



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



# TAVUK ÜRÜNLERİNİN DERİN ÖĞRENME YARDIMIYLA SINIFLANDIRILMASI

MUSTAFA ALI HUSSEIN HUSSEIN

YÜKSEK LİSANS TEZİ

KIRŞEHİR

2024



T.C.

KIRSEHİR AHI EVRAN ÜNİVERSİTESİ

FEN BİLİMLERİ ENSTİTÜSÜ

İLERİ TEKNOLOJİLER ANABİLİM DALI



# TAVUK ÜRÜNLERİNİN DERİN ÖĞRENME YARDIMIYLA SINIFLANDIRILMASI

MUSTAFA ALI HUSSEIN HUSSEIN

YÜKSEK LİSANS TEZİ

DANIŞMAN

DR. ÖĞR. ÜYESİ MEMDUH KÖSE

KIRSEHİR

2024

**KIRŐEHİR AHİ EVRAN ÜNİVERSİTESİ FEN BİLİMLERİ ENSTİTÜSÜ**  
**YÜKSEK LİSANS TEZ ÇALIŐMASI**  
**ETİK BEYANI**

Kırőehir Ahi Evran Üniversitesi Bilimsel Arařtırma ve Yayın Etięi Yönergesini okuduęumu ve anladığımı ve Kırőehir Ahi Evran Üniversitesi Fen Bilimleri Enstitüsü Tez Yazım Kurallarına uygun olarak hazırladığım bu tez çalışmasında;

- Tez içinde sunduęum verileri, bilgileri ve dokümanları akademik ve etik kurallar çerçevesinde elde ettięimi,
- Tüm bilgi, belge, deęerlendirme ve sonuçları bilimsel etik kurallarına uygun olarak sunduęumu,
- Tez çalışmasında yararlandığım eserlerin tümüne uygun atıfta bulunarak kaynak gösterdiğimi,
- Kullanılan verilerde ve ortaya çıkan sonuçlarda herhangi bir deęişiklik yapmadığımı,
- Tez olarak sunduęum bu çalışmanın özgün olduęunu,

bildirir, aksi bir durumda bu konuda hakkımda yapılacak tüm yasal işlemleri ve aleyhime doğabilecek tüm hak kayıplarını kabullendięimi beyan ederim. 15/01/2024

Öęrenci

Mustafa Ali Hussein HUSSEIN

<b>İÇİNDEKİLER DİZİNİ.....</b>	<b>I</b>
<b>TEŞEKKÜR.....</b>	<b>III</b>
<b>ÖZET .....</b>	<b>IV</b>
<b>ABSTRACT .....</b>	<b>V</b>
<b>TABLolar DİZİNİ .....</b>	<b>VI</b>
<b>ŞEKİLLER DİZİNİ .....</b>	<b>VII</b>
<b>SİMGELER VE KISALTMALAR DİZİNİ.....</b>	<b>VIII</b>
<b>1. GİRİŞ.....</b>	<b>1</b>
<b>2. ÖNCEKİ ÇALIŞMALAR.....</b>	<b>3</b>
<b>3. MATERYAL VE METOT .....</b>	<b>9</b>
3.1. Sınıflandırma sistemi .....	9
3.2. Derin Öğrenme .....	9
3.3. Önceden Eğitilmiş Ağlarla Öznitelik Çıkarma .....	11
3.4. Önceden Eğitilmiş Derin Sinir Ağları.....	12
3.5. ResNet-50 Modeli.....	13
3.6. ResNet-50 Yapısı.....	14
3.7. ResNet-50'nin özellikleri .....	15
3.8. Mimari.....	16
3.9. Tavuk Ürünlerinden Verilerin Toplanması.....	17
3.10. Makine Öğrenimi Koşulları .....	18
3.11. Resnet-50 Matlab Kullanımı.....	19
<b>4. BULGULAR VE TARTIŞMA .....</b>	<b>21</b>
4.1. Sınıf Bazında Sınıflandırma .....	21
4.2. Gün Bazında Sınıflandırma .....	21
4.2.1. Göğüs'ün gün bazlı sınıflandırması .....	21
4.2.2. Baget'in gün bazlı sınıflandırması.....	30
4.2.3. But'un gün bazlı sınıflandırması .....	31
4.2.4. Bütün kanat'ın gün bazlı sınıflandırması.....	32
4.2.5. Kanat'ın gün bazlı sınıflandırması.....	33
<b>5. SONUÇLAR VE ÖNERİLER.....</b>	<b>35</b>
<b>6. KAYNAKLAR .....</b>	<b>37</b>



## TEŐEKKÜR

Bu alıőmamda gsterdiĐi byk aba, zen ve akademik yardımdan dolayı danıőmanım olan Dr. Đr. yesi Memduh KSE'ye en derin őkranlarımı ve teőekkrlerimi sunmak isterim. Bu hedefe ulaőmada srekli ilham ve cesaret veren anne ve babama teőekkr etmek istiyorum. Bana her zaman destek olan dostlarıma minnettarım. Bana alıőkan bir insan olma gc ve azmini veren Yaradan'a őkrediyorum.

Ocak, 2024

Mustafa Ali Hussein HUSSEIN



## ÖZET

### YÜKSEK LİSANS TEZİ

## TAVUK ÜRÜNLERİNİN DERİN ÖĞRENME YARDIMIYLA SINIFLANDIRILMASI

Mustafa Ali Hussein HUSSEIN

KIRŞEHİR AHI EVRAN ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ  
İLERİ TEKNOLOJİLER ANABİLİM DALI

Danışman: Dr. Öğr. Üyesi Memduh KÖSE  
Yıl: 2024 Sayfa: 40  
Jüri: Dr. Öğr. Üyesi Memduh KÖSE  
Doç. Dr. Filiz SARI  
Dr. Öğr. Üyesi İbrahim ŞANLIALP

Gıda ürünlerinin saklanması, izlenmesi ve tüketilmesi ile ilgili bilgiler insan hayatında kritik öneme sahiptir. İnsanların günlük hayatta en çok tükettiği tavuk ürünleri bu ürünler arasında en önemli gıda ürünü sayılmaktadır. Bu ürünlerin son kullanıcıya ulaşıncaya kadar iyi koşullarda saklanması ve kullanıcıya ulaştırılması gerekir. Otomatik sistemler olmakla birlikte bu sistemlerin kontrolü yine insan tarafından yapılmaktadır. Nesnelerin interneti bunu kolaylaştırmakla birlikte tavuk ürünlerinin gerçek zamanlı sistemler tarafından kontrolü ve izlenimi çok önemlidir. Derin öğrenme, görüntülerin kullanıldığı izleme sistemlerinde sıklıkla kullanılır. Bu çalışmada marketlerde satılan ve sıklıkla tüketilen beş çeşit tavuk ürünü derin öğrenme yöntemiyle sınıflandırılmıştır. Herbir ürün uygun saklama koşullarında saklanarak bir hafta boyunca görüntüleri kaydedilmiştir. Görüntüler derin öğrenme modellerinden Resnet-50 ile gün bazlı olarak sınıf içi sınıflandırılmıştır. Her sınıf için toplanan görüntüler kullanılarak sınıflararası bazda sınıflandırılmıştır. Derin öğrenme kullanılarak tavuk ürünleri gün bazında sınıf içi ve sınıflararası %94'ün üzerinde başarımla sınıflandırılmıştır.

**Anahtar Kelimeler:** Derin öğrenme, ResNet-50, Sınıflandırma

## ABSTRACT

### MASTER'S THESIS

#### CLASSIFICATION OF CHICKEN PRODUCTS BY DEEP LEARNING

Mustafa Ali Hussein HUSSEIN

KIRŞEHİR AHİ EVRAN UNIVERSITY  
INSTITUTE OF NATURAL AND APPLIED SCIENCES  
DEPARTMENT OF ADVANCED TECHNOLOGIES

**Supervisor:** Asst. Prof. Dr. Memduh KÖSE  
Year: 2024 Pages: 40  
**Juries:** Asst. Prof. Dr. Memduh KÖSE  
Doç. Dr. Filiz SARI  
Dr. Öğr. Üyesi İbrahim ŞANLIALP

Information regarding the storage, monitoring and consumption of food products is of critical importance in human life. Chicken products, which people consume most in daily life, are considered the most important food product among these products. These products must be stored and delivered in good conditions until they reach the end user. Although there are automatic systems, these systems are still controlled by humans. While the internet of things makes this easier, the control and monitoring of chicken products by real-time systems is very important. Deep learning is frequently used in tracking systems where images are used. In this study, six types of chicken products sold in markets and frequently consumed were classified using the deep learning method. Each product was stored under appropriate storage conditions and sufficient images were recorded for a week. These recorded images were classified in-class on a daily basis with ResNet-50, one of the deep learning models. It is also classified on a class-by-class basis. Chicken products were classified with a deep learning algorithm with over 94% success in inter-class and intra-class classification.

**Keywords:** Deep learning, ResNet-50, Classification



## TABLolar DİZİNİ

Sayfa No

<b>Tablo 2.1.</b> ESA modelleri üzerine ilgili çalışmaların özeti .....	7
<b>Tablo 3.1.</b> Eğitilmiş ağ özellikleri (Beale ark.,2023) .....	14



## ŞEKİLLER DİZİNİ

Sayfa No

Şekil 3.1. Sınıflandırma sistemi blok diagramı.....	9
Şekil 3.2. Derin öğrenme blok diagramı .....	11
Şekil 3.3. Eğitilmiş ağlar seçim grafiği (Beale ark.,2023).....	15
Şekil 3.4. ResNet-50 modeli özellikleri .....	15
Şekil 3.5. ResNet-50 mimarisi .....	15
Şekil 3.6. ResNet-50 kalan öğrenme: yapı taşı .....	15
Şekil 3.7. Tavuk ürünleri veri setinden örnekler.....	15
Şekil 4.1. Tavuk ürünleri 1. gün sınıflar arası karışıklık matrisleri .....	22
Şekil 4.2. Tavuk ürünleri 2. gün sınıflar arası karışıklık matrisleri .....	23
Şekil 4.3. Tavuk ürünleri 3. gün sınıflar arası karışıklık matrisleri .....	23
Şekil 4.4. Tavuk ürünleri 4. gün sınıflar arası karışıklık matrisleri .....	24
Şekil 4.5. Tavuk ürünleri 5. gün sınıflar arası karışıklık matrisleri .....	25
Şekil 4.6. Tavuk ürünleri 6. gün sınıflar arası karışıklık matrisleri .....	25
Şekil 4.7. Tavuk ürünleri 7. gün sınıflar arası karışıklık matrisleri .....	26
Şekil 4.8. Sınıflar arası sınıflandırma başarımları kutu diagramı.....	26
Şekil 4.9. Sınıflar arası sınıflandırma başarımları.....	27
Şekil 4.10. Tavuk ürünleri gün bazlı sınıflandırma kutu diagramları.....	28
Şekil 4.11. Tavuk ürünleri gün bazlı sınıflandırma başarımları .....	29
Şekil 4.12. Göğüs sınıf içi gün bazlı sınıflandırma.....	30
Şekil 4.13. Baget sınıf içi gün bazlı sınıflandırma.....	31
Şekil 4.14. But sınıf içi gün bazlı sınıflandırma .....	32
Şekil 4.15. Bütün kanat sınıf içi gün bazlı sınıflandırma.....	32
Şekil 4.16. Kanat sınıf içi gün bazlı sınıflandırma.....	33

## SİMGELER VE KISALTMALAR DİZİNİ

<b>Kısaltmalar</b>		<b>Açıklama</b>
<b>ANN</b>	:	Artificial Neural Network (Yapay Sinir Ağı)
<b>ESA</b>	:	Evrişimli Sinir Ağı
<b>GPU</b>	:	Graphics Processing Unit (Grafik İşleme Birimi)
<b>YSA</b>	:	Yapay Sinir Ağları



## 1. GİRİŞ

Günümüzde gıda güvenliği ilkelerinin halk sağlığının korunmasında uygulanmasıyla birlikte sağlık/gıda ilişkisi daha anlaşılır hale gelmiştir. Bu bağlamda insan vücudunda üretilmeyen ve dışarıdan almamız gereken besinler ile bu besinlerin insan vücuduna yapacağı olumlu katkıların önemi gün geçtikçe artmaktadır. Bu yiyeceklerden biri de tavuklardır. ABD Tarım Bakanlığı'na göre, 100 gramında 21 gram protein bulunan yerel tavuk göğsü, en iyi protein kaynaklarından biridir. Protein beslenmede önemli bir rol oynar ve kasların yapı taşları olan amino asitlerden oluşur. Genel olarak önerilen günlük protein ihtiyacı miktarı 1 kg vücut ağırlığı başına 1 gram veya 0.5 kg vücut ağırlığı başına 0.4 gram proteindir. Sporcular için günlük protein gereksinimi 0.5 kg başına 0.6 gram ile 0.9 gram arasında değişmektedir. Yerel tavuk etindeki D vitamini, kalsiyumun emilmesine ve kemiklerin güçlenmesine yardımcı olur. A vitamini ayrıca görme yeteneğinin güçlenmesine yardımcı olur ve bağışıklık sisteminde önemli bir rol oynar. Demir gibi mineraller hemoglobin oluşumunda, kasların aktive edilmesinde ve aneminin önlenmesinde faydalıdır. Potasyum ve sodyum sıvı dengesine yardımcı olan elektrolitlerdir; fosfor ise zayıflığa, kemik sağlığına, beyin fonksiyonuna, diş sağlığına ve metabolik sorunlara yardımcı olur.

Gıda üretim, tedarik ve arz güvenliğinde test, izleme ve kontrol süreçleri önemli bir yere sahiptir. Bu öneminden dolayı zaman bu süreçlerde çok önemli bir parametredir. Gıda izleniminde test süresi uzarsa şirketler para ve zaman kaybına uğrayarak büyük zarar uğrarlar ve buda şirketin itibar kaybına sebep olur. Bu süreçlere müdahale ederek zamanın azaltılması ya da farklı ve hızlı süreçler ortaya konması gerekir. Görüntü işleme teknikleride gıda izleme ve kalitesinin belirlenmesinde son zamanlarda sıklıkla kullanılmaya başlanmış yöntemlerdir. Makine öğrenmesi kullanılarak gıdaların kaliteleri tespit edilmekte test süreçlerinin azaltılması için böylece yollar aranmaktadır. Bu yöntemle gıdaların miktar, bozunum, kalite belirteçleri analiz edilebilmektedir. Makine öğrenmesi meyve, hayvansal gıdalar, stok zincirinde ve ulaşım ağında kolay uygulanabilir bir yöntemdir. Son kullanıcılarda evlerinde stok takibi ve gıdaların kalitesini izleyebilir hale gelmektedirler. Buzdolaplar, fırınlar, mutfak eşyaları gibi elektronik eşyaların nesnelere internetinide kullanarak makine öğrenmesi ile insanlara bu konuda işlerinde yardımcı olmaktadır. Bu kullanıcının hem zaman kaybını önlemekte hem de gıda güvenliği açısından yardımcı olmaktadır.

Bu çalışma sınıflandırmada tavuk ürünlerinin kullanıldığı ve önceden eğitilmiş ağlarla sınıflandırıldığı özgün bir çalışmadır. Çalışmada Bölüm 2’de önceki çalışmalar, Bölüm 3’te materyal ve metod kısmında kullanılan yöntem hakkında bilgi verilecek, Bölüm 4’te bulgulardan bahsedilerek bölüm 5’te sonuçlar ile çalışma sonlandırılacaktır.



## 2. ÖNCEKİ ÇALIŞMALAR

Gıdaların görüntüleri kullanılarak sınıflandırılması hız ve kolaylık sağlamaktadır. Kimyasal ve biyolojiksistemlerin analizi bu sistemler kadar hızlı değildir. Köse (2023) görüntü işlemede derin öğrenmenin öznelik çıkarımında kullanımını göstermiştir. Farklı insan görüntülerini Resnet-50 modeli kullanarak sınıflandırmıştır. Hussein ve ark. (2023) tavuk ürünlerini derin öğrenme teknikleri kullanarak sınıflandırmıştır. Bu çalışmada önceden eğitilmiş ağ olan ResNet-50 modelini kullanılmıştır. Bu metodun Matlab yazılım ortamında nasıl gerçekleştirilebileceğini ayrıntılı göstermiştir. Demir ve ark. (2023) farklı balık türlerini aynı modeli kullanarak sınıflandırmıştır. Doğan ve ark. (2022) ve Doğan (2023) farklı modeller kullanarak sınıflandırma yapmış biyolojik ve kimyasal analiz ile karşılaştırmalı olarak sonuçları incelemiştir.

Tavuk ürünleri insanların en çok tükettiği gıdadır. Ucuz ve kolay ulaşılabilir olması bunu tercih edilir kılmaktadır. Ayrıca yararı ve besleyiciliği açısından tercih edilir bir gıdadır. Uygun koşullarda saklanmaz ve uygun tüketilmezse insan sağlığında geri dönüşü olmayan zararları da vardır. Bu çalışmada bu riski en aza indirmek için görüntü işleme yöntemine dayalı tavuk ürünleri için makine öğrenmesi kullanılarak kalite tespit yöntemi önerilmiştir. Literatürde derin öğrenme gıda algılanması, sınıflandırılmasında kullanılmıştır. Tavuk ürünleri açısından bir kaynağa rastlanmamıştır. Yüksek başarı oranına sahip önceden eğitilmiş modellerle tavuk ürünlerinin sınıflandırılması gerçekleştirilmiştir. Bu çalışma bu açıdan özgünlüğe sahiptir.

Tavuğun günlük hayatımızdaki önemi nedeniyle yapılan araştırma şu şekilde özetlendi: Etinin yağ oranı düşük ve kolesterol içermediği değerlendiriliyor, bu da çeşitli kalp hastalıkları riskini azaltıyor. Eti, yağ olarak depolamak yerine enerjiyi yakan kırmızı et olarak sınıflandırılır. Yüksek düzeyde hemoglobine sahiptir, bu da onu insan vücudunun sağlığı için önemli olan önemli bir demir kaynağı yapar. Emilimi kolay proteinler içerir, bu da vücudun hızla beslenmesini sağlar. Tavuk, demir, kalsiyum, fosfor ve manganez gibi mineral tuzları açısından zengindir. Demir açısından zengin olduğundan vücudun çok kan kaybettiği ameliyatlara giren ve kanaması olan kişilere reçete edilir. Kan dolaşımını uyarır, kadınlarda adet döngüsünü kolaylaştırır ve kadınlarda kadınlık hormonları da dahil olmak üzere çeşitli vücut hormonlarını kontrol eder. Demir açısından zengin olması nedeniyle çocukların büyümesine ve boy uzamasına yardımcı olur. Tavuk bir besin zenginliğidir çünkü tavuk eti vücut ve sağlık için en önemli ve en iyi temel besin kaynaklarından biridir. Ancak hormonlarla (yüksek miktarda testosteron), pestisitlerle, fungusitlerle, herbisitlerle veya ticari gübrelerle beslenen tavukları

kastetmiyoruz. Daha doğrusu sağlıklı ve sağlıklı beslenen tavukları kastediyoruz. Kilo vermek için yağ yakan besinlerden biri de tavuktur. Lezzetli ve hazırlama yöntemleri çeşitlidir ve yüksek oranda protein içerir. Tavuk, öğle ve akşam yemeklerinde çeşitli yemeklerde kullanılabilir. Tavuk eti insan vücudunun ihtiyaç duyduğu en önemli besin kaynaklarından biridir. İçerdiği faydalı element yağsız proteindir, yani gres (yağ) içermez. Protein, amino asitlerden oluşur ve bu asitlerin temel görevi, vücudun hücrelerini, hormonal dengesini koruyarak, tutarlı kas gücü ve cilt elastikiyetini sağlayarak sağlığı korumaktır. Tavuk eti, sindiriminin kolay olması ve bir gramının tavuk etinden daha fazla miktarda protein içermesi nedeniyle en önemli protein kaynaklarından biri olarak kabul edilir. Bir gram sığır eti başına demir, kanda kırmızı hücrelerin oluşumu için çok gerekli olan bir mineral tuzudur ve demir türlerinden biri de tavukta mevcuttur. Bu nedenle anemisi olan kişiler yeter miktarda tavuk yemelidir. Tavuk eti, nişasta, yağ ve proteinlerin metabolize edilmesi sürecinde önemli olduğu düşünülen fosfor da dahil olmak üzere bazı mineral tuzları içerir. D vitamininin yanı sıra fosfor da güçlü kemik ve dişlerin oluşmasında önemli rol oynar ve bu nedenle tavuk yenmelidir. Tavuk eti, vücuttaki madde değişimi ve karbonhidrat üretimi, albümin yağları, enerji üretimi, hücrelerdeki solunum süreci ve diğerleri için önemli bileşikler olan riboflavin gibi birçok vitamin içerir.

Makine öğrenimi, akıllı evler, sağlık hizmetlerinde insanın tanımlanması dahil olmak üzere çeşitli alanlardaki geniş bir yelpazedeki sorunları çözmek için bir veri işleme tekniği olarak kullanılmaktadır. Geleneksel makine öğreniminde, yüksek düzeyde ayırt edici bir özellik üretmek için zor ve kapsamlı özellik çıkarımı çok yaygın bir uygulamadır. Ancak hesaplama ve depolama kapasitesindeki ilerlemeler nedeniyle, derin öğrenmeye dayalı özelliklerin daha kapsamlı bir temsili, sınıflandırma ve regresyon için daha iyi performans sağlamak üzere yaygın bir uygulama haline geldi. Çok düzeyli özellik öğrenmeye sahip çeşitli katmanlardan oluşan derin bir Yapay Sinir Ağı (YSA), genel derin öğrenme kavramını tanımlar. Spesifik olarak, Evrişimli Sinir Ağı (ESA: Convolutional Neural Network) olarak adlandırılan havuzlama, evrişimli ve tamamen bağlantılı katmanlardan oluşan bir dizi bileşen, gıda tanımayı içeren çalışmalar da dahil olmak üzere bir örüntü tanıma tekniği olarak popülerlik kazanmıştır. Bunun nedeni, basit ESA konfigürasyonlarında bile tanıma kapasitesinin çok başarılı olmasıdır. Örneğin Lu (2016), küçük ölçekli bir gıda görüntüleri veri setinin on kategorisini sınıflandırmak için dört gizli nöron katmanını gösterdi. Görüntünün RGB bileşeni, giriş verisi olarak iki boyutlu bir forma dönüştürüldü. İlk olarak, 32 özellik haritası çıkarmak için 7'ye 7

boyutlu ve adım değeri bir olan evrişimli bir katman kullanıldı. İkinci olarak, 64 özellik haritası çıkarmak için 5'e 5 boyutunda evrişim katmanları kullanıldı. Son olarak 3'e 3 evrişim katmanından toplam 128 özellik haritası üretildi. Bildirilen test setindeki en iyi doğruluk %74 idi. Bununla birlikte, eğitim verilerinin sınırlı boyutunun bir sonucu olarak aşırı uyumdan şüphelenilmektedir, bu da test veri setinin daha yüksek bir çağdaki doğruluğunu sınırlamaktadır.

Lu 2016 tarafından yürütülen bir çalışmada, toplanan Malezya gıdalarının 11 kategorisini tanımak için ESA uygulandı. VGG19-CNN'nin mimarisi, VGG19'daki 16 evrişimli katmana kıyasla 21 evrişimli katman ve üç tamamen bağlı katmandan oluşan daha fazla katman eklenerek değiştirildi. Ancak performans sonuçları açıklanmadı. Subhi ve ark. (2018), yiyecek tanıma modülleri için önerdikleri ESA konfigürasyonunu ve InceptionV3 modelini Food-11 veri seti üzerinde değerlendirdiler. Görüntüler 224 x 224 x 3 boyutlu olarak yeniden şekillendirildi ve görüntülerdeki gereksiz gürültüyü ortadan kaldırmak için beyazlatma uygulandı. Önerilen ESA konfigürasyonu ve önceden eğitilmiş Inception V3 modeli için bildirilen doğruluk sırasıyla %74.7 ve %92.86 idi.

Geleneksel ESA'daki hiper parametre konfigürasyonları karmaşıktır ve zaman alıcıdır. Zahisham ve ark. (2020), FoNet tabanlı bir Derin Artık Sinir Ağı uygulayarak ve bunu altı Bangladeş gıda kategorisi üzerinde test ederek çok sayıda katmanı yönetmek için başka bir yöntem önerdi. Model, havuzlama katmanlarını, aktivasyon fonksiyonlarını, düzleştirilmiş katmanları, bırakma ve normalleştirmeyi içeren 47 katmandan oluşmaktadır. Test veri setlerinde bildirilen %98.16 doğruluk oranı, sırasıyla %95.8 ve %94.5 doğruluk bildiren Inception V3 ve Mobile Net modellerinden daha iyi performans gösterdi.

Jamnekar ark. (2023) yiyecek görselini YOLO algoritmasını kullanarak sınıflandırmaya yarayan bir teknik sunmuştur. Geleneksel yapay sinir ağlarından farklı olarak YOLO algoritması daha verimlidir ve doğrudan tespiti karşılık gelen bir kayıp fonksiyonu üzerinde eğitilir. Gıda görsellerinin benzer özellikteki yüksek çeşitliliği nedeniyle gıda sınıflandırması zor bir iş haline gelse de, birçok kaynak tarafından kullanılabilmesi nedeniyle günümüzde insan yaşamında önemli bir role sahiptir. Bu makalede YOLO algoritmasının ResNet-50, VGG-16, ImageNet ve Inception gibi görüntü işlemede kullanılan diğer tekniklerle karşılaştırılması yapılmıştır. Bu çalışmada uygulama amacıyla hazır veri seti kullanılmıştır. Veri seti 80 farklı kategori veya sınıftan 4000 Hint gıda görüntüsünden oluşmaktadır. Önerilen model gıdanın sınıflandırılmasında %99 doğruluk oranına sahiptir (Jamnekar ark., 2023).



Wang ark. (2021) karmaşıklık, tanıma doğruluğu ve hız sorunlarını çözmeye çalışan ve sinir ağına dayalı bir gıda görüntü tanıma yöntemi önermektedir. Bu çalışmada YOLO'ya dayalı iki aşamalı bir öğrenme modu önerilmiş ve YOLO-SiamV1 ve YOLO-SiamV2'nin iki versiyonu tasarlanmıştır. Deneysel sonuçlar, bu yöntemin genel bir tanıma doğruluğu vardır. Bununla birlikte, manuel işaretlemeye gerek yoktur ve pratik yaygınlaştırma ve uygulama açısından iyi bir gelişme potansiyeline sahiptir. Ayrıca gıdalarda yabancı cisim tespiti ve tanınmasına yönelik bir yöntem önerilmiştir. Bu yöntem, yabancı cisim gıdadan eşik segmentasyon teknolojisi ile etkili bir şekilde ayırabilir. Deneysel sonuçlar, bu yöntemin kurutucuyu yabancı maddeden etkili bir şekilde ayırabildiğini ve istenen başarılı etkiyi elde edebildiğini göstermektedir.

Memiş ark. (2020) makalesinde, gıda görüntüleri tanıma zorluğu için çeşitli derin öğrenme yöntemlerinin performansları üzerine karşılaştırmalı bir çalışma sunmaktadır. Deneysel sonuçlar UEC Food-100 veri seti üzerinde ResNet-18, Inception-V3, ResNet-50, Densenet-121, Wide ResNet-50 ve ResNet-50 kullanılarak 320x320 ve 299x299 boyutunda görüntülerle gerçekleştirilmiştir. Veritabanının sınırlı boyutu, transfer öğrenme yaklaşımını gerektirmektedir ancak tüm modeller önceden eğitilmiş ImageNet ağırlıklarıyla eğitilmiştir. Bu çalışmada en iyi sınıflandırma sonucu %87.7 doğrulukla ResNext-50 kullanılarak elde edilmiştir.

Pan ark. (2017) derin öğrenmeyi kullanarak yalnızca gıda içeriği görüntülerinden oluşan veri kümesinden zengin ve etkili özellikler çıkarmakla kalmayan, aynı zamanda gelişmiş makine öğrenme tekniklerini uygulayarak çok sınıflı sınıflandırmanın ortalama doğruluğunu da artıran DeepFood adı verilen yeni bir çatı çalışma önermektedir. İlk olarak, derin özellik çıkarımı için Evrişimli Sinir Ağlarına (CNN'ler) dayanan bir dizi transfer öğrenme algoritmasından yararlanır. Daha sonra, sınıflandırıcıların her derin özellik kümesindeki performansına dayalı olarak çok sınıflı bir sınıflandırma algoritmasından yararlanır. DeepFood çatısı, 41 sınıf gıda bileşeni ve her sınıf için 100 görsel içeren çok sınıflı bir veri kümesi üzerinde değerlendirilir. Deneysel sonuçlar, DeepFood çatı çalışmasının gıda içeriklerinin çok sınıflı sınıflandırılmasındaki etkinliğini göstermektedir. ResNet derin özellik kümelerini, Bilgi Kazanımı (IG: Information gain) özellik seçimini ve SMO sınıflandırıcısını birleştiren bu model, bu alanda mevcut birçok çalışmaya kıyasla gıda bileşenlerinin tanınmasında üstünlüğünü göstermiştir.

Zhang ark. (2023), türün, içeriklerin, kalitenin ve miktarın tespit edilmesi de dahil olmak üzere çeşitli gıda kategorisi tanıma görevlerine uygulanabilecek yöntemlere genel bir bakış sağlamıştır. Veri kümeleri, veri artırma, genel özellik çıkarma ve makine

öğrenimi algoritmaları dahil olmak üzere, gıda kategorisi tanıma için bir makine öğrenimi sistemi oluşturmaya yönelik temel bileşenleri araştırmıştır. Evrişimsel sinir ağlarının, transfer öğrenmenin ve yarı denetimli öğrenmenin kullanımını içeren derin öğrenme alanına özellikle odaklanılmıştır. Araştırma ve endüstriyel uygulamalar için gıda kategorisinin tanınmasında daha fazla gelişmeyi teşvik etmek amacıyla ilgili çalışmalara genel bir bakış sunulmuştur.

Özetle, önceki araştırmalar ESA ve transfer öğrenmeye dayalı tekniklerin gıda görseli tanımda etkili olduğunu göstermiştir. Ancak son dönemdeki ESA mimari modellerinin özellikle özellik çıkarımı açısından analiz ve değerlendirmesinde eksiklikler bulunmaktadır. Ayrıca ESA'ların yeni oluşturulan veri setine göre ayarlanması gereken hiper parametreleri vardır. Tablo 2.1'de ESA modelleriyle ilgili çalışmalar özetlenmektedir.

**Tablo 2.1.** ESA modelleri üzerine ilgili çalışmaların bir özeti


Literatür	Veri seti	Kategori sayısı	Teknik	Sonuç
Lu (2016)	Küçük ölçekli veri seti	10	Önerilen bir ESA konfigürasyon modeli; 3 evrişim havuzu katmanı ve 1 tamamen bağlı katman.	Test set doğruluğu %74
Subhi and Ali (2018)	Kişisel toplanmış Malezya gıda veri kümesi	11	Önerilen bir ESA konfigürasyon modeli 3 evrişim havuzu katmanı ve 1 tamamen bağlı katman	Rapor edilmemiş
Islam et al. (2018)	Food-11 veriseti	11	(i) Önerilen bir ESA konfigürasyon modeli 5 evrişim katmanı, 3 maksimum havuzlama katmanı ve 1 tamamen bağlı katman. (ii) Inception V3 önceden eğitilmiştir 2 tam model bağlantılı katmanlar	(i) Önerilen yaklaşım %74,7 doğruluk elde etti. (ii) Ön eğitilmiş Başlangıç V3'e ulaşıldı %92,86 doğruluk.
Jeny et al. (2019)	Kişisel toplanmış Malezya gıda veri kümesi	6	FoNet Tabanlı Derin Kalıntı 47 katmanlı Sinir Ağı havuzlama katmanlarından oluşur, aktivasyon fonksiyonları, düzleştirilmiş katmanlar ve bırakma ve normalleştirme.	Test set doğruluğu % 98.16.



