



T.C.
KIRŞEHİR AHİ EVRAN ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
İLERİ TEKNOLOJİLER ANABİLİM DALI

**MAKİNE ÖĞRENMESİ İLE ALABALIK, ÇİPURA
VE LEVREK BALIKLARININ KALİTE
SEVİYELERİNİN VE TÜRLERİNİN BELİRLENMESİ**

ÖZKAN DOĞAN

YÜKSEK LİSANS TEZİ

KIRŞEHİR / 2023



T.C.
KIRŞEHİR AHİ EVRAN ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
İLERİ TEKNOLOJİLER ANABİLİM DALI

**MAKİNE ÖĞRENMESİ İLE ALABALIK, ÇİPURA
VE LEVREK BALIKLARININ KALİTE
SEVİYELERİNİN VE TÜRLERİNİN BELİRLENMESİ**

ÖZKAN DOĞAN

YÜKSEK LİSANS TEZİ

DANIŞMAN
Doç. Dr. Emre YAVUZER

KIRŞEHİR / 2023

TEZ BİLDİRİMİ

Tez içindeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edilerek sunulduğunu, ayrıca tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade bilginin kaynağına eksiksiz atıf yapıldığını bildiririm.

ÖZKAN DOĞAN



20.04.2016 tarihli Resmî Gazete’de yayımlanan Lisansüstü Eğitim ve Öğretim Yönetmeliğinin 9/2 ve 22/2 maddeleri gereğince; Bu Lisansüstü teze, Kırşehir Ahi Evran Üniversitesi’nin aboneli olduğu intihal yazılım programı kullanılarak Fen Bilimleri Enstitüsü’nün belirlemiş olduğu ölçütlere uygun rapor alınmıştır.



ÖNSÖZ

Yüksek Lisansa başlamamda ve yüksek lisans ders sürecinde kendisini tanıdığım günden bu yana gösterdiği sakin ve sabırlı hali ile her zaman bana örnek olmasının yanı sıra bir bilim adamının nasıl çalışması gerektiğini kendisinden öğrendiğim değerli danışmanım Doç. Dr. Emre YAVUZER'e, MATLAB programının kullanımında bana göstermiş olduğu emek ve sabır için Dr. Öğr. Üyesi Memduh KÖSE'ye, tezin en başından beri her aşamada yanımda olan ve desteklerini esirgemeyen Dr. Öğr. Üyesi Şefik TEKLE hocama ve çalışmalarım boyunca sabır göstererek beni her zaman destekleyen babam Abdullah DOĞAN ve annem Nazende DOĞAN'a çok kıymetli eşim Mehtap DOĞAN ve çocuklarım Nazende Nisa DOĞAN ve Abdullah DOĞAN'a büyük bir içtenlikle teşekkür ederim.

Ocak, 2023

ÖZKAN DOĞAN

İÇİNDEKİLER

ÖNSÖZ	iv
İÇİNDEKİLER.....	v
ŞEKİL LİSTESİ	vii
SİMGE VE KISALTMA LİSTESİ.....	ix
ÖZET	x
ABSTRACT	xii
1 GİRİŞ.....	1
1.1 Amaç	3
1.2 Önem.....	3
1.3 İlgili Çalışmalar	4
2 GENEL KISIMLAR	7
2.1 Derin Öğrenme	7
2.2 Evrişimsel Sinir Ağı (ESA)	7
2.3 Evrişimsel Sinir Ağlarını Oluşturan Katmanlar.....	8
2.3.1 Giriş Katmanı	8
2.3.2 Konvolüsyon Katmanı	8
2.3.3 Havuzlama Katmanı	8
2.3.4 Tam Bağlantı Katmanı.....	8
2.3.5 Dropout Katmanı	9
2.3.6 Sınıflandırma Katmanı	9
3 MALZEME VE YÖNTEM	10

3.1	Balık Materyali	10
3.2	Görüntü Verilerinin Elde Edilmesi	10
3.3	Makine Öğrenme Koşulları.....	14
4	BULGULAR	15
4.1	Balıkların Hangi Güne Ait Olduğu Sınıflandırma Matrisleri	15
4.1.1	Alabalığın Hangi Günlere Ait Olduğu Sınıflandırma Matrisleri.....	15
4.1.2	Çipuranın Hangi Günlere Ait Olduğu Sınıflandırma Matrisleri.....	18
4.1.3	Levreğin Hangi Günlere Ait Olduğu Sınıflandırma Matrisleri	21
4.2	Balık Türü Sınıflandırma Matrisleri	24
4.3	Balıkların Tazelik Sınıflandırma Matrisleri.....	30
5	TARTIŞMA VE SONUÇ	39
	KAYNAKLAR.....	42
	ÖZGEÇMİŞ	45

ŞEKİL LİSTESİ

Şekil 3.1 Alabalık örneklerine ait ilk gün elde edilen veriler.....	11
Şekil 3.2. Çipura örneklerine ait ilk gün elde edilen veriler.....	12
Şekil 3.3. Levrek örneklerine ait ilk gün elde edilen veriler	13
Şekil 4.1. Alabalığın Günlere Göre Sınıflandırma Hata Matrisi 0,1 (%10) Eğitim Kümesi 480 Adet Test Kümesi	15
Şekil 4.2. Alabalığın Günlere Göre Sınıflandırma Hata Matrisi 0,2 (%20) Eğitim Kümesi 480 Adet Test Kümesi	16
Şekil 4.3. Alabalığın Günlere Göre Sınıflandırma Hata Matrisi 0,4 (%40) Eğitim Kümesi 480 Adet Test Kümesi	17
Şekil 4.4. Çipuranın Günlere Göre Sınıflandırılma Hata Matrisi 0,1 (%10) Eğitim Kümesi 480 Adet Test Kümesi	18
Şekil 4.5. Çipuranın Günlere Göre Sınıflandırılma Hata Matrisi 0,2 (%20) Eğitim Kümesi 480 Adet Test Kümesi	19
Şekil 4.6. Çipuranın Günlere Göre Sınıflandırılması Hata Matrisi 0,4 (%40) Eğitim Kümesi 480 Adet Test Kümesi	20
Şekil 4.7. Levreğin Günlere Göre Sınıflandırılma Hata Matrisi 0,1 (%10) Eğitim Kümesi 480 Adet Test Kümesi	21
Şekil 4.8. Levreğin Günlere Göre Sınıflandırılması Hata Matrisi 0,2 (%20) Eğitim Kümesi 480 Adet Test Kümesi	22
Şekil 4.9. Levreğin Günlere Göre Sınıflandırılması Hata Matrisi 0,4 (%40) Eğitim Kümesi 480 Adet Test Kümesi	23
Şekil 4.10. Balıkların Hangi Türe Ait Olduğu Sınıflandırma Hata Matrisi 0,1 (%10) Eğitim Kümesi 50 Adet Test Kümesi.....	24
Şekil 4.11. Balıkların Hangi Türe Ait Olduğu Hata Sınıflandırma Matrisi 0,2 (%20) Eğitim Kümesi 50 Adet Test Kümesi.....	25
Şekil 4.12. Balıkların Hangi Türe Ait Olduğu Sınıflandırma Hata Matrisi 0,4 (%40) Eğitim Kümesi 50 Adet Test Kümesi.....	26
Şekil 4.13. Balıkların Hangi Türe ait Olduğu Sınıflandırma Hata Matrisi 0,1 (%10) Eğitim Kümesi 100 Adet Test Kümesi.....	27
Şekil 4.14. Balıkların Hangi Türe Ait Olduğu Sınıflandırma Matrisi 0,2 (%20) Eğitim Kümesi 100 Adet Test Kümesi.....	28
Şekil 4.15. Balıkların Hangi Türe Ait Olduğu Sınıflandırma Hata Matrisi 0,4 (%40) Eğitim Kümesi 100 Adet Test Kümesi.....	29
Şekil 4.16. Balıkların Taze-Orta-Bayat Sınıflandırma Hata Matrisi 0,1 (%10) Eğitim Kümesi 100 Adet Test Kümesi.....	30
Şekil 4.17. Balıkların Taze-Orta-Bayat Sınıflandırma Hata Matrisi 0,2 (%20) Eğitim Kümesi 100 Adet Test Kümesi.....	31
Şekil 4.18. Balıkların Taze-Orta-Bayat Sınıflandırma Hata Matrisi 0,4 (%40) Eğitim Kümesi 100 Adet Test Kümesi.....	32

Şekil 4.19. Balıkların Taze-Orta-Bayat Sınıflandırma Hata Matrisi 0,6 (%60) Eğitim Kümesi 100 Adet Test Kümesi	33
Şekil 4.20. Balıkların Taze-Orta-Bayat Sınıflandırma Hata Matrisi 0,8 (%80) Eğitim Kümesi 100 Adet Test Kümesi.....	34
Şekil 4.21. Balıkların Taze-Orta-Bayat Sınıflandırma Hata Matrisi 0,1 (%10) Eğitim Kümesi 500 Adet Test Kümesi	35
Şekil 4.22. Balıkların Taze-Orta-Bayat Sınıflandırma Hata Matrisi 0,2 (%20) Eğitim Kümesi 500 adet Test Kümesi	36
Şekil 4.23. Balıkların Taze-Orta-Bayat Sınıflandırma Hata Matrisi 0,1 (%10) Eğitim Kümesi 900 Adet Test Kümesi	37
Şekil 4.24. Balıkların Taze-Orta-Bayat Sınıflandırma Hata Matrisi 0,2 (%20) Eğitim Kümesi 900 Adet Test Kümesi	38



SİMGE VE KISALTMA LİSTESİ

Simgeler	Açıklama
°C	: Santigrat derece
mg	: Mili gram
g	: Gram
MDA	: Malondialdehit
Kg	: Kilo gram
%	: Yüzde
nm	: Nanometre
cm	: Santimetre
Cfu	: Colony Forming Unit
Log	: Logaritmik artış faz

Kısaltmalar	Açıklama
CNN	: Çok Katmanlı Algılayıcı
SVM	: Destek Vektör Makinesi
DHA	: Dokosaheksaenoik Asit
EPA	: Eikozapentaenoik Asit
ESA	: Evrimsel Sinir Ağı
FHD	: Full HD
TVB-N	: Toplam Uçucu Bazik Azot
PV	: Peroksit değeri
TBA	: Tiyobarbitürik asit
TVC	: Total viable counts
PTC	: Plateletokrit
FFA	: Serbest yağ asidi
K- MEANS	: Kümeleme ve ortalama tabanlı sınıflandırma yöntemi
NEAR-İNFRARED (NIR)	: Yakın kızıl ötesi ışınlar
XGA	: Extended Video Graphics Array
PCA	: Principal Component Analysis
PLS-DA	: Partial Least Squares and Sparse Partial Least Squares Discriminant Analysis

