çıkış katmanında bulunan n . proses elemanına ait hata değeri,

$$H_n = B_n - \zeta_n \quad (3.6)$$

bağıntı 3.6 yardımıyla hesaplanır ve bu bir çıktı prosesi tarafından üretilen çıkış değerine karşılık düşen hata değeridir. Toplam hata için tüm hata değerlerinin bulunarak toplanması gerekir. Hata değerleri pozitif veya negatif çıkabilir, bu durumda toplam hatanın sıfır çıkmasına karşılık hata değerlerinin kareleri alınarak toplanır ve toplam değerin karekökü alınarak toplam hata değeri hesaplanır.

Ağın performansını yükseltmek için ve doğru çıkış değerleri vermesi için hatanın ağa yayılarak azaltılması gerekmektedir. Hatanın ağa yayılması işlemi bağlantı ağırlıklarının ilgili bağıntılar yardımıyla değiştirilmesi ile gerçekleştirilir. Bu işlem çıktı katmanı ile ara katman arasındaki bağlantı değerlerinin güncellenmesi, ara katmanlar arası bağlantı değerlerinin güncellenmesi ve ara katman ile giriş katmanı arasındaki bağlantıların güncelleştirilmesi işlemleri ile gerçekleştirilmektedir.

- **Çıktı katmanı ile ara katman arasındaki ağırlıkların değiştirilmesi:**

Çıkış katmanındaki n . proses elemanı ile ara katmandaki j . proses elemanını bağlayan bağlantının ağırlık değişim miktarı,

$$\Delta w_{jn}^a = \lambda \delta_n \zeta_j^a + \alpha \Delta w_{jn}^a (t - 1) \quad (3.7)$$

bağıntı 3.7 yardımıyla hesaplanır ve Δw^a değişim miktarını, α momentum katsayısını, λ öğrenme katsayısını ve t ise iterasyon değerini temsil etmektedir (Öztemel 2006, Aydemir 2017). Bağıntıda bulunan δ_n çıktı katmanındaki n . proses elemanı çıktısına karşılık hatayı temsil etmektedir ve

$$\delta_n = f'(NET) \cdot H_n \quad (3.8)$$

bağıntı 3.8 ile hesaplanmaktadır (Öztemel 2006, Aydemir 2017). f' proses elemanında kullanılan aktivasyon fonksiyonunun türevidir. Sigmoid fonksiyonu aktivasyon fonksiyonu olarak seçildiğini varsayarsak fonksiyon türevi, sonucu bağıntı 3.9 elde edilir.

$$\delta_n = \zeta_n(1 - \zeta_n) \cdot H_n \quad (3.9)$$

Değişim miktarlarının hesaplanmasının ardından yeni ağırlık değerlerinin hesaplanması işlemine geçilir. Ağırlık değeri güncellemesi t . iterasyon için,

$$w_{jn}^a(t) = w_{jn}^a(t-1) + \Delta w_{jn}^a(t) \quad (3.10)$$

bağıntı 3.10 yardımıyla hesaplanarak gerçekleştirilir (Öztemel 2006, Aydemir 2017). Eşik değeri ile çıkış katmanı arasındaki ağırlıklarında benzer şekilde değiştirilmesi gerekmektedir. Çıkış katmanındaki eşik değeri ağırlıkları E^c olsun. Bu durumda ağırlık değeri değişimi,

$$\Delta E_n^c(t) = \lambda \delta_n + \alpha \Delta E_n^c(t-1) \quad (3.11)$$

bağıntı 3.11 yardımı ile hesaplanır (Öztemel 2006, Aydemir 2017). Eşik değeri ile çıkış prosesi arasındaki bağlantının t . iterasyon için yeni ağırlık değeri,

$$E_n^c(t) = E_n^c(t-1) + \Delta E_n^c(t) \quad (3.12)$$

bağıntı 3.12 kullanılarak bulunur (Öztemel 2006, Aydemir 2017). İzlenen işlemler neticesinde ara katman ile çıkış katmanı arasındaki bağlantılara hata değerleri yayılarak ağırlık değerleri güncellenmiş olur.

• **Ara katmanlar arası veya giriş katmanı ile ara katman arası ağırlık değerlerinin güncellenmesi:**

Ara katman ile giriş katmanı arasındaki ağırlıkların değişimini Δw^i ile gösterelim. Bu durumda ağırlık değişimleri,

$$\Delta w_{kj}^i(t) = \lambda \delta_j^a \zeta_k^i + \alpha \Delta w_{kj}^i(t-1) \quad (3.13)$$

bağıntı 3.13 yardımıyla hesaplanır (Öztemel 2006, Aydemir 2017). δ^a hata terimi ise,

$$\delta_j^a = f'(NET) \cdot \sum_n \delta_n w_{jn}^a \quad (3.14)$$

bağıntı 3.14 şeklinde olur ve sigmoid fonksiyonu seçilmesi durumunda türev işlemi uygulandıktan sonra hata değeri için,

$$\delta_j^a = \zeta_j^a (1 - \zeta_j^a) \cdot \sum_n \delta_n w_{jn}^a \quad (3.15)$$

bağıntı 3.15 elde edilerek hata değeri hesaplanır (Öztemel 2006, Aydemir 2017). Bu durumda ağırlıkların yeni değerleri,

$$w_{kj}^i(t) = w_{kj}^i(t-1) + \Delta w_{kj}^i(t) \quad (3.16)$$

bağıntı 3.16 yardımı ile hesaplanarak güncellenir (Öztemel 2006, Aydemir 2017). Aynı şekilde ara katmana bağlanan eşik değerlerin bağlantı ağırlıklarının da güncellenmesi gerekmektedir. Eşik değer ile ara katman arasındaki bağlantı ağırlıklarını E^a ile gösterelim. Bu durumda değişim miktarı bağıntısı,

$$\Delta E_j^a(t) = \lambda \delta_j^a + \alpha \Delta E_j^a(t-1) \quad (3.17)$$

bağıntı 3.17 şeklinde olur ve t . iterasyon için ağırlıkların yeni değerleri,

$$E_j^a(t) = E_j^a(t-1) + \Delta E_j^a(t) \quad (3.18)$$

bağıntı 3.18 yardımı ile hesaplanarak güncellenir (Öztemel 2006, Aydemir 2017). Tüm bu işlemler ile ağda bulunan tüm ağırlık değerleri güncellenerek değiştirilmiş olur. Ve öğrenme için belirlenen kritere ulaşana kadar bu işlemler dizisi tekrarlayarak

gerçekleştirilir.