### 3. MATERYAL VE METOT

#### 3.1. Sınıflandırma Sistemi

Tavuk ürünlerinin sınıflandırması genel bir sınıflandırma problemi olarak ele alınabilir. Sınıflandırmada ilk adım verilerin toplanmasıdır. Sınıflandırılacak nesnelere veriler uygun sensörler yardımıyla toplanırlar. Bu çalışmada sensör kamera nesne ise tavuk ürünleridir. Her ne kadar uygun koşullarda toplansada veriler ön veri işleme aşamasına ihtiyaç duyulur. Bunun nedeni sensör, insan gibi veriyi toplayan sistemden kaynaklı nedenlerdir. Bu çalışmada ortamdaki kaynaklı ışık şiddeti v.b. nedenlerden kaynaklı gürültü azaltma işlemi ön işleme aşamasında yapılır. Daha sonra öznelik dediğimiz nesneden toplanan verilerin kullanılacak sınıflandırıcıya uygun hale getirilmesi işlemidir. Doğrudan veri kümesininin kullanıldığı bu çalışmada kullanılan yöntemlerin olduğu gibi analitik, dönüşüm gibi yöntemler kullanılarak veriyi en iyi ifade eden veriye dönüştürülür. Hem daha hızlı sistemin çalışmasını sağlayacak hemde sistem başarımını doğrudan etkilediğinden sistem başarımını artırmak açısından öznelik çıkarımı aşaması önemlidir. Bu çalışmada doğrudan veriden öznelikler kullanılmaktadır. Daha sonraki aşama sınıflandırma aşamasıdır. Burada yapay sinir ağları, derin öğrenme, yapay zeka gibi popüler yöntemler kullanılabilir. Bu çalışmada evrişimli sinir ağlarına dayalı önceden eğitilmiş ağlar kullanılmıştır. Şekil 3.1’de sistem blok diagramı verilmiştir.



Şekil 3.1. Sınıflandırma sistemi blok diagramı

#### 3.2. Derin Öğrenme


Deep Learning Toolbox algoritmaları, önceden eğitilmiş modeller ve uygulamalarla derin sinir ağlarının tasarlanması ve uygulanması için bir çerçeve çatı sağlar. Görüntü, zaman serisi ve metin verileri üzerinde sınıflandırma ve regresyon gerçekleştirmek için evrişimli sinir ağlarını (ConvNet'ler, ESA'lar) ve uzun kısa süreli bellek (LSTM) ağlarını kullanabilirsiniz (Beale ve ark., 2023). Otomatik farklılaştırmayı, özel eğitim döngülerini ve paylaşılan ağırlıkları kullanarak üretken rakip ağlar (GAN'ler) ve Siyam ağları gibi ağ mimarileri oluşturabilirsiniz. Deep Network Designer

uygulamasıyla ağırları grafiksel olarak tasarlayabilir, analiz edebilir ve eğitebilirsiniz. Experiment Manager uygulaması birden fazla derin öğrenme deneyini yönetmenize, eğitim parametrelerini takip etmenize, sonuçları analiz etmenize ve farklı deneylerden gelen kodları karşılaştırmanıza yardımcı olur. Katman aktivasyonlarını görselleştirebilir ve eğitim ilerlemesini grafiksel olarak izleyebilirsiniz. TensorFlow 2, TensorFlow-Keras ve PyTorch, ONNX (Açık Sinir Ağı Değişimi) model formatı, Caffe'den ağırları ve katman grafiklerini içe aktarabilirsiniz. Ayrıca Deep Learning Toolbox ağırlarını ve katman grafiklerini TensorFlow 2'ye ve ONNX model formatına aktarabilirsiniz. Araç kutusu, DarkNet-53, ResNet-50, NASNet, SqueezeNet ve diğer birçok önceden eğitilmiş modelle aktarım öğrenimini destekler. Tek veya çoklu GPU iş istasyonunda (Parallel Computing Toolbox) ile eğitimi hızlandırabilir veya NVIDIA GPU Cloud ve Amazon EC2 GPU bulut sunucuları (MATLAB Parallel Server) dahil olmak üzere kümelere ve bulutlara ölçeklendirebilirsiniz.

Derin öğrenme, birden fazla işlem katmanından oluşan hesaplama modellerinin, birden fazla soyutlama düzeyine sahip veri temsillerini öğrenmesine olanak tanır. Bu yöntemler, konuşma tanıma, görsel nesne tanıma, nesne algılama ve ilaç keşfi ve genomik gibi diğer birçok alanda en son teknolojiyi önemli ölçüde geliştirmiştir. Derin öğrenme, bir makinenin her katmandaki temsili önceki katmandaki temsilden hesaplamak için kullanılan dahili parametrelerini nasıl değiştirmesi gerektiğini belirtmek için geri yayılım algoritmasını kullanarak büyük veri kümelerindeki karmaşık yapıyı keşfeder. Derin evrimsel ağırlar görüntü, video, konuşma ve sesin işlenmesinde çığır açıcı gelişmelere yol açarken, yinelenen ağırlar metin ve konuşma gibi sıralı verilere ışık tutmuştur (Leung ark., 2014; Kim, 2017).

Derin öğrenme yöntemleri, her biri bir düzeydeki temsili (ham girdiden başlayarak) daha yüksek, biraz daha soyut bir seviyedeki bir temsile dönüştüren basit ancak doğrusal olmayan modüllerin oluşturulmasıyla elde edilen, birden fazla temsil düzeyine sahip temsil-öğrenme yöntemleridir. Bu tür dönüşümlerin yeterince birleştirilmesiyle çok karmaşık işlevler öğrenilebilir. Sınıflandırma görevleri için, daha yüksek temsil katmanları, girdinin ayırmacılık için önemli olan yönlerini güçlendirir ve ilgisiz varyasyonları bastırır. Örneğin bir görüntü, bir piksel değerleri dizisi biçiminde gelir ve birinci temsil katmanındaki öğrenilen özellikler, tipik olarak görüntüdeki belirli yönlerde ve konumlarda kenarların varlığını veya yokluğunu temsil eder. İkinci katman tipik olarak, kenar konumlarındaki küçük değişikliklere bakılmaksızın, kenarların belirli düzenlemelerini tespit ederek motifleri tespit eder. Üçüncü katman, motifleri tanıdık

nesnelerin parçalarına karşılık gelen daha büyük kombinasyonlar halinde bir araya getirebilir ve sonraki katmanlar, nesnelere bu parçaların kombinasyonları olarak algılayabilir (Leung ark., 2014). Şekil 3.2’de derin öğrenmeyi anlatan blok diagram verilmiştir.



Şekil 3.2. Derin öğrenme blok diagramı

Derin öğrenme ağları genellikle "kara kutular" olarak tanımlanır çünkü bir ağın belirli bir kararı vermesinin nedeni her zaman açık değildir. Ağ davranışını bir kişinin yorumlayabileceği çıktıya dönüştürmek için yorumlanabilirlik tekniklerini kullanabilirsiniz. Bu yorumlanabilir çıktı daha sonra bir ağın tahminleriyle ilgili soruları yanıtlayabilir.


### 3.3. Önceden Eğitilmiş Ağlarla Öznitelik Çıkarma

Özellik çıkarma, eğitime zaman ve çaba harcamadan önceden eğitilmiş ağların gücünden yararlanmanıza olanak tanır. Özellik çıkarma, derin öğrenmeyi kullanmanın en hızlı yolu olabilir. Önceden eğitilmiş ağdan öğrenilen özellikler çıkarılır ve bu özellikler, örneğin bir destek vektör makinesi (SVM) gibi bir sınıflandırıcıyı eğitmek için kullanılır. Örneğin, Alexnet kullanılarak eğitilmiş bir SVM, eğitim ve doğrulama kümesinde >%90 doğruluk elde edebiliyorsa, transfer öğrenimiyle ince ayar yapmak, ekstra doğruluk elde etmek için çaba harcamaya değmeyebilir. Küçük bir veri kümesinde ince ayar yapılırsa aşırı uyum riskiyle karşı karşıya kalınır. Eğer SVM iyi bir sonuç elde edemiyorsa uygulamanız için yeterli doğruluk varsa, daha yüksek doğruluk elde etmek için ince ayar yapmak çabaya değer. Matlab’da bir örnek, öğrenilen görüntü özelliklerinin önceden eğitilmiş bir evrişimli sinir ağından nasıl çıkarılacağını ve bu özelliklerin bir görüntü sınıflandırıcıyı eğitmek için nasıl kullanılacağını gösterir ve bunu kullanmak çok kolaydır. Bu örnekler kullanılarak önceden eğitilmiş ağlarla problemleri kolay bir şekilde çözmeye yardımcı olur.

### 3.4. Önceden Eğitilmiş Derin Sinir Ağları

Doğal görüntülerden güçlü ve bilgilendirici özellikler çıkarma öğrenilebilir, önceden eğitilmiş görüntü sınıflandırma sinir ağı alınıp, yeni bir görevi öğrenmek için başlangıç noktası olarak kullanılabilir. Önceden eğitilmiş sinir ağlarının çoğunluğu, ImageNet Büyük Ölçekli Görsel Tanıma Yarışmasında (ILSVRC) (Russakovsky ve ark., 2015) kullanılan ImageNet veritabanının bir alt kümesi üzerinde eğitilir.

Bu sinir ağları bir milyondan fazla görüntü üzerinde eğitilmiştir ve görüntüleri klavye, kahve kupası, kalem ve birçok hayvan gibi 1000 nesne kategorisine göre sınıflandırabilmektedir. Transfer öğrenimi ile önceden eğitilmiş bir sinir ağını kullanmak, genellikle bir sinir ağını sıfırdan eğitmekten çok daha hızlı ve kolaydır. Daha önce eğitilmiş sinir ağlarını aşağıdaki amaçlar için kullanabilir: sınıflandırma, öznelik çıkarma, öğrenmeyi aktarma. Önceden eğitilmiş sinir ağlarını doğrudan sınıflandırma problemlerine uygulanabilir. Yeni bir görüntüyü sınıflandırmak için Matlab sınıflandırma komutu kullanılır. Katman aktivasyonlarını özellik olarak kullanarak, önceden eğitilmiş bir sinir ağını özellik çıkarıcı olarak kullanılabilir. Bu etkinleştirmeleri, destek vektör makinesi (SVM) gibi başka bir makine öğrenimi modelini eğitmek için özellik olarak kullanılabilir. Bu çalışmada bu yapılmıştır. Büyük bir veri kümesi üzerinde eğitilmiş bir sinir ağından katmanlar alınır ve yeni bir veri kümesi üzerinde ince ayar yapılarak öğrenme aktarılır. Şekil 3.3'te Matlab ortamında eklenen ve kullanılabilen önceden eğitilmiş ağlar yer almaktadır.



Şekil 3.3. Eğitilmiş ağlar seçim grafiği (Beale ark.,2023)

Kullanıcı donanım yapısına ve istediği başarı oranına göre buradan seçim yapar daha sonra problemine bunu uygular.

Önceden eğitilmiş sinir ağlarını karşılaştırırsak, önceden eğitilmiş sinir ağları, probleminize uygulanacak bir sinir ağı seçerken önemli olan farklı özelliklere sahiptir. En önemli özellikler sinir ağının doğruluğu, hızı ve boyutudur. Bir sinir ağının seçilmesi genellikle bu özellikler arasında bir seçimdir. Matlab ortamında 19 adet önceden eğitilmiş sinir ağı kullanılabilir (Beale ark.,2023). Sinir ağı seçiminde şunlara dikkat edilir. İyi bir sinir ağı yüksek doğruluğa sahiptir ve hızlıdır. Modern bir ekran kartı birimi ve 128'lik bir mini parti boyutu kullanıldığında sınıflandırma doğruluğunu ve tahmin süresini gösteren grafiklere bakılır (Beale ark.,2023). Tahmin süresi en hızlı sinir ağına göre ölçülür. Grafikteki her işaretleyicinin alanı, diskteki sinir ağının boyutuyla orantılıdır. Örneğin ImageNet doğrulama setindeki sınıflandırma doğruluğu, ImageNet üzerinde eğitilen sinir ağlarının doğruluğunu ölçmenin en yaygın yoludur. ImageNet'te doğru olan sinir ağları, aktarım öğrenmeyi veya özellik çıkarımı kullanarak bunları diğer doğal görüntü veri kümelerine uyguladığımızda da genellikle doğrudur. Bu genelleme mümkündür çünkü sinir ağları, diğer benzer veri kümelerine genelleme yapan doğal görüntülerden güçlü ve bilgilendirici özellikler çıkarmayı öğrenmiştir. Ancak ImageNet'teki yüksek doğruluk her zaman doğrudan diğer görevlere aktarılmaz; bu nedenle birden fazla sinir ağını denemek iyi bir fikirdir. Kısıtlı donanım kullanarak tahmin yapmak veya sinir ağlarını internet üzerinden dağıtmak isteniyorsa, diskteki ve bellekteki sinir ağının boyutunu da göz önünde bulundurmak gerekir. Bunlardan dolayı bu çalışmada ResNet-50 seçilmiştir. Kullanıcı grafikten elindeki donanıma, istediği hız ve başarıma göre ağ seçerek kullanır.

### **3.5. ResNet-50 Modeli**

ResNet, Kalıntı Ağ anlamına gelir ve He ark.(2015) tarafından geliştirilmiş özel bir evrişimsel sinir ağı türüdür. ESA'lar yaygın olarak bilgisayarla görme uygulamalarına güç ve başarı sağlamak için kullanılır. ResNet-50, 50 katmanlı bir evrişimli sinir ağıdır (48 evrişimli katman, bir MaxPool katmanı ve bir ortalama havuz katmanı). Artık sinir ağları, artık blokları istifleyerek ağlar oluşturan bir tür yapay sinir ağıdır (YSA). Tablo 3.1'de Matlab ortamında kullanılan önceden eğitilmiş ağlar listelenmiştir. Bu ağların derinlik, boyut, parametre sayısı ve görüntü giriş boyutu gibi özelliklerini de içeren bu tablo ağ seçimine yardımcı olmaktadır. Örneğin Alexnet ağına bakılırsa derinliği en az olan ağıdır ve Şekil 3.3'tede grafiğin en altında yer almaktadır. Ancak doğruluk değeride



çok düşüktür. Eğer kullanıcı başarımlarını yüksek bir ağ kullanmak istiyorsa diğer ağlara yönelmek zorunda kalır. Nasnetlarge ise başarımlar açısından en yüksekte yer almakla birlikte GPU kullanımını ve erişimi en yüksek ağ olarak karşımıza çıkmaktadır. Bu çalışmada ResNet-50 seçmemizin nedeni hem başarımlar açısından hemde GPU kullanımını açısından en iyi değerlere sahip olan ağ olmasından kaynaklanmaktadır. Denemelerimiz sonucunda da bu ortaya çıkmıştır.

**Tablo 3.1.** Eğitilmiş ağ özellikleri (Beale ark.,2023)

Sinir Ağı	Derinlik	Boyut	Parametre (Milyon)	Görüntü giriş boyutu
Squeezenet	18	5.2MB	1.24	227x227
Googlenet	22	27MB	7.0	224x224
Inceptionv3	48	89MB	23.9	299x299
Densenet201	201	77MB	20.0	224x224
Mobilenetv2	53	13	3.5	224x224
ResNet-18	18	44	11.7	224x224
ResNet-50	50	96	25.6	224x224
ResNet-101	101	167	44.6	224x224
Xception	71	85	22.9	299x299
Inceptionresnetv2	164	209	55.9	299x299
Shufflenet	50	5.4	1.4	224x224
Nasnetmobile	*	20	5.3	224x224
Nasnetlarge	*	332	88.9	331x331
Darknet19	19	78	20.8	256x256
Darknet53	53	155	41.6	256x256
Efficientnetb0	82	20	5.3	224x224
Alexnet	8	227	61.0	227x227
Vgg16	16	515	138	224x224
Vgg19	19	535	144	224x224

### 3.6. ResNet-50 Yapısı

Orijinal ResNet mimarisi, 34 ağırlıklı katmandan oluşan ResNet-34'tü. Kısayol bağlantıları kavramını kullanarak, kaybolan gradyan problemiyle karşılaşmadan bir ESA'ya daha fazla evrişimli katman eklemenin yeni bir yolunu sağladı. Kısayol bağlantısı bazı katmanları "atlayarak" normal bir ağı artık bir ağa dönüştürür.