ÖZET

YÜKSEK LİSANS TEZİ

MAKİNE ÖĞRENMESİ İLE ALABALIK, ÇİPURA VE LEVREK BALIKLARININ KALİTE SEVİYELERİNİN VE TÜRLERİNİN BELİRLENMESİ

ÖZKAN DOĞAN

Kırşehir Ahi Evran Üniversitesi

Fen Bilimleri Enstitüsü

İleri Teknolojiler Anabilim Dalı

Doç. Dr. Emre YAVUZER

Sağlıklı beslenme kavramının bilimsel araştırmaların sonuçları ile işlenmesine bağlı olarak toplum sağlığı için balık eti tüketiminin önemi her geçen gün artmaktadır. Balık etinde bulunan doymamış yağ asitlerinin insan metabolizmasındaki esansiyel etkileri kendisini diğer gıdalara göre daha fonksiyonel hale getirmektedir. Ancak söz konusu fonksiyonel bileşiklerin kompleks yapısı balık etini hızlı bozulan bir gıdaya dönüştürmektedir. Buna bağlı olarak da balık etinin kalite parametrelerinin çok iyi ve hızlı tespit edilmesi gerekir. Balık kalitesinin belirlenmesinde kullanılan duyuşal, kimyasal ve mikrobiyolojik analizler zaman, teçhizat ve yetişmiş personel gerektiren ayrıca sonuçlarının geç elde edildiğı spesifik analizlerdir. Makine öğrenimi ise yapılan bilgi girişlerini işleyerek onları kullanıcıya yararlı bilgilere dönüştürebilen ve bunları tahmin yapmada kullanabilen çeşitli algoritmalarından oluşan yapay zekâlardır. Gelişen teknoloji ile makine öğrenimi birçok endüstride anlamlı değışiklikler başlatmış ve gösterdiği yüksek performans ile önemli sorunların ortadan kaldırılmasını sağlamıştır. Makine öğreniminin en büyük avantajı büyük miktarda veriyi hızla işlemek ve zamandan tasarruf sağlayan bir kontrol noktasına sahip olmaktır. Gıda kalitesinin belirlenmesinde ise makine öğrenmesi gıdaya temas etmeden ve onu tahrip

etmeden uygulanabilecek önemli bir yöntem olabilir. Bu tez çalışmasında derin öğrenme yöntemi ile farklı türdeki balıkların kalite parametreleri belirlenmek istenmiştir. Bu işlem için farklı türdeki; alabalık, levrek ve çipura balıkları 7 gün boyunca ($3\pm 1^{\circ}\text{C}$) buz içerisinde depolanmış ve her depolama gününde resimleri kayıt altına alınmıştır. 3 farklı balık türü için depolama süresince toplam 21.386 adet görüntü elde edilmiştir. Elde edilen bu görüntüler makine öğrenimi ile kalite sınıflandırılmasına tabi tutulmuştur. Çalışmada, görüntülerden elde edilen Convolutional neural networks (CNN) özelliklerinin kullanıldığı görüntüleri sınıflandırmak için bir destek vektör makinesi olan ve SVM (support vector machine) olarak bilinen algoritma kullanılmıştır. CNN'nin ilk katmanı, görüntülerin giriş boyutlarını belirtmiştir. Doğru sınıflandırma oranları %90,6 ile %100 arasında değişmiş ve veri artışının artması ile doğruluk oranında beklenen artışın olduğu gözlenmiştir. Alabalık, çipura ve levrek için ortalama doğru sınıflandırma oranları %80 üzerinde elde edilmiştir. Çalışma sonuçları makine öğrenmesi ile balığa ait taze-bayat ayrımının yüksek doğruluk oranında belirlenebileceğini ve makine öğrenmesinin hızlı kalite belirleme metodu olarak kullanılabileceğini göstermiştir.

Ocak 2023, 44 sayfa

Anahtar Kelimeler: Balık kalite seviyesi, Derin öğrenme, Görüntü işleme, Makine öğrenmesi

ABSTRACT

M.Sc. THESIS

DETERMINING THE QUALITY LEVELS AND SPECIES OF TROUT, SEA BREAM, AND BASS FISH BY MACHINE LEARNING

ÖZKAN DOĞAN

Kırsehir Ahi Evran University

Graduate School of Sciences and Engineering

Advanced Technologies Department

Supervisor: Assoc. Dr. Emre YAVUZER

Depending on the processing of the concept of healthy nutrition with the results of scientific research, the importance of fish meat consumption for public health increases day by day. The essential effects of unsaturated fatty acids found in fish in human metabolism make it more functional than other foods. However, the complex structure of the functional compounds in question turns fish meat into a perishable food. Accordingly, the quality parameters of fish meat must be determined very well and quickly. Sensory, chemical and microbiological analyzes used to determine fish quality are specific analyzes that require time, equipment and trained personnel, and the results are delayed. Machine learning, on the other hand, is artificial intelligence consisting of various algorithms that can process information inputs and turn them into useful information for the user and use them to make predictions. With the developing technology, machine learning has initiated significant changes in many industries and has enabled the elimination of important problems with its high performance. The biggest advantage of machine learning is to process large amounts of data quickly and have a time-saving checkpoint. In determining food quality, machine learning can be an important method that can be applied without contacting and destroying food. In this thesis, it was aimed to determine the quality parameters of different types of fish by using deep learning method. Different types for this process; Trout, sea bass and sea bream were stored in ice for 7 days ($3\pm 1^{\circ}\text{C}$) and their pictures were recorded on each storage day. A total of 21,386 images were obtained during storage for 3 different fish species. These

images were subjected to quality classification by machine learning. In the study, an algorithm known as SVM (support vector machine), which is a support vector machine, is used to classify images using CNN (Convolutional neural networks) features obtained from images. CNN's first layer specified the input dimensions of the images. Accurate classification rates ranged from 90.6% to 100%, and it was observed that the expected increase in accuracy was achieved with the increase in data. Average correct classification rates for trout, sea bream and sea bass were above 80%. The results of the study showed that the fresh-stale distinction of fish can be determined with high accuracy with machine learning and machine learning can be used as a fast quality determination method.

January 2023, 44 pages

Keywords: Fish quality level, Deep learning, Machine learning, Image Processing

1 GİRİŞ

Günümüzde toplum sağlığının sürdürülmesinde gıda güvenliği esaslarının uygulanması ile sağlık/gıda ilişkisi daha anlaşılır duruma gelmiştir. Bu bağlamda insan vücudunda üretilmeyen ve mutlaka dışarıdan almak zorunda olduğumuz besinler ve bu besinlerin insan vücudunda meydana getireceği olumlu katkılar her geçen gün önemini artırmaktadır. Bu besinlerin başında da balık eti gelmektedir. Balık etinden elde edilen tekli ve çoklu doymamış yağ asitlerinin insan beslenmesindeki önemi uzun yıllardır bilinmektedir [1-3]. Bu yağ asitlerinden omega3 yağ asidi insan beslenmesinde çok önemli bir yere sahiptir. Çocuk ve yetişkin beslenmesindeki formları Dokosakeksaenoik asit (DHA) ve Eikosapentaenoik asit (EPA) miktarları beyin hücrelerinin beslenmesi, kalp damar sağlığı, obezite, büyüme ve gelişmeye sağladığı faydalar, göz sağlığı ve bağışıklık sistemine olumlu etkileri balık eti tüketiminin önemini ortaya çıkarmaktadır [4-6].

Kasaplık hayvanların etlerinin sağladığı protein ve yağ türleri ile mukayese edildiğinde balık etlerinin diyetle daha fonksiyonel olduğu bilinmektedir [7]. Bunun en önemli nedenlerinden biri balık etlerinin sindiriminin yapısına bağlı olarak kolay gerçekleşmesidir. Ayrıca balık etlerinin yapısında kıkırdak, bağ doku gibi unsurların bulunmaması ve kasaplık hayvanlar gibi yer çekiminin olmadığı bir alanda yaşamaları balık etlerinin yumuşak olmasına neden olur [8].

Balık etlerinin kimyasal bileşiminin insan beslenmesinde oldukça önemli bir yer tutmasının yanında balık etinin kimyasal bileşiminin bozulmaya çok yatkın olduğu bilinmektedir [1]. Ülkemizde hasat edilen balıkların yüksek bir kısmı herhangi bir teknolojik muhafaza yöntemine tabi olmadan korunurken, çok düşük bir kısmı uygun muhafaza yöntemleri tercih edilerek korunur [9]. Hasat edildikten sonra balık kalitesi, avlanma yöntemine, avlandıktan sonra uygulanan işlemlere, toptancıdan soframıza gelene kadar uygulanan işlemlere bağlı olarak değişiklik gösterir [10]. Tüketiciler sofralarına gelen balığın kalitesi konusunda bazı tereddütlere sahip olmakla birlikte balık kalitesinin tespiti genellikle alanında uzmanlaşmış kişilerce yapılmaktadır [11].

Balıklar sudan çıktıkları andan itibaren bozulma eğilimindedir. Bozulmada etkili olan mikroorganizmaların gelişimden kaynaklanan mikrobiyal bozulma ve balık etinin oksijenle temas etmesinden kaynaklan kimyasala bozulma başlıca kalite kayıplarının aktörleridir [11]. Bununla birlikte mikrobiyal bozulmadan önce balıklarda aktif olarak çalışan enzimlerde balığın bozulmasını hızlandırır [12]. Ayrıca hem kimyasal hem enzimatik ve mikrobiyal bozulmalar balığın tat ve kokusunda dayanılmaz olumsuz sonuçlar meydana getirir [13]. Balıkların öldükten sonra yapılarında bulunan besin öğelerinin korunması, bu korunmanın sürdürülebilmesi için kalite koruma kriterlerine dikkat edilmelidir [14].

Balıkların yapısında meydana gelecek kimyasal ve oksidatif bozulmaları belirlemek için farklı gıda analizleri yapılır [15]. Balığın kalitesinin tespitinde farklı şekillerde üretilmiş farklı yöntemlerle kalite tespiti yapan cihazlar geliştirilmiştir [16].

Uzmanlık gerektiren bir işlem olan balık tazelik kontrolü için son yıllarda teknolojinin gelişimi ile birlikte görüntü işleme teknolojisi de kullanılmaya başlanmıştır [16, 39]. Teknolojinin hızla gelişmesine paralel olarak balık kalitesinin tespitinde görüntü işleme teknolojileri önemini artırmaktadır [17].

Görüntü işleme teknolojisi araç park yeri girişlerinde, meyve ve sebzelerin kalite sınıflandırılmalarında, tekstil sanayinde, etlerin sınıflandırılmalarında, tıp, uzay, maden araştırmalarında, farklı fotoğraf uygulamalarında, görsel sanatlarda, fizik ve askeri mühimmat ve hedef belirlenmesi gibi birçok farklı sanayi dallarında kullanılmaktadır [1]. Ayrıca farklı balık türlerinin balık kalite parametreleri kolaylıkla yüklendiği ve yapay zekâ ile kalite seviyelerinin belirlendiği online platformlar da önceki çalışmalarda kullanılmıştır [18]. Görüntü işleme; kamera ile alınan fotoğraf veya video verilerinin amacına uygun şekilde düzenlenmesi, bu veriler sayesinde farklı alanlarda farklı analizlerin değerlendirilmesi işlemidir [19].

Bilgisayar teknolojisinde meydana gelen hızlı gelişmeler bizlere görüntü işleme teknolojisini daha verimli ve daha ayrıntılı kullanım imkânı sağlamaktadır. Görüntü işleme teknolojisini geliştirmek için farklı programlar kullanılmaktadır. Görüntü işleme teknolojisi uzaktan idrak etme, anlama ve kavrama gibi durumların uygulanması işlemidir [18].

Dijital görüntü işlemede uygulanması gereken ilk basamak herhangi bir görüntüleme makinası ile görüntünün oluşturulmasıdır. Daha sonra elde edilen bu görüntünün istenilen bir programla işlenmesi işlemidir [18].

Görüntü işleme teknolojisinin uygulanmasında; algılayıcılar, yapay sinir ağları ve günümüzde derin öğrenme yöntemleri kullanılmaktadır [20]. Bu yöntemlerden biri olan Convolutional Neural Networks (CNN) konvolüsyonel sinir ağları derin öğrenmede kullanılan etkili yöntemlerden biridir. Derin öğrenmede daha önceden bilgisayara tanıtılan görüntüler sayesinde bilgisayar eğitilir ve bu eğitilen küme kullanılarak tüm verilerin tasnif ve sınıflandırma işlemleri gerçekleştirilir [20].

1.1 Amaç

Bu tezin amacı, farklı türlerdeki; alabalık, çipura ve levrek balıklarının +4°C'deki 1 haftalık depolama süresindeki tazelik kontrolünün makine öğrenmesi ile belirlenebilmesinin araştırılmasıdır. Çalışmada 0. günden başlanılarak 7. güne kadar depolanan balıkların makine öğrenimi verilerinin elde edilebilmesi için ön işlemleri yapılmıştır. Her bir balık türü için sabah ve akşam aynı saatte dijital fotoğraf makinesi kullanılarak görüntüler kaydedilmiştir ve depolama sonunda balıkların görünüşlerindeki değişiklikler görüntü işleme teknolojisi kullanılarak değerlendirilmiştir. Süre ilerledikçe balık etinin mikrobiyal ve kimyasal değişimlerine bağlı olarak balık etinin görüntüsünde olumsuz yönde değişimi gözlemlenmiştir. Derin öğrenme yöntemi kullanılarak balıkların tazelik kontrolü; taze, orta, bayat şeklinde sınıflandırma yapılmış, aynı zamanda derin öğrenme yöntemi ile balıkların hangi türe ait olduğu hakkında yüzdesel sonuçlar elde edilmiştir.

