



**T.C.
AMASYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**PİRİNÇ ÜRÜNÜNÜN DERİN ÖĞRENME TEKNİKLERİ
KULLANILARAK SINIFLANDIRILMASI**

YÜKSEK LİSANS TEZİ

ÖMER ESEN

MAYIS

**PIRINÇ ÜRÜNÜNÜN DERİN ÖĞRENME TEKNİKLERİ
KULLANILARAK SINIFLANDIRILMASI**

Ömer ESEN

**YÜKSEK LİSANS TEZİ
TEKNOLOJİ VE İNOVASYON YÖNETİMİ ANABİLİM DALI**

Danışman

Prof. Dr. Meryem EVECEN

**AMASYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

MAYIS 2025

Yüksek Lisans Tezi Kabul ve Onay Sayfası

Ömer ESEN tarafından hazırlanan “Pirinç Ürününün Derin Öğrenme Teknikleri Kullanılarak Sınıflandırılması” adlı tez çalışması aşağıdaki jüri tarafından OY BİRLİĞİ ile Amasya Üniversitesi Fen Bilimleri Enstitüsü Teknoloji ve İnovasyon Yönetimi Anabilim Anabilim Dalında YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Danışman: Prof. Dr. Meryem EVECEN

Fizik Anabilim Dalı, Amasya Üniversitesi

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum

Başkan: Dr. Öğr. Üyesi İnayet Hakkı ÇİZMECİ

Bilgisayar Yazılımı Anabilim Dalı, Afyon Kocatepe Üniversitesi

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum

Üye: Dr. Öğr. Üyesi Yavuz ÜNAL

Bilgisayar Mühendisliği Anabilim Dalı, Sinop Üniversitesi

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum

Tez Savunma Tarihi: 05/05/2025

Jüri tarafından kabul edilen bu tezin Yüksek Lisans Tezi olması için gerekli şartları yerine getirdiğini onaylıyorum.

.....

Doç. Dr. Ümit YILDIRIM

Fen Bilimleri Enstitüsü Müdürü

ETİK BEYAN

Amasya Üniversitesi Fen Bilimleri Enstitüsü Tez Yazım Kurallarına uygun olarak hazırladığım bu tez çalışmada;

- Tez içinde sunduğum verileri, bilgileri ve dokümanları akademik ve etik kurallar çerçevesinde elde ettiğimi,
- Tüm bilgi, belge, değerlendirme ve sonuçları bilimsel etik ve ahlak kurallarına uygun olarak sunduğumu,
- Tez çalışmada yararlandığım eserlerin tümüne uygun atıfta bulunarak kaynak gösterdiğimi,
- Kullanılan verilerde herhangi bir değişiklik yapmadığımı,
- Bu tezde sunduğum çalışmanın özgün olduğunu, bildirir, aksi bir durumda aleyhime doğabilecek tüm hak kayıplarını kabullendiğimi beyan ederim.

Ömer ESEN

15.05.2025

PIRİNÇ ÜRÜNÜNÜN DERİN ÖĞRENME TEKNİKLERİ KULLANILARAK SINIFLANDIRILMASI

(Yüksek Lisans Tezi)

Ömer ESEN

AMASYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Mayıs 2025

ÖZET

Pirinç hem küresel ölçekte hem de Türkiye özelinde stratejik öneme sahip temel bir gıda maddesi ve ekonomik bir tarımsal üründür. Özellikle Asya kıtasında yoğunlaşan üretim faaliyetlerine ek olarak, Türkiye'de de Edirne, Samsun ve Manisa gibi bölgelerde pirinç üretimi yaygın olarak sürdürülmektedir. Dünyada ve Türkiye'de morfolojik, renk ve şekil olarak çok farklı pirinç türleri mevcuttur. Ancak geleneksel yöntemlerle gerçekleştirilen manuel sınıflandırma işlemleri, zaman ve maliyet açısından verimsizliklere yol açmakta ve bu durum tarımda daha yenilikçi ve otomasyona dayalı yaklaşımların gerekliliğini ortaya koymaktadır. Bu bağlamda yürütülen çalışmada, Türkiye'de yaygın olarak yetiştirilen Arborio, Basmati, Jasmine, İpsala ve Karacadağ pirinci çeşitlerinin sınıflandırılması amacıyla, her bir tür için 15 000 olmak üzere toplamda 75 000 görüntüden oluşan kapsamlı bir veri seti kullanılmıştır. Görüntüler hem morfolojik özellikler hem de RGB ve HSV renk uzayları temelinde değerlendirilmiş; sınıflandırma işlemleri derin öğrenmeye dayalı Evrişimsel Sinir Ağları (CNN) aracılığıyla gerçekleştirilmiştir. Çalışma kapsamında VGG-16, InceptionV3, EfficientNetB0, ResNet50 ve DenseNet gibi yaygın olarak kullanılan transfer öğrenme modellerine ek olarak, katmanlı iyileştirmelerle geliştirilen yedi farklı yeni model mimarileri test edilmiştir. Bu süreçte uygulanan veri ön işleme ve veri artırma teknikleri, model performanslarını olumlu yönde etkilemiş ve sınıflandırma doğruluklarında anlamlı artışlar sağlanmıştır. Yapılan karşılaştırmalı değerlendirmeler sonucunda, test edilen tüm modellerin yüksek başarı oranları sergilediği gözlemlenmiştir; özellikle geliştirilen Model 7, %99,6 doğruluk oranı ile öne çıkarak transfer öğrenme tabanlı modellerle rekabet edebilecek düzeye ulaşmıştır. Elde edilen bulgular, pirinç çeşitlerinin sınıflandırılmasında evrişimsel sinir ağları ve transfer öğrenme yöntemlerinin yüksek doğrulukla çalışabildiğini göstermektedir. Bu çalışma, tarımsal ürünlerin sınıflandırılmasında yapay zekâ destekli otomasyon sistemlerinin etkinliğini ortaya koymakta ve bu teknolojilerin tarım sektöründe verimliliği artırmaya yönelik uygulamalarda geniş bir kullanım potansiyeline sahip olduğunu göstermektedir.

Sayfa Adedi : 132

Anahtar Kelimeler : Derin öğrenme, Pirinç, Evrişimsel sinir ağları, Sınıflandırma

Danışman : Prof. Dr. Meryem EVECEN

CLASSIFICATION OF RICE PRODUCT USING DEEP LEARNING TECHNIQUES

(M. Sc. Thesis)

Ömer ESEN

AMASYA UNIVERSITY

GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCES

May 2025

ABSTRACT

Rice is a basic foodstuff and an economic agricultural product of strategic importance both globally and in Turkey. In addition to the production activities concentrated especially in the Asian continent, rice production is also widely carried out in regions such as Edirne, Samsun and Manisa in Turkey. There are many different types of rice in terms of morphology, color and shape in the world and in Turkey. However, manual classification processes carried out with traditional methods lead to inefficiencies in terms of time and cost, and this situation reveals the need for more innovative and automated approaches in agriculture. In this context, a comprehensive dataset consisting of 75 000 images in total, 15 000 for each type, was used to classify Arborio, Basmati, Jasmine, Ipsala and Karacadag rice varieties commonly grown in Türkiye. The images were evaluated based on both morphological features and RGB and HSV color spaces; classification operations were performed using deep learning-based Convolutional Neural Networks (CNN). In addition to widely used transfer learning models such as VGG-16, InceptionV3, EfficientNetB0, ResNet50 and DenseNet, seven different new model architectures developed with layered improvements were tested within the scope of the study. Data preprocessing and data augmentation techniques applied in this process positively affected model performances and significant increases were achieved in classification accuracies. As a result of the comparative evaluations, it was observed that all tested models exhibited high success rates; especially the developed Model 7 stood out with an accuracy rate of 99,6% and reached a level that could compete with transfer learning-based models. The findings obtained show that convolutional neural networks and transfer learning methods can work with high accuracy in the classification of rice varieties. This study demonstrates the effectiveness of artificial intelligence-supported automation systems in the classification of agricultural products and shows that these technologies have a wide potential for use in applications aimed at increasing efficiency in the agricultural sector.

Number of pages : 132
Keywords : Deep learning, Rice, Convolutional neural networks, Classification
Supervisor : Prof. Dr. Meryem EVEÇEN

ÖN SÖZ ve TEŞEKKÜR

Bu çalışmanın her aşamasında bilgi, deneyim ve rehberliğiyle yolumu aydınlatan, yönelttiğim her soruya sabırla ve içtenlikle yanıt vererek her zaman destek olan değerli danışmanım Prof. Dr. Meryem EVECEN'e en derin teşekkürlerimi sunuyorum. Kendisiyle çalışma fırsatı bulmuş olmak, akademik yaşamımın en kıymetli kazanımlarından biri olmuştur.

Yüksek lisans sürecim boyunca bilgi ve tecrübeleriyle katkı sunan hem akademik hem de moral desteğiyle her zaman yanımda olan Cemil ERGİN, Fırat GÖKHAN, Hasan YALDIR, Hamdi SAĞLAM ve Atılğan KİZİR'e; manevi desteğini daima hissettiren M. Fettah Bey'e ve birlikte çalışmaktan büyük mutluluk duyduğum değerli sınıf arkadaşlarıma içten teşekkür ederim.

Tüm bu süreçte anlayışları, sabırları ve sevgileriyle bana güç veren, her zaman yanımda olan sevgili eşime ve çocuklarıma ise sonsuz minnettarlığımı ifade etmek isterim. Onların desteği olmasaydı bu çalışmayı tamamlamak çok daha güç olurdu.

Bu tez, yalnızca akademik bir sürecin ürünü değil; aynı zamanda destek, sabır ve inançla örülmüş bir emeğin sonucudur.

İÇİNDEKİLER

	Sayfa
ÖZET	iv
ABSTRACT.....	v
ÖN SÖZ VE TEŞEKKÜR.....	vi
İÇİNDEKİLER	vii
ÇİZELGELER DİZİNİ	xi
HARİTALAR DİZİNİ	xiii
ŞEKİLLER DİZİNİ	xiv
RESİMLER DİZİNİ.....	xvii
1. GİRİŞ	1
2. GENEL BİLGİLER	2
2.1. Pirincin Küresel Beslenme Sistemindeki Rolü ve Ekonomik Önemi	2
2.2. Türkiye’de Pirincin Ekonomik ve Beslenme Açısından Önemi	4
2.3. Farklı Pirinç Türleri.....	5
2.3.1. Karacadağ pirinci.....	6
2.3.2. Basmati pirinci.....	7
2.3.3. Jasmine pirinci.....	7
2.3.4. İpsala pirinci	8
2.3.5. Arborio pirinci	9
2.4. Pirinçte Kalite Sınıflandırması	9
2.5. Geleneksel Sınıflandırma Yöntemleri ve Yetersizliği	10
2.6. Modern Çözümler ve Otomatik Sınıflandırma.....	11
2.7. Derin Öğrenme ile Pirinç Sınıflandırma	12
2.8. Yöntemlerin Karşılaştırılması	15

3.GÖRÜNTÜ İŞLEME.....	16
3.1. Dijital Görüntü ve Türleri	16
3.2. Görüntü İşleme Adımları	18
3.3. Morfolojik Görüntü İşleme	23
3.3.1. Aşındırma işlemi	24
3.3.2. Genişleme işlemi	25
3.3.3. Açma işlemi	26
3.3.4. Kapama işlemi	27
3.4. Özellik Çıkarımı.....	28
4. YAZILIM.....	30
4.1. MATLAB.....	30
4.2. Python.....	30
4.3. Kullanılan Kütüphaneler	33
4.3.1. OpenCV	33
4.3.2. NumPy	35
4.3.3. Matplotlib	35
4.3.4. Os.....	37
5. YÖNTEM	38
5.1. Veri Seti.....	38
5.2. Derin Öğrenme	39
5.3. Evrimsel Sinir Ağları.....	40
5.3.1. CNN katmanları.....	40
5.4. Önceden Eğitilmiş Evrimsel Sinir Ağları Mimarileri.....	42
5.5. Transfer Öğrenme Yaklaşımları ve Geliştirilen CNN Modelleri.....	43
5.5.1. VGGNet.....	43

5.5.2. ResNet	44
5.5.3. EfficientNet	45
5.5.4. Inception V3	46
5.5.5. DenseNet	48
5.5.6. Model 1.....	49
5.5.7. Model 2.....	51
5.5.8. Model 3.....	54
5.5.9. Model 4.....	57
5.5.10. Model 5.....	59
5.5.11. Model 6.....	62
5.5.12. Model 7.....	64
6. BULGULAR.....	68
6.1. Başarım Ölçütleri	68
6.1.1. Karmaşıklık matrisi	69
6.1.2. Doğruluk (Accuracy).....	70
6.1.3. Duyarlılık (Recall).....	71
6.1.4. Kesinlik (Precision).....	71
6.1.5. F1 skor (F1-score)	71
6.1.6. Logaritmik kayıp (Log loss).....	72
6.1.7. ROC eğrisi (ROC curve)	72
6.1.8. Intersection over union (IoU)	73
6. 2. Transfer Öğrenme Eğitim Verileri	73
6.3. Transfer Öğrenme Modelleri Performansları.....	75
6.3.1. VGG16 modeli performansı	75
6.3.2. Resnet50 modeli performansı.....	79

6.3.3. EfficientNetB6 modeli performansı	81
6.3.4. InceptionV3 modeli performansı.....	83
6.3.5. DenseNet modeli performansı	86
6.4. Yeni Oluşturulan Modellerin Performansları.....	89
6.4.1. Model 1 performansı	90
6.4.2. Model 2 performansı	92
6.4.3. Model 3 performansı	95
6.4.4. Model 4 performansı	98
6.4.5. Model 5 performansı	101
6.4.6. Model 6 performansı	105
6.4.7. Model 7 performansı	108
6.5. Yeni Oluşturulan Modellerin Karşılaştırılması	111
6.6. Transfer Öğrenme Modelleri ile Yeni Oluşturulan Modellerin Karşılaştırılması	112
7. SONUÇLAR VE ÖNERİLER.....	115
7.1. Öneriler.....	118
KAYNAKLAR	121
ÖZGEÇMİŞ	132

ÇİZELGELER DİZİNİ

Çizelge	Sayfa
Çizelge 2. 1. Yöntemlerin karşılaştırılması.....	15
Çizelge 4. 1. Programlama dilleri kullanım alanları	31
Çizelge 4. 2. 2025 yılı programlama dilleri popülerlik oranları	32
Çizelge 5. 1. Pirinç çeşitlerine ait teknik özellikler	38
Çizelge 5. 2. Model 1'in geliştirilmesi gereken yönleri.....	50
Çizelge 5. 3. Model 1 modelinin popüler CNN modelleri ile karşılaştırma tablosu	50
Çizelge 5. 4. Model 1 ile Model 2'nin teknik karşılaştırması.....	54
Çizelge 5. 5. Model 2'den Model 3'e geçişte yapılan değişiklikler.....	56
Çizelge 5. 6. Model 2 ile Model 3'ün teknik karşılaştırılması	57
Çizelge 5. 7. Model 3 ile Model 4'ün teknik karşılaştırılması	58
Çizelge 5. 8. Model 4 ile Model 5'in teknik karşılaştırılması	61
Çizelge 5. 9. Model 5 ve Model 6'nın teknik karşılaştırılması	63
Çizelge 5. 10. Model 6 ve Model 7'nin teknik karşılaştırılması.....	66
Çizelge 5. 11. Modellerin karşılaştırılma tablosu	67
Çizelge 6. 1. Eğitim verileri	73
Çizelge 6. 2. VGG16 modeli değerlendirme verileri	77
Çizelge 6. 3. Resnet50 modeli değerlendirme verileri.....	80
Çizelge 6. 4. EfficientNetB6 modeli değerlendirme verileri	82
Çizelge 6. 5. InceptionV3 modeli değerlendirme verileri.....	85
Çizelge 6. 6. DenseNet modeli değerlendirme verileri.....	88
Çizelge 6. 7. Model 1 modelinin değerlendirme verileri	91
Çizelge 6. 8. Model 2 modelinin değerlendirme verileri	94

Çizelge 6. 9. Model 3 modelinin değerlendirme verileri	97
Çizelge 6. 10. Model 3 modelinin karşılaştırmalı analizi	98
Çizelge 6. 11. Model 4 modelinin değerlendirme verileri	100
Çizelge 6. 12. Model 4 sınıf bazlı kıyaslama	101
Çizelge 6. 13. Model 5 modelinin değerlendirme verileri	103
Çizelge 6. 14. Model 5 sınıf bazlı kıyaslama	105
Çizelge 6. 15. Model 6 modelinin değerlendirme verileri	106
Çizelge 6. 16. Model 6 sınıf bazlı kıyaslama	108
Çizelge 6. 17. Model 7 modelinin değerlendirme verileri	109
Çizelge 6. 18. Model 7 sınıf bazlı kıyaslama	111
Çizelge 6. 19. Modellerin karşılaştırmalı performans özeti	111
Çizelge 6. 20. Tüm modellerin doğruluk, kesinlik, duyarlılık, F1-skor tablosu	114

HARİTALAR DİZİNİ

Harita	Sayfa
Harita 2. 1. Dünya genelinde pirinç üretimi haritası.....	3
Harita 2. 2. Türkiye’de pirinç üretimi haritası	4



ŞEKİLLER DİZİNİ

Şekil	Sayfa
Şekil 3. 1. Görüntü işleme adımları	18
Şekil 3. 2. Orijinal bir pirinç görüntüsüne ait histogram grafikleri	23
Şekil 3. 3. Aşındırma işlemi uygulaması	24
Şekil 3. 4. Genişleme işlemi uygulaması	25
Şekil 3. 5. Açma işlemi uygulaması.....	26
Şekil 3. 6. Kapama işlemi uygulaması.....	28
Şekil 4. 1. OpenCV bileşen yapısı	34
Şekil 4. 2. Matplotlib grafik örnekleri	36
Şekil 5. 1. CNN katmanları.....	41
Şekil 5. 2. Model boyutu ve imagenet doğruluk oranları	42
Şekil 5. 3. VGG16 mimarisi	44
Şekil 5. 4. Artık öğrenme.....	45
Şekil 5. 5. EfficientNet mimarisi	46
Şekil 5. 6. Inception V3 mimarisi.....	47
Şekil 5. 7. DensenNet mimarisi	49
Şekil 5. 8. Model 1 mimarisi.....	51
Şekil 5. 9. Model 2 mimarisi.....	53
Şekil 5. 10. Model 3 mimarisi.....	56
Şekil 5. 11. Model 4 mimarisi.....	59
Şekil 5. 12. Model 5 mimarisi.....	61
Şekil 5. 13. Model 6 mimarisi.....	64
Şekil 5. 14. Model 7 mimarisi.....	66
Şekil 6. 1. Beşli sınıflandırma için örnek bir karmaşıklık matrisi	70

Şekil 6. 2. ROC eğrisi tanımlaması.....	72
Şekil 6. 3. VGG16 modeli karmaşıklık matrisi.....	76
Şekil 6. 4. VGG16 modeli kayıp ve doğrulama değerleri.....	76
Şekil 6. 5. VGG16 modeli ROC eğrisi	77
Şekil 6. 6. VGG16 modeli sınıflara göre performans metrikleri	78
Şekil 6. 7. ResNet50 modelinin karmaşıklık matrisi	79
Şekil 6. 8. ResNet50 modelinin kayıp ve doğrulama değerleri	79
Şekil 6. 9. ResNet50 modelinin ROC eğrisi	80
Şekil 6. 10. EfficientNetB6 modeli karmaşıklık matrisi.....	81
Şekil 6. 11. EfficientNetB6 modeli kayıp ve doğrulama değerleri.....	82
Şekil 6. 12. EfficientNetB6 modeli ROC eğrisi.....	82
Şekil 6. 13. InceptionV3 modelini karmaşıklık matrisi	84
Şekil 6. 14. InceptionV3 modelinin kayıp ve doğrulama değerleri	84
Şekil 6. 15. InceptionV3 modelinin ROC eğrisi	85
Şekil 6. 16. DenseNet modeli karmaşıklık matrisi	87
Şekil 6. 17. DenseNet modeli kayıp ve doğrulama değerleri	87
Şekil 6. 18. DenseNet modeli ROC eğrisi	88
Şekil 6. 19. Model 1 modelinin karmaşıklık matrisi.....	90
Şekil 6. 20. Model 1 modelinin kayıp ve doğrulama değerleri.....	91
Şekil 6. 21. Model 1 modelinin ROC eğrisi	91
Şekil 6. 22. Model 2 modelinin karmaşıklık matrisi.....	93
Şekil 6. 23. Model 2 modelinin kayıp ve doğrulama değerleri.....	93
Şekil 6. 24. Model 2 modelinin ROC eğrisi	94
Şekil 6. 25. Model 3 modelinin karmaşıklık matrisi.....	96
Şekil 6. 26. Model 3 modelinin kayıp ve doğrulama değerleri.....	96
Şekil 6. 27. Model 3 modelinin ROC eğrisi	97

Şekil 6. 28. Model 4 modelinin karmaşıklık matrisi.....	99
Şekil 6. 29. Model 4 modelinin kayıp ve doğrulama değerleri.....	99
Şekil 6. 30. Model 4 modelinin ROC eğrisi	100
Şekil 6. 31. Model 5 modelinin karmaşıklık matrisi.....	102
Şekil 6. 32. Model 5 modelinin kayıp ve doğrulama değerleri.....	102
Şekil 6. 33. Model 5 modelinin ROC eğrisi	103
Şekil 6. 34. Model 6 modelinin karmaşıklık matrisi.....	105
Şekil 6. 35. Model 6 modelinin kayıp ve doğrulama değerleri.....	106
Şekil 6. 36. Model 6 modelinin ROC eğrisi	106
Şekil 6. 37. Model 7 modelinin karmaşıklık matrisi.....	108
Şekil 6. 38. Model 7 modelinin kayıp ve doğrulama değerleri.....	109
Şekil 6. 39. Model 7 modelinin ROC eğrisi	109
Şekil 6. 40. Modellerin doğruluk gelişimi	112
Şekil 6. 41. Modellerin sınıf ortalaması F1-skor karşılaştırması	112
Şekil 6. 42. Modellerin doğruluk değerleri karşılaştırması.....	113
Şekil 6. 43. Modellerin kesinlik, duyarlılık ve F1-skor değerleri karşılaştırması.....	114

RESİMLER DİZİNİ

Resim	Sayfa
Resim 2. 1. Genel pirinç görüntüsü	2
Resim 2. 2. Farklı pirinç türleri.....	6
Resim 2. 3. Karacadağ pirinç örnekleri	6
Resim 2. 4. Basmati pirinç örnekleri	7
Resim 2. 5. Jasmine pirinç örnekleri.....	8
Resim 2. 6. İpsala pirinç örnekleri	8
Resim 2. 7. Arborio pirinç örnekleri.....	9
Resim 3. 1. Görüntü işleme	16
Resim 3. 2. Renkli görüntünün gri görüntüye çevrilmiş gösterimi.....	19
Resim 3. 3. Bulanıklaştırma işlemi	20
Resim 3. 4. Renk uzayı dönüşümü.....	21
Resim 3. 5. Klasik eşikleme yöntemi.....	22
Resim 3. 6. Aşındırma işlemi uygulanmış görüntü.....	25
Resim 3. 7. Genişleme işlemi uygulanmış görüntü	26
Resim 3. 8. Açma işlemi uygulanmış görüntü	27
Resim 3. 9. Kapama işlemi uygulanmış görüntü	28
Resim 6. 1. Arborio pirinç resimleri	74
Resim 6. 2. Basmati pirinç resimleri.....	74
Resim 6. 3. İpsala pirinç resimleri	74
Resim 6. 4 Jasmine pirinç resimleri	75
Resim 6. 5 Karacadağ pirinç resimleri.....	75

SİMGELER VE KISALTMALAR DİZİNİ

Bu çalışmada kullanılmış bazı simgeler ve kısaltmalar, yanda açıklamaları verilmek üzere aşağıda listelenmiştir.

Simgeler

Açıklama

f	Fonksiyon
x, y	Eşitlik değişkenleri
T	Zaman
A, B	Veri kümeleri
$\ominus$	Aşınma işlemi
$\emptyset$	Boş küme
$\oplus$	Genleşme işlemi
$\circ$	Açma işlemi
$\cdot$	Kapama işlemi

Kısaltmalar

Açıklama

A	Alan
AUC	ROC eğrisi altındaki alan
CNN	Evrişimsel sinir ağlar
DL	Derin öğrenme
DNN	Derin sinir ağı
ESA	Evrişimsel sinir ağları
FPR	Yanlış olasılık oranı
GPU	Grafik işlem birimi
HSV	Renk tonu, doygunluk, parlaklık

ICAP	Bilgi kuramı özellik seçimi yönetimi
PCA	Temel bileşenler analizi
RGB	Kırmızı, yeşil, mavi renkler
ROC	Alıcı işletim karakteristiği
TP	Toplam piksel sayısı
TPR	Doğru olasılık oranı
YZ	Yapay zekâ



1. GİRİŞ

Pirinç, dünya genelinde milyonlarca insanın temel gıda kaynağını oluşturan stratejik bir tarım ürünüdür. Üretim süreci, kalite değerlendirmesi ve çeşit farklılıkları, gıda güvenliği ve ekonomisi açısından önemli unsurlar arasında yer almaktadır. Pirincin tür ve kalite açısından sınıflandırılması, tüketicilere kaliteli ürün sunmak ve tarım sektöründeki verimliliği artırmak açısından kritik bir aşamadır. Ancak geleneksel sınıflandırma yöntemleri, uzman gözlemine dayalı manuel işlemler içerdiğinden zaman alıcı olmakta ve doğruluk oranı beklenen düzeye ulaşamamaktadır. Bu nedenle, pirinç sınıflandırma sürecinde otomasyonun sağlanması, doğruluğun artırılması ve insan hatasının azaltılması amacıyla yeni teknolojilere ihtiyaç duyulmaktadır (Xia vd., 2025; Wang vd., 2025).

Son yıllarda, derin öğrenme (deep learning) teknikleri, görüntü işleme ve sınıflandırma uygulamalarında kayda değer başarılar elde etmiştir. Derin öğrenme tabanlı yöntemler, özellikle karmaşık ve büyük veri setlerinde yüksek doğruluk oranları sağlaması nedeniyle gıda ürünlerinin sınıflandırılması gibi alanlarda yaygın olarak tercih edilmektedir. Derin öğrenme algoritmaları, pirinç gibi tarım ürünlerinin görüntülerini analiz ederek tür ve kalite farklarını başarılı bir şekilde sınıflandırabilme potansiyeline sahiptir. Bu bağlamda, derin öğrenme yöntemlerinin pirinç sınıflandırma sürecine uygulanması, geleneksel yöntemlere kıyasla önemli avantajlar sunmaktadır. (Koklu vd.,2021; Abuelelwa ve Abu-Naser, 2024). Bu çalışmanın amacı, pirinç türlerini farklı derin öğrenme teknikleri kullanarak sınıflandırmaktır. Çalışmada, farklı pirinç türlerinin ve kalite derecelerinin belirlenmesinde derin öğrenme tabanlı bir model geliştirilmesi ve bu modelin iyileştirilmesi hedeflenmektedir. Bunun için Evrişimsel Sinir Ağları (CNN) gibi yaygın olarak kullanılan derin öğrenme mimarilerinden yararlanılacaktır. Bu yöntem, pirinç tanelerinin renk, büyüklük, doku gibi görsel özelliklerini öğrenerek farklı türlerin ve kalite düzeylerinin doğru şekilde ayırt edilmesine olanak tanımaktadır. Çalışma sonucunda, derin öğrenme tekniklerinin pirinç sınıflandırmasında geleneksel yöntemlere göre daha hızlı, güvenilir ve düşük maliyetli çözümler sunduğu gösterilecektir. Ayrıca, mevcut ve önerilen yöntemlerin doğruluk oranı, hız ve pratik kullanım kolaylığı gibi performans ölçütleri bakımından avantajları ve sınırlılıkları incelenecek, elde edilen bulgular değerlendirilerek gelecek çalışmalar için öneriler sunulacaktır.

2. GENEL BİLGİLER

Pirinç çeltik bitkisinden elde edilmektedir. Pirinçteki nişasta oranı oldukça yüksektir. Pirinç yalnızca besin maddesi olarak değil aynı zamanda sanayi alanında da yaygın kullanıma sahiptir (Çınar, 2019). Bu bölümde pirincin önemi, çeşitleri, sınıflandırılması ve yapılan derin öğrenme çalışmalarına yer verilmiştir.

2.1. Pirincin Küresel Beslenme Sistemindeki Rolü ve Ekonomik Önemi


Pirinç (*Oryza sativa*), dünya genelinde temel bir gıda kaynağı olup milyarlarca insanın günlük beslenmesinde önemli bir rol oynamaktadır (Resim 2.1). Küresel tahıl üretiminde mısır ve buğday ile birlikte ilk sıralarda yer alan pirinç, özellikle Asya, Afrika ve Latin Amerika'daki gelişmekte olan ülkelerde temel besin kaynağı olarak kabul edilmektedir (Harita 2.1). Pirinç, dünya çapında üretilen toplam tahılın yaklaşık %20'sini oluşturarak 3,5 milyar insan için kalori alımının en büyük kaynağını temsil etmektedir (Khush, 2013). Pirincin beslenme sistemindeki önemi, içerdiği karbonhidrat, lif, vitamin ve mineraller sayesinde temel enerji ve besin kaynağı sunmasından kaynaklanmaktadır (Fitzgerald vd., 2009).



Resim 2. 1. Genel pirinç görüntüsü

Özellikle Asya ülkelerinde pirinç, günlük kalori alımının yaklaşık %60'ını sağlamaktadır. Örneğin, Bangladeş, Kamboçya ve Vietnam gibi ülkelerde kişi başına pirinç tüketimi yıllık 150 kg seviyelerindedir. Japonya, Çin, Hindistan gibi kalabalık nüfuslu ülkelerde ise pirinç, ülke ekonomisinin tarımsal üretiminde merkezi bir yere sahiptir. Ayrıca pirinç

üretimi ve ticareti, bu ülkelerin tarımsal iş gücünün büyük bir kısmını oluşturmakta ve kırsal ekonominin temel taşını oluşturmaktadır (Mohanty, 2013). Pirinç yetiştiriciliği, aynı zamanda iklim değişikliği gibi çevresel faktörlerden etkilendiği için, sürdürülebilir üretim yöntemleri geliştirmek ve bu üretimin devamını sağlamak, küresel gıda güvenliği açısından da büyük önem taşımaktadır (Sahrawat, 2005).



Harita 2. 1. Dünya genelinde pirinç üretimi haritası (AtlasBig, b.t)


Ekonomik açıdan, pirinç, birçok ülke için önemli bir ihracat kalemi olarak da dikkat çekmektedir. Örneğin, Tayland ve Vietnam gibi ülkeler, dünya pirinç pazarında önemli ihracatçılar arasında yer almakta ve ekonomik kalkınmada pirincin rolü büyüktür. Pirinç ihracatı, Tayland'ın tarım sektöründe önemli bir döviz kaynağı sağlamaktadır. Küresel pirinç ticareti, pirinç arz ve talep dengesine, uluslararası fiyat dalgalanmalarına ve iklim koşullarına bağlı olarak değişkenlik göstermektedir (Muthayya vd., 2014). İklim değişikliği ve su kaynaklarının azalması gibi etmenler, pirinç üretiminde sürdürülebilirliği tehlikeye sokmakta ve pirinç fiyatlarını etkilemektedir (Rezvi vd., 2023).

Küresel ekonomik sistemde pirinç hem iç tüketimdeki yüksek talep hem de uluslararası ticaretteki yoğun işlem hacmi ile stratejik bir ürün olarak kabul edilmektedir. Pirinç üretiminde yaşanan herhangi bir azalma, pirinç ithalatına bağımlı olan ülkelerde ciddi ekonomik ve toplumsal sorunlara yol açabilmektedir. 2007-2008 yıllarında yaşanan küresel gıda krizi sırasında pirinç fiyatlarının aşırı artması, özellikle gelişmekte olan ülkelerdeki yoksul kesimlerin gıda güvenliğini tehdit etmiş ve bu durum, uluslararası ticarete pirincin

stratejik önemini bir kez daha gözler önüne sermiştir (Dawe, 2012). Bu nedenle pirinç üretiminin sürdürülebilirliğini sağlamak ve küresel piyasalardaki arz-talep dengesini korumak, dünya ekonomisi ve toplumsal denge açısından kritik öneme sahiptir. Aynı zamanda pirinç üretimi kırsal kalkınma, iş gücü ve uluslararası ticaret açısından da önem taşımaktadır.

2.2. Türkiye’de Pirincin Ekonomik ve Beslenme Açısından Önemi

Pirinç, dünya genelinde olduğu gibi Türkiye’de de önemli bir temel gıda maddesi ve stratejik bir tarım ürünüdür. Türkiye'nin iklim ve toprak koşulları, yerli pirinç çeşitlerinin yetiştirilmesine elverişli olmakla birlikte, farklı iklimlere adapte olmuş ithal pirinç çeşitlerinin de geniş bir tüketici kitlesine ulaşmasına olanak tanımaktadır. Pirinç üretimi, ülkenin gıda güvenliği politikaları ve ekonomik dengesi açısından kritik bir rol oynar. Bu nedenle, pirinç sektörünün gelişimi ve yerli üretimin teşvik edilmesi Türkiye’nin tarımsal kalkınması için önemli bir alan olarak öne çıkmaktadır (Arslan, 2022). Türkiye’de tarım sektörü, milli gelirin önemli bir parçasını oluşturur ve istihdam açısından geniş bir kesimi içine alır. Pirinç üretimi, özellikle kırsal alanlarda yaşayan çiftçilerin geçim kaynağını oluşturarak tarımsal istihdamı destekler (Özçelebi ve Yılmaz, 2020). Türkiye'nin en çok pirinç ürettiği bölgeler arasında Trakya, Güneydoğu Anadolu ve Karadeniz bölgeleri yer almakta olup, bu bölgelerdeki çiftçiler için pirinç, başlıca ekonomik gelir kaynağıdır (Harita 2.2). Örneğin, İpsala pirinci olarak bilinen yerli çeşit, sadece yurt içinde değil, yurt dışında da büyük talep görmektedir ve Türkiye'nin pirinç ihracatında önemli bir yer tutmaktadır (Avkırın ve Yılmaz 2023).



Harita 2. 2. Türkiye’de pirinç üretimi haritası (Coğrafya Hocası, 2021)

Pirincin ülke ekonomisine sağladığı katkılardan biri de ithalat ve ihracat dengesidir. Türkiye, pirinç talebinin büyük bir kısmını yerli üretimle karşılamakla birlikte, talebi karşılamak için bazı dönemlerde ithalat yapmak zorunda kalmaktadır. Bu durum, pirinç ithalatı üzerindeki maliyetlerin ve döviz harcamalarının ülke ekonomisine etkisini ortaya koymaktadır. Özellikle yerli üretimin artırılması yoluyla bu ithalatın azaltılması, Türkiye'nin dış ticaret dengesine katkı sağlayabilir ve döviz çıkışını önleyebilir. Türkiye'nin tarım politikaları, yerli üreticiyi destekleme ve verimliliği artırma amacıyla pirinç üretiminde modern tekniklerin kullanımını teşvik etmektedir (Tarım ve Orman Bakanlığı, 2023).

Pirinç, yüksek karbonhidrat içeriği nedeniyle enerji sağlayan bir gıda kaynağı olarak önemli bir rol oynamaktadır. Türkiye'de pirinç, geleneksel mutfakın vazgeçilmez unsurlarından biridir ve her yaş grubunun tükettiği bir besin maddesi olarak öne çıkar. Özellikle pilav gibi geleneksel yemeklerde sıkça kullanılan pirinç, yüksek enerji değeri ve düşük yağ içeriğiyle sağlıklı bir diyetin parçası olarak kabul edilmektedir. Pirincin beslenme açısından önemi, gıda güvenliği politikalarında da kendini göstermektedir. Gıda güvenliği, tüm dünya ülkelerinde olduğu gibi Türkiye'de de ulusal öncelikler arasında yer almakta ve temel gıda maddelerinin erişilebilirliğini garanti altına almak amacıyla çeşitli stratejiler uygulanmaktadır. Türkiye'nin pirinç üretimi, gıda güvenliği açısından stratejik bir role sahiptir; özellikle pandemi ve küresel kriz dönemlerinde bu tür gıda maddelerinin yerel olarak temin edilmesi büyük önem kazanmıştır. İthalata olan bağımlılığı azaltma hedefi doğrultusunda, pirinç gibi temel gıda maddelerinde sürdürülebilir üretim yöntemlerinin kullanılması, gıda güvenliği açısından kritik bir unsur olarak değerlendirilmektedir (Mohidem vd.,2022).

2.3. Farklı Pirinç Türleri

Dünya genelinde pirinç, yetiştiği iklim koşulları ve genetik özellikleri doğrultusunda farklı türlere ayrılmaktadır (Resim 2.2). Pirinç türlerinin tat, aroma, tane uzunluğu ve yapısal özellikleri gibi farklılıkları hem yerel hem de uluslararası pazarda önem taşır. Yaygın olarak bilinen bazı pirinç türleri arasından bu çalışmada Karacadağ, Basmati, Jasmine, İpsala ve Arborio gibi çeşitler yer almaktadır. Bu türlerin her biri, farklı damak tatlarına hitap eden karakteristik özelliklere sahip olup, çeşitli kültürlerde önemli bir yere sahiptir.



Resim 2. 2. Farklı pirinç türleri

2.3.1. Karacadağ pirinci


Karacadağ pirinci, Türkiye'nin Güneydoğu Anadolu Bölgesi'nde, özellikle Şanlıurfa ilinde Karacadağ bölgesinde yetiştirilen bir türdür (Resim 2.3). Geleneksel tarım yöntemleriyle, tamamen doğal koşullarda yetiştirilen Karacadağ pirinci, dayanıklı yapısı ve aromatik tadı ile tanınır. Taneleri kısa ve yuvarlaktır, pişirildiğinde birbirine yapışma eğilimindedir. Geleneksel mutfaklarda oldukça tercih edilen Karacadağ pirinci, bu özelliği nedeniyle pilav gibi yemeklerde kullanıma uygundur. Ayrıca, mineral ve vitamin içeriği yüksek olduğu için sağlıklı bir seçenek olarak öne çıkmaktadır (Kahraman vd., 2021).