3.2.2 Destek Vektör Makinaları


Destek vektör makinaları V. Vapnik tarafından 1960’larda bir teori olarak ileri sürülmüş ve temel olarak istatistiksel öğrenme teorilerine dayanan, veri kümelerini kullanarak örnekleri uygun sınıflara ayırabilecek doğruyu bulmayı amaçlayan makine öğrenme disiplinlerinden biridir. DVM yüksek performansı ve basit yapısı nedeniyle zaman içerisinde birçok regresyon ve sınıflandırma probleminin çözümü için önerilen bir yöntem olmuştur.

Problem verileri DVM’ye gösterilir ve DVM’den verilerin öz niteliklerindeki karakteristikler yardımıyla verileri ayırma işlemini gerçekleştirebilecek bir fonksiyon üretmesi istenir. Problem verilerini veri uzayında bir nokta olarak düşünürsek DVM’lerinin amacını da veri uzayındaki noktalar arasında bir ayırım düzlemi oluşturarak verileri sınıflandırmaya çalışmak olarak ifade edebiliriz. DVM yöntemi ses tanıma, finans, arıza tespiti, yüz tanıma, tıbbi tanı gibi birçok araştırma disiplinde uygulama alanı bulmuştur (Tuncer 2015, Yahyaoui 2017).

DVM’ları, problemleri kareli optimizasyon problemlerine dönüştürerek çözmesi sonucu diğer yöntemlere göre daha hızlı bir öğrenme ve çözüm süresi sağlaması, sınıflandırma performansı ve kullanılabilirlik yönünden diğer yöntemlere göre daha başarılı olması, genelleme performansı ve öğrenme kabiliyeti problem örneklerinin veri uzayındaki öznitelik sayısı ile sınırlı olmaması ve veri setlerinin az olduğu durumlar dahi uygulanabilmesi gibi avantajlar sağlayabilmektedir (Ayhan ve Erdoğan 2014, Başer ve Apaydın 2015). DVM, belirtilen bu avantajlar ışığında tez çalışmasında YSA ile birlikte sınıflandırma yöntemi olarak kullanılmıştır.

DVM veri sınıflarını ayırabilecek en iyi ayırıcı düzlemi bulmayı amaçlar. Şekil 3.4 temel DVM yapısı görülmektedir. Şekil 3.4 (a)’da görüldüğü gibi iki veri sınıfını ayırabilecek sonsuz doğrular çizilebilir. Fakat DVM yöntemindeki ana amaç verileri maksimum doğrulukla ayırabilecek en etkin ayırıcı düzlemi bulmaktır Şekil 3.4 (b) .

Destek vektör makinaları ilk olarak doğrusal bir sınıflandırma yöntemi olarak ileri sürülmüş fakat zaman içerisinde geliştirilerek doğrusal olmayan sınıflandırma problemlerinin çözümü için de önerilmiştir. Bu açıdan DVM yöntemi doğrusal ve doğrusal olmayan durumlar için işlenecektir.



Şekil 3.4 Veri sınıflarını ayırabilecek doğrular (a) ve veri sınıflarını en iyi ayırabilecek doğru (b) için temel DVM yapısı (Bagherzadi 2014, Yahyaoui 2017).


3.2.2.1 Doğrusal Destek Vektör Makinaları

Problem verilerinin doğrusal olarak ayrılabilceği durumlarda doğrusal DVM yöntemi kullanılmaktadır. İki sınıflı ve doğrusal olarak ayrılabilen bir problemimiz ve bu probleme ait n adet öz nitelik değerine sahip $x_i \rightarrow R^n$ eğitim veri setimiz, her bir veri örneğinin ait olduğu sınıfı belirtecek $y_i \rightarrow \{-1, +1\}$ etiket değerimiz olsun. Bu durumda doğrusal olarak ayrılabilen problem verilerine ait DVM sınıflandırıcı ifadesi,

$$f(x) = \text{sgn}(\omega x_i + b) \quad (3.19)$$

bağıntı 3.19 ile tanımlanır. Burada ω ağırlık vektörünü, $\text{sgn}(\omega x_i + b)$ 'nin işaretini, x her bir örnek için öznitelik vektörünü ve b ise sabit bir değere sahip eşik değeri ifade etmektedir. DVM sınıflandırıcısına uygulanan x_i vektörü için $f(x_i)$ fonksiyon değeri pozitif ise x_i verisi pozitif değerler için etiketlenen sınıfa, eğer negatif ise negatif değerler için etiketlenen diğer sınıfa ayrılarak sınıflandırma işlemi gerçekleştirilmektedir (Ünal,

2016). DVM doğrusal bir sınıflama problemini nasıl gerçekleştirdiği Şekil 3.5’de görülmektedir.



Şekil 3.5 Doğrusal DVM için en uygun ayırıcı düzlem ve destek vektörleri.

Şekil 3.5’de H iki sınıfı en iyi derecede ayırabilecek düzlemi, m iki düzlem arasındaki maksimum aralığı ve H₁ ve H₂ ise en etkin ayırıcı düzleme en yakın iki sınıfa ait örnekleri ifade eden destek vektörlerini ifade etmektedir. Doğrusal DVM sınıflandırıcısında amaç maksimum aralığı (m) bularak bu sayede tüm problem verilerini doğru sınıfa ayırabilmektir. Doğrusal olarak ayrılabilen sınıflar arasındaki açıklık (marjin) $2/\|w\|$ olarak tanımlanmıştır ve maksimum açıklığa ulaşmak için $\|w\|$ en küçük değerini alması gerekmektedir. Maksimum açıklık değeri, bağıntı 3.20’de verilen optimizasyon probleminin çözümü ile bulunur (Bagherzadi 2014, Ünal 2016).

$$\min \frac{1}{2} \|w\|^2 \quad \rightarrow \quad y_i(wx_i + b) \geq 1 \quad (3.20)$$


3.2.2.2 Doğrusal Olmayan Destek Vektör Makinaları

Bazı durumlarda problem verileri doğrusal olmayan bir dağılım gösterebilmektedir. Böyle durumlarda polinomik eğriler ve daireler yardımıyla problem verileri sınıflandırılabilir. Ancak bazı durumlar için uygun polinom ve daire fonksiyonunu bulmak zorlaşabilmektedir. V. Vapnik ve arkadaşları doğrusal olarak sınıflandırılmayan problemler için kernel (çekirdek) fonksiyonu kullanarak doğrusal olmayan problem verilerini sınıflandırılabileceğini öne sürmüşlerdir (Bagherzadi 2014).