1.2 Önem

İnsan beslenmesinde balık etinin önemi gün geçtikçe açığa çıkmaktadır. Balık etinin sağladığı önemli yağ asitleri bedensel ve ruhsal gelişimimiz için olmazsa olmazlar arasında yerini almıştır. Sağlıklı beslenme için bu kadar önemli olan balık etinin sofralarımıza güvenli bir şekilde gelebilmesi için balık etinin taze olarak tüketilmesi şarttır. Çalışma ile hızlı kalite seviyesinin belirlenebileceği bir öğrenmiş makine sistemi geliştirilmiştir. Ayrıca tazelik kontrolü dışında öğrenmiş makine balığın hangi türe ait olduğu hakkında da bilgi verebilmektedir. Bu tez çalışmasında kullanılan verilerin geliştirilmesi ile görüntü işleme teknolojisi ve derin öğrenme kullanılarak balıkların tazeliklerinin kontrol ve tür tespiti hakkında yüksek doğruluk oranı ile belirleme yapılabilecektir.

1.3 İlgili Çalışmalar

Görüntü işleme teknikleri son yıllarda gıda kalitesinin belirlenmesinde kullanılmaya başlanmıştır. Bir nesnenin boyut ölçümü için yaygın olarak kullanılan özellikler; alan, çevre, uzunluk ve genişlik gibi kriterler gıda kalitesi değerlendirmesi için kullanılmıştır [21].

Dutta vd., [22], Haar filtresi kullanılarak balık solungaç yapıları kısımlara ayrılmış ve bu kısımların özelliklerini belirlemişlerdir. Elde edilen veriler ile daha önceden belirlenen özellikler arasında ortak bir payda oluşmuş ve görüntü işleme teknolojisinin balıkların tazeliğinin belirlenmesinde kullanılabileceği belirlenmiştir.

Xing vd., [23], yapmış oldukları çalışmalarında Golden cinsi elmalarda oluşabilecek çürüklerin belirlenebilmesi için 400 ve 1000 nm dalga boyunda Hiperspektral görüntüleme sistemleri kullanılmışlardır. Çalışmalarında Hiperspektral sistemden ayırmak ve kısaltmak için PCA ve PLS-DA modelleri kullanmışlar ve elmaların kalitesi hakkında bilgi sahibi olunabileceğini bildirmişlerdir.

Sabancı vd., [24], görüntü işleme teknolojisi ve Yapay Sinir Ağları ile patates örneklerinin ebatlarına göre kategorize etmişler ve patateslerde bulunan hastalıkları belirlemişlerdir.

Momin vd., [25], 8 bitlik Extended Video Graphics Array (XGA): Genişletilmiş Video Grafik Dizisi formatlı kameralar ile tropikal bir meyve olan mangonun kalite seviyelerini belirlemişlerdir. Çalışma neticesinde görüntü işleme teknolojisinin mangoların kalite sınıflandırılmasında yüksek doğruluk sağladığı tespit edilmiştir.

Görüntü işleme teknikleri tahıllarda meydana gelecek fiziksel değişiklikler ve yabancı maddelerin belirlenmesinde de kullanılmıştır. Bu işlemde buğday Cumhuriyet-75 türü buğdayın morfolojik özellikleri MATLAB görüntü işleme yöntemine tanıtılmış ve bu buğday çeşidinin sınıflandırılması amaçlanmıştır. Bu araştırma için farklı özelliklere sahip buğday çeşitleri ve farklı tahıl grupları ile karışmış vaziyette bulunan 100'er tane buğday içeren 3 farklı buğday örneği hazırlanmıştır. Çalışma sonucunda görüntü işleme ile %97 gibi yüksek bir başarı elde edilmiştir. Bu sayede insanlar tarafından yapılan incelemelerden çok daha kaliteli ve etkili bir ayırımın elde edilebileceği bildirilmiştir [26].

Bir başka çalışmada farklı buğday çeşitleri sınıflandırılmış ve bu sınıflandırma sayesinde buğday alım döneminde buğdayın fiyatının belirlenmesinde kolaylıklar sağlanmıştır. Çalışmada Near-Infrared (NIR) yakın kızıl ötesi ışınlar kullanılmış ve 24 farklı buğday

çeşidinin piksel değerleri ölçümü yapılmış ve makine öğrenmesi işlemi uygulanmıştır. Sonuçlar buğdayların, tür, olgunluk durumu ve kalitesi hakkında geleneksel yöntemlere göre daha doğru sonuçlar verdiğini göstermiştir [27].

Derin öğrenmeye dayalı görünür yakın kızılötesi kamera kullanılarak buğday çeşitlerinin sınıflandırılması, fiyatlandırılması, hastalık vb. olumsuzlukların tespitinde 50 farklı buğday çeşidi ve her buğday çeşidinden 220 görüntü kullanılarak elde edilen 11.000 veri kullanılarak sınıflandırılma işlemi yapılmıştır. Derin öğrenme yönteminin kullanılması buğday çeşitlerinin sınıflandırılmasındaki doğruluk derecesinin çok yüksek olduğunu belirlenmiştir [28].

Derin öğrenme metotları kullanılarak yapılan başka bir çalışmada meyve ve sebzelerin kalite parametreleri belirlenmiştir. Derin öğrenmenin farklı mimarilerin uygulanması sonucunda elde edilen farklı sonuçlar ve bu sonuçların karşılaştırılmaları gerçekleştirilmiştir. AlexNet, Vgg16, GoogLeNet, ResNet18, ResNet101, SqueezeNet ve ShallowNet gibi popüler derin öğrenme mimarilerinin sınıflandırmada gösterdikleri performansların karşılaştırılmaları incelenmiştir. Elde edilen bilgiler doğrultusunda basit mimariye sahip ShallowNet'in kabul edilebilir değerlerin verdiği, kullanılan verilerde yüksek bozulmaların olmadığı durumlarda SqueezeNet mimarisinin %80 üzeri sonuç vererek sınıflandırma için kullanılabilir sonuçlar verdiği ve diğer mimarilerde değişkenlere bağlı olarak yüksek doğrulukla sonuçlar verdiği bildirilmiştir [29].

Daha önceki çalışmalarda derin öğrenme yumurtaların kategorize edilmesi içinde kullanılmıştır. Makine öğrenmesi kullanılmadan çok fazla emek isteyen bir işlem olan yumurta kategorizasyonunda Evrişimsel Sinir Ağlarının (ESA) farklı mimarileri AlexNet, VGG16, VGG19, SqueezeNet, GoogleNet, Inceptionv3, ResNet18 ve Xception uygulanmış, bu mimarilerden VGG19 %96,25 doğruluk oranı ile çok yüksek bir başarı elde edilmiştir [30].

Başka bir çalışmada fındık meyvesine ait görüntü verileri kamera ile oluşturulup kayıt altına alınmıştır. Fındık görüntüleri üzerinde farklı hesaplamalar yapılmış ve fındık meyvesini küçük, orta ve büyük olacak şekilde 3 farklı kategoriye ayrılmıştır. Bu işlem için K- means kümeleme ve ortalama tabanlı sınıflandırma yöntemleri kullanılmış ve K-means yöntemi %100 doğru sonuçla fındık meyvelerini başarıyla kategorize etmiştir. Kullanılan diğer sınıflandırma yöntemi olan ortalama tabanlı sınıflandırma yönteminde de çok yüksek başarı elde edilmiştir [31].

İçecek şişelerinin kapak üzerindeki görüntülerle ilişkilendirilmesinde de derin öğrenme kullanılmıştır. Her şişenin kendine özgü olan kapağın belirlenmesinde Evrişimsel Sinir Ağı (ESA) VGG-16 modeli kullanılmıştır [32]. Bu çalışma için 9 farklı kapak ile 7200 adet görüntü kullanılmış ve başarı oranı %100 yakın tatmin edici bir sonuç olarak ortaya çıkmıştır.

Şeftali hastalıklarının tespitinde de derin öğrenme yöntemleri kullanılmıştır. Bu işlem için monilya ve koşnili şeftalilerinin hastalıklarından oluşturulan görsel veriler Evrişimsel Sinir Ağı yöntemi ile çalışılmış Alex Net modeli ile mevcut hastalık belirlenmiştir. Yapılan çalışmalar sonucunda %99,30 oranında başarı tespit edilmiş, diğer tercih edilen yöntemlerden %1.44 daha doğru sonuçlar alındığı belirlenmiş ve bu hastalıkların tespitinde daha önceki çalışmalardan daha yüksek verimli sonuçlar alınmıştır [33].

Meyvelerin tazelik kontrolü işlemlerinde de derin öğrenme mimarisi kullanılmıştır. Bu işlem için 3 farklı meyve çeşidi; elma, portakal ve muz örneklerinin tazeliğinin kontrolünde kullanılmıştır. Bu çalışma için 2 tane VGG-16 modeli ile çalışılmış ve bu modellerin hangisinin tazelik kontrolünde yüksek doğruluk sağladığı belirlenmiştir [34].

2 GENEL KISIMLAR

2.1 Derin Öğrenme

Makine öğrenmesinin bir çeşidi olan derin öğrenme görüntü işleme teknolojisinin son yıllarda en fazla kullandığı çalışma alanıdır. Bilgisayar öğrenmesi ve kendi kendine eğitimi işlemlerine çok fazla katkıda bulunmaktadır. Derin öğrenmede daha önceden bilgisayara tanıtılmış veriler bilgisayar tarafından kullanılarak bu verilerle ilgili; ayırma, sınıflandırma gibi işlemleri kendi kendine yapmasına imkân sunan bir alandır [35].

Derin öğrenme, diğer makine öğrenmelerinin kullandığı verilerin kodlanması ve bu verilerin kodlarının çözümlenmesi işleyişinden farklı olarak çalışır. Derin öğrenmede; resim, video gibi görüntüleme araçları ile elde edilen verilerin bir kısmının bilgisayara tanıtılması bu tanıtılan örnek kümeyle göre yüklenen tüm verilerin istenilen sınıflandırma, kümeleme, nesnelerin algılanması gibi işlemleri yerine getirebilmektedir. Bilgisayara daha önceden öğretilen örnek veriler sayesinde tüm veriler istenilen işlemlerin uygulanması sağlanır. Yani bilgisayara kendi kendini eğitime imkânı sağlar. Bilgisayara kendini eğitebilmesi için yüklenen verilerin miktarı artırıldıkça istenilen sonuç tahmini de bir o kadar artar. Derin öğrenme çok fazla miktarda veri kullanılarak gerçekleştirilen bir öğrenme çeşididir. Bilgisayardan istenilen sınıflandırma işleminin doğru tahmini yüzdesel olarak gerçekleştirilir. Veri miktarı arttıkça hata yapma olanağı azalır. Bu alan Evrişimsel Sinir Ağları (ESA) yardımıyla işlem yapar. Evrişimsel Sinir Ağları verilen bilgileri gruplandıran, sınıflandıran, kümeleyen yapay sinir ağlarıdır [35].

Sonuç olarak makine öğrenme; gruplandırma, kümeleme gibi işlemleri hızlı ve daha ekonomik olarak gerçekleştirir. Diğer kullanılan yöntem ve sistemlerden çok daha hızlı ve kesin sonuç almamızı sağlar [36].

2.2 Evrişimsel Sinir Ağı (ESA)

ESA derin öğrenme teknolojisinin alt koludur. Genellikle resim, video gibi görsel materyallerin sınıflandırılması, gruplandırılması ve ayırması gibi işlemlerde kullanılır [36].