Resim 2. 3. Karacadağ pirinç örnekleri

2.3.2. Basmati pirinci


Basmati pirinci, Hindistan ve Pakistan'ın kuzey kesimlerinde yetiştirilen, uzun taneli ve aromatik bir türdür (Resim 2.4). Basmati, Sanskritçe kökenli bir kelime olup "aromatik" anlamına gelir ve bu özellik pirinci dünya çapında popüler hale getirmiştir. Basmati pirinci piştiğinde tane uzunluğunun neredeyse iki katına çıkmasıyla dikkat çeker. Kuru, ince ve uzun yapılı bir pirinç olduğu için pişirme sonrası dağılmadan kalabilmesi, özellikle Hint mutfağında tercih edilmesini sağlar. Düşük glisemik indeks oranı nedeniyle diyabet hastaları tarafından da tercih edildiğinden Basmati, sağlıklı beslenme açısından önem taşır (Bharathi vd., 2024).



Resim 2. 4. Basmati pirinç örnekleri

2.3.3. Jasmine pirinci

Jasmine pirinci, Tayland'a özgü, orta uzunlukta, ince yapılı ve karakteristik bir aromaya sahip bir türdür (Resim 2.5). Pirinç taneleri pişirildiğinde hafif yapışkan bir yapı kazanır ve çiçeksi bir koku yayar. Jasmine pirinci, bu özellikleriyle Güneydoğu Asya mutfağında özellikle Thai yemekleri için yaygın olarak kullanılmaktadır. Beyaz ve kahverengi çeşitleri bulunan Jasmine pirinci, yüksek oranda karbonhidrat içeriğine sahip olup enerji verici bir besindir. Özellikle kahverengi Jasmine pirinci, kepekli yapısıyla lif oranı yüksek bir seçenek olarak sağlıklı diyetlerde tercih edilmektedir (Juliano ve Villareal, 1993).



Resim 2. 5. Jasmine pirinç örnekleri

2.3.4. İpsala pirinci

Türkiye'nin Edirne ilinde, İpsala ilçesinde yetiştirilen İpsala pirinci, kendine özgü tadı ve kalitesiyle tanınır (Resim 2.6). Genellikle iri taneli ve yüksek su emme kapasitesine sahip olan İpsala pirinci, Türkiye'nin önemli pirinç çeşitlerinden biridir. Düşük nişasta içeriği sayesinde pişirildiğinde tane tane kalır ve pilav gibi yemeklerde dağılmadan kalabilme özelliği taşır. İpsala bölgesindeki sulak alanlar, pirinç tarımı için ideal koşulları sağlamaktadır ve bu durum İpsala pirincinin kaliteli bir ürün olarak öne çıkmasını sağlamaktadır (Şener vd., 2017).



Resim 2. 6. İpsala pirinç örnekleri

2.3.5. Arborio pirinci

Arborio pirinci, adını İtalya'nın Piyemonte bölgesindeki Arborio kasabasından alan, kısa taneli ve yüksek nişasta içeriğine sahip bir pirinç çeşididir (Resim 2.7). Pişirildiğinde kremamsı bir doku kazanır ve bu özelliğiyle özellikle risotto yapımında tercih edilir (Wilkinson ve Champagne, 2004). Geleneksel olarak İtalya'nın Po Vadisi'nde yetiştirilen Arborio pirinci, günümüzde ABD'nin Kaliforniya ve Teksas eyaletlerinde de üretilmektedir (Wikipedia, b.t)



Resim 2. 7. Arborio pirinç örnekleri

2.4. Pirinçte Kalite Sınıflandırması

Pirinç türlerinin değerlendirilmesinde kalite sınıflandırması büyük önem taşır. Kalite sınıflandırması, pirinç tanelerinin fiziksel, kimyasal ve duyuşal özelliklerine göre yapılır. Pirinç kalite sınıflandırmasında tane uzunluğu, renk, sertlik, aroma ve yapışkanlık gibi faktörler dikkate alınır. Örneğin, uzun taneli pirinçler, yüksek kaliteli ve aromatik olarak değerlendirilirken, kısa taneli ve yapışkan pirinçler daha çok yerel kullanıma uygundur. Ayrıca, pirincin nişasta yapısı, su emme kapasitesi ve pişirme sonrası dokusu, kalite sınıflandırmasında belirleyici faktörler arasındadır (Fitzgerald vd., 2009).

Tüketici tercihleri, pirinç türünün kalitesini doğrudan etkileyen önemli bir etkidir. Gelişmiş pazarlarda, uzun taneli ve düşük yapışkanlık oranına sahip pirinçler, genellikle daha yüksek kalite olarak kabul edilirken; Asya ve Güney Amerika gibi bölgelerde ise kısa

taneli ve yapışkan pirinçler geleneksel mutfak kültürü ile uyumlu oldukları için tercih edilir. Kalite sınıflandırması ayrıca, pirinç üreticilerinin ürünlerini uluslararası pazara sunarken uygun fiyatlandırma yapabilmesi açısından da kritik öneme sahiptir (Juliano ve Villareal, 1993).

2.5. Geleneksel Sınıflandırma Yöntemleri ve Yetersizliği

Geleneksel pirinç sınıflandırma yöntemleri, genellikle görsel incelemeye, el ile yapılan ayıklama işlemlerine ve bazı kimyasal testlere dayanır. Tarım ürünlerinin sınıflandırılması, gıda endüstrisi, kalite kontrol süreçleri ve pazar taleplerine uygun ürün sunumu açısından kritik bir rol oynar. Pirinç gibi geniş tüketici kitlelerine hitap eden temel tarım ürünlerinde, kalite sınıflandırması ürün fiyatlarını belirlemek ve tüketici taleplerine uyum sağlamak için büyük önem taşır. Geleneksel sınıflandırma yöntemleri, birçok durumda hala manuel işlemler ve insan gözlemi ile yapılmaktadır. Manuel işlemler, insan hatası ve zaman alıcı süreçler gibi faktörler, geleneksel sınıflandırma yöntemlerini modern ihtiyaçlara yanıt vermede yetersiz kılmaktadır (Alzubaidi vd., 2021; Gopalakrishnan ve Vivek, 2022; Paliwal vd., 2015). Ancak, teknolojinin hızla geliştiği bir dünyada bu yöntemlerin yetersiz kaldığı açıkça görülmektedir.

Bir diğer geleneksel yöntem, pirinç tanelerinin fiziksel özelliklerine dayalı olan ayırıştırma teknikleridir. Bunlar arasında, pirinç tanelerinin büyüklüğünü, şekil ve renk farklarını inceleyen mekanik sınıflandırıcılar yer alır. Ancak, bu sistemler sadece sınırlı özellikleri analiz edebilir ve bu nedenle karmaşık sınıflandırma gereksinimlerini karşılayamaz. Özellikle, pirinç tanelerindeki ince kalite farklarını ve tür çeşitliliklerini ayırt etmek zordur (Singh ve Chaudhury, 2016). Geleneksel yöntemlerin sınırlamaları, derin öğrenme tekniklerinin kullanılmasının gerekliliğini ortaya koymuştur.

Ayrıca, büyük hacimli tarım ürünlerinde, manuel işlemlerle sınıflandırma yapılması, üretim sürecini yavaşlatır ve pazar talebine hızlı yanıt verememeye yol açar. Bu durum, uluslararası pazarda rekabet avantajını da olumsuz etkiler. Teknolojinin ilerlemesiyle birlikte, otomatik sınıflandırma sistemlerinin bu süreci hızlandırma potansiyeli büyük bir avantaj sunmaktadır (Özdal, 2023). Örneğin, Tayland ve Vietnam gibi pirinç ihracatçısı ülkelerde, hızlı ve doğru sınıflandırma yapmak için teknolojik sınıflandırma yöntemlerine geçiş hızlanmıştır (Pathare vd., 2013).

Geleneksel sınıflandırma yöntemlerinde insan gözlemi esastır; bu ise bireyler arasında gözle görülür hatalara neden olabilir. İnsan hataları, görsel olarak yapılan sınıflandırma işlemlerinde oldukça yaygındır ve bu hatalar, ürün kalitesinin tutarlı bir şekilde sınıflandırılmasını zorlaştırır. Gözle yapılan değerlendirmeler, özellikle uzun süreli çalışmalarda çalışanların dikkat seviyelerinin azalmasına bağlı olarak hem yanlış sınıflandırmaların yapılmasına hem de verim kaybına neden olabilir. Araştırmalar, manuel sınıflandırma sürecinde farklı operatörlerin aynı ürünleri farklı sınıflandırma eğiliminde olduğunu, bu durumun ise kalite kontrol süreçlerinde tutarsızlığa yol açtığını ortaya koymaktadır (Çam vd., 2022).

İnsan gözlemiyle yapılan sınıflandırma, ayrıca operatörün bilgi birikimi, deneyimi ve fiziksel durumu gibi birçok faktörden etkilenir. Dolayısıyla, her bir operatörün farklı değerlendirme yapması, ürünlerin standart bir kalite seviyesi altında piyasaya sunulmasını zorlaştırır. Örneğin, pirinç tanelerinin rengi veya boyutunun belirlenmesi gibi faktörlerde, operatörler arasında farklı algılar oluşabilir ve bu da tüketici memnuniyetini olumsuz etkileyebilir. Ayrıca, insan hatasına bağlı olarak yanlış sınıflandırılan ürünler, şirketlerin maliyetlerini artırarak ekonomik kayıplara yol açabilir (Paliwal vd., 2001).

Geleneksel sınıflandırma yöntemleri, zaman alıcı ve verimliliği düşük süreçler içerir. Özellikle büyük hacimli ürünlerde, manuel sınıflandırma işlemi, saatler hatta günler sürebilir. Tarım ve gıda endüstrisi gibi hızlı ve kesintisiz üretimin önemli olduğu sektörlerde, bu kadar uzun süren işlemler kabul edilemez hale gelmektedir. Teknolojinin sınırlı olduğu durumlarda, zaman alıcı işlemler üretim sürecini yavaşlatmakta ve işletme maliyetlerini artırmaktadır. Özellikle sezonluk tarım ürünlerinde, sınıflandırma işleminin gecikmesi, ürünlerin kalite kaybına uğramasına ve bozulmasına yol açabilir (Gupta ve Rani, 2019).

2.6. Modern Çözümler ve Otomatik Sınıflandırma

Geleneksel yöntemlerin dezavantajları, tarım ürünlerinin sınıflandırılmasında otomatik sistemlere geçişi hızlandırmıştır. Görüntü işleme ve derin öğrenme gibi teknolojiler, tarım ürünlerinin daha hızlı ve doğru bir şekilde sınıflandırılmasına imkân tanır. Bu teknolojiler, insan hatalarını en aza indirerek, büyük hacimli tarım ürünlerinde yüksek doğruluk oranları sunar. Örneğin, Evrişimsel Sinir Ağı (CNN) gibi derin öğrenme teknikleri, pirinç gibi tahıl

ürünlerinin renk, boyut ve yapı gibi özelliklerine göre hızlı ve doğru bir şekilde sınıflandırılmasına olanak tanır. Farklı pirinç çeşitlerinin sınıflandırılması ile ilgili CNN modeli çalışmada %100 doğruluk oranı ile en başarılı sonuçları elde etmiştir. Bu da üretim süreçlerinde verimliliği artırarak, üreticilere zaman ve maliyet tasarrufu sağlar (Köklü vd, 2021; Çınar, 2019). Ayrıca lojistik sektöründe geliştirilen mobil yazılımlar sayesinde, müşteri taleplerine hızlı, ekonomik ve güvenilir çözümler sunularak süreçlerin dijitalleşmesi sağlanmıştır (Cizmeci ve Altun, 2023).

Türkiye’de de pirinç üretimini artırmak amacıyla modern tarım teknolojilerinin kullanılması ve yerel çeşitleri koruma stratejilerinin geliştirilmesi hem ekonomik bağımsızlık hem de gıda güvenliği açısından büyük avantajlar sunacaktır. Bu nedenle, pirinç üretiminde kalite ve verimliliği artırmaya yönelik çalışmaların devam etmesi, ülke tarımının geleceği için önemli bir adım olacaktır (Beşer ve Sürek, 2012). Özellikle son yıllarda pirinç sınıflandırma işlemleri için derin öğrenme ve Yapay Zekâ (YZ) tabanlı yöntemler büyük bir potansiyel taşımaktadır. (Cinar ve Koklu, 2022).

2.7. Derin Öğrenme ile Pirinç Sınıflandırma

Derin öğrenme, yapay zekanın bir alt dalı olup, çok katmanlı yapılarla karmaşık verileri modelleme yeteneği sağlar. Derin öğrenme, özellikle büyük veri setlerini işlemek, örüntüleri tanımak ve sınıflandırmak için güçlü bir araçtır.

Son yıllarda, derin öğrenme tabanlı pirinç sınıflandırma sistemleri, tarım sektörü ve gıda endüstrisi için büyük bir yenilik oluşturmuştur (Hoang vd., 2020). Bu tür sistemler, pirinç tanelerinin çeşitli kalite düzeylerini, çeşitlerini ve hatta hastalık belirtilerini doğru şekilde tespit edebilir. Bu, geleneksel yöntemlerle karşılaşılan sınıflandırma hatalarını en aza indirmekte ve sınıflandırma sürecini hızlandırmaktadır (Xia vd., 2025).

Birçok çalışma, derin öğrenme tekniklerinin pirinç tanelerinin tür ve kalite sınıflandırmalarında üstün başarılar sağladığını göstermektedir. Özellikle, CNN tabanlı sistemlerin yüksek doğruluk oranlarına sahip olması, bu yöntemlerin tarım ürünleri üzerinde uygulanabilirliğini artırmaktadır (Saddami vd., 2024).

Örneğin, Yakkundimath vd. tarafından yapılan bir çalışmada, pirinç hastalıklarının tespiti ve sınıflandırması için CNN tabanlı bir model kullanılmış ve %92,24'ün üzerinde doğruluk oranı elde edilmiştir (Yakkundimath vd. 2022). Benzer şekilde, Din vd tarafından geliştirilen bir derin öğrenme modeli, pirinç tanelerinin türünü sınıflandırırken %100 e yakın doğruluk oranına ulaşmıştır (Din vd 2024). Harmancı vd, fındık türlerinin tespitinde CNN modellerini kullanarak yüksek bir doğruluk oranına ulaşmıştır (Harmancı vd. 2023). Yine Unal vd kahve çekirdeğinin türlerinin tespitinde evrimsel sinir ağları modellerini kullanmış ve çok yüksek doğruluk oranlarına ulaşmıştır (Unal vd 2022). Bu tür başarılar, derin öğrenme tekniklerinin, pirinç ürünlerinin doğru bir şekilde sınıflandırılmasında geleneksel yöntemlere kıyasla çok daha etkili olduğunu göstermektedir. Benzer şekilde, Bükücü tarafından geliştirilen bir gömülü sistem, üretim sırasında cam yüzeylerdeki hataları otomatik olarak tespit edebilmekte ve bu sayede manuel denetime duyulan ihtiyacı azaltmaktadır. Bu çalışma, görüntü işleme ve makine öğrenmesi tabanlı sınıflandırıcıların üretim süreçlerindeki etkinliğini göstermektedir (Bükücü 2021). Pirinç sınıflandırması gibi tarım ürünleri kalite kontrol uygulamalarında da benzer yöntemlerin kullanılması, doğruluk oranlarını artırmakta ve süreçleri otomatikleştirmektedir.

Pirinç tanelerinin kaliteye göre ayrılması, gıda güvenliğini sağlamak ve tüketiciye en iyi ürünü sunmak için kritik bir adımdır. Derin öğrenme teknikleri, kaliteyi belirleyen çok çeşitli faktörleri analiz ederek daha hassas sınıflandırmalar yapabilmektedir (Son ve Thai-Nghe, 2019). Pirinç ürünlerinin derin öğrenme teknikleri ile sınıflandırılması, gıda sektörü ve tarım endüstrisi için devrim niteliğinde bir yeniliktir. Ancak, bu yöntemlerin uygulanabilirliği ve etkinliği ile ilgili bazı zorluklar da bulunmaktadır. Özellikle, büyük veri setlerinin toplanması ve etiketlenmesi, derin öğrenme modellerinin doğru bir şekilde eğitilmesi için kritik bir adımdır. Ayrıca, derin öğrenme modellerinin büyük miktarda işlem gücü gerektirmesi ve karmaşık altyapılarının olması, pratikte zorluklar oluşturabilir (Yusuf vd.,2024).

Bununla birlikte, bu zorluklar, derin öğrenme yöntemlerinin daha verimli hale gelmesiyle aşılabılır. Örneğin, daha hızlı hesaplama gücüne sahip donanımlar ve daha optimize edilmiş algoritmalar, bu tekniklerin pratikte daha yaygın kullanılmasını sağlayabilir. Ayrıca, veri etiketleme sürecinde otomasyonun artırılması, derin öğrenme modellerinin daha doğru ve verimli çalışmasına olanak tanıyacaktır (Chen, Z., 2023).

Pirincin yapay zekâ ve derin öğrenme yöntemleriyle sınıflandırılması üzerine yapılan çalışmalar, tarım ürünlerinin otomasyonu ve kalite değerlendirilmesinde önemli bir yere sahiptir. Mevcut bazı akademik çalışmalar şu şekilde özetlenebilir:

Kuo ve arkadaşları, pirinç tanelerinin kalite sınıflandırması için görüntü işleme yöntemleri kullanmıştır. Çalışmalarında, pirinç tanelerinin fiziksel özelliklerini (uzunluk, genişlik, renk) çıkararak makine öğrenmesi algoritmaları ile sınıflandırma yapmışlardır (Kuo vd., 2016).

Silva ve Sonnadara, CNN tabanlı bir model kullanarak farklı pirinç türlerini sınıflandırmıştır. Çalışmalarında, pirinç tanelerinin görüntülerini analiz eden bir model geliştirilmiş ve %95'in üzerinde doğruluk oranı elde edilmiştir (Silva ve Sonnadara, 2013).

Kambo ve Yerpude, Basmati pirinç tanelerinin sınıflandırılması için görüntü işleme ve ana bileşen analizi (PCA) yöntemlerini kullanmıştır. Makine öğrenmesi algoritmaları ile yapılan sınıflandırmada yüksek doğruluk oranları elde edilmiştir (Kambo ve Yerpude, 2014).

Koklu ve arkadaşları pirinç tanelerinin sınıflandırılmasında hibrit bir yaklaşım kullanarak hem görüntü işleme hem de derin öğrenme tekniklerini bir araya getirmiştir. Bu çalışmada, önce temel morfolojik ve renk özellikleri çıkarılmış, ardından bu özellikler evrimsel sinir ağı modelleri ile analiz edilmiştir. Elde edilen sonuçlar, hibrit yaklaşımın sınıflandırma doğruluğunu artırarak yüksek başarı oranlarına ulaştığını göstermektedir (Koklu vd, 2021).

Sağlam ve Oy, güneş enerjisi sistemlerinin izlenmesi ve optimizasyonu sürecinde görüntü verilerinden anlamlı sonuçlar elde etmek amacıyla veri işleme tekniklerinden yararlanmıştır (Sağlam ve Oy 2024). Elde edilen bu veriler derin öğrenme modelleri ile daha anlamlı hale getirilebilir. Eğitim alanında yapılan çalışmalar, teknolojik araçların ve yenilikçi yaklaşımların bilişsel süreçler üzerindeki etkisini vurgulamaktadır. Örneğin, Erdal tarafından yürütülen çalışmada, ters yüz sınıf uygulamalarının öğrencilerin bilişsel aktivitelerini olumlu yönde etkilediği ve öğrencilerin özellikle açık uçlu cevap verme gibi yapılandırmacı katılım düzeylerinde daha aktif hale geldikleri gözlemlenmiştir (Erdal, 2022). Bu durum, derin öğrenme yöntemlerinin yalnızca tarım ürünlerinin sınıflandırılmasında değil, aynı zamanda enerji sistemlerinin izlenmesi ve eğitim ortamları

gibi farklı alanlarda da etkin biçimde kullanılabildiğini ve bu tekniklerin uygulama çeşitliliğini ortaya koymaktadır.

2.8. Yöntemlerin Karşılaştırılması

Çeşitli çalışmalar, derin öğrenme yöntemlerinin, geleneksel makine öğrenmesi ve görüntü işleme yöntemlerine kıyasla daha üstün performans sergilediğini ortaya koymuştur. Yine de makine öğrenmesi ile yapılan sınıflandırmalar sıklıkla kullanılmaktadır. Makine öğrenimi algoritmaları kullanarak pirinç çeşitlerinin tanımlanması ve hangi algoritmaların en iyi sonuçları verdiği ile ilgili çalışmalar bulunmaktadır (Cinar ve Koklu, 2022). Tüm bunlara rağmen derin öğrenme tabanlı yöntemler, büyük veri setleri ile çalışırken daha yüksek doğruluk ve genelleme kapasitesine sahiptir (Bhattacharjee, 2024). Bununla birlikte, derin öğrenme algoritmalarının eğitimi için güçlü donanım gereksinimleri ve yüksek işlem maliyetleri, bu yöntemlerin dezavantajları arasında yer alır. Aşağıdaki Çizelge 2.1, farklı yöntemlerin karşılaştırmasını sunmaktadır.

Çizelge 2. 1. Yöntemlerin karşılaştırılması

Yöntem	Doğruluk Oranı	Hız	Maliyet
Görüntü İşleme	Orta	Yüksek	Düşük
Makine Öğrenmesi	Orta	Orta	Orta
Derin Öğrenme (CNN)	Yüksek	Düşük	Yüksek
Transfer Öğrenimi	Çok Yüksek	Orta	Orta


Sonuç olarak; pirincin tür ve kalite sınıflandırılmasında yapay zekâ ve derin öğrenme yöntemlerinin kullanımı, geleneksel yöntemlere göre önemli avantajlar sunmaktadır. Özellikle, CNN tabanlı modellerin yüksek doğruluk oranları ile sınıflandırma yapması, tarım sektöründe otomasyonu artırmaktadır. Mevcut literatür, derin öğrenme tekniklerinin yalnızca sınıflandırma doğruluğunu artırmakla kalmadığını, aynı zamanda işlem hızını ve verimliliğini de yükselttiğini göstermektedir. Gelecekteki çalışmalar, hibrit yaklaşımlar ve transfer öğrenimi gibi yöntemlerin daha geniş çapta uygulanması ile pirinç sınıflandırmasının daha verimli hale getirilmesini amaçlamaktadır. Ayrıca, yerel pirinç türlerinin sınıflandırılması üzerine yapılan çalışmaların artırılması, Türkiye gibi tarım merkezli ülkelerde sektörel kalkınmaya önemli katkılar sağlayacaktır.

3.GÖRÜNTÜ İŞLEME

Görüntü işleme, görsel verilerin analiz edilmesi ve işlenmesi amacıyla gerçekleştirilen bir dizi teknik ve yöntemden oluşmaktadır. Süreç, görüntülerin elde edilmesiyle başlar ve bu görüntüler genellikle satır ve sütunlar halinde düzenlenmiş diziler veya matrisler biçimindedir. Görüntüleme cihazları, her piksel için parlaklık, renk veya yoğunluk gibi belirli özellikleri tanımlayan sayısal değerler üretir. Bu sayısal değerler, görüntüyü oluşturan piksellerin dikey ve yatay konumlarına karşılık gelen bir dizi matris biçiminde düzenlenir. Görüntü işlemede ilk olarak görüntünün elde edilmesi gerekmektedir. İki boyutlu veya üç boyutlu bir sahnenin mekânsal temsili, "görüntü" olarak tanımlanır.

3.1. Dijital Görüntü ve Türleri

Sensörler aracılığıyla elde edilen ham görüntü verisinin dijital bir formata dönüştürülmesiyle dijital görüntü oluşur (Peker, 2009). Dijital görüntülerin elde edilme yöntemi, kullanılan görüntü kaynağına, algılayıcı sensörlere ve işleme yazılımına bağlı olarak farklılık göstermektedir. Her bir pikselin değeri, parlaklık düzeyi, renk tonu, yoğunluk gibi fiziksel özellikleri veya görüntü işleme teknikleri sonucunda sınıflandırılmış bir kategorik değeri temsil eder. Görüntüler, binlerce pikselin bir araya gelmesiyle oluşur ve bu piksellerin her biri, görüntünün temel yapı taşı oluşturur. Piksellerin içerdiği bilgiler, görüntü analizinin temelini oluşturmakta ve bu bilgiler, ileri görüntü işleme algoritmaları aracılığıyla daha karmaşık anlamlar çıkarmak için kullanılmaktadır. Bu süreç, Resim 3.1’de gösterilen bir örnek görüntü üzerinden açıklanabilir ve ilgili piksellerin mekânsal düzenlemeleri incelenerek detaylandırılabilir.



Resim 3. 1. Görüntü işleme (Simurg Ai Lab, 2020)

Dijital görüntüler, analog görüntülerin örneklenmesiyle oluşturulmakta ve sayısal formatlarda temsil edilmektedir (Pratt, 2007). Bu süreç, bir kamera veya sensör tarafından yakalanan görsel verinin analog sinyalden dijital bir yapıya dönüştürülmesiyle başlar (Altunay, 2012). Dijital görüntülerin temel bazı türleri vardır:

İkili görüntüler, her pikselin yalnızca iki olası değere sahip olduğu görüntülerdir. Genellikle 0 değeri siyahı, 1 veya 255 değeri ise beyazı temsil eder. Bu tür görüntüler, basit nesne algılama veya kenar tespiti gibi temel görüntü işleme uygulamalarında sıklıkla kullanılmaktadır. İkili görüntüler, veri boyutunu minimize ederek algoritmaların verimliliğini artırmaktadır.

Gri tonlamalı görüntüler, her pikseldeki ışık yoğunluğunu ifade eden tek renkli görüntülerdir. Bu görüntülerde, renk bilgisi yerine yalnızca parlaklık değerleri temsil edilmektedir. Gri tonlamalı görüntüler, görüntü işleme algoritmalarında yaygın bir şekilde kullanılmakta olup, özellikle desen tanıma, segmentasyon ve filtreleme gibi uygulamalar için uygun bir veri türüdür.

Renkli (RGB) görüntüler, genellikle kırmızı, yeşil ve mavi (RGB) renk kanallarını içeren çok kanallı görüntülerdir. Renkli görüntü işleme süreci, bu kanallar üzerinde çeşitli analizler ve işlemleri kapsamaktadır. Bu işlemler; renk düzeltme, renk filtreleme, renk bölütleme (segmentation) ve renk tabanlı nesne tanıma gibi uygulamalardan oluşur. Renkli görüntülerin işlenmesi, karmaşık sahnelerin detaylı analizini mümkün kılmaktadır.

Çok spektrumlu görüntüler, nesnelerin farklı spektrum bölgelerindeki yansımalarını inceleyerek görselleştirilmesini sağlar. İnsan gözünün algılayamadığı ancak spektral analizle tespit edilebilen bilgilerin elde edilmesi için kullanılan bu yöntem, özellikle savunma, uzaktan algılama ve tarım gibi alanlarda önemli bir avantaj sunmaktadır.


Görüntü işleminin avantajları ve kullanım alanları, uygulanan yöntem ve amaca bağlı olarak farklılık göstermektedir. Örneğin;

- *Tıp Alanında:* Röntgen, manyetik rezonans görüntüleme (MRI) gibi tekniklerle elde edilen görseller hastalıkların teşhisinde ve tedavi süreçlerinde analiz edilmektedir.

- Otomotiv Sektöründe: Görüntü işleme algoritmaları, otonom sürüş ve sürücü destek sistemlerinin geliştirilmesinde kritik bir rol oynamaktadır.
- Sanayi ve Üretim: Kalite kontrol ve otomasyon sistemlerinde hataların tespiti ve izlenmesi amacıyla kullanılmaktadır.
- Güvenlik Sistemleri: Yüz tanıma, hareket algılama ve nesne takip gibi uygulamalarda yaygın bir şekilde tercih edilmektedir (Ergin, 2024).

3.2. Görüntü İşleme Adımları

Görüntü işleme süreci, görüntülerin edinilmesiyle başlar. Bu ilk adımı, görüntü üzerinde çeşitli ön işleme tekniklerinin uygulanması izler. Ön işleme aşamaları genellikle gürültü azaltma, kontrast iyileştirme, parlaklık düzeltme ve kenar keskinleştirme gibi işlemleri içerir. Ardından, görüntüdeki önemli yapısal bilgilerin belirlenmesi amacıyla özellik çıkarımı ve görüntü tanıma aşamaları gerçekleştirilir. Bu adımlar, görüntüdeki nesnelerin veya karakteristik öğelerin tanımlanmasını sağlar. Sürecin son aşamasında ise, elde edilen veriler yorumlanarak görüntülerin anlamsal içeriği değerlendirilir (Santaş ve Gülesin, 2011). Şekil 3.1’de bu işlem basamakları görselleştirilmiştir.




Şekil 3. 1. Görüntü işleme adımları

Görüntü işleme teknikleri, yapay zekâ yöntemleriyle birleştirildiğinde, görüntüler üzerinde daha derinlemesine ve anlamlı analizler yapılmasına olanak tanır. Özellikle makine öğrenmesi ve derin öğrenme algoritmaları, büyük veri kümeleri üzerinde eğitilerek görüntülerdeki örüntüleri tanıma, nesneleri sınıflandırma ve belirli özellikleri otomatik olarak tespit etme yeteneği kazanır. Bu sayede, görüntü işleme süreçleri daha esnek, öğrenebilir ve uyarlanabilir hale gelir (Goodfellow vd., 2016).

Görüntü işleme süreçlerinde ön işleme, ham görüntü verilerinin daha ileri analiz adımlarına uygun hale getirilmesi amacıyla gerçekleştirilen temel bir aşamadır. Bu aşamada, görüntü kalitesini artırmak, gürültüyü azaltmak, kontrastı iyileştirmek, kenarları belirginleştirmek ve gereksiz detayları ortadan kaldırmak gibi işlemler uygulanır. Bu işlemler, daha doğru özellik çıkarımı ve sınıflandırma sonuçları elde edilmesine olanak tanır (Perihanoglu, 2015).

Gri tona dönüştürme

Görüntü işlemede gri tonlamaya dönüştürme, renkli bir görüntüdeki her pikselin renk bileşenlerinin kaldırılarak yalnızca parlaklık bilgisiyle temsil edilmesini sağlayan bir ön işleme tekniğidir. Bu işlem sonucunda oluşan gri tonlamalı görüntü, yalnızca siyah, beyaz ve çeşitli gri düzeylerinden oluşur ve her piksel tek bir parlaklık değeriyle ifade edilir. Gri tonlamalı görüntüler, renk bilgisi içermediğinden bellek kullanımı açısından daha verimlidir ve birçok görüntü işleme algoritmasının daha hızlı ve etkili çalışmasını sağlar. Ayrıca, nesne tanıma ve kenar tespiti gibi temel analizlerde sade bir yapı sunarak işlem yükünü azaltır (Gonzalez ve Woods, 2018). Renkli bir görüntünün gri tonlamalı versiyonu örnek olarak Resim 3.2’de sunulmuştur.




Resim 3. 2. Renkli görüntünün gri görüntüye çevrilmiş gösterimi

Bulanıklaştırma

Bulanıklaştırma işlemi, bir görüntüdeki keskin kenarları yumuşatmak ve detayları azaltmak amacıyla uygulanan temel bir görüntü işleme tekniğidir. Bu işlem, görüntüdeki gürültüleri azaltmak, odak dışı alanları yumuşatmak ve genel olarak daha pürüzsüz ve estetik bir görüntü elde etmek için kullanılır. Bulanıklaştırma, kenarları yumuşatarak pikseller arasındaki geçişleri daha akıcı hale getirir (Pratt, 2007).

Bu tez çalışmasında da bulanıklaştırma yöntemlerinden medyan bulanıklaştırma (median blurring) tercih edilmiştir. Bu yöntemde, her pikselin değeri çevresindeki piksellerin medyan değeriyle değiştirilir, böylece özellikle gürültülü görüntülerde daha doğal ve etkili bir yumuşatma sağlanır. Medyan bulanıklaştırma tekniği, pirinç üzerindeki uygulamasıyla Resim 3.3'te örneklenmiştir.



Resim 3. 3. Bulanıklaştırma işlemi


Renk uzayı dönüşümü

Renk uzayları, rengi tanımlamada kullanılan matematiksel bir temsildir. Bazı renk alanları insanların renkleri seçmesine olanak sağlamak için formüle edilirken bazıları ise makinelerde verilerin işlenmesini kolaylaştırma amaçlı formüle edilmiştir. Renk uzaylarının tasarımları üç boyutlu olarak tasarlanmaktadır. Renkli bir görüntü üzerinde bulunan her piksel 3 renk kanalından oluşmaktadır (Toptaş, 2017).

Bu tez çalışmasında da görüntülerin Lab renk uzayına dönüştürülmesi gerçekleştirilmiştir. Lab renk uzayı, renk bilgisini üç farklı bileşenle ifade eden bir modeldir: parlaklık (L), yeşil-magenta (a^*), ve mavi-sarı (b^*) bileşenleri (Othman, 2020). Bu tez çalışması kapsamında yalnızca parlaklık bileşeni (L) kullanılmıştır. Parlaklık bilgisi, görüntü işleme

ve analiz süreçlerinde geniş bir uygulama yelpazesinde değerlendirilebilmektedir. Özellikle, görüntü segmentasyonu, kenar tespiti, nesne tanıma gibi işlemlerde etkili bir şekilde kullanılabilir.

Lab renk uzayı, insan gözünün renk algılama şekline daha yakın bir model sunması nedeniyle, görüntü işleme ve analiz uygulamalarında yaygın bir şekilde tercih edilmektedir. Bu özellik hem renk duyarlılığı gerektiren işlemlerde hem de nesne tanıma ve analizi gibi uygulamalarda Lab renk uzayını önemli bir araç haline getirmektedir (Bora, Gupta ve Khan 2015). Resim 3.4'te renk uzayı dönüşümü gösterilmiştir.



Resim 3. 4. Renk uzayı dönüşümü

Görüntü eşikleme

Makine öğrenimi yöntemleri kullanılarak görüntülerden bilgi ve özellik çıkarımı, eşikleme yöntemi ile gerçekleştirilmiştir. Eşikleme, görüntü işleme alanında sıkça kullanılan ve görüntüleri farklı bölgelere ayırmayı amaçlayan temel bir yöntemdir (Elen, 2020). Bu yöntem, özellikle görüntüdeki nesneleri arka plandan ayırmak ve istenmeyen detayları kaldırmak için etkili bir şekilde kullanılmaktadır.


Eşikleme, bir görüntüdeki piksellerin belirli bir eşik değerini (T) geçip geçmediğini kontrol ederek nesne ve arka plan ayırımı yapmayı sağlar. Bu yöntemde, her pikselin yoğunluğu, belirlenen eşik değeri ile karşılaştırılır; eşik değerini aşan pikseller nesne olarak kabul edilirken, bu değeri aşamayan pikseller arka plan olarak değerlendirilir. Böylece, görüntüdeki nesnelerin belirginleştirilmesi ve gereksiz detayların ortadan kaldırılması sağlanır. Eşik değerinin uygun bir şekilde belirlenmesi, görüntü içeriğinin doğruluğunun korunması açısından kritik bir öneme sahiptir. Bu değer, uygulandığı görüntüye bağlı

olarak deęişiklik gösterebilir ve nesne ile arka plan arasındaki farkların belirginliğine göre ayarlanır (Ergin, 2024).

Eşikleme işlemi, Denklem 3.1'de matematiksel olarak tanımlanmıştır (Boyacıgil, 2022):

$$f(x,y) = \begin{cases} 255, & \text{eğer } f(x,y) > T(x,y) \text{ ise} \\ 0, & \text{eğer } f(x,y) \leq T(x,y) \end{cases} \quad (3.1)$$

Bu çalışmada, klasik eşikleme yöntemi kullanılmış olup, gri tonlamalı bir görüntüyü siyah ve beyaz piksellerden oluşan bir ikili (binary) görüntüye dönüştürmek amacıyla uygulanmıştır. Klasik eşikleme, basit ve yaygın olarak tercih edilen bir yöntemdir. Denklem 3.1'de belirtilen bu yöntemde, tek bir eşik değeri kullanılarak gri piksel değerlerinin eşik değerinden büyük veya küçük olduğuna göre ayrımı gerçekleştirilmiştir. Eşikleme yöntemiyle işlenmiş pirinç görüntüsü, Resim 3.5'te örneklendirilmiştir.




Resim 3. 5. Klasik eşikleme yöntemi

Görüntü histogramı

Görüntü histogramı, bir görüntüdeki piksellerin renk veya gri tonlama değerlerinin dağılımını ve frekansını gösteren bir grafiksel temsildir (Horasan, 2016). Bu grafik, görüntü analizi ve işleme süreçlerinde temel bir araç olarak kullanılmaktadır. Histogram, görüntüdeki her pikselin yoğunluk değerini tespit ederek, bu değerlere sahip piksel sayısını frekans olarak yansıtır. Bu sayede, bir görüntüye ait çeşitli nitelikler ve istatistiksel bilgiler elde edilebilir. Görüntü histogramları, özellikle bir görüntünün genel olarak karanlık mı açık mı olduğunu, renklerin homojen mi yoksa heterojen bir şekilde mi dağıldığını ve

baskın renk tonlarını analiz etmede etkilidir. Bu analiz yöntemi, görüntü işleme algoritmalarında sıklıkla uygulanmaktadır. Örneğin, kontrast ayarları, parlaklık düzeltmeleri veya renk dengesinin optimize edilmesi gibi işlemler için histogram analizinden faydalanılır. Ayrıca, görüntü histogramları, nesne tespiti, görüntü segmentasyonu ve sınıflandırma gibi ileri seviye uygulamalarda da yaygın olarak kullanılmaktadır. Şekil 3.2’de bir görüntüye ait histogramın bu analizlere olan katkısı açıkça görülmektedir.