Doğrusal olarak ayrılamayan problem verileri kernel olarak adlandırılan ve doğrusal olmayan bir ϕ çekirdek fonksiyonu yardımı ile giriş verileri özellik uzayına dönüştürülür. Bu sayede giriş verileri daha yüksek bir boyuta taşınmış olunur (Şekil 3.6). Bu durumda bir üst boyuta dönüştürülen giriş verilerini ayıracak en iyi ayırıcı düzlem ifadesi,

$$f(x) = \text{sgn}\left(\sum_{i=1}^n \alpha_i y_i K(x_i, x_j) + b\right) \quad (3.21)$$

bağıntı 3.21 şeklinde tanımlanır. Burada α_i Lagrange çarpanlarını $K(x_i, x_j)$ ise verilerin bir üst boyuta dönüştürülmesini sağlayan çekirdek (kernel) fonksiyonunu ifade etmektedir. DVM sınıflandırma performansı parametre seçimine ve çekirdek fonksiyonu türüne göre değişiklik göstermektedir (Bagherzadi 2014, Ünal 2016).



Şekil 3.6 Doğrusal olmayan veri uzayının çekirdek fonksiyonu yardımı ile daha yüksek boyuta dönüştürülmesi (Yahyaoui 2017).

DVM yönteminde yaygın olarak kullanılan çekirdek (kernel) fonksiyonları Çizelge 3.1’de verilmiştir. Çekirdek fonksiyonlarında bulunan a ve b parametreleri çekirdek davranışını tanımlamaktadır.

Çizelge 3.1 Yaygın olarak kullanılan çekirdek fonksiyonları.


Fonksiyon	Açıklama
$K(x_i, x_j) = (x_i x_j + a)^b$	Polinom Çekirdek Fonksiyonu.
$K(x_i, x_j) = \tanh(ax_i x_j - b)$	Sigmoid Çekirdek Fonksiyonu.
$K(x_i, x_j) = x_i^T x_j$	Doğrusal Çekirdek Fonksiyonu.

4. BULGULAR

4.1 Verilerin Elde Edilmesi ve Analizi


Veri setlerini oluşturmak için M (53-63 gr) sınıfı yumurtalar aynı tedarikçiden ve toplam 200 adet yumurta satın alınmıştır. Yumurtalar laboratuvar ortamına getirilerek paketlerdeki sağlam ve çatlak yumurtalar ait oldukları sınıf paketlerine veri alma işlemi için ayrıştırılmıştır.

Bu tez çalışmasında amaç çatlak ve sağlam yumurtaları doğru bir şekilde sınıflandırarak ayırtırmaktır. Bu neticede yumurtalar iki gruba ayrılmıştır bunlar, çatlak yumurta grubu ve sağlam yumurta grubu şeklindedir. Çatlak yumurta grubu 90 adet, sağlam yumurta grubu 100 adet olmak üzere iki grupta toplam 200 adet yumurta örneği bulunmaktadır.



Resim 4.1 Gruplara ait yumurta örnekleri.

Her sınıfa ait örnek sağlam ve çatlak yumurta görselleri Resim 4.1’de, sağlam ve çatlak yumurtalardan elde edilen cevap sinyallerine ait grafikler ise Şekil 4.1’de görülmektedir.



Şekil 4.1 Sağlam ve çatlak yumurtalara ait cevap sinyalleri.

Resim 4.1 'de yumurta üzerindeki mevcut çatlak ve uzantıları çıplak gözle bariz olarak görülebilmektedir. Fakat bazı yumurtalarda gözle görülemeyen gizli çatlaklar bulunabilmektedir. Çatlak tespitinde geleneksel yöntemde bir ışık kaynağının üzerinden yumurtalar geçmesi sonucu operatör tarafından çatlak yumurtalar tespit edilmeye çalışılmakta, fakat mikro çatlaklar için bu yöntemin başarısız olduğu belirtilmiştir (Li *et al.* 2012).



Resim 4.2 Mikro çatlak bulunan yumurtanın baskı uygulanmamış durumdaki görseli.

Resim 4.2’de mikro çatlak barındıran bir yumurtanın herhangi bir basınç etkisi uygulanmadan atmosferik basınç altında görseli verilmiştir. Bu durumda sağlam yumurtadan görsel olarak bir farkı bulunmadığı gözükmemektedir. Resim 4.2’de atmosferik basınç altında görseli verilen yumurtayı el yardımı ile bir sıkıştırma kuvveti uyguladığımızda Resim 4.3’de görüldüğü gibi çatlak bölgelerin ortaya çıktığı gözlemlenmektedir.




Resim 4.3 Mikro çatlak bulunan yumurtanın baskı uygulanmış durumdaki görseli.

Mikro çatlakların görsel olarak normal şartlar altında gözle görülememesi, sınıflandırma problemleri için kullanılan makine görme yöntemleri için de bir engel oluşturmaktadır. Bu engeli aşmak için araştırmacılar yumurtaya bir basınç uygulayarak mikro çatlakları belirginleştirip makine görme yöntemlerini uygulamaya çalışmışlardır (Wang *et al.* 2016).

Yumurta verilerinin elde edilmesi için LABVIEW uygulama geliştirme ortamı üzerinde yazılan ve Resim 3.6’da görseli verilen program kullanılarak 50 çatlak, 50 sağlam olmak üzere toplam 100 adet yumurtaya ait veri örnekleri bilgisayar ortamına aktarılmıştır. Veri alınması işleminde, örnekleme frekansı 50 kHz olup her bir yumurta için 10 000 örnek noktası alınmıştır. Resim 3.6’da görseli verilen program ile alınan ve bir yumurtaya ait


50 kHz örnekleme frekansı ile alınan 10 000 örnek noktasına ait grafik Şekil 4.2’de görülmektedir.