ESA farklı katmanların kullanıldığı yapay bir sinir ağıdır. ESA arka arkaya konumlandırılmış birbirinden farklı tabakalardan oluşmuştur. Bu tabakaların bazılarında

makine öğrenim yapılmakta, diğer tabakalarda öğrenilen bu verilerle istenilen gruplama, sınıflama gibi işlemler gerçekleştirilmektedir [37].

2.3 Evrişimsel Sinir Ağlarını Oluşturan Katmanlar

2.3.1 Giriş Katmanı

Giriş katmanı ESA'yı oluşturan birinci katmandır. Bu katmanda bilgisayara eğitilecek fotoğraf, resim gibi verilerin girildiği bölümdür. Bu katmanda kullanılacak verilerin öğrenme ve öğrenme işleminin kalitesini ve süresini doğrudan etkileyen katmandır. Kullanılacak verilerin büyüklüğü hesaplama süresini ve bilgisayardan yapılmasını istediği ayırma işleminin başarı oranını doğrudan etkiler ve bu katmanda bilgisayara girilecek tüm veriler bilgisayarın eğitimi için kullanılır [37].

2.3.2 Konvolüsyon Katmanı

Bu katman da farklı filtreler bulunmaktadır. Bu filtreler bilgisayara yüklenen görüntülerin farklı özelliklerini belirleyebilmek yani mevcut özelliklerin belirleyicisi olarak kullanılır. Farklı boyutta filtreleme işlemleri gerçekleştirilir. Konvolüsyon katmanında örnek matrisler küçültülerek kullanılacak verilerin daha net Evrişimsel Sinir Ağlarına tanımı yapılır [37].

2.3.3 Havuzlama Katmanı

Havuzlama Katmanı iki tane evrişim katmanının ortasında bulunur. Bu katmanda sisteme yüklenen görüntüler gereğinden fazla büyük olduğunda ayarlama yapar. Giriş katmanından giren görüntünün geometrik olarak ayarlanması yapılır. Görüntülerin yükseklik, en, boy gibi özellikleri azaltılması sonucu dominant özelliklerin ortaya çıkarılması ve bu sayede daha verimli bir eğitim gerçekleşmesi sağlanır. Ayrıca değişken sayısı azaltılır [37].

2.3.4 Tam Bağlantı Katmanı

Havuzlama katmanından gelen verilerin diğer katmanlara bağlanıldığı bir ağ türüdür. Kendisinden önce kullanılan veri ağlarının tamamına bağlıdır. Elde edilen verilere düzleştirme işlemi uygulanır ve bu katmana gelen bütün veriler düz bir vektör haline getirilir [37].

2.3.5 Dropout Katmanı

Bilgisayar derin öğrenimi sırasında bazı nöronları unutup bilgisayarın aşırı öğrenmesini önlemek amacıyla bu katman kullanılır. Bu işlem gerçekleşmesi sırasında unutilan nöronlar sistemin çalışma kapasitesini de yükseltir [37].

2.3.6 Sınıflandırma Katmanı

Bu katmanda farklı kategorize ediciler kullanılsa da en fazla tercih edilen Softmax kategorize ediciler tercih edilirler. Bu katmanda ayrımı tanımlanması kategorize edilecek veri sayısı kadar sonuç elde edilir [37]. Bilgisayara öğretilen verilerle istenilen kategorilerin sınıflamaların gruplamaların eşleşmelerini sağlar [37].



3 MALZEME VE YÖNTEM

3.1 Balık Materyali


Çalışmada kullanılan balık materyalleri Kırşehir’de bulunan yerel bir balık marketten taze olarak temin edilmiş ve aseptik koşullarda temizlendikten sonra buzdolabı koşullarında ($3\pm 1^{\circ}\text{C}$) buz içerisinde 7 gün boyunca depolanmıştır.

3.2 Görüntü Verilerinin Elde Edilmesi

Çalışmada kullanılan Çipura, Levrek ve Alabalığa ait görüntüler her gün sabah 07.00 ve akşam 19.00’da kaydedilmiştir. Fotoğraf verilerinin elde edilmesinde dairesel bir stant üzerine arka zemini beyaz bir ortam kullanılmıştır. Görüntü yakalama işlemi 1080*1920 (FHD) piksel ekran çözünürlüklü fotoğraf makinesi ile gerçekleştirilmiştir. Görüntülerin elde edileceği tezgâhın 18 farklı açılarından minimum 20 şer görüntü elde edilecek şekilde, tezgâhtan 20 cm yükseklikten çekilerek 21.380 adet görüntü elde edilmiştir. Şekil 1’de alabalık grubunun, Şekil 2’de çipura grubunun ve Şekil 3’te levrek grubunun ilk depolama gününden örnek resimler verilmiştir.



Şekil 3.1 Alabalık örneklerine ait ilk gün elde edilen veriler



Şekil 3.2. Çipura örneklerine ait ilk gün elde edilen veriler



Şekil 3.3. Levrek örneklerine ait ilk gün elde edilen veriler

3.3 Makine Öğrenme Koşulları

Çalışmada, görüntülerden elde edilen CNN özelliklerinin kullanıldığı görüntüleri sınıflandırmak için bir destek vektör makinesi olan ve SVM olarak bilinen algoritma kullanılmıştır. CNN'nin ilk katmanı, görüntülerin giriş boyutlarını belirtmiştir. 0. günden başlayarak 1, 2, 3, 4, 5, 6 ve 7. gün boyunca görüntüleri elde edilen 3 farklı balık türünün türlerine göre sınıflandırılmalarında, aynı tür balıkların kaçınıcı güne ait olduğuna ve her 3 türün de 0.ve 1. gün taze, 2 ve 3. gün orta taze ve 4. günden sonraki günler ise bayat olacak şekilde sınıflandırmaya tabi tutulmuştur. Bilgisayara %10, %20, %40, %60, %80'lik oranlarla test kümesi tanımlanmış bilgisayar öğrenmesi yapılmış ve eğitilen bu oranlarla geriye kalan fotoğraflarda kalite parametreleri sınıflandırılması yapılmış ve kayıt altına alınmıştır.

Türlere göre sınıflandırmada 100, 200, 480 adet görüntü ile çalışılmıştır. Aynı türün kaçınıcı güne ait olduğu sınıflandırma için 100, 500, 1000, 7000 adet görüntü ile çalışılmıştır. Balıkların taze bayat sınıflandırılmaları için 100, 500, 900 adet görüntü ile çalışılmıştır.

Belirlenen her veri kümesinin belirtilen yüzdelerik (%) kısım ile bilgisayar eğitilmiş ve geri kalanlar test aşamasında kullanılmış belirlenen verilerden rast gele elemanlar seçilerek 10 kez tekrarlanmıştır. Bu Monte Carlo denemeleri sonucunda hata matrisleri oluşturulmuştur.

4 BULGULAR

4.1 Balıkların Hangi Güne Ait Olduğu Sınıflandırma Matrisleri

4.1.1 Alabalığın Hangi Günlere Ait Olduğu Sınıflandırma Matrisleri

Her güne ait 480 adet alabalık veri kümesinin %10'u sınıflandırma için bilgisayarın eğitiminde, geri kalanı test aşamasında kullanılmıştır. Bu test rastgele elamanlar seçilerek 10 kez tekrarlanmış ve bu Monte Carlo denemeleri sonucunda Şekil 4.1'de verilen hata matrisleri elde edilmiştir. Elde edilen verilere göre 480 adet verinin sınıflandırılmasında 6. gün hariç diğer günlerde alabalığın hangi güne ait olduğu %90'ın üzerinde doğru tespit etmiş, alabalığın 6. güne ait olduğu %80'in altında doğru tespit etmiştir.

day 0	476	2			1				99.4%	0.6%
day 1	1	476				1	1	1	99.2%	0.8%
day 2			447	23	6			4	93.1%	6.9%
day 3			13	460	2	2	4		95.6%	4.4%
day 4			6	2	465	1	5		97.1%	2.9%
day 5				2	7	445	15	11	92.7%	7.3%
day 6		3		11	8	21	368	68	76.8%	23.2%
day 7				1	3	5	30	441	91.9%	8.1%

99.8%	99.0%	95.9%	92.2%	94.5%	93.7%	87.0%	84.0%
0.2%	1.0%	4.1%	7.8%	5.5%	6.3%	13.0%	16.0%

True Class

day 0 day 1 day 2 day 3 day 4 day 5 day 6 day 7

Predicted Class

Şekil 4.1. Alabalığın Günlere Göre Sınıflandırma Hata Matrisi 0,1 (%10) Eğitim Kümesi
480 Adet Test Kümesi

Her güne ait 480 adet alabalık veri kümesinin %20'si sınıflandırma için bilgisayarın eğitiminde, geri kalanı test aşamasında kullanılıp bu test rast gele elemanlar seçilerek 10 kez tekrarlanmış ve bu Monte Carlo denemeleri sonucunda Şekil 4.2'de verilen hata matrisleri elde edilmiştir. Elde edilen verilere göre 480 adet verinin sınıflandırılmasında eğitim kümesi %10'dan %20'ye çıkarılması ile tüm günlerde alabalığın hangi güne ait olduğu %95 üzerinde doğru tespit edilmiştir.

True Class	day 0	480								100.0%	
	day 1	1	478				1		1	99.4%	0.6%
	day 2			476	3					99.2%	0.8%
	day 3			5	473		1	1		98.5%	1.5%
	day 4			1		479				99.8%	0.2%
	day 5				1	1	471	7		98.1%	1.9%
	day 6				2	1	10	455	12	94.8%	5.2%
	day 7				1		2	9	468	97.5%	2.5%

99.8%	100.0%	98.8%	98.5%	99.6%	97.1%	96.4%	97.1%
0.2%		1.2%	1.5%	0.4%	2.9%	3.6%	2.9%
day 0	day 1	day 2	day 3	day 4	day 5	day 6	day 7

Predicted Class

Şekil 4.2. Alabalığın Günlere Göre Sınıflandırma Hata Matrisi 0,2 (%20) Eğitim Kümesi 480 Adet Test Kümesi

Her güne ait 480 adet alabalık veri kümesinin %40'ı sınıflandırma için bilgisayarın eğitiminde, geri kalanı test aşamasında kullanılıp rast gele elemanlar seçilerek 10 kez tekrarlanmış bu Monte Carlo denemeleri sonucunda Şekil 4.3'te verilen hata matrisleri elde edilmiştir. Elde edilen verilere göre 480 adet verinin sınıflandırılmasında eğitim kümesi %40'a çıkarılması ile alabalığın tüm günlerde hangi güne ait olduğu %100 doğru tespit edilmiştir.

day 0	480								100.0%	
day 1	1	479							99.8%	0.2%
day 2			480						100.0%	
day 3			1	479					99.8%	0.2%
day 4			1		479				99.8%	0.2%
day 5					1	477	3		99.2%	0.8%
day 6						2	476	3	99.0%	1.0%
day 7							1	479	99.8%	0.2%

99.8%	100.0%	99.6%	100.0%	99.8%	99.6%	99.2%	99.4%
0.2%		0.4%		0.2%	0.4%	0.8%	0.6%
day 0	day 1	day 2	day 3	day 4	day 5	day 6	day 7

Predicted Class

Şekil 4.3. Alabalığın Günlere Göre Sınıflandırma Hata Matrisi 0,4 (%40) Eğitim Kümesi
480 Adet Test Kümesi

4.1.2 Çipuranın Hangi Günlere Ait Olduğu Sınıflandırma Matrisleri

Her güne ait 480 adet çipuranın veri kümesinin %10'u sınıflandırma için bilgisayarın eğitiminde, geri kalanı test aşamasında kullanıldığında rast gele elemanlar seçilerek 10 kez tekrarlanmış ve bu Monte Carlo denemeleri sonucunda Şekil 4.4'te verilen hata matrisleri elde edilmiştir. Elde edilen verilere göre 480 adet verinin sınıflandırılmasında tüm günlerde çipuranın hangi güne ait olduğu %90'ın üzerinde doğru tespit edilmiştir.

day 0	480								100.0%	
day 1		464	14		1		1		96.7%	3.3%
day 2	1	6	466	1		4	2		97.1%	2.9%
day 3		1		470	9			1	97.7%	2.3%
day 4			2	10	461	4		3	96.0%	4.0%
day 5		2	6	2	12	451	1	6	94.0%	6.0%
day 6			1		2	1	469	6	97.9%	2.1%
day 7			4		3	8	15	448	93.7%	6.3%