Normal ağ, VGG sinir ağlarına (VGG-16 ve VGG-19) dayanıyordu; her evrişimli ağda 3x3 filtre vardı. Ancak ResNet'in daha az filtresi vardır ve VGGNet'ten daha az karmaşıktır. 34 katmanlı bir ResNet, 3.6 milyar FLOP'luk bir performansa ulaşabilir ve daha küçük bir 18 katmanlı ResNet, 1.8 milyar FLOP'a ulaşabilir; bu, 19,6 milyar FLOP'lu bir VGG-19 Ağından önemli ölçüde daha hızlıdır (He ve ark., 2015).

ResNet mimarisi iki temel tasarım kuralını takip eder. İlk olarak, her katmandaki filtre sayısı, çıktı özellik haritasının boyutuna bağlı olarak aynıdır. İkincisi, özellik haritasının boyutu yarıya indirilirse, her katmanın zaman karmaşıklığını korumak için filtre sayısı iki katına çıkar.

### 3.7. ResNet-50'nin özellikleri

ResNet-50, yukarıda gösterilen modele dayalı bir mimariye sahiptir ancak önemli bir farkı vardır. 50 katmanlı ResNet, yapı bloğu için bir darboğaz tasarımı kullanır. Bir darboğaz artık bloğu, parametre sayısını ve matris çarpımlarını azaltan, "darboğaz" olarak bilinen 1x1 evrişimleri kullanır. Bu, her katmanın çok daha hızlı eğitilmesine olanak tanır. İki katman yerine üç katmandan oluşan bir yığın kullanır.

50 katmanlı ResNet mimarisi, aşağıdaki Şekil 3.4'te gösterildiği gibi aşağıdaki öğeleri içerir:

- 2 boyutlu bir adımla diğer 64 çekirdeğin yanında 7×7 çekirdek evrişimi.
- 2 boyutlu adımlarla maksimum havuzlama katmanı.
- 9 katman daha — 3×3,64 çekirdek evrişimi, bir diğeri 1×1,64 çekirdekli ve üçüncüsü 1×1,256 çekirdekli. Bu 3 katman 3 kez tekrarlanır.
- 1×1.128 çekirdekli, 3×3.128 çekirdekli ve 1×1.512 çekirdekli 12 katman daha, 4 kez yinelenir.
- 1×1.256 çekirdekli 18 katman ve 2 çekirdek 3×3.256 ve 1×1.1024, 6 kez yinelenir.
- 3 kez yinelenen 1×1.512 çekirdekli, 3×3.512 çekirdekli ve 1×1.2048 çekirdekli 9 katman daha. (bu noktaya kadar ağda 50 katman bulunmaktadır)
- Ortalama havuzlama ve ardından softmax aktivasyon fonksiyonu kullanılarak 1000 düğümlü tam bağlı katman.

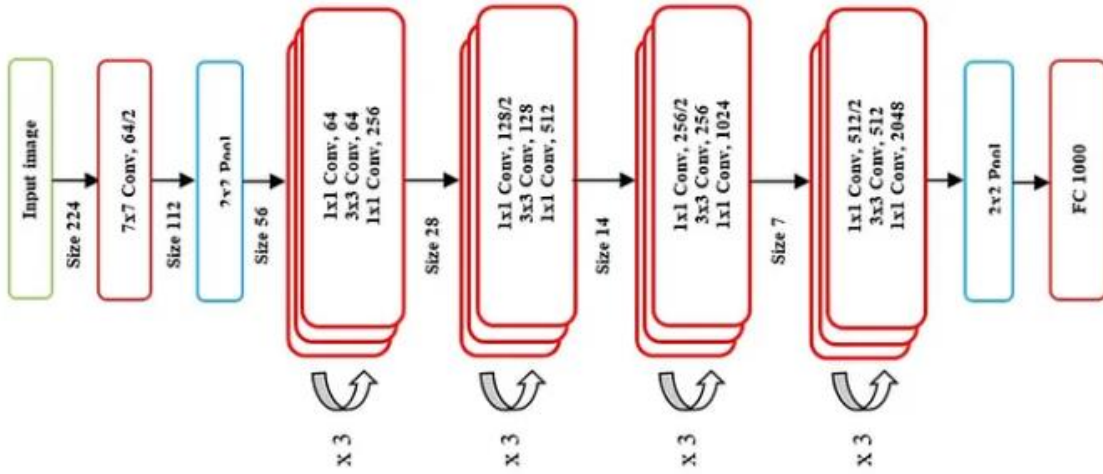
layer name	output size	18-layer	34-layer	50-layer	101-layer	152-layer
conv1	112×112	7×7, 64, stride 2				
conv2.x	56×56	3×3 max pool, stride 2				
		$\begin{bmatrix} 3 \times 3, 64 \\ 3 \times 3, 64 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 64 \\ 3 \times 3, 64 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{bmatrix} \times 3$
conv3.x	28×28	$\begin{bmatrix} 3 \times 3, 128 \\ 3 \times 3, 128 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 128 \\ 3 \times 3, 128 \end{bmatrix} \times 4$	$\begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{bmatrix} \times 4$	$\begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{bmatrix} \times 4$	$\begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{bmatrix} \times 8$
conv4.x	14×14	$\begin{bmatrix} 3 \times 3, 256 \\ 3 \times 3, 256 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 256 \\ 3 \times 3, 256 \end{bmatrix} \times 6$	$\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix} \times 6$	$\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix} \times 23$	$\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix} \times 36$
conv5.x	7×7	$\begin{bmatrix} 3 \times 3, 512 \\ 3 \times 3, 512 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 512 \\ 3 \times 3, 512 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2048 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2048 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2048 \end{bmatrix} \times 3$
	1×1	average pool, 1000-d fc, softmax				
FLOPs		$1.8 \times 10^9$	$3.6 \times 10^9$	$3.8 \times 10^9$	$7.6 \times 10^9$	$11.3 \times 10^9$

Şekil 3.4. ResNet-50 modeli özellikleri

bakılmaksızın, kenarların belirli düzenlemelerini tespit ederek motifleri tespit eder. Üçüncü katman, motifleri tanıdık nesnelerin parçalarına karşılık gelen daha büyük kombinasyonlar halinde bir araya getirmektedir.

### 3.8. Mimari

ResNet-50 mimarisinin, piyasadaki en popüler Evrişimli Sinir Ağı mimarileri arasında olduğu düşünülmektedir. Microsoft tarafından tanıtılan Residual Networks (ResNet), He tarafından ilk kez tanıtıldığında birçok rekora imza atmıştır. Mimari açıdan, herhangi bir katman düz bir ağıdaki modelin performansına zarar verirse atlama bağlantılarının varlığı nedeniyle atlanır. ResNet mimarisi Şekil 3.5'te verilmiştir.




Şekil 3.5. ResNet-50 mimarisi

ResNet-50 mimarisi 6 parçaya ayrılabilir: 1. Giriş Ön İşleme 2. Cfg[0] blokları 3. Cfg[1] blokları 4. Cfg[2] blokları 5. Cfg[3] blokları 6. Tamamen bağlı katman

ResNet gibi bir modele olan gereksinim, o dönemde modern ağlardaki bazı tuzaklardan dolayı ortaya çıkmıştır. 1. Derin sinir ağlarının eğitiminin zorluğu: Bir modeldeki katman sayısı arttıkça modeldeki parametre sayısı da katlanarak artar. Her Evrişimli katman için toplam faturaya eklenir. Bunu bağlam içine koymak için, 3 kanaldan 32 kanala kadar basit bir 7x7 çekirdek Evrişim katmanı 4736 parametre ekler. Deney amaçlı katman sayısındaki artış, modelin eğitiminin karmaşıklığında da aynı oranda artışa yol açar. Eğitim daha sonra daha fazla hesaplama gücü ve hafıza gerektirir. 2. Daha anlamlı, daha az farklı: Bir sinir ağının genellikle bir fonksiyon yaklaşım aracı olduğu düşünülür. Girdi, hedef verilen fonksiyonları modelleme ve fonksiyon çıktısı ile

hedef arasında karşılaştırma yapma yeteneğine sahiptir. Bir ağı birden fazla katman eklemek, karmaşık işlevleri modellemeyi daha yetenekli hale getirir. Ancak yayınlanan sonuçlar, aşağıdaki grafikte görülebileceği gibi 18 katmanlı düz sinir ağının, 34 katmanlı düz sinir ağından önemli ölçüde daha iyi performans gösterdiğini belirtti. 3. Kaybolan/Patlayan Gradyan: Bu, daha büyük/derin sinir ağlarının eğitimini zorlaştıran en yaygın sorunlardan biridir ve ağ parametrelerinin sayısal kararlılığı açısından gözetimin bir sonucudur. Geri yayılım sırasında derin katmanlardan sığ katmanlara doğru ilerledikçe, farklılaşmanın zincir kuralı gradyanları çarpmamızı sağlar. Genellikle bu eğimler küçüktür veya daha fazladır. ResNet mimarisi, bağlantıları atlama yaklaşımını popüler hale getirmiştir. Fonksiyon uzayı problemlerinin çözümü yaklaşımı onları iç içe yerleştirmektir. Bunu kullanım durumuna uygulama açısından, kimlik fonksiyonunun çıktıya basit bir şekilde eklenmesiydi. Matematiksel açıdan bu,  $y=x+F(x)$  anlamına gelir; burada  $y$ , katmanın son çıktısıdır. Bu yapı Şekil 3.6'da verilmiştir.




Şekil 3.6. ResNet-50 kalan öğrenme: yapı taşı

### 3.9. Tavuk Ürünlerinden Verilerin Toplanması

Araştırmada kullanılan tavuk malzemeleri marketten taze olarak temin edilmiş ve doğal olarak dondurulmuştur. Temel olarak tavuk bir bütündür ve daha sonra kesme işlemini tamamlamak için önerilen sisteme girilir. Araştırmada kullanılan tavukların görüntüleri iPhone 14 telefonu aracılığıyla her gün saat 8'den gece saat 9'a kadar kaydedildi. Kullanılan her tavuk parçası için günlük 1.500 adet fotoğraf çekilmiş olup, genel toplam tavuk parça sayısı 5 adet, her parça için 1.500 adet fotoğraf olmak üzere toplam 10.500 adet olmuştur. Şekiller 3.7 bu görsellerin örneklerini göstermektedir. Görselde her satır bir sınıfı her sütun bir günü göstermektedir. Görseldeki satırlar sırasıyla göğüs, baget, etli but, tüm kanat, kanat sütunları sırasıyla birinci, ikinci, üçüncü, dördüncü, beşinci, altıncı ve yedinci gün resimlerini göstermektedir. Zemin sistem kolaylığı açısından tek renk ve beyaz seçilmiştir. Yaklaşık 45 derece döndürülerek resimler seri

modda kaydedilmiştir. Işık şiddet ve koşulların aynı olması aynı saatte kayıt alınarak sağlanmıştır. Tavuk ürünler hergün resimler kaydedildikten sonra buzdolabında uygun saklama koşullarında saklanmıştır.

Beş çeşit tavuk ürününü tabağa alınmış, mat beyaz bir zemin üzerinde (sehpa), yansıtıcı olmayan, görüntüler toplanmıştır. Telefonla aynı mesafeden seri çekim yapılmıştır. Dairesel olarak 360 derece boyunca dönülerek aynı mesafeden 1000 fotoğraf çekilmiştir. Her gün 5 türden en az 5000 fotoğraf olacaktır. Ürünler tabaklara dizilmiş ve tabaklar streç filmle kaplanıp dolaba koyulmuştur. Aynı işlem 2 ile 7. Günler boyunca yapılmıştır. Bu işlemler toplam 7 gün boyunca yapılmıştır. Bu genel tanımlama için deney setinin oluşturulması aşamasıdır. Şekil 3.7.'de 7 gün boyunca her sınıftan alınan birer örnek görüntü gösterilmiştir. Resimlerde ışık şiddetlerinin çok yakın olduğuna dikkat ediniz.



Şekil 3.7. Tavuk ürünleri veri setinden örnekler

### 3.10. Makine Öğrenimi Koşulları

Çalışmada, görüntülerden elde edilen ResNet-50 özelliklerini kullanarak görüntüleri sınıflandırmak için bir destek vektör makinesi olan SVM olarak bilinen algoritma kullanılmış olup, her biri bir dizi artık blok içeren 5 bloğa bölünmüş 50 katmandan oluşmaktadır. Artık bloklar, önceki katmanlardan gelen bilgilerin korunmasına olanak tanır ve bu da ağın giriş verilerinin daha iyi temsillerini öğrenmesine yardımcı olur. Ağın ilk katmanı, giriş görüntüsü üzerinde evrişim gerçekleştiren evrişimli bir katmandır. Bunu, evrişimsel katmanın çıktısını aşağı örnekleyen bir maksimum

havuzlama katmanı izler. Maksimum havuzlama katmanının çıktısı daha sonra bir dizi artık bloktan geçirilir. Her artık blok, her biri bir toplu normalizasyon katmanı ve düzeltilmiş doğrusal birim (ReLU) aktivasyon fonksiyonu tarafından takip edilen iki evrişimli katmandan oluşur. İkinci evrişimsel katmanın çıktısı daha sonra artık bloğun girişine eklenir ve bu daha sonra başka bir ReLU aktivasyon fonksiyonundan geçirilir. Artık bloğun çıktısı daha sonra bir sonraki bloğa aktarılır. Ağın son katmanı, son kalan bloğun çıktısını alan ve onu çıktı sınıflarına eşleyen, tamamen bağlı bir katmandır. Tam bağlantılı katmandaki nöronların sayısı çıktı sınıflarının sayısına eşittir.

### **3.11. Resnet-50 Matlab Kullanımı**

Matlab yazılım ortamına isteğe bağlı özellikler, uygulamalar, araç kutuları ve destek paketleri de dahil olmak üzere eklentiler bulunup, çalıştırılıp yüklenebilmektedir. Eklentiler, donanım aygıtlarına bağlanma, ek algoritmalar ve etkileşimli uygulamalar gibi belirli görev ve uygulamalar için ek işlevler sağlayarak MATLAB'ın yeteneklerini genişleterek kullabilmemize yarar. Eklentiler üretici firmanın sayfasından ve küresel MATLAB kullanıcı topluluğundan edinilebilir ve ürünler, uygulamalar, araç kutuları ve destek paketleri de dahil olmak üzere çok çeşitli kaynakları kapsar.

Eklentileri bulmak, yüklemek ve yönetmek için üretici firmanın sayfasından yararlanılabilir. Ayrıca uygulamalar ve araç kutuları da dahil olmak üzere kendi eklentilerinizi de oluşturabilirsiniz. Oluşturduğunuz eklentileri paylaşmakta üretici firmanın sayfasından mümkündür.

Eğitilmiş ağların Matlab yazılım ortamında kullanımı için bu ortama eklenmesi gerekmektedir. Bunun için bütün eğitilmiş ağların bulunduğu internet ağından (github) ilgili eğitilmiş ağa ait Matlab eklentisi gereklidir. Bu eklenti yazılımın ilgili menüsünden ekleme aracı ile eklenir. Eklentinin doğru çalışıp çalışmadığının test edilmesi için derin öğrenme tanıtım örneklerinden birisinde test yapılır. Örnek çalışmazsa kurulum tekrar yapılır. Bu araçlar ve eklentilerden yararlanılarak Matlab'ın bütün yeteneklerinden faydalanıp yazılım geliştirme yapılabilir. Eklentiler MATLAB'ın yeteneklerini genişleterek ne üzerinde çalışıyor olursanız olun, göreviniz için size yardımcı olur.



#### 4. BULGULAR VE TARTIŞMA

Tavuk ürünlerinin kullanıldığı bu çalışmada sonuçlar sınıfların ayırtediciliğini göstermek için sınıflararası sonuçlarla ve gün ayırtediciliğini göstermek için sınıfiçi sonuçlarla gösterilmiştir. Sınıflararası testlerde 5 üründen toplanan görüntüler her biri ayrı klasörde toplanarak teste tabi tutulmuştur. Sınıf içi testleri ise her klasörde 7 gün görüntüleri yer almıştır.

Sınıf bazında sınıflandırmada 5 farklı sınıf için sonuçlar verilmektedir. Gün bazlı sınıflandırma sonuçlarında ise her sınıf için 7 gün sonuç verilmektedir. Bu sonuçlar karışıklık matrislerinin boyutundan anlaşılır. Sınıf bazlı sonuçlar 5\*5 matris biçiminde gün bazlı sonuçlar ise 7\*7 matris tipinde ortaya çıkacaktır.

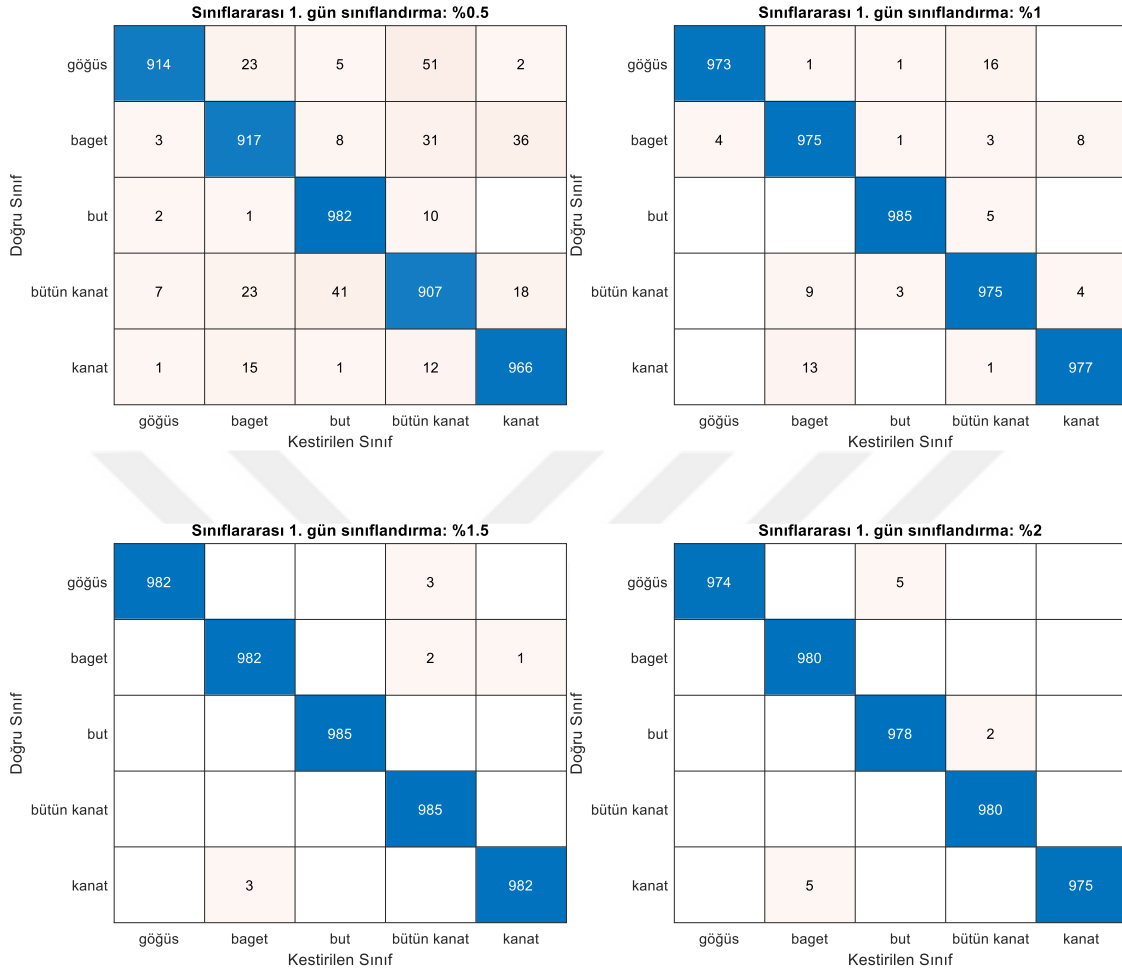
##### 4.1. Sınıf Bazında Sınıflandırma

Tavuk protein ve yağ oranı açısından insan sağlığına faydalı bir gıdadır. Tavuk ürünlerinde tavuk yağının büyük bir kısmı deri altında bulunur, az bir kısmı da kas dokusu arasında bulunur. Pişmiş bir tavuk göğsü %1.3 oranında yağ içerirken, bir parça sığır eti %13-30 oranında yağ içerir. Tavuk yağı doymamış yağ asitleri bakımından yüksektir, ancak bazı bitkisel yağlar kadar yüksek değildir. Taze halde tatsız ve kokusuzdur. Doymamış yağ asitlerinin varlığında kokuşma hızlı bir şekilde meydana gelir ve oksijen, ısı ve ultraviyole ışınlarının varlığında acılaşıma artar. İnsan sağlığına faydalı olması yanında uygun ortamda saklanmaları ve mümkün olan en kısa sürede tüketilmeleri esastır. Dikkat edilmezse insan sağlığına ciddi zararlar verebilir.


Beş tavuk ürünü parçası ile yapılan çalışmada aşağıdaki sonuçlar elde edilmiştir. Bu sonuçlar için her sınıf için toplanan görüntüler tek klasörde toplanmıştır. 5 farklı klasörde toplanan veriler sınıflandırmaya tabi tutulmuştur. Her test 30 defa tekrar edilmiştir. Şekil 4.1.'de verilen karışıklık matrisi 1000 adet için sınıflararası hataları göstermektedir. Baget, but, bütün kanat, göğüs ve kanat olmak üzere beş sınıfın %1 eğitim sonuçları herbir sınıfın yeterli başarımla sınıflandırıldığını gösterir. En az hata but %0.5 oranında bütün kanata karıştırılarak yapılırken en büyük hata göğüs %1.6 bütün kanata karıştırılarak yapılmıştır. Bin adet görüntüde yüzde yerine adet olarak verilen şekil 4.1.'de en çok baget adet olarak diğer sınıflara karıştırılmıştır. Sınıflararası başarımla sonuçları şekil 4.8'de kutu diagramları ile ve şekil 4.9'da ortalama çizim ile verilmiştir. Kutu çizilerine bakıldığında %1.5 eğitim oranından sonraki oranlarda başarımla %85'in üzerinde olduğu %5'ten sonra kutuların dar bir yapıya sahip olduğu görülür. Bu yapı




başarımın hem yük olduğunu hemde her denemenin yakın başarı oranına sahip olduğunu

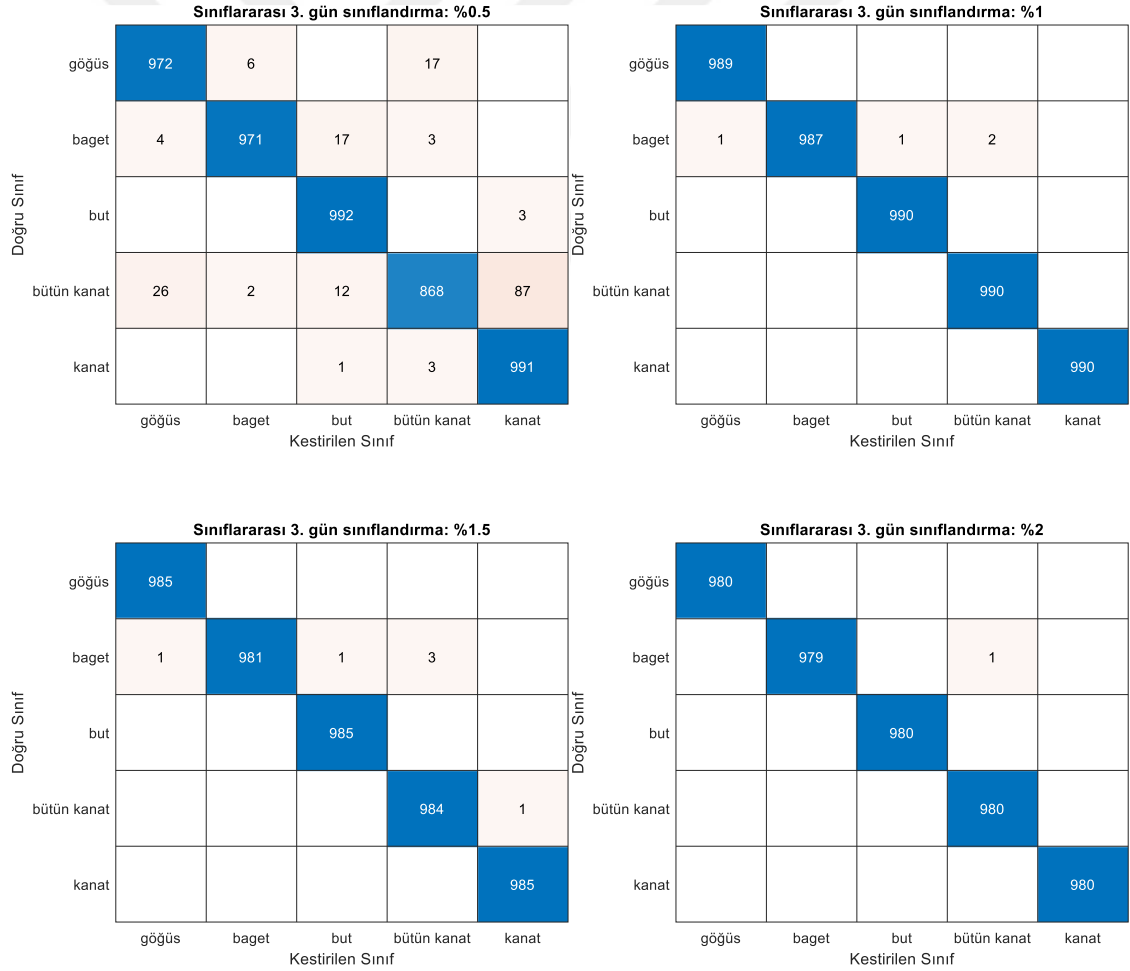


**Şekil 4.1.** Tavuk ürünleri 1. gün sınıflar arası karışıklık matrisleri





**Şekil 4.2.** Tavuk ürünleri 2. gün sınıflar arası karışıklık matrisleri



**Şekil 4.3.** Tavuk ürünleri 3. gün sınıflar arası karışıklık matrisleri

**Sınıflararası 4. gün sınıflandırma: %0.5**

Doğru Sınıf	göğüs	968	9	8	11	
	baget	19	930	38		7
	but	1	26	967	1	
	bütün kanat	21	1		963	9
	kanat		5		20	970
		göğüs	baget	but	bütün kanat	kanat

Kestirilen Sınıf

**Sınıflararası 4. gün sınıflandırma: %1**

Doğru Sınıf	göğüs	990				
	baget		975	15		
	but	1	20	962	1	6
	bütün kanat				990	
	kanat					990
		göğüs	baget	but	bütün kanat	kanat

Kestirilen Sınıf

**Sınıflararası 4. gün sınıflandırma: %1.5**

Doğru Sınıf	göğüs	985				
	baget		975	10		
	but		5	980		
	bütün kanat				985	
	kanat					985
		göğüs	baget	but	bütün kanat	kanat

Kestirilen Sınıf

**Sınıflararası 4. gün sınıflandırma: %2**

Doğru Sınıf	göğüs	980				
	baget		980			
	but			980		
	bütün kanat				979	1
	kanat					980
		göğüs	baget	but	bütün kanat	kanat

Kestirilen Sınıf

**Şekil 4.4.** Tavuk ürünleri 4. gün sınıflar arası karışıklık matrisleri

**Sınıflararası 5. gün sınıflandırma: %0.5**


Doğru Sınıf	göğüs	995				
	baget	1	970	24		
	but	46	65	880	4	
	bütün kanat				954	41
	kanat				6	989
		göğüs	baget	but	bütün kanat	kanat

Kestirilen Sınıf

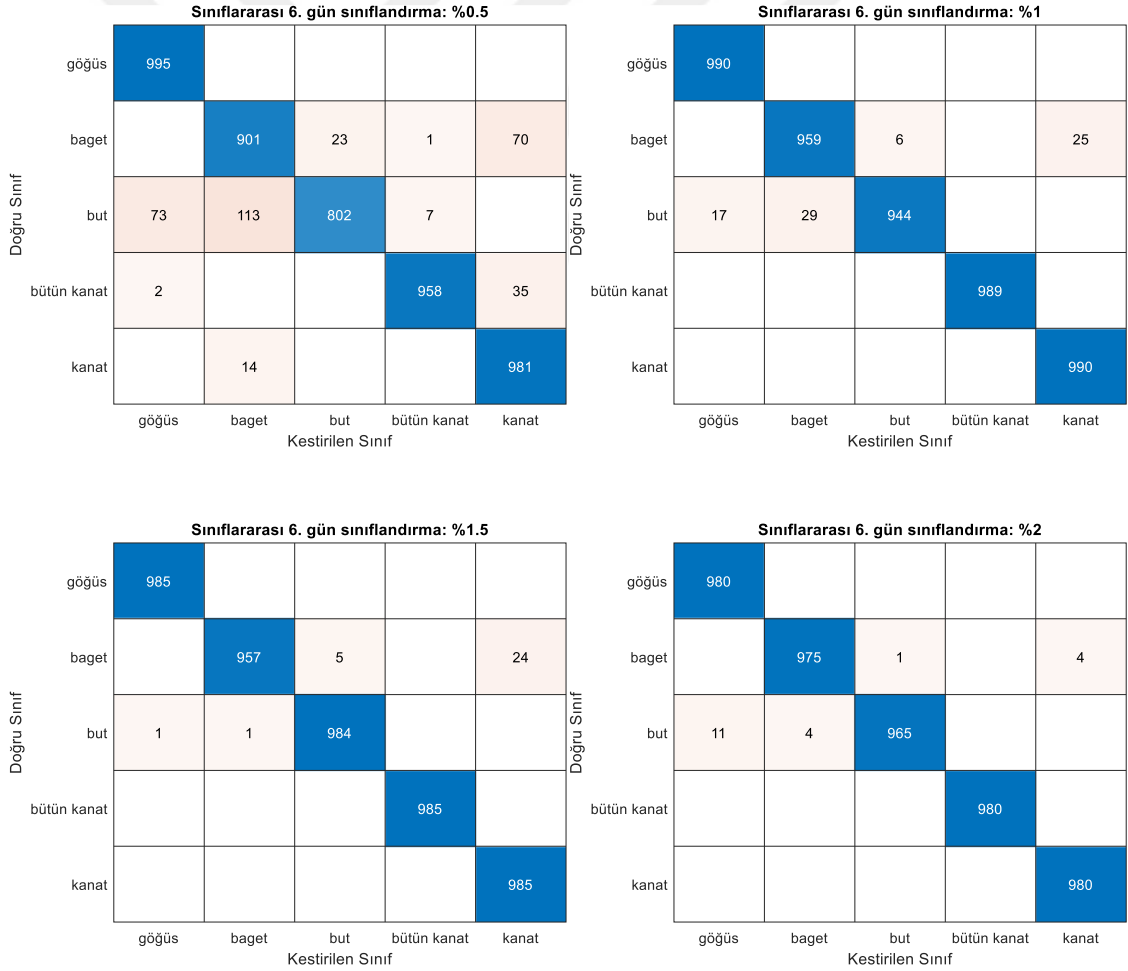
**Sınıflararası 5. gün sınıflandırma: %1**

Doğru Sınıf	göğüs	990				
	baget		988	2		
	but	5	40	943	2	
	bütün kanat				985	5
	kanat					990
		göğüs	baget	but	bütün kanat	kanat

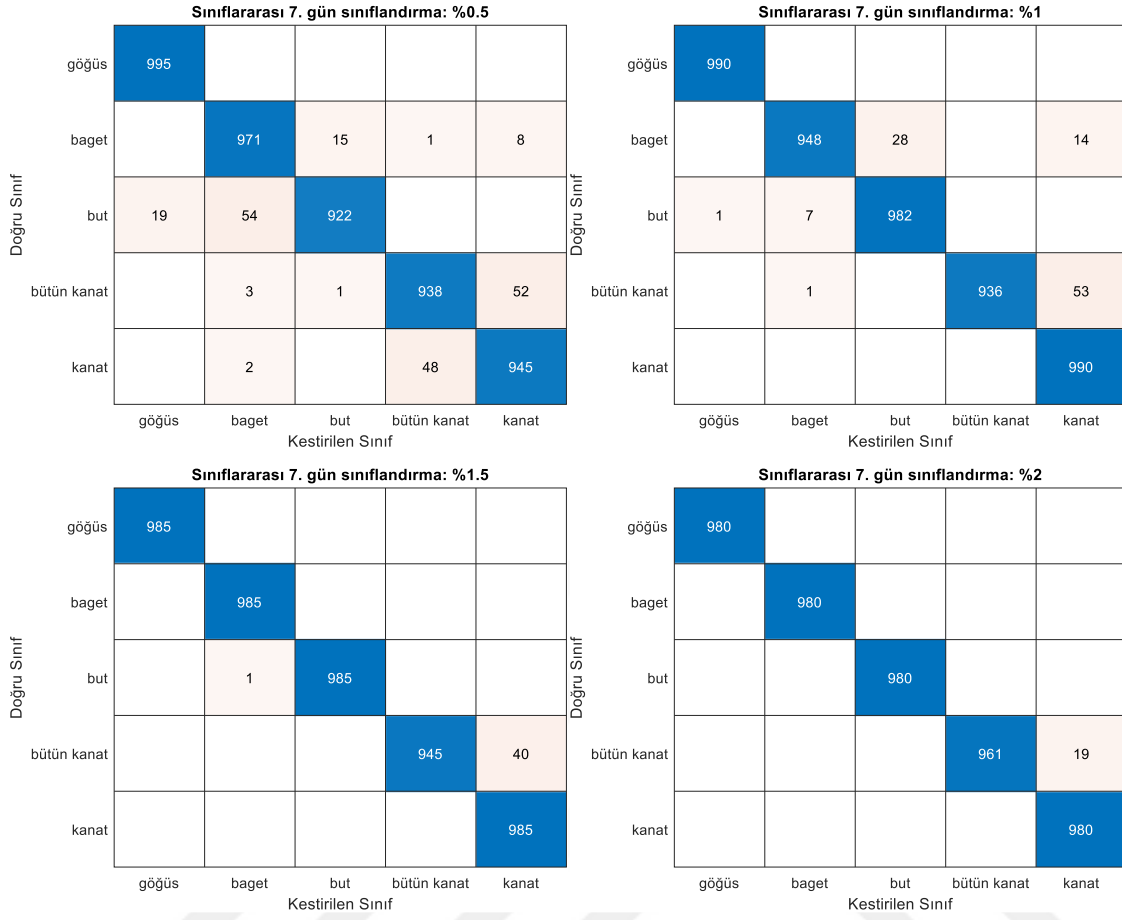
Kestirilen Sınıf



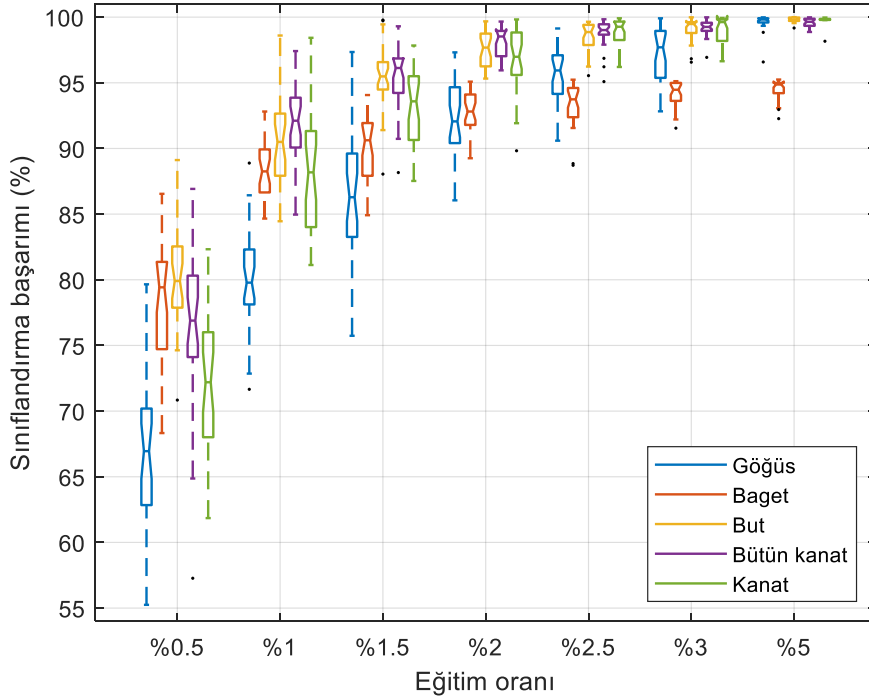
**Şekil 4.5.** Tavuk ürünleri 5. gün sınıflar arası karışıklık matrisleri



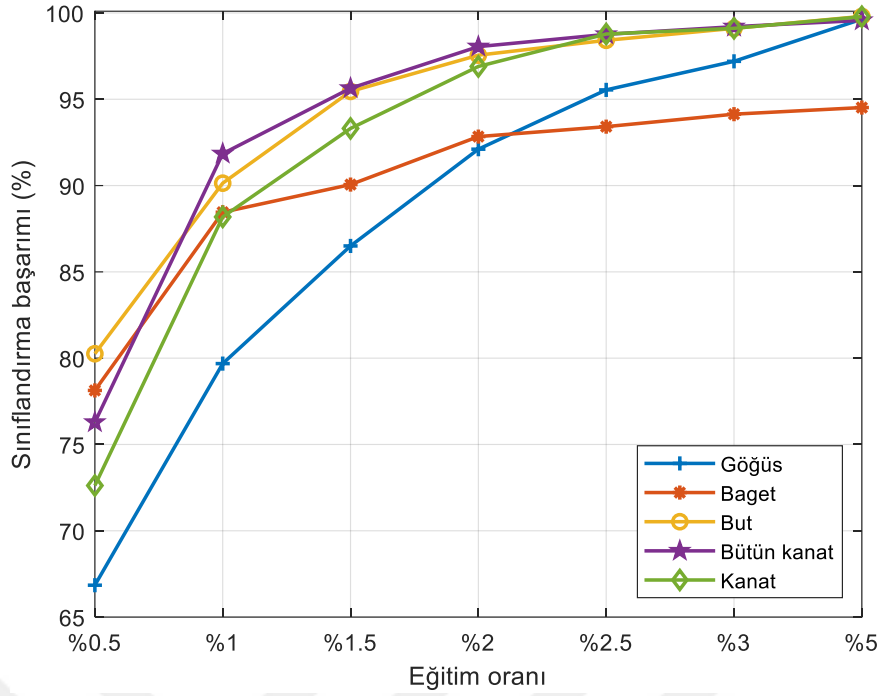
**Şekil 4.6.** Tavuk ürünleri 6. gün sınıflar arası karışıklık matrisleri



**Şekil 4.7.** Tavuk ürünleri 7. gün sınıflar arası karışıklık matrisleri



**Şekil 4.8.** Sınıflar arası sınıflandırma başarımları kutu diogramı



**Şekil 4.9.** Sınıflar arası sınıflandırma başarımları

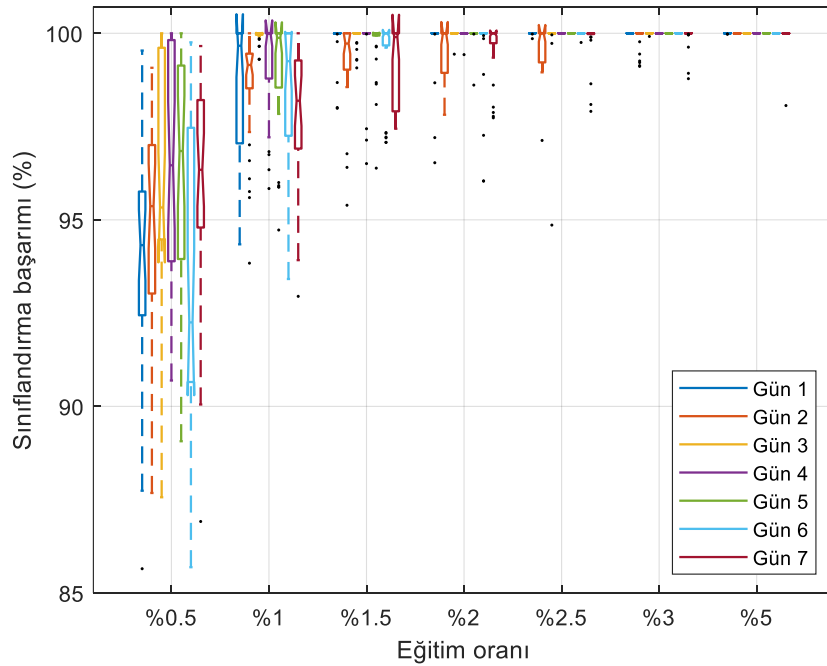
göstermektedir. Bu kullanılan yöntemin uygun olduğunu göstermektedir. Eğitim oranı %5'ten sonra başarımları oranları %99 civarında gelmektedir. Bagette ise bu oran %95 civarında gelmektedir. Bunun sebebi baget görüntüsünün çok benzerliğinden kaynaklanmaktadır. Baget parçasını hergün aynı koymak ya da koymamak görüntüde farklılığa sebep olmadığından görüntüden elde edilen özniteliklerde de fazla bir değişikliğe neden olmaz. Buda günler arasında ve görüntüler arasında benzerliği korur. Bunun sonucunda öznitelik aşamasındaki çok küçük değişimler bile sınıflandırıcıda işe yaramaz. Görüntü işlemenin öznitelik çıkarımı aşamasında farklı çıkarımlarla bu başarımları artırılabilir.

#### 4.2. Gün Bazında Sınıflandırma

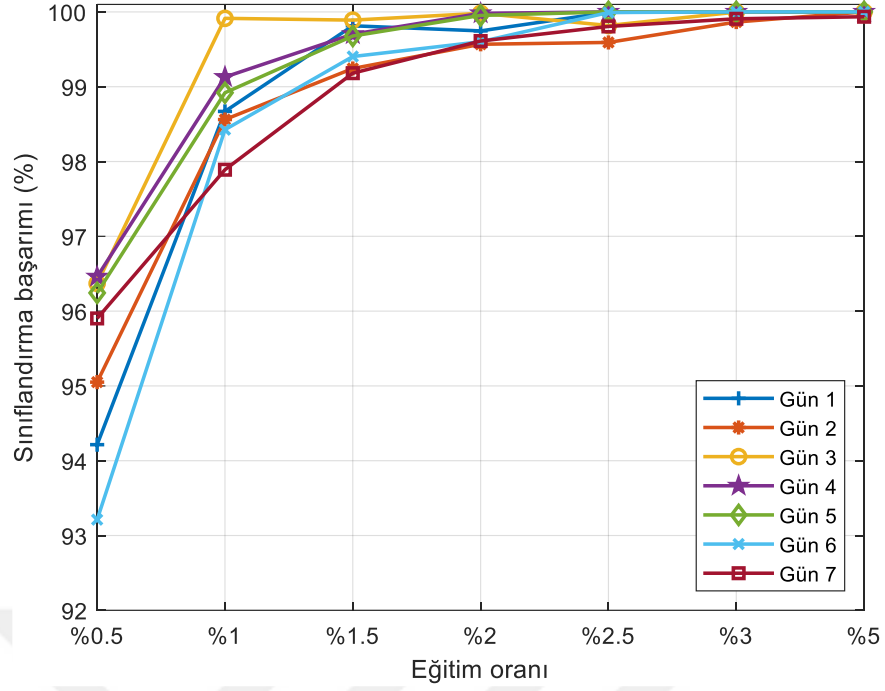
Her sınıfın klasörüne dokunmadan her sınıf için ayrı sınıflandırma işlemi gerçekleştirilmiştir. Sınıflandırma başarımları testleri 30 kere test edilmiş ve her testte eğitim ve test kümeleri rasgele seçilmiştir. Bu sınıflandırma tazelik bayatlık sınıflandırılmasında kullanılabilir. Örneğin tazelik için ilk 3 gün ele alınırsa sonraki 4 gün tavuk bayat kabul edilerek uyarı yapılabilir. Yedi günde yapılan sınıflandırma başarımları yeterli olduğundan günler birleştirilse bile yaklaşık sonuca ulaşılır. Kutu diagramları sınıflandırmada çok kullanılan bir gösterimdir. Bu gösterimde testlerin ne kadar yayıldığı görülebilir. Seçilen testin en küçük başarımları ortalaması, en büyük başarımları gibi istatistiksel bilgileri kutu diagramları içerirler. Kutu diagramlarının tam orta noktası medyanı gösterir. Kutu üst

köşeki %75 üçüncü çeyrekliği alt köşesinde %25 ilk çeyrekliğe karşılık gelir. En üst nokta en büyük değeri en alt nokta en düşük değeri göstermektedir. Şekil 4.10 kutu diagramları en düşük ortalama sınıflandırma başarımının %0.5 eğitim oranında 6.günde %92.5 ile gerçekleştiğini gösterir. Eğitim oranı yükseldikçe başarı oranı artmaktadır. Şekil 4.11’de gün bazlı sınıflandırmanın başarı oranlarının ortalamaları verilmiştir. Bu grafikten %1.5 eğitim oranından sonra %99’dan büyük sınıflandırma başarımı elde edilmiştir. Gün bazlı sınıflandırma sonuçlarından %2 eğitim oranı ile tavuk ürünlerinin yüksek başarı oranı ile sınıflandırıldığı sonucu çıkar.

Her tavuk ürünü toplanılan bir haftalık verileri ile sınıflandırma işlemine tabi tutulmuştur. Yedi gün boyunca toplanan verilerin ResNet-50 kullanılarak sınıflandırılması sonucunda karışıklık matrisleri elde edilmiştir. Bu matrislerin elde edilmesinde hergün toplanan 1000 er adet görüntüden %1’den %10’a kadar eğitim için geri kalan görüntüler test aşaması için kullanılmıştır. 50 deneme yapılmış ve bu denemelerin sonucunda bu matrisler elde edilmiştir. Denemelerin yanlılığının önlenmesi amacıyla her Monte Carlo denemesinde görüntüler rasgele sıralanmıştır. Karışıklık matrisleri sınıflandırma doğruluğu yerine kullanılan sınıf içi sonuçları da içeren bir hata karşılaştırma parametrik veridir. Bu matrisin köşegen ortalaması sınıflandırma doğruluğuna karşılık gelmektedir. Karışıklık matrisleri yüzde değer olarak ya da nümerik değer olarak verilebilirler. Burada



**Şekil 4.10.** Tavuk ürünleri gün bazlı sınıflandırma kutu diagramları



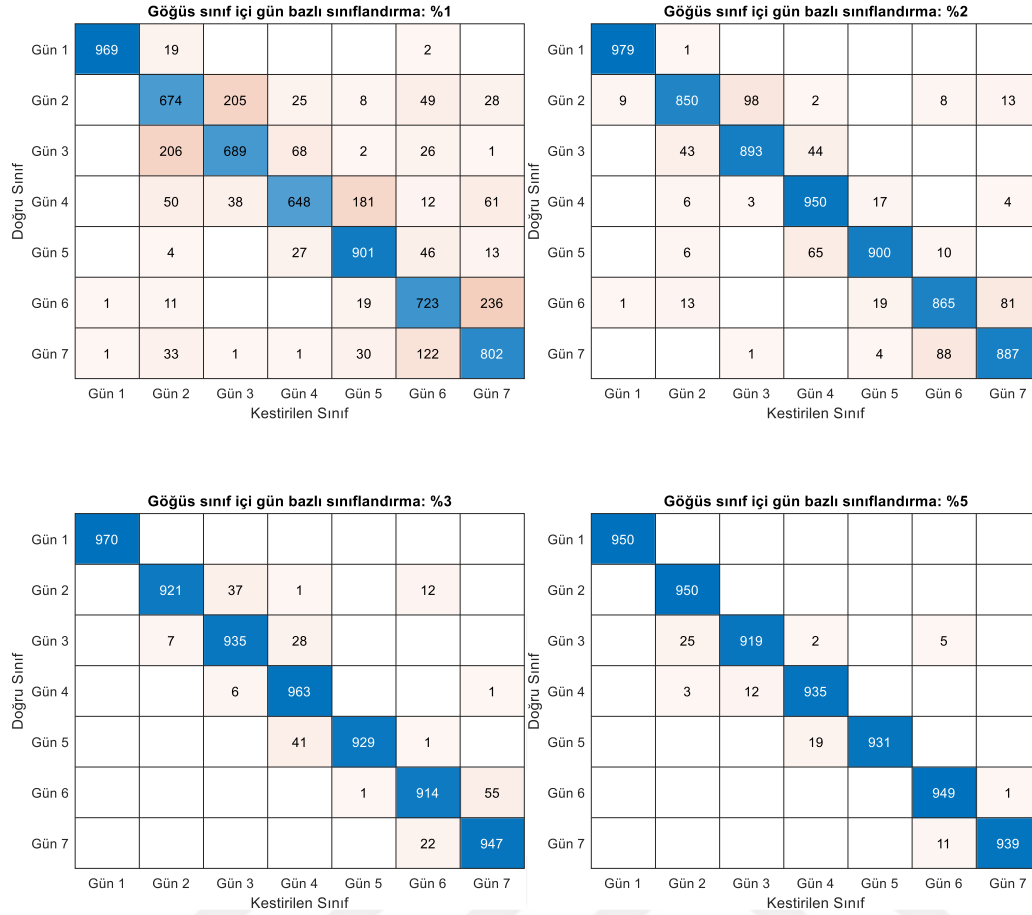
**Şekil 4.11.** Tavuk ürünleri gün bazlı sınıflandırma başarımları

nümerik sonuçlar verilmiştir. Satırlar doğru sınıfı sütunlar ise kestirilen sınıfı göstermektedir. Her satır köşegen elemanları doğru sınıf başarımını satırın geri kalan elemanları o sınıfın sütundaki sınıfa karıştırılma oranı ya da değerini göstermektedir. Beş farklı tavuk ürünü için 4 farklı test sonucu karışıklık matrisi elde edilmiştir. Sonuçlar daha az veri kullanıldığında ve yeterli veri kullanıldığında başarımlarının gözlemlenmesi için sırasıyla %1, %2, %3 ve %5 eğitim oranları için Şekil 4.12 -Şekil 4.16 şekilleri ile verilmiştir.

#### 4.2.1. Göğüs'ün gün bazlı sınıflandırması

Tavuk göğsünün gün bazlı sınıflandırma karışıklık matrislerinden %1 eğitim oranında hatalı sınıflandırma değerleri yüksektir. Her satırda hatalı sınıflandırılan elemanlar mevcuttur. Eğitim oranı %5 olduğundan bu sayısal değerler azalmıştır. En çok hata değeri gün 3 gün 2'ye 25 adet karıştırılarak yapılmıştır. Daha sonraki en büyük değer gün 5 gün 4'e 19 adet karıştırılarak yapılmıştır. Bu eğitim oranında sınıflandırma başarımları %99'un üzerindedir. Sonuçlar Şekil 4.12'de verilmiştir.

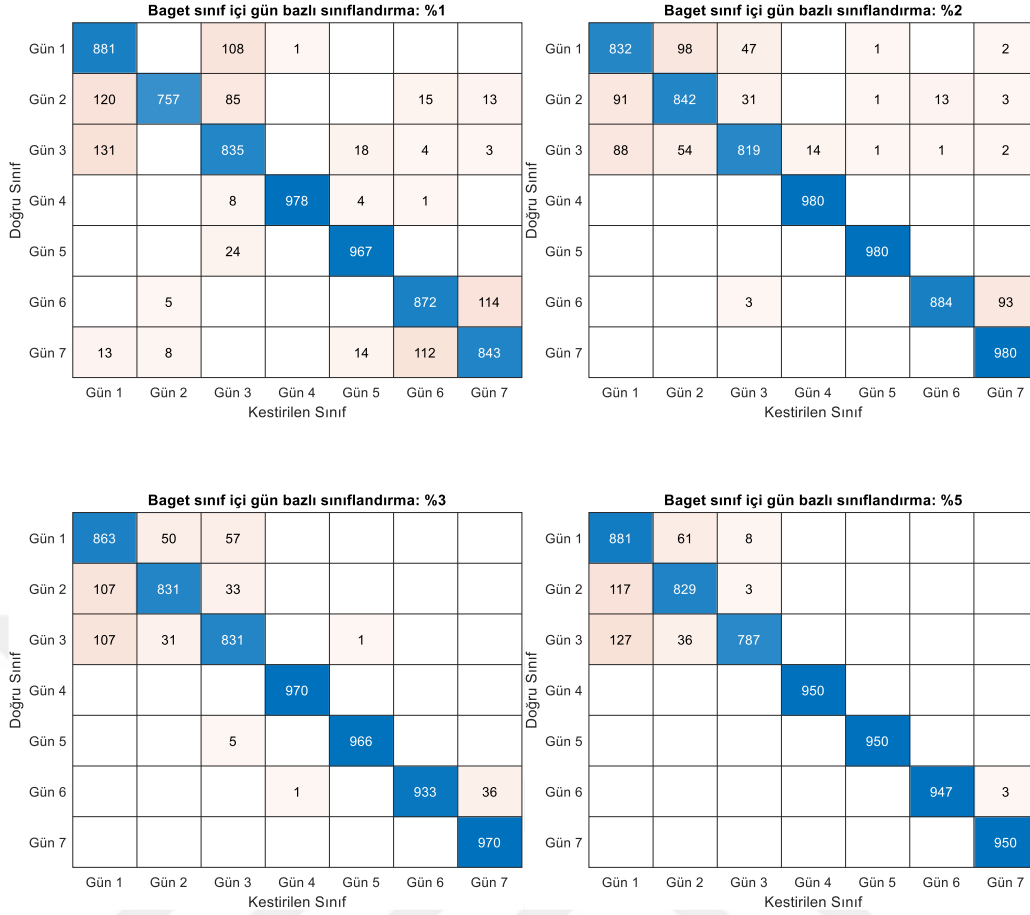




**Şekil 4.12.** Göğüs sınıf içi gün bazlı sınıflandırma

#### 4.2.2. Baget'in gün bazlı sınıflandırması

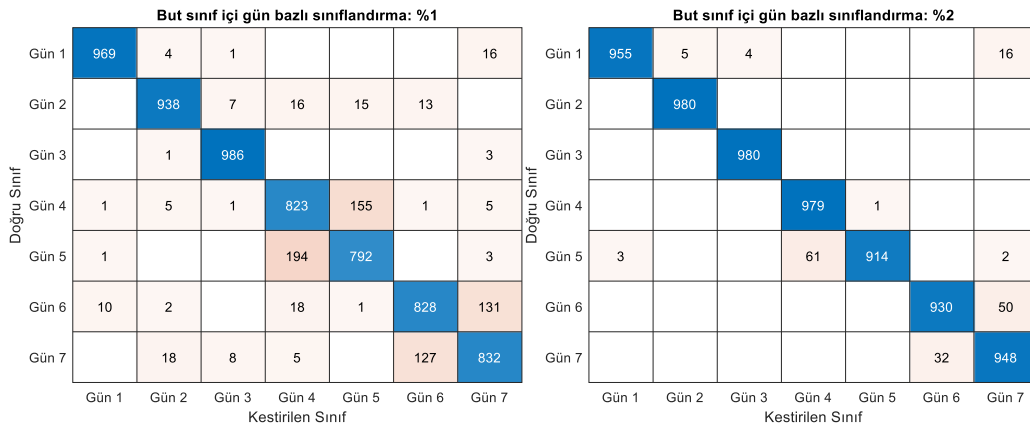
Tavuk bagetin gün bazlı sınıflandırma karışıklık matrislerinden %1 eğitim oranında hatalı sınıflandırma değerleri yüksektir. Her satırda hatalı sınıflandırılan elamanlar mevcuttur. Gün 2 ve gün 3 gün 1'e çok karıştırılmıştır. Eğitim oranı %5 olduğundan bu sayısal değerler azalmıştır. En çok hata değeri gün 3 gün 1'ye 127 adet karıştırılarak yapılmıştır. Daha sonraki en büyük değer gün 2 gün 1'e 117 adet karıştırılarak yapılmıştır. Bu eğitim oranında sınıflandırma başarımı %96'nın üzerindedir. Gün 1 2 3 ün birbirine karıştırılma değerleri eğitim oranı artsada devam etmiştir. Bunun nedeni baget in çok benzerliğine dayalıdır. Çok benzer verilerde bu değerlerle karşılaşmak olasıdır. Sonuçlar Şekil 4.13'te verilmiştir.

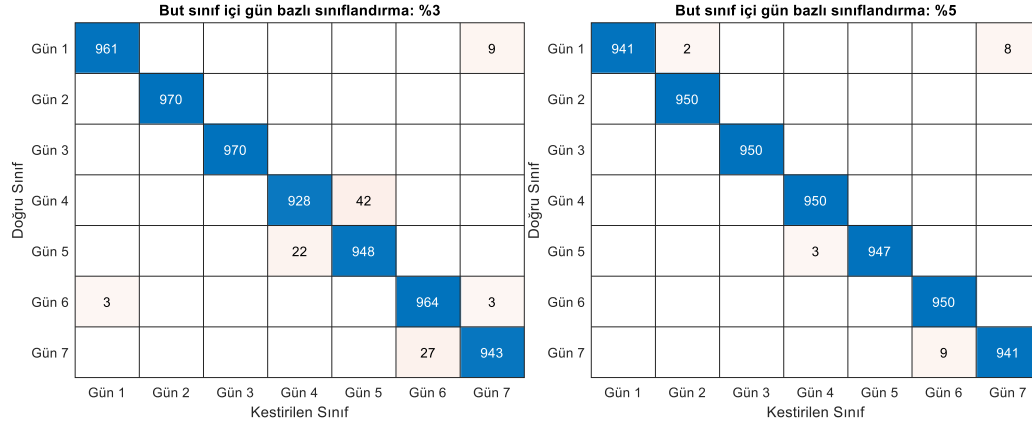


**Şekil 4.13.** Baget sınıf içi gün bazlı sınıflandırma

### 4.2.3. But'un gün bazlı sınıflandırması

Tavuk butun gün bazlı sınıflandırma karışıklık matrislerinden %1 eğitim oranında hatalı sınıflandırma değerleri yüksektir. Her satırda hatalı sınıflandırılan elamanlar mevcuttur. Eğitim oranı %3 ve %5 olduğundan bu sayısal değerler azalmıştır. Hiç yok denecek kadar azdır. Bu eğitim oranında sınıflandırma başarımı %100'e yakındır. Sonuçlar Şekil 4.14'te verilmiştir.

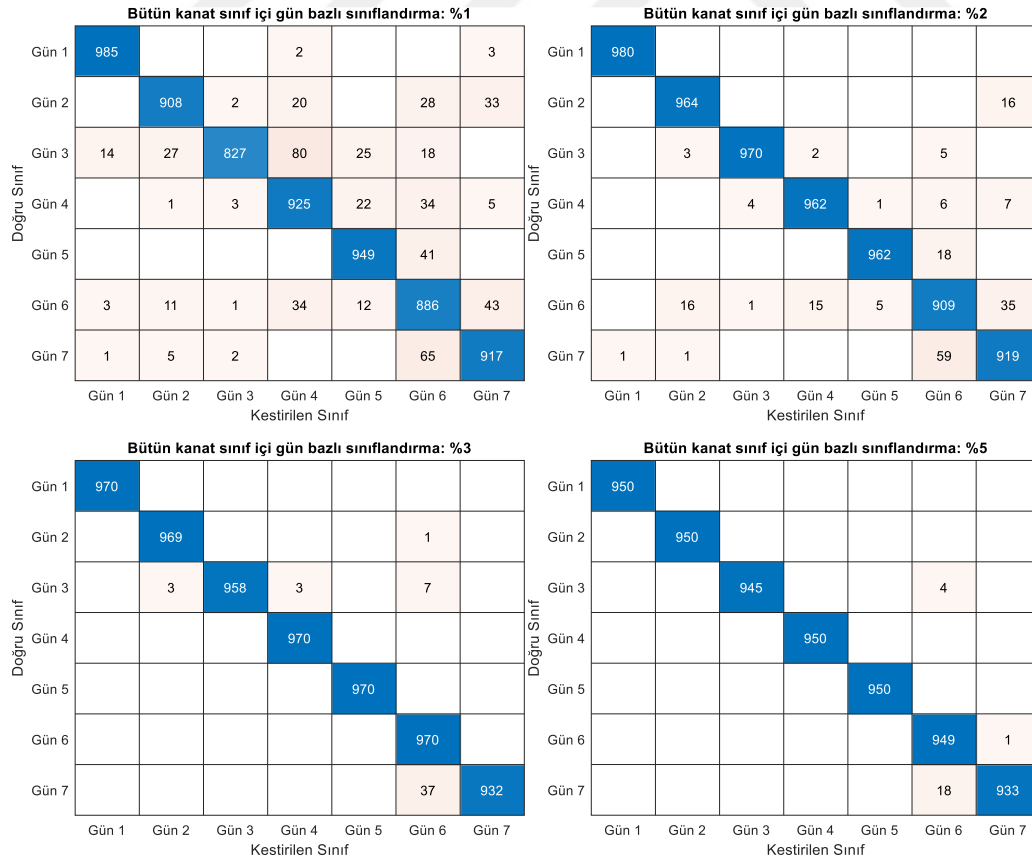




**Şekil 4.14.** But sınıf içi gün bazlı sınıflandırma

#### 4.2.4. Bütün kanat'ın gün bazlı sınıflandırması

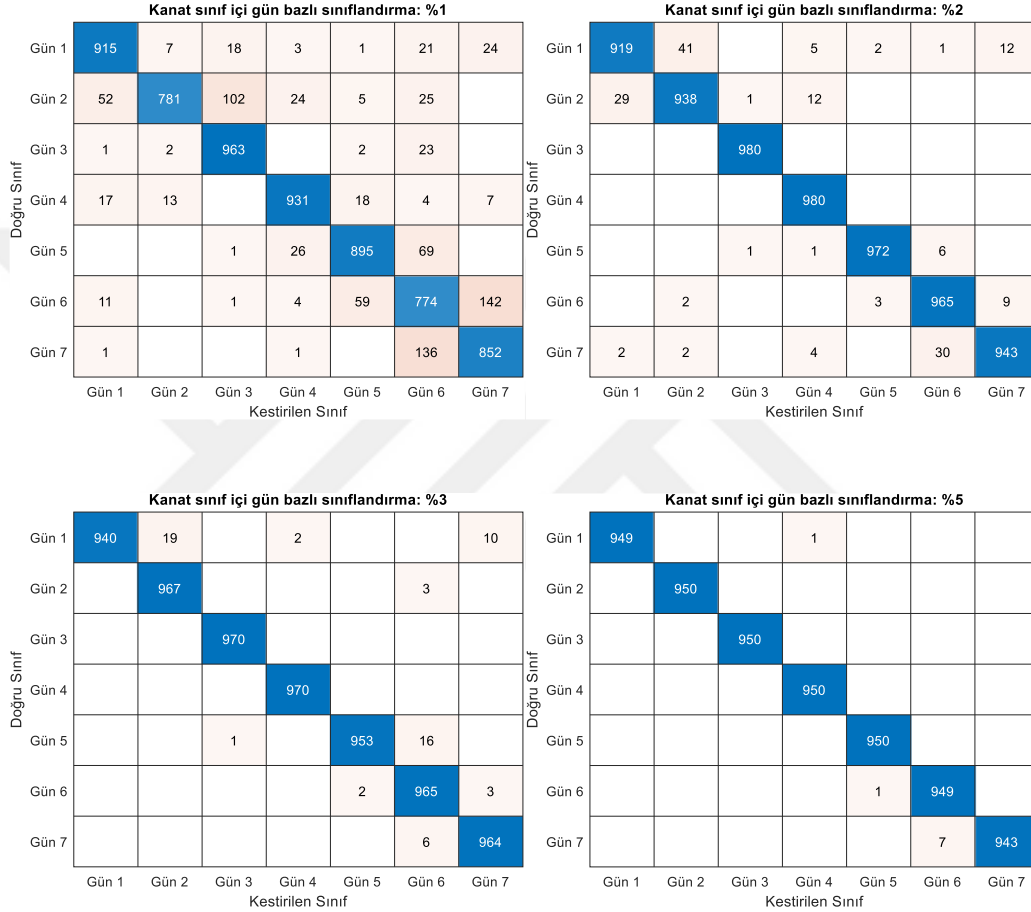
Tavuk bütün kanatın gün bazlı sınıflandırma karışıklık matrislerinden %1 eğitim oranında hatalı sınıflandırma değerleri yüksektir. Her satırda hatalı sınıflandırılan elamanlar mevcuttur. Eğitim oranı %3 ve %5 olduğundan bu sayısal değerler azalmıştır. Hiç yok denecek kadar azdır. Bu eğitim oranında sınıflandırma başarımları %100'e yakındır. Sonuçlar Şekil 4.15'de verilmiştir.



**Şekil 4.15.** Bütün kanat sınıf içi gün bazlı sınıflandırma

#### 4.2.5. Kanat'ın gün bazlı sınıflandırması

Tavuk kanatın gün bazlı sınıflandırma karışıklık matrislerinden %1 eğitim oranında hatalı sınıflandırma değerleri yüksektir. Her satırda hatalı sınıflandırılan elamanlar mevcuttur. Eğitim oranı %3 ve %5 olduğundan bu sayısal değerler azalmıştır. Hiç yok denecek kadar azdır. Bu eğitim oranında sınıflandırma başarımı %100'e yakındır. Bütün kanat ve kanat derin öğrenme ile büyük başarı oranıyla sınıflandırılmıştır.



Şekil 4.16. Kanat sınıfı içi gün bazlı sınıflandırma

Şekil 4.16'da göğüs için %1 eğitim oranı sonuçları incelendiğinde karışıklık matrisinde her satıra dağılan hatalı sınıflandırma değerleri yüksektir. Bu değerler %2'den %5'e eğitim oranlarında azalmıştır. Köşegen değerleri test kümesi adetlerine çok yakın değerlerdir. Bu başarımın %100 başarıma değerine yaklaştığını göstermektedir. But, kanat ve bütün kanat sınıflandırmalarında %3 ve %5 eğitim oranı sınıflandırmaları incelendiğinde başarımın yüksek olduğu görülmektedir. Baget tavuğun sınıflandırılma karışıklık matrisine bakıldığında ilk 3 gün verisi birbirlerine karıştırılmaktadır. Bunun sebebi incelendiğinde baget parçasının çok benzerliği ve bu görüntüler için farklı

öznitelik çıkarımı tekniđi denenmesi gerektiđi anlaşılır. Karışıklık matrislerinden %2 eğitim oranı kullanımının sınıflandıırma başarımı açısından yeterli başarımı gösterdiđi anlaşılmaktadır. Oran %5'e yükseltildiđinde ise başarımın doyuma yani sınır deđere ulaştıđı söylenebilir. Hatalı sınıflandırılan görüntü az olduđundan %3 eğitim oranı bile tercih edilebilir düzeydedir. Eğitim oranının yükseltilmesi eğitim aşamasının yükünü artırır, gecikmelere sebep olabilir. Şartlar zorlaştırıldıđında ve bu sebeple daha fazla görüntü ile ağır eğitilmesi gerektiđinde bu tercih edilebilir.

Eğitim oranını yükseltmek eğitim aşamasının karmaşıklığını artırırken test aşamasının oranını yükseltmek test aşamasının karmaşıklığını artırmaktadır. Eğitim aşaması bulut sistemlerde çalışacak ise bunun önemi yoktur ancak bu sistem saha da online olarak eğitilip test edilecek ise bu aşamada önemli olduđu ortaya çıkar. Ayrıca gerçek sistemlerde eğitim aşamasında %50 civarında eğitim oranları kullanılır. Bu çalışmada başarıım için %5 civarında yeterli eğitim oranının görülmesi tavuk ürünlerinin kullanıldıđı bu çalışmada önemli bir sonuçtur. Bu sayede önerilen yöntem mobil ve saha sistemler için avantajlı hale gelmektedir.

## 5. SONUÇLAR VE ÖNERİLER

Bu çalışma sık tüketilen tavuk ürünlerinin kalitesinin mikrobiyolojik ve kimyasal analizinin yanında görüntü işleme teknikleri kullanarak tespit edilmesine yardımcı olmaktadır. Analizlerin uzun sürmesi bu tür gıdalar için uzun sürelerdir. Sınıflandırmada beş çeşit tavuk ürünü kullanılmıştır. Bu sınıflar önce sınıflararası sınıflandırmaya tabi tutulmuştur. Burada elde edilen bulgular üçüncü bölümde karışıklık matrisleri ve başarımlarını şeklinde verilmiştir. Başarımlarından tatmin edici başarımlarını elde edildiği görülmüştür.

Endüstriyel ve ticari gıda sistemlerinde nesnelere interneti kullanımı hızlı bir şekilde artmaktadır. Görüntü işlemeyle dayalı gıda izleme yöntemlerinin kullanımında bu sistemlerle birlikte paralel bir şekilde yaygınlaşmaktadır. Görüntü bazlı sistemler biyolojik ve kimyasal kalite ölçümlerinin zaman kısıtı dezavantajına karşı bir alternatif olarak geliştirilmektedir. İzleme, kontrol, stok takibi gibi görüntü işlemeyle uygun sistem gereksinimlerinin karşılanması insan hayatında büyük kolaylıklar sağlayacaktır. Buzdolapları, fırınlar gibi çok sık kullanılan insan hayatının vazgeçilmez araçları bu sistemler sayesinde daha güvenilir ve kullanışlı hale geleceklerdir.

Gıda güvenliğinin izlenmesi ve takip edilmesinde görüntü işleme uygulamaları kullanılmaktadır. Düşük maliyetli sistemlerin yaygınlaşması ve yöntemlerin geliştirilmesiyle bunlar daha da hızla yaygınlaşacaktır. Tavuk ürünlerinin kullanıldığı bu çalışma Raspberry pi, Tinkerboard, Banan pi gibi ucuz bilgisayarlar ve bulut sistem kullanılarak gerçekleştirilebilir bir sistem ortaya konabilir. Bu mini bilgisayarlar için uygun kamera modülü eklenerek ve sistem entegrasyonu ile mini bir sınıflandırma sistemi gerçekleştirilebilir. Karmaşıklığı düşük bu uygulama mobil sistem ile de kullanılabilir. Geliştirilecek bir mobil yazılım ile bulutta çalışacak bir sınıflandırma sistemi ortaya konursa son kullanıcı bunu mobil marketten cihazına kurarak günlük hayatta kullanabilecektir.

Endüstriyel cihazlarda cihaza entegre edilecek nesnelere interneti bir cihaz vasıtasıyla bulutta çalışan bir sistem gerçekleştirilirse stok takibi, izleme, kalite gibi bildirimler alınabilir. Şirketler bunlarla hem zamandan hemde maliyetten tasarruf ederler. İnsanın kendi yaptığı otomatik sonuç çıkarma olayını makine öğrenmesi kullanarak gerçekleştirirler.

Tavuk, et, balık gibi dondurulmuş gıda ya da dondurularak saklama süresi uzatılan gıdalarda iç sensörler geliştirilirse bunlardan gelen bilgiler ilede gıda güvenliğine büyük

katkılar sağlanır. Önemli gıdalarda risk azaltma ve güvenlik bu sayede sağlanmış olacaktır.

Sınıf bazlı sınıflandırma sonuçlarına bakıldığında beş tavuk ürünü için eğitim oranı %0.5'ten %2'ye değiştirildiğinde doğru sınıflandırma sonucu %86'dan %99'a artmıştır (Şekil 4.1-4.7). Karışıklık matrislerinden 7 gün için bu değerler yakın sonuçlar vermiştir. Bazı günlerin karışıklık matrislerindeki yüksek değerler test aşamasının yanlılığını önlemek için yapılan Monte Carlo benzetiminden kaynaklanmaktadır. Diğer bir nedeni ise o gün alınan görüntülerin yakınlığından kaynaklıdır. Bu da sistemin dayanıklılığını gösteren bir sonuçtur. Değişimin görüntü işleme teknikleriyle analiz edildiği ve izlendiği sistemler için değerli bir sonuçtur. Kutu çizimlerinden ve çizgi gösterimlerinden uç değerlerinde fazla çıkmamış olması tutarlılığa bir işarettir.

Her bir ürünün gün bazlı sınıflandırma sonuçlarına bakılırsa karışıklık matrislerinden eğitim oranının %1'den %5' artırılması sınıflandırma başarımını bagette fazla etkilememiştir (Şekil 4.13). %3 ve %5 eğitim oranı karışıklık matrislerine bakıldığında Gün 2 ve Gün 3'ün Gün 1'e karıştırılma oranı fazladır. Diğer 4 tavuk parçasında bunu gözlenmemiştir (Şekil 4.12; Şekil 4.14-4.16). Eğitim oranı sınıf bazlı sınıflandırmada %2 yeterli iken gün bazlı sınıflandırmada %5 oranına çıkmıştır. Sistem tasarımı düşünüldüğünde önce tavuğun sınıfı belirlenecek daha sonra o sınıfın kaç günlük olduğu test edilecektir. Gerçek sistemde ilk blok %5 eğitim ile zaman karmaşıklığı daha yüksek olacaktır. Sahada çalışan gezgin bir sistemde eğitim aşaması daha uzun sürecektir.

Gerçekleştirilebilir bir sistem olarak ele alındığında bu sınıflandırma sistemi esnek yapısıyla diğer görüntülenebilir gıdalardada kullanıma uygundur. Ambalajlı gıdalarda kullanılamasada içi görünen şeffaf ambalajlı gıdalarda kullanılabilir. Örneğin süt ürünlerinden kaymak, şakşuka, ezme gibi şeffaf ambalajlı hazır gıdalar bakterilerden etkilenerek renkleri değişir ve küflenmelere uğrarlar. Buda önerilen görüntü işleme tabanlı sınıflandırma sisteminin kullanıldığı bu tezde önerilen sistemin kullanılabilceğini gösterir. Kaymak üzerindeki küf kolaylıkla görüntüden belirlenebilir ve kullanıcı ile satıcı uyarılabilir. Bu sistemle hem sağlık bakımından sakıncalar önlenecek hemde satıcı maddi kayba uğramadan uyarılacaktır. Bu tez kapsamında ve elde edilen sonuçları ile tavuk ürünlerinin kullanıldığı ve sınıflandırıldığı özgün çalışmadır.

## 6. KAYNAKLAR

- Beale, M.K., Hagan, M.T. & Demuth, H.B. (2023). Deep Learning Toolbox User's Guide.
- Dargham, J.A., Chekima, A. & Mounq, E.G. (2012). Fusing facial features for face recognition. In Distributed Computing and Artificial Intelligence; Springer: Berlin/Heidelberg, Germany, 565–572.
- Dargham, J.A., Chekima, A., Mounq, E. & Omatu, S. (2010). Data fusion for face recognition. In Distributed Computing and Artificial Intelligence; Springer: Berlin/Heidelberg, Germany, 681–688.
- Demir, S., Köse, M., Yavuzer, E. (2023). Balık Türlerinin Evrişimli Sinir Ağları İle Sınıflandırılması. 4th International Conference On Engineering And Applied Natural Sciences.
- Doğan, Ö., Yavuzer, E., Köse, M., Tekle, Ş. (2022). Makine öğrenmesi ile balık tazelik seviyesinin tahmini. 5th International Eurasian Conference on Biological and Chemical Sciences (EurasianBioChem 2022).
- Doğan, Ö. (2023). Makine öğrenmesi ile alabalık, çipura ve levrek balıklarının kalite seviyelerinin ve türlerinin belirlenmesi. Kırşehir: Yüksek Lisans Tezi, Kırşehir Ahi Evran Üniversitesi, Fen Bilimler Enstitüsü, İleri Teknolojiler Anabilim Dalı.
- Hammadi, A. (2023). A simple security application using real-time face recognition. Kırşehir: Yüksek Lisans Tezi, Kırşehir Ahi Evran Üniversitesi, Fen Bilimler Enstitüsü, İleri Teknolojiler Anabilim Dalı.
- He, K., Zhang, X., Ren, S., & Sun, J. (2015). Deep Residual Learning for Image Recognition. 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 770-778.
- Hussein, M.A.H., Köse, M., Yavuzer, E., Şanlıalp, İ. (2023). Using A Pre-Trained Convolutional Neural Network In Chicken Meat Classification. 8. International Sciences and Innovation Congress.
- Jamnekar, R.V., Keole, R.R., Mohod, S.W., Mahore, T.R., Pande, S. (2023). Food Classification Using Deep Learning Algorithm. In: Gupta, D., Khanna, A., Hassanien, A.E., Anand, S., Jaiswal, A. (eds) International Conference on Innovative Computing and Communications. Lecture Notes in Networks and Systems, vol 492. Springer, Singapore.



- Kim, P. (2017). *MatLab Deep Learning with Machine Learning, Neural Networks and Artificial Intelligence*. Apress.
- Köse, M. (2023). Use Of Convolutionary Neural Network As Feature Extractor In Image Classification. 8. International Sciences and Innovation Congress.
- Lawal, R. A., Martin, S. H., Vanmechelen, K., Vereijken, A., Silva, P., Al-Atiyat, R. M., ... Hanotte, O. (2020). The wild species genome ancestry of domestic chickens. *BMC Biology*, *18*(1), 13. doi:10.1186/s12915-020-0738-1.
- Leung, M. K., Xiong, H. Y., Lee, L. J. & Frey, B. J. (2014). Deep learning of the tissue-regulated splicing code. *Bioinformatics* *30*, 121–129.
- Lu, Y. (2016). Food Image Recognition by Using Convolutional Neural Networks (CNNs). arXiv 2016, arXiv:1612.00983.
- Paluszek, M. & Thomas, S. (2020). *Practical MATLAB Deep Learning: A Project-Based Approach*. Apress.
- Russakovsky, O., Deng, J., Su, H., et al. (2015). ImageNet Large Scale Visual Recognition Challenge. *International Journal of Computer Vision (IJCV)*. Vol 115, Issue 3, 211–252
- Subhi, M.A. & Ali, S.M. (2018). A Deep Convolutional Neural Network for Food Detection and Recognition. In Proceedings of the 2018 IEEE-EMBS Conference on Biomedical Engineering and Sciences (IECBES), Kuching, Sarawak, Malaysia, 284-287.
- Wang, Y., Wu, J., Deng, H., & Zeng, X. (2021). Food Image Recognition and Food Safety Detection Method Based on Deep Learning. *Computational Intelligence and Neuroscience*, 1–13.
- Xiang, H., Gao, J., Yu, B., Zhou, H., Cai, D., Zhang, Y., ... Zhao, X. (2014). Early Holocene chicken domestication in northern China. *Proceedings of the National Academy of Sciences*, *111*(49), 17564–17569. doi:10.1073/pnas.1411882111
- Yahya, F., Fazli, B., Sallehudin, H. & Jaya, M. (2020). Machine Learning in Dam Water Research: An Overview of Applications and Approaches. *Int. J. Adv. Trends Comput. Sci. Eng.*, *9*, 1268–1274.
- Yavuzer, E., & Köse, M. (2022). Prediction of fish quality level with machine learning. *International Journal of Food Science & Technology*, *57*(8), 5250–5255. doi:10.1111/ijfs.15853

Zahisham, Z., Lee, C.P., & Lim, K.M. (2020). Food Recognition with ResNet-50. 2020 IEEE 2nd International Conference on Artificial Intelligence in Engineering and Technology (IICAIET), 1-5.



## ÖZGEÇMİŞ

<b>Kişisel Bilgiler</b>	
<b>Adı Soyadı:</b>	Mustafa Ali Hussein HUSSEIN
<b>Uyruğu:</b>	IRAQ
<b>Orcid Numarası:</b>	0009-0006-5472-2852

<b>Eğitim Bilgileri</b>	
<b>Lisans</b>	
<b>Üniversite</b>	IMAM JA'AFAR AI-SADIQ UNIVERSITY
<b>Fakülte</b>	INFORMATION TECHNOLOGY COLLEGE OF SCIENCE
<b>Bölümü</b>	COMPUTER ENGINEERING
<b>Mezuniyet Yılı</b>	2016
<b>Yüksek Lisans</b>	
<b>Üniversite</b>	Kırşehir Ahi Evran Üniversitesi
<b>Enstitü Adı</b>	Fen Bilimleri Enstitüsü
<b>Anabilim Dalı</b>	İleri Teknolojiler Anabilim Dalı
<b>Mezuniyet Tarihi</b>	2024

<b>Tezden Üretilen Makaleler ve Bildiriler</b>
<i>Mustafa Ali Hussein HUSSEIN, Memduh KÖSE, Emre YAVUZER, İbrahim ŞANLIALP (2023). Using a Pre-Trained Convolutional Neural Network in Chicken Meat Classification. 8. International Scientific Research and Innovation Congress</i>