Şekil 4.2 Yumurta cevap sinyali grafiği.

Şekil 4.2’de yumurta örneğine ait sinyal (a) ile belirtilmiştir. Görüldüğü üzere sinyal örneklerinin büyük bir çoğunluğu parazit sinyallerinden ve sistem tarafından oluşturulan harici etmenlerden oluşmaktadır.

Sinyalin bu şekilde kullanılması sınıflandırma yöntemlerinde başarımı düşürebileceği ve işlem sürecini uzatabileceği ihtimallerine karşılık yumurta verileri 0,75 genlik eşik değerinden itibaren 680 örnek noktası uzunluğunda kırılarak yumurtaya ait faydalı kısım elde edilmiştir. Bu sayede mekanik etkinin yumurta yüzeyine temas etmesi ile başlamasından, yumurta yüzeyinden temasın kesilmesine kadar olan süreçte oluşan ve yumurta tarafından üretilen akustik ses sinyal örnek verileri elde edilmiştir. Belirlenen eşik değere göre kırma işlemi uygulanmış sinyal grafiği Şekil 4.3’de görülmektedir.




Şekil 4.3 Sadece yumurta sinyaline ait veri grafiği.

Çatlak yumurta örneklerine ait veriler mekanik etkinin çatlak bölgeye dik olarak uygulanması ile elde edilmiştir. Ayrıca çatlak bölgeden uzaklaştıkça yumurta sinyalindeki varsa değişimin gözlemlenmesi için çatlak yumurtalardan çatlak bölgenin uzağındaki bölgelerden de örnekler alınmıştır.


Resim 4.4’de çatlak bir yumurtaya ait işaretlenmiş çatlak bölge ve çatlak bölgenin uzağındaki noktanın görseli verilmiştir. Çatlak bölgeden, çatlağın uzağındaki noktadan ve sağlam bir yumurtadan alınan örneklere ait grafik Şekil 4.4’de verilmiştir. Şekil 4.4’de (1) numaralı sinyal Resim 4.4’de verilen çatlak yumurtanın çatlak bölgesinden alınan örneklere ait sinyalin, (2) numaralı sinyal sağlam yumurtadan alınan örneklere ait sinyalin ve (3) numaralı sinyal ise Resim 4.4’de verilen çatlak bölgenin uzağındaki noktadan alınan örneklere ait sinyalin grafikleridir.

Şekil 4.4’de çatlak yumurtanın çatlak noktasından (1), çatlak noktanın uzağındaki bir noktadan alınan (3) ve sağlam yumurtadan alınmış (2) cevap sinyali grafikleri verilmiştir. Şekil 4.4’de de görüleceği üzere çatlak bölgenin uzağındaki bir noktadan alınan sinyal cevabındaki tepe değerlerin genliğinde bir atış ve sinyal salınım süresinin uzadığı

görülmüştür. Sonuç olarak çatlak yumurtaya ait uzak nokta sinyali, çatlak yumurtaya ait çatlak bölge sinyalinden uzaklaşarak, sağlam yumurta sinyaline ait karakteristik sinyale benzediği görülmüştür.



Resim 4.4 Çatlak bölge ve uzağındaki bir noktanın görseli.



Şekil 4.4 Sağlam yumurta ve çatlak yumurtanın farklı noktalarından alınan sinyal grafikleri.

4.2 Sınıflandırma Yöntemlerinin Uygulanması

Bu çalışmada DVM ve YSA yöntemleri kullanılarak çatlak ve sağlam yumurtaların tespit edilerek uygun oldukları gruba ayrılması işlemi gerçekleştirilmeye çalışılmıştır. Bu bağlamda yumurta verileri kullanılarak oluşturulacak SVM ve YSA yapay zeka modelleri için LABVIEW programı ve AML (Analytics and Machine Learning Toolkit) araçları kullanılmıştır. AML NI firması tarafından LABVIEW yazılım ortamı için üretilmiş yapay zekâ fonksiyonlarını içeren eklenti aracıdır (İnt.Kyn.2).

Eğitim veri seti için 50 adet çatlak yumurta örneği, 50 adet sağlam yumurta örneği olmak üzere toplam 100 adet yumurta örneği kullanılmıştır. Geriye kalan 40 çatlak yumurta örneği ile 60 sağlam yumurta örneği oluşturulacak olan yapay zekâ modelleri kullanılarak test edilmesi için kullanılmıştır. Eğitim için kullanılacak veri üçe bölünerek üçte biri test için geriye kalan kısmı ise eğitim işlemi için program algoritması tarafından paylaştırılmaktadır.

Yapay Zeka Türü

Neural Network

Eğitim Veri Seti Dosya Yolu (CSV)

C:\Users\BLC\Desktop\Yeni klasör\Tez\Veriler\Programla 0,75eşik değere göre alınan tez devresi verileri\Veri_setleri_CSV\Egitim_veri_seti.csv

Yapay Zeka Model Çıktısı Dosya Yolu (JSON)

C:\Users\BLC\Desktop\Yeni klasör\Tez\Veriler\Programla 0,75eşik değere göre alınan tez devresi verileri\Model_dosyaları\ANN_MODEL.json

Yapay Sinir Ağı Modeli

Gizli Katman Sayısı

40

Çıkış Katmanı Aktivasyon Fonksiyon Tipi

Sigmoid

Ara Katmanı Aktivasyon Fonksiyon Tipi

Sigmoid

Çapraz Doğrulama Değerleri (YSA)

Doğruluk	Hassasiyet
0,99	0,99
recall	f1
0,99	0,99

Yapay Zeka Eğitim Arayüzü

Şekil 4.5 YSA eğitim arayüzü görünümü.

Şekil 4.5’de YSA modeli oluşturulması ve eğitimi için hazırlanan program görülmektedir. YSA modelinde ara katmana ait kırk adet nöron bulunmaktadır. Ara katman ile çıkış katmanı için aktivasyon fonksiyonları sigmoid fonksiyon olarak seçilmiştir. YSA modeli oluşturulurken nöron sayısı ve aktivasyon fonksiyonu seçimi için genel geçer bir kural olmadığı için deneme yanılma sonucu ağ yapısının eğitiminde en iyi sonuçların elde edildiği fonksiyon ve nöron sayısı seçilmiştir (Öztemel 2006). Eğitim sonucunda eğitilen ağ test aşamasından tahmin işlemini 0,99 doğruluk ile gerçekleştirdiği görülmüştür.