99.8%	98.1%	94.5%	97.3%	94.5%	96.4%	96.1%	96.6%
0.2%	1.9%	5.5%	2.7%	5.5%	3.6%	3.9%	3.4%

day 0 day 1 day 2 day 3 day 4 day 5 day 6 day 7
Predicted Class

Şekil 4.4. Çipuranın Günlere Göre Sınıflandırılma Hata Matrisi 0,1 (%10) Eğitim Kümesi
480 Adet Test Kümesi

Her güne ait 480 adet çipura veri kümesinin %20'si sınıflandırma için bilgisayarın eğitiminde, geri kalanı test aşamasında kullanılıp bu test rast gele elemanlar seçilerek 10 kez tekrarlanmış ve bu Monte Carlo denemeleri sonucunda Şekil 4.5'te verilen hata matrisleri elde edilmiştir. Elde edilen verilere göre 480 adet verinin sınıflandırmasında eğitim kümesi%10'dan %20'ye çıkarılması ile tüm günlerde çipuranın hangi güne ait olduğu %98 doğru tespit edilmiştir.


day 0	480									100.0%	
day 1		479	1							99.8%	0.2%
day 2		1	479							99.8%	0.2%
day 3				480						100.0%	
day 4			3	2	472	2	1			98.3%	1.7%
day 5	1		5	1	3	470	1			97.7%	2.3%
day 6					1		476	3		99.2%	0.8%
day 7					2	1	3	473		98.7%	1.3%

99.8%	99.8%	98.2%	99.4%	98.7%	99.4%	99.0%	99.4%
0.2%	0.2%	1.8%	0.6%	1.3%	0.6%	1.0%	0.6%
day 0	day 1	day 2	day 3	day 4	day 5	day 6	day 7

Predicted Class

Şekil 4.5. Çipuranın Günlere Göre Sınıflandırılma Hata Matrisi 0,2 (%20) Eğitim Kümesi
480 Adet Test Kümesi

Her güne ait 480 adet çipura veri kümesinin %40'si sınıflandırma için bilgisayarın eğitiminde, geri kalanı test aşamasında kullanılıp bu test rast gele elemanlar seçilerek 10 kez tekrarlanmış ve bu Monte Carlo denemeleri sonucunda Şekil 4.6'da verilen hata matrisleri elde edilmiştir. Elde edilen verilere göre 480 adet verinin sınıflandırılmasında eğitim kümesi %20'den %40'a çıkarılması ile çipuranın tüm günlerde hangi güne ait olduğu %100 doğru tespit edilmiştir.



Şekil 4.6. Çipuranın Günlere Göre Sınıflandırılması Hata Matrisi 0,4 (%40) Eğitim Kümesi 480 Adet Test Kümesi

4.1.3 Levreğin Hangi Günlere Ait Olduğu Sınıflandırma Matrisleri

Her güne ait 480 adet levrek veri kümesinin %10'u sınıflandırma için bilgisayarın eğitiminde, geri kalanı test aşamasında kullanılıp bu test rast gele elemanlar seçilerek 10 kez tekrarlanmış ve bu Monte Carlo denemeleri sonucunda Şekil 4.7'de verilen hata matrisleri elde edilmiştir. Elde edilen verilere göre 480 adet veri kümesinin sınıflandırılmasında levreğin tüm günlerde hangi güne ait olduğu %90 doğru tespit edilmiştir.

day 0	480								100.0%	
day 1	1	474		1				4	98.8%	1.2%
day 2		11	454	1	5	1	1	8	94.4%	5.6%
day 3			2	456	3	16	2		95.2%	4.8%
day 4		1	4	3	450	5	17	1	93.6%	6.4%
day 5		2	5	16	9	431	10	7	89.8%	10.2%
day 6		1	2		14	1	456	6	95.0%	5.0%
day 7	11	1	4	3	3	17	8	434	90.2%	9.8%

97.6%	96.7%	96.4%	95.0%	93.0%	91.5%	91.6%	95.2%
2.4%	3.3%	3.6%	5.0%	7.0%	8.5%	8.4%	4.8%
day 0	day 1	day 2	day 3	day 4	day 5	day 6	day 7

Predicted Class

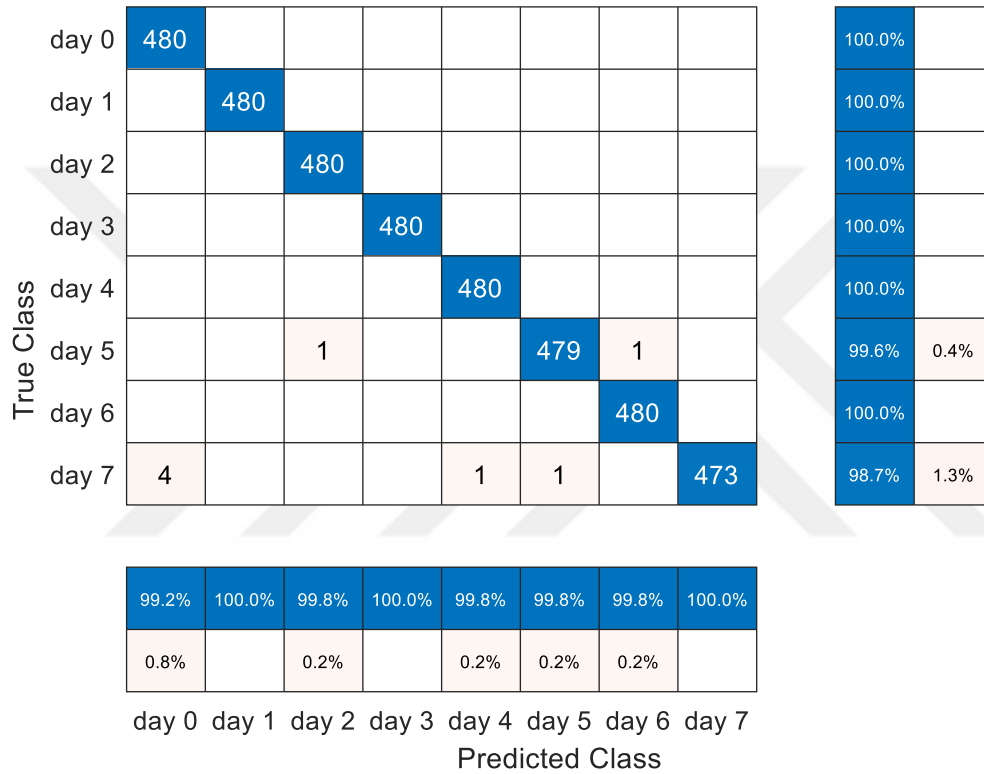
Şekil 4.7. Levreğin Günlere Göre Sınıflandırılma Hata Matrisi 0,1 (%10) Eğitim Kümesi
480 Adet Test Kümesi

Her güne ait 480 adet levrek veri kümesinin %20'si sınıflandırma için bilgisayarın eğitiminde, geri kalanı test aşamasında kullanılıp bu test rast gele elemanlar seçilerek 10 kez tekrarlanmış ve bu Monte Carlo denemeleri sonucunda Şekil 4.8'de verilen hata matrisleri elde edilmiştir. Elde edilen 480 adet veri kümesinin sınıflandırılmasında eğitim kümesinin %10'dan %20'ye çıkarılması ile levreğin tüm günlerde hangi güne ait olduğu %98 doğru tespit edilmiştir.

True Class	day 0	480								100.0%	
	day 1		480							100.0%	
	day 2		2	476					2	99.2%	0.8%
	day 3				474		6			98.8%	1.2%
	day 4	3	1	1	1	466	1	7		97.1%	2.9%
	day 5			1	4	1	470	4		97.9%	2.1%
	day 6			2		2		473	3	98.5%	1.5%
	day 7	6		3	1		3	1	465	97.1%	2.9%
		98.2%	99.4%	98.6%	98.8%	99.4%	97.9%	97.5%	98.9%		
		1.8%	0.6%	1.4%	1.2%	0.6%	2.1%	2.5%	1.1%		
		day 0	day 1	day 2	day 3	day 4	day 5	day 6	day 7		
		Predicted Class									

Şekil 4.8. Levreğin Günlere Göre Sınıflandırılması Hata Matrisi 0,2 (%20) Eğitim Kümesi
480 Adet Test Kümesi

Her güne ait 480 adet levrek veri kümesinin %40'ı sınıflandırma için bilgisayarın eğitiminde, geri kalanı test aşamasında kullanılıp bu test rast gele elemanlar seçilerek 10 kez tekrarlanmış ve Monte Carlo denemeleri sonucunda Şekil 4.9'da verilen hata matrisleri elde edilmiştir. Elde edilen verilere göre 480 adet veri kümesinin sınıflandırılmasında eğitim kümesinin %40'a çıkarılması ile levreğin tüm günlerde hangi güne ait olduğu %100 doğru tespit etmiştir.



Şekil 4.9. Levreğin Günlere Göre Sınıflandırılması Hata Matrisi 0,4 (%40) Eğitim Kümesi
480 Adet Test Kümesi

4.2 Balık Türü Sınıflandırma Matrisleri

Her türe ait 50 adet veri kümesinin %10'u sınıflandırma için bilgisayarın eğitiminde, geri kalanı test aşamasında kullanılmıştır. Bu test rast gele elemanlar seçilerek 10 kez tekrarlanmıştır. Bu Monte Carlo denemeleri sonucunda Şekil 4.10'da verilen hata matrisleri belirlenmiştir. Elde edilen verilere göre 50 adet veri kümesinin kullanılarak sınıflandırmasında balığın hangi türe ait olduğu %90'ın üzerinde doğru tespit edilmiştir.

True Class	Predicted Class					
	alabalik	cipura	levrek			
alabalik	49			100.0%		
cipura		48	2	96.0%	4.0%	
levrek		1	49	98.0%	2.0%	
	100.0%	98.0%	96.1%			
		2.0%	3.9%			
	alabalik	cipura	levrek			

Şekil 4.10. Balıkların Hangi Türe Ait Olduğu Sınıflandırma Hata Matrisi 0,1 (%10) Eğitim Kümesi 50 Adet Test Kümesi

Her türe ait 50 adet veri kümesinin %20'si sınıflandırma için bilgisayarın eğitiminde, geri kalanı test aşamasında kullanılmıştır. Bu test rast gele elemanlar seçilerek 10 kez tekrarlanmıştır. Bu Monte Carlo denemeleri sonucunda Şekil 4.11'de verilen hata matrisleri belirlenmiştir. Elde edilen verilere göre 50 adet veri kümesinin kullanılarak sınıflandırmasında eğitim kümesinin %10'dan %20'ye çıkarılması ile balıkların hangi türe ait olduğunu %95'in üstünde doğru tespit etmiştir. Veri kümesinin düşük olması nedeni ile %100 doğru tespit edilememiştir.

True Class	alabalik	48	1	1	96.0%	4.0%
	cipura		50		100.0%	
	levrek			50	100.0%	
		100.0%	98.0%	98.0%		
			2.0%	2.0%		
	alabalik	cipura	levrek	Predicted Class		

Şekil 4.11. Balıkların Hangi Türe Ait Olduğu Hata Sınıflandırma Matrisi 0,2 (%20) Eğitim Kümesi 50 Adet Test Kümesi

Her türe ait 50 adet veri kümesinin %40'ı sınıflandırma için bilgisayarın eğitiminde, geri kalanı test aşamasında kullanılmıştır. Bu test rast gele elemanlar seçilerek 10 kez tekrarlanmıştır. Bu Monte Carlo denemeleri sonucunda Şekil 4.12'de verilen hata matrisleri belirlenmiştir. Elde edilen verilere göre 50 adet veri kümesinin sınıflandırmasında eğitim kümesinin %40'a çıkarılması ile balıkların hangi türe ait olduğu %95 doğru tespit edilmiş fakat veri kümesinin düşük olması nedeni ile balıkların hangi türe ait olduğu %100 doğru tespit edilememiştir.