Şekil 3. 2. Orijinal bir pirinç görüntüsüne ait histogram grafikleri

3.3. Morfolojik Görüntü İşleme


Morfolojik görüntü işleme, dijital görüntülerin geometrik şekiller temelinde analiz edilmesi ve işlenmesi için kullanılan kapsamlı bir yöntemler kümesidir. Bu yöntem, dijital görüntülerdeki eksik bölgelerin doldurulması veya fazlalıkların giderilmesi amacıyla geometrik hesaplamalara dayanır ve genellikle çeşitli yapısal elemanların kullanımıyla gerçekleştirilir. Yapısal elemanlar, genellikle daire, kare veya dikdörtgen gibi basit geometrik şekiller olup, görüntü üzerinde belirli bir düzenle gezdirilerek işlemler uygulanır

(Karhan vd., 2011). Morfolojik işlemler, görüntü işleme ve analizi alanında geniş bir uygulama yelpazesi sunmakta ve bu alandaki birçok problem için etkili bir çözüm yöntemi olarak kullanılmaktadır. Morfolojik görüntü işleme, şekil analizi, kenar tespiti, nesne tanıma, nesne ayrımı ve gürültü giderme gibi çeşitli uygulamalarda yaygın olarak kullanılmaktadır. Bu yöntem, nesnelerin boyut, şekil, uzantı ve bağlantı gibi geometrik özelliklerini belirlemek amacıyla farklı matematiksel operatörler ve filtrelerin kullanımını içerir (Balcı vd., 2016). Morfolojik işlemler, özellikle tıp ve endüstriyel görüntüleme alanlarının yanı sıra, robotik, otomasyon ve görüntü işleme tabanlı diğer teknolojilerde de önemli bir rol oynamaktadır.


3.3.1. Aşındırma işlemi

Aşındırma işlemi, bir görüntüdeki nesnelerin boyutunu küçültmek, detayları azaltmak veya bağlantılı bölgeleri ayırmak amacıyla kullanılan temel bir morfolojik işlemidir. Bu işlem, piksellerin yoğunluğunu azaltarak ya da bazılarını tamamen ortadan kaldırarak görüntüyü belirli ölçüde sadeleştirir. Aşındırma uygulanmış görüntüler, orijinal görüntüye kıyasla daha az piksel içerir; nesneler küçülür, delikler genişler ve bağlantılı alanlar ayrılır (Altunkurt ve Kahrman, 2011). Aşındırma işlemi, genellikle gürültü azaltma, kenar keskinliğini iyileştirme ve görüntü sıkıştırma gibi amaçlarla uygulanır. Matematiksel olarak aşındırma işlemi, belirli bir yapısal eleman kullanılarak gerçekleştirilir. Bu işlem, morfolojik işlemler kapsamında yer alan bir dizi matematiksel yöntemi içermektedir. Matematiksel ifade olarak aşındırma işlemi Denklem 3.2’de sunulmakta, görsel açıklaması ise Şekil 3.3 ve Resim 3.6’da gösterilmektedir.

$$A \ominus B = \{z | (B)z \subseteq A\} \quad (3.2)$$



Şekil 3. 3. Aşındırma işlemi uygulaması




Resim 3. 6. Aşındırma işlemi uygulanmış görüntü


3.3.2. Genişleme işlemi

Morfolojik genişleme, bir görüntüdeki nesnelerin veya yapıların boyutunu artırmak veya alanını genişletmek amacıyla kullanılan bir morfolojik işlemdir (Acar ve Bayram, 2009). Bu işlemde, genellikle bir yapı elemanı kullanılır. Yapı elemanı, görüntüdeki nesnelerin kenarlarını ve sınırlarını keskinleştirerek, delikleri tıkar ve küçük boşlukları doldurur. Morfolojik genişleme, görüntü işleme alanında özellikle nesne tespiti, kenar tespiti ve şekil analizi gibi uygulamalarda yaygın olarak kullanılmaktadır. Genişleme işlemi ile ilgili matematiksel denklemler Denklem 3.3'te, görsel açıklamalar ise Şekil 3.4 ve Resim 3.7'de ayrıntılı olarak sunulmuştur.

$$A \oplus B = \{z | (B)z \cap A \neq \emptyset\} \quad (3.3)$$



Şekil 3. 4. Genişleme işlemi uygulaması




Resim 3. 7. Genişleme işlemi uygulanmış görüntü


3.3.3. Açma işlemi

Morfolojik açma işlemi, görüntü işleme alanında, sırasıyla aşındırma ve ardından genişletme işlemlerinin uygulanmasıyla gerçekleştirilen temel bir morfolojik operatördür. Bu işlem, özellikle görüntüdeki küçük gürültü öğelerinin giderilmesi, nesne sınırlarının düzeltilmesi ve ince yapıların sadeleştirilmesi amacıyla tercih edilmektedir (Boztoprak vd., 2007). Açma işlemi, öncelikle nesnelerin boyutunu geçici olarak küçülterek ayrık ya da istenmeyen küçük detayları ortadan kaldırmakta; ardından uygulanan genişletme ile ana yapılar yeniden kazandırılmaktadır. Bu süreç sonucunda, görüntüdeki nesneler daha düzgün ve yumuşak kenarlara sahip olurken, küçük boşlukların kapanması da sağlanır. Dolayısıyla, açma işlemi hem nesne bütünlüğünü koruyan hem de görüntüdeki istenmeyen ayrıntıları azaltan etkili bir tekniktir. (Serra, 1983). Opening işlemi ile ilgili matematiksel denklemler 3.4'de, görsel açıklamalar ise Şekil 3.5'te ve Resim 3.8'de ayrıntılı olarak sunulmuştur.

$$A \circ B = (A \ominus B) \oplus B \quad (3.4)$$



Şekil 3. 5. Açma işlemi uygulaması



Resim 3. 8. Açma işlemi uygulanmış görüntü


3.3.4. Kapama işlemi

Morfolojik kapama işlemi, açma işleminin tersine, sırasıyla genişletme ve ardından aşındırma işlemlerinin uygulanmasıyla gerçekleştirilir. Bu işlem, dijital görüntülerde nesne kenarlarının düzeltilmesi, eksik bağlantıların tamamlanması ve küçük boşlukların kapatılması gibi amaçlarla yaygın olarak kullanılmaktadır (Jimeno-Morenilla vd., 2014).


Kapama işlemi, özellikle nesneler arasındaki boşlukların doldurulması ve ince detayların korunarak küçük çaplı gürültülerin giderilmesi gereken durumlarda etkili bir yöntemdir. Bu teknik, nesne sınırlarının daha düzgün ve sürekli hale getirilmesini sağlarken, aynı zamanda kenar tespiti ve nesne ayrımı gibi görüntü işleme uygulamalarında önemli avantajlar sunar. Ayrıca, görüntüdeki küçük nokta ya da çizgi şeklindeki istenmeyen gürültü öğelerini azaltarak, görsel bilginin daha net ve anlaşılır bir şekilde elde edilmesine katkı sağlar.

Morfolojik kapama işlemi, yapısal bütünlüğün korunması ve detayların vurgulanması açısından da sıklıkla tercih edilmektedir (Ergin, 2024). Kapanma işlemi ile ilgili matematiksel denklemler 3.5'te, görsel açıklamalar ise Şekil 3.6'da ve Resim 3.9'da ayrıntılı olarak sunulmuştur.

$$A \cdot B = (A \oplus B) \oplus B \quad (3.5)$$



Şekil 3. 6. Kapama işlemi uygulaması



Resim 3. 9. Kapama işlemi uygulanmış görüntü

3.4. Özellik Çıkarımı

Özellik çıkarma işlemi, nesne tanıma ve sınıflandırma sistemlerinde temel bir bileşen olarak yer almakta ve bu sistemlerin doğruluk oranlarını doğrudan etkilemektedir. Bu işlem, nesnelerin özgün ve ayırt edici niteliklerinin daha küçük boyutlu temsillerle ifade edilmesine olanak tanıyarak, tanıma sürecinin hem verimliliğini hem de doğruluğunu artırır (Toraman, 2016).

Özellik çıkarma, yalnızca geleneksel görüntü işleme yöntemlerinde değil, aynı zamanda makine öğrenmesi ve derin öğrenme tabanlı yaklaşımlarda da önemli bir role sahiptir. Karmaşık veri kümelerinden anlamlı bilgilerin çıkarılması, modelin eğitilme sürecini kolaylaştırmakta ve hesaplama maliyetlerini azaltmaktadır.

Nesne tanıma uygulamalarında kullanılan özellik çıkarma yöntemleri; kenar tespiti, köşe tespiti, renk ayrıştırma, doku analizi ve şekil tabanlı analizler gibi çeşitli teknikleri içermektedir. Bu yöntemler, nesnelerin tanımlayıcı karakteristiklerini vurgulamakta ve sınıflandırma aşamasında daha yüksek ayırt edicilik sağlamaktadır.

Özellik çıkarma sürecinde tercih edilen algoritmaların tipi ve ilgili parametrelerin optimizasyonu, sistemin genel başarımını doğrudan etkileyen faktörlerdendir. Bu nedenle, ilgili veri kümesine uygun özellik çıkarma tekniklerinin seçimi ve bu tekniklerin dikkatle yapılandırılması, başarılı bir nesne tanıma sisteminin inşasında kritik öneme sahiptir. (Dalal ve Triggs, 2005).

Geliştirilen bazı teknikler, görüntüdeki nesne kenarlarını veya köşe noktalarını belirlemek amacıyla kenar tabanlı analiz yöntemlerini kullanırken; diğer yaklaşımlar, renk histogramları (verilerin dağılımını görselleştirmek için kullanılan bir grafik türü), doku örüntüleri veya şekil tanımlayıcıları gibi daha kapsamlı özellikleri temel alarak nesneleri tanımlamaya çalışmaktadır. Bu yöntemlerin ortak amacı, görüntüde yer alan nesnelerin benzersiz özelliklerini yakalayıp daha doğru ve güvenilir tanıma sonuçları elde edilmesini sağlamaktır (Bishop ve Nasrabadi, 2006).

4. YAZILIM

Yazılım, bilgisayar sistemleri veya elektronik cihazlar üzerinde belirli işlevleri yerine getirmek amacıyla geliştirilen programlar ve veri kümelerini ifade eder. Bu programlar, donanım ile etkileşim içerisinde çalışarak kullanıcıların gereksinimlerini karşılamakta, çeşitli işlevleri yerine getirmekte ve veri işleme süreçlerini etkin bir şekilde yönetmektedir. Bu bölümde derin öğrenmeye özgü program dilleri ve kullanılan kütüphaneler detaylı bir şekilde ele alınarak incelenmiştir.

4.1. MATLAB

MATLAB, mühendislik ve bilimsel hesaplamalar için geliştirilmiş, yüksek seviyeli bir programlama dili ve etkileşimli bir ortamdır. Özellikle sayısal analiz, veri görselleştirme, algoritma geliştirme ve sistem modelleme gibi alanlarda yaygın olarak kullanılmaktadır (Aydın, 2003).

Derin öğrenme ve Convolutional Neural Network (CNN) modelleri bağlamında MATLAB, güçlü görselleştirme araçları, hazır derin öğrenme kütüphaneleri (örneğin Deep Learning Toolbox) ve GPU hızlandırmalı hesaplama desteği sayesinde model geliştirme, eğitme ve değerlendirme süreçlerinde etkin biçimde kullanılabilir. Ayrıca, kullanıcı dostu arayüzü ve entegre araçları ile hızlı prototipleme imkânı sunarak akademik ve endüstriyel araştırmalarda tercih edilmektedir.

4.2. Python

Python programlama dili, esnek, dinamik, yorumlanabilir ve nesne yönelimli yapısıyla öne çıkan, yüksek seviyeli ve açık kaynak kodlu bir yazılım dilidir (Hlavatý vd., 2022). Python, 1980’li yılların sonlarında Hollanda’daki Centrum Wiskunde ve Informatica (CWI) araştırma merkezinde Guido van Rossum tarafından, ABC programlama diline alternatif olarak geliştirilmiştir (Van Rossum ve Drake,1995; Sarı, 2023). Hem akademik dünyada hem de endüstriyel Ar-Ge faaliyetlerinde yaygın olarak kullanılmakta olup; kullanıcı dostu sözdizimi, okunabilirlik düzeyi yüksek yapısı ve düşük bakım maliyeti sayesinde eğitim alanında da sıkça tercih edilmektedir. Özellikle programlama öğrenimine yeni başlayanlar

için uygun bir yapı sunması, Python'un eğitim kurumlarında tercih edilme oranını artırmaktadır (Yılmaz, 2019).

Python'un modüler yapısı, yeniden kullanılabilir kod üretimine olanak tanıyan modül ve paket desteği ile desteklenmektedir. Bu yönüyle, büyük ölçekli yazılım projelerinde sürdürülebilirliği ve geliştirilebilirliği kolaylaştırmaktadır. Platformlar arası taşınabilirliği sağlayan geniş standart kütüphanesi ve ücretsiz olarak erişilebilir olması, Python'un kullanım alanlarını genişletmektedir (Tiryaki ve Balaman, 2021).

Python, sıklıkla Ruby, JavaScript ve Scheme gibi dillerle karşılaştırılsa da basit yapısı, öğrenim kolaylığı, geniş uygulama yelpazesi ve çoklu işletim sistemi desteği (ör. MacOS, Windows, Linux) gibi nitelikleriyle diğer dillere kıyasla daha erişilebilir ve üretken bir programlama ortamı sunmaktadır. Nitekim bu özellikleri, geliştiricilere diğer dillere oranla 3 ila 5 kat daha hızlı kod yazma imkânı tanımaktadır (Yılmaz, 2019).

Programlama dillerinin popülerliği üzerine düzenli istatistikler sunan TIOBE Endeksi, eğitim kaynakları, satıcılar ve yazılım mühendisleri tarafından yapılan aramaların analizine dayanarak hazırlanmaktadır. TIOBE verilerine göre, Python son yıllarda en çok tercih edilen programlama dilleri arasında yer almakta, bu da dilin sektörel ve akademik popülaritesini gözler önüne sermektedir (TIOBE Index, 2025). Çizelge 4.1'de programlama dilleri kullanım alanları sunulmuştur. Programlama dillerine dair popülerlik oranları ise Çizelge 4.2'de görselleştirilmiştir.

Çizelge 4. 1. Programlama dilleri kullanım alanları

Programlama Dili	Kullanım Alanları
Python	Veri bilimi, yapay zekâ, web geliştirme, otomasyon
JavaScript	Web geliştirme, dinamik ve etkileşimli web siteleri, oyunlar, mobil uygulamalar
Java	Kurumsal uygulamalar, mobil uygulamalar, platform bağımsız projeler
C#	Oyun geliştirme, masaüstü uygulamalar, web uygulamaları
C++	Sistem programlama, oyun motorları, yüksek performanslı uygulamalar
PHP	Dinamik web siteleri, veritabanı ile etkileşimli web uygulamaları
Swift	iOS ve macOS uygulama geliştirme
Kotlin	Android uygulama geliştirme

Çizelge 4. 2. 2025 yılı programlama dilleri popülerlik oranları (TIOBE Index for May, 2025)

Mayıs 2025	Mayıs 2024	Değişim	Programlama Dili	Oranlar	Değişim (%)
1	1		Python	25,35%	+9,02%
2	3	↑	C++	9,94%	+0,41%
3	2	↓	C	9,71%	-0,27%
4	4		Java	9,31%	+0,62%
5	5		C#	4,22%	-2,27%
6	6		JavaScript	3,68%	+0,66%
7	8	↑	Go	2,70%	+1,10%
8	7	↓	Visual Basic	2,62%	+0,61%
9	11	↑	Delphi/Object Pascal	2,29%	+1,05%
10	9	↓	SQL	1,90%	+0,45%

Python, günümüzde çok yönlü ve güçlü yapısı sayesinde farklı sektörlerde ve bilimsel alanlarda yaygın olarak kullanılan bir programlama dilidir. Bu dilin kullanım alanları hem yazılım geliştirme hem de veri bilimi uygulamaları açısından oldukça geniştir. Öncelikle Python, Django ve Flask gibi çerçeveler aracılığıyla dinamik web uygulamaları geliştirmek için sıklıkla tercih edilmektedir. Ayrıca, Pygame ve Panda3D gibi kütüphaneler kullanılarak 2D ve 3D oyun geliştirme süreçlerinde de etkin bir rol oynamaktadır. Görsel ve etkileşimli uygulamalarda yaygın olarak kullanılması, Python'un multimedya destekli projeler için uygunluğunu artırmaktadır.

Makine öğrenimi ve yapay zekâ alanlarında da Python önemli bir yere sahiptir. Özellikle TensorFlow, Keras, Scikit-learn ve PyTorch gibi kütüphanelerle bu alanda güçlü modeller geliştirmek mümkündür (Raschka ve Mirjalili, 2019). Veri analizi ve görselleştirme konularında ise NumPy, Pandas, Matplotlib ve Seaborn gibi kütüphaneler ile kullanıcıya esnek ve işlevsel çözümler sunar (McKinney, 2012).

Donanıma yakın uygulamalar geliştirmeye de uygun olan Python, mikrodenetleyiciler ve gömülü sistemlerle etkileşimli projelerde kullanılabilir. Bunun yanı sıra, görüntü işleme (OpenCV), veri analizi ve matematiksel modelleme gibi teknik alanlarda da yaygın bir kullanım alanına sahiptir (Bradski, 2000). Tıp, farmakoloji, astronomi, robotik, otonom araç teknolojileri, iş zekâsı uygulamaları ve meteoroloji gibi disiplinlerde Python'un kullanımı giderek artmakta; bu da dilin disiplinler arası uygulamalarda ne denli güçlü bir araç olduğunu göstermektedir (Tiryaki ve Balaman, 2021).

4.3. Kullanılan Kütüphaneler

Yazılım kütüphaneleri, yazılım geliştirme sürecinde geliştiricilere tekrar kullanılabilirlik ve verimlilik sağlayan, belirli işlevleri yerine getirmek üzere önceden yazılmış ve yapılandırılmış kod bileşenlerinden oluşan yapılardır. Bu kütüphaneler; veri işleme, dosya yönetimi, grafik arayüz oluşturma veya ağ bağlantıları gibi yaygın görevlerin hızlı ve etkin biçimde gerçekleştirilmesine olanak tanıyarak, yazılımın geliştirme süresini kısaltmakta ve kodun tutarlılığını artırmaktadır (Sommerville, 2016; Fagundes ve de Macedo, 2023).


4.3.1. OpenCV

OpenCV (Open Source Computer Vision), açık kaynak kodlu bir bilgisayarla görme kütüphanesi olup, ilk olarak 1999 yılında Intel tarafından geliştirilmiştir. Geliştirilme sürecine zamanla Nvidia, AMD ve Google gibi önde gelen teknoloji firmaları ile açık kaynak toplulukları da katkı sağlamıştır (Akkoca ve Buluş, 2021). OpenCV'nin temel amacı, bilgisayarla görme alanında geniş çapta bir altyapı sunmak ve bu teknolojilerin ticari uygulamalarda daha hızlı şekilde benimsenmesini sağlamaktır. Kütüphane, özellikle görüntü işleme, nesne tanıma ve makine öğrenimi uygulamaları için kapsamlı fonksiyonlar ve algoritmalar içermektedir. Yaygın kullanım alanı ve güçlü işlevselliği sayesinde dünya genelinde 47.000'den fazla geliştirici tarafından aktif olarak kullanılmakta ve 18 milyondan fazla indirme sayısına ulaşmış durumdadır. OpenCV, Google, Microsoft, Intel, IBM, Sony, Honda ve Toyota gibi birçok büyük ölçekli şirketin projelerinde tercih ettiği güvenilir bir teknolojidir (Elkiran, 2020).

OpenCV'nin ilk alfa sürümü 2000 yılında yayımlanmış olup, başlangıçta C programlama dili kullanılarak geliştirilmiştir (Deepthi ve Sankaraiah, 2011). İlerleyen yıllarda, kütüphanenin çekirdek algoritmaları C++ dilinde yeniden yapılandırılarak daha geniş ve esnek bir yapıya kavuşturulmuştur. OpenCV, BSD lisansı kapsamında açık kaynaklı olarak sunulmaktadır; bu durum, kütüphanenin akademik ya da ticari projelerde ücretsiz şekilde kullanılmasına olanak tanımaktadır. Platformdan bağımsız bir yapıya sahip olan OpenCV, Windows, Linux, Android, macOS ve iOS gibi çok çeşitli işletim sistemlerinde çalışabilmektedir. Geliştiricilere sunduğu çoklu dil desteği sayesinde OpenCV, C++, C, Python, Java ve Matlab gibi dillerle doğrudan kullanılabilirdiği gibi, topluluk tarafından sağlanan sarmalayıcılar (wrapper) aracılığıyla Perl ve Ruby gibi dillerde de entegre

edilebilmektedir. Bu çok yönlü yapı, özellikle yapay zekâ ve bilgisayarla görme uygulamaları geliştirmek isteyen araştırmacılar ve yazılım geliştiriciler için önemli bir avantaj sunmaktadır. OpenCV'nin sunduğu bu esneklik, onu hem akademik çalışmalarda hem de endüstriyel uygulamalarda tercih edilen güçlü bir araç haline getirmiştir (OpenCV, b.t).

OpenCV, temel düzeydeki görüntü işleme görevlerinden başlayarak mantıksal ve aritmetik işlemlerin gerçekleştirilmesini sağlamaktadır. Bunun yanı sıra, nesne tespiti ve takibi gibi daha karmaşık bilgisayarla görü uygulamalarını da desteklemektedir. Kütüphane, modüler bir mimariye sahip olup, kullanıcıların farklı bileşenleri ihtiyaca göre entegre etmelerine olanak tanımaktadır. OpenCV'nin bileşenlerine ilişkin genel yapı Şekil 4.1'de sunulmaktadır.



Şekil 4. 1. OpenCV bileşen yapısı (Erişti, 2010)

OpenCV kütüphanesi, görüntü işleme ve bilgisayarla görme uygulamalarında kullanılan modüler yapısı sayesinde kullanıcılarına geniş bir işlevsellik sunmaktadır. Bu kütüphane, farklı bileşenlerden oluşmakta ve her bir bileşen belirli görevleri yerine getirmektedir (Güler, 2018). Python programlama dilinde OpenCV kütüphanesini kullanmak için “import cv2” şeklinde import edilir.

4.3.2. NumPy


NumPy (Numerical Python), Python programlama dilinde bilimsel hesaplamalar için temel bir kütüphane olarak büyük bir öneme sahiptir. Bu kütüphane, çok boyutlu diziler ve matrisler üzerinde yüksek verimlilikle işlem yapabilmeyi sağlayarak sayısal hesaplamaların etkinliğini önemli ölçüde artırır. NumPy, esasen N-boyutlu dizileri (ndarray) temel veri yapısı olarak kullanılmaktadır (Harris vd., 2020). Bu veri yapısı, verilerin depolanması ve işlenmesi açısından güçlü ve verimli bir çözüm sunmakta olup, Python'un yerleşik liste veri tipine kıyasla hem hafıza kullanımı hem de işlem hızı açısından daha üstün performans sergiler. Aynı zamanda, vektör ve matris tabanlı matematiksel işlemleri optimize ederek bu tür hesaplamaları daha hızlı ve etkili bir şekilde gerçekleştirir.

NumPy, veri bilimi, makine öğrenimi, görüntü işleme, mühendislik ve diğer bilimsel disiplinlerde yaygın olarak kullanılmaktadır. Bu kütüphane, özellikle büyük veri setleri üzerinde yapılan analizler için önemli bir araçtır. Veri işleme ve analizinin yanı sıra, görselleştirme (örneğin, matplotlib) ve veri manipülasyonu (örneğin, pandas) gibi alanlarda da diğer Python kütüphaneleriyle entegrasyon sağlayarak kapsamlı bir bilimsel hesaplama ekosistemi oluşturur. Bu özellik, NumPy'nin bilimsel ve mühendislik uygulamalarında etkin bir şekilde kullanılmasını mümkün kılmaktadır. Python programlama dilinde NumPy kütüphanesini kullanabilmek için, genellikle şu komutla kütüphane sisteme dahil edilir: `import numpy as np`. Bu kullanım, kütüphanenin fonksiyonlarının ve özelliklerinin daha verimli bir şekilde çağrılmasını sağlar (Van Der Walt vd., 2011).

4.3.3. Matplotlib

Matplotlib, Python programlama dilinde veri görselleştirme için en yaygın kullanılan kütüphanelerden biridir. Başta John Hunter olmak üzere, birçok katkıcının geliştirdiği bu kütüphane, dünya çapında bilim insanları ve mühendisler tarafından geniş bir kullanıcı kitlesine hitap etmektedir (Hunter, 2008; Hunter ve Dale, 2007). Matplotlib, Python ekosisteminde veri bilimi alanında önemli bir yer tutan ve NumPy, Pandas gibi diğer bilimsel hesaplama kütüphaneleriyle uyumlu olarak çalışan bir görselleştirme aracıdır. Kullanıcı dostu arayüzleri ve esnek yapısı sayesinde, farklı grafik türlerini üretmek için son derece çeşitlendirilmiş bir araç sunar. Bu kütüphane, çizgi grafiklerinden sütun, dağılım,

pasta grafikleri ve histogramlar gibi temel görselleştirmelere kadar geniş bir yelpazede grafik oluşturma yeteneğine sahiptir. Ayrıca, güç spektrumu gibi özel ve karmaşık görselleştirme uygulamaları için de uygun bir yapı sunmaktadır. Bu özellikler, Matplotlib'i veri görselleştirme sürecinde vazgeçilmez bir araç haline getirmektedir. Şekil 4.2'de gösterildiği gibi çizgi, sütun, dağılım, pasta grafikleri ve histogramlar gibi grafik türlerini oluşturmak için idealdir.



Şekil 4. 2. Matplotlib grafik örnekleri

Python programlama dilinde matplotlib kütüphanesini kullanmak için “import matplotlib.pyplot as plt” şeklinde import edilir.

4.3.4. Os

Python programlama dilinde işletim sistemi işlemlerini gerçekleştirmek için os (Operating System) kütüphanesi kullanılmaktadır. Bu kütüphane, dosya ve izin yönetimi, sistem bilgilerine erişim, ortam değişkenleri ile etkileşim ve sistem komutlarının çalıştırılması gibi geniş bir yelpazede işlevsellik sunar.

Os kütüphanesi, işletim sistemi düzeyindeki işlemlerin Python programlarına entegre edilmesini sağlayarak, kullanıcıların sistemle etkileşimde bulunmalarını kolaylaştırır. Özellikle dosya ve izinlerin oluşturulması, silinmesi, taşınması ve yeniden adlandırılması gibi işlemler, çalışma izinlerinin değiştirilmesi, mevcut dosya ve izinlerin listelenmesi ve varlık durumlarının kontrol edilmesi gibi fonksiyonlar bu kütüphane aracılığıyla yapılabilir. Ayrıca, sistemin genel durumu hakkında bilgi edinmek ve sistem komutlarını çalıştırmak için de kullanılabilir.

Python’da os kütüphanesini kullanabilmek için, import os komutu ile kütüphane programınıza dahil edilir (Python Software Foundation, 2021; Rajamani ve Iyer, 2023).

5. YÖNTEM

Bu bölümde, çalışmada kullanılan yöntemsel yaklaşımlar detaylı şekilde açıklanacaktır. İlk olarak, modelin eğitimi ve değerlendirilmesi sürecinde kullanılan veri seti tanıtılacak; verinin kaynağı, içeriği, sınıflandırma kategorileri ve ön işleme adımları ele alınacaktır. Ardından, sınıflandırma amacıyla kullanılan hazır (önceden eğitilmiş) evrişimsel sinir ağı (CNN) mimarileri tanıtılacaktır. Bu kapsamda, farklı CNN modellerinin karşılaştırmalı performansları değerlendirilerek çalışmaya en uygun mimariler belirlenecektir.

Bunun yanı sıra, bu tez çalışması kapsamında özgün yedi model önerisi de sunulmuştur. Bu yeni modeller, mevcut CNN mimarilerinin güçlü yönlerinden faydalanarak geliştirilmiş olup, performans iyileştirme amacıyla çeşitli katman yapıları ve hiperparametre ayarlarıyla optimize edilmiştir. Modellerin eğitiminde kullanılan yöntemler, eğitim-doğrulama oranı, epoch sayısı, öğrenme oranı, optimizasyon algoritmaları gibi teknik detaylara da bu bölümde yer verilecektir.

5.1. Veri Seti

Pirinç türlerinin sınıflandırılmasına yönelik bu tez çalışmasında, farklı türlere ait görsellerin yer aldığı kapsamlı bir veri seti kullanılmıştır. Söz konusu veri seti, Murat Köklü tarafından oluşturulmuş ve araştırmacıların erişimine açık şekilde paylaşılmıştır (Koklu, 2020). Veri seti; Basmati, Arborio, Karacadağ, İpsala ve Jasmine olmak üzere beş farklı pirinç türünden toplam 75 000 adet etiketlenmiş görüntü içermektedir. Bu görüntüler MATLAB yazılımı yardımıyla ön işlemlerden geçirilerek görüntü üzerinde bulunabilecek istenmeyen maddelerden arındırılmış ve özellik çıkarımı aşamasına hazırlanmıştır. Çizelge 5. 1’de verildiği gibi bu türlerin her biri, fiziksel ve morfolojik açıdan ayırt edici özelliklere sahiptir.

Çizelge 5. 1. Pirinç çeşitlerine ait teknik özellikler (Çınar, 2019)

Çeşit Adı	Tane Uzunluğu (mm)	Tane Genişliği (mm)	10 gr’a Karşılık Tane Adedi
Arborio	6-7,5	3-4	303
Basmati	8,5-11,5	3,5-4,5	507
İpsala	9-11	4-5,5	425
Jasmine	6,5-10	2,5-3,5	547
Karacadağ	4,5-6	3-4	513

Veri seti, görüntü sınıflandırma, özellik çıkarımı ve transfer öğrenme gibi bilgisayarla görü tabanlı derin öğrenme uygulamaları için kullanılabilecek zengin bir kaynak sunmaktadır. Görseller RGB renk uzayında yer almakta olup, farklı aydınlatma koşulları, şekil, doku ve renk gibi çeşitli değişkenlikler göstermektedir. Bu çeşitlilik, modelin genelleme yeteneğini artırma açısından önemlidir.

Veri setinin dengeli yapısı sayesinde her bir sınıfa ait yaklaşık eşit sayıda örnek bulunmaktadır. Bu durum, sınıflar arası dengesizliğin model performansını olumsuz etkilemesini önlemektedir. Bu yönleriyle veri seti hem akademik araştırmalarda hem de tarım ve gıda endüstrisinde otomatik kalite kontrol sistemleri gibi uygulamalarda kullanılabilecek değerli bir kaynak niteliği taşımaktadır.

5.2. Derin Öğrenme

Derin öğrenme, insan beynindeki nöronların çalışma prensiplerinden esinlenerek geliştirilen bir yapay zekâ yöntemidir. Bu yaklaşım, özellikle çok katmanlı yapay sinir ağlarının eğitilmesi sürecine olan ilgiyi artırmış ve bu alanda kapsamlı araştırmaların yapılmasına zemin hazırlamıştır (Bolouri, 1995).

Derin öğrenme modelleri, birden fazla katmandan oluşan mimariler şeklinde yapılandırılmıştır. Bu yapıda, her katmanın çıktısı bir sonraki katmanın girdisini oluşturur. Modelin en dış katmanları giriş ve çıkış katmanları olarak adlandırılırken, arada yer alan katmanlar gizli katmanlar olarak tanımlanır (Deng ve Yu, 2013).

Görüntü işleme alanında derin öğrenme, başta nesne algılama, görüntü sınıflandırma ve görüntü segmentasyonu olmak üzere pek çok görevde yüksek başarı göstermektedir. Örneğin, bir görüntüde yer alan nesneler doğru biçimde tespit edilip sınıflandırılabilir ya da görüntü parçalara ayrılarak her bir bileşenin içeriği ayrıntılı biçimde analiz edilebilir. Bununla birlikte, derin öğrenme yöntemlerinin uygulanmasında bazı temel zorluklar da bulunmaktadır. Bu yöntemler genellikle çok büyük hacimli veri kümelerine ihtiyaç duymakta, eğitim süreçleri ise yüksek hesaplama gücü ve zaman gerektirmektedir. Ayrıca model mimarilerinin karmaşıklığı, özellikle donanım kaynakları açısından ciddi bellek ve işlem kapasitesi gereksinimlerini beraberinde getirmektedir.


5.3. Evrişimsel Sinir Ağları

Evrişimsel Sinir Ağları (Convolutional Neural Networks – CNN), biyolojik nöronlar arasındaki bağlantılardan esinlenilerek geliştirilen ileri beslemeli bir yapay sinir ağı mimarisidir (LeCun, Bengio ve Hinton, 2015). Bu yapı, görüntü ve video verilerinden doğrudan öğrenme yeteneği ile özellikle sınıflandırma problemlerinde öne çıkan bir modeldir (Ciresan vd., 2012). CNN'ler, görsel verilerden anlamlı özelliklerin otomatik olarak çıkarılmasını sağlayan evrişim katmanları aracılığıyla, geleneksel el ile özellik çıkarma yöntemlerine kıyasla daha etkili bir alternatif sunar. Nöron ağırlıkları ve öğrenme algoritmaları yardımıyla, görsel veriler üzerinde kapsamlı analizler gerçekleştirebilirler. Bu mimarinin en önemli avantajlarından biri, segmentasyon veya arka plan ayrımı gibi ön işleme adımlarına ihtiyaç duymadan ham görüntü verisiyle doğrudan çalışabilmesidir.

Geleneksel yöntemlere kıyasla daha yüksek sınıflandırma performansı göstermesi, karmaşık ve zorlu görsel analiz problemlerinde esnek ve güçlü bir çözüm sunması, CNN'leri öne çıkaran başlıca özelliklerdendir. Nesnelerin bağlamsal ve yapısal özelliklerini daha doğru temsil edebilmesi sayesinde, daha güvenilir sonuçlar üretir. Ayrıca farklı veri seti boyutlarına ve yapısal karmaşıklıklara uyum sağlayabilen ölçeklenebilir bir yapı sunar. Yüksek doğruluk oranı ve düşük hata oranı ile derin öğrenme tabanlı görüntü işleme uygulamalarında dikkate değer bir başarı sağlamaktadır. Özellikle transfer öğrenme gibi yöntemlerle birleştirildiğinde, etiketli veri gereksinimi azalmakta ve daha az veri ile etkili öğrenme mümkün olmaktadır. Bu yönüyle CNN mimarisi, görüntü işleme alanında yeni ufuklar açarak, daha gelişmiş ve akıllı sistemlerin geliştirilmesine olanak sağlamaktadır (Litjens vd., 2017).

5.3.1. CNN katmanları

Evrişimsel Sinir Ağları (CNN), görüntü verilerinden anlamlı özellikler çıkarmak ve bu özellikleri sınıflandırmak için geliştirilmiş derin öğrenme mimarileridir. Temel olarak dört ana bileşenden oluşur: konvolüsyon katmanı, aktivasyon fonksiyonu (ReLU), havuzlama katmanı ve tam bağlantılı katman. Bu çok katmanlı yapı, görsel verilerden giderek soyutlaşan özelliklerin çıkarılmasına olanak tanır. Bu katmanların birlikte çalışması, görüntü işleme alanında oldukça başarılı sonuçlar alınmasını sağlar (LeCun vd., 1998). Söz konusu mimarinin yapısal bileşenleri ve işleyişi Şekil 5.1'de gösterilmektedir.



Şekil 5. 1. CNN katmanları (Erdal ve Korucuk, 2023)

Konvolüsyon katmanı, giriş görüntüsüne çeşitli filtreler uygulayarak kenar, köşe, doku gibi düşük ve orta düzeydeki özelliklerin çıkarılmasını sağlar. Bu işlem, filtrelerin giriş üzerinde kaydırılarak lokal bölgelerde çarpım-toplam işlemi yapılmasıyla gerçekleştirilir ve sonuç olarak özellik haritaları elde edilir (Krizhevsky vd., 2012).

Aktivasyon fonksiyonu (ReLU: Rectified Linear Unit), konvolüsyon sonucunda elde edilen doğrusal çıktıları doğrusal olmayan bir dönüşüm uygular. Bu işlem, negatif değerleri sıfıra indirirken pozitif değerleri aynen geçirir. Böylece sinir ağı, doğrusal olmayan ilişkileri öğrenebilir ve gradyanların yok olma problemi hafifletilmiş olur (Nair ve Hinton, 2010).

Havuzlama katmanı, konvolüsyon sonucunda elde edilen özellik haritalarının boyutunu küçültmek ve en baskın özellikleri korumak için kullanılır. En yaygın havuzlama yöntemi olan maksimum havuzlama, her bölgedeki en yüksek değeri alarak özelliklerin soyut temsilini oluşturur. Bu yaklaşım, modelin genel performansını artırırken hesaplama maliyetini azaltır (Scherer vd., 2010).

Tam bağlantılı katman, ağın son aşamasında yer alır ve önceki katmanlardan gelen soyut özelliklerin birleştirilerek sınıflandırma yapılmasını sağlar. Bu katmanda her nöron, bir önceki katmandaki tüm nöronlara bağlıdır ve çıkışta genellikle softmax gibi bir aktivasyon fonksiyonu ile sınıf etiketleri tahmin edilir (Goodfellow vd., 2016).


5.4. Önceden Eğitilmiş Evrişimsel Sinir Ağları Mimarileri

Evrişimsel sinir ağlarına dayalı olarak çeşitli derin öğrenme mimarileri geliştirilmiştir. Bu tez çalışmasında, transfer öğrenme yaklaşımıyla önceden eğitilmiş modellerden VGG-16, ResNet-50, EfficientNetB6, InceptionV3 ve DenseNet mimarileri kullanılmıştır.

Transfer öğrenme, kaynak bir görev üzerinde önceden eğitilmiş bir modelin, hedef bir görevde yeniden kullanılmasını sağlayan bir tekniktir. Transfer öğrenme yaklaşımları insan öğrenme modelinden etkilenir (Ying vd., 2018).

Önceden eğitilmiş modeller, genellikle ImageNet gibi milyonlarca örnek içeren büyük veri kümeleri üzerinde eğitilmekte ve kenar, renk, doku gibi temel özelliklerin yanı sıra daha karmaşık soyut temsilleri de öğrenebilmektedir. Bu kapsamda geliştirilen modeller, yalnızca görüntü sınıflandırma değil; genel nesne tanıma, yüz tanıma, duygu analizi ve doğal dil işleme gibi farklı alanlarda da yaygın biçimde kullanılmaktadır.

Tez kapsamında kullanılan modellerin parametre boyutları ve ImageNet veri kümesi üzerindeki doğruluk oranları Şekil 5.2’de sunulmaktadır.



Şekil 5. 2. Model boyutu ve imagenet doğruluk oranları (Wang vd., 2020)

Transfer öğrenme, sınırlı veriyle çalışılan durumlarda dahi etkili sonuçlar elde edilebilmesine olanak tanıyan bir yaklaşımdır. Bu yöntem, önceden büyük veri kümeleri üzerinde eğitilmiş modellerin, yalnızca son sınıflandırma katmanlarının hedef görev için yeniden eğitilmesi esasına dayanır. Böylece, hem eğitim süresi önemli ölçüde azaltılır hem de daha az sayıda örnekle yüksek doğruluk düzeyine ulaşmak mümkün hale gelir. Ayrıca, önceden eğitilmiş modellerin genel özellikleri öğrenme yeteneği sayesinde, hedef görevdeki benzer desen ve yapıları tanımada daha güçlü bir genelleme performansı sergiledikleri görülmektedir.