The image shows a software interface for training a Support Vector Machine (SVM) model. The interface is titled 'Yapay Zeka Eğitim Arayüzü' (Artificial Intelligence Training Interface). It contains several sections for configuring the model and training process.

- Yapay Zeka Türü** (Artificial Intelligence Type): A dropdown menu set to 'SVM'.
- Eğitim Veri Seti Dosya Yolu (CSV)** (Training Data Set File Path (CSV)): A text box containing the path 'C:\Users\BLC\Desktop\Yeni klasör\Tez\Veriler\Programla 0,75eşik değere göre alınan tez devresi verileri\Veri_setleri_CSV\Egitim_veri_seti.csv'.
- Yapay Zeka Model Çıktısı Dosya Yolu (JSON)** (Artificial Intelligence Model Output File Path (JSON)): A text box containing the path 'C:\Users\BLC\Desktop\Yeni klasör\Tez\Veriler\Programla 0,75eşik değere göre alınan tez devresi verileri\Model_dosyaları\SVM_MODEL.json'.
- Destek Vektör Makinaları Modeli** (Support Vector Machines Model): A section for configuring the SVM model.
 - Çekirdek Fonksiyonu** (Kernel Function): A dropdown menu set to 'Linear'.
 - c**: A text box containing the value '10'.
- Çapraz Doğrulama Değerleri (DVM)** (Cross Validation Values (DVM)): A section for configuring cross-validation values.
 - Doğruluk** (Accuracy): A text box containing the value '1'.
 - Hassasiyet** (Precision): A text box containing the value '1'.
 - recall**: A text box containing the value '1'.
 - f1**: A text box containing the value '1'.

Yapay Zeka Eğitim Arayüzü

Şekil 4.6 DVM eğitim arayüzü görünümü.

Şekil 4.6’de DVM modelinin oluşturulması ve eğitim için hazırlanan program görülmektedir. Şekil 4.6’da c ceza parametresi 10 olarak ve çekirdek fonksiyonu olarak da doğrusal çekirdek fonksiyonu seçildiği görülmektedir. Eğitim sonucunda modelin 1 doğruluk değeri ile test için ayrılan verileri tahmin ettiği görülmüştür.

YSA ve DVM eğitim programlarında bulunan çapraz doğrulama değerleri oluşturulan modelin performansı hakkında bilgi edinmemizi sağlamaktadır. Bu bağlamda çapraz doğrulama değerlerini ve hesaplamada kullanılan bağıntılar aşağıda incelenmiştir. Bağıntılarda kullanılacak etiket açıklamaları Çizelge 4.1’de verilmiştir.

Çizelge 4.1 Performans değerlerinin bağıntılarında kullanılan etiket ve açıklamaları.

Etiket	Açıklama
TP	Doğru onaylanmış.
TN	Hatalı onaylanmış.
FP	Doğru reddedilmiş.
FN	Hatalı reddedilmiş.
P	Toplam pozitif örnek sayısı.
N	Toplam negatif örnek sayısı.

- Doğru olarak sınıflandırılan örnek sayısının tüm örnek sayısına oranı bize doğruluk değerini vermektedir ve doğruluk değerinin hesaplanmasında kullanılan ifade bağıntı 4.1’de verilmiştir (İnt.Kyn.3).

$$\text{doğruluk} = \frac{TP + TN}{P + N} \quad (4.1)$$

- Pozitif değere sahip ve pozitif olarak sınıflandırılan örneklerin sayısının, pozitif değer sınıflarına sınıflandırılan toplam örnek sayısına oranı ise hassasiyet değerini vermektedir. Hassasiyet bize tahminlerin gerçekte olması gereken değerlerle arasındaki ilgi değerini vermektedir ve hesaplamada kullanılan ilgili ifade bağıntı 4.2’de verilmiştir (İnt.Kyn.3).

$$\text{hassasiyet} = \frac{TP}{TP + FP} \quad (4.2)$$

- Recall, pozitif değere sahip ve pozitif olarak sınıflandırılan örneklerin sayısının, gerçek pozitif değere sahip tüm örneklere oranıdır ve bu değerinin hesaplanmasında kullanılan ifade bağıntı 4.3’de verilmiştir (İnt.Kyn.3).

$$\text{recall} = \frac{TP}{TP + FN} \quad (4.3)$$


- F1 ise doğruluk ve hassasiyet değerlerinin harmonik ortalamasıdır ve F1 değerinin hesaplanmasında kullanılan ifade bağıntı 4.4’de verilmiştir (İnt.Kyn.3).

$$f1 = \frac{2TP}{2TP + FP + FN} \quad (4.4)$$

Şekil 4.5 ve Şekil 4.6’da görselleri verilen YSA ve DVM eğitim programları aracılığıyla eğitilen yapay zekâ modelleri YSA için 0,99 DVM için 1 doğruluk değerlerine ulaşmasından ötürü performans bakımından yeterli görülerek eğitim işlemi sonlandırılarak modeller kullanılmak üzere kaydedilmiştir.

Daha önce, tez çalışmasında kullanılması için 90 çatlak 110 sağlam yumurta olmak üzere toplamda 200 yumurta örneğimiz olduğunu belirtmiştik. Bu 200 yumurtanın 50 çatlak, 50 sağlam olmak üzere toplam 100 adet yumurta örneği YSA ve DVM modellerinin eğitimi için kullanılmıştır. Geriye kalan 40 adet çatlak, 60 adet sağlam olmak üzere toplam 100 yumurta örneği eğitilen DVM ve YSA modelleri kullanılarak üretecekleri sonuçları gözlemlenmesi ve ikinci bir test için kullanılmıştır. Eğitilen YSA ve DVM yapıları 40 çatlak yumurta örneğinin ve 60 sağlam yumurta örneğinin tümünü ait oldukları sınıf etiketine sınıflandırdığı görülmüştür.


DVM ve YSA modellerinin kullanılarak gerçek zamanlı olarak bir yumurtanın çatlak tespiti işlemini gerçekleştirmesi için gerçek zamanlı programı LABVIEW ortamında geliştirilmiştir. Yumurta çatlak tespit program Şekil 4.7’de görseli verilmiştir.