True Class	alabalik	49		2	96.1%	3.9%
	cipura		50		100.0%	
	levrek			50	100.0%	
		100.0%	100.0%	96.2%		3.8%
		alabalik	cipura	levrek	Predicted Class	

Şekil 4.12. Balıkların Hangi Türe Ait Olduğu Sınıflandırma Hata Matrisi 0,4 (%40) Eğitim Kümesi 50 Adet Test Kümesi

Her türe ait 100 adet veri kümesinin %10'u sınıflandırma için bilgisayarın eğitiminde, geri kalanı test aşamasında kullanılmıştır. Bu test rast gele elemanlar seçilerek 10 kez tekrarlanmıştır. Bu Monte Carlo denemeleri sonucunda Şekil 4.13'te verilen hata matrisleri belirlenmiştir. Elde edilen verilere göre 100 adet veri kümesinin sınıflandırılmasında balıkların hangi türe ait olduğu %95'in üstünde doğru tespit etmiştir.

True Class	alabalik	98	1	1	98.0%	2.0%
	cipura		96	4	96.0%	4.0%
	levrek		2	98	98.0%	2.0%
		100.0%	97.0%	95.1%		
			3.0%	4.9%		
		alabalik	cipura	levrek		
		Predicted Class				

Şekil 4.13. Balıkların Hangi Türe ait Olduğu Sınıflandırma Hata Matrisi 0,1 (%10) Eğitim Kümesi 100 Adet Test Kümesi

Her türe ait 100 adet veri kümesinin %20'si sınıflandırma için bilgisayarın eğitiminde, geri kalanı test aşamasında kullanılmıştır. Bu test rast gele elemanlar seçilerek 10 kez tekrarlanmıştır. Bu Monte Carlo denemeleri sonucunda Şekil 4.14'de verilen hata matrisleri belirlenmiştir. Elde edilen verilere göre 100 adet veri kümesinin sınıflandırılmasında eğitim kümesinin %10'dan %20'ye çıkarılması ile balıkların hangi türe ait olduğunu %99 doğru tespit etmiştir.

True Class	alabalik	99	1	99.0%	1.0%
	cipura	99	1	99.0%	1.0%
	levrek	1	99	99.0%	1.0%
		100.0%	99.0%	98.0%	
		1.0%	2.0%		
		alabalik	cipura	levrek	
		Predicted Class			

Şekil 4.14. Balıkların Hangi Türe Ait Olduğu Sınıflandırma Matrisi 0,2 (%20) Eğitim Kümesi 100 Adet Test Kümesi

Her türe ait 100 adet veri kümesinin %40'a sınıflandırma için bilgisayarın eğitiminde, geri kalanı test aşamasında kullanılmıştır. Bu test rast gele elemanlar seçilerek 10 kez tekrarlanmıştır. Bu Monte Carlo denemeleri sonucunda Şekil 4.15'de verilen hata matrisleri belirlenmiştir. Elde edilen verilere göre 100 adet veri kümesinin sınıflandırılmasında eğitim kümesinin %40'a çıkarılması ile balıkların hangi türe ait olduğunu %100 doğru tespit etmiştir.

True Class	alabalik	99	1		99.0%	1.0%
	cipura		100		100.0%	
	levrek			100	100.0%	
		100.0%	99.0%	100.0%		
			1.0%			
	alabalik	cipura	levrek	Predicted Class		

Şekil 4.15. Balıkların Hangi Türe Ait Olduğu Sınıflandırma Hata Matrisi 0,4 (%40) Eğitim Kümesi 100 Adet Test Kümesi

4.3 Balıkların Tazelik Sınıflandırma Matrisleri

Her türe ait 100 adet veri kümesinin %10'u sınıflandırma için bilgisayarın eğitiminde, geri kalanı test aşamasında kullanılmıştır. Bu test rast gele elemanlar seçilerek 10 kez tekrarlanmıştır. Bu Monte Carlo denemeleri sonucunda Şekil 4.16'da verilen hata matrisleri belirlenmiştir. Elde edilen verilere göre 3 tür balığın 100 adet veri kümesinin sınıflandırılmasında balıkların taze olduğunu %96 doğru tespit etmiştir. Balıkların orta tazelikte olduğunu %83 doğru tespit etmiştir. Balıkların bayat olduğunu %88 doğru tespit etmiştir.

True Class	bayat	88	9	3	88.0%	12.0%
	orta	14	83	3	83.0%	17.0%
	taze	2	2	96	96.0%	4.0%
		84.6%	88.3%	94.1%		
		15.4%	11.7%	5.9%		
		bayat	orta	taze		
		Predicted Class				

Şekil 4.16. Balıkların Taze-Orta-Bayat Sınıflandırma Hata Matrisi 0,1 (%10) Eğitim Kümesi 100 Adet Test Kümesi

Her türe ait 100 adet veri kümesinin %20'si sınıflandırma için bilgisayarın eğitiminde, geri kalanı test aşamasında kullanılmıştır. Bu test rast gele elemanlar seçilerek 10 kez tekrarlanmıştır. Bu Monte Carlo denemeleri sonucunda Şekil 4.17'de verilen hata matrisleri belirlenmiştir. Elde edilen verilere göre 3 tür balığın 100 adet veri kümesinin sınıflandırılmasında eğitim kümesinin %10'dan %20'ye çıkarılması balıkların taze olduğunu %91 doğru tespit etmiştir. Balıkların orta tazelikte olduğunu %93 doğru tespit etmiştir. Balıkların bayat olduğunu %96 doğru tespit etmiştir.

True Class	bayat	94	6		94.0%	6.0%
	orta	7	93		93.0%	7.0%
	taze	5	4	92	91.1%	8.9%
		88.7%	90.3%	100.0%		
		11.3%	9.7%			
		bayat	orta	taze	Predicted Class	

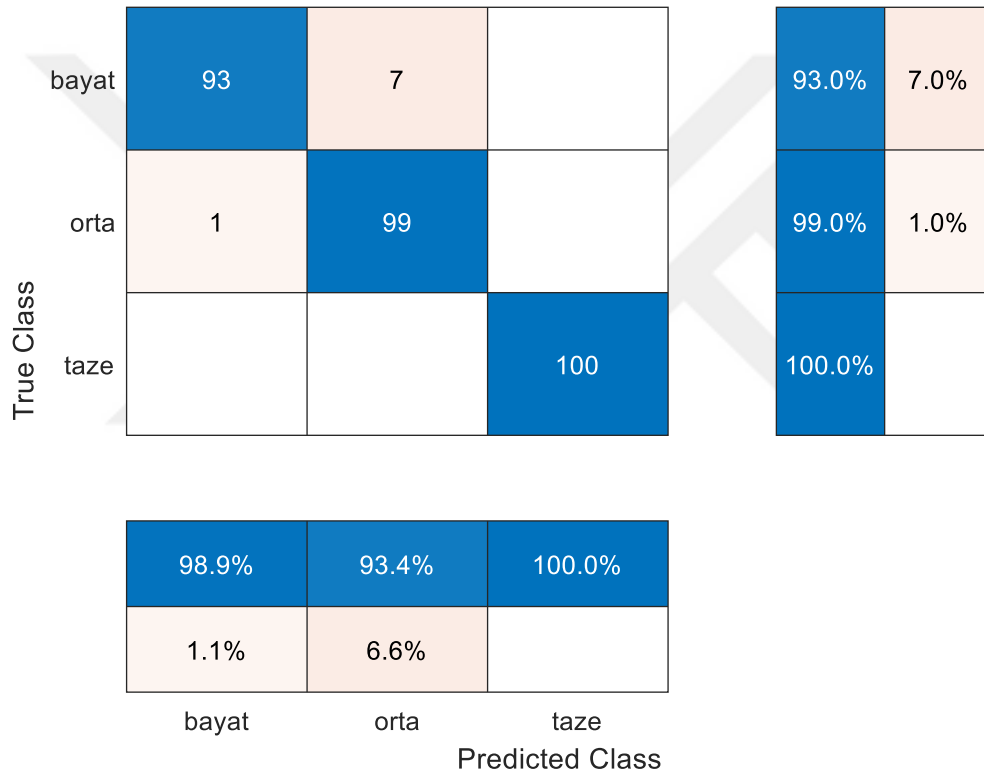
Şekil 4.17. Balıkların Taze-Orta-Bayat Sınıflandırma Hata Matrisi 0,2 (%20) Eğitim Kümesi 100 Adet Test Kümesi

Her türe ait 100 adet veri kümesinin %40'ı sınıflandırma için bilgisayarın eğitiminde, geri kalanı test aşamasında kullanılmıştır. Bu test rast gele elemanlar seçilerek 10 kez tekrarlanmıştır. Bu Monte Carlo denemeleri sonucunda Şekil 4.18'de verilen hata matrisleri belirlenmiştir. Elde edilen verilere göre 3 tür balık için 100 adet veri kümesinin sınıflandırılmasında eğitim kümesinin %20'den %40'a çıkarılması balıkların taze olduğunu %97 doğru tespit etmiştir. Balıkların orta tazelikte olduğunu %98 doğru tespit etmiştir. Balıkların bayat olduğunu %94 doğru tespit etmiştir.

True Class	bayat	94	6		94.0%	6.0%
	orta	2	98		98.0%	2.0%
	taze	1	2	97	97.0%	3.0%
		96.9%	92.5%	100.0%		
		3.1%	7.5%			
		bayat	orta	taze		
		Predicted Class				

Şekil 4.18. Balıkların Taze-Orta-Bayat Sınıflandırma Hata Matrisi 0,4 (%40) Eğitim Kümesi 100 Adet Test Kümesi

Her türe ait 100 adet veri kümesinin %60'u sınıflandırma için bilgisayarın eğitiminde, geri kalanı test aşamasında kullanılmıştır. Bu test rast gele elemanlar seçilerek 10 kez tekrarlanmıştır. Bu Monte Carlo denemeleri sonucunda Şekil 4.19'da verilen hata matrisleri belirlenmiştir. Elde edilen verilere göre 3 tür balık için 100 adet veri kümesinin sınıflandırılmasında eğitim kümesi %40'tan %60'a çıkarılması balıkların taze olduğunu %100 doğru tespit etmiştir. Balıkların orta tazelikte olduğunu %99 doğru tespit etmiştir. Balıkların bayat olduğunu %93 doğru tespit etmiştir. Veri sayısının yetersiz olması %100 doğru tespit edilmesini önlemektedir.



Şekil 4.19. Balıkların Taze-Orta-Bayat Sınıflandırma Hata Matrisi 0,6 (%60) Eğitim Kümesi 100 Adet Test Kümesi

Her türe ait 100 adet veri kümesinin %80'i sınıflandırma için bilgisayarın eğitiminde, geri kalanı test aşamasında kullanılmıştır. Bu test rast gele elemanlar seçilerek 10 kez tekrarlanmıştır. Bu Monte Carlo denemeleri sonucunda Şekil 4.20'de verilen hata matrisleri belirlenmiştir. Elde edilen verilere göre 3 tür balığın 100 adet veri kümesinin sınıflandırılmasında eğitim kümesinin %80'e çıkarılması balıkların taze ve orta tazelikte olduğunu %99 doğru tespit etmiş, balıkların bayat olduğunu %95 doğru tespit etmiştir. Veri kümesinin yetersiz olması nedeni ile balıkların tazelik bayatlık sınıflandırmasını %100 doğru tespit edememiştir.

True Class	bayat	96	5		95.0%	5.0%
	orta	1	99		99.0%	1.0%
	taze		1	99	99.0%	1.0%
		99.0%	94.3%	100.0%		
		1.0%	5.7%			
		bayat	orta	taze		
		Predicted Class				

Şekil 4.20. Balıkların Taze-Orta-Bayat Sınıflandırma Hata Matrisi 0,8 (%80) Eğitim Kümesi 100 Adet Test Kümesi

Her türe ait 500 adet veri kümesinin %10'u sınıflandırma için balıkların eğitiminde, geri kalanı test aşamasında kullanılmıştır. Bu test rast gele elemanlar seçilerek 10 kez tekrarlanmıştır. Bu Monte Carlo denemeleri sonucunda Şekil 4.21'de verilen hata matrisleri belirlenmiştir. Elde edilen verilere göre 3 tür için 500 adet veri kümesinin sınıflandırılmasında balıkların taze ve orta tazelikte olduğunu %99 doğru tespit etmiştir. Balıkların bayat olduğunu %97 doğru tespit etmiştir. Veri sayısının 100'den 500'e çıkarılması %10 bilgisayar eğitim kümesinde bile balıkların taze, orta tazelikte, bayat olarak sınıflandırılmasında %95'in üzerinde doğru tespit gerçekleştirmiştir.

True Class	bayat	482	15	2	96.6%	3.4%	
	orta	7	493		98.6%	1.4%	
	taze	3	2	495	99.0%	1.0%	
		98.0%	96.7%	99.6%	2.0%	3.3%	0.4%
		bayat	orta	taze	Predicted Class		

Şekil 4.21. Balıkların Taze-Orta-Bayat Sınıflandırma Hata Matrisi 0,1 (%10) Eğitim Kümesi 500 Adet Test Kümesi

Her türe ait 500 adet veri kümesinin %20'si sınıflandırma için bilgisayarın eğitiminde, geri kalanı test aşamasında kullanılmıştır. Bu test rast gele elemanlar seçilerek 10 kez tekrarlanmıştır. Bu Monte Carlo denemeleri sonucunda Şekil 4.22'de verilen hata matrisleri belirlenmiştir. Elde edilen verilere göre 3 tür balığın 500 adet veri kümesinin sınıflandırılmasında eğitim kümesinin %20'ye çıkarılması ile balıkların taze, orta tazelikte, bayat olarak sınıflandırılmasında %100 doğru tespit gerçekleşmiştir.

True Class	bayat	492	8		98.4%	1.6%
	orta	3	497		99.4%	0.6%
	taze			500	100.0%	
		99.4%	98.4%	100.0%		
		0.6%	1.6%			
		bayat	orta	taze	Predicted Class	

Şekil 4.22. Balıkların Taze-Orta-Bayat Sınıflandırma Hata Matrisi 0,2 (%20) Eğitim Kümesi 500 adet Test Kümesi

Her türe ait 900 adet veri kümesinin %10'u sınıflandırma için bilgisayarın eğitiminde, geri kalanı test aşamasında kullanılmıştır. Bu test rast gele elemanlar seçilerek 10 kez tekrarlanmıştır. Bu Monte Carlo denemeleri sonucunda Şekil 4.23'te verilen hata matrisleri belirlenmiştir. Elde edilen verilere göre 3 tür balığın 900 adet veri kümesinin sınıflandırılmasında eğitim kümesinin %10 olarak kullanılmasında bile balıkların taze, orta tazelikte, bayat olarak sınıflandırılmalarında %99 doğru tespit gerçekleşmiştir.

True Class	bayat	888	12		98.7%	1.3%
	orta	9	891		99.0%	1.0%
	taze	2		898	99.8%	0.2%
		98.8%	98.7%	100.0%		
		1.2%	1.3%			
		bayat	orta	taze		
		Predicted Class				

Şekil 4.23. Balıkların Taze-Orta-Bayat Sınıflandırma Hata Matrisi 0,1 (%10) Eğitim Kümesi 900 Adet Test Kümesi

Her türe ait 900 adet veri kümesinin %20'si sınıflandırmanın eğitiminde, geri kalanı test aşamasında kullanılmıştır. Bu test rast gele elemanlar seçilerek 10 kez tekrarlanmıştır. Bu Monte Carlo denemeleri sonucunda Şekil 4.24'te verilen hata matrisleri belirlenmiştir. Elde edilen verilere göre 3 tür balığın 900 adet veri kümesinin sınıflandırılmasında eğitim kümesinin %10'dan %20'ye çıkarılması balıkların taze, orta-taze, bayat olarak sınıflandırmalarında %100 doğru tespit yapmıştır.

True Class	bayat	891	8		99.1%	0.9%
	orta	2	898		99.8%	0.2%
	taze			900	100.0%	
		99.8%	99.1%	100.0%		
		0.2%	0.9%			
		bayat	orta	taze		
		Predicted Class				

Şekil 4.24. Balıkların Taze-Orta-Bayat Sınıflandırma Hata Matrisi 0,2 (%20) Eğitim Kümesi 900 Adet Test Kümesi

5 TARTIŞMA VE SONUÇ

Yavuzer [38], ceviz yeşil kabuğu ekstraktı ile hazırlanmış buz ile depolanmış alabalık filetolarının buzda depolama süresince kontrol grubunun mikrobiyolojik, kimyasal ve duyuşsal olarak kalite parametrelerinde düzenli düşme olduğunu bildirmiştir. Söz konusu çalışmada Toplam Aerobik Mezofil Bakteri Sayısı açısından 7. günden itibaren balıkların istenmeyen kalite şartlarına geldiği rapor edilmiştir.

Alabalığın buzda depolandığı başka bir çalışmada Yavuzer vd., [39], 25 günlük depolama süresince TVB-N, PV ve TBA değerlerinin depolamanın 4. Gününden itibaren artmaya başladığı belirlenmiştir. Depolama sonunda TVB-N değerinin 25,1 mg/100 g, TBA değerinin 0.84 mg MDA/kg ve PV değerinin 13.80 meq O₂/kg olarak belirlendiği bildirilmiştir. Çalışma verileri mikrobiyolojik olarak balığın istenmeyen bozulma eşiğine gelme noktasına 4. günden sonra başladığı belirlenmiştir.

Ozogul vd., [1], kültür alabalığın başlangıç TVC değerini 3.59 log CFU/g olarak bulmuşlar ve depolama süresince kalite parametrelerindeki düşüşün mikrobiyal ve kimyasal analiz sonuçlarındaki artışa bağılı olarak düştüğünü bildirmişlerdir. Balığın duyuşsal olarak reddedildiği depolamanın 14. gününde de TVC'nin 6.35 log CFU/g olduğunu rapor etmişlerdir

Alabalığın kalite parametrelerinin Arduino mikrokontrolör ile belirlendiği bir başka çalışmada Yavuzer [13], TVC, PTC ve Enterobacteriaceae düzeylerinin depolamanın 4. gününden sonra istenmeyen seviyelere yaklaştığı bildirilmiştir.

Buzdolabı koşullarında 16 gün depolanan çipuranın kalite değişimlerinin incelendiği bir çalışmada Cai vd., [40], TVB-N değerinin depolamanın 8. Gününden itibaren 20 mg/100 g seviyelerine yaklaştığını ve bu günden sonra balığın kalite parametrelerinde hızlı artış olduğunu bildirmişlerdir

Parlapani vd., [41], çipuraya ait istenmeyen kimyasal kalite parametrelerinin ve mikrobiyal üst seviyenin depolamanın 4. gününden itibaren başladığını, depolama süresi arttıkça çipura filetolarının uçucu organik bileşiklerin varlığında da artış olduğunu bildirmişlerdir.

Özyurt vd., [42], Çipuranın depolama süresince lipit oksidasyonu seviyesindeki artışı kimyasal analizler ile tespit etmişler FFA, PV ve TBA gibi değerlerin depolama süresince arttığını bildirmişlerdir. Papadopoulos vd., [43] ise buzda depolanan Levreklerin raf ömrünü 8 gün olarak rapor etmiştir. Ayrıca Özogul vd., [44] buzsuz depolanan levreklerin 4 gün raf ömrüne sahip olduğunu bildirmiştir.

Gelişen teknoloji ile makine öğrenimi birçok endüstride anlamlı değişiklikler başlatmış ve gösterdiği yüksek performans ile önemli sorunların ortadan kaldırılmasını sağlamıştır. Bu tez çalışmasında kullanılan farklı türdeki balıkların kalite parametreleri değerlendirilmiştir.

Çalışmada, görüntülerden elde edilen Convolutional neural networks (CNN) özelliklerinin kullanıldığı görüntüleri sınıflandırmak için bir destek vektör makinesi olan ve support vector machine (SVM) olarak bilinen algoritma kullanılmıştır. CNN'nin ilk katmanı, görüntülerin giriş boyutlarını belirtmiştir. Tez çalışması için her 3 tür balıktan toplam 21.380 adet balık görüntüsü kullanılmıştır. Yapılan analizler neticesinde kullanılan balıkların tür sınıflandırmaları, aynı türün taze, orta, bayat olarak sınıflandırmaları ve aynı türe ait balıkların kaçınıcı güne ait olduğunun belirlenmesi makine öğrenmesi ile yüksek başarımlı olarak belirlenmesi hedeflenmiştir. Kullanılan verilerden belirlenen %lik kısım 0,1: %10, 0,2: %20, 0,4: %40, 0,6: %60, 0,8: %80 bilgisayarın eğitimi için kullanılmış geriye kalan %'lik kısım test edilmiştir.

Aynı türe ait balıkların kaçınıcı güne ait olduğunun belirlendiği çalışmada her 3 tür içinde 480 adet veri ile çalışılmıştır. Bu verilerden 0,1: %10, 0,2: %20, 0,4: %40'lık 3 farklı veri kümesi bilgisayarın eğitiminde geriye kalan %lik kısım test aşamasında kullanılmıştır. Monte Carlo denemeleri sonucunda elde edilen hata matrislerine göre balıkların kaçınıcı güne ait olduğu 0,1'lik eğitim kümesinde başarımlı %90'larda iken eğitim kümesinin 0,2, 0,4'e çıkarılması başarımlı %100 ulaştırmıştır. 0,6 ve 0,8'lik eğitim kümesinin kullanılmasına gerek kalmamıştır.

Balıkların tür sınıflandırılmasında 50 ve 100'er adetlik veri ile çalışılmıştır. 50 adet veri ile yapılan sınıflandırma çalışmasında 0,1, 0,2, 0,4'lük eğitim kümesi ile çalışılmıştır. Monte Carlo denemeleri sonucunda elde edilen hata matrislerine göre her 3 eğitim kümesinde de başarımlı %90 üzerindedir fakat veri kümesi sayısı düşük olduğu için %100 başarımlı göstermemiştir. Kullanılan veri sayısı 100'e çıkarıldığı zaman 0,1 eğitim kümesinde başarımlı %90 üzeri çıkmakta iken eğitim kümesinin 0,2 ve 0,4 e yükseltilmesi başarımlı %99'un üzerine çıkarmıştır. 0,6 ve 0,8 eğitim kümesinin kullanılmasına gerek kalmamıştır.

Balıkların tazelik bayatlık sınıflandırılmalarında 100, 500 ve 900 adetlik veriler ile çalışılmıştır. Kullanılan 100 adet veri ile yapılan çalışmada 0,1, 0,2, 0,3, 0,4, 0,6, 0,8'lik eğitim kümeleri kullanılmıştır. 0,1 eğitim kümesi kullanılarak gerçekleştirilen çalışmada başarımların %90'ın altında iken eğitim kümesi oranı yükseldikçe başarımlar artmış fakat veri kümesinin yetersizliğinden dolayı %100 başarımlar elde edilememiştir. 500 adet veri ile yapılan sınıflandırmada 0,1'lik eğitim kümesi ile yapılan denemede başarımların %95 üzerine çıkmış, eğitim kümesi 0,2'ye yükseltildiği zaman başarımların %99 ulaşılmıştır. 900 adet veri ile yapılan sınıflandırmada 0,1'lik eğitim kümesinde başarımların %99 iken eğitim kümesi 0,2 ye çıkarılınca başarımların %100 olmuş diğer eğitim kümelerinin kullanılmasına gerek kalmamıştır.



KAYNAKLAR

- [1] F. Ozogul, E. Yavuzer, Y. Ozogul, and E. Kuley, "Comparative quality loss in wild and cultured rainbow trout (*Oncorhynchus mykiss*) during chilling storage," *Food Sci Technol Res*, vol. 19, no. 3, pp. 445-454, 2013.
- [2] E. Yavuzer, "Development of defective fish egg sorting machine with colour sensor for trout facilities," *Aquac Res*, vol. 49, no. 11, pp. 3634-3637, 2018.
- [3] Y. Zhu *et al.*, "The migration of docosahexenoic acid (DHA) to the developing ovary of female zebrafish (*Danio rerio*)," *Comparative Biochemistry and Physiology Part A: Molecular & Integrative Physiology*, vol. 233, pp. 97-105, 2019.
- [4] O. P. Ward and A. Singh, "Omega-3/6 fatty acids: alternative sources of production," *Process biochemistry*, vol. 40, no. 12, pp. 3627-3652, 2005.
- [5] W. S. Fenton, J. Hibbeln, and M. Knable, "Essential fatty acids, lipid membrane abnormalities, and the diagnosis and treatment of schizophrenia," *Biological psychiatry*, vol. 47, no. 1, pp. 8-21, 2000.
- [6] B. Y. Setty *et al.*, "Relationship of Omega-3 fatty acids DHA and EPA with the inflammatory biomarker hs-CRP in children with sickle cell anemia," *Prostaglandins, Leukotrienes and Essential Fatty Acids*, vol. 146, pp. 11-18, 2019.
- [7] D. Gordon and V. Ratliff, "The implications of omega 3 fatty acids in human health," *Advances in seafood biochemistry composition and quality*, Technomic Publishing Co. Inc, pp. 69-98, 1992.
- [8] P. Çelik, "Kanatlı eti (hindi eti ve tavuk eti) ve kırmızı et karışımı ile elde edilen köftelerin kalite özelliklerinin belirlenmesi," Namık Kemal Üniversitesi, 2012.
- [9] H. Ertaş, "Balıkların Soğutma-Dondurma ve Salamura Metodları ile Muhafazası," *Gıda*, vol. 3, no. 6, 1978.
- [10] J. Freitas, P. Vaz-Pires, and J. S. Câmara, "Quality Index Method for fish quality control: Understanding the applications, the appointed limits and the upcoming trends," *Trends in Food Science & Technology*, vol. 111, pp. 333-345, 2021.
- [11] A. E. Ghaly, D. Dave, S. Budge, and M. Brooks, "Fish spoilage mechanisms and preservation techniques," *American journal of applied sciences*, vol. 7, no. 7, p. 859, 2010.
- [12] M. Shawyer and A. M. Pizzali, *The use of ice on small fishing vessels* (no. 436). Food & Agriculture Org., 2003.
- [13] E. Yavuzer, "Determination of rainbow trout quality parameters with Arduino microcontroller," *Journal of Food Safety*, vol. 40, no. 6, p. e12857, 2020.
- [14] L. Cao *et al.*, "Essential oil composition, antimicrobial and antioxidant properties of *Mosla chinensis* Maxim," *Food Chemistry*, vol. 115, no. 3, pp. 801-805, 2009.
- [15] X. Huang, J. Xin, and J. Zhao, "A novel technique for rapid evaluation of fish freshness using colorimetric sensor array," *Journal of Food Engineering*, vol. 105, no. 4, pp. 632-637, 2011.
- [16] R. Woods and R. Gonzalez, "Real-time digital image enhancement," *Proceedings of the IEEE*, vol. 69, no. 5, pp. 643-654, 1981.

- [17] M. Peker, "Görüntü işleme tekniği kullanılarak gerçek zamanlı hareketli görüntü tanıma," Sakarya Üniversitesi, 2009.
- [18] E. Yavuzer and M. Köse, "Prediction of fish quality level with machine learning," *International Journal of Food Science & Technology*, vol. 57, no. 8, pp. 5250-5255, 2022.
- [19] G. M. Perihanoğlu, "Dijital görüntü işleme teknikleri kullanılarak görüntülerden detay çıkarımı," Fen Bilimleri Enstitüsü, 2015.
- [20] K. Kayaalp and S. Metlek, "Derin Öğrenme ile Balık Türlerinin Tespiti," *International Journal of 3D Printing Technologies and Digital Industry*, vol. 5, no. 3, pp. 569-576, 2021.
- [21] M. Nagata, B. P. Shrestha, and Y. Gejima, "Study on Quality Estimation for Strawberry using Color and NIR Image Processing," *IFAC Proceedings Volumes*, vol. 34, no. 28, pp. 233-237, 2001.
- [22] M. K. Dutta, A. Issac, N. Minhas, and B. Sarkar, "Image processing based method to assess fish quality and freshness," *Journal of Food Engineering*, vol. 177, pp. 50-58, 2016.
- [23] J. Xing, W. Saeys, and J. De Baerdemaeker, "Combination of chemometric tools and image processing for bruise detection on apples," *Computers and electronics in agriculture*, vol. 56, no. 1, pp. 1-13, 2007.
- [24] K. Sabancı, C. Aydın, and M. F. Ünlerşen, "Görüntü işleme ve yapay sinir ağları yardımıyla patates sınıflandırma parametrelerinin belirlenmesi," *Journal of the Institute of Science and Technology*, vol. 2, no. 2 Sp: A, pp. 59-62, 2012.
- [25] M. Momin, M. Rahman, M. Sultana, C. Igathinathane, A. Ziauddin, and T. Grift, "Geometry-based mass grading of mango fruits using image processing," *Information processing in agriculture*, vol. 4, no. 2, pp. 150-160, 2017.
- [26] A. Masoumi, "Görüntü İşleme Tekniği İle Ekmeklik Buğday Çeşidinde Kaliteye Esas Bazı Özelliklerin Belirlenmesi," *Ege Üniversitesi Fen Bilimleri Enstitüsü Yüksek Lisans Tezi*, 2013.
- [27] M. Ceyhan, "Ülkesel ekmeklik buğday alımı için derin öğrenme tabanlı buğday sınıflandırma," ESOGÜ, Fen Bilimleri Enstitüsü, 2021.
- [28] K. Özkan, S. Erol, and I. Şahin, "Wheat kernels classification using visible-near infrared camera based on deep learning," *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi*, vol. 27, no. 5, pp. 618-626, 2021.
- [29] D. Ünay, "Meyve ve Sebzelerin Otomatik Sınıflandırılması için Farklı Derin Öğrenme Yöntemlerinin Karşılaştırılması Analizi," *Turkish Studies-Information Technologies and Applied Sciences*, vol. 15, no. 4, pp. 533-544, 2020.
- [30] M. Türkoğlu, "Evrişimsel Sinir Ağları Kullanılarak Yumurta Kabuğu Kusurlarının Tespiti," *Türk Tarım-Gıda Bilim ve Teknoloji dergisi*, vol. 9, no. 3, pp. 559-567, 2021.
- [31] S. Solak and U. Altınışik, "Görüntü işleme teknikleri ve kümeleme yöntemleri kullanılarak fındık meyvesinin tespit ve sınıflandırılması," *Sakarya University Journal of Science*, vol. 22, no. 1, pp. 56-65, 2018.
- [32] Coşkun Volkan, "Derin öğrenme ile içecek şişe kapağı üzerindeki görsellerden ürün tipi tanıma," Yüksek lisans, Beykent Üniversitesi, Yüksek Lisans Enstitüsü, Beykent Üniversitesi, Yüksek Lisans Enstitüsü, 2020.

- [33] M. Aslan, "Derin Öğrenme ile Şeftali Hastalıklarının Tespiti," *Avrupa Bilim ve Teknoloji Dergisi*, no. 23, pp. 540-546, 2021.
- [34] Buluş Aysin, " Derin öğrenme yöntemleri ile meyvelerin tazelik durumunun belirlenmesi," Yüksek Lisans, Tekirdağ Namık Kemal Üniversitesi Fen Bilimleri Enstitüsü, Tekirdağ Namık Kemal Üniversitesi Fen Bilimleri Enstitüsü, 2022.
- [35] Aydın Ahmet, "Görüntü İşleme ve Derin Öğrenme Yöntemleri ile Çelik Yüzey Kusurlarının Tespiti ve Sınıflandırılması," Yüksek Lisans, Fırat Üniversitesi Fen Bilimleri Enstitüsü, Fırat Üniversitesi Fen Bilimleri Enstitüsü, 2022.
- [36] F. Doğan and İ. Türkoğlu, "Derin öğrenme algoritmalarının yaprak sınıflandırma başarımlarının karşılaştırılması," *Sakarya University Journal of Computer and Information Sciences*, vol. 1, no. 1, pp. 10-21, 2018.
- [37] İ. Özkan and E. Ülker, "Derin öğrenme ve görüntü analizinde kullanılan derin öğrenme modelleri," *Gaziosmanpaşa Bilimsel Araştırma Dergisi*, vol. 6, no. 3, pp. 85-104, 2017.
- [38] E. Yavuzer, "Ceviz Yeşil Kabuğu Özütü İle Hazırlanan Buzun Gökkuşluğu Alabalığı (*Oncorhynchus mykiss*) Filetolarının Kalite Özelliklerine Etkisi," *Journal of Limnology and Freshwater Fisheries Research*, vol. 4, no. 3, pp. 146-153, 2018.
- [39] E. Yavuzer, F. Özogul, and Y. Özogul, "Impact of icing with potato, sweet potato, sugar beet, and red beet peel extract on the sensory, chemical, and microbiological changes of rainbow trout (*Oncorhynchus mykiss*) filets stored at (3±1° C)," *Aquaculture International*, vol. 28, no. 1, pp. 187-197, 2020.
- [40] L. Cai, X. Wu, Z. Dong, X. Li, S. Yi, and J. Li, "Physicochemical responses and quality changes of red sea bream (*Pagrosomus major*) to gum arabic coating enriched with ergothioneine treatment during refrigerated storage," *Food chemistry*, vol. 160, pp. 82-89, 2014.
- [41] F. F. Parlapani, A. Mallouchos, S. A. Haroutounian, and I. S. Boziaris, "Microbiological spoilage and investigation of volatile profile during storage of sea bream filets under various conditions," *International journal of food microbiology*, vol. 189, pp. 153-163, 2014.
- [42] G. Özyurt, A. S. Özkütük, and A. Polat, "Capability of the rosemary (*Rosmarinus officinalis*) extract on the oxidative stability of cooked sea bream (*Sparus aurata*) during frozen storage," *Journal für Verbraucherschutz und Lebensmittelsicherheit*, vol. 6, no. 2, pp. 167-174, 2011.
- [43] V. Papadopoulos, I. Chouliara, A. Badeka, I. Savvaidis, and M. Kontominas, "Effect of gutting on microbiological, chemical, and sensory properties of aquacultured sea bass (*Dicentrarchus labrax*) stored in ice," *Food microbiology*, vol. 20, no. 4, pp. 411-420, 2003.
- [44] F. Özogul, C. Gökbulut, G. Özyurt, Y. Özogul, and M. Dural, "Quality assessment of gutted wild sea bass (*Dicentrarchus labrax*) stored in ice, cling film and aluminium foil," *European Food Research and Technology*, vol. 220, no. 3, pp. 292-298, 2005.

ÖZGEÇMİŞ



Kişisel Bilgiler	
Adı Soyadı	Özkan DOĞAN
Doğum Yeri	
Doğum Tarihi	
Uyruğu	☐ T.C. ☼ Diğer:

Eğitim Bilgileri	
Lisans	
Üniversite	Çukurova Üniversitesi
Fakülte	Ziraat Fakültesi
Bölümü	Gıda Mühendisliği
Mezuniyet Yılı	2005

Makale ve Bildiriler
<ol style="list-style-type: none">Doğan, Ö., Yavuzer, E., Köse, M., Tekle, Ş., 2022, Makine Öğrenimi ile Balık Tazelik Seviyesinin Tahmini, 5. International Eurasian Conference on Biological and Chemical Sciences (5. Uluslararası Avrasya Biyolojik ve Kimya Bilimleri Konferansı), Eurasianbiochem 2022, 23-25 Kasım 2022, Ankara/Türkiye, Ankara, 978-605-72134-0-2Doğan Özkan, Tekle Şefik, Yavuzer Emre, Yayın Yeri: International Symposium On Engineering, Natural And Social Sciences, 28.11.2021