5.5. Transfer Öğrenme Yaklaşımları ve Geliştirilen CNN Modelleri

Bu bölümde mevcut transfer öğrenme modelleri ile tez çalışması sırasında geliştirilen 7 model tanıtılacaktır. Bu modeller ile, Arborio, Basmati, Karacadağ, İpsala ve Jasmine olmak üzere beş farklı pirinç türünü sınıflandırmak amaçlanmış ve mevcut transfer öğrenme modelleri ile geliştirilen modeller karşılaştırılmıştır.


5.5.1. VGGNet

Oxford Üniversitesi'nden K. Simonyan ve A. Zisserman tarafından geliştirilen “Very Deep Convolutional Networks for Large-Scale Image Recognition” başlıklı çalışma kapsamında sunulan VGGNet modeli, ImageNet veri kümesi üzerinde gerçekleştirdiği yüksek doğruluk oranları ile dikkat çekmiştir (Kılıç, 2023).

VGGNet mimarisi, 224x224 boyutundaki RGB görüntüler üzerinde çalışacak şekilde tasarlanmış olup, 16 ve 19 katmandan oluşan iki temel varyasyona sahiptir. Modelin her bir katmanında 3x3 boyutunda evrişim filtreleri kullanılmış; bu filtreler, doğrusal olmayan özellikler kazandırmak amacıyla ReLU (Rectified Linear Unit) aktivasyon fonksiyonları ile birlikte uygulanmıştır. Ayrıca her birkaç evrişimli katmandan sonra 2x2 boyutunda maksimum havuzlama işlemleri ile boyut indirgeme gerçekleştirilmiştir.

Bu yapı, derinliğin ağırlı öğrenme kapasitesi üzerindeki olumlu etkisini ortaya koymakta ve daha karmaşık örüntülerin başarıyla öğrenilmesine olanak tanımaktadır (Prasetyo vd., 2022). Ayrıca, VGGNet'in önceden eğitilmiş ağırlıklarla transfer öğrenme uygulamalarında yaygın olarak kullanılabilir olması, onu birçok görev için tercih edilen bir mimari hâline

getirmiştir. Bu tez çalışmasında da transfer öğrenme kapsamında VGG-16 modeli tercih edilmiş olup, modelin genel yapısı Şekil 5.3'te sunulmuştur.




Şekil 5. 3. VGG16 mimarisi (Varshney, 2020).

5.5.2. ResNet

Residual Network (ResNet), derin öğrenme alanında önemli bir dönüm noktası niteliği taşıyan bir mimaridir. 2015 yılında Kaiming He, Xiangyu Zhang, Shaoqing Ren ve Jian Sun tarafından geliştirilen bu yapı, ImageNet sınıflandırma yarışmasında kayda değer bir başarı elde etmiş ve derin sinir ağlarının (DNN) mimari tasarımında yeni bir yaklaşım sunmuştur (He vd., 2016). ResNet'in en ayırt edici özelliği, "residual bağlantılar" ya da diğer adıyla "skip connections" olarak bilinen yapıları kullanmasıdır. Bu bağlantılar, bir katmanın çıktısının, kendisinden sonraki katmana doğrudan eklenmesini sağlayarak, bilgi kaybını azaltmakta ve derin mimarilerin eğitilebilirliğini artırmaktadır.

Geleneksel mimarilerde ağ derinliği arttıkça karşılaşılan gradyan sönmesi gibi problemler, ResNet'in sunduğu bu "kalıntı öğrenme" veya "artık öğrenme" yapısıyla büyük ölçüde aşılmaktadır. Bu sayede model, çok daha derin katmanlardan oluşmasına rağmen hem daha hızlı hem de daha verimli bir şekilde öğrenme gerçekleştirebilmektedir. ResNet mimarisi, VGGNet gibi klasik yapılara kıyasla daha az parametre ile daha yüksek doğruluk oranlarına ulaşabilmekte; bu da hem model boyutunun küçülmesini hem de hesaplama maliyetlerinin azalmasını sağlamaktadır.

ResNet mimarisi içerisinde en sık kullanılan versiyonlardan biri olan ResNet-50, 50 katmandan oluşan derin yapısıyla oldukça karmaşık özellikleri öğrenme kapasitesine sahiptir. Bu derin yapı, modelin yüksek soyutlama düzeylerinde öğrenme yapmasını mümkün kılar. Ayrıca residual blokların yapısı sayesinde, modelin eğitimi daha kararlı hâle gelmektedir. Bu çalışmada kullanılan ResNet-50 mimarisine ilişkin katman yapısı Şekil 5.4'te sunulmuştur.



Şekil 5. 4. Artık öğrenme (Ergin, 2024).


5.5.3. EfficientNet

EfficientNet, ölçeklenebilirliği yüksek ve performansı optimize edilmiş modern yapay sinir ağı mimarilerinden biridir. 2019 yılında Mingxing Tan ve Quoc V. Le tarafından yayımlanan “Rethinking Model Scaling for Convolutional Neural Networks” başlıklı çalışmada tanıtılan bu mimari, görüntü işleme gibi derin öğrenme tabanlı görevlerde yüksek doğruluk oranlarına ulaşmasının yanı sıra, hesaplama kaynaklarını etkin biçimde kullanma yetkinliğiyle de dikkat çekmektedir (Tan ve Le, 2019).

Tan ve Le’nin önerdiği model, yalnızca ağı derinliğini, genişliğini veya çözünürlüğünü tek başına ölçeklendirmek yerine; bu üç parametrenin dengeli ve birlikte ölçeklendirilmesinin model performansı üzerindeki olumlu etkilerini ortaya koymuştur. Bu doğrultuda geliştirilen "ölçeklendirme katsayısı" yaklaşımı, EfficientNet’in çeşitli versiyonlarının (B0’dan B7’ye kadar) oluşturulmasına imkân sağlamıştır. Model boyutu büyüdükçe parametre sayısı artmakta ve bu artış doğruluk performansına da yansımaktadır. EfficientNet’in temel hedefi, daha küçük ve verimli modellerle yüksek performans elde etmektir. Bu mimari, ağı derinlik, genişlik ve çözünürlük boyutlarını eş zamanlı olarak

optimize ederek geleneksel mimarilere kıyasla daha kompakt yapılar sunar. Ölçeklendirme işleminin ilk adımında, bu üç boyut arasında optimal dengeyi sağlamak amacıyla bir grid search algoritması kullanılır. Bu algoritma, ağın temel yapı taşlarını yeniden boyutlandırarak, kaynak verimliliği açısından en uygun mimariyi belirler (Türkmen, 2021).

Mimari açıdan EfficientNet, MBConv (Mobile Inverted Bottleneck Convolution) adı verilen özel katmanlar kullanılmaktadır. Bu katmanlar, ResNet bloklarından farklı olarak önce kanal boyutunu genişletip ardından daraltan bir yapı izler. Böylelikle bilgi kaybı minimize edilirken, parametre sayısı ve hesaplama maliyetleri de azaltılmış olur. Ayrıca bu bloklar, atlama bağlantıları (skip connections) sayesinde öğrenme sürecini güçlendirmekte ve modelin genelleme kapasitesini artırmaktadır (Sandler vd., 2018). EfficientNetB0 mimarisine ait yapılandırma ve katmanlar Şekil 5.5'te sunulmuştur.



Şekil 5. 5. EfficientNet mimarisi (Ahmed ve Sabab, 2022)


5.5.4. Inception V3

Inception V3, Google tarafından geliştirilen ve Inception mimari ailesine ait olan, görüntü sınıflandırma görevlerinde yüksek başarı sağlayan bir derin öğrenme modelidir (Szegedy vd., 2016). Bu mimari, temel olarak önceki sürüm olan GoogLeNet'e dayanmakta ve verimlilik ile doğruluk arasında dengeli bir yapı sunmaktadır. Model, büyük çekirdekli konvolüsyonları daha küçük ve hesaplama açısından verimli 1x5 ile 5x1 (veya 1x3 ile 3x1) konvolüsyonlara ayrıştırarak hem parametre sayısını azaltmakta hem de temsili kapasiteyi korumaktadır.

Faktörize konvolüsyonların yanı sıra, modelin eğitimi sırasında kullanılan etiket yumuşatma, yardımcı sınıflandırıcılar ve RMSProp optimizasyon algoritması, genelleme yeteneğini ve yakınsama hızını artırmaktadır (Goodfellow vd.,2016). Ayrıca, küme normalizasyonu ile eğitim süresi kısaltılarak daha stabil bir öğrenme sağlanmaktadır (Ioffe ve Szegedy, 2015).

Inception modülleri, farklı boyutlardaki çekirdekleri ve havuzlama işlemlerini tek bir yapıda birleştirerek hem yerel hem de küresel özelliklerin aynı anda öğrenilmesini mümkün kılar. Bu da modelin yüksek doğruluk oranlarına ulaşmasını sağlar. Inception V3, ImageNet yarışmasında %3,5'e kadar düşen top-5 hata oranı ile dönemin en başarılı modellerinden biri olmuştur (Russakovsky vd., 2015).

Modelin modüler ve esnek yapısı, nesne tespiti, segmentasyon ve GAN gibi farklı bilgisayarla görme görevlerine kolayca uyarlanabilmesini sağlamaktadır. Bununla birlikte, yüksek miktarda etiketli veri gereksinimi ve nispeten yüksek hesaplama maliyeti, küçük veri kümelerinde ve gerçek zamanlı uygulamalarda bazı kısıtlamalara yol açmaktadır. Günümüzde ResNet ve EfficientNet gibi mimariler daha yüksek performans sunsa da Inception V3 sağlam yapısı ve genelleme kapasitesi sayesinde hâlâ birçok uygulamada tercih edilmektedir (Tan ve Le, 2019). Inception V3 modelinin mimarisine ait yapılandırma ve katmanlar Şekil 5.6'da sunulmuştur.



Şekil 5. 6. Inception V3 mimarisi (Medium, 2021).

5.5.5. DenseNet

DenseNet, 2017 yılında Huang ve arkadaşları tarafından tanıtılan, derin konvolüsyonel sinir ağlarında bilgi akışını güçlendirmeye yönelik yenilikçi bir mimaridir (Huang vd., 2017). Bu modelde her katman, kendisinden önceki tüm katmanlardan doğrudan giriş alır ve kendi çıktısını da sonraki tüm katmanlara iletir. Bu yoğun bağlantı yapısı, gradyanların erken katmanlara daha kolay ulaşmasını sağlayarak gradyan sönümlenmesi sorununu azaltır (Iandola vd., 2016).


DenseNet'in temel avantajı, öğrenilmiş özelliklerin tekrar kullanılabilmesi ve bu sayede gereksiz hesaplamaların önlenmesidir. Her katman yalnızca yeni ve anlamlı bilgileri öğrenmeye odaklandığı için parametre sayısı azalır, modelin hem doğruluğu hem de hesaplama verimliliği artar (He vd., 2016).

Katmanlar belirli bloklar hâlinde gruplanır ve bu bloklar arasındaki geçiş katmanlarında genellikle 1x1 konvolüsyon ve ortalama havuzlama işlemleri uygulanır. Modelin “büyüme hızı” olarak adlandırılan hiperparametresi, her katmanın üreteceği yeni özellik sayısını belirleyerek performans ile karmaşıklık arasında denge kurar (Zhang vd., 2018).

Özellik paylaşımı sayesinde, DenseNet daha az veriyle daha iyi genelleme yeteneği gösterir. Bu durum özellikle küçük veri kümeleriyle çalışan uygulamalar için önemli bir avantaj sağlar (Gu vd., 2018).

DenseNet-121, -169 ve -201 gibi varyantlar, farklı derinlik ve kaynak kısıtlarına göre tasarlanmıştır. Ayrıca Hybrid DenseNet gibi türev mimariler, başka ağlarla birleştirilerek daha geniş uygulama alanlarına ulaşmıştır (Tan ve Le, 2019).

DenseNet, ResNet gibi önceki mimarilere göre daha az parametreyle daha yüksek doğruluk sunarak, derin öğrenme mimarilerinde önemli bir paradigma değişimi oluşturmuştur. DenseNet modelinin mimarisine ait yapılandırma ve katmanlar Şekil 5.7’de sunulmuştur.



Şekil 5. 7. DensenNet mimarisi (MIR, b.t)

5.5.6. Model 1

Model 1, transfer öğrenme metodlarına ilaveten geliştirilen ilk modeldir. Sınırlı öğrenme kapasitesi ile özellikle referans veya deneysel karşılaştırmalar amacıyla oluşturulmuş oldukça basit bir CNN mimarisidir. Modelin giriş boyutu, yaygın biçimde kullanılan 224x224 piksel ve 3 kanallı (RGB) görüntülerden oluşmaktadır. İlk katmanda yalnızca bir adet 7x7 boyutlu konvolüsyon filtresi kullanılmıştır. Bu kadar düşük sayıda filtre, görsel verideki farklı örüntü ve kenarları ayırt etme kapasitesini ciddi şekilde sınırlandırmaktadır. Ayrıca, adım (stride) değerinin 6 olarak belirlenmesi, giriş görüntüsünün önemli oranda alt örneklenmesine neden olmakta; bu da detayların büyük kısmının daha ağır başında kaybedilmesiyle sonuçlanmaktadır (Simonyan ve Zisserman, 2015; Zeiler ve Fergus, 2014). Konvolüsyon katmanının ardından yer alan 6x6 boyutundaki maksimum havuzlama katmanı, görsel bilginin daha da azalmasına yol açmakta ve öğrenme için kullanılabilecek örüntü miktarını en aza indirmektedir. Bu evrelerin ardından gelen Flatten katmanı, konvolüsyonel çıktıyı düzleştirerek yoğun katmanlara aktarır. Ancak burada yalnızca 5 nörondan oluşan tek bir tam bağlantılı (dense) katman yer almakta olup, bu yapı modelin öğrenebileceği özellik temsillerini ciddi şekilde kısıtlamaktadır. Çıkış katmanında yine 5 nöron yer almakta ve bu katman, softmax aktivasyon fonksiyonu aracılığıyla çok sınıflı (5 sınıf) sınıflandırma görevini gerçekleştirmektedir. Modelin optimizasyonu, RMSprop algoritması ile gerçekleştirilmiştir. RMSprop, adaptif öğrenme oranı güncellemeleriyle

küçük ölçekli modellerde kullanılabilir olsa da SGD veya Adam gibi daha gelişmiş optimizasyon algoritmalarına kıyasla genellikle daha yavaş yakınsama göstermektedir (Tieleman ve Hinton, 2012; Krizhevsky vd., 2012). Genel olarak değerlendirildiğinde, Model 1 filtre ve nöron sayısı bakımından son derece düşük kapasiteye sahiptir. Aynı zamanda aşırı alt örnekleme nedeniyle sınırlı özellik çıkarımı gerçekleştirmektedir. Bu yönüyle model, daha çok performans düşüklüğü oluşturmak veya mimari sınırlamaların etkisini analiz etmek amacıyla deneysel bir temel yapı olarak kullanılmaya uygundur. Çizelge 5.2’de modelin geliştirilmesi gerek yönleri verilmiştir. Çizelge 5.3’de ise modelin diğer transfer öğrenme modelleri ile karşılaştırılması verilmiştir.


Çizelge 5. 2. Model’in geliştirilmesi gereken yönleri

Geliştirilecek Yönler	Açıklama
Filtre Sayısı (1)	Öğrenilecek özellik yetersiz kalır.
Büyük Kernel ve Stride	Detay kaybı yaşanır, küçük desenler öğrenilemez.
Aşırı Havuzlama	Görsel bilgilerin büyük kısmı kaybolur.
Az Nöronlu Dense Katmanı	Öğrenme kapasitesi çok düşüktür.
BatchNorm, Dropout Yok	Düzenleme ve genelleme yeteneği zayıf.
Derinlik Eksikliği	Özellik hiyerarşisi oluşmaz

Çizelge 5. 3. Model 1 modelinin popüler CNN modelleri ile karşılaştırma tablosu

Özellik	Model 1	VGG 19	ResNet 50	EfficientNet B0	Inception V3	DenseNet 121
Katman Sayısı	4+2 (6)	~47	~177	~237	~159	~121
Parametre Sayısı	Çok düşük (<<1M)	~143M	~25M	~5.3M	~23M	~8M
Filtre Sayısı	1	64–512	64–2048	32–1280	32–2048	64–1024
Derinlik	Çok düşük	Derin	Çok derin	Derin ve verimli	Derin	Derin
Atlama Bağlantıları	Yok	Yok	Var	Var	Var (farklı mimari)	Var
Öğrenme Gücü	Çok düşük	Yüksek	Çok yüksek	Verimli yüksek	Yüksek	Yüksek
Parametre Verimliliği	Kötü	Kötü	Orta	Çok iyi	Orta	Çok iyi
Eğitim Hızı	Çok hızlı	Orta	Yavaş	Orta	Yavaş	Orta
Aşırı Öğrenme Riski	Düşük	Yüksek	Orta	Düşük	Orta	Düşük

Model 1'in iyileştirilmesi adına daha küçük kernel boyutları, artan filtre sayısı, daha derin katman yapısı, uygun stride değerleri, dropout ve batch normalization uygulamaları gibi pek çok öneri getirilebilir. Bu tip yapısal ve hiperparametrik düzenlemeler, sonraki modellerde doğruluğu ve genelleme başarısını artıracaktır. Şekil 5.8'de Model 1 mimarisi verilmiştir.



Şekil 5. 8. Model 1 mimarisi

5.5.7. Model 2

Model 2, Model 1'in sınırlılıkları dikkate alınarak yeniden tasarlanmış ve daha derin, optimize edilmiş bir CNN mimarisi olarak yapılandırılmıştır. Tasarım sürecinde düşük öğrenme oranı, katman normalizasyonu (batch normalization), dropout, global average Pooling (küresel ortalama havuzama) ve artan filtre sayıları gibi çağdaş derin öğrenme teknikleri entegre edilmiştir. Bu tür iyileştirme stratejilerinin, sınıflandırma performansını önemli ölçüde artırdığı literatürde geniş biçimde desteklenmektedir (He vd., 2016;

Simonyan ve Zisserman, 2015). Model mimarisi, her biri birer konvolüsyonel bloktan oluşan beş ana katmandan meydana gelmektedir. Her blok içerisinde sırasıyla konvolüsyon, batch normalization, ReLU aktivasyon fonksiyonu ve dropout işlemleri yer almaktadır. Bu yapı, ağıın hem genel performansını artırmakta hem de aşırı öğrenme (overfitting) riskini azaltmaktadır. Konvolüsyonel blokların ardından, boyutsal indirgeme işlemi için global average pooling katmanı kullanılmaktadır. Bu katman, geleneksel tam bağlantılı katmanlara kıyasla daha düşük parametre gereksinimiyle çalışarak öğrenme sürecini hem daha verimli hâle getirmekte hem de modelin genelleme yeteneğini artırmaktadır (Lin vd., 2013). Modelin çıkış katmanında yer alan yoğun katmanlar aracılığıyla beş sınıflı sınıflandırma işlemi gerçekleştirilmektedir. Bu yaklaşım, ResNet (He vd., 2016) ve DenseNet (Huang vd., 2017) gibi modern derin öğrenme mimarilerinde olduğu gibi hem derinliği artırmakta hem de öğrenilen özelliklerin daha anlamlı temsil edilmesini sağlamaktadır. Sonuç olarak, Model 2; artırılmış yapısal derinliği, düzenleyici bileşenleri ve parametrik verimliliği sayesinde pirinç türlerinin doğru şekilde sınıflandırılmasında yüksek bir doğruluk oranı hedeflemektedir.

Model 1'den Model 2'ye Geçişte Gerçekleştirilen Yapısal ve İşlevsel İyileştirmeler

Katman Mimarisi ve Derinlik: Model 1, yalnızca tek bir konvolüsyonel katman ve ardından gelen bir flatten yapısı içeren basit bir mimariye sahiptir. Buna karşın Model 2, daha derin ve optimize bir yapı sunmak amacıyla beş adet konvolüsyonel blok ile yeniden tasarlanmıştır. Bu bloklarda filtre sayısı aşamalı olarak artırılarak (32, 64, 128, 256, 512) daha soyut ve karmaşık özelliklerin çıkarımı hedeflenmiştir. Ayrıca flatten katmanı yerine kullanılan Global Average Pooling yapısı sayesinde parametre sayısı azaltılmış ve modelin genelleme kabiliyeti artırılmıştır.


Katman Dondurma ve Transfer Öğrenmeye Uygunluk: Model 2 sıfırdan eğitildiği için bu aşamada önceden eğitilmiş ağılar veya transfer öğrenme teknikleri kullanılmamıştır. Dolayısıyla herhangi bir katman dondurma işlemi gerçekleştirilmemiştir. Ancak modelin yapısı, ilerleyen aşamalarda transfer öğrenme ve ince ayar (fine-tuning) uygulamalarına olanak sağlayacak şekilde esnek bir biçimde tasarlanmıştır.

Düzenleyici Katmanlar ve Ağ Stabilitesi: Her bir konvolüsyonel bloktan sonra sırasıyla Batch Normalization, ReLU aktivasyon fonksiyonu ve Dropout katmanları entegre

edilmiştir. Bu yapı, eğitim sürecinde ağın stabilitesini artırmakta, öğrenmeyi hızlandırmakta ve aşırı öğrenme riskini azaltmaktadır. Ayrıca, tam bağlantılı katmanların sayısı artırılarak modelin doğrusal sınıflandırma kapasitesi güçlendirilmiştir.

Hiperparametre Ayarları ve Optimizasyon Stratejileri: Model 2'de, daha modern ve yaygın olarak kullanılan Adam optimizasyon algoritması tercih edilmiştir. Öğrenme oranı, daha kararlı ve dengeli bir öğrenme süreci elde edebilmek adına 0,0001 olarak belirlenmiştir. Bu ayarlamalar, modelin eğitim sürecinde daha istikrarlı bir performans göstermesini sağlamaktadır.

Dropout Stratejisi ve Öğrenme Düzenliliği: Modelde kullanılan Dropout oranları, ağın derinliğine bağlı olarak esnek bir biçimde (0,2 ila 0,5 aralığında) katmanlara dağıtılmıştır. Bu düzenleme, modelin öğrenme sürecini dengeleyerek genelleme yeteneğini desteklemektedir. Aynı zamanda, farklı derinlik seviyelerine özgü varyansları kontrol altında tutarak eğitim sürecinin verimliliğini artırmaktadır. Şekil 5.9'da Model 2'nin ayrıntılı mimarisi görsel olarak sunulmaktadır.



Şekil 5. 9. Model 2 mimarisi

Model 2, temel konvolüsyonel sinir ağı yapısının ötesine geçerek daha derin, düzenli ve öğrenme açısından istikrarlı bir mimari sunmaktadır. Model 1'in sınırlı parametre sayısı, düşük filtre kapasitesi ve yetersiz öğrenme kabiliyeti gibi yapısal eksiklikleri; Model 2'de katman sayısının artırılması, batch normalization ve dropout gibi düzenleyici bileşenlerin eklenmesi, global average pooling kullanımı ve daha uygun bir optimizasyon algoritmasının (Adam) tercih edilmesiyle büyük ölçüde giderilmiştir. Özellikle aşırı öğrenmeye (overfitting) karşı uygulanan düzenlemeler ve düşük öğrenme oranı ile desteklenen eğitim süreci, modelin genelleme yeteneğini artırmış ve pirinç türlerinin sınıflandırılması görevinde güçlü ve güvenilir bir temel model ortaya koymuştur. Çizelge 5.4'te Model 1 ile Model 2'nin teknik karşılaştırılması sunulmuştur.

Çizelge 5. 4. Model 1 ile Model 2'nin teknik karşılaştırması

Özellik	Model 1	Model 2
Giriş Boyutu	(224, 224, 3)	(224, 224, 3)
Konvolüsyonel Katman Sayısı	1	10
Filtre Sayıları	1 (sabit)	32, 64, 128, 256, 512
Aktivasyon Fonksiyonu	ReLU	ReLU + Softmax
Havuzlama	MaxPooling2D	Her blok sonrası MaxPooling2D
Dropout Katmanları	Yok	Var (0,2 – 0,5 arası)
Yığın Normalizasyonu	Yok	Her konvolüsyon sonrası
Tam Bağlantılı Katmanlar	1 adet Dense	Dense (1024) → Dense (512) + BN + Dropout
Parametre Azaltımı	Flatten	GlobalAveragePooling2D
Optimizer	RMSprop	Adam
Öğrenme Oranı	0,001	0,0001
Aşırı Öğrenme Önleme	Yok	Dropout, BN, GAP ile desteklenmiş
Genel Başarı	Düşük	Orta-Yüksek (geliştirilmiş mimari)

5.5.8. Model 3

Model 3, önceki model olan Model 2'nin performansını temel alarak mimariyi daha da derinleştiren, öğrenme kapasitesini artıran ve çeşitli düzenleme mekanizmaları aracılığıyla aşırı öğrenme riskini azaltmayı hedefleyen gelişmiş bir CNN mimarisidir. Bu modelin temel amacı, pirinç türlerinin yüksek doğrulukla sınıflandırılmasına olanak tanıyan daha sağlam ve genellenebilir bir yapay sinir ağı altyapısı oluşturmaktır. Bu doğrultuda, transfer öğrenmeye elverişli bir mimari tasarım benimsenmiş; katman bazlı dropout stratejileri, optimize edilmiş hiperparametre değerleri ve modern düzenleme teknikleri bütünlük şeklinde uygulanarak modelin öğrenme süreci istikrarlı ve verimli hâle getirilmiştir. Model 3, derin öğrenme tabanlı görsel sınıflandırma uygulamaları için güçlü bir temel

oluşturmakta ve veri setine özgü sınırlamalara karşı yüksek adaptasyon kapasitesi sergilemektedir.

Model 2'den Model 3'e Geçişte Yapılan Mimari ve Öğrenme Stratejisi Değişiklikleri

Katman Mimarisi ve Derinlik Artırımı: Model 3, önceki modele kıyasla daha derin bir konvolüsyonel yapı sunmaktadır. Her bir konvolüsyon bloğuna ek katmanlar entegre edilerek filtre sayısı artırılmış, bu sayede modelin daha karmaşık ve soyut özellikleri öğrenme kapasitesi genişletilmiştir. Bu derinleşme, özellikle görsel örüntülerin daha yüksek düzeyde temsil edilmesi açısından önemli avantajlar sağlamaktadır.

Katman Dondurma ve Transfer Öğrenmeye Uygunluk: Model 3, transfer öğrenmeye uyarlanabilir bir yapıda tasarlanmıştır. Modelin erken evre konvolüsyon katmanları dondurulmuş; buna karşılık daha üst düzey katmanlar yeniden eğitilebilir şekilde bırakılmıştır. Bu yapılandırma, önceden öğrenilmiş temel özelliklerin korunarak yeni veriye özgü soyutlamaların öğrenilmesini mümkün kılar.

Tam Bağlantılı Katmanlar ve Düzenleme Mekanizmaları: Küresel ortalama havuzlama (GlobalAveragePooling2D) katmanının ardından sırasıyla 1024, 512 ve 256 nörona sahip üç yoğun (Dense) katman eklenmiştir. Bu katmanların her birine %50 oranında dropout uygulanarak modelin aşırı öğrenme yapma riski azaltılmış ve genelleme performansı artırılmıştır. Bu yapı hem sınıflandırma doğruluğunu artırmakta hem de öğrenme sürecinin istikrarını korumaktadır.


Hiperparametre Ayarları ve Optimizasyon: Model 3'te optimize edilmiş hiperparametreler kullanılmış; öğrenme oranı 0,0005 olarak belirlenmiştir. Adam optimizasyon algoritması ile modelin parametre güncellemeleri daha dengeli ve uyarlanabilir biçimde gerçekleştirilmiştir. Dropout oranlarının artırılmasıyla modelin aşırı öğrenmeye karşı dayanıklılığı geliştirilmiştir.

İnce Ayar Yaklaşımı: Model 3, önceki katmanlarda öğrenilmiş temel özellikleri koruyacak şekilde yapılandırılmış, bu katmanlar dondurulmuştur. Üst katmanlar ise yeniden eğitilerek modelin hedef görev olan pirinç sınıflandırmasına özgü ayırt edici örüntüleri öğrenmesi sağlanmıştır. Bu strateji, modelin hem mevcut bilgi birikimini kullanmasını hem de yeni

veriye özgü öğrenmeyi gerçekleştirmesini sağlamaktadır. Model 2'den Model 3'e geçişte yapılan değişiklikler Çizelge 5.5'te verilmiştir. Şekil 5.10'da Model 3 mimarisi verilmiştir.

Çizelge 5. 5. Model 2'den Model 3'e geçişte yapılan değişiklikler

Yapılan Geliştirme	Açıklama
Katman Değişiklikleri	Model 3'te, her bir konvolüsyon bloğu içinde ek konvolüsyon katmanları eklenmiş ve daha fazla filtre kullanılmıştır. Bu sayede daha derin özellik çıkarımı sağlanmıştır.
Katman Dondurma	İlk konvolüsyon katmanları transfer öğrenmeye açık hale getirilerek eğitilebilirliği kısıtlanmış, ileri katmanlar serbest bırakılarak ince ayar yapılmıştır.
Katman Ekleme	Model 3'te GlobalAveragePooling2D katmanı sonrası Dense (1024), Dense (512), Dense (256) şeklinde üçlü bir fully connected yapı oluşturulmuş ve her birinin ardından %50 oranında Dropout uygulanmıştır.
Hiperparametre Optimizasyonu	Öğrenme oranı 0,0005 olarak sabitlenmiş, optimizör olarak Adam tercih edilmiştir. Dropout oranları Model 2'ye kıyasla artırılarak overfitting riski azaltılmıştır.
İnce Ayar	Önceden eğitilmiş bazı temel katmanlar dondurulmuş, yeni eklenen katmanlar üzerine eğitim uygulanarak transfer öğrenme desteklenmiştir.



Şekil 5. 10. Model 3 mimarisi

Model 3, çağdaş derin öğrenme mimarilerinde önerilen prensipler doğrultusunda tasarlanmış, derinlik ile düzenlileştirme arasındaki dengeyi gözetten bir yapı sunmaktadır. Bu yaklaşım, modelin genel doğruluk performansını artırmakla kalmamış, aynı zamanda eğitim sürecinde daha istikrarlı bir optimizasyon sağlamıştır. Ayrıca, transfer öğrenme altyapısının etkin biçimde entegre edilmesi, sınırlı veri setlerinde dahi yüksek başarımlar elde edilmesine imkân tanımaktadır. Çizelge 5.6'da Model 2 ile Model 3'ün teknik karşılaştırılması sunulmuştur.

Çizelge 5. 6. Model 2 ile Model 3'ün teknik karşılaştırılması

Özellikler	Model 2	Model 3
Evrişimsel Katman Sayısı	6	8
Tam Bağlantılı Katmanlar	2 (512, 256)	3 (1024, 512, 256)
Dropout Oranı	0,3 – 0,5	0,2 – 0,5 (Daha yaygın)
Yığın Normalizasyonu	Var	Var (Her blok sonrası)
Küresel Ortalama Havuzlama	Var	Var
Toplam Parametre Sayısı	Daha az	Daha fazla (daha derin yapı)
Öğrenme Oranı	0,001	0,0005 (Daha hassas ayarlanmış)
İnce Ayar	Sınırlı	Aktif olarak uygulanmış
Katman Dondurma	Yok	İlk katmanlarda uygulanmış

5.5.9. Model 4

Model 4, Model 3'ün yüksek doğruluk performansı sağlayan ancak hesaplama maliyeti yüksek yapısından yola çıkılarak, daha yalın, verimli ve kaynak dostu bir mimari hedefiyle tasarlanmıştır. Bu modelin temel amacı, özellikle küçük ölçekli veri kümelerinde görülen aşırı öğrenme (overfitting) riskini minimize etmek, eğitim süresini kısaltmak ve sınırlı donanım kaynaklarında dahi etkin biçimde çalışabilecek optimize bir yapı sunmaktır. Mimari tasarımı katman derinliği azaltılmış, hesaplama yüküne katkısı sınırlı düzenlileştirme katmanları çıkarılmış ve daha kompakt bir yapı benimsenmiştir. Bu sayede, model hem işlem verimliliğini artırmakta hem de daha genel amaçlı uygulamalara uyarlabilir nitelik kazanmaktadır.

Model 3'ten Model 4'e Geçişte Yapılan Mimari Değişiklikler

Katmanlarda Sadeleştirme: Model 3, dört adet derin konvolüsyonel bloktan oluşmakta ve her blok içerisinde Dropout, Batch Normalization ve Global Average Pooling gibi düzenlileştirme katmanlarını barındırmaktadır. Buna karşılık Model 4, bu karmaşık yapıyı

büyük ölçüde sadeleştirerek yalnızca tek bir Conv2D katmanı ile temel özellik çıkarımını gerçekleştirmektedir. Bu sade yaklaşım, özellikle küçük ölçekli veri kümelerinde, modelin daha düşük overfitting eğilimi göstermesini ve daha stabil bir öğrenme süreci sunmasını sağlamaktadır.

Hiperparametre Ayarlamaları: Model 3'te öğrenme oranı özel olarak 0,0005 olarak belirlenmiş ve eğitim süreci bu ayarlama üzerinden yürütülmüştür. Model 4 ise sadeleştirilmiş yapısına uygun olarak, Adam optimizasyon algoritmasını varsayılan hiperparametreleriyle kullanmaktadır. Bu yaklaşım hem eğitim süresini azaltmakta hem de modelin temel doğruluk seviyesini muhafaza etmeyi hedeflemektedir (Kingma ve Ba, 2014).


Tam Bağlantılı Katmanların Basitleştirilmesi: Model 3'te sırasıyla 1024, 512 ve 256 nörondan oluşan üç katmanlı tam bağlantılı (fully connected) yapı mevcuttur. Model 4'te ise yalnızca 10 nörona sahip tek bir gizli katman bulunmaktadır. Bu değişiklik, modelin parametre sayısını önemli ölçüde azaltarak daha hızlı çalışan ve düşük kaynak tüketimiyle çalışan bir yapı sunmuştur.

İnce Ayar Stratejisi: Model 3, derin yapısı sayesinde yüksek öğrenme kapasitesine sahip olmakla birlikte, küçük veri kümelerinde aşırı öğrenme eğilimi sergilemiştir. Model 4 ise mimaride yapılan sadeleştirme ile bu durumu dengelemiş ve genel genelleme performansını artırmayı hedeflemiştir. Bu strateji, düşük donanım kaynaklarına sahip sistemlerde modelin daha işlevsel kullanılmasına olanak tanımaktadır. Çizelge 5.7'de Model 3 ile Model 4'ün teknik karşılaştırılması sunulmuştur.

Çizelge 5. 7. Model 3 ile Model 4'ün teknik karşılaştırılması

Özellik	Model 3	Model 4
Model Tipi	Derin CNN	Basit CNN
Katman Derinliği	20+ katman	5 katman
Evrişim Katmanı	4 blok (64 → 128 → 256x2 → 512x2)	1 Conv2D katmanı
Düzenleştirme	BatchNormalization, Dropout (0,2-0,5)	Yok
Havuzlama Katmanları	4 MaxPooling2D katmanı	1 MaxPooling2D
Tam Bağlantılı Katmanlar	1024 → 512 → 256 + softmax	10 → softmax
Parametre Sayısı	Yüksek (milyonlarca)	Çok düşük
Öğrenme Oranı Ayarı	Adam (learning_rate=0,0005)	Adam (default)
Avantajlar	Yüksek doğruluk	Aşırı öğrenme düşük
Dezavantajlar	Eğitim süresi uzun	Sıbrılı öğrenme

Bu model, basit ve hafif bir CNN mimarisine sahiptir. Tek bir Conv2D katmanı (2 filtre, 3x3 kernel) ve MaxPooling ile temel özellik çıkarımı yapar, ardından tam bağlı (Dense) katmanlarla sınıflandırma yapar. Modelin küçük boyutuna rağmen, Adam optimizer ve ReLU aktivasyonu kullanarak öğrenme yeteneğini optimize etmeyi hedefler. Model 4'ün mimari yapısı Şekil 5.11'de sunulmuştur.



Şekil 5. 11. Model 4 mimarisi

5.5.10. Model 5

Model 5, önceki model olan Model 4'ün sadeleştirilmiş ve hızlı yapısını temel alarak, daha yüksek doğruluk ve öğrenme kapasitesi hedefiyle geliştirilmiş bir derin öğrenme mimarisidir. Bu modelde, katman sayısının artırılması, nöron sayılarının genişletilmesi,

düzenlileştirme (regularization) stratejilerinin uygulanması ve hiperparametrelerin optimize edilmesi gibi yapısal ve eğitsel iyileştirmelere gidilmiştir. Böylece model, daha karmaşık ve soyut örüntüleri öğrenebilecek kapasiteye ulaşmış; aynı zamanda overfitting riski azaltılarak daha yüksek genelleme başarımı elde edilmiştir. Bu gelişmiş yapı, özellikle sınıflar arası benzerliğin yüksek olduğu veri kümelerinde etkin performans göstermektedir.

Model 4'ten Model 5'e Geçişte Yapılan Mimari ve Eğitsel İyileştirmeler

Katman Derinliğinin Artırılması: Model 4'te yalnızca tek bir konvolüsyonel katman yer almakta iken, Model 5'te üç konvolüsyonel blok içinde toplam altı adet Conv2D katmanı yapılandırılmıştır. Bu derinlik artışı, modelin daha soyut ve yüksek düzey özellikleri öğrenebilmesini mümkün kılmış, böylece sınıflar arası ayırım gücü artırılmıştır. Derin mimariler, özellikle karmaşık örüntülerin sınıflandırılmasında öğrenme kapasitesini önemli ölçüde geliştirmektedir.

Yığın Normalleştirme (Batch Normalization) Entegrasyonu: Model 5'in her konvolüsyonel katmanından sonra yığın normalleştirme katmanları eklenmiş; bu sayede modelin ağırlık güncellemeleri sırasında oluşabilecek gradyan patlamaları ve kayıpları önlenmiş, daha istikrarlı ve hızlı bir öğrenme süreci sağlanmıştır. Bu iyileştirme, Model 4'te bulunmayan bir düzenlileştirme unsurudur ve eğitimin konverjans hızını da olumlu yönde etkilemektedir.

Dropout Stratejisinin Uygulanması: Model 4'te dropout mekanizması yer almazken, Model 5'te hem konvolüsyonel bloklar sonrasında hem de tam bağlantılı (fully connected) katmanlardan sonra dropout uygulanmıştır. Özellikle, ara bloklarda %25 ve çıkış öncesi katmanlarda %50 oranında dropout tercih edilmiştir. Bu yapılandırma, overfitting riskini azaltarak modelin genelleme yeteneğini artırmayı hedeflemektedir. (Srivastava vd., 2014)


Tam Bağlantılı Katmanların Genişletilmesi: Model 4'te yalnızca 10 nörondan oluşan tek bir gizli katman kullanılırken, Model 5'te sırasıyla 512 ve 256 nörona sahip iki Dense katman yapılandırılmıştır. Bu düzenleme, sınıflandırma kararlarının daha sağlam ve hassas bir şekilde alınmasına katkı sağlamış; sınıf ayrımlarındaki doğruluğu önemli ölçüde artırmıştır.

Hiperparametre ve Optimizasyon Ayarları: Her iki modelde de Adam optimizasyon algoritması tercih edilmiş olmakla birlikte, Model 5 daha karmaşık bir yapıya sahip olmasına rağmen varsayılan parametrelerle istikrarlı bir eğitim süreci sunmuştur. Adam algoritmasının adaptif öğrenme oranı sayesinde, öğrenme süreci derin mimarilerde bile kararlı bir şekilde ilerlemiştir.

İnce Ayar ve Genişletilebilirlik Yaklaşımı: Model 5, Model 4'ün temel alınmasıyla sıfırdan eğitilebilen bir yapı sunmakta olup, transfer öğrenme mekanizmalarına da uyumlu olacak biçimde esnek olarak tasarlanmıştır. Transfer öğrenme kullanılsa da artırılmış yapısı sayesinde Model 5, küçük veri kümelerinde dahi yüksek doğruluk oranlarına ulaşabilecek potansiyele sahiptir. Çizelge 5.8'de Model 4 ile Model 5'in teknik karşılaştırılması sunulmuştur. Model 5'in mimari yapısı Şekil 5.12'de sunulmuştur.

Çizelge 5. 8. Model 4 ile Model 5'in teknik karşılaştırılması

Özellik	Model 4	Model 5
Model Tipi	Basit CNN	Derinleştirilmiş CNN
Katman Derinliği	5 katman	20+ katman
İki Boyutlu Evrişim Katmanı	1	6
Yığın Normalizasyonu	Yok	Var (her konvolüsyon sonrası)
Dropout Kullanımı	Yok	3 yerde %25, 2 yerde %50
Tam Bağlantılı Yapı	1 katman (10 nöron)	2 katman (512 ve 256 nöron)
Öğrenme Algoritması	Adam (default)	Adam (default)
Avantajları	Basit, hızlı çalışır	Karmaşık örüntüleri öğrenme kapasitesi
Dezavantajları	Sınırlı öğrenme	Daha fazla hesaplama ve bellek ihtiyacı



Şekil 5. 12. Model 5 mimarisi

Model 5'in mimarisi, özellikle orta ölçekli görüntü sınıflandırma problemleri için uygun olup, modern CNN yaklaşımlarının temel bileşenlerini içermektedir. Modelin derin yapısı, karmaşık örüntülerin tanınmasında etkinlik sağlarken, regularizasyon teknikleri sayesinde sınırlı veri setlerinde bile kararlı performans sergileyecek şekilde tasarlanmıştır.

5.5.11. Model 6

Model 6 yapısında ardışık şekilde yapılandırılmış konvolüsyon blokları ile birlikte Batch Normalization, Global Average Pooling ve çok aşamalı Dropout katmanları kullanılarak hem öğrenme kapasitesi artırılmış hem de eğitim süreci boyunca modelin istikrarı sağlanmıştır. Model 5'e kıyasla yapısal olarak daha derin ve geniş kapsamlı olan Model 6, yüksek parametre sayısı ve zenginleştirilmiş mimari yapısıyla daha karmaşık örüntüleri öğrenebilme yeteneğine sahiptir. Ayrıca aşırı öğrenme (overfitting) riskini azaltmak amacıyla, her blokta düzenleme katmanlarının sistematik entegrasyonu gerçekleştirilmiş, böylece modelin genelleme performansı anlamlı biçimde yükseltilmiştir. Modelin bu bileşenleri, eğitim doğruluğunu artırmanın yanı sıra test verisi üzerindeki performansı da dengede tutmayı amaçlamaktadır.

Model 5'ten Model 6'ya Geçişte Yapılan Mimari ve Optimizasyonel İyileştirmeler

Katman Yapısında Derinleştirme ve Topolojik Genişleme: Model 6'da Model 5'in üç konvolüsyonel blok yapısı genişletilerek dördüncü bir konvolüsyon bloğu entegre edilmiştir. Bu yeni blokta yer alan 256 filtreli ek Conv2D katmanları, daha derin ve ayrıntılı özellik çıkarımı yapmayı mümkün kılarak modelin öğrenme kapasitesini artırmıştır. Buna ek olarak, Model 5'te kullanılan Flatten katmanı yerine GlobalAveragePooling2D katmanı tercih edilmiştir. Bu yapılandırma, modelin parametre sayısını anlamlı ölçüde azaltarak hem hesaplama verimliliğini artırmış hem de aşırı öğrenme (overfitting) riskini azaltarak genelleme yeteneğini güçlendirmiştir.

Hiperparametre Ayarı ve Düzenleme Stratejileri: Her iki modelde de Adam optimizasyon algoritması kullanılmış olmakla birlikte, Model 6'da öğrenme oranı sabitlenmiş şekilde 0,0005 olarak optimize edilmiştir. Bu düşük öğrenme oranı, daha hassas ağırlık güncellemelerine olanak sağlayarak öğrenme sürecinde daha stabil ve kontrollü bir seyir sağlamıştır (Kingma ve Ba, 2015). Ayrıca, konvolüsyon bloklarının her

birinden sonra sırasıyla %20, %30 ve %40 oranlarında Dropout uygulanmış; bu yapı tam bağlantılı katmanlardan önce %50 Dropout ile tamamlanmıştır. Bu kademeli düzenleme stratejisi, ağıın genelleme performansını artırırken yüksek doğruluk seviyelerine ulaşmasına da katkı sunmuştur.

Tam Bağlantılı Katmanlarda İyileştirilmiş Derinlik ve Düzenleme: Model 6, Tam bağlantılı katman yapısını Model 5'teki mimariyle benzer biçimde 512 ve 256 nörondan oluşan iki katman üzerinden sürdürmekle birlikte, bu katmanlardan önce uygulanan yüksek oranlı Dropout (0,5), bilgi kaybını dengeleyerek genelleme yeteneğini daha da artırmıştır. Bu düzenleme, öğrenilen temsillerin daha sağlam ve kararlı olmasını sağlamış, aşırı öğrenme eğilimini kontrol altında tutmuştur.


İnce Ayar Yaklaşımına Uygun Mimari Tasarım: Model 6 her ne kadar sıfırdan eğitilecek biçimde yapılandırılmış olsa da optimizasyon (modelin öğrenmesini sağlayan matematiksel yöntem) yapılandırması, düşük öğrenme oranı tercihi ve yoğun Dropout kullanımı gibi bileşenler sayesinde ince ayar prensipleriyle uyumlu bir çerçeve sunmaktadır. Bu yaklaşım, modelin hassas parametre güncellemeleriyle daha derin temsilleri istikrarlı biçimde öğrenebilmesini mümkün kılmıştır. Çizelge 5.9'de Model 5 ile Model 6'nın teknik karşılaştırılması sunulmuştur.

Çizelge 5. 9. Model 5 ve Model 6'nın teknik karşılaştırılması

Özellik	Model 5	Model 6
Evrişim Bloğu Sayısı	3	4
Düzleştirme Katmanı	Var	Yok
Küresel Ortalama Havuzlama	Yok	Var
Dropout Katmanları	0,25 (sabit)	Artan (0,2 → 0,4)
Tam Bağlantılı Yapı	512 → 256	512 → 256
Optimizasyon Algoritması	Adam (varsayılan)	Adam (özel learning rate: 0,0005)
Yığın Normalizasyonu	Var	Var
Aşırı Öğrenme Önlemleri	Düşük	Yüksek (dropout + GAP + özel LR)
Parametre Sayısı	Daha fazla (Flatten)	Daha az (GAP sayesinde)
Eğitim Performansı	Daha hızlı overfitting	Daha dengeli öğrenme

Model 6, görüntü tabanlı sınıflandırma görevleri için optimize edilmiş, derinleştirilmiş bir konvolüsyonel sinir ağı mimarisidir. Dört ardışık evrişim bloğu, Yığın Normalizasyonu ve Dropout katmanları ile birlikte yapılandırılarak hem öğrenme istikrarı hem de genelleme başarımı artırılmıştır. Flatten yerine kullanılan GlobalAveragePooling2D, parametre

sayısını azaltarak aşırı öğrenme riskini düşürürken, yüksek boyutlu tam bağlantılı katmanlar modelin karar verme kapasitesini güçlendirmiştir. Bu yapı, sınıflandırma doğruluğu yüksek, düzenlileştirme stratejileriyle desteklenmiş modern bir CNN mimarisi sunmaktadır. Model 6'nın mimari yapısı Şekil 5.13'de sunulmuştur.



Şekil 5. 13. Model 6 mimarisi

5.5.12. Model 7

Model 7, pirinç tanelerinin görüntü tabanlı sınıflandırılmasına yönelik geliştirilen modeller arasında en yüksek doğruluk oranına ulaşan, ileri düzey bir konvolüsyonel sinir ağı (CNN) mimarisidir. Bu model, Model 6'nın güçlü yapısal bileşenlerini temel alarak tasarlanmış; ancak hesaplama verimliliğini artırmak, öğrenme sürecinde istikrarı sağlamak ve genelleme kapasitesini daha da geliştirmek amacıyla çeşitli yapısal ve parametrik iyileştirmelerle yeniden yapılandırılmıştır.

Model 7, derin konvolüsyonel bloklar, Yığın Normalizasyonu, Küresel Ortalama Havuzlama ve çok aşamalı Dropout uygulamaları gibi düzenlileştirme tekniklerini entegre bir biçimde kullanarak aşırı öğrenmeyi minimize etmiş ve modelin genel doğruluk performansını maksimize etmiştir. Ayrıca, hiperparametrelerin (özellikle öğrenme oranı ve dropout oranları) deneysel olarak optimize edilmesiyle, eğitim sürecinin hem daha kararlı hem de daha hızlı ilerlemesi sağlanmıştır. Bu mimari yapı, karmaşık örüntüleri öğrenme kapasitesi yüksek, aynı zamanda kompakt ve verimli bir CNN çözümü sunmaktadır.

Model 6'dan Model 7'ye Geçişte Yapılan Mimari ve Parametrik İyileştirmeler

Yığın Normalizasyonu Konumlandırmasının Yeniden Düzenlenmesi: Model 6'da her Conv2D katmanından sonra doğrudan uygulanan Yığın Normalizasyonu işlemi, Model 7'de her iki konvolüsyon katmanından sonra bir kez uygulanacak şekilde yeniden konumlandırılmıştır. Bu düzenleme, eğitim sürecinin hesaplama yükünü azaltırken, aynı zamanda bellek kullanımını optimize ederek daha verimli bir eğitim süreci sağlamıştır.

Konvolüsyonel İşleme Zincirinin Derinleştirilmesi: Model 7'de, her konvolüsyon bloğu içerisinde bir yerine iki ardışık Conv2D katmanının kullanılmasıyla, blok sayısı sabit tutulurken toplam katman derinliği artırılmıştır. Bu yaklaşım, modelin parametrik yükünü dramatik şekilde artırmadan daha yüksek seviye özellik temsilleri elde etmesine olanak tanımıştır. Aynı zamanda, çok aşamalı filtreleme işlemi, karmaşık örüntülerin öğrenilmesine katkı sağlamıştır.

Dropout Oranlarının Kademeli Artırılması: Model 6'da sabit oranlarla uygulanan Dropout, Model 7'de özellikle derin katmanlarda artırılarak (%40 → %50) daha agresif bir düzenleme politikası benimsenmiştir. Bu değişiklik, modelin aşırı öğrenme eğilimini sınırlayarak genelleme başarımını artırmıştır.

Hiperparametre Ayarlamaları ve Eğitim Dinamikleri: Model 6'da kullanılan 0,0005 öğrenme oranı, Model 7'de 0,0003 seviyesine indirilmiştir. Daha düşük öğrenme oranı, modelin ağırlık güncellemelerini daha hassas gerçekleştirmesine olanak tanımış; bu da eğitim sürecinin daha dengeli ilerlemesini ve doğruluk düzeyinin artmasını sağlamıştır.

İşlem Derinliği ve Blok Sayısı ile İlgili Ayarlamalar: Model 7'de toplam blok sayısı Model 6 ile aynı tutulmuş, ancak her blokta yer alan ardışık Conv2D katmanları sayesinde özellik çıkarım zinciri derinleştirilmiştir. Böylece parametre sayısının kontrol altında tutulması sağlarken, modelin temsil kapasitesi yükseltilmiştir.


İnce Ayar Stratejilerinin Uygulanabilirliği: Model 7, sıfırdan eğitim için yapılandırılmış olmasına rağmen, sahip olduğu optimize edilmiş yapı sayesinde ince ayar stratejilerine uyumlu hale getirilmiştir. Özellikle öğrenme hızı, dropout oranları, yığın normalizasyonu konumlandırması ve konvolüsyonel yapıdaki mikro düzeyde iyileştirmeler sayesinde,

model hem farklı veri kümelerine kolayca adapte olabilmekte hem de transfer öğrenme uygulamalarında güçlü bir başlangıç noktası sunmaktadır. Bu yapılandırma, Model 7'yi yalnızca bir sınıflandırma modeli değil, aynı zamanda esnek bir derin öğrenme çerçevesi haline getirmiştir. Çizelge 5.10'da Model 6 ile Model 7'nin teknik karşılaştırılması sunulmuştur.

Çizelge 5. 10. Model 6 ve Model 7'nin teknik karşılaştırması

Özellik	Model 6	Model 7
Evrişim Bloğu Sayısı	4	4
2D Evrişim Katmanı Tekrar Sayısı	Her blokta 2 Conv2D + BN	Her blokta 2 Conv2D ardından tek BN
Yığın Normalizasyonu	Her Conv2D'den sonra	Her blok sonunda tek BN
Dropout Oranları	0,2 → 0,3 → 0,4 → 0,4	0,2 → 0,3 → 0,4 → 0,5
Tam Bağlantılı Yapı	512 → 256	512 → 256
Flatten	Yok (GAP kullanıldı)	Yok (GAP kullanıldı)
Küresel Ortalama Havuzlama	Var	Var
Optimizer	Adam (lr = 0,0005)	Adam (lr = 0,0003)
Öğrenme Kararlılığı	İyi	Daha kararlı (düşük LR)
Aşırı Öğreme Önleme	Orta	Yüksek (dropout + düşük LR)
En Yüksek Doğruluk	Orta-Yüksek	En yüksek doğruluk

Model 7, her biri iki ardışık 3×3 konvolüsyon katmanı ve yığın normalizasyonu içeren hiyerarşik yapıda tasarlanmıştır. Global average pooling ile parametre verimliliği sağlanırken, kademeli artan dropout oranları (0,2-0,5) ile regularizasyon gerçekleştirilmiştir. Optimizasyon için düşük öğrenme oranlı (0,0003) Adam optimizer kullanılarak stabil bir eğitim süreci hedeflenmiştir. Bu mimari, orta ölçekli görüntü sınıflandırma problemlerinde etkin bir şekilde uygulanabilir. Model 7'nin mimari yapısı Şekil 5.14'te sunulmuştur.



Şekil 5. 14. Model 7 mimarisi

Bu tez çalışmasında, geleneksel CNN mimarilerinin yanı sıra, özelleştirilmiş yedi farklı model (Model 1'den Model 7'ye) tasarlanarak, pirinç tanelerinin görüntü tabanlı sınıflandırmasında doğruluk oranını sistematik biçimde artırmak hedeflenmiştir. Her bir model, bir önceki mimarinin güçlü ve zayıf yönleri analiz edilerek yapılandırılmış; katman sayısı, filtre derinliği, normalizasyon (modelin dengeli öğrenmesi için verilerin standartlaştırılması) teknikleri, havuzlama stratejileri, dropout (aşırı öğrenmeyi önlemek için nöronların rastgele devre dışı bırakılması) oranları ve optimizasyon parametrelerinde kademeli iyileştirmeler yapılmıştır. Bu ardışık geliştirme süreciyle Model 1'den başlayarak her aşamada performans artırımı sağlanmış ve nihai olarak geliştirilen Model 7, test verisi üzerinde en yüksek doğruluk oranına ulaşarak, modern derin öğrenme mimarileriyle rekabet edebilecek düzeyde bir başarı ortaya koymuştur. Söz konusu yaklaşım, hem mimari tasarım ilkelerinin deneysel olarak sınanmasını hem de özelleştirilmiş bir CNN yapısı ile tarımsal ürün sınıflandırmasında yüksek performans elde edilmesini mümkün kılmıştır. Bu bağlamda geliştirilen modellerin teknik olarak karşılaştırılması Çizelge 5.11'd sunulmuştur.

Çizelge 5. 11. Modellerin karşılaştırılma tablosu

Özellikler	Model 1	Model 2	Model 3	Model 4	Model 5	Model 6	Model 7
Yığın Normalizasyonu	Yok	Var	Var	Yok	Var	Var	Var
Dropout	Yok	Var	Var	Yok	Var	Var	Var
Küresel Ortalama Havuzlama	Yok	Var	Var	Yok	Yok	Var	Var
Tam Bağlantılı Katman	Var	Var	Var	Yok	Var	Var	Var
Derinlik	Orta	Orta	Derin	Orta	Yüksek	Yüksek	Yüksek
Parametre Sayısı	Çok Düşük	Düşük	Çok Yüksek	Düşük	Yüksek	Yüksek	Yüksek
Aşırı Öğrenme Riski	Orta	Düşük	Yüksek	Düşük	Çok düşük	Çok düşük	Düşük
Genelleme Gücü	Zayıf	Orta	Zayıf	Orta	Yüksek	Yüksek	Çok yüksek
Eğitim Hızı	Normal	Hızlı	Yavaş	Hızlı	Orta	Biraz yavaş	Orta
Stabilite (Loss)	Düşük	Orta	Düşük	Orta	Yüksek	Yüksek	Yüksek
Doğrulama Doğruluğu	Düşük	Orta	Düşük-Orta	Orta+	Yüksek	Yüksek +	En yüksek
İnce ayar	Yok	Var	Var	Var	Var	Var	Var
Optimizör	RMSprop	Adam	Adam	Adam	Adam	Adam	Adam
Özellik Çıkarımı	Basit	Gelişmiş	Daha gelişmiş	Çok gelişmiş	Çok gelişmiş	Hızlı derin	En ileri seviye

6. BULGULAR

Sınıflandırma, veri analizi ve öngörülebilirlik bağlamında kritik bir rol oynamakta olup, belirli bir veri kümesindeki örneklerin önceden tanımlanmış kategorilere veya sınıflara atanmasını amaçlayan denetimli bir öğrenme yaklaşımıdır (Alan ve Karabatak, 2020).

Pirinç türlerinin sınıflandırılmasına yönelik bu tez çalışmasında, Murat Köklü tarafından oluşturulmuş ve araştırmacıların erişimine açık şekilde paylaşılan farklı türlere ait görsellerin yer aldığı kapsamlı bir veri seti kullanılmıştır (Koklu, 2020). Veri seti; Basmati, Arborio, Karacadağ, İpsala ve Jasmine olmak üzere beş farklı pirinç türünden toplam 75 000 adet etiketlenmiş görüntü içermektedir. Bu görüntüler MATLAB yazılımı yardımıyla ön işlemlerden geçirilerek görüntü üzerinde bulunabilecek istenmeyen maddelerden arındırılmış ve özellik çıkarımı aşamasına hazırlanmıştır. Çalışmada, farklı pirinç türlerinin ve kalite derecelerinin belirlenmesinde derin öğrenme tabanlı bir model geliştirilmesi ve bu modelin iyileştirilmesi hedeflenmektedir. Bunun için Evrişimsel Sinir Ağları (CNN) gibi yaygın olarak kullanılan derin öğrenme mimarilerinden yararlanılmıştır.

Modellerin performansı; doğruluk (accuracy), genel başarı düzeyi, öğrenme kabiliyeti ve uygulama esnekliği gibi çeşitli metrikler çerçevesinde değerlendirilmiş, elde edilen sonuçlar karşılaştırmalı olarak sunulmuştur.

6.1. Başarım Ölçütleri

Derin öğrenme modellerinin başarımını değerlendirmek amacıyla kullanılan performans metrikleri, modelin sınıflandırma görevlerindeki etkinliğini nicel olarak ortaya koyar ve genel başarı düzeyini belirlemede önemli bir rol oynar (Ünal, 2015). Bu çalışmada, önceden eğitilmiş derin öğrenme mimarileri (ESA modelleri) arasından VGG16, ResNet50 ve EfficientNetB6, Inception V3 ve DenseNet yapıları ile tez aşamasında oluşturduğumuz Model 1, Model 2, Model 3, Model 4, Model 5, Model 6 ve Model 7 yapıları detaylı olarak incelenmiş ve sınıflandırma performansları karşılaştırılmıştır. Değerlendirme sürecinde; karmaşıklık matrisi (confusion matrix), F1 skoru (F1-score), kayıp değeri (loss), doğruluk oranı (accuracy) ve ROC eğrisi (Receiver Operating Characteristic Curve) gibi temel performans metrikleri kullanılarak modellerin sınıflandırma başarımı analiz edilmiştir.

6.1.1. Karmaşıklık matrisi

Sınıflandırma modellerinin doğruluk oranları sıklıkla performans göstergesi olarak paylaşılacakla birlikte, bu tekil metriğin model başarımını tam anlamıyla yansıtmayı yansıtmadığı konusunda çeşitli belirsizlikler bulunmaktadır. Özellikle dengesiz veri kümelerinde doğruluk değeri yanıltıcı olabilir. Bu nedenle, modelin sınıflandırma yeteneğini daha kapsamlı bir şekilde değerlendirmek ve hataların doğasını daha iyi analiz edebilmek amacıyla çeşitli performans analiz yöntemleri geliştirilmiştir. Bu yöntemlerden en yaygın ve açıklayıcı olanlardan biri karmaşıklık matrisidir. Karmaşıklık matrisi, bir sınıflandırma modelinin tahmin performansını gerçek etiketlerle karşılaştırarak özetleyen ve modelin hangi sınıflarda ne tür hatalar yaptığını ayrıntılı biçimde ortaya koyan bir tablodur (Wu, 2022; Aliyev ve Güneş, 2023). Bu matris, modelin çıktılarının dört temel bileşenini içerir:


- Gerçek Pozitif (True Positive- TP): Modelin pozitif sınıfa ait bir örneği doğru biçimde pozitif olarak tahmin ettiği durumların sayısıdır.
- Gerçek Negatif (True Negative- TN): Modelin negatif sınıfa ait bir örneği doğru biçimde negatif olarak tahmin ettiği durumların sayısıdır.
- Yanlış Pozitif (False Positive- FP): Modelin negatif sınıfa ait bir örneği hatalı şekilde pozitif olarak tahmin ettiği durumların sayısıdır.
- Yanlış Negatif (False Negative- FN): Modelin pozitif sınıfa ait bir örneği hatalı şekilde negatif olarak tahmin ettiği durumların sayısıdır.

Bu dört temel unsurdan hareketle, modelin duyarlılığı (recall), özgüllüğü (specificity), kesinliği (precision) ve F1 skoru gibi daha kapsamlı performans metrikleri türetilir. Böylece modelin yalnızca genel doğruluğu değil, aynı zamanda hata türlerine karşı duyarlılığı da değerlendirilebilir.

Beşli sınıflandırma problemlerinde karmaşıklık matrisi, modelin her bir sınıf için yaptığı doğru ve hatalı tahminlerin sayısal olarak değerlendirilmesini sağlayan temel bir analiz aracıdır (Şekil 6.1). Matrisin satırları gerçek sınıfları, sütunları ise modelin tahmin ettiği sınıfları temsil eder. Bu yapı sayesinde modelin sınıflar arasında ne ölçüde ayırım

yapabildiği sistematik şekilde analiz edilebilir. Çalışmada yer alan sınıflar Basmati, Arborio, Karacadağ, İpsala ve Jasmine olarak tanımlanmıştır. Bu sınıflar doğrultusunda oluşturulan 5x5 boyutundaki karmaşıklık matrisi, her bir gözlemin hangi sınıfta yer aldığını ve model tarafından hangi sınıfa atandığını gösterir. Diyagonal üzerindeki hücreler doğru sınıflamaları, diyagonal dışındaki hücreler ise hatalı sınıflamaları yansıtır. Doğru sınıflamaların yüksek olması, modelin ilgili sınıfları başarılı şekilde ayırt ettiğini gösterirken; yanlış sınıflamaların fazlalığı, sınıflar arası karışıklığın varlığına işaret eder.

Karmaşıklık matrisi üzerinden doğruluk, yanlış pozitif ve yanlış negatif oranları gibi temel performans ölçütleri hesaplanabilir. Ayrıca sınıf bazlı kesinlik, duyarlılık ve F1-skor gibi metriklerin elde edilmesine de olanak tanır. Bu yönüyle karmaşıklık matrisi, model başarımının ayrıntılı ve bütüncül olarak değerlendirilmesini sağlayan önemli bir yapıdır.



Şekil 6. 1. Beşli sınıflandırma için örnek bir karmaşıklık matrisi

6.1.2. Doğruluk (Accuracy)

Doğruluk, bir sınıflandırma modelinin genel performansını değerlendirmek amacıyla en sık kullanılan temel ölçütlerden biridir. Modelin doğru sınıflandırdığı örneklerin, toplam örnek sayısına oranını ifade eder. Bu metrik, modelin ne ölçüde isabetli tahminlerde bulunduğunu gösterir. Değeri 0 ile 1 arasında değişmekte olup, 1'e yaklaştıkça modelin başarımı artmaktadır. Doğruluk, özellikle dengeli veri kümelerinde anlamlı bir gösterge

olmakla birlikte, sınıf dağılımının dengesiz olduğu durumlarda tek başına yeterli olmayabilir. Bu nedenle, diğer performans ölçütleriyle birlikte yorumlanması önerilmektedir. Hesaplaması Denklem 6.1’de sunulan formül ile gerçekleştirilmektedir.

$$\text{Doğruluk} = (TN + TP) / (TP + FP + FN + TN) \quad (6.1)$$

6.1.3. Duyarlılık (Recall)

Duyarlılık, pozitif sınıfa ait örneklerin doğru şekilde tahmin edilme oranını gösteren temel bir performans ölçütüdür. Özellikle kritik durumların tespit edilmesinde, örneğin hastalık tanısı gibi pozitif sınıfların kaçırılmasının önemli sonuçlar doğurabileceği uygulamalarda büyük önem taşır. Bu metrik, modelin pozitif örnekleri ne ölçüde doğru tanımlayabildiğini değerlendirir. İlgili hesaplama Denklem 6.2’de sunulmuştur.

$$\text{Duyarlılık} = TP / (TP + FN) \quad (6.2)$$

6.1.4. Kesinlik (Precision)

Kesinlik (precision), bir sınıflandırma modelinin pozitif olarak tahmin ettiği örneklerin ne kadarının gerçekten pozitif olduğunu gösteren temel bir performans ölçütüdür. Özellikle yanlış pozitif tahminlerin minimize edilmesinin önemli olduğu uygulamalarda, modelin güvenilirliğini değerlendirmek açısından kritik bir rol oynar. İlgili hesaplama Denklem 6.3’te sunulmaktadır.

$$\text{Kesinlik} = TP / (TP + FP) \quad (6.3)$$

6.1.5. F1 skor (F1-score)

F1 skor, bir sınıflandırma modelinin performansını değerlendirmek amacıyla kesinlik ve duyarlılık değerlerinin harmonik (özellikle dengesiz sınıflarda duyarlılığı ve kesinliği birlikte değerlendiren ortalama türü) ortalamasını esas alan bileşik bir ölçüttür. Özellikle sınıf dengesizliğinin bulunduğu veri setlerinde, modelin pozitif sınıfları hem doğru hem de eksiksiz biçimde tahmin etme yeteneğini daha dengeli şekilde yansıtır. İlgili hesaplama Denklem 6.4’te sunulmaktadır.

$$\text{F1 Skor} = 2 * (\text{Duyarlılık} * \text{Kesinlik}) / (\text{Duyarlılık} + \text{Kesinlik}) \quad (6.4)$$

6.1.6. Logaritmik kayıp (Log loss)


Logaritmik kayıp, bir modelin tahmin ettiği olasılık dağılımı ile gerçek sınıf etiketleri arasındaki uyumsuzluğu ölçen bir performans metriğidir. Her bir örnek için doğru sınıfa atanan olasılık değeri üzerinden hesaplanır ve bu değer küçüldükçe modelin tahmin doğruluğu artar. Özellikle çok sınıflı sınıflandırma problemlerinde ve olasılığa dayalı tahminlerde modelin güvenilirliğini değerlendirmek amacıyla yaygın olarak kullanılmaktadır.

6.1.7. ROC eğrisi (ROC curve)

ROC (Receiver Operating Characteristic) eğrisi, farklı eşik değerlerinde duyarlılık ile özgüllük arasındaki ilişkiyi görselleştirir. AUC (Area Under the Curve), ROC eğrisinin altındaki alanı ifade eder. AUC-ROC eğrisi, sınıflandırma modellerinin ayırım gücünü değerlendirmek amacıyla kullanılan önemli bir performans ölçütüdür. AUC değeri, modelin pozitif ve negatif sınıfları ne ölçüde doğru şekilde ayırt edebildiğini gösterir. AUC'nin yüksek olması, modelin sınıflar arasında güçlü bir ayırım yeteneğine sahip olduğunu ve özellikle hastalık tanısı gibi kritik uygulamalarda güvenilir tahminler yapabildiğini gösterir. Şekil 6.2'de ROC eğrisi görsel olarak sunulmaktadır. Roc eğrisi hesaplama formülü Denklem 6.5 ve Denklem 6.6' da verilmiştir.

$$TPR = TP / (TP + FN) \quad (5.5)$$

$$FPR = FP / (FP + TN) \quad (5.6)$$



Şekil 6. 2. ROC eğrisi tanımlaması (Tao, 2021)

6.1.8. Intersection over union (IoU)

İki kümenin örtüşme miktarını ölçen bu metrik, özellikle bilgisayarla görme ve görüntü işleme alanlarında yaygın olarak kullanılmaktadır. Nesne tespiti ve segmentasyon algoritmalarının performansını değerlendirmek için önemli bir araçtır (Aydın vd., 2023). Intersection over Union (IoU) değerinin 1'e yakın olması, tespit edilen ve gerçek alanlar arasında yüksek bir örtüşme olduğunu ve modelin başarılı bir şekilde doğru alanları belirlediğini gösterir. Bu durum Denklem 6.7'de formüle edilmiştir.

$$\text{IoU} = \text{iki kümenin kesişim alanı} / \text{iki kümenin birleşim alanı} \quad (6.7)$$

6. 2. Transfer Öğrenme Eğitim Verileri

Bu çalışmada, pirinç türlerinden "Arborio", "Basmati", "Jasmine", "Karacadağ" ve "İpsala" sınıflandırması için evrimsel sinir ağlarına (ESA) dayalı çeşitli modeller kullanılmıştır. Bu modeller arasında VGG16, ResNet50, Inception V3, DenseNet, EfficientNetB6 ve tez aşamasında geliştirilen yeni yedi modelin mimarileri yer almaktadır.

Veri seti, <https://www.muratkoklu.com/datasets/> adresinden temin edilmiştir ve beş pirinç türüne ait toplamda 75.000 (her bir tür için 15 000) pirinç fotoğrafı içermektedir. Bu fotoğraflardan 12 000'i eğitim verisi, 3 000'i ise doğrulama verisi olarak ayrılmıştır. Eğitim verileri ve veri setine ait örnekler, Çizelge 6.1'de sunulmakta olup, Resim 6.1, Resim 6.2, Resim 6.3, Resim 6.4 ve Resim 6.5'te veri seti örnekleri görsel olarak gösterilmektedir.

Çizelge 6. 1. Eğitim verileri

Toplam Resim Sayısı (her bir tür için)- 15 000 Adet	
Eğitim için ayrılan resim %80-12 000	Doğrulama için ayrılan resim %20-3 000


Bu tez çalışmasında, ESA mimarileri olarak VGG16, ResNet50, EfficientNetB6, DenseNet ve InceptionV3 kullanılmış olup, model geliştirme sürecinde Keras ve TensorFlow kütüphanelerinden yararlanılmıştır. Çalışma ortamı olarak Jupyter IDE tercih edilmiştir. Modellerin performanslarını eşit bir şekilde değerlendirebilmek amacıyla eğitim süreci, Intel® 3. Nesil Core™ i7-3630QM işlemci ve NVIDIA GeForce GT 650M ekran kartına sahip bir bilgisayar üzerinde gerçekleştirilmiş ve karmaşıklık matrisleri hesaplanmıştır.




Resim 6. 1. Arborio pirinç resimleri (15 000 adet)




Resim 6. 2. Basmati pirinç resimleri (15 000 adet)



Resim 6. 3. İpsala pirinç resimleri (15 000 adet)



Resim 6. 4. Jasmine pirinç resimleri (15 000 adet)



Resim 6. 5. Karacadağ pirinç resimleri (15 000 adet)


6.3. Transfer Öğrenme Modelleri Performansları

Transfer öğrenme, bir modelin bir görevde kazandığı bilgiyi farklı bir görevde yeniden kullanma yöntemidir (Çiftçi ve Tekin, 2023). Bu çalışmada, transfer öğrenme yaklaşımını kullanan modellerin performansları detaylı bir şekilde değerlendirilmiştir.


6.3.1. VGG16 modeli performansı

Veri seti, modelin eğitim ve test süreçlerinde kullanılmak üzere %80 eğitim ve %20 test olarak ayrılmıştır. Görseller, 224 x 224 piksel boyutunda yeniden boyutlandırılmıştır. Modelin eğitim süreci sırasında, görseller "Arborio", "Basmati", "Jasmine", "Karacadağ" ve "İpsala" sınıfları altında etiketlenmiştir. VGG16 modeline ait performans


değerlendirmeleri, karmaşıklık matrisi Şekil 6.3'te, kayıp ve doğrulama değerleri Şekil 6.4'te, ROC eğrisi Şekil 6.5'te ve eğitim sürecine ilişkin değerlendirme verileri Çizelge 6.2'de sunulmaktadır.



Şekil 6. 3. VGG16 modeli karmaşıklık matrisi



Şekil 6. 4. VGG16 modeli kayıp ve doğrulama değerleri




Şekil 6. 5. VGG16 modeli ROC eğrisi

Çizelge 6. 2. VGG16 modeli değerlendirme verileri

Pirinç Türü	Kesinlik	Duyarlılık	F1-Skor	Veri Sayısı
Arborio	0,99	0,99	0,99	3 000
Basmati	1,0	0,99	0,99	3 000
İpsala	1,0	0,99	1,0	3 000
Jasmine	0,98	1,0	0,99	3 000
Karacadağ	0,99	0,99	0,99	3 000
Doğruluk	0,99			15 000
Sınıf Bazlı Ortalama	0,99	0,99	0,99	15 000
Ağırlıklı Ortalama	0,99	0, 99	0,99	15 000

Modelin genel doğruluğu %99 (0,99) olarak hesaplanmıştır, bu da tüm sınıflarda yüksek doğrulukla tahminlerde bulunulduğunu ve genel performansın başarılı olduğunu göstermektedir. Makro ortalama hesaplamaları da aynı başarıyı yansıtarak, kesinlik, duyarlılık ve F1-skor değerlerinin tamamının %99 (0,99) olduğunu ortaya koymaktadır. Bu, modelin her sınıfta tutarlı bir performans sergilediğini ifade etmektedir. Ağırlıklı ortalama metrikleri de %99 (0,99) olarak hesaplanmış olup, sınıfların eşit sayıda örnekle temsil edilmesi nedeniyle makro ortalama ile uyumlu bir sonuç elde edilmiştir. Arborio sınıfı için kesinlik değeri 0,99 duyarlılık değeri 0,99 ve F1-skor değeri 0,99 olarak hesaplanmıştır, bu da modelin Arborio sınıfında yüksek doğrulukla tahmin yapıldığını ve iyi bir denge sağladığını göstermektedir. Basmati sınıfında kesinlik 1,00 duyarlılık 0,99 ve F1-skor 0,99 olarak belirlenmiş, bu da modelin Basmati sınıfında mükemmel bir


doğrulukla tahmin yaptığı, ancak duyarlılık değerinin biraz daha düşük olduğunu göstermektedir. İpsala sınıfı için kesinlik ve duyarlılık değerleri sırasıyla 1,00 ve 0,99 F1-skor ise 1,00 olarak hesaplanmış, bu da modelin İpsala sınıfındaki performansının çok yüksek olduğunu ortaya koymaktadır. Jasmine sınıfı için kesinlik değeri 0,98 duyarlılık değeri 1,00 ve F1-skor değeri 0,99 olarak belirlenmiştir. Bu, Jasmine sınıfının tüm örneklerinin doğru şekilde sınıflandırıldığını, ancak modelin Jasmine sınıfına yönelik biraz fazla yanlış pozitif tahmin yaptığına işaret etmektedir. Karacadağ sınıfı için ise kesinlik ve duyarlılık değerleri 0,99 F1-skor ise 0,99 olarak hesaplanmış, bu da sınıfın doğru bir şekilde sınıflandırıldığını ve modelin genel performansının dengeli olduğunu göstermektedir. Tüm metriklerin 0,98 ile 1,00 arasında yer alması, modelin beş sınıf arasında tutarlı ve güçlü bir performans sergilediğini göstermektedir. Özellikle Jasmine sınıfının %100 duyarlılık değeri ve İpsala sınıfının %100 F1-skor değeri dikkat çekicidir. Ancak Jasmine sınıfı için elde edilen 0,98'lik kesinlik değeri, modelin bu sınıfa ait olmayan bazı örnekleri Jasmine olarak yanlış sınıflandırdığına, yani yanlış pozitif tahminlerin görece yüksek olduğuna işaret etmektedir. Bu sorunu çözmek için daha fazla veri eklemek ya da Jasmine sınıfına özel ince ayar yaparak modelin doğruluğu artırılabilir. Genel olarak, model beş farklı pirinç türünü sınıflandırma görevinde olağanüstü bir başarı göstermiştir. Kesinlik, duyarlılık ve F1-skor gibi metriklerin yüksekliği, modelin doğru tahmin yapma yeteneğini ve yanlış pozitif/negatif oranlarını düşük tutma becerisini yansıtmaktadır. Küçük iyileştirmelerle modelin performansı daha da geliştirilebilir ve %100 başarıya ulaşılabilir. Şekil 6.6'da VGG16 modelinin sınıflara göre performans metrikleri verilmiştir.




Şekil 6. 6. VGG16 modeli sınıflara göre performans metrikleri

6.3.2. Resnet50 modeli performansı


Veri seti, modelin eğitim ve test süreçlerinde kullanılmak üzere %80 eğitim ve %20 test olarak ayrılmıştır. Görseller, 224 x 224 piksel boyutunda yeniden boyutlandırılmıştır. Modelin eğitim süreci sırasında, görseller "Arborio", "Basmati", "Jasmine", "Karacadağ" ve "İpsala" sınıfları altında etiketlenmiştir. ResNet50 modeline ait performans değerlendirmeleri, karmaşıklık matrisi Şekil 6.7'de, kayıp ve doğrulama değerleri Şekil 6.8'de, ROC eğrisi Şekil 6.9'da ve eğitim sürecine ilişkin değerlendirme verileri Çizelge 6.3'te sunulmaktadır.



Şekil 6. 7. ResNet50 modelinin karmaşıklık matrisi



Şekil 6. 8. ResNet50 modelinin kayıp ve doğrulama değerleri



Şekil 6. 9. ResNet50 modelinin ROC eğrisi

Çizelge 6. 3. Resnet50 modeli değerlendirme verileri


Pirinç Türü	Kesinlik	Duyarlılık	F1-Skor	Veri Sayısı
Arborio	0,99	0,93	0,96	3 000
Basmati	0,99	0,99	0,99	3 000
İpsala	1,00	0,99	1,00	3 000
Jasmine	0,98	0,99	0,98	3 000
Karacadağ	0,94	0,99	0,97	3 000
Doğruluk	0,98			15 000
Sınıf Bazlı Ortalama	0,98	0,98	0,98	15 000
Ağırlıklı Ortalama	0,98	0,98	0,98	15 000

Modelin performansı değerlendirildiğinde, genel olarak yüksek doğruluk ve dengeli bir başarı gözlemlenmiştir. Arborio türü için model yüksek doğruluk sergilemekle birlikte, duyarlılık oranının %93'e düşmesi bazı gerçek Arborio türlerinin gözden kaçtığını gösteriyor. Basmati türü hem kesinlik hem de duyarlılık değerlerinin çok yüksek olduğu ve neredeyse hiçbir yanlış sınıflandırma yapılmadığı bir türdür. İpsala türünde ise model, %100 kesinlik değeri ve %99 duyarlılık oranıyla mükemmel bir performans sergileyerek bu türde en iyi sınıflandırmayı gerçekleştirmiştir. Jasmine türünde model, kesinlik ve duyarlılık değerlerinin yüksek olduğu dengeli bir performans göstermiştir. Karacadağ türünde ise duyarlılık değeri oldukça yüksek (%99), ancak kesinlik değeri %94'e düşmüş, bu da bazı yanlış pozitiflerin olduğunu göstermektedir. Genel performans açısından modelin doğruluğu %98 ile oldukça yüksek bir seviyededir. Sınıf Bazlı Ortalama ve


Ağırlıklı Ortalama değerleri ise sırasıyla Kesinlik: 0,98 Duyarlılık: 0,98 ve F1-Skor: 0,98 olarak hesaplanmış ve modelin tüm sınıflarda dengeli bir şekilde iyi performans gösterdiği doğrulanmıştır. Modelin İpsala türünde mükemmel sonuçlar verdiği, ancak Karacadağ türünde kesinlik değerinin biraz daha düşük kaldığı dikkate değerdir. Bu sonuçlar, modelin pirinç türü sınıflandırması için güçlü ve güvenilir bir araç olduğunu, ancak küçük iyileştirmelerle daha da geliştirilerek mükemmel sonuçlar elde edilebileceğini göstermektedir.

6.3.3. EfficientNetB6 modeli performansı


Veri seti, modelin eğitim ve test süreçlerinde kullanılmak üzere %80 eğitim ve %20 test olarak ayrılmıştır. Görseller, 224 x 224 piksel boyutunda yeniden boyutlandırılmıştır. Modelin eğitim süreci sırasında, görseller "Arborio", "Basmati", "Jasmine", "Karacadağ" ve "İpsala" sınıfları altında etiketlenmiştir. EfficientNetB6 modeline ait performans değerlendirmeleri, karmaşıklık matrisi Şekil 6.10'da kayıp ve doğrulama değerleri Şekil 6.11'de, ROC eğrisi Şekil 6.12'de ve eğitim sürecine ilişkin değerlendirme verileri Çizelge 6.4'te sunulmaktadır.



Şekil 6. 10. EfficientNetB6 modeli karmaşıklık matrisi



Şekil 6. 11. EfficientNetB6 modeli kayıp ve doğrulama değerleri



Şekil 6. 12. EfficientNetB6 modeli ROC eğrisi

Çizelge 6. 4. EfficientNetB6 modeli değerlendirme verileri


Pirinç Türü	Kesinlik	Duyarlılık	F1-Skor	Veri Sayısı
Arborio	0,98	0,94	0,96	3 000
Basmati	1,00	0,96	0,98	3 000
İpsala	1,00	1,00	1,00	3 000
Jasmine	0,95	1,00	0,97	3 000
Karacadağ	0,94	0,98	0,96	3 000
Doğruluk	0,97			15 000
Sınıf Bazlı Ortalama	0,98	0,97	0,97	15 000
Ağırlıklı Ortalama	0,98	0,97	0,97	15 000

Modelin genel performansı oldukça yüksek olup, test kümesindeki verilerin %97'si doğru sınıflandırılmıştır. Bu, modelin doğruluk oranının %97 olduğu anlamına gelir, bu da genel sınıflandırma performansının etkileyici olduğunu göstermektedir. Arborio sınıfı için modelin kesinlik değeri %98, duyarlılık değeri ise %94 olarak belirlenmiştir. F1-skor ise %96'dır. Bu, modelin Arborio sınıfındaki örnekleri çoğunlukla doğru sınıflandırdığını ancak bazı gerçek Arborio örneklerini kaçırmış olabileceğini gösteriyor. Kesinlik değeri yüksekken, duyarlılık değerinin biraz daha düşük olması, bazı hatalı sınıflandırmaların olduğunu işaret eder. Basmati sınıfında model mükemmel bir performans sergilemiştir. Kesinlik değeri %100 iken, duyarlılık değeri %96 olarak kaydedilmiştir. Bu da modelin Basmati sınıfındaki örneklerin tamamını doğru sınıflandırmasıyla birlikte, birkaç yanlış negatif örnek olduğunu gösterir. F1-skor ise %98'dir, bu da kesinlik ve duyarlılık arasında iyi bir denge olduğunu gösteriyor. İpsala sınıfı, modelin mükemmel bir performans sergilediği bir diğer sınıftır. Kesinlik, duyarlılık ve F1-skor değerlerinin tamamı %100'dür, bu da modelin İpsala sınıfındaki tüm örnekleri doğru şekilde sınıflandırdığını ve oldukça güçlü bir performans sergilediğini göstermektedir. Jasmine sınıfında modelin kesinlik değeri %95, duyarlılık değeri ise %100'dür. F1-skor değeri %97 ile oldukça yüksektir. Model, Jasmine sınıfındaki örneklerin tamamını doğru sınıflandırırken, bir miktar yanlış pozitif tahmin yapmış olabilir. Ancak, genel olarak bu sınıf için modelin performansı güçlüdür. Karacadağ sınıfı için kesinlik değeri %94, duyarlılık değeri ise %98'dir. F1-skor ise %96'dır. Karacadağ sınıfında da model, doğru sınıflandırmalarda başarılı olmakla birlikte, bazı yanlış pozitifler bulunabilir. Ancak, duyarlılık değerinin yüksek olması, modelin bu sınıftaki örnekleri kaçırmadığını gösteriyor. Sonuç olarak, modelin performansı oldukça yüksektir ve çoğu sınıf çok iyi dengelenmiş, özellikle Basmati ve İpsala sınıflarında neredeyse mükemmel sonuçlar elde edilmiştir. Arborio ve Karacadağ sınıflarında duyarlılığın biraz daha düşük olması, modelin bu sınıflarda küçük iyileştirmelere ihtiyaç duyabileceğini göstermektedir. Ancak, genel olarak modelin doğruluğu ve performansı tatmin edici düzeydedir.


6.3.4. InceptionV3 modeli performansı

Veri seti, modelin eğitim ve test süreçlerinde kullanılmak üzere %80 eğitim ve %20 test olarak ayrılmıştır. Görseller, 224 x 224 piksel boyutunda yeniden boyutlandırılmıştır. Modelin eğitim süreci sırasında, görseller "Arborio", "Basmati", "Jasmine", "Karacadağ" ve "İpsala" sınıfları altında etiketlenmiştir. InceptionV3 modeline ait performans


değerlendirmeleri, karmaşıklık matrisi Şekil 6.13'te, kayıp ve doğrulama değerleri Şekil 6.14'te, ROC eğrisi Şekil 6.15'te ve eğitim sürecine ilişkin değerlendirme verileri Çizelge 6.5'te sunulmaktadır.



Şekil 6. 13. InceptionV3 modelini karmaşıklık matrisi



Şekil 6. 14. InceptionV3 modelinin kayıp ve doğrulama değerleri



Şekil 6. 15. InceptionV3 modelinin ROC eğrisi

Çizelge 6. 5. InceptionV3 modeli değerlendirme verileri

Pirinç Türü	Kesinlik	Duyarlılık	F1-Skor	Veri Sayısı
Arborio	0,99	0,98	0,98	3 000
Basmati	0,99	0,99	0,99	3 000
İpsala	1,00	0,99	1,00	3 000
Jasmine	0,98	0,99	0,99	3 000
Karacadağ	0,98	0,99	0,99	3 000
Doğruluk	0,99			15 000
Sınıf Bazlı Ortalama	0,99	0,99	0,99	15 000
Ağırlıklı Ortalama	0,99	0,99	0,99	15 000

InceptionV3 modeli test verisi üzerinde oldukça yüksek bir sınıflandırma başarısı elde etmiştir. Modelin genel doğruluk değeri %99 olarak hesaplanmıştır. Bu sonuç, test kümesindeki 15 000 örneğin %99'unun doğru sınıflandırıldığını ve modelin genel olarak istikrarlı bir performans sergilediğini göstermektedir.

Sınıf bazlı performans incelendiğinde, tüm sınıflarda kesinlik, duyarlılık ve F1-skor değerlerinin birbirine oldukça yakın ve yüksek olduğu görülmektedir. Arborio sınıfı için kesinlik değeri 0,99 duyarlılık değeri 0,98 ve F1-skor 0,98 olarak elde edilmiştir. Bu değerler, modelin Arborio sınıfını yüksek doğrulukla tanımladığını ancak bazı örnekleri farklı sınıflar ile karıştırdığını göstermektedir.

Basmati sınıfı için hem kesinlik hem duyarlılık değeri 0,99'dur. Bu durum, modelin bu sınıfı hem doğru tahmin etme hem de ayırt etme konusunda son derece başarılı olduğunu ortaya koymaktadır.

Benzer şekilde, İpsala sınıfında kesinlik değeri 1,00 duyarlılık değeri ise 0,99'dur. Bu sonuçlar, modelin İpsala sınıfına ait örnekleri neredeyse hatasız şekilde tanıdığını göstermektedir.

Jasmine sınıfı için kesinlik değeri 0,98 duyarlılık değeri ise 0,99 olarak hesaplanmıştır. Bu değerler, modelin Jasmine sınıfındaki örnekleri büyük ölçüde doğru sınıflandırdığını; ancak bazı durumlarda farklı sınıflara ait örnekleri Jasmine olarak tahmin ettiğini göstermektedir.


Karacadağ sınıfı için de benzer bir tablo söz konusudur. Kesinlik değeri 0,98 duyarlılık değeri ise 0,99'dur. Bu da modelin Karacadağ sınıfını tanımada oldukça başarılı olduğunu, ancak sınıflar arası küçük karışıklıkların meydana gelebildiğini göstermektedir.

Genel olarak değerlendirildiğinde, modelin tüm sınıflarda yüksek doğrulukla çalıştığı, sınıflar arası ayırım gücünün güçlü olduğu ve yanlış sınıflandırma oranlarının oldukça düşük kaldığı görülmektedir.


Sınıf bazlı ve ağırlıklı ortalamalar da tüm metrikler açısından 0,99 seviyesindedir. Bu durum, modelin yalnızca bireysel sınıflarda değil, genel performans açısından da dengeli ve tutarlı bir sınıflandırma yaptığına işaret etmektedir.

6.3.5. DenseNet modeli performansı


Veri seti, modelin eğitim ve test süreçlerinde kullanılmak üzere %80 eğitim ve %20 test olarak ayrılmıştır. Görseller, 224 x 224 piksel boyutunda yeniden boyutlandırılmıştır. Modelin eğitim süreci sırasında, görseller "Arborio", "Basmati", "Jasmine", "Karacadağ" ve "İpsala" sınıfları altında etiketlenmiştir. DenseNet modeline ait performans değerlendirmeleri, karmaşıklık matrisi Şekil 6.16'da kayıp ve doğrulama değerleri Şekil 6.17'de, ROC eğrisi Şekil 6.18'te ve eğitim sürecine ilişkin değerlendirme verileri Çizelge 6.6'da sunulmaktadır.



Şekil 6. 16. DenseNet modeli karmaşıklık matrisi



Şekil 6. 17. DenseNet modeli kayıp ve doğrulama değerleri



Şekil 6. 18. DenseNet modeli ROC eğrisi

Çizelge 6. 6. DenseNet modeli değerlendirme verileri

Pirinç Türü	Kesinlik	Duyarlılık	F1-Skor	Veri Sayısı
Arborio	0,99	0,99	0,99	3 000
Basmati	1,00	0,98	0,99	3 000
İpsala	1,00	1,00	1,00	3 000
Jasmine	0,98	1,00	0,99	3 000
Karacadağ	1,00	0,99	0,99	3 000
Doğruluk	0,99			15 000
Sınıf Bazlı Ortalama	0,99	0,99	0,99	15 000
Ağırlıklı Ortalama	0,99	0,99	0,99	15 000

Modelin genel doğruluk değeri %99 olarak hesaplanmıştır. Bu oran, modelin test kümesinde yer alan toplam 15 000 örneğin yaklaşık 14 850'sini doğru bir şekilde sınıflandırdığını ifade etmektedir. Elde edilen bu yüksek doğruluk değeri, modelin genel sınıflandırma performansının oldukça güçlü ve güvenilir olduğunu göstermektedir.

Kesinlik değerleri incelendiğinde, modelin her bir sınıf için pozitif tahminlerde bulunurken oldukça isabetli sonuçlar ürettiği görülmektedir. Arborio, Basmati, İpsala ve Karacadağ sınıfları sırasıyla 0,99 1,00 1,00 ve 1,00 kesinlik değerlerine ulaşmıştır. Bu sonuçlar, modelin bu sınıflara ait pozitif tahminlerinin neredeyse tamamının doğru olduğunu

göstermektedir. Jasmine sınıfında ise kesinlik değeri 0,98 olarak hesaplanmıştır. Bu, modelin Jasmine sınıfına ait bazı tahminlerinde sınıf dışı örnekleri de yanlışlıkla bu sınıfa dahil etmiş olabileceğini göstermektedir. Duyarlılık açısından bakıldığında, İpsala ve Jasmine sınıflarında 1,00 değerine ulaşılmıştır. Bu durum, modelin bu iki sınıfa ait tüm örnekleri eksiksiz bir şekilde doğru sınıflandırdığını göstermektedir. Arborio, Basmati ve Karacadağ sınıflarında ise duyarlılık değerleri sırasıyla 0,99 0,98 ve 0,99 olarak ölçülmüştür. Özellikle Basmati sınıfındaki 0,98'lik duyarlılık değeri, modelin bu sınıfa ait bazı örnekleri yanlış sınıflandırmış olabileceğine işaret etmektedir. F1-skoru değerleri, modelin kesinlik ve duyarlılığı birlikte ele alarak her sınıftaki genel başarısını ortaya koymaktadır. Tüm sınıflarda F1-skoru 0,99 ile 1,00 aralığında değişmekte olup, bu durum modelin dengeli ve güçlü bir sınıflandırma yeteneğine sahip olduğunu göstermektedir. Özellikle İpsala sınıfında 1,00'lük F1-skoru, modelin bu sınıfa ilişkin tüm tahminlerinde hem hatasız hem de eksiksiz bir başarı sergilediğini ifade etmektedir.

Destek değeri, her bir sınıfa ait test verisi sayısını göstermekte olup, bu çalışmada tüm sınıflar için eşit olarak 3 000 örnekle temsil edilmiştir. Bu eşit dağılım, modelin sınıf bazlı performansının dengeli bir şekilde değerlendirilmesine olanak sağlamaktadır. Makro ortalama (sınıf bazlı ortalama) ve ağırlıklı ortalama değerleri incelendiğinde hem kesinlik hem duyarlılık hem de F1-skoru metriklerinde ortalama değerin 0,99 olduğu görülmektedir. Sınıflar arasında örnek sayılarının eşit olması nedeniyle her iki ortalama da benzer sonuçlar vermiştir. Bu, modelin tüm sınıflarda homojen bir performans sergilediğini ve sınıf dengesizliğinden kaynaklanan herhangi bir yanlılık içermediğini göstermektedir. Sonuç olarak, DenseNet tabanlı model, yüksek doğruluk ve sınıf bazlı güçlü metriklerle desteklenen başarılı bir sınıflandırma performansı sunmaktadır. Özellikle İpsala ve Jasmine sınıflarında elde edilen 1,00'lik duyarlılık değerleri ile birlikte Basmati ve Karacadağ sınıflarındaki yüksek kesinlik oranları, bu mimarinin pirinç sınıflandırma problemi için oldukça etkili bir çözüm sunduğunu ortaya koymaktadır.


6.4. Yeni Oluşturulan Modellerin Performansları

Bu bölümde, tez kapsamında yeni geliştirilmiş yedi farklı derin öğrenme modelinin (Model 1'den Model 7'ye) sınıflandırma performansına yönelik değerlendirme sonuçları sunulmaktadır. Her bir model, sabit bir veri seti ve ortak eğitim koşulları altında test edilmiş ve elde edilen doğruluk, kesinlik, duyarlılık, F1-skoru gibi temel sınıflandırma


metrikleri üzerinden karşılaştırılmıştır. Amaç, önerilen modellerin kendi aralarındaki performans farklarını ortaya koymak ve her birinin sınıflandırma başarısını nesnel ölçütlerle değerlendirmektir. Elde edilen bulgular, modellerin güçlü ve zayıf yönlerini belirlemeye yardımcı olmakta ve nihai model seçimi açısından önemli bir temel oluşturmaktadır.

6.4.1. Model 1 performansı


Veri seti, modelin eğitim ve test süreçlerinde kullanılmak üzere %80 eğitim ve %20 test olarak ayrılmıştır. Görseller, 224 x 224 piksel boyutunda yeniden boyutlandırılmıştır. Modelin eğitim süreci sırasında, görseller "Arborio", "Basmati", "Jasmine", "Karacadağ" ve "İpsala" sınıfları altında etiketlenmiştir. Model 1'e ait performans değerlendirmeleri, karmaşıklık matrisi Şekil 5.19'ta, kayıp ve doğrulama değerleri Şekil 5.20'te, ROC eğrisi Şekil 5.21'de ve eğitim sürecine ilişkin değerlendirme verileri Çizelge 5.7'de sunulmaktadır.



Şekil 6. 19. Model 1 modelinin karmaşıklık matrisi



Şekil 6. 20. Model 1 modelinin kayıp ve doğrulama değerleri



Şekil 6. 21. Model 1 modelinin ROC eğrisi

Çizelge 6. 7. Model 1 modelinin değerlendirme verileri

Pirinç Türü	Kesinlik	Duyarlılık	F1-Skor	Veri Sayısı
Arborio	0,75	0,58	0,65	3 000
Basmati	0,96	0,95	0,95	3 000
İpsala	1,00	0,97	0,98	3 000
Jasmine	0,79	0,90	0,84	3 000
Karacadağ	0,75	0,83	0,79	3 000
Doğruluk	0,85			15 000
Sınıf Bazlı Ortalama	0,85	0,85	0,84	15 000
Ağırlıklı Ortalama	0,85	0,85	0,84	15 000

Model 1, genel olarak %85 doğruluk oranı ile başarılı bir performans sergilemiştir. Bu, modelin sınıflandırma görevinde yüksek bir doğruluk oranı elde ettiğini ve genel olarak iyi bir performans gösterdiğini işaret etmektedir.

Özellikle İpsala sınıfında, kesinlik, duyarlılık ve F1-skor değerleri neredeyse mükemmel seviyelere ulaşmış olup, modelin bu sınıfı doğru bir şekilde ayırt etme başarısı oldukça yüksektir.

Ancak, Arborio sınıfında duyarlılık değeri %58 olarak belirlenmiş, bu da bu sınıfa ait örneklerin önemli bir kısmının yanlış sınıflandırıldığına işaret etmektedir.

Arborio sınıfındaki düşük duyarlılık değeri, modelin bu sınıfı diğer sınıflardan ayırt etme konusunda zorluklar yaşadığını ve çoğu örneği yanlış sınıflandırdığını göstermektedir.


Ayrıca, Arborio ve Karacadağ sınıflarında kesinlik ve duyarlılık arasında belirgin bir dengesizlik olduğu gözlemlenmektedir.

Bu dengesizlik, modelin bu sınıflar arasında hata yapma olasılığının yüksek olduğunu ve bazı örneklerin yanlış sınıfa atanma riski taşıdığını ortaya koymaktadır.


Bu durum, modelin bu sınıflara ait örnekleri daha doğru sınıflandırabilmesi için iyileştirmeye ihtiyaç duyduğunu göstermektedir.

6.4.2. Model 2 performansı


Veri seti, modelin eğitim ve test süreçlerinde kullanılmak üzere %80 eğitim ve %20 test olarak ayrılmıştır. Görseller, 224 x 224 piksel boyutunda yeniden boyutlandırılmıştır. Model eğitilirken, görseller “Arborio”, “Basmati”, “Jasmine”, “Karacadağ” ve “İpsala” sınıfları altında etiketlenmiştir. Model 2'ye ait performans değerlendirmeleri, karmaşıklık matrisi Şekil 6.22’de, kayıp ve doğrulama değerleri Şekil 6.23’te, ROC eğrisi Şekil 6.24’te ve eğitim sürecine ilişkin değerlendirme verileri Çizelge 6.8’de sunulmaktadır.



Şekil 6. 22. Model 2 modelinin karmaşıklık matrisi



Şekil 6. 23. Model 2 modelinin kayıp ve doğrulama değerleri



Şekil 6. 24. Model 2 modelinin ROC eğrisi

Çizelge 6. 8. Model 2 modelinin değerlendirme verileri

Pirinç Türü	Kesinlik	Duyarlılık	F1-Skor	Veri Sayısı
Arborio	0,715	0,998	0,833	3 000
Basmati	1,000	0,983	0,992	3 000
İpsala	1,000	0,602	0,751	3 000
Jasmine	0,986	0,998	0,992	3 000
Karacadağ	0,994	1,000	0,997	3 000
Doğruluk	0,916			15 000
Sınıf Bazlı Ortalama	0,939	0,916	0,913	15 000
Ağırlıklı Ortalama	0,939	0,916	0,913	15 000


Modelin %91,6 doğruluk oranı ile sınıflandırma yapabilmesi, genel anlamda yüksek bir başarı düzeyine işaret etmektedir. Bu doğruluk seviyesi, modelin test verisi üzerinde güvenilir ve istikrarlı sonuçlar üretebildiğini göstermektedir. Özellikle Jasmine, Basmati ve Karacadağ sınıflarında elde edilen yüksek performans metrikleri, modelin bu sınıfları etkin bir biçimde ayırt edebildiğini ortaya koymaktadır. Karacadağ sınıfında gözlemlenen kesinlik, duyarlılık ve F1-skor değerleri neredeyse kusursuzdur. Benzer şekilde, Jasmine ve Basmati sınıflarında da oldukça yüksek değerler elde edilmiştir. Tüm sınıflar genelinde kesinlik ortalamasının %93,9 gibi dikkat çekici bir seviyede olması, modelin yaptığı pozitif tahminlerin büyük oranda isabetli olduğunu göstermektedir. Ancak modelin sınıflar arası ayırım gücü her sınıf için aynı düzeyde değildir. Özellikle Arborio sınıfında kesinlik değerinin %71,5 gibi düşük bir seviyede kalması, modelin bu sınıf için yaptığı pozitif

tahminlerin önemli bir kısmının hatalı olduğunu göstermektedir. Bu durum, Arborio sınıfına yönelik tahminlerde yüksek düzeyde yanlış pozitif üretildiğine işaret etmektedir. İlginç bir şekilde, bu sınıf için duyarlılık değeri %99,8 gibi oldukça yüksek bir seviyede gerçekleşmiştir; bu da modelin Arborio sınıfına ait örneklerin neredeyse tamamını doğru tanıdığını ancak bu sırada başka sınıflara ait örnekleri de hatalı olarak bu sınıfa atadığını ortaya koymaktadır. Bu dengesizlik, sınıf içi sınırların yeterince keskin çizilemediğini düşündürmektedir. İpsala sınıfında ise daha belirgin performans sorunları mevcuttur. Duyarlılık oranının %60,2 düzeyinde kalması, modelin bu sınıfa ait örneklerin yaklaşık %40'ını başka sınıflar altında yanlış sınıflandırdığını göstermektedir. Aynı şekilde F1-skor'un %75,1 gibi diğer sınıflara kıyasla oldukça düşük bir seviyede kalması, modelin bu sınıfa yönelik sınıflandırma yeteneğinin zayıf olduğunu göstermektedir. Modelin karar verme eğilimleri incelendiğinde, bazı sınıflarda yüksek kesinlik değerlerine ulaşılmış olması, modelin bu sınıflarda daha emin ve güvenilir tahminlerde bulunduğunu göstermektedir. Ancak, bu durumun her zaman yüksek duyarlılık ile desteklenmediği, özellikle İpsala gibi sınıflarda açıkça görülmektedir. Bu durum, modelin bazı sınıflara ait örnekleri yeterince temsil edemediğini ve dolayısıyla bu sınıfları ayırt etmekte güçlük çektiğini ortaya koymaktadır. Ayrıca, Arborio ve İpsala sınıflarındaki kesinlik-duyarlılık dengesizlikleri, bu sınıfların özellik uzayında diğer sınıflarla benzerlikler taşıdığını ve bu nedenle modelin bu sınıflar arasında ayırım yapmakta zorlandığını düşündürmektedir. Bu bağlamda, model performansını artırmak adına çeşitli stratejilerin uygulanması önerilmektedir. İpsala sınıfı için veri artırımı ya da yeniden örnekleme gibi yöntemlerin kullanılması, modelin bu sınıfa özgü örnekleri daha iyi öğrenmesini sağlayabilir. Ayrıca, bu sınıfa ait örneklerin sayıca veya çeşitlilik açısından yetersiz olması durumunda, veri setine bu eksikliği giderecek şekilde müdahale edilmesi gerekebilir. Arborio sınıfı için ise, sınıf sınırlarının daha net şekilde tanımlanmasına yardımcı olacak özellik mühendisliği süreçleri önerilmektedir. Bunun yanı sıra, karmaşıklık matrisinin detaylı biçimde analiz edilmesi, söz konusu sınıfların hangi diğer sınıflarla daha sık karıştırıldığını belirlemek açısından faydalı olacaktır. Bu tür analizler, daha hedeflenmiş ve sınıfa özgü iyileştirme stratejileri geliştirilmesine zemin hazırlayabilir.


6.4.3. Model 3 performansı

Veri seti, modelin eğitim ve test süreçlerinde kullanılmak üzere %80 eğitim ve %20 test olarak ayrılmıştır. Tüm görseller 224 x 224 piksel boyutlarına yeniden ölçeklendirilmiştir.


Modelin eğitimi süresince veriler, “Arborio”, “Basmati”, “Jasmine”, “Karacadağ” ve “İpsala” sınıfları altında etiketlenmiştir. Model 3’e ait performans değerlendirmeleri; karmaşıklık matrisi Şekil 6.25’te, eğitim ve doğrulama kayıpları Şekil 6.26’da ROC eğrisi Şekil 6.27’de ve modelin eğitime ilişkin istatistiksel değerlendirme sonuçları Çizelge 6.9’da sunulmuştur.



Şekil 6. 25. Model 3 modelinin karmaşıklık matrisi



Şekil 6. 26 Model 3 modelinin kayıp ve doğrulama değerleri



Şekil 6. 27. Model 3 modelinin ROC eğrisi

Çizelge 6. 9. Model 3 modelinin değerlendirme verileri

Pirinç Türü	Kesinlik	Duyarlılık	F1-Skor	Veri Sayısı
Arborio	0,759	0,981	0,856	3 000
Basmati	1,000	0,992	0,996	3 000
İpsala	1,000	1,000	1,000	3 000
Jasmine	0,974	1,000	0,987	3 000
Karacadağ	1,000	0,688	0,815	3 000
Doğruluk	0,932			15 000
Sınıf Bazlı Ortalama	0,947	0,932	0,931	15 000
Ağırlıklı Ortalama	0,947	0,932	0,931	15 000

Model 3, %93,2'lik doğruluk oranıyla genel anlamda oldukça başarılı bir performans sergilemiştir. Bu yüksek doğruluk değeri, modelin beş farklı pirinç türünü büyük ölçüde doğru biçimde ayırt edebildiğini göstermektedir. Özellikle İpsala sınıfı için elde edilen sonuçlar dikkat çekicidir; bu sınıfa ait kesinlik, duyarlılık ve F1-skor değerlerinin tamamı 1,000 olarak hesaplanmıştır. Bu durum, modelin İpsala sınıfına ait tüm örnekleri eksiksiz ve hatasız bir şekilde sınıflandırabildiğini ortaya koymaktadır. Benzer şekilde, Basmati ve Jasmine sınıflarında da güçlü bir performans gözlemlenmiştir. Her iki sınıf için F1-skor değerlerinin %97'nin üzerinde olması, modelin bu sınıflara ait örnekleri yüksek doğrulukla tanıdığını göstermektedir. Özellikle Jasmine sınıfında elde edilen %100 duyarlılık değeri, modelin bu sınıfa ait hiçbir örneği atlamadığını ve tüm gerçek Jasmine örneklerini doğru şekilde sınıflandırdığını ifade etmektedir. Bununla birlikte, modelin başarısı bazı sınıflar

için sınırlı kalmıştır. Karacadağ sınıfında elde edilen duyarlılık oranı %68,8 olup, modelin bu sınıfa ait örneklerin yaklaşık üçte birini yanlış sınıflandırdığını göstermektedir. Öte yandan, Karacadağ sınıfına ilişkin kesinlik değerinin 1,000 olması, modelin bu sınıfa dair yaptığı tüm pozitif tahminlerin doğru olduğunu ortaya koymaktadır. Bu durum, modelin yalnızca çok emin olduğu örnekleri Karacadağ olarak sınıflandırdığını, ancak bu stratejinin yüksek oranda yanlış negatifle sonuçlandığını düşündürmektedir. Arborio sınıfı içinse belirgin bir dengesizlik söz konusudur. Bu sınıfa ait duyarlılık oranı %98,1 gibi oldukça yüksek bir değerde olmasına rağmen, kesinlik oranı %75,9 seviyesinde kalmıştır. Bu sonuç, modelin Arborio sınıfına ait örnekleri büyük ölçüde doğru biçimde tespit ettiğini; ancak aynı zamanda bu sınıfa ait olmayan bazı örnekleri de yanlışlıkla Arborio olarak sınıflandırdığını göstermektedir. Diğer bir ifadeyle, model bu sınıfa ilişkin pozitif tahminlerde bulunurken daha “gevşek” bir yaklaşım sergilemekte, bu da yanlış pozitif sayısının artmasına neden olmaktadır. Elde edilen bulgular doğrultusunda, Karacadağ sınıfı için modelin ayırt edici gücünün artırılması önerilmektedir. Bu sınıf, özellik uzayında diğer sınıflarla özellikle Arborio ve Jasmine gibi daha baskın sınıflarla benzerlikler taşıyor olabilir. Bu nedenle, Karacadağ sınıfının hangi sınıflarla sıklıkla karıştırıldığı detaylı şekilde incelenmeli ve bu sınıfa özgü daha belirgin özellikler tanımlanmalıdır. Arborio sınıfında gözlenen yüksek yanlış pozitif oranının azaltılması içinse, karar eşiklerinin yeniden düzenlenmesi ve modelin bu sınıf için yaptığı hatalı sınıflandırmaların analiz edilmesi faydalı olacaktır. Böylece, modelin aşırı pozitif tahmin eğilimi dengeye kavuşturularak daha dengeli ve hassas bir sınıflandırma başarısı elde edilebilir. Model 3’ün karşılaştırmalı analizi Çizelge 6.10’da sunulmuştur.


Çizelge 6. 10. Model 3 modelinin karşılaştırmalı analizi

Sınıf	En Güçlü Yön	İyileştirilmesi Gereken
Arborio	Yüksek duyarlılık	Düşük kesinlik (yanlış pozitif)
Basmati	Yüksek F1, dengeli	Neredeyse mükemmel
İpsala	Tüm metriklerde 1,0	Yok
Jasmine	Yüksek duyarlılık	Kesinlik biraz daha artırılabilir
Karacadağ	Kesinlik çok iyi	Düşük duyarlılık (yanlış negatif fazla)


6.4.4. Model 4 performansı

Veri seti, modelin eğitim ve test aşamalarında kullanılmak üzere %80 eğitim ve %20 test olarak ayrılmıştır. Görseller, 224 x 224 piksel boyutlarında yeniden ölçeklendirilmiştir.


Modelin eğitim süreci boyunca görüntüler “Arborio”, “Basmati”, “Jasmine”, “Karacadağ” ve “İpsala” sınıfları altında etiketlenmiştir. Model 4’e ait performans değerlendirmeleri; karmaşıklık matrisi Şekil 6.28’de, kayıp ve doğrulama değerleri Şekil 6.29’da ROC eğrisi Şekil 6.30’da ve eğitime ilişkin değerlendirme verileri Çizelge 6.11’de sunulmuştur.



Şekil 6. 28. Model 4 modelinin karmaşıklık matrisi



Şekil 6. 29. Model 4 modelinin kayıp ve doğrulama değerleri



Şekil 6. 30. Model 4 modelinin ROC eğrisi

Çizelge 6. 11. Model 4 modelinin değerlendirme verileri

Pirinç Türü	Kesinlik	Duyarlılık	F1-Skor	Veri Sayısı
Arborio	0,97	0,88	0,92	3 000
Basmati	1,00	0,98	0,99	3 000
İpsala	1,00	0,98	0,99	3 000
Jasmine	0,95	0,99	0,97	3 000
Karacadağ	0,90	0,98	0,94	3 000
Doğruluk	0,96			15 000
Sınıf Bazlı Ortalama	0,96	0,96	0,96	15 000
Ağırlıklı Ortalama	0,96	0,96	0,96	15 000

Model, %96 doğruluk oranıyla tahmin yaparak, önceki modellere kıyasla en yüksek genel başarı oranlarından birine ulaşmıştır. Bu oran, sınıflandırma sürecinde modelin büyük ölçüde doğru kararlar verdiğini ve genel performans açısından oldukça başarılı olduğunu ortaya koymaktadır. Özellikle Basmati ve İpsala sınıflarında modelin performansı dikkat çekici düzeydedir. Her iki sınıf için hem kesinlik hem de duyarlılık değerlerinin %98'in üzerinde olması, modelin bu sınıfları neredeyse hatasız biçimde tanımladığını göstermektedir. Benzer şekilde, Jasmine sınıfında elde edilen %97 F1-skor değeri de bu sınıf için güçlü bir performansa işaret etmektedir. Karacadağ sınıfında ise önceki modellere kıyasla duyarlılık değerinin %98'e yükselmiş olması, modelin bu sınıfa ait yanlış negatif oranını önemli ölçüde azalttığını göstermektedir. Ayrıca, sınıf bazlı ve ağırlıklı ortalama değerlerinin eşit düzeyde (%96) olması, modelin tüm sınıflarda dengeli bir performans

sergilediğini ortaya koymakta, herhangi bir sınıfa karşı belirgin bir eğilim ya da zayıflık göstermediğini kanıtlamaktadır. Bununla birlikte, bazı sınıflarda iyileştirme potansiyeli bulunan noktalar da dikkat çekmektedir. Arborio sınıfında duyarlılık oranının %88 seviyesinde kalması, bu sınıfa ait örneklerin %12'sinin başka sınıflar altında yanlış sınıflandırıldığını göstermektedir. Kesinlik oranının %97 olması, modelin Arborio tahminlerinde genellikle doğru sonuçlar verdiğini, ancak bazı gerçek Arborio örneklerini tanımakta zorlandığını ortaya koymaktadır. Bu durum, modelin bu sınıfa ait sınırlı örnek çeşitliliğinden ya da diğer sınıflarla olan özellik benzerliğinden kaynaklanıyor olabilir. Karacadağ sınıfında ise kesinlik değerinin %90 seviyesinde olması, modelin bu sınıfa ait yaptığı her on tahminden birinin hatalı olduğunu göstermektedir. Bu da modelin Karacadağ sınıfını tanımlarken bazı yanlış pozitif kararlar verdiğini göstermekte, sınıf içi sınırların daha net tanımlanması gerektiğine işaret etmektedir. Bu doğrultuda önerilen iyileştirme stratejileri arasında, Arborio sınıfı için örnek çeşitliliğini artırmaya yönelik veri artırma tekniklerinin uygulanması ve özellikle kaçırılan örneklerin analiz edilerek ayırt edici yeni özelliklerin belirlenmesi yer almaktadır. Karacadağ sınıfı için ise, yanlış pozitiflerin yoğunlaştığı diğer sınıfların karmaşıklık matrisi aracılığıyla belirlenmesi ve bu sınıflar arasında ayrım çizgilerinin netleştirilmesi faydalı olacaktır. Sonuç olarak, bu model genel anlamda yüksek doğruluk ve dengeli sınıflandırma performansı ile başarılı bir yapı ortaya koymaktadır. Basmati, İpsala ve Jasmine sınıflarındaki yüksek başarı düzeyi, modelin tarımsal sınıflandırma gibi kritik alanlarda uygulanabilirliğini güçlendirmektedir. Arborio ve Karacadağ sınıflarında belirli ölçüde gelişim alanları bulunmakla birlikte, bu sınıflara ait doğruluk ve F1-skor değerleri de yüksek düzeydedir ve iyileştirilmeye açık yapılar sunmaktadır. Çizelge 6.12'de Model 4'ün sınıf bazlı kıyaslaması sunulmuştur.


Çizelge 6. 12. Model 4 sınıf bazlı kıyaslama

Sınıf	En Güçlü Yön	İyileştirme Gereken Alan
Arborio	Yüksek kesinlik	Duyarlılık düşük → kaçırılan örnek sayısı yüksek
Basmati	Tüm metrikler güçlü	-
İpsala	Tüm metrikler güçlü	-
Jasmine	Denge çok iyi	Kesinlik daha da artırılabilir
Karacadağ	Yüksek duyarlılık	Kesinlik iyileştirilebilir


6.4.5. Model 5 performansı

Veri seti, modelin eğitim ve test aşamalarında kullanılmak üzere %80 eğitim ve %20 test olarak ayrılmıştır. Görseller, 224 x 224 piksel boyutlarında yeniden ölçeklendirilmiştir.


Modelin eğitim süreci boyunca görüntüler “Arborio”, “Basmati”, “Jasmine”, “Karacadağ” ve “İpsala” sınıfları altında etiketlenmiştir. Model 5’e ait performans değerlendirmeleri; karmaşıklık matrisi Şekil 6.31’de, kayıp ve doğrulama değerleri Şekil 6.32’de, ROC eğrisi Şekil 6.33’te ve eğitime ilişkin değerlendirme verileri Çizelge 6.13’te sunulmuştur.



Şekil 6. 31. Model 5 modelinin karmaşıklık matrisi



Şekil 6. 32. Model 5 modelinin kayıp ve doğrulama değerleri



Şekil 6. 33. Model 5 modelinin ROC eğrisi

Çizelge 6. 13. Model 5 modelinin değerlendirme verileri

Pirinç Türü	Kesinlik	Duyarlılık	F1-Skor	Veri Sayısı
Arborio	0,99	0,95	0,97	3 000
Basmati	0,99	0,99	0,99	3 000
İpsala	1,00	0,99	1,00	3 000
Jasmine	0,98	0,99	0,99	3 000
Karacadağ	0,96	1,00	0,98	3 000
Doğruluk	0,98			15 000
Sınıf Bazlı Ortalama	0,99	0,98	0,98	15 000
Ağırlıklı Ortalama	0,99	0,98	0,98	15 000

Model 5, %98 doğruluk oranı ile önceki modellere kıyasla en yüksek doğruluk değerlerinden birine ulaşmış ve genel sınıflandırma performansı açısından dikkat çekici bir başarı ortaya koymuştur. Sınıf bazlı ve ağırlıklı ortalama değerlerinin birbirine çok yakın (yaklaşık %98–99) olması, modelin tüm sınıflarda tutarlı ve dengeli bir performans sergilediğini göstermektedir. Bu uyum, sınıf dengesizliklerinin modelin genel başarımına olumsuz etki etmediğini ve her sınıfa benzer derecede etkili yaklaşıldığını ortaya koymaktadır. İpsala sınıfında elde edilen sonuçlar neredeyse kusursuz düzeydedir. Kesinlik değeri %100, duyarlılık oranı %99 ve F1-skor değeri yine %100 olarak hesaplanmıştır. Bu durum, modelin İpsala sınıfına ait örnekleri doğru şekilde tespit ettiğini ve bu sınıfa

yönelik herhangi bir sistematik hata üretmediğini göstermektedir. Karacadağ sınıfında da önceki modellere kıyasla önemli bir gelişme kaydedilmiştir.

Duyarlılık oranının %100'e ulaşması, modelin bu sınıfa ait tüm örnekleri doğru şekilde sınıflandırdığını göstermekte ve bu sınıfın, daha önceki modellerde sıklıkla hatalı sınıflandırıldığı göz önüne alındığında, son modelde önemli bir yapısal iyileşmenin sağlandığına işaret etmektedir. Arborio sınıfında da F1-skor değerinin %97'ye yükselmiş olması, bu sınıfa yönelik sınıflandırma doğruluğunda dikkate değer bir iyileşme olduğunu göstermektedir. Bununla birlikte, modelin performansı çok yüksek olsa da bazı sınıflarda sınırlı düzeyde iyileştirme gerektiren alanlar mevcuttur. Arborio sınıfında duyarlılık oranı %95 seviyesindedir; bu da modelin bazı Arborio örneklerini hâlâ başka sınıflarla karıştırma eğiliminde olduğunu göstermektedir. Ancak, kesinlik oranının yüksekliği modelin bu sınıfa karşı seçici bir yaklaşıma sahip olduğunu, yani yanlış pozitif üretme eğiliminin düşük olduğunu ortaya koymaktadır. Benzer şekilde, Karacadağ sınıfı için kesinlik oranı %96 olarak hesaplanmıştır. Bu durum, modelin bazı başka sınıfları yanlışlıkla Karacadağ olarak sınıflandırdığını ve dolayısıyla bu sınıf özelinde sınırlı sayıda da olsa yanlış pozitiflerin üretildiğini düşündürmektedir. Bu tür hataların daha ayrıntılı biçimde analiz edilebilmesi adına, karışıklık matrisinin görselleştirilmesi önerilmektedir. Özellikle hangi sınıflar arasında kalan karışıklıkların daha yoğun olduğu tespit edilerek, bu örneklerin özel olarak analiz edilmesi mümkündür. Ayrıca, Grad-CAM gibi görselleştirme teknikleri kullanılarak modelin karar verirken hangi özelliklere odaklandığı incelenebilir ve bu sayede modelin belirli sınıflarda neden hata yaptığı daha iyi anlaşılabilir. Performans düzeyinin zaten oldukça yüksek olduğu göz önüne alındığında, ince ayar stratejileri ya da farklı model çıktılarının birleştirilmesine dayanan ensembling yöntemleri kullanılarak doğruluk oranının %98'in üzerine çıkarılması olasıdır.


Sonuç olarak, bu model şu ana kadar geliştirilenler arasında en dengeli ve yüksek doğruluk oranına sahip yapı olarak öne çıkmaktadır. İpsala, Basmati ve Jasmine sınıflarında neredeyse kusursuz bir başarı sergilerken, önceki modellerde problemli olduğu tespit edilen Karacadağ ve Arborio sınıflarında da belirgin iyileşmeler sağlamıştır. Bu bulgular, modelin tüm sınıflarda yüksek performans sergilediğini ve uygulamaya yönelik güçlü bir aday olduğunu göstermektedir. Çizelge 6.14'te Model 5'e ait sınıf bazlı kıyaslama sunulmuştur.

Çizelge 6. 14. Model 5 sınıf bazlı kıyaslama


Sınıf	En Güçlü Yön	İyileştirme Gereken Alan
Arborio	Kesinlik (%99)	Duyarlılık (%95) → Bazı örnekleri kaçırıyor
Basmati	Denge (%99 F1)	-
İpsala	Mükemmel (1,00 F1)	-
Jasmine	Yüksek duyarlılık (%99)	Kesinlik biraz daha iyileştirilebilir
Karacadağ	Tam duyarlılık (%100)	Kesinlik iyileştirilebilir (%96)

6.4.6. Model 6 performansı


Veri seti, modelin eğitim ve test aşamalarında kullanılmak üzere %80 eğitim ve %20 test olarak ayrılmıştır. Görseller, 224 x 224 piksel boyutlarında yeniden ölçeklendirilmiştir. Modelin eğitim süreci boyunca görüntüler “Arborio”, “Basmati”, “Jasmine”, “Karacadağ” ve “İpsala” sınıfları altında etiketlenmiştir. Model 6’ya ait performans değerlendirmeleri; karmaşıklık matrisi Şekil 6.34’te, kayıp ve doğrulama değerleri Şekil 6.35’te, ROC eğrisi Şekil 6.36’da ve eğitime ilişkin değerlendirme verileri Çizelge 6.15’te sunulmuştur.



Şekil 6. 34. Model 6 modelinin karmaşıklık matrisi



Şekil 6. 35. Model 6 modelinin kayıp ve doğrulama değerleri



Şekil 6. 36. Model 6 modelinin ROC eğrisi

Çizelge 6. 15. Model 6 modelinin değerlendirme verileri

Pirinç Türü	Kesinlik	Duyarlılık	F1-Skor	Veri Sayısı
Arborio	0,978	0,992	0,985	3 000
Basmati	0,982	1,000	0,991	3 000
İpsala	0,998	1,000	0,999	3 000
Jasmine	0,994	0,982	0,988	3 000
Karacadağ	1,000	0,978	0,989	3 000
Doğruluk	0,990			15 000
Sınıf Bazlı Ortalama	0,990	0,990	0,990	15 000
Ağırlıklı Ortalama	0,990	0,990	0,990	15 000

Model 6, %99 doğruluk oranı ile şimdiye kadar geliştirilen modeller arasında en yüksek genel başarıya ulaşmıştır. Bu seviye, her 100 örnekten yalnızca birinin yanlış sınıflandırıldığını ve modelin sınıflandırma görevini neredeyse hatasız yerine getirdiğini göstermektedir. Ayrıca, sınıf bazlı ve ağırlıklı ortalama değerlerinin her ikisinin de %99 seviyesinde olması, modelin tüm sınıflarda son derece dengeli ve tutarlı bir performans sergilediğini ortaya koymaktadır. Bu, sınıf dengesizliğinin modelin performansını olumsuz etkilemediğini ve her sınıfa eşit ağırlıkla başarılı bir şekilde yaklaşabildiğini göstermesi açısından önemlidir. Özellikle İpsala sınıfında elde edilen sonuçlar dikkat çekicidir. Kesinlik oranı 0.998, duyarlılık oranı ise 1,000 olarak ölçülmüş ve F1-skor değeri 0,999 seviyesinde gerçekleşmiştir. Bu, modelin İpsala sınıfına ait örnekleri hem çok yüksek doğrulukla tahmin ettiğini hem de neredeyse hiçbir gerçek İpsala örneğini atlamadığını göstermektedir. Benzer şekilde, daha önceki modellerde sınıflar arası karışıklığın gözlemlendiği Karacadağ ve Jasmine sınıflarında da belirgin iyileşmeler sağlanmıştır. Karacadağ sınıfında kesinlik oranı 1,000'e ulaşmış, duyarlılık değeri ise 0,978 olarak hesaplanmıştır. Jasmine sınıfında ise kesinlik değeri 0,994 duyarlılık oranı ise 0,982 olarak ölçülmüş ve her iki metrik de sınıfın genel başarımlar düzeyinin oldukça yüksek olduğunu göstermektedir. Modelin genel başarımlar çok yüksek düzeyde olmakla birlikte, iyileştirme potansiyeli barındıran bazı küçük farklılıklar gözlemlenmiştir. Karacadağ sınıfında duyarlılık oranının %97,8 olması, modelin birkaç örneği başka sınıflarla karıştırdığını göstermektedir. Benzer şekilde Jasmine sınıfında %99,4 kesinlik ve %98,2 duyarlılık değerleri küçük çaplı yanlış negatifleri işaret etmektedir. Bu hatalar modelin genel başarısını kayda değer ölçüde etkilememekle birlikte, karmaşıklık matrisi görselleştirmeleri ile bu örneklerin hangi sınıflarla karıştırıldığı analiz edilebilir ve sınıf sınırlarının daha da netleştirilmesi sağlanabilir. Modelin gösterdiği bu güçlü genel performans, aynı zamanda başka veri setlerine transfer öğrenme yoluyla adapte edilmesi için de güçlü bir temel sunmaktadır. Bu doğrultuda, mevcut ağırlıklar ince ayar yöntemi ile yeni problem alanlarına kolaylıkla uyarlanabilir. Modelin hem doğruluk hem de sınıflar arası denge açısından sergilediği tutarlılık, onu gelecekteki model değerlendirmelerinde bir referans noktası haline getirmektedir. Aşırı öğrenme belirtilerinin bulunmaması ve performansın tüm sınıflar arasında eşit biçimde dağılmış olması, modelin genellenebilirliğini desteklemektedir. Ayrıca, sınıf dengesizliğinden etkilenmediği net biçimde ortaya konmuş ve bu durum, sınıf bazlı ile ağırlıklı ortalamaların eşit düzeyde yüksek çıkmasıyla kanıtlanmıştır. Tüm bu nitelikler bir araya geldiğinde, modelin yalnızca doğruluk açısından değil, aynı zamanda bütüncül sınıflandırma performansı bakımından da


en güçlü model olarak öne çıktığı söylenebilir. Çizelge 6.16’da Model 6 sınıf bazlı kıyaslama gösterilmiştir.

Çizelge 6. 16. Model 6 sınıf bazlı kıyaslama


Sınıf	En Güçlü Yön	İyileştirme Gereken Nokta
Arborio	Çok yüksek duyarlılık (%99,2)	Kesinlik %97,8 → az da olsa yanlış pozitif var
Basmati	Mükemmel duyarlılık (%100)	Kesinlik %98,2 → çok az yanlış pozitif
İpsala	Neredeyse mükemmel	Yok denecek kadar az hata
Jasmine	Yüksek kesinlik (%99,4)	Duyarlılık %98,2 → birkaç örnek kaçmış
Karacadağ	Kesinlik %100	Duyarlılık %97,8 → az sayıda kaçan örnek var

6.4.7. Model 7 performansı


Veri seti, modelin eğitim ve test aşamalarında kullanılmak üzere %80 eğitim ve %20 test olarak ayrılmıştır. Görseller, 224 x 224 piksel boyutlarında yeniden ölçeklendirilmiştir. Modelin eğitim süreci boyunca görüntüler “Arborio”, “Basmati”, “Jasmine”, “Karacadağ” ve “İpsala” sınıfları altında etiketlenmiştir. Model 7’ye ait performans değerlendirmeleri; karmaşıklık matrisi Şekil 6.37’de, kayıp ve doğrulama değerleri Şekil 6.38’de, ROC eğrisi Şekil 6.39’da ve eğitime ilişkin değerlendirme verileri Çizelge 6.17’de sunulmuştur.



Şekil 6. 37. Model 7 modelinin karmaşıklık matrisi



Şekil 6. 38. Model 7 modelinin kayıp ve doğrulama değerleri



Şekil 6. 39. Model 7 modelinin ROC eğrisi

Çizelge 6. 17. Model 7 modelinin değerlendirme verileri

Pirinç Türü	Kesinlik	Duyarlılık	F1-Skor	Veri Sayısı
Arborio	1,000	0,988	0,994	3 000
Basmati	0,995	1,000	0,997	3 000
İpsala	1,000	1,000	1,000	3 000
Jasmine	0,999	0,995	0,997	3 000
Karacadağ	0,988	1,000	0,994	3 000
Doğruluk	0,996			15 000
Sınıf Bazlı Ortalama	0,996	0,996	0,996	15 000
Ağırlıklı Ortalama	0,996	0,996	0,996	15 000

Modelin teknik deęerlendirmesi, %99,6 doęruluk oranıyla řimdiye kadarki en yksek bařarı dzeyine ulařıldığını gstermektedir. Bu oran, 15 000 rnek zerinden yapılan testte yalnızca ok kk bir kısmın hatalı sınıflandırıldığını ve modelin sınıflandırma grevinde neredeyse kusursuz bir performans sergilediğini ortaya koymaktadır. Ayrıca kesinlik, duyarlılık ve F1-skor gibi temel performans metriklerinin hem sınıf bazlı hem de aęırlıklı ortalamalarının %99,6 dzeyinde ve birbirine eřit olması, modelin tm sınıflarda dengeli ve tutarlı bir sınıflandırma yaptığını iřaret etmektedir. zellikle İpsala sınıfında elde edilen sonular dikkat ekicidir. Kesinlik, duyarlılık ve F1-skor deęerlerinin tamamı 1,000 olarak gerekleřmiř ve modelin bu sınıfı %100 doęrulukla tanıdığı anlařılmıřtır. Ayrıca dięer tm sınıflarda F1-skor deęerinin 0,994 ve zeri olması, modelin yalnızca yksek doęrulukta tahminler yapmakla kalmayıp aynı zamanda olduka dřk hata oranıyla alıřtığını gstermektedir. Bu genel bařarı dzeyi, modeli pratik kullanım aısından olduka gl bir konuma getirmektedir. Bununla birlikte, iyileřtirme gerektiren alanlar son derece sınırlı ve minimal dzeydedir. Arborio sınıfında duyarlılık oranı %98,8 olarak llmř; bu durum, 36 Arborio rneğinin farklı sınıflara atandığını gstermektedir. Benzer řekilde Jasmine sınıfında duyarlılık oranı %99,5 olup yalnızca 15 rneğın yanlış sınıflandırılmıř olabileceğı ngrlmektedir. Karacadaę sınıfında ise kesinlik oranı %98,8 seviyesindedir; bu da modelin, Karacadaę dıřındaki bazı rnekleri bu sınıfa atadığını gstermektedir. Ancak bu sapmalar olduka dřk dzeyde olup modelin genel bařarısını pratikte etkilemeyecek ldedir.

Model 7, veri setindeki tm sınıfları ayırt etme aısından ideal bir sonuca olduka yakın bir performans sergilemektedir. Bu durum, nceki modellerle kıyaslandığında yalnızca en yksek genel doęruluęun deęil, aynı zamanda en dengeli sınıf bazlı performansın da elde edildiğini gstermektedir. Ayrıca minimum hata oranı ile modelin sınıflar arası karıřıklıkları byk lde ortadan kaldırdığını anlařılmaktadır. Bu modelin canlı sistemlerde kullanıma hazır hale geldiğı sylenbilir. Uygulama ncesi srete, kalan az sayıda hatanın hangi sınıflar arasında gerekleřtiğini daha net grebilmek adına karmařıklık matrisi zerinden detaylı bir analiz yapılması nerilmektedir. Ayrıca, ilerleyen ařamalarda sınıf bazlı aęırlıklandırma veya modelin genellenebilirliğini artırmak iin yapılan veri eřitlendirme iřlemi olan augmentasyon stratejilerinin eřitlendirilmesi gibi ince ayarlarla bu kk sapmalar da giderilebilir. Mevcut haliyle bu model, referans alınabilecek bir yapı olarak retim ortamında kullanılmak zere gl bir adaydır. izelge 6.18’de modelin sınıf bazlı kıyaslaması sunulmuřtur.

Çizelge 6. 18. Model 7 sınıf bazlı kıyaslama

Sınıf	En Güçlü Yön	Minimal Gelişim Noktası
Arborio	Kesinlik: 1,000	Duyarlılık %98,8 (az kaçırma var)
Basmati	Duyarlılık: 1,000	Kesinlik %99,5
İpsala	Tüm metriklerde 1,000	-
Jasmine	Kesinlik %99,9	Duyarlılık %99,5
Karacadağ	Duyarlılık: 1,000	Kesinlik %98,8

6.5. Yeni Oluşturulan Modellerin Karşılaştırılması


Sonuçlar incelendiğinde, en yüksek performansa sahip modelin Model 7 olduğu açıkça görülmektedir. Bu model, %99,6 doğruluk oranıyla yalnızca en yüksek genel başarıyı elde etmekle kalmamış, aynı zamanda tüm sınıflarda neredeyse kusursuz bir denge sergilemiştir. Özellikle İpsala sınıfında %100 başarı oranına ulaşılması, modelin belirli sınıflarda öğrenmeyi tam anlamıyla gerçekleştirdiğini ortaya koymaktadır. Sınıflar arasında belirgin bir dengesizlik bulunmaması, bu modelin üretim ortamına uygunluğunu güçlü biçimde desteklemektedir. Çizelge 6.19’da yeni oluşturulan modellerin karşılaştırmalı tablosu ortaya konulmuştur.

Çizelge 6. 19. Modellerin karşılaştırmalı performans özeti

Model No	Doğruluk	Kesinlik	Duyarlılık	F1-Skor
Model 1	0,850	0,85	0,85	0,84
Model 2	0,916	0,939	0,916	0,913
Model 3	0,932	0,947	0,932	0,931
Model 4	0,960	0,96	0,96	0,96
Model 5	0,980	0,99	0,98	0,98
Model 6	0,990	0,990	0,990	0,990
Model 7	0,996	0,996	0,996	0,996


Model 6, %99 doğruluk oranıyla istikrarlı ve yüksek güvenilirliğe sahip bir yapı sunmaktadır. Performans metrikleri arasında minimal sapmalar gözlenmiş, ancak genel değerlendirmede modelin oldukça dengeli ve kararlı bir sınıflandırıcı olduğu anlaşılmıştır. Bu yönüyle Model 6, özellikle açıklanabilirlik açısından avantaj sunabilir; aynı zamanda farklı modellerin birlikte kullanımıyla tahmin gücünü artırma yöntemi olan ensemble yöntemlerinde ana model bileşeni olarak tercih edilebilecek niteliktedir. Model 4’ten Model 5’e geçiş süreci, özellikle performans artışı açısından dikkat çekicidir. Doğruluk oranında %96’dan %98’e yükselen bu sıçrama, modelin hem yapısal hem de hiperparametrik iyileştirmelerle önemli ölçüde geliştiğini göstermektedir. Karacadağ gibi

önceki modellerde sorun yaşanan sınıflarda gözlemlenen belirgin iyileşmeler, bu gelişim sürecini somutlaştırmaktadır. Model 2 ise erken aşamada fark oluşturan bir model olarak değerlendirilebilir. %91,6 doğruluk oranıyla sınıflandırma performansı açısından başarılı bir temel oluşturmuştur. Ancak özellikle İpsala sınıfında görülen belirgin sınıflandırma hataları, bu modelin sonraki aşamalarda kapsamlı bir şekilde yeniden yapılandırıldığını göstermektedir. Şekil 6.40'da modellerin doğruluk gelişimi gösterilmiştir.



Şekil 6. 40. Modellerin doğruluk gelişimi

Sonuç olarak, Model 7 şu an için en uygun üretim adayı olarak öne çıkmaktadır. Bu modelin genişletilmiş veri setlerine adapte edilmesi, mobil uygulamalara uyarlanması ya da gerçek zamanlı tahmin sistemlerine entegre edilmesi yönünde çalışmalar yapılabilir. Öte yandan, Mevcut modellerde kalan az sayıdaki hatanın daha detaylı analiz edilebilmesi için karmaşıklık matrisi verilerinin incelenmesi ve örnek görsellerin değerlendirilmesi, son adımda önemli katkılar sağlayacaktır. Şekil 6.41'de modellerin F1-Skor karşılaştırılması yapılmıştır.




Şekil 6. 41. Modellerin sınıf ortalaması F1-skor karşılaştırması


6.6. Transfer Öğrenme Modelleri ile Yeni Oluşturulan Modellerin Karşılaştırılması

Tezin bu bölümünde, beş farklı pirinç türünü (Arborio, Basmati, İpsala, Jasmine, Karacadağ) sınıflandırmak amacıyla eğitilmiş 12 farklı derin öğrenme modelinin başarımını kapsamlı biçimde analiz edilmektedir. Her model, aynı veri kümesi üzerinde

test edilerek doğruluk, kesinlik, duyarlılık ve F1-skoru gibi temel sınıflandırma metrikleriyle değerlendirilmiştir. Özellikle Model 7, VGG16, DenseNet121 ve InceptionV3 modelleri %99 ve üzeri doğruluk oranlarıyla dikkat çekerken; Model 1, %85 doğruluk oranı ile en düşük başarıyı göstermiştir.-Model 5 ve Model 6, önceki sürümlerine göre hem mimari hem de hiperparametre düzeyinde iyileştirilmiş olup %98-99 doğruluk aralığında istikrarlı sonuçlar sunmuştur. Bununla birlikte, Arborio ve Karacadağ sınıflarında genel olarak daha düşük F1-skorumları gözlenmiştir; bu durum, sınıflar arası ayrımın zorluğuna işaret etmektedir. Transfer öğrenme temelli VGG16, DenseNet121 ve InceptionV3 modelleri yalnızca yüksek doğruluk oranlarıyla değil, aynı zamanda tüm sınıflarda dengeli performans göstermeleriyle öne çıkmaktadır. EfficientNetB0 ve ResNet50 gibi daha sade yapıli modeller ise %97-98 doğrulukla yeterli düzeyde başarı sağlamıştır. Özellikle İpsala sınıfı tüm modeller için yüksek F1-skoru ile dikkat çekerken, Arborio ve Karacadağ sınıflarında ise daha düşük başarılar gözlemlendiği dikkat çekmektedir. Bu sınıflar arası varyasyon, modellerin ayırt edici özellikleri algılama kapasitesi ile ilişkilendirilebilir. Kullanılan 12 modelin doğruluk karşılaştırması Şekil 6.42’de verilmiştir. Yine tüm modellerin kesinlik, duyarlılık ve F1-skor değerleri karşılaştırması Şekil 6.43’te verilmiştir. Çizelge 6.20’de tüm modellerin başarıml ölçütleri karşılaştırılması verilmiştir.



Şekil 6. 42. Modellerin doğruluk değerleri karşılaştırması



Şekil 6. 43. Modellerin kesinlik, duyarlılık ve F1-skor değerleri karşılaştırması

Genel değerlendirmede, üretim ortamlarında kullanılacak modeller için doğruluk ve kararlılık temel kıstaslar olarak belirlenmiş; bu bağlamda VGG16, DenseNet121 ve Model 7 gibi yüksek performanslı modeller önerilmektedir. Özelleştirilmiş Model 6 ve Model 5 ise esnek yapıları nedeniyle farklı senaryolara uyarlanabilir alternatifler sunmaktadır. Düşük başarı gösteren sınıflar için ise veri artırma, sınıf ağırlığı ayarlaması ve focal loss (sınıf dengesizliğini azaltmaya yönelik özel bir loss türüdür) gibi yöntemler önerilmektedir.

- Yüksek Performans: Model 7 > VGG16 $\approx$ DenseNet121 $\approx$ InceptionV3 > Model 6
- Orta Seviye: Model 4 < EfficientNetB0 < Model 5 < ResNet50
- Düşük Performans: Model 1 < Model 2 < Model 3

Çizelge 6. 20. Tüm modellerin doğruluk, kesinlik, duyarlılık, F1-skor tablosu

Model	Doğruluk	Kesinlik	Duyarlılık	F1-skor
Model 1	0,85	0,85	0,85	0,84
Model 2	0,916	0,939	0,916	0,913
Model 3	0,932	0,947	0,932	0,931
Model 4	0,96	0,96	0,96	0,96
Model 5	0,98	0,99	0,98	0,98
Model 6	0,99	0,99	0,99	0,99
Model 7	0,996	0,996	0,996	0,996
DenseNet121	0,99	0,99	0,99	0,99
EfficientNetB0	0,97	0,98	0,97	0,97
InceptionV3	0,99	0,99	0,99	0,99
ResNet50	0,98	0,98	0,98	0,98
VGG16	0,99	0,99	0,99	0,99

7. SONUÇLAR VE ÖNERİLER

Bu çalışmada, beş farklı pirinç türünün (Arborio, Basmati, İpsala, Jasmine ve Karacadağ) görsel verileri kullanılarak sınıflandırılmasına yönelik derin öğrenme tabanlı yaklaşımların etkinliği araştırılmıştır. Çalışmanın temel amacı, geleneksel sınıflandırma yöntemlerinin yerine geçebilecek; daha hızlı, daha doğru ve düşük maliyetli bir otomatik sınıflandırma sistemi geliştirmektir. Bu doğrultuda, hem yaygın olarak kullanılan transfer öğrenme temelli evrişimsel sinir ağı modelleri (VGG16, InceptionV3, EfficientNetB0, ResNet50 ve DenseNet121) hem de bu çalışma kapsamında yeni tasarlanıp kademeli iyileştirmelerle oluşturulan yedi özel model (Model 1–7) kapsamlı bir şekilde değerlendirilmiştir.

Tez kapsamında kullanılan ve 75 000 görüntüden oluşan veri seti, kapsamı ve dengeli dağılımı açısından literatürdeki birçok çalışmaya kıyasla daha üstün bir nitelik taşımaktadır. Her bir pirinç türüne ait eşit sayıda örnek kullanılarak gerçekleştirilen model eğitimi sayesinde, sınıflar arası dengesizlikten kaynaklanabilecek olası yanlışlıkların önüne geçilmiştir. Elde edilen deneysel bulgular, hem transfer öğrenme tabanlı derin öğrenme modellerinin hem de bu çalışma özelinde yeni tasarlanarak geliştirilen mimarilerin söz konusu sınıflandırma problemine etkili bir şekilde uygulanabileceğini ortaya koymaktadır.

Transfer öğrenme tabanlı modeller arasında VGG16, DenseNet121 ve InceptionV3, %99 seviyesine ulaşan doğruluk oranları ile son derece istikrarlı ve yüksek performans sergilemiştir. Bu modellerin her birinde, tüm sınıflar için kesinlik, duyarlılık ve F1-skor değerlerinin dengeli ve yüksek düzeyde olması, sınıflar arası ayrım yeteneğinin etkili bir biçimde öğrenildiğini ortaya koymaktadır. Öte yandan, EfficientNetB0 ve ResNet50 gibi daha sade ve hafif mimariler de %97–98 aralığında doğruluk oranlarına ulaşarak, düşük donanım gereksinimleriyle birlikte tatmin edici bir performans sunmuştur. Bu sonuçlar, farklı mimari yapıların hem doğruluk hem de kaynak kullanımı açısından çeşitli avantajlar sağlayabildiğini göstermektedir.

Çalışmanın en dikkat çekici yönlerinden biri, yeni tasarlanarak geliştirilen yedi özel modelin, transfer öğrenme tabanlı önceden eğitilmiş modellerle rekabet edebilecek düzeye ulaşmış olmasıdır. Model 1, temel ve sade bir mimariyi temsil ederken, sonraki modellerde katman derinliği, dropout oranları, normalizasyon stratejileri ve havuzlama teknikleri gibi yapısal bileşenler kademeli olarak iyileştirilmiş; böylece her bir model, selefine kıyasla

anlamli performans artişları sergilemiştir. Bu aşamalı geliştirme sürecinin sonunda elde edilen Model 7, %99,6 doğruluk oranına ulaşarak yalnızca özelleştirilmiş modeller arasında değil, tüm modeller içerisinde en yüksek başarıyı göstermiştir.

Özelleştirilmiş modeller kapsamında, mimari derinlik, katman sayısı, optimizasyon algoritmaları ve renk uzayı dönüşümlerinin (ör. RGB'den HSV'ye geçiş) model performansına etkisi sistematik olarak incelenmiştir. Başlangıçta %85 seviyelerinde olan doğruluk oranı, gerçekleştirilen iyileştirmeler sayesinde kademeli olarak yükseltilmiş ve nihayetinde %99,6 düzeyine taşınmıştır. Örneğin, Model 4'te Global Average Pooling katmanının entegrasyonu ile doğruluk oranı %96'ya ulaşmış; Model 5'te ise modelin öğrenme sürecini belirleyen kullanıcı tanımlı ayarı olan hiperparametre optimizasyonu ve modelin karmaşıklığını düşürerek test başarımını iyileştirme yöntemi olan regularization tekniklerinin uygulanması sonucunda Karacadağ sınıfı için duyarlılık değeri %100'e çıkarılmıştır. Bununla birlikte, tüm modellerde Arborio ve Karacadağ sınıflarında zaman zaman gözlemlenen kesinlik ve duyarlılık dengesizliklerinin, bu sınıfların morfolojik ve renk özelliklerinin diğer sınıflarla örtüşmesinden kaynaklanabileceği düşünülmektedir. Model 1'den Model 7'ye uzanan bu gelişim süreci, derinlik artışı, dropout ve katmanlara giren verilerin standart dağılıma getirilmesi işlemi gibi düzenleme teknikleri, farklı aktivasyon fonksiyonları ve renk uzayı dönüşümlerinin model başarımı üzerindeki etkisini açık biçimde ortaya koymuştur. Sonuç olarak, geliştirilen Model 7, yalnızca yüksek doğruluk seviyesiyle değil, aynı zamanda tüm sınıflarda dengeli performans sergileyerek üretim ortamlarına entegre edilebilecek düzeyde güvenilir bir sınıflandırma aracı olarak değerlendirilmiştir.

Model 7, yüksek doğruluk oranı ve tüm sınıflarda gösterdiği dengeli performans ile öne çıkmaktadır. Özellikle İpsala sınıfında elde edilen %100 başarı oranı, modelin bu kategoriye ait örüntüleri etkili biçimde öğrenebildiğini ve genelleme yeteneğinin güçlü olduğunu göstermektedir. Arborio ve Karacadağ türlerinde bazı modellerde gözlemlenen sınıflandırma hataları ise, bu türlerin görsel özelliklerinin diğer pirinç türleriyle belirli açılardan örtüşmesiyle ilişkilendirilmektedir. Bununla birlikte, geliştirilen özel modellerde bu sınıflar için de belirgin performans artışları sağlanmış ve ayırt edicilik gücü artırılmıştır.

Model 7'nin ulaştığı %99,6 doğruluk oranı, yalnızca özel mimariler arasında değil, aynı zamanda güçlü transfer öğrenme tabanlı modellerle de rekabet edebilecek düzeyde bir

başarıyı temsil etmektedir. Bu model, doğruluk metriğinin ötesinde, sınıfa özgü değerlendirme ölçütlerinde de tutarlı ve dengeli sonuçlar vermiş; bu yönüyle üretim ortamlarında uygulanabilir, güvenilir bir çözüm sunma potansiyelini ortaya koymuştur.

İpsala türünün neredeyse tüm modeller tarafından yüksek doğrulukla sınıflandırılması, bu sınıfa özgü belirgin morfolojik ve renk özelliklerinin model tarafından kolaylıkla öğrenildiğini göstermektedir. Öte yandan, Arborio ve Karacadağ türlerinde gözlemlenen daha düşük F1 skorları, sınıflar arası ayrım gücünün mimari özelliklerin yanı sıra veri setinin içsel çeşitliliği ile de yakından ilişkili olduğunu ortaya koymaktadır. Bu bağlamda, Model 6'nın istikrarlı başarımı ve yapısal yalınlığı, onu potansiyel olarak farklı modellerin birlikte kullanımıyla tahmin gücünü artırma yöntemi olan ensemble sınıflandırma sistemlerinde temel bileşen olarak değerlendirmeye açık hâle getirmiştir.

Elde edilen bulgular, RGB ve HSV renk uzaylarının birlikte kullanılması, veri artırma tekniklerinin entegrasyonu ve dropout ile batch normalization gibi düzenleme mekanizmalarının mimariye sistematik biçimde dâhil edilmesinin model başarımı üzerinde anlamlı bir etki oluşturduğunu ortaya koymuştur. Renk uzayı dönüşümlerinin birlikte kullanımı, veri çeşitliliğini artırarak modelin farklı görsel varyasyonlara karşı daha dirençli hâle gelmesini sağlamıştır. Özellikle RGB ve HSV renk uzaylarının kombinasyonu ile veri artırma stratejilerinin eş zamanlı uygulanması, aşırı öğrenmenin önlenmesinde ve modelin genelleme kapasitesinin güçlendirilmesinde kritik bir rol oynamıştır. Bu teknik yaklaşımlar, morfolojik olarak benzer sınıfların ayrıştırılmasında modelin başarısını %3 ile %5 oranında artırmış; karmaşık örneklerin doğru sınıflandırılmasında belirgin bir iyileşme sağlamıştır. Dolayısıyla, bu yapılandırmalar yalnızca modelin genel doğruluğunu yükseltmekle kalmamış, aynı zamanda sınıflar arası ayrım gücünü de kuvvetlendirmiştir.

Akademik açıdan değerlendirildiğinde, bu çalışma yalnızca yüksek doğruluk oranlarına sahip modellerin geliştirilmesiyle sınırlı kalmamış, aynı zamanda bir derin öğrenme mimarisinin sistematik olarak nasıl optimize edilebileceğine dair metodolojik bir çerçeve de sunmuştur. Model geliştirme süreci boyunca gerçekleştirilen katman bazlı iyileştirmeler, hiperparametre optimizasyonları ve dropout gibi düzenleme stratejileri, performansın adım adım nasıl evrildiğini ortaya koymuş; böylece derin öğrenme mimarilerinin tasarımına yönelik değerli bir yol haritası sunulmuştur.

Tarım 4.0 perspektifiyle ele alındığında ise, bu çalışma yalnızca teknik bir sınıflandırma probleminin çözümüne katkı sunmakla kalmamış; aynı zamanda gıda güvenliği, sürdürülebilir üretim ve tarımsal dijitalleşme süreçlerine yönelik stratejik bir açılım da sağlamıştır. Özellikle yüksek doğruluk oranlarına ulaşılan özel modellerin hem teorik bilgi üretimine hem de pratik uygulamalara dönük yapıları, çalışmanın disiplinler arası değerini artırmaktadır.

Sonuç olarak, bu tez çalışması, derin öğrenme tabanlı yöntemlerin pirinç türlerinin görsel sınıflandırmasında geleneksel yaklaşımlara kıyasla hem daha yüksek doğruluk hem de operasyonel uygulanabilirlik sunduğunu ortaya koymuştur.

Geliştirilen modeller yalnızca akademik düzeyde başarılı olmakla kalmamış; aynı zamanda tarım sektöründe kalite kontrol, ürün izleme ve otomasyon sistemlerine entegre edilebilecek nitelikte, güçlü ve sürdürülebilir bir teknolojik altyapı sunmuştur. Ayrıca, bu çalışma bir CNN mimarisinin nasıl sistematik biçimde optimize edilebileceğini adım adım göstermiştir. Böylece hem teorik hem uygulamalı düzeyde derin öğrenme yöntemlerinin tarımsal üretimde nasıl dönüştürücü bir role sahip olabileceği kanıtlanmıştır.