Şekil 4.7 Gerçek zamanlı olarak sağlam yumurta için YSA tahmin sonucu.

Geliştirilen gerçek zamanlı çatlak tespiti programı koşturulması ile yumurtadan 50 kHz örnekleme frekansı ile örnekler alıp bu örneklerden yumurta örneğine ait olan kısmı, belirlenen eşik değere ve veri uzunluğuna göre ayırarak yapay zekâ algoritmasına giriş olarak hazırlamaktadır. Şekil 4.7 ve Şekil 4.8’de verilen görsellerde bir yumurtaya ait 10 000 örnek noktası, Cevap Sinyali grafiğinde ve 0,75 eşik değerinden itibaren alınan 680 örnek noktası uzunluğundaki sadece yumurta sinyaline ait olan kısım Eşik Değere Göre Alınan Veri isimli grafikte görülmektedir.

Şekil 4.7’de sağlam yumurta örneğinin, daha önce eğitilen YSA modeli kullanılarak gerçek zamanlı olarak sınıflandırma sonucu görülmektedir.



Şekil 4.8 Gerçek zamanlı olarak çatlak yumurta için YSA tahmin sonucu.

Şekil 4.8’de ise çatlak yumurta örneğinin, daha önce eğitilen YSA modeli kullanılarak gerçek zamanlı olarak sınıflandırma sonucu görülmektedir.

Geliştirilen program üzerinde sınıflandırma metodu dinamik olarak seçilebilmektedir. Yumurta örneğinden alınan sinyalin girilen parametreler kullanılarak kırılmasının ardından program üzerinden seçilen yapay zekâ metoduna giriş verisi olarak uygulanır. Yapay zekâ modeline uygulanan yumurta giriş verisine karşılık seçilen yapay zekâ modeli tarafından çıkış olarak yumurta sınıf tahmini üretilmektedir.

Gerçek zamanlı çatlak tespiti işlemlerinde kullanılan yumurtalar haricen alınmıştır eğitim ve test işleminde kullanılmamış verilerdir. Gerçek zamanlı yumurta çatlak tespit programında kullanılan ve daha önce eğitilen yapay zekâ modellerinin yumurta sınıflarını gerçek zamanlı uygulamada da doğru olarak sınıflandırdığı görülmüştür.



5. TARTIŞMA VE SONUÇ

Yumurta insan beslenmesinin temel gıdalarından birisidir. Bu sebepten ötürü yumurtaya olan talep giderek artmaktadır. Artan tüketime karşı ihtiyaç duyulan üretim artışına paralel olarak yumurta üretim çiftlikleri için birçok yumurta toplama ve ayırma makinaları geliştirilmiştir. Yumurtaların toplanması, taşınması, sınıflandırılması, kan, kir, çatlak ve kırık gibi işlem süreçleri bu makinalar tarafından gerçekleştirilmektedir. Yumurtalar bu makinelerdeki işlem süreçlerinde, taşınma, paketleme vb. durumlarda etkilere maruz kalarak yumurtaların kabuklarında çatlaklar ve kırıklar meydana gelebilmektedir. Oluşan çatlak ve kırıklar yumurtayı, bakterilere ve zararlı mikrobiyolojik yapılara karşı savunmasız hale getirebilmektedir.

Gerçekleştirilen bu tez çalışmasında amaç, yukarıda belirtilen etmenler sonucu yumurtalarda oluşan çatlakların tespit edilerek sınıflandırılmasıdır. Çalışma kapsamında 100 adet yumurta örneği, geliştirilen veri alma yazılımı ile verileri bilgisayar ortamına alınmıştır. Verilerin alınması işleminin ardından örnek verileri içerisinde sadece yumurta örneğine ait olan bölümler kırılarak yapay zekâ yöntemleri için giriş eğitim veri setleri elde edilmiştir. Bu sayede bir yumurtaya ait 10 000 örnek noktası 680 örnek noktasına düşürülmüştür. Daha sonra 50 sağlam yumurta, 50 çatlak yumurta örneği içeren eğitim setleri kullanılarak DVM ve YSA algoritmaları eğitilerek YSA ve DVM modelleri oluşturulmuştur.

Yapay zekâ yapıları eğitim işlemleri, YSA için 0,99 doğruluk ve DVM için 1 doğruluk değeri ile gerçekleştiği görülmüştür. Ayrıca daha önce ayrılan 40 çatlak ve 60 sağlam yumurta örneği eğitilen YSA ve DVM yapılarına gösterilmesi sonucunda her iki yapay zekâ yönteminin de tüm örnekleri doğru olarak sınıflandırıldığı görülmüştür. Bu tez çalışmasında uygulanan yöntemler neticesinde elde edilen doğruluk değerleri, çatlak yumurta tespitinde YSA ve DVM için literatürde mevcut değerlerin üzerindedir. Ayrıca gerçekleştirilen bu tez çalışması ile gözle görülemeyen ve görüntü işleme ile çatlak tespitinde bir sorun teşkil eden mikro çatlaklar da başarılı bir şekilde tespit edilerek sınıflandırılmıştır.

YSA yumurta tahmin sonucunu 0,99 doğruluk ile 120 milisaniye civarında üretirken,

DVM yumurta tahmin sonucunu 1 doğruluk değeri ile 20 milisaniye civarında ürettiği görülmüştür. Bu bağlamda gerek hız gerekse doğruluk bakımından DVM'nin bu tez çalışması için daha iyi sonuç verdiği söylenebilir.

Tez kapsamında gerçek zamanlı olarak yumurta çatlak tespiti işleminin gerçekleştirilebilmesi için bir yazılım geliştirilmiştir. Bu yazılım, gerçek zamanlı olarak yumurtadan alınan örneklerin sadece yumurtaya ait olan kısmını ayırarak, yazılım üzerinden seçilen yapay zekâ yöntemine uygulanmasının ardından gerçek zamanlı olarak yumurta için tahmin sınıfı üretmektedir. Yazılım arayüzü üzerinden DVM veya YSA yöntemleri herhangi bir sınıflandırma işlemi sürecinde seçim imkânı sağlamaktadır ve bu sayede geliştirilen yazılım ile artı bir esneklik sağlanmıştır.

Tez çalışmasındaki deneysel düzenek ve yazılım ile gerçek zamanlı olarak sınıflandırma işlemleri yumurta tahmin sonucu yumurtanın fiziksel boyutları ile değişebilmekle birlikte yaklaşık olarak 450-550 milisaniye arasında gerçekleşmektedir. Bu tez çalışmasında deneysel düzenek tek yumurta için tasarlanmış ve işlem süreçleri bu çerçevede şekillenmiştir. Bu nedenle belirtilen gecikme bu tez çalışmasındaki sistem için çok önemli olmayabilir. Fakat endüstride bulunan ve gerçek zamanlı olarak yumurta sınıflandıran makinelerde yumurtadan alınan veri ile sınıflandırma sonucunun üretildiği noktaya kadar olan süre makine için verim ve hız açısından önemli olabilmektedir. Bu nedenle sınıflandırma sonucunun hızlı bir şekilde üretilebilmesi önem arz etmektedir.

Yumurta cevap sinyalinden sadece yumurta örnek noktalarını ayırma işlemi, örnekleme bitiminden sonra alınan veri üzerinde gerçekleşmektedir. Yumurta verisinin ayrılması işlemi, örnekleme esnasında analog verinin eşik değere göre karşılaştırarak alınması sonucu sistemin hızının arttırılabileceği düşünülmektedir. Ayrıca farklı algoritmalar geliştirilerek uygulanabilecek ayırma işlemi, sistemin performans ve hızında iyileştirmeler sağlayacağı düşünülmektedir.

6. KAYNAKLAR

- Akın, B. (2017). Yapay sinir ağlarıyla konya bölgesinde kullanıcı doğal gaz tüketim öngörüsü. Yüksek Lisans Tezi. İstanbul Üniversitesi, Enerji Enstitüsü, İstanbul.
- Aksakal, A. (2017). Türkiye'deki resmi dairelerde talep tarafı yönetimi ve yapay zeka uygulamaları. Yüksek Lisans Tezi. Kırıkkale Üniversitesi, Fen Bilimleri Enstitüsü, Kırıkkale.
- Aydemir, F. (2017). QCM tabanlı sensör dizisiyle sıvı algılama sistemi tasarımının gömülü sistemlerle gerçekleştirilmesi. Doktora Tezi. Dumlupınar Üniversitesi, Fen Bilimleri Enstitüsü, Kütahya.
- Ayhan, S. ve Erdoğan, Ş. (2014). Destek vektör makineleriyle sınıflandırma problemlerinin çözümü için çekirdek fonksiyonu seçimi. *Eskişehir Osmangazi Üniversitesi İktisadi ve İdari Bilimler Dergisi*, **9** (1): 175-198.
- Attar, M. and Fathi, M. (2014). Non-Destructive acoustic resonance method for evaluating eggshell strength and thickness. *International Journal of Biophysics*, **4** (1): 9-15.
- Bagherzadi, N. (2014). Post operative prognostic prediction of esophageal cancer cases using bayesian networks and support vector machines. Yüksek Lisans Tezi. Middle East Technical University, Graduate School of Informatics, Ankara.
- Başer, F. ve Apaydın, A. (2015). Sınıflandırma amaçlı destek vektör makinelerinin lojistik regresyon ile karşılaştırılması. *Anadolu University of Sciences and Technology-B: Theoretical Sciences*, **3** (2): 53-65.
- Bechou, L., Dallet, D., Dante, Y., Daponte, P., Ousten, Y. and Rapuano, S. (2003). An improved method for automatic detection and location of defects in electronic components using scanning ultrasonic microscopy. *IEEE Transactions On Instrumentation and Measurement*, **52** (1): 135-142.
- Chicco, D. (2017). Ten quick tips for machine learning in computational biology. *BioData Mining*, 10-35.

- DE Aguiar, P. R., Blanchi, E. C., Serni, P. J. and Lançon, P. N. (2002). Control of thermal damage grinding by digital signal processing of raw acoustic emission. Seventh International Conference on Control, Automation, Robotics And Vision, Singapore, 1392-1397.
- De Ketelaere, B., Coucke, P. and De Baerdemaeker, J. (2000). Eggshell crack detection based on acoustic resonance frequency analysis. *J. Agric. Engng Res.*, **76**: 157-163.
- Deng, X., Wang, Q., Wu, L., Gao, H., Wen, Y. and Wang, S. (2009). Eggshell crack detection by acoustic impulse response and support vector machine. *African Journal of Agricultural Research*, **4** (1): 40-48.
- Deng, X., Xiaoyan, Q., Chen, H. and Xie, H. (2010). Eggshell crack detection using a wavelet-based support vector machine. *Computers and Electronics in Agriculture*, **70**: 135-143.
- Fang, W. and Youxian, W. (2011). Detecting preserved eggshell crack using machine vision. International Conference of Information Technology Computer Engineering and Management Sciences, IEEE Computer Society, 62-65.
- Fang, W., Zuojun, T., Fei, C. and Youxian, W. (2013). Detecting cracks of preserved egg based on polarized light. Fifth International Conference on Intelligent Human-Machine Systems and Cybernetics, IEEE Computer Society, 66-69.
- Hacıoğlu, C. (2014). Derinlikli öğrenme kullanılarak konuşmadan uyku/uykusuzluk tespiti. Yüksek Lisans Tezi. İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.
- Jin, C., Xie, L. and Ying, Y. (2015). Eggshell crack detection based on the time-domain acoustic signal of rolling eggs on a step-plate. *Journal of Food Engineering*, **153**: 53-62.
- Kandpal, M., Kakar, V. K. and Verma, G. (2013). Classification of ground vehicles using acoustic signal processing and neural network classifier. 512-518.
- Kovač, J., Legat, A., Zajec, B., Kosec, T. and Goverkar, E. (2015). Detection and characterization of stainless steel SCC by the analysis of crack related acoustic emission. *Ultrasonics*, **62**: 312-322.

- Kutlu, A. ve Turan, C. (2010). Elektronik deney modüllerinin labview ile kontrolü. *SDU International Journal of Technologic Sciences*, **2** (3): 1-8.
- Li, P., Wang, Q., Zhang, Q., Cao, S., Liu, Y. and Zhu, T. (2012). Non-destructive detection on the egg crack based on wavelet transform. 2012 International Conference on Future Computer Supported Education, IERI Procedia, 372-382.
- Li, Y., Dhakal, S. and Peng, Y. (2012). A machine vision system for identification of micro-crack In eggshell. *Journal of Food Engineering*, **109**: 127-134.
- Lin, H., Zhao, J.-w., Chen, Q.-s., Cai, J.-r. and Zhou, P. (2009). Eggshell crack detection based on acoustic response and support vector data description algorithm. *Eur Food Res Technol*, **230**: 95-100.
- Lu, W., Zhang, C., Luo, H., Ding, W., and Wang, L. (2015). Micro-Cracks detection of eggshells based on a magnetostrictive transducer. *Sensors & Transducers*, **186** (3): 49-54.
- Manik, H. M. (2011). Underwater acoustic signal processing for detection and quantification of fish. 2011 International Conference on Electrical Engineering and Informatics, Bandung, 3-5.
- Omid, M., Soltani, M., Dehrouyeh, M. H., Mohtasebi, S. S. and Ahmadi, H. (2013). An expert egg grading system based on machine vision and artificial intelligence techniques. *Journal of Food Engineering*, **118**: 70-77.
- Öztemel, E. (2006). Yapay Sinir Ağları. Papatya Yayıncılık, İstanbul.
- Öztürk, N. ve Gangal, A. (2014). Görüntü işleme teknikleri ile beyaz yumurtalar üzerindeki yumurta kabuğu kusurlarının algılanması. 22nd Signal Processing and Communications Applications Conference, IEEE, 810-813 .
- Sezer, Ö. F. (2017). Sürekli tavlama hatlarında enerji giderinin kalite ve boyut değerlerine göre optimize edilmesi ve geçişlerde operatör davranışlarının modellenmesi. Doktora Tezi. Sakarya Üniversitesi, Sosyal Bilimler Enstitüsü, Sakarya.
- Strnková, J. and Nedomová, Š. (2013). Eggshell crack detection using dynamic frequency analysis. MendelNet Conference, Brno, 603-608.

- Sun, L., Bi, X.-k., Lin, H., Zhao, J.-w. and Cai, J.-r. (2013). On-line detection of eggshell crack based on acoustic resonance analysis. *Journal of Food Engineering*, **116**: 240-245.
- Taşkıran, M. (2016). İnverter klima akıllı etkileşim sistemi tasarımı. Yüksek Lisans Tezi. Yıldız Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.
- Tuncer, E. (2015). Uyku evrelemede çeşitli dalgacık ve sınıflandırıcıların performans analizi. Yüksek Lisans Tezi. Kocaeli Üniversitesi, Fen Bilimleri Enstitüsü, Kocaeli.
- Ünal, F. (2016). Yüksek gerilim doğru akım enerji iletiminde meydana gelen arızaların sayısal koruma yöntemleri ile belirlenmesi. Yüksek Lisans Tezi. Fırat Üniversitesi, Fen Bilimleri Enstitüsü, Elazığ.
- Wang, H., Mao, J., Zhang, J., Jiang, H. and Wang, J. (2016). Acoustic feature extraction and optimization of crack detection for eggshell. *Journal of Food Engineering*, **171**: 240-247.
- Yahyaoui, A. (2017). Göğüs hastalıklarının teşhis edilmesinde makine öğrenmesi algoritmalarının kullanılması. Doktora Tezi. Sakarya Üniversitesi, Fen Bilimleri Enstitüsü, Sakarya.
- Yangın, A. (2017). Yapay sinir ağı teknikleri kullanarak eğitim yayıncılığı sektöründe veri madenciliği. Yüksek Lisans Tezi. İstanbul Aydın Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.
- Yarmatov, B. (2017). Hibrid makine öğrenmesi teknikleri ile yol yüzey durumunun modellenmesi. Yüksek lisans tezi. Süleyman Demirel Üniversitesi, Fen Bilimleri Enstitüsü, Isparta.
- Yoo, H., Liu, Z., Quang, N. N., Kim, S. and Bien, F. (2016). Implementation of nondestructive crack detection system for automotive press panel. *IEEE Sensors Journal*, **16** (2): 383-389.
- Zhao, S., Li, B., Ge, Y. and Tong, W. (2010). Intelligent diagnosis algorithm of power equipment based on acoustic signal processing. Third International Workshop on Advanced Computational Intelligence, Jiangsu, 661-665.

Zhao, Y., Wang, J., Lu, Q. and Jiang, R. (2010). Pattern recognition of eggshell crack using PCA and LDA. *Innovative Food Science and Emerging Technologies*, **11**: 520-525.



İnternet Kaynakları

- 1) <http://www.ni.com/compactrio/>, 23.12.2017
- 2) <http://sine.ni.com/nips/cds/view/p/lang/en/nid/216169>, 14.03.2018
- 3) http://zone.ni.com/reference/en-XX/help/377059A-1/lvaml/aml_train_classification_model/, 28.06.2018
- 4) <https://en.wikipedia.org/wiki/CompactRIO>, 28.06.2018



ÖZGEÇMİŞ

Adı Soyadı : ZEKERİYA BALCI
Doğum Yeri ve Tarihi : GÜMÜŞHANE 1991
Yabancı Dili : İNGİLİZCE
İletişim (Telefon/e-posta) : 05439664964 / balcizekeriya29@gmail.com

Eğitim Durumu

Lise : Atatürk A.T.L ve E.M.L (2011)
Lisans : Afyon Kocatepe Üniversitesi, Teknoloji Fakültesi,
Elektrik Elektronik Mühendisliği Bölümü, (2012-
2016)
Yüksek Lisans : Afyon Kocatepe Üniversitesi, Fen Bilimleri
Enstitüsü, Elektrik Elektronik Mühendisliği
Anabilim Dalı, (2016-2018)

Başarı ve Ödüller :

Bursa Atatürk EM ve Anadolu Teknik meslek lisesinin Elektrik-Elektronik bölümünden birincilik ile mezun oldum.

Afyon Kocatepe Üniversitesi Elektrik-Elektronik Mühendisliği bölümünden birincilik derecesi ile mezun oldum.

Afyon Kocatepe Üniversitesi Teknoloji Fakültesinden fakülte bazında üçüncülük derecesi ile mezun oldum.