



**T.C.
BATMAN ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
BİLGİ TEKNOLOJİLERİ ANA BİLİM DALI**

YÜKSEK LİSANS TEZİ

**TARIM ÜRÜNLERİNİN SINIFLANDIRILMASINDA
DERİN ÖĞRENME KULLANIMI: SIIRT FISTIĞI ÖRNEĞİ**

Mesut ERDOĞAN

**Ocak-2025
BATMAN**

**T.C.
BATMAN ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
BİLGİ TEKNOLOJİLERİ ANA BİLİM DALI**

YÜKSEK LİSANS TEZİ

**TARIM ÜRÜNLERİNİN SINIFLANDIRILMASINDA
DERİN ÖĞRENME KULLANIMI: SIIRT FISTIĞI ÖRNEĞİ**

Mesut ERDOĞAN

**Danışman
Dr. Öğr. Üyesi Abdulkerim ÖZTEKİN**

**Diğer Jüri Yeleri
Doç. Dr. Yılmaz KAYA Doç. Dr. Melih KUNCAN**

**Ocak-2025
BATMAN**

TEZ KABUL VE ONAYI

Mesut ERDOĞAN tarafından hazırlanan “Tarım ürünlerinin sınıflandırılmasında derin öğrenme kullanımı: Siirt fıstığı örneği” adlı tez çalışması 21/01/2025 tarihinde aşağıdaki jüri tarafından oy birliği ile Batman Üniversitesi Lisansüstü Eğitim Enstitüsü Bilgi Teknolojileri Ana Bilim Dalı’nda YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Jüri Üyeleri

İmza

Başkan

Doç. Dr. Yılmaz KAYA

.....

Danışman

Dr. Öğr. Üyesi Abdulkerim ÖZTEKİN

.....

Üye

Doç. Dr. Melih KUNCAN

.....

Yukarıdaki sonucu onaylarım.

Dr. Öğr. Üyesi Ömer Murat ÖTER
Lisansüstü Eğitim Enstitüsü Müdürü V.

ETİK BEYANI

Bu tezdeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edildiğini ve tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını beyan eder, aksinin ortaya çıkması durumunda her türlü yasal sorumluluğu kabullendiğimi bildiririm.

ETHICAL DECLARATION

I declare that all the information in this thesis has been obtained within the framework of ethical behavior and academic rules, and that the source of any statements and information that do not belong to me in this study prepared in accordance with the thesis writing rules has been fully cited, and I declare that I accept all kinds of legal responsibility in case of any contrary situation.

Mesut ERDOĞAN
Tarih: 21/01/2025

ÖZET

YÜKSEK LİSANS TEZİ

TARIM ÜRÜNLERİNİN SINIFLANDIRILMASINDA DERİN ÖĞRENME KULLANIMI: SIİRT FISTIĞI ÖRNEĞİ

Mesut ERDOĞAN

Batman Üniversitesi Lisansüstü Eğitim Enstitüsü

Bilgi Teknolojileri Ana Bilim Dalı

Danışman: Dr. Öğr. Üyesi Abdulkerim ÖZTEKİN

2025, 45 Sayfa

Bu tez, tarım ürünlerinin sınıflandırılmasında derin öğrenme tekniklerinin potansiyelini incelemek ve uygulamalı bir model geliştirmek amacıyla hazırlanmıştır. Tarım sektörü, kalite kontrol ve sınıflandırma süreçlerinde genellikle manuel yöntemlere dayanmakta olup bu da süreçlerin hem zaman alıcı hem de hata oranlarının yüksek olmasına neden olmaktadır. Gelişen teknolojiyle birlikte, tarım ürünlerinin otomatik olarak sınıflandırılmasını sağlayacak yapay zeka temelli yaklaşımlar, hem üreticilere hem de tüketicilere çeşitli avantajlar sunma potansiyeline sahiptir. Bu çalışmada, Siirt fıstığı örneği üzerinden derin öğrenme tabanlı bir sınıflandırma modeli geliştirilmiştir. Çalışmanın ilk aşamasında, Siirt fıstığının kalite kriterleri belirlenmiş ve bu kriterlere göre geniş bir veri seti oluşturulmuştur. Veri seti, farklı kalite sınıflarını (örneğin, iri, orta boy, düşük kaliteli; deformasyona uğramış ya da renk farkı olan fıstıklar) kapsayacak şekilde çeşitlendirilmiştir. Görüntüler, gelişmiş görsel veri toplama teknikleri kullanılarak yüksek çözünürlükte elde edilmiş ve veri setinin zenginleştirilmesi amacıyla veri artırma yöntemleri uygulanmıştır. Derin öğrenme modeli olarak konvolüsyonel sinir ağları (CNN) tercih edilmiş ve modelin performansını artırmak için çeşitli mimari düzenlemeler yapılmıştır. Modelin eğitimi ve testi sırasında hiperparametre optimizasyonu gerçekleştirilmiş, doğruluk oranını artırmak için dropout, öğrenme hızı ayarı ve erken durdurma gibi teknikler uygulanmıştır. Modelin performansı, doğruluk, kesinlik, duyarlılık ve F1 skor metriği kullanılarak değerlendirilmiştir. Elde edilen sonuçlar, Siirt fıstığının sınıflandırılmasında geliştirilen derin öğrenme modelinin %99 doğruluk oranı ile başarılı bir şekilde çalıştığını ortaya koymuştur. Modelin sonuçları, geleneksel manuel sınıflandırma yöntemleri ile karşılaştırıldığında, hem zaman hem de doğruluk açısından önemli avantajlar sağlamaktadır. Ayrıca, tarım sektöründeki diğer ürünlere uygulanabilirlik potansiyeli de değerlendirilmiştir. Bu çalışma, tarım sektöründe kalite kontrol süreçlerini optimize etmek, üreticilere verimlilik sağlamak ve tüketici memnuniyetini artırmak adına önemli bir adım olarak değerlendirilmektedir. Gelecekteki çalışmalar için, daha büyük veri setlerinin oluşturulması, farklı derin öğrenme mimarilerinin test edilmesi ve modelin gerçek zamanlı uygulamalarda denenmesi önerilmektedir.

Anahtar Kelimeler: Derin öğrenme, Konvolüsyonel sinir ağları, ResNet Modelleri, Siirt fıstığı, Tarım ürünleri sınıflandırması, Yapay zeka.

ABSTRACT
MASTER THESIS
THE USE OF DEEP LEARNING IN CLASSIFICATION OF AGRICULTURAL
PRODUCTS: SİİRT PISTACHIO CASE STUDY

Mesut ERDOĞAN

Batman University Graduate Education Institute

Department of Information Technologies

Advisor: Dr. Öğr. Üyesi Abdulkarim ÖZTEKİN

2025, 45 Pages

This thesis aims to investigate the potential of deep learning techniques in the classification of agricultural products and to develop an applied model. The agricultural sector generally relies on manual methods for quality control and classification processes, which makes these processes both time-consuming and error-prone. With the advancing technology, artificial intelligence-based approaches to automatically classify agricultural products have the potential to offer various advantages to both producers and consumers. In this study, a deep learning-based classification model is developed on the example of Siirt pistachio. In the first stage of the study, the quality criteria of Siirt pistachio were determined and a large dataset was created according to these criteria. The dataset was diversified to cover different quality classes (e.g., large, medium, low quality, deformed or discolored pistachios). The images were acquired at high resolution using advanced visual data acquisition techniques and data augmentation methods were applied to enrich the dataset. Convolutional neural networks (CNN) were chosen as the deep learning model and various architectural modifications were made to improve the performance of the model. During the training and testing of the model, hyperparameter optimization was performed and techniques such as dropout, learning rate adjustment and early stopping were applied to increase the accuracy rate. The performance of the model was evaluated using accuracy, precision, recall and F1 score metric. The results show that the developed deep learning model works successfully in the classification of Siirt pistachio with an accuracy rate of %99. The results of the model provide significant advantages in terms of both time and accuracy when compared to traditional manual classification methods. The potential for applicability to other products in the agricultural sector was also evaluated. This study is considered as an important step towards optimizing quality control processes in the agricultural sector, providing efficiency to producers and increasing consumer satisfaction. For future studies, it is recommended to create larger data sets, test different deep learning architectures and test the model in real-time applications.

Keywords: Agricultural product classification, Artificial intelligence, Convolutional neural networks, Deep learning, ResNet Models, Siirt pistachio.

ÖN SÖZ

Bu tez çalışmasını hazırlama sürecimde, bilgi ve deneyimleriyle beni yönlendiren, araştırmalarımnda doğru adımları atmama yardımcı olan ve her aşamada desteğini esirgemeyen değerli danışman hocam Dr. Öğr. Üyesi Abdülkerim ÖZTEKİN' e sonsuz teşekkürlerimi sunarım. Onun rehberliği, bu çalışmanın başarıyla tamamlanmasında belirleyici olmuştur.

Çalışmam sırasında görüş ve önerileriyle katkıda bulunan, beni devamlı motive eden kıymetli meslektaşlarım Berivan AKDOĞAN ve Evin ORTAÇ' a teşekkür ederim.

Bu süreçte manevi destekleriyle yanımda olan ve bana sabır, anlayış ve sevgiyle yaklaşan aileme, özellikle eşim Esma ERDOĞAN' a en içten şükranlarımı sunarım. Ayrıca, zor zamanlarımda moral kaynağım olan ve yanımda olan dostlarıma da teşekkür ederim.

Bu çalışmanın, tarım ve teknoloji alanında yeni ufuklar açmasını ve diğer araştırmacılara ilham kaynağı olmasını dilerim.

Mesut ERDOĞAN
BATMAN-2025

İÇİNDEKİLER

ÖZET	iv
ABSTRACT.....	v
İÇİNDEKİLER.....	vii
TABLO LİSTESİ.....	viii
ŞEKİL DİZİNİ.....	ix
1. GİRİŞ.....	1
2. LİTERATÜR ARAŞTIRMASI	3
2.1. Fıstığın Tarihçesi	3
2.2. Dünya Fıstık Üretimi	4
2.3. Türkiye Fıstık Üretimi	6
2.4. Siirt Fıstığının Üretimi.....	7
2.5. Siirt Fıstığının Özellikleri	8
2.6. Literatürde Yapılan Çalışmalar.....	9
3. MATERYAL VE YÖNTEM.....	13
3.1. Veri Setinin Oluşturulması	13
3.2. Yöntem.....	14
3.2.1. Yapay zeka (AI)	14
3.2.2. Makine öğrenmesi.....	16
3.2.3. Derin öğrenme	17
3.2.4. Derin öğrenme ile makine öğrenmesi arasındaki fark	29
3.2.5. Performans metrikleri ve karışıklık matrisi	29
4. BULGULAR VE TARTIŞMA.....	33
5. SONUÇLAR VE ÖNERİLER	40
5.1. Hedefler ve Kısıtlamalar	41
5.1.1. Hedefler	41
5.1.2. Kısıtlamalar.....	41
5.2. Gelecek Çalışmalar	42
KAYNAKLAR	43

TABLO LİSTESİ

Tablo 2.1. Türkiye fıstık üretim bölgeleri (Gaziantep ticaret ve sanayi odası, 2022).....	6
Tablo 2.2. Türkiye fıstık üretim miktarları (Gaziantep ticaret ve sanayi odası, 2022)....	6
Tablo 2.3. Siirt yıllara göre fıstık üretim miktarları (Siirt il tarım ve orman müdürlüğü, 2021)	7
Tablo 3.1. Veri setinden rastgele görüntüler	13
Tablo 3.2. Karışıklık Matrisi Örneği (İkili Sınıflandırma).....	28
Tablo 4.1. Derin öğrenme modellerinin hiperparametre değerleri.....	32
Tablo 4.2. Test veri seti ile derin öğrenme modellerinin performans değerlendirmeleri.	33
Tablo 4.3. Derin öğrenme modelleri ile sınıflandırma başarı oranları ve harcanan süreler.....	34

ŞEKİL DİZİNİ

Şekil 2.1. Dünya Fıstık üretimi ve yıllara göre dağılımı (FAO, 2022).....	4
Şekil 2.2. Dünya ülkeler arası fıstık ihracat oranları ve gelirleri (FAO, 2022)	5
Şekil 2.3. Türkiye fıstık üretim miktarı ve en çok fıstık üretimi yapan şehirler (Gaziantep ticaret ve sanayi odası, 2022).....	7
Şekil 3.1. Yapay zeka, makine öğrenmesi ve derin öğrenme (Chollet, 2017)	16
Şekil 3.2. Derin öğrenmenin üç katmanlı örnek modellemesi (Ateş, 2021).....	19
Şekil 3.3. Evrişimli sinir ağları yapısı (Panwar, 2018)	22
Şekil 3.4. MobileNet ağ mimarisi (Singhal,2020).....	228
Şekil 3.5. ResNet 50 mimarisi.	284
Şekil 3.6. ResNet 101 mimarisi.	285
Şekil 3.7. ResNet 152 mimarisi.	286
Şekil 3.8. DenseNet mimarisi (Zhangve ark., 2021).	286
Şekil 4.1. Derin öğrenme modelleri ile sınıflandırma başarı oranları	364
Şekil 4.2. Modellerin başarı grafikleri ve iterasyon değerleri	37
Şekil 4.3. Modellerin Loss (Hata) Değer Grafikleri	38
Şekil 4.4. Modellerin karışıklık matrisi Grafikleri	397

SİMGELER VE KISALTMALAR

<u>Simgeler</u>	<u>Açıklama</u>	
ADAM	Adaptive Moment	Uyarlanabilir Moment Tahmini
AUC	Area Under the ROC Curve	ROC Eğrisi Altındaki Alan
AI	Artificial İntelligence	Yapay Zekâ
CNN	Convolutional Neural Networks	Evrişimli Sinir Ağları
DL	Deep Learning	Derin Öğrenme
FN	False Negative	Yanlış Negatif
FP	False Positive	Yanlış Pozitif
ML	Machine Learning	Makine Öğrenmesi
MobileNet	Mobile Network	Mobil Ağ
PCA	Principal Component Analysis	Temel Bileşen Analizi
RELU	Rectified Linear Unit	Rektifiye Lineer Ünite
ResNet	Residual Network	Artık Ağ
SVM	Support Vector Machine	Destek Vektör Makinesi
TN	True Negative	Doğru Negatif
TP	True Positive	Doğru Pozitif
VGG	Visual Geometry Group	Görsel Geometri Grubu

1. GİRİŞ

Tarım ve gıda endüstrisinde, ürünlerin doğru sınıflandırılması, kalite kontrolü ve verimliliğin artırılması kritik öneme sahiptir. Geleneksel sınıflandırma yöntemleri, zaman alıcı olmasının yanı sıra, insan kaynaklı hatalara açık ve doğruluk açısından sınırlı olabilmektedir. Özellikle ticari değeri yüksek ürünlerde yanlış sınıflandırma, ciddi ekonomik kayıplara ve kalite sorunlarına yol açabilir (Brosnan & Sun, 2004). Bu bağlamda, yapay zeka ve derin öğrenme gibi modern teknolojiler, tarımda daha hızlı, güvenilir ve otomatik süreçler sunarak bu sorunları çözme potansiyeline sahiptir. (Kamilaris & Prenafeta-Boldu, 2018)

Siirt ve Antep fıstığının sınıflandırılması, tarım ve gıda sektöründe oldukça önemli bir konudur. Derin öğrenme modellerinin bu süreçteki kullanımı, geleneksel yöntemlere kıyasla daha hassas, hızlı ve otomatikleştirilmiş bir sınıflandırma imkanı sunacaktır. Siirt ve Antep fıstığı gibi tarımsal ürünlerin sınıflandırılması, ürün kalitesini belirlemek ve ticari değerini artırmak için kritik öneme sahiptir. Derin öğrenme modelleri, bu süreçte manuel yöntemlere kıyasla çok daha hızlı sonuçlar verecektir. Görüntü işleme ve yapay zeka tabanlı sınıflandırma yöntemleri sayesinde fıstığın boyutu, rengi, şekli ve iç dolgunluğu gibi özellikler değerlendirilecektir. Böylece kalite kontrol süreci iyileştirilecek ve insan hatası minimize edilecektir.

Derin öğrenme, özellikle Evrişimsel Sinir Ağları (Convolutional Neural Networks - CNN) gibi evrişimli sinir ağlarıyla görüntü tanıma konusunda büyük başarılar elde etmiştir. Bu yöntemler, fıstık görüntülerini analiz ederek sınıflandırmayı otomatik hale getirebilir. Ürünlerin farklı kalitelere ayrılması, hasarlı ve sağlam fıstıkların belirlenmesi gibi işlemler için kullanılabilir. Bu da iş gücü maliyetlerini düşürürken aynı zamanda daha tutarlı ve güvenilir sonuçlar sağlar.

Gıda sektöründe izlenebilirlik ve standartlara uygunluk oldukça önemlidir. Derin öğrenme modelleri ile yapılan sınıflandırma sayesinde, her bir fıstık türünün (Siirt ve Antep fıstığı) ait olduğu kalite standardı korunur ve üretim süreçlerinde herhangi bir hile veya sapmanın önüne geçilebilir. Aynı zamanda, ürünlerin coğrafi işaretlerine ve kökenine göre ayırmak, yerel ekonomilerin desteklenmesi açısından da önem taşır. Siirt ve Antep fıstığı gibi yerel ürünler, dünya çapında bilinir ve yüksek ticari değere sahiptir. Derin öğrenme modelleriyle yapılan sınıflandırma, ürünlerin pazar değeri açısından da avantaj sağlar. Farklı kalitelerdeki ürünlerin doğru şekilde sınıflandırılması ve

paketlenmesi, ihracat pazarlarında rekabet gücünü artırır. Doğru ürün doğru pazarda olacaktır.

Geleneksel sınıflandırma yöntemleri, genellikle uzman kişiler tarafından yapılan manuel gözlem ve değerlendirme süreçlerini içerir. Ancak derin öğrenme modelleri, geniş veri setleri ile eğitildiğinde bu süreci hızlandırarak büyük ölçekli tarımsal üretimlerde uygulanabilir hale getirir. Bu sayede üretimden satışa kadar olan süreçlerin hızlanması ve optimize edilmesi mümkün olur. Derin öğrenme, tarım sektöründe son yıllarda giderek daha fazla uygulama alanı bulan bir teknoloji haline gelmiştir. Siirt ve Antep fıstığı gibi tarımsal ürünlerin sınıflandırılması üzerine yapılan akademik çalışmalar, hem bilgisayar bilimi hem de tarım bilimi alanlarında önemli katkılar sağlar. Bu çalışmalar, aynı zamanda yapay zekâ tabanlı tarım teknolojilerinin daha da geliştirilmesine ve uygulanabilirliğinin artırılmasına katkıda bulunur. Bu tür çalışmalar tarımda dijitalleşme ve yapay zeka uygulamalarının yaygınlaşmasına katkı sağlayarak, sektördeki inovasyonun önünü açmaktadır.

Siirt ve Antep fıstığının sınıflandırılması, tarımsal verimlilik, kalite kontrol ve pazar değeri açısından büyük bir öneme sahiptir. Derin öğrenme teknolojileri, bu süreci otomatikleştirerek hızlandırmakta, insan hatasını minimize etmekte ve ürün standartlarını korumaktadır. Ayrıca, bu konu üzerine yapılan akademik çalışmalar hem yapay zeka ve derin öğrenme alanına hem de tarımsal uygulamalara ve bölge ekonomisine önemli katkılar sağlayacaktır.

2. LİTERATÜR ARAŞTIRMASI

2.1. Fıstığın Tarihçesi

Antep fıstığının tarihçesi, insanlık tarihine eşlik eden köklü bir geçmişe sahiptir ve binlerce yıl öncesine dayanmaktadır. Antep fıstığının ilk yetiştirildiği yerin, bugün Mezopotamya olarak bilinen bölge olduğu düşünülmektedir. Bu bölge, tarih boyunca tarımın ve medeniyetlerin geliştiği önemli bir merkez olmuştur. Arkeolojik kazılarda, Antep fıstığına dair kalıntılar MÖ 7000 yıllarına kadar uzanmakta, bunun da fıstığın insan beslenmesinde çok erken bir dönemde yer aldığını göstermektedir. Fıstık, doğal olarak bu bölgede yetişmiş ve zamanla insanlar tarafından kültüre alınarak tarımı yapılmaya başlanmıştır.

Antik dönemde, Pers İmparatorluğu, Roma ve Yunan medeniyetleri gibi büyük uygarlıklar tarafından hem besin kaynağı olarak hem de ticari bir ürün olarak büyük bir değer görmüştür. Özellikle lezzeti, enerji verici özelliği ve uzun süre saklanabilmesi nedeniyle askeri seferlerde önemli bir gıda kaynağı olmuştur. Romalılar döneminde Akdeniz çevresine yayılan Antep fıstığı, ticaret yolları aracılığıyla farklı coğrafyalara ulaşmış ve böylece ün kazanmıştır.

Osmanlı İmparatorluğu döneminde, Gaziantep ve çevresi, Antep fıstığının yetiştiriciliği için önemli bir merkez haline gelmiştir. Bölgenin iklimi ve toprağı, bu ürünün kalitesini artırmış ve Antep fıstığı bu yöreyle özdeşleşmiştir. Osmanlı mutfağında tatlılardan yemeklere kadar geniş bir kullanım alanı bulan Antep fıstığı, baklava gibi ünlü tatlıların da vazgeçilmez bir malzemesi olmuştur.

Cumhuriyet döneminde Türkiye’de fıstık üretimi daha sistematik hale gelmiş, Gaziantep ve çevresinde modern tarım yöntemleri uygulanmaya başlanmıştır. 2000’li yıllardan itibaren "Antep fıstığı" adı, hem Türkiye’de hem de dünyada tanınmış bir marka haline gelmiştir. Bugün, Türkiye’nin Antep fıstığı üretiminin büyük bir kısmı Gaziantep, Şanlıurfa, Adıyaman ve Siirt gibi illerde gerçekleştirilmektedir. Özellikle Gaziantep, bu ürünle özdeşleşmiş olup, 2000 yılında Avrupa Birliği tarafından "Antep Fıstığı" coğrafi işareti ile tescillenmiştir.

2.2. Dünya Fıstık Üretimi

Dünya üzerinde fıstık üretiminde söz sahibi ülkelerin fıstık üretimi ile ilgili genel bilgiler aşağıda verilmiştir.

➤ İran

İran, dünya genelinde Antep fıstığı üretiminde uzun yıllardır önde gelen ülkelerden biridir. Üretim hacmi açısından genellikle Türkiye ile başa baş bir durumdadır. İran'da Kerman ve Rafsanjan bölgeleri, Antep fıstığı üretiminin merkezleridir. Ancak son yıllarda su kıtlığı ve iklim değişiklikleri üretimi etkilemiştir.