7.1. Öneriler

Bu tez çalışması, pirinç türlerinin görsel sınıflandırılmasında derin öğrenmenin sunduğu yüksek doğruluk, genellenebilirlik ve operasyonel verimlilik gibi avantajları somut biçimde ortaya koymuştur. Özellikle Model 7 başta olmak üzere geliştirilen özel mimariler, yalnızca teorik olarak yüksek başarıya ulaşmakla kalmamış, aynı zamanda üretim hatlarında kullanılabilecek düzeye erişmiştir. %99,6 doğruluk oranı ve sınıf bazlı dengeli performans değerleriyle Model 7, transfer öğrenme temelli yaklaşımlarla rekabet edebilecek düzeyde güvenilir bir sistem ortaya koymuştur. Bu kapsamda geliştirilen sistemler, endüstriyel pirinç işleme tesislerinde gerçek zamanlı kalite kontrol çözümleri olarak entegre edilebilir. Böylece insan müdahalesine ihtiyaç duymayan, tam otomatik ve yüksek hassasiyetli sınıflandırma sistemleri hayata geçirilebilir. Model 6 gibi istikrarlı ve açıklanabilir yapılara sahip mimarilerin ensemble yaklaşımlarla birleştirilmesi ise hata toleransı daha yüksek ve kararlı hibrit sistemlerin geliştirilmesini mümkün kılacaktır.

Geliştirilen modellerin yalnızca pirinç özelinde değil, buğday, mercimek gibi benzer morfolojik yapı gösteren diğer tahıl türlerine de transfer öğrenme yoluyla uyarlanabilir olması, bu çalışmanın genellenebilirliğini artıran önemli bir noktadır. Özellikle zorlayıcı sınıflar olan Arborio ve Karacadağ türlerinde gözlemlenen hata oranlarının azaltılması amacıyla sınıfa özgü veri artırma stratejileri uygulanmalı; farklı kamera açılarında, değişken ışık koşullarında ve çeşitli zeminlerde veri toplanmalıdır. Gerekli durumlarda multispektral veya üç boyutlu görüntüleme tekniklerinin entegrasyonu da veri zenginliği açısından değerlendirilebilir.

Modelin karar verme sürecinin daha şeffaf hale getirilmesi için Grad-CAM (derin öğrenmede karar yorumlama aracı) gibi açıklanabilir yapay zekâ yöntemlerinin kullanımı, üretim ortamlarında kullanıcı güveni sağlamak ve model iç görülerini anlamak açısından önem arz etmektedir. Özellikle kararın hangi özelliklere dayandığının görsel olarak sunulabilmesi, sistemin yorumlanabilirliğini ve kabul edilebilirliğini artıracaktır. Ayrıca mobil cihazlara veya tarım makinelerine entegre edilebilecek daha hafif yapılar (örneğin Model 4 gibi) geliştirilerek saha uygulamaları test edilmeli, düşük enerji tüketimli sistemlerin kırsal alanlarda çalışabilirliği değerlendirilmelidir. Bu tür hafif mimarilerle çiftçilere yönelik kullanıcı dostu mobil uygulamalar geliştirilebilir ve Türkçe dil destekli çözümler ile sınıflandırma işlemleri tarlada dahi gerçekleştirilebilir.

Bu çalışma aynı zamanda sosyal ve politik düzlemde de öneriler sunmaktadır. Tarım ve Orman Bakanlığı gibi kamu kurumlarının açık veri setleri oluşturması, yapay zekâ yarışmaları düzenlemesi ve pilot bölgelerde (örneğin Edirne, Samsun) yapay zekâ destekli tarım kooperatiflerini desteklemesi, bu teknolojilerin yaygınlaşmasını hızlandıracaktır. Federated learning (veri paylaşımı olmadan çoklu cihazlarda ortak model eğitimi) gibi merkezsiz öğrenme stratejileri ise veri gizliliğini koruyarak farklı üreticiler arasında model paylaşımını mümkün kılabilir. Bu bağlamda, üretici kooperatifleri arasında merkezi olmayan ama ortak akıl yürüten sistemlerin kurulması teşvik edilmelidir.

İleriye dönük olarak, mevcut sistem yalnızca tür sınıflandırmasına odaklanmıştır. Gelecekte bu sistem, kırık oranı, tane boyutu, saflık ve nem oranı gibi kalite parametrelerini de içerecek şekilde çoklu etiketli sınıflandırma sistemlerine dönüştürülebilir. Bu yönde yapılacak çalışmalar, kalite kontrol kapsamını genişleterek, ürün standardizasyonunu ve ihracat potansiyelini artırabilir.

Ayrıca, Vision Transformer (dikkat mekanizması kullanan modern görsel sınıflandırma yöntemi), Swin Transformer (görüntüleri kaydırmalı pencerelerle işleyerek verimli dikkat mekanizması uygulayan model) gibi güncel mimarilerin tarımsal sınıflandırma problemlerinde nasıl bir başarı göstereceği de önemli bir araştırma konusu olabilir. Bu yeni nesil yapılar, mevcut CNN temelli modellerle karşılaştırılarak daha esnek ve yüksek kapasiteli sistemlerin geliştirilmesine olanak sağlayabilir.

Bu tez kapsamında geliştirilen derin öğrenme modelleri, tarım sektörünün ötesinde farklı disiplinlerde de önemli katkılar sağlayabilecek potansiyele sahiptir. Özellikle güneş enerjisi sistemlerinde panel yüzeylerinin görsel olarak izlenmesi ve arıza tespitinde kullanılabilir; böylece enerji verimliliğinin artırılması ve bakım maliyetlerinin azaltılması mümkün hale gelir.

Eğitim teknolojilerinde ise yapay zekâ destekli görsel analiz yöntemleri, uzaktan eğitim ortamlarında öğrencilerin etkileşimlerinin değerlendirilmesi veya eğitsel içeriklerin otomatik sınıflandırılması gibi yenilikçi uygulamalara zemin hazırlayabilir. Ayrıca, sağlık, güvenlik, perakende ve şehir planlaması gibi farklı alanlarda da nesne tanıma ve sınıflandırma yeteneği sayesinde karar destek sistemlerinin geliştirilmesine katkı sağlayabilir. Bu bağlamda, geliştirilen modellerin esnek ve uyarlanabilir yapısı, yaşamın çeşitli alanlarında dijital dönüşümü destekleyerek yapay zekânın çok yönlü kullanımına olanak tanımaktadır.

Geliştirilen sistemler, Türkiye’deki pirinç üreticileri başta olmak üzere tarım sektöründe faaliyet gösteren tüm paydaşlar için kalite kontrol süreçlerini modernize edebilecek potansiyele sahiptir. Uygun kamusal destek, saha testleri ve çiftçi eğitimleri ile bu teknolojilerin yaygınlaştırılması, yalnızca tarımda dijitalleşmeyi değil; aynı zamanda sürdürülebilir üretim ve gıda güvenliği hedeflerini de doğrudan destekleyecektir.

“Geleneksel tarımı dijitalle buluşturan her adım, gıda güvenliği ve sürdürülebilirlik için atılmış bir temeldir.”

KAYNAKLAR

- Abuelelwa, M. H. S. and Abu-Naser, S. S. (2024). Classification of Rice Using Deep Learning. *International Journal of Academic Information Systems Research (IJAIRS)*, 8(4), 26–36.
- Acar, U. ve Bayram, B. (2009, 11-15 Mayıs). *Morfolojik Görüntü Filtreleri ile İkonos Görüntülerinden Otomatik Bina Çıkarımı*. TMMOB Harita ve Kadastro Mühendisleri Odası 12. Türkiye Harita Bilimsel ve Teknik Kurultayı, Ankara.
- Ahmed, T. and Sabab, N. H. N. (2022). Classification and understanding of cloud structures via satellite images with EfficientUNet. *SN Computer Science*, 3(1), 99.
- Akkoca, E. ve Buluş, E. (2021). Telea ve Naiver Stokes Algoritmaları Kullanılarak Görüntülerdeki Bozulmaları Düzeltme. *Türkiye Bilişim Vakfı Bilgisayar Bilimleri ve Mühendisliği Dergisi*, 14(2), 77-85.
- Alan, A. ve Karabatak, M. (2020). Veri Seti- Sınıflandırma İlişkisinde Performansa Etki Eden Faktörlerin Değerlendirilmesi. *Fırat Üniversitesi Mühendislik Bilimleri Dergisi*, 32(2), 531-540.
- Alıyev, H. ve Güneş, P. (2023). Makine öğrenme algoritmalarını kullanan duygu tahminine dayalı müzik öneri sistemi. *Anadolu Bil Meslek Yüksekokulu Dergisi*, 18(68), 189-234.
- Altunay, A. (2012). Geleneksel Medyadan Yeni Medyaya: Görüntü Yüzeyi. *Selçuk Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 27, 33-44.
- Altunkurt, Ö. ve Kahrıman, M. (2011). Gerçek Zamanlı Olarak, Anfis ile Renk Tabanlı Nesne Tespit ve Motorlu Sistem ile Takip Edilmesi. *Teknik Bilimler Dergisi*, 1(1), 1-5.
- Alzubaidi, L., Zhang, J., Humaidi, A. J., Al-Dujaili, A., Duan, Y., Al-Shamma, O. and Farhan, L. (2021). Review of deep learning: concepts, CNN architectures, challenges, applications, future directions. *Journal of big Data*, 8, 1-74.
- Arslan, S. (2022). *Türkiye’de tarım sektöründe pirinç üretimi*. Tarım ve Orman Bakanlığı Raporu. URL: <https://www.tarimorman.gov.tr> (Son erişim tarihi: 01.11.2024)
- Avkıran, B. ve Yılmaz, H. (2023). Çeltik Üreticilerinin Sürdürülebilir Tarım Algılamalarını Etkileyen Faktörlerin Analizi: Edirne İli İpsala İlçesi Örneği. *Türk Tarım ve Doğa Bilimleri Dergisi*, 10(2), 371-379.
- Aydın, H. (2003), *Matlab ile Kontrol Sistemlerinin İncelenmesi*, Lisans Bitirme Tezi, Marmara Üniversitesi Teknik Eğitim Fakültesi, İstanbul, 2003
- Aydın, S., Taşyürek, M. ve Öztürk, C. (2023). MR Görüntülerinde Evrişimli Sinir Ağlar Kullanılarak Alzheimer Hastalık Tespiti. *Erciyes Üniversitesi Fen Bilimleri Enstitüsü Fen Bilimleri Dergisi*, 39(3), 357-368.

- Balcı, M., Altun, A. A. ve Taşdemir, Ş. (2016). Görüntü işleme teknikleri kullanılarak napolyon tipi kirazların sınıflandırılması.
- Beşer, N. and Sürek, H. (2012). Rice food security and production in Turkey. *Advances in Temperate Rice Research, International Rice Research Institute, Los Baños, Philippines*, 89-96.
- Bharathi, V. P. N., Muthusamy, K., Natarajan, B., Appavu, S., Vasudevan, B., Marimuthu, R. and Rajaram, D. (2024). Leveraging machine learning models for export assessment of basmati and non-basmati rice in tamil nadu. *Feb-Fresenius Environmental Bulltten*, 1619.
- Bhattacharjee, A. (2024). A comparative study on rice grain classification using convolutional neural network and other machine learning techniques. *International Journal of Intelligent Systems and Applications in Engineering*, 12(4), 2466–2472.
- Bishop, C. M. and Nasrabadi, N. M. (2006). *Pattern recognition and machine learning* (Vol. 4, No. 4, p. 738). New York: springer.
- Bora, D. J., Gupta, A. K. and Khan, F. A. (2015). Comparing the performance of L* A* B* and HSV color spaces with respect to color image segmentation. arXiv preprint arXiv:1506.01472.
- Bolouri, H. (1995). Book Review: Fundamentals of Neural Networks – Architectures, Algorithms, and Applications: L. FAUSETT. *International Journal of Electrical Engineering and Education*, 32(3), 284–285.
- Boyacıgil, M. F. (2022). *Görüntü İşleme Teknikleriyle Bir Endüstriyel Kalite Kontrol Uygulaması*. Yüksek Lisans Tezi, Necmettin Erbakan Üniversitesi Fen Bilimleri Enstitüsü, Konya.
- Boztoprak, H., Çağlar, M. F. ve Merdan, M. (2007). Alternatif morfolojik bir yöntemle plaka yerini saptama. *XII. Elektrik, Elektronik, Bilgisayar, Biyomedikal Mühendisliği Ulusal Kongresi. Eskişehir, Kasım*.
- Bradski, G. (2000). The opencv library. *Dr. Dobb's Journal: Software Tools for the Professional Programmer*, 25(11), 120-123.
- Bükücü, Ç. C. (2021). *Görüntü İşleme Teknikleri ile Cam Ürünlerde Hata Tespiti*, Doktora Tezi, Gaziosmanpaşa Üniversitesi Lisansüstü Eğitim Enstitüsü, Tokat.
- Chen, Z. (2023). *Hardware accelerated optimization of deep learning model on artificial intelligence chip*. *Frontiers in Computing and Intelligent Systems*, 6(2).
- Cinar, I. and Koklu, M. (2022). Identification of rice varieties using machine learning algorithms. *Journal of Agricultural Sciences*, 9-9.

- Ciresan, D. C., Meier, U., Masci, J., Maria Gambardella, L. and Schmidhuber, J. (2011, July). Flexible, high performance convolutional neural networks for image classification. In *IJCAI proceedings-international joint conference on artificial intelligence* (Vol. 22, No. 1, p. 1237).
- Cizmeci, I. H. and Altun, A. A. (2023). Improved Electro Search Algorithm with Intelligent Controller Control System: ESPID Algorithm. *Intelligent Automation and Soft Computing*, 35(3).
- Çam, K., Aydın, C. and Tarhan, C. (2022, September). Classification of fabric defects using deep learning algorithms. In *2022 Innovations in Intelligent Systems and Applications Conference (ASYU)* (pp. 1-6). IEEE.
- Çınar, İ. (2019). Yapay zekâ teknikleri kullanılarak pirinç çeşitlerinin sınıflandırılması, Selçuk Üniversitesi Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi
- Çiftçi, M. E. ve Tekin, R. (Mart 2023). *Türk İşaret Dilinin Transfer Öğrenme Yöntemleriyle Sınıflandırılması*. Uluslararası Bilişim Kongresi Bildiriler Kitabı, Batman.
- Dalal, N. and Triggs, B. (2005, June). Histograms of oriented gradients for human detection. In *2005 IEEE computer society conference on computer vision and pattern recognition (CVPR'05)* (Vol. 1, pp. 886-893). Ieee.
- Dawe, D. (Ed.). (2012). *The rice crisis: Markets, policies and food security*. Routledge.
- Deepthi, R. S. and Sankaraiah, S. (2011, September). Implementation of mobile platform using Qt and OpenCV for image processing applications. In *2011 IEEE Conference on Open Systems* (pp. 284-289). IEEE.
- Deng, L., Yu, D. (2013). Deep Learning: Methods and Applications. *Foundations and Trends® in Signal Processing*, 7(3-4), 197-387.
- Din, N. M. U., Assad, A., Dar, R. A., Rasool, M., Sabha, S. U., Majeed, T. and Yaseen, A. (2024). RiceNet: A deep convolutional neural network approach for classification of rice varieties. *Expert Systems with Applications*, 235, 121214.
- Elen, A. (2020). Görüntü ikileştirme için global eşikleme yöntemleri üzerine bir inceleme. *Mühendislik Bilimleri ve Araştırmaları Dergisi*, 2(2), 38-49.
- Elkıran, H. (2020). *Occ-Opencv kütüphanesi için blok tabanlı programlama aracı* (Master's thesis, İstanbul Sabahattin Zaim Üniversitesi, Fen Bilimleri Enstitüsü, Bilgisayar Bilimleri ve Mühendisliği Anabilim Dalı).
- Erdal, H. ve Korucuk, S. (2023). Bütünleşik Dalgacık Dönüşümü-Evrişimsel Sinir Ağları Tabanlı Derin Öğrenme Yaklaşımı ve Borsa Tahmini Üzerine Bir Uygulama. *Karadeniz Sosyal Bilimler Dergisi*, 15(29), 387-404.
- Erdal, F. (2022). *Uzaktan eğitimde ters-yüz sınıf uygulamalarının bilişsel aktiviteye etkisi*, Yüksek Lisans Tezi, Ondokuz Mayıs Üniversitesi, Lisansüstü Eğitim Enstitüsü.

- Ergin, C. (2024), *Tütün yaprağı üzerinde bulunan hastalıkları morfolojik görüntü işleme metotlarıyla tespit eden gerçek zamanlı gömülü sistem tasarımı*, Yüksek Lisans Tezi, Amasya Üniversitesi Fen Bilimleri Enstitüsü, Amasya
- Erişti, E. (2010, 10-12 Şubat). *Görüntü İşlemede Yeni Bir Soluk, Opencv*. Akademik Bilişim'10, XII. Akademik Bilişim Konferansı Bildirileri, Muğla.
- Fagundes, P. B. and de Macedo, D. D. J. (2023). An analysis on the Use of Knowledge Organization Systems in the process of requirements Engineering. *Ko Knowledge Organization*, 49(6), 411-422.
- Fitzgerald, M. A., McCouch, S. R. and Hall, R. D. (2009). Not just a grain of rice: the quest for quality. *Trends in plant science*, 14(3), 133-139.
- Gonzalez, R. C. and Woods, R. E. (2018). *Digital image processing* (4th ed.). Pearson.
- Goodfellow, I., Bengio, Y., Courville, A. and Bengio, Y. (2016). *Deep learning* (Vol. 1, No. 2). Cambridge: MIT press.
- Gopalakrishnan, K. and Vivek, J. D. R. (2022). Rice grain classification using image processing technique. *International journal of health sciences*, 6(S5), 919-928.
- Gu, J., Wang, Z., Kuen, J., Ma, L., Shahroudy, A., Shuai, B. and Chen, T. (2018). Recent advances in convolutional neural networks. *Pattern recognition*, 77, 354-377.
- Gupta, D. and Rani, R. (2019). A study of big data evolution and research challenges. *Journal of information science*, 45(3), 322-340.
- Güler, E. (2018). *Fındık Zarı Uygunluğunun Opencv ile Belirlenmesi İçin Yazılım ve Donanım Geliştirilmesi*. Yüksek Lisans Tezi, Selçuk Üniversitesi Fen Bilimleri Enstitüsü, Konya.
- Harmanci, S., Yavuz, Ü. and Barış, A. (2023). Classification of hazelnut species with pre-trained deep learning models. *Intelligent Methods In Engineering Sciences*, 2(2), 58-66.
- Harris, C. R., Millman, K. J., van der Walt, S. J., Gommers, R., Virtanen, P., Cournapeau, D., Wieser, E., Taylor, J., Berg, S., Smith, N. J., Kern, R., Picus, M., Hoyer, S., van Kerkwijk, M. H., Brett, M., Haldane, A., del Río, J. F., Wiebe, M., Peterson, P., Gérard-Marchant, P., Sheppard, K., Reddy, T., Weckesser, W., Abbasi, H., Gohlke, C. and Oliphant, T. E. (2020). Array Programming with NumPy. *Nature*, 585(7825), 357-362.
- He, K., Zhang, X., Ren, S. and Sun, J. (2016). Deep residual learning for image recognition. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 770-778).
- Hlavatý, M., Kozáková, A. and Haffner, O. (2022, September). Application for python programming language education developed by unity engine. In *2022 Cybernetics and Informatics (K and I)* (pp. 1-6). IEEE

- Hoang, V. T., Van Hoai, D. P., Surinwarangkoon, T., Duong, H. T. and Meethongjan, K. (2020). A comparative study of rice variety classification based on deep learning and hand-crafted features. *ECTI Transactions on Computer and Information Technology (ECTI-CIT)*, 14(1), 1-10.
- Horasan, D. (2016). *Mermer Yüzeylerinin Görüntü İşleme Yöntemi ile Değerlendirilmesi*. Tezsiz Yüksek Lisans Bitirme Projesi, Pamukkale Üniversitesi Fen Bilimleri Enstitüsü, Denizli.
- Huang, G., Liu, Z., Van Der Maaten, L. and Weinberger, K. Q. (2017). Densely connected convolutional networks. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 4700-4708).
- Hunter, J. and Dale, D. (2007). The matplotlib user's guide. Matplotlib 0.90. 0 user's guide, 487.
- Iandola, F. N., Han, S., Moskewicz, M. W., Ashraf, K., Dally, W. J. and Keutzer, K. (2016). SqueezeNet: AlexNet-level accuracy with 50x fewer parameters and <0.5 MB model size. ArXiv preprint arXiv:1602.07360.
- Ioffe, S. and Szegedy, C. (2015, June). Batch normalization: Accelerating deep network training by reducing internal covariate shift. In *International conference on machine learning* (pp. 448-456). pmlr.
- İnternet 1: AtlasBig. (b.t.) Pirinç üretimine göre ülkeler URL: <https://atlasbig.com.tr/pirinc-uretimine-gore-ulkeler> Son Erişim Tarihi: 24.12.2024
- İnternet 2: Coğrafya Hocası (2021) İllerimizin Çeltik (Pirinç) Üretim Miktarı Harita (2020) URL: <https://cogrfyahocasi.com/haritalar/turkiye-celtik-pirinc-uretimi-harita-2020.html> Son Erişim Tarihi: 14.12.2024
- İnternet 3: Hunter, J. D. (2008). History (Project Information). The Matplotlib. <https://matplotlib.org/stable/users/project/history.html>. Son Erişim Tarihi: 10.12.2024.
- İnternet 4: Medium (2021). Inception V3 CNN Architecture Explained. URL: <https://medium.com/@AnasBrital98/inception-v3-cnn-architecture-explained-691cfb7bba08> Son Erişim Tarihi: 10.08.2024
- İnternet 5: MIR, (b.t), Structure of DenseNet: (a) Dense block structure; (b) DenseNet overall structure. URL: <https://www.mi-research.net/supplement/2fd644e5-3c8e-4c47-8342-caccbcb49dc3> Son Erişim Tarihi: 08.10.2024
- İnternet 6: OpenCV. (t.b.). About. URL: <https://opencv.org/about/> Son Erişim Tarihi: 10.10.2024
- İnternet 7: Simurg AI Lab (2020) Görüntü İşleme Nedir? URL: <https://www.simurgai.com/G%C3%B6r%C3%BCnt%C3%BC-%C4%B0%C5%9Fleme-Nedir/> Son Erişim Tarihi: 10.10.2024

- İnternet 8: Tao, K. (2021), The AUC-ROC Curve. URL: https://udrc.ushe.edu/news/2021/research_skills/20210407AucRocCurve.html. Son Erişim Tarihi: 11.12.2024.
- İnternet 9: Tarım ve Orman Bakanlığı. (2023). Pirinç Durum ve Tahmin Raporu 2023. Tarımsal Ekonomi ve Politika Geliştirme Enstitüsü (TEPGE). URL: <https://arastirma.tarimorman.gov.tr/tepge/Belgeler/PDF%20Durum-Tahmin%20Raporlar%C4%B1/2023%20Durum-Tahmin%20Raporlar%C4%B1/Pirin%C3%A7%20Durum%20Tahmin%20Raporu%202023-387%20TEPGE.pdf> Son Erişim Tarihi:01.11.2024
- İnternet 10: TIOBE Index for May 2025. URL: <https://www.tiobe.com/tiobe-index>. Son Erişim Tarihi:01.05.2025.
- Jimeno-Morenilla, A., Pujol, F. A., Molina-Carmona, R., Sánchez-Romero, J. L. and Pujol, M. (2014). Trajectory-based morphological operators: a model for efficient image processing. *The Scientific World Journal*, vol. 2014, 1-9.
- Juliano, B. O. and Villareal, C. P. (1993). *Grain quality evaluation of world rices*. International Rice Research Institute.
- Kahraman, Ş., Atakul, Ş., Kılınç, S., Alp, A., Duman, M., Baran, B. ve Özaslan, C. (2021). Çeltik yetiştiriciliğinde organik tarım olanaklarının araştırılması ve konvansiyonel tarım ile karşılaştırılması. *Toprak Bilimi ve Bitki Besleme Dergisi*, 9(2), 54-61.
- Kambo, R. and Yerpude, A. (2014). Classification of basmati rice grain variety using image processing and principal component analysis. arXiv preprint arXiv:1405.7626.
- Karhan M, Oktay M. O., Karhan Z., Demir H., 2011, Morfolojik Görüntü İşleme Yöntemleri ile Kayıslarda Yaprak Delen (Çil) Hastalığı Sonucu Oluşan Lekelerin Tespiti, 6 th International Advanced Technologies Symposium (IATS'11), Elâzığ, Türkiye, 172-176.
- Khush, G. S. (2013). Strategies for increasing the yield potential of cereals: case of rice as an example. *Plant Breeding*, 132(5), 433-436.
- Kılıç, Ş. (2023). *Derin Öğrenme Yöntemleri Kullanılarak Giyilebilir Sensörlerden Kişi Tanıma*, Doktora Tezi, Ankara Üniversitesi Fen Bilimleri Enstitüsü, Ankara.
- Kingma, D. P. and Ba, J. (2014). Adam: A method for stochastic optimization. arXiv preprint arXiv:1412.6980.
- Koklu, M., Cinar, I. and Taspinar, Y. S. (2021). Classification of rice varieties with deep learning methods. *Computers and electronics in agriculture*, 187, 106285.
- Köklü, M. (2020). *Rice Image Dataset*. Erişim adresi: <https://www.muratkoklu.com/datasets/>

- Krizhevsky, A., Sutskever, I. and Hinton, G. E. (2012). Imagenet classification with deep convolutional neural networks. *Advances in neural information processing systems*, 25.
- Kuo, T. Y., Chung, C. L., Chen, S. Y., Lin, H. A. and Kuo, Y. F. (2016). Identifying rice grains using image analysis and sparse-representation-based classification. *Computers and Electronics in Agriculture*, 127, 716-725.
- LeCun, Y., Bengio, Y. and Hinton, G. (2015). Deep Learning. *Nature*, 521(7553), 436-444.
- LeCun, Y., Bottou, L., Bengio, Y. and Haffner, P. (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11), 2278-2324.
- Lin, M., Chen, Q. and Yan, S. (2013). Network in network. *arXiv preprint arXiv:1312.4400*.
- Litjens, G., Kooi, T., Bejnordi, B. E., Setio, A. A. A., Ciompi, F., Ghafoorian, M. and Sánchez, C. I. (2017). A survey on deep learning in medical image analysis. *Medical image analysis*, 42, 60-88.
- McKinney, W. (2012). *Python for data analysis: Data wrangling with Pandas, NumPy, and IPython*. " O'Reilly Media, Inc."
- Mohanty, S. (2013). Trends in global rice consumption. *Rice Today*, 12(1), 44-45.
- Mohidem, N. A., Hashim, N., Shamsudin, R. and Che Man, H. (2022). Rice for food security: Revisiting its production, diversity, rice milling process and nutrient content. *Agriculture*, 12(6), 741.
- Muthayya, S., Sugimoto, J. D., Montgomery, S. and Maberly, G. F. (2014). An overview of global rice production, supply, trade, and consumption. *Annals of the new york Academy of Sciences*, 1324(1), 7-14.
- Nair, V. and Hinton, G. E. (2010). Rectified linear units improve restricted boltzmann machines. In *Proceedings of the 27th international conference on machine learning (ICML-10)* (pp. 807-814).
- Othman, O. A. O. (2020). *Evreşimsel Sinir Ağları Tabanlı Otomatik Görüntü Renklendirme*. Yüksek Lisans Tezi, Selçuk Üniversitesi Fen Bilimleri Enstitüsü, Konya.
- Özçelebi, M. A. ve Yılmaz, C. (2020). Samsun'da çeltik üretimi ve pirinç imalat sanayi. *Kesit Akademi Dergisi*, 6(24), 324-349.
- Özdal, M. A. (2023). Görüntü İçeriği Sınıflandırmasında Yapay Zekanın Rolü ve Uygulamaları. *Van İnsani ve Sosyal Bilimler Dergisi*, (6), 37-61.
- Paliwal, J., Erkinbaev, C. and Mebatsion, H. K. (2015). Towards Machine Vision Based Grain Classification: Challenges and Future Prospects. In *BIOLOGICAL SHAPE ANALYSIS: Proceedings of the 3rd International Symposium* (pp. 65-78).

- Paliwal, J., Visen, N. S. and Jayas, D. S. (2001). Evaluation of neural network architectures for cereal grain classification using morphological features.
- Pathare, P. B., Opara, U. L. and Al-Said, F. A. J. (2013). Colour measurement and analysis in fresh and processed foods: A review. *Food and bioprocess technology*, 6, 36-60.
- Perihanoğlu, G. M., 2015, Dijital Görüntü İşleme Teknikleri Kullanılarak Görüntülerden Detay Çıkarımı, Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi, İstanbul.
- Peker, M. (2009). *Görüntü İşleme Tekniği Kullanılarak Gerçek Zamanlı Hareketli Görüntü Tanıma*. Yüksek Lisans Tezi, Sakarya Üniversitesi Fen Bilimleri Enstitüsü, Sakarya.
- Prasetyo, E., Suciati, N. and Fatichah, C. (2022). Multi-level residual network VGGNet for fish species classification. *Journal of King Saud University-Computer and Information Sciences*, 34(8), 5286-5295.
- Pratt, W. K. (2007). *Digital image processing: PIKS Scientific inside* (Vol. 4). Hoboken, New Jersey: Wiley-interscience.
- Python Software Foundation. (2021). os — Miscellaneous operating system interfaces. Python 3.9.7 documentation. Retrieved from
- Rajamani, S. K. and Iyer, R. S. (2023). Machine learning-based mobile applications using Python and Scikit-Learn. In *Designing and developing innovative mobile applications* (pp. 282-306). IGI Global.
- Raschka, S. and Mirjalili, V. (2019). *Python machine learning: Machine learning and deep learning with Python, scikit-learn, and TensorFlow 2*. Packt publishing ltd.
- Rezvi, H. U. A., Tahjib-Ul-Arif, M., Azim, M. A., Tumpa, T. A., Tipu, M. M. H., Najnine, F. and Brestič, M. (2023). Rice and food security: Climate change implications and the future prospects for nutritional security. *Food and Energy Security*, 12(1), e430.
- Russakovsky, O., Deng, J., Su, H., Krause, J., Satheesh, S., Ma, S. and Fei-Fei, L. (2015). Imagenet large scale visual recognition challenge. *International journal of computer vision*, 115, 211-252.
- Saddami, K., Nurdin, Y., Zahramita, M. and Safiruz, M. S. (2024). Advancing Green AI: Efficient and Accurate Lightweight CNNs for Rice Leaf Disease Identification. *arXiv preprint arXiv:2408.01752*.
- Sağlam, S. ve Oy, S. A. (2024). İki eksenli güneş takip sistemi ile sabit eksenli fotovoltaik (PV) sistemlerinin tasarımı ve uzaktan izlenmesi. *Düzce Üniversitesi Bilim ve Teknoloji Dergisi*, 12(1), 348-364.
- Sahrawat, K. L. (2005). Fertility and organic matter in submerged rice soils. *Current science*, 735-739.
- Samtaş, G. ve Gülesin, M. (2011). Sayısal görüntü işleme ve farklı alanlardaki uygulamaları. *Ejovoc (Electronic Journal of Vocational Colleges)*, 2(1), 85-97.

- Sandler, M., Howard, A., Zhu, M., Zhmoginov, A. and Chen, L.- C. (2018, June). *Mobilenetv2: Inverted Residuals and Linear Bottlenecks*. IEEE Conference on Computer Vision and Pattern Recognition, Salt Lake City, UT, USA.
- Sarı, C. (2023). *Python Programlama Dili Kullanılarak Günlük Maksimum Yağış Verilerinin Trend ve Risk Analizleri*. Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi Lisansüstü Eğitim Enstitüsü, İstanbul.
- Scherer, D., Müller, A. and Behnke, S. (2010, September). Evaluation of pooling operations in convolutional architectures for object recognition. In *International conference on artificial neural networks* (pp. 92-101). Berlin, Heidelberg: Springer Berlin Heidelberg.
- Serra, J. (1983). *Image analysis and mathematical morphology*. Academic Press, Inc..
- Silva, C. S. and Sonnadara, U. (2013, September). Classification of rice grains using neural networks. In *Proceedings of technical sessions* (Vol. 29, pp. 9-14). Institute of Physics Sri Lanka.
- Simonyan, K. and Zisserman, A. (2014). Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*.
- Singh, K. R. and Chaudhury, S. (2016). Efficient technique for rice grain classification using back-propagation neural network and wavelet decomposition. *IET Computer Vision*, 10(8), 780-787.
- Sommerville, I. (2016). *Software Engineering* (10th ed.). Pearson Education.
- Son, N. H. and Thai-Nghe, N. (2019, November). Deep learning for rice quality classification. In *2019 international conference on advanced computing and applications (ACOMP)* (pp. 92-96). IEEE.
- Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I. and Salakhutdinov, R. (2014). Dropout: a simple way to prevent neural networks from overfitting. *The journal of machine learning research*, 15(1), 1929-1958.
- Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J. and Wojna, Z. (2016). Rethinking the inception architecture for computer vision. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 2818-2826).
- Şener, T., Helvacıoğlu, İ. A., Tokatlı, C. and Balkan, A. (2017). Fertilizer and Pesticide Preferences of Rice Producers in İpsala District: An Economic Survey. *Tarım Bilimleri Araştırma Dergisi*, 10(2), 33-37.
- Tan, M. and Le, Q. (2019, May). Efficientnet: Rethinking model scaling for convolutional neural networks. In *International conference on machine learning* (pp. 6105-6114). PMLR.

- Tieleman, T. and Hinton, G. (2012). Lecture 6.5- RMSprop: Divide the gradient by a running average of its recent magnitude. *COURSERA: Neural Networks for Machine Learning*.
- Tiryaki, S. H. ve Balaman, F. (2021). Açık Kaynak Kodlu Yazılımlardan Scratch, Arduino ve Python Kullanımı Hakkında Öğrenci Görüşleri. *Journal of Computer and Education Research*, 9(18), 831-852.
- Toptaş, B., 2017, Yangın/Alev Renk Özellikleri Kullanılarak Orman Yangınlarının Tespiti, Yüksek Lisans Tezi, İnönü Üniversitesi, Malatya.
- Toraman, S. (2016). *Kızılötesi Spektroskopisi Kullanılarak Kan Örneklerinden Kolon Kanserine Yönelik Özellik Çıkarımı*, Doktora Tezi, Fırat Üniversitesi Fen Bilimleri Enstitüsü, Elâzığ.
- Türkmen, A. (2021). *Konvolüsyonel Yapay Sinir Ağları ve Görüntü İşleme Teknikleri ile Biyomedikal Görüntülerden Diyabetik Retinopati Teşhisi*. Yüksek Lisans Tezi, Ankara Üniversitesi Fen Bilimleri Enstitüsü, Ankara.
- Unal, Y., Taspınar, Y. S., Cinar, I., Kursun, R. and Koklu, M. (2022). Application of pre-trained deep convolutional neural networks for coffee beans species detection. *Food Analytical Methods*, 15(12), 3232-3243.
- Ünal, Y. (2015). *Makine Öğrenmesi Yöntemleriyle Bel Bölgesi Rahatsızlıklarının Tanısı*, Doktora Tezi, Selçuk Üniversitesi Fen Bilimleri Enstitüsü, Konya.
- Van Der Walt, S., Colbert, S. C. and Varoquaux, G. (2011). The NumPy array: a structure for efficient numerical computation. *Computing in science and engineering*, 13(2), 22-30.
- Van Rossum, G. and Drake, F. L. (1995). Python reference manual (Vol. 111, pp. 1-52). Amsterdam: Centrum voor Wiskunde en Informatica.
- Wang, X., Kondratyuk, D., Kitani, K. M., Movshovitz-Attias, Y. and Eban E. (2020). Multiple Networks are More Efficient than One: Fast and Accurate Models via Ensembles and Cascades. *Computing Research Repository (CoRR)*, December 2020.
- Wang, Z.; Wang, R.; Wang, M.; Lai, T.; Zhang, M. Self-Supervised Transformer-Based Pre-Training Method with General Plant Infection Dataset. In Proceedings of the Pattern Recognition and Computer Vision; Lin, Z., Cheng, M.-M., He, R., Ubul, K., Silamu, W., Zha, H., Zhou, J., Liu, C.-L., Eds.; Springer Nature Singapore: Singapore, 2025; pp. 189–202.
- Wilkinson, H. C., and Champagne, E. T. 2004. Value-added rice products. Pages 473-493 in: Rice: Chemistry and Technology, 3rd Ed. E. T. Champagne, ed. American Association of Cereal Chemists: Saint Paul, MN.
- Wu, M.T. (2022). Confusion matrix and minimum cross-entropy metrics based motion recognition system in the classroom. *Scientific Reports*, 12, 3095.

- Xia, W., Peng, R., Chu, H., Zhu, X., Yang, Z. and Wang, Y. (2025). An Overall Real-Time Mechanism for Classification and Quality Evaluation of Rice. *arXiv preprint arXiv:2502.13764*.
- Yakkundimath, R., Saunshi, G., Anami, B. and Palaiah, S. (2022). Classification of rice diseases using convolutional neural network models. *Journal of The Institution of Engineers (India): Series B*, 103(4), 1047-1059.
- Yılmaz, T. (2019). *Raspberry Pi Kartı Kullanarak Nesne Tespit ve Takip Robotunun Tasarımı ve Modellenmesi*. Yüksek Lisans Tezi, Fırat Üniversitesi Fen Bilimleri Enstitüsü, Elâzığ.
- Ying W, Zhang Y, Huang J, Yang Q (2018) Transfer learning via learning to transfer. in International Conference on Machine Learning. PMLR
- Yusuf, H. M., Ali, Y. S., Abubakar, A. H., Abdullahi, M. and Hassan, I. H. (2024). A systematic review of deep learning techniques for rice disease recognition: Current trends and future directions. *Franklin Open*, 100154.
- Zeiler, M. D. and Fergus, R. (2014). Visualizing and understanding convolutional networks. In *Computer Vision–ECCV 2014: 13th European Conference, Zurich, Switzerland, September 6-12, 2014, Proceedings, Part I* 13 (pp. 818-833). Springer International Publishing.
- Zhang, X., Zhou, X., Lin, M. and Sun, J. (2018). Shufflenet: An extremely efficient convolutional neural network for mobile devices. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 6848-6856).

ÖZGEÇMİŞ

Adı-Soyadı : Ömer ESEN

Bilimsel Faaliyetler (Yayınlar, Bildiriler, Katıldığı Projeler)

- 1-) Esen, Ö. ve Evecen, M. (2024, Ekim). *Pirinç Ürününün Derin Öğrenme Tekniklerini Kullanılarak Türlerinin Ayırıt Edilmesi*. Al Farabi 13. Uluslararası Bilimsel Araştırmalar ve İnovasyon Kongresi (s. 126). Tekirdağ, Türkiye.