➤ ABD

ABD, özellikle Kaliforniya eyaletinde yoğunlaşan Antep fıstığı üretimi ile dünya sıralamasında üçüncü sıradadır. 1970'lerden sonra yapılan yatırımlarla büyük bir üretim kapasitesine ulaşmıştır. Amerikan Antep fıstığı, genellikle mekanize tarım yöntemleriyle üretilir ve önemli bir ihracat ürünüdür.


Çin, Suriye ve Yunanistan gibi ülkeler de küçük ölçekli üretim gerçekleştirmektedir. Ancak bu ülkeler, üretimde Türkiye, İran ve ABD'nin gerisinde kalmaktadır.

Aşağıda şekil 2.1'de dünya Antep fıstığı üretimindeki paylar ve Antep fıstığının üretiminin yıllara göre dağılımı verilmiştir.

Ülkelerin Fıstık Üretimindeki Payları (2022)



Fıstık Üretiminin Yıllara Göre Dağılımı



Şekil 2.1. Dünya Fıstık üretimi ve yıllara göre dağılımı (FAO, 2022)

Dünya Antep Fıstığı Üretimindeki Paylar (2022)

Türkiye, dünya üretiminin %40'ını gerçekleştirerek lider konumda yer alıyor. İran %33, ABD %16 ve diğer ülkeler %11'lik bir üretim payına sahip.


Yıllara Göre Üretim Dağılımı (2010-2022)

Türkiye, üretimde sürekli bir artış göstermiştir. İran üretimi, iklimsel zorluklara rağmen sabit bir düzeyde kalmıştır. ABD ise üretimini 2010'dan bu yana düzenli olarak artırmıştır.

Aşağıda şekil 2.2. dünya ülkeler arası fıstık ihracat oranları ve gelirleri verilmiştir.

Ülkeler Arası İhracat Oranları (2022)

Dünya Fıstık ihracat Gelirleri(Milyar \$)



Şekil 2.2. Dünya ülkeler arası fıstık ihracat oranları ve gelirleri (FAO, 2022)

- **Türkiye:** Üretimin yaklaşık %30'unu ihraç etmektedir. Türkiye'nin Antep fıstığı ihracatında başlıca pazarları Avrupa Birliği ülkeleri, Orta Doğu ve Uzak Doğu'dur. Gaziantep baklavası gibi coğrafi işaretli ürünler, fıstık ihracatına dolaylı olarak katkı sağlamaktadır.
- **İran:** Antep fıstığı üretiminin %48'ini ihraç etmektedir ve uzun yıllardır Çin başta olmak üzere Asya pazarında güçlü bir konuma sahiptir. Ancak, uluslararası ambargolar İran'ın ihracatını olumsuz etkileyebilmektedir.
- **ABD:** Üretimin %92'sini ihraç ederek en yüksek oranı yakalamıştır. Başta Avrupa ve Asya pazarları olmak üzere geniş bir ihracat ağına sahiptir. Modern tarım teknikleri sayesinde yüksek verimlilik elde ederek ihracatta lider ülkelerden biri olmuştur.

2.3. Türkiye Fıstık Üretimi

Türkiye, dünya Antep fıstığı üretiminde önemli bir yere sahiptir ve üretimi genellikle Güneydoğu Anadolu Bölgesi'nde yoğunlaşmaktadır. Özellikle Gaziantep, Şanlıurfa, Adıyaman, Siirt ve Diyarbakır, üretim açısından başlıca merkezlerdir. Antep fıstığı, Türkiye ekonomisine hem iç tüketim hem de ihracat yoluyla büyük katkı sağlamaktadır.

Tablo 2.1.'de illerin fıstık üretim miktarı ve ülke genelinde üretim alanındaki oranları gösterilmektedir.

Tablo 2.1. Türkiye fıstık üretim bölgeleri (Gaziantep ticaret ve sanayi odası, 2022)

Bölge	Üretim Miktarı (Ton)	Türkiye Toplamındaki Pay (%)
Gaziantep	120.000	%40
Şanlıurfa	90.000	%30
Adıyaman	45.000	%15
Siirt	30.000	%10
Diğer Bölgeler	15.000	%5

Türkiye'de Antep fıstığı üretimi, "var yılı" ve "yok yılı" olarak adlandırılan bir döngüye sahiptir. Fıstık ağaçları doğal olarak bir yıl yüksek, bir yıl düşük verim verir. Bu durum, üretimdeki yıllık dalgalanmaların başlıca nedenidir. Tablo 2.2.'de 2010-2022 yılları arasında Türkiye'de üretilen toplan fıstık miktarları verilmiştir.

Tablo 2.2. Türkiye fıstık üretim miktarları (Gaziantep ticaret ve sanayi odası, 2022)


Yıl	Üretim (Ton)
2010	120.000
2012	150.000
2014	180.000
2016	220.000
2018	240.000
2020	270.000
2022	300.000

Türkiye Antep Fıstığı Üretim Miktarı (2010-2022)

Yıllara göre üretim miktarındaki artış, dalgalanmalara rağmen net şekilde görülebilir.

Başlıca Üretim Bölgelerinin Payı

Üretim bölgelerinin Türkiye toplamına katkısını görselleştiren bir pasta grafik. Aşağıda şekil 2.3'te Türkiye fıstık üretim miktarını yıllara göre dağılımı ve üretim yapan iller verilmiştir.



Şekil 2.3. Türkiye fıstık üretim miktarı ve en çok fıstık üretimi yapan şehirler (Gaziantep ticaret ve sanayi odası, 2022)

Gaziantep, toplam üretimin %40'ını karşılayarak lider konumdadır. Şanlıurfa, %30 ile ikinci sırada yer alırken, Adıyaman ve Siirt gibi iller de önemli katkılar sağlamaktadır.

2.4. Siirt Fıstığının Üretimi

Siirt fıstığı, Siirt ilinin en önemli tarımsal ürünlerinden biridir ve bölgenin ekonomisine önemli katkı sağlamaktadır. Üretim alanı ve miktarı, yıllar içinde önemli bir artış göstermiştir. Tablo 2.3. Siirt ilinde yıllara göre Siirt fıstığının üretim alanlarının ve miktarlarının değişimi verilmiştir.

Tablo2.3. Siirt yıllara göre fıstık üretim miktarları (Siirt il tarım ve orman müdürlüğü, 2021)

YILLARA GÖRE SİİRT FISTIĞI		
YIL	ALAN (Da)	ÜRETİM MİKTARI (Ton)
2002	45.543	2.000
2005	267.830	2.175
2010	205.050	11.128
2015	255.000	12.000

2019	285.206	12.208
2020	320.600	25.624
2021	334.920	26.994

2002 yılında Siirt fıstığı üretim alanı 45.543 dekar olup, üretim miktarı 2.000 ton olarak kaydedilmiştir. Bu rakamlar, 2010 yılında 205.050 dekar alanda 11.128 ton, 2015 yılında ise 255.000 dekar alanda 12.000 ton olarak gerçekleşmiştir. 2020 yılında üretim alanı 320.600 dekar, üretim miktarı ise 25.624 ton olmuştur. 2021 yılında ise üretim alanı 334.920 dekar, üretim miktarı ise 26.994 ton olarak belirlenmiştir.

2.5. Siirt Fıstığının Özellikleri

Siirt fıstığı, Türkiye'nin güneydoğusunda yetişen ve kendine özgü özellikleriyle tanınan bir fıstık türüdür. İşte Siirt fıstığının başlıca özellikleri:

a. Tat ve Lezzet:

- Siirt fıstığı, özellikle yüksek yağ içeriğiyle bilinir. Bu yüksek yağ oranı, fıstığa benzersiz bir lezzet ve kıvam kazandırır. Lezzeti tatlı ve yoğun olup, kuru yemiş olarak tüketildiğinde oldukça aromatik ve zengin bir tada sahiptir.

b. Yapı ve Boyut

- Siirt fıstığı, genellikle büyük boyutlu ve yuvarlak şekilde olur. Kabukları ince ve kırılması kolaydır. Fıstık çekirdeği ise içeriği oldukça dolgun ve besleyicidir.

c. Renk

- Siirt fıstığının kabuğu, genellikle açık kahverengi tonlarında olur. Çekirdeği ise sarımsı beyaz renkte olup bu renk fıstığa karakteristik bir görünüm kazandırır.

d. Yüksek Besin Değeri

- Siirt fıstığı, protein, lif, vitamin ve mineraller bakımından zengindir. Özellikle E vitamini, magnezyum, potasyum ve fosfor içerir. Ayrıca, fıstıklar sağlıklı yağlar açısından da oldukça besleyicidir.

e. Yetiştirme Koşulları

- Siirt fıstığı, sıcak iklimlerde yetişir ve yüksek rakımlı bölgelerde en iyi verimi alır. İyi bir güneş ışığı alması ve uygun sulama koşullarına sahip olması gerekir. Genellikle kurak iklimlere dayanıklıdır.

f. İhracat ve Ekonomik Katkı

- Siirt fıstığı, Türkiye'nin en önemli tarım ürünlerinden biridir ve büyük bir ihracat potansiyeline sahiptir. Özellikle Orta Doğu ve Avrupa pazarlarına ihraç edilmektedir.

g. Farklı Kullanım Alanları

- Siirt fıstığı, genellikle çerez olarak tüketilir, ancak baklava, dondurma, helva ve çeşitli tatlıların yapımında da kullanılır. Ayrıca, yemeklere lezzet katmak amacıyla da kullanılabilir.

h. Özel Farklılıklar

- Siirt fıstığı, Türkiye'deki diğer fıstık türlerinden farklı olarak, iri olması, kabuğu oldukça ince ve kolayca soyulabilir. Bu da onu pazarlarda daha avantajlı bir ürün yapmaktadır.

Siirt fıstığı, bu özellikleriyle hem yerel hem de global pazarda değerli bir tarım ürünüdür.

2.6. Literatürde Yapılan Çalışmalar

Fıstık Orta Doğu ve Orta Asya'ya özgü bir tarım ürünüdür. Dünyanın başlıca fıstık üreticileri olan İran, ABD, Türkiye ve Suriye, dünya genelindeki toplam üretimin yaklaşık %90'ına katkıda bulunmaktadır (Sağlam ve Çetin, 2022). Türkiye'de fıstık üretimi, farklı isimler altında çok sayıda türü kapsamaktadır. Bu fıstık türleri arasında en çok tercih edilenler Antep ve Siirt fıstığıdır. Siirt ve Antep fıstığı gibi tarımsal ürünlerin sınıflandırılması, ürün kalitesini belirlemek ve ticari değerini artırmak için kritik öneme sahiptir. Derin öğrenme modelleri, bu süreçte manuel yöntemlere kıyasla çok daha hızlı sonuçlar vereceği düşünülmektedir. Görüntü işleme ve yapay zeka tabanlı sınıflandırma yöntemleri sayesinde fıstığın boyutu, rengi, şekli ve iç dolgunluğu gibi özellikler değerlendirilecektir. Böylece kalite kontrol süreci iyileştirilecek ve insan hatası minimize etmesi beklenmektedir.

Son yıllarda, literatürde derin öğrenme ve makine öğrenmesi yöntemleriyle tarım ürünlerinin sınıflandırılmasına odaklanan birçok çalışma yapılmıştır. Ancak, özellikle derin öğrenmenin kullanıldığı çalışmalar olmak üzere, fıstık türlerinin sınıflandırılmasıyla ilgili çalışma sayısı oldukça sınırlıdır. Literatürdeki bu çalışmalar aşağıda özetlenmiştir.

Mahdavi-Jafari ve arkadaşları (2022), YSA kullanarak fıstıkların (açık kabuk, dolu ve kapalı kabuk, boş ve kapalı kabuk) sınıflandırılması için akıllı bir sistem sunmuştur. YSA, bir çelik plakaya çarpan fıstıklardan üretilen akustik sinyallerin analizine dayanarak eğitilmiştir. Sinyal işleme için Hızlı Fourier dönüşümü (FFT), Ayırık Kosinüs Dönüşümü (DCT) ve Ayırık Dalgacık Dönüşümü (DWT) kullanılmıştır. Çalışmanın sonuçlarına göre, önerilen yöntem %99.89'dan daha yüksek bir doğruluk oranına sahip bir performansa sahiptir.

Farazi ve arkadaşları (2012), çalışmalarında açık kabuklu fıstıkları diğer çürük fıstıklardan ve kabuklardan ayırmak için derin öğrenme ve makine öğrenme mimarileri kullanmıştır. Fıstık ve kabuklardan elde edilen 1000 ayrı görüntüden oluşan bir set, veri artırma yoluyla 20.000'e çıkarılmıştır. Bu görüntülerden, AlexNet ve GoogleNet mimarileri kullanılarak özellikler çıkarılmış ve bu özellikler arasında yer alan temel bileşen analizi (Principal Component Analysis-PCA) ile en etkili 300 özellik seçilmiştir. Son olarak, bu özellikler SVM sınıflandırıcısına girdi olarak verildi ve sınıflandırma işlemleri gerçekleştirilmiştir. GoogleNet mimarisinden elde edilen özellikler ile %99'lük en yüksek sınıflandırma doğruluğu elde edilmiştir.

Omid ve diğerleri (2017), çalışmalarında soyulmuş fıstıkları sınıflandırmak için görüntü işleme ve makine öğrenme tekniklerine dayalı bir sistem önermişleridir. Soyulmuş fıstıklar, sınıflandırma için yapay sinir ağları (YSA) ve destek vektör makinesi (SVM) kullanılarak beş sınıfa ayrılmıştır. Sınıflandırma doğruluğu YSA ile %99.4 iken, SVM ile bu oran %99.8'dir.

Abbaszadeh ve arkadaşları (2019), yaptıkları çalışmada fıstıkları kusurlu ve kusursuz olarak sınıflandırmak için derin oto-kodlayıcı sinir ağlarını kullanmışlardır. Çalışma sonucunda, kusurlu fıstıkların tespitinde %80.3'lük bir sınıflandırma doğruluğu elde edilmiştir.

Er çalışmasında göğüs röntgenlerinden bakterilerin, virüslerin ve mantarların akciğerde enfeksiyona sebep olduğu Pnömoni hastalığını tespit etme üzerine çalışma yapmıştır. Bu çalışmada göğüs röntgenlerinden önceden eğitilmiş derin öğrenme modelleri olarak AlexNet, VGG16, ResNet (ResNet18, ResNet50, ResNet101) modelleri kullanarak pnömoni hastalığının olup olmadığı ile ilgili çalışma yapmıştır. Modellerden elde ettiği özellikleri birleştirerek hibrit model elde etmiş ve destek vektör olarak da softmax kullanmıştır. Çalışmada en yüksek doğruluk oranını hibrit özellik vektörü ile %98.32 ile elde etmiştir.

Dini ve arkadaşları, yağlı lekeler, koyu lekeler, yapışan kabuk ve mantar çürüklüğü gibi kabuk kusurlarına sahip fıstıkları tespit edip kalitesini iyileştirmek için görüntüleme algoritmaları geliştirmektedir. Çalışmada belirlenen özelliklerin tespiti için özel laboratuvar kurulmuştur. Çalışmada kullanılmak üzere 276'sı kusurlu Antep fıstığı ve 682'si sağlıklı olmak üzere toplam 958 Antep fıstığı görüntüsü kullanılmıştır. Sağlıklı ve kusurlu görüntülerin sınıflandırılması GoogleNet, ResNet18 ve VGG16 olmak üzere 3 tip derin öğrenme yöntemi kullanılmıştır. GoogleNet %95,8 ResNet18 %97,1 ve VGG16 %95,83 sonucu elde edilmiştir. En yüksek doğruluk oranını ResNet18 %97,1 ile vermiştir.

Akdoğan çalışmasında Mardin bölgesine ait asma yapraklarını derin öğrenme yöntemleriyle sınıflandırma çalışması yapmıştır. Çalışma Türk mutfağının önemli değerlerinden olan asma yapraklarının hangilerinin yenilebilir olduğu, yaprağın hangi üzüm çeşidine ait olduğu, yaprağın kalitesinin öğrenilmesi ve nerelerde kullanılabilir olduğunu tespit etme amacıyla derin öğrenme yöntemlerini kullanma suretiyle sınıflandırma işlemi uygulamıştır. Çalışmasında derin öğrenme yöntemlerinden ResNet50, , ResNet101, ResNet152, Xception, MobileNet ve DenseNet modellerini kullanmıştır. Sınıflandırma işlemi için 8 farklı tür belirlemiş olup her tür için 500 adet asma yaprağı görüntüsü almıştır. Görüntü kalitesini standartlaştırmak amacıyla özel düzenek kurmuş olup Kerkuş, Mazrone, Payizi, Tayfi, Bilbizeki, Deywani, Benitat ve Hazirani üzümlerinde toplam 4000 adet görüntü ile veri setini toplamıştır. Sınıflandırma işlemi sonunda en yüksek başarıyı ResNet-101 %0,88 ile en düşük başarıyı da %0,73 ile DenseNet modeliyle elde etmiştir.

Ortaç çalışmasında down sendromunun erken teşhis ve müdahalesi için yüz ifadelerinden down sendromlu olup olmadığının derin öğrenme yöntemleriyle tespit etmeye çalışmıştır. Açık kaynak kodlu sitelerden 600 adet sağlıklı birey ve 600 adet down sendromlu bireylerin görüntülerini elde ederek veri setini oluşturmuştur. Sınıflandırma işlemi için derin öğrenme modellerinden ResNet-50, ResNet-101, ResNet-152, MobileNet modellerini kullanmıştır. Derin öğrenme modelleriyle yapılan sınıflandırma işlemi başarılı sonuçlar elde edilmiştir. En yüksek başarıyı % 0,99 ile Resnet-50, ResNet-101 modelleri elde etmiştir. En düşük başarıyı da % 0,84 ile MobileNet elde etmiştir.

Idress çalışmasında makine öğrenme algoritmaları kullanarak Antep fıstıklarının kapalı ve açık olmasının tespiti için çalışma yapmıştır. Çalışmada makine algoritmaları ile Antep fıstığının sınıflandırılması ve doğruluğunun derecesinin tespiti

temel hedef alınmıştır. Çalışmada kullanılmak üzere 500 adet kapalı uçlu ve 500 adet açık uçlu Antep fıstığı olmak üzere toplam 1000 adet Antep fıstığı kullanılmıştır. Çalışma için makine öğrenme modelleri olarak da Lojistik Regresyon, Destek Vektör Makinesi, Rastgele Orman sınıflandırma algoritmaları kullanılmıştır. İşlem sonucunda en başarılı sonucu % 95,6 ile Rastgele Orman algoritması en düşük başarıya da Lojistik Regresyon algoritması elde etmiştir.

3. MATERYAL VE YÖNTEM

3.1. Veri Setinin Oluşturulması

Derin öğrenme, Siirt ve Antep fıstığının sınıflandırılması için kullanılan etkili yöntemlerden bir tanesidir. Bu yöntem, genellikle görüntü işleme tekniklerini kullanarak teşhis koymaya yardımcı olur. Genellikle resim, ses veya diğer veriler gibi büyük ve karmaşık veri kümeleri üzerinde çalışır. Derin öğrenme algoritmaları, geniş veri setlerini kullanarak öğrenir ve kendi kendine geliştirirler. Bu nedenle, Siirt ve Antep fıstığının sınıflandırılması için kullanılan derin öğrenme yöntemleri, geniş bir veri kümesi ile eğitilirler. Bu yöntemler, çok katmanlı sinir ağları kullanarak büyük miktarda veriyi analiz eder ve daha sonra verileri sınıflandırmak veya tahmin etmek için kullanabilir.

Bunun için öncelikle, veri seti açık kaynak web sitelerinden elde edilen 2.148 adet Siirt ve Antep fıstığının görüntülerinden oluşan bir veri seti toplanmıştır (<https://www.kaggle.com/datasets/muratkokludataset/pistachio-image-dataset>). Bunların 916 adedi Siirt, 1.232 adedi ise Antep fıstığı görsellerinden oluşmaktadır. Veri setindeki görüntüler standart hale getirmek amacıyla 225x225 piksele dönüştürülmüştür. Daha sonra, bu veri seti, derin öğrenme algoritmaları kullanılarak eğitilir. Eğitim sürecinin sonunda, algoritma, yeni bir görüntü üzerinde test edilebilir ve Siirt mi Antep fıstığı mı tahmin edebilir. Derin öğrenme yöntemleri, Siirt ve Antep fıstığının sınıflandırılması için kullanılan diğer yöntemlerden daha yüksek doğruluk oranlarına sahip olabilir. Ayrıca elde ettiğimiz veri setinin doğru bir şekilde eğitilmesi için gerekirse veri artırma teknikleri de kullanılacaktır. Veri artırma; aynı veri kümesindeki görüntüleri çevirme, döndürme, ölçeklendirme, kesme ve diğer işlemlerle değiştirerek, kullanılacak modellerin daha fazla veriyle eğitilmesine yardımcı olur. Veri setinden örnek görüntüler Tablo 3.1’de verilmiştir.

Tablo 3.1. Veri setinden rastgele görüntüler

	Görüntü	Görüntü Sayısı
Siirt Fıstığı		916
Antep Fıstığı		1232

3.2. Yöntem

3.2.1. Yapay zeka (AI)

Yapay zeka (AI), bilgisayar sistemlerinin insan zekasına benzer şekilde düşünme, öğrenme, problem çözme ve karar verme yeteneklerini taklit etmesini sağlayan bir bilim dalıdır. Yapay zekanın temel amacı, insan zihninin işleyişini anlamak ve bu işleyişi bilgisayarlara uyarlamaktır. Alanın kökleri, matematik, istatistik, bilgisayar bilimi ve sinirbilim gibi disiplinlere dayanır. Yapay zekanın başlangıcı 1950'lere kadar uzanır ve Alan Turing'in "Turing Testi" ile bu alandaki temel sorular ilk kez ele alınmıştır. Turing, bir makinenin insana özgü zekayı taklit edip edemeyeceğini sorgulayan bir sistem geliştirmiştir. Bu dönemden itibaren yapay zeka, kuramsal tartışmaların ötesine geçerek uygulamalı bir bilim dalına dönüşmüştür.

Yapay zeka, birkaç temel alt alana ayrılır. Makine öğrenimi (ML), veriden öğrenen algoritmaların geliştirilmesine odaklanır. ML, istatistiksel teknikler kullanarak geçmiş verilerden model oluşturur ve gelecekteki veriler için tahminler yapar. ML'in bir alt dalı olan derin öğrenme (DL), insan beynindeki nöronlara benzer yapay sinir ağlarını kullanır ve özellikle büyük veriyle çalışırken olağanüstü sonuçlar elde eder. DL, yüz tanıma, ses işleme ve görüntü sınıflandırma gibi karmaşık görevlerde yaygın olarak kullanılmaktadır. Bir başka önemli alt dal olan doğal dil işleme (NLP), bilgisayarların


insan dilini anlamasını, yorumlamasını ve üretmesini sağlar. NLP'nin uygulamaları arasında metin analizi, çeviri sistemleri ve sohbet botları bulunur.

Yapay zeka, modern dünyada geniş bir uygulama yelpazesine sahiptir. Sağlık sektöründe, yapay zeka, medikal görüntüleme ve hastalık teşhisinde kullanılmaktadır. Örneğin, manyetik rezonans (MRI) ve bilgisayarlı tomografi (CT) gibi görüntüler üzerinde çalışan algoritmalar, insan doktorlardan daha hızlı ve doğru teşhisler yapabilmektedir. Ayrıca, ilaç geliştirme süreçlerinde de Yapay zeka, aday molekülleri tarayarak zaman ve maliyetten tasarruf sağlar. Eğitimde, kişiselleştirilmiş öğrenme platformları, her öğrencinin ihtiyaçlarına uygun içerikler sunarak öğrenme süreçlerini optimize eder. Finans sektöründe, yapay zeka dolandırıcılık tespitinde, risk analizinde ve yatırım portföyü yönetiminde kritik bir rol oynamaktadır. Otomotiv sektöründe ise otonom araçlar, yapay zeka tabanlı görsel algılama sistemleri sayesinde çevresel faktörlere adapte olarak sürüş güvenliğini artırmaktadır.

Bunun yanı sıra, yapay zekanın toplumsal ve etik etkileri de dikkat çekicidir. İş gücü piyasasında otomasyonun artması, bazı sektörlerde istihdam kayıplarına yol açabilirken, yeni meslek alanlarının doğmasına da zemin hazırlamaktadır. Ayrıca, yapay zekanın karar mekanizmalarındaki şeffaflık eksikliği, adil olmayan sonuçlara neden olabilir ve bu durum, toplumsal eşitlik açısından tartışmalara yol açmaktadır. Bu nedenle, yapay zekanın geliştirilmesinde etik kuralların ve düzenlemelerin oluşturulması büyük önem taşımaktadır.

Sonuç olarak, yapay zeka teknolojileri, hem fırsatlar hem de sorumluluklarla dolu bir alan sunmaktadır. Gelişen algoritmalar ve artan veri miktarı, yapay zekanın potansiyelini artırmakta ve gelecekte daha büyük bir etki yaratmasını mümkün kılmaktadır. Sağlıktan eğitime, otomotivden finans sektörüne kadar her alanda devrim niteliğinde değişimler yaratan yapay zekanın, insan yaşamını kolaylaştırırken, aynı zamanda teknolojinin etik ve sosyal yönleri üzerine düşünmeyi de zorunlu kılmaktadır.

Yapay zeka, makine öğrenmesi ve derin öğrenme kavramları arasında ilişki Şekil 4 'te gösterilmiştir.



Şekil 3.1. Yapay zeka, makine öğrenmesi ve derin öğrenme (Chollet, 2017)

3.2.2. Makine öğrenmesi

Makine öğrenmesi (ML), bilgisayar sistemlerinin açıkça programlanmadan öğrenmesini sağlayan ve yapay zekânın bir alt dalı olan bir bilim dalıdır. Makine öğrenmesi, istatistiksel teknikler ve algoritmalar kullanarak verilerden öğrenir, kalıpları tanır ve gelecekteki durumlar hakkında tahminlerde bulunur. Alan, özellikle büyük veri çağında hızlı bir gelişim göstermiş ve birçok sektörde yenilikçi çözümler sunmuştur. Makine öğrenmesinin temel prensibi, bilgisayarların bir problemi çözmek için büyük miktarda veriyi analiz etmesi ve bu veriden çıkarımlar yaparak performansını sürekli iyileştirmesidir. Öğrenme süreci, farklı yöntemlere dayanır ve bu yöntemler üç ana başlıkta incelenir: gözetimli öğrenme, gözetimsiz öğrenme ve pekiştirmeli öğrenme.

Gözetimli öğrenme, algoritmaların etiketlenmiş veriler üzerinde çalıştığı bir yaklaşımdır. Burada algoritmaya, giriş verileri ve bunlara karşılık gelen doğru çıktılar sunulur. Örneğin, bir e-posta sisteminde spam olan ve olmayan e-postaların sınıflandırılması bu yönteme dayanır. Gözetimsiz öğrenme, etiketlenmemiş verilerle çalışır ve veriler arasındaki gizli kalıpları ve ilişkileri ortaya çıkarmayı amaçlar. Örnek olarak, müşteri segmentasyonu veya davranış analizleri gözetimsiz öğrenme teknikleriyle gerçekleştirilir. Pekiştirmeli öğrenme ise bir sistemin, çevresiyle etkileşim kurarak bir görevi yerine getirmeyi öğrenmesini sağlar. Bu yöntem genellikle oyunlar veya otonom araçların kontrol sistemlerinde kullanılır.

Makine öğrenmesi, birçok farklı algoritma ve modelden oluşur. Bunlar arasında karar ağaçları, destek vektör makineleri (SVM), k-en yakın komşu algoritması (k-NN), ve doğrusal regresyon gibi klasik yöntemler bulunur. Son yıllarda, derin öğrenme gibi daha karmaşık teknikler, makine öğrenmesinin kapsamını genişletmiştir. Derin

öğrenme, özellikle büyük veri kümeleri ve karmaşık hesaplamalar için uygundur ve sinir ağları kullanarak daha hassas tahminler yapabilir. Bu yöntemler, görüntü tanıma, doğal dil işleme ve ses analizi gibi alanlarda devrim yaratmıştır.

Makine öğrenmesinin uygulama alanları oldukça geniştir ve sağlık, finans, eğitim, perakende gibi sektörlerde kullanılmaktadır. Sağlıkta, tıbbi teşhislerde kullanılan makine öğrenmesi modelleri, hastalıkların erken teşhisinde insanlara yardımcı olmaktadır. Finans sektöründe, makine öğrenmesi algoritmaları dolandırıcılık tespitinde, kredi risk analizinde ve algoritmik ticarete yaygın olarak kullanılmaktadır. Eğitimde, kişiselleştirilmiş öğrenme platformları, öğrencilerin bireysel ihtiyaçlarına göre öğrenme materyalleri sunmak için makine öğrenmesi teknolojilerinden yararlanmaktadır. Ayrıca, perakende sektöründe öneri sistemleri, kullanıcıların alışveriş deneyimlerini optimize etmek için makine öğrenmesi modellerini kullanır.

Sonuç olarak, makine öğrenmesi, modern teknolojinin temel taşlarından biri haline gelmiş ve birçok alanda dönüşüm yaratmıştır. Ancak, makine öğrenmesinin etkili bir şekilde uygulanması, kaliteli verilere ve doğru algoritma seçimine bağlıdır. Aynı zamanda, şeffaflık ve etik konuları da Makine öğrenmesi uygulamalarında göz önünde bulundurulması gereken kritik noktalar. Gelişen teknolojiler ve artan veri hacmiyle birlikte, makine öğrenmesinin gelecekteki etkisi daha da belirgin hale gelecektir.

3.2.3. Derin öğrenme

Derin öğrenme (Deep Learning - DL), çok katmanlı yapay sinir ağlarının yapısını kullanarak karmaşık desenleri ve ilişkileri öğrenme yeteneğine dayalı bir makine öğrenimi alt dalıdır. Derin öğrenme, birçok karmaşık problemin çözümünde son derece etkilidir ve birçok alanda, özellikle de görüntü tanıma, konuşma tanıma, doğal dil işleme gibi alanlarda büyük başarı elde etmiştir. (Ergün, 2023)


Derin öğrenme, makine öğrenmesinin bir alt dalı olarak, büyük veri setleri üzerinde çalışabilen ve çok katmanlı yapay sinir ağları aracılığıyla karmaşık problemlere çözüm sunabilen bir teknolojidir. Derin öğrenme, biyolojik sinir sisteminden esinlenerek geliştirilen yapay sinir ağları (Artificial Neural Networks-ANN) üzerine kuruludur ve özellikle görüntü, ses, video gibi yüksek boyutlu verilerde başarılı sonuçlar elde eder. Bu teknoloji, her biri bir öğrenme seviyesini temsil eden birden fazla katmandan oluşur. Alt katmanlar, ham verilerden temel özellikleri öğrenirken, üst katmanlar bu özellikleri daha karmaşık temsillerle birleştirir. Bu çok

katmanlı yapı, verilerdeki karmaşık ilişkileri ve desenleri öğrenebilme kabiliyeti sağlar.

Derin öğrenme, özellikle büyük veri ve yüksek işlem gücüne sahip donanımların (örneğin GPU ve TPU) gelişimiyle popülerlik kazanmıştır. En yaygın kullanılan modeller arasında evrimsel sinir ağları (Convolutional Neural Networks - CNN), yinelemeli sinir ağları (Recurrent Neural Networks - RNN) ve bunların daha ileri versiyonları olan LSTM (Long Short-Term Memory) ve GRU (Gated Recurrent Unit) bulunur. CNN'ler genellikle görüntü işleme ve nesne tanıma gibi görevlerde, RNN'ler ise zaman serisi analizi ve doğal dil işleme (NLP) gibi sıralı verilerde kullanılır. Ayrıca, derin öğrenmenin bir diğer önemli uygulaması olan GAN (Generative Adversarial Networks), veri üretiminde ve simülasyonlarda çığır açmıştır.

Uygulama alanları arasında otonom araçların çevre algılaması, tıbbi görüntüleme ile hastalık teşhisi, sesli asistanların konuşma tanıma sistemleri, dil çeviri araçları ve kişiselleştirilmiş öneri sistemleri bulunur. Örneğin, bir otonom araç, derin öğrenme algoritmaları sayesinde yol işaretlerini tanıyabilir, diğer araçların hareketlerini tahmin edebilir ve çevresine uygun bir sürüş stratejisi geliştirebilir. Benzer şekilde, tıbbi görüntü analizi alanında derin öğrenme, bir radyologun gözünden kaçabilecek tümörleri tespit etme kapasitesine sahiptir.

Derin öğrenme, etkileyici başarılarına rağmen bazı zorluklarla da karşı karşıyadır. Eğitim sürecinde büyük veri setleri ve yüksek işlem gücü gerektirmesi, en büyük sınırlayıcı faktörlerden biridir. Ayrıca, modellerin "kara kutu" doğası, yani karar verme sürecinin şeffaf olmaması, etik ve güvenilirlik konularında tartışmalara yol açmaktadır. Bu nedenle, derin öğrenme modellerinin daha açıklanabilir ve daha az veriyle çalışabilir hale getirilmesi, gelecekteki araştırmaların önemli bir odak noktasıdır. Derin öğrenme, hem akademik dünyada hem de endüstriyel uygulamalarda teknolojinin sınırlarını zorlayan bir alan olarak, yapay zekanın en heyecan verici bileşenlerinden biri olmaya devam etmektedir.



Şekil 3.2. Derin öğrenmenin üç katmanlı örnek modellemesi (Ateş, 2021).

Derin öğrenmenin temel öğeleri şunlardır.

Giriş Katmanı (Input Layer): Derin öğrenme modelinin ilk katmanıdır ve modelin dış dünyadan aldığı veriyi temsil eder. Bu katman, modelin işleme başlamadan önce veriyi alır, genellikle ham veriyi modelin anlayabileceği bir formata dönüştürür ve sonraki katmanlara aktarır. Giriş katmanındaki her nöron, giriş verisinin bir özelliğini (feature) temsil eder. Örneğin, bir görüntü sınıflandırma modelinde her piksel bir nöronla temsil edilir ve giriş katmanındaki nöronlar bu piksellerin değerlerini alır. Giriş katmanı, yalnızca veriyi iletmekle sorumludur ve herhangi bir işlem yapmaz. Bu katmanda yer alan nöron sayısı, kullanılan veri türüne bağlı olarak değişir. Giriş katmanı, modelin başarılı bir şekilde öğrenebilmesi için verinin doğru şekilde sunulmasını sağlar ve bu nedenle veri ön işleme süreci, giriş katmanının etkinliğini artırmak için kritik bir rol oynar.

Gizli Katmanlar (Hidden Layers): Derin öğrenme modellerinde modelin öğrenme sürecinin temelini oluşturan katmanlardır. Bu katmanlar, giriş verisini işleyerek daha soyut özellikler çıkarır ve sonrasında elde edilen bu özellikler, daha üst katmanlarda daha karmaşık hale gelir. Gizli katmanlar, modelin karmaşık ilişkileri öğrenmesini sağlar. Birçok farklı türde gizli katman vardır: Tam Bağlantılı Katmanlar (Dense Layers), her nöronun bir sonraki katmandaki tüm nöronlarla bağlantı kurduğu katmanlardır ve genellikle modelin son derece soyut özellikleri öğrenmesini sağlar. Konvolüsyonel Katmanlar (Convolutional Layers), genellikle görüntü verisi üzerinde kullanılır ve görüntüdeki belirli özellikleri, örneğin kenarları veya renk geçişlerini tanımlar. Havuzlama Katmanları (Pooling Layers) ise, verinin boyutlarını küçültmek ve önemli özellikleri koruyarak işlem gücünü azaltmak için kullanılır. Tekrarlayan Sinir

Ağı Katmanları (Recurrent Layers), zaman serisi verisi veya sıralı veri için uygundur ve geçmiş bilgilerden öğrenme yaparak sıralı verilerin özelliklerini modellemeye çalışır. Gizli katmanlar, genellikle doğrusal olmayanlık eklemek için aktivasyon fonksiyonları (ReLU, Sigmoid, Tanh gibi) kullanır. Bu fonksiyonlar, ağı daha karmaşık ve esnek fonksiyonları öğrenebilmesine olanak tanır. Sonuç olarak, gizli katmanlar, ağı veri üzerinde soyutlamalar yaparak daha genel ve doğru tahminler yapabilmesini sağlayan kritik bileşenlerdir.

Çıkış Katmanı (Output Layer): Derin öğrenme modelinin son katmanıdır ve modelin tahminlerini veya sınıflandırmalarını yaptığı yerdir. Bu katman, modelin öğrenme sürecinde tüm ara katmanlardan elde edilen bilgileri birleştirir ve nihai çıktıyı üretir. Çıkış katmanındaki nöron sayısı, çözülmek istenen probleme bağlıdır. Örneğin, bir ikili sınıflandırma probleminde genellikle bir tek nöron kullanılırken, çok sınıflı sınıflandırmalarda her sınıf için bir nöron bulunur. Çıkış katmanındaki aktivasyon fonksiyonu, modelin çıktısını belirler. Sigmoid fonksiyonu, ikili sınıflandırma problemlerinde, 0 ile 1 arasında bir olasılık değeri verir. Softmax fonksiyonu, çoklu sınıf problemlerinde her sınıf için bir olasılık hesaplar ve bu olasılıkların toplamı 1'e eşit olur. Linear fonksiyonu ise regresyon problemlerinde, sürekli bir değer üretmek için kullanılır. Çıkış katmanı, modelin son kararını verir ve bu karar, modelin ne kadar doğru olduğunu belirlemek için karşılaştırılır ve değerlendirilir.

Derin öğrenme modelleri, farklı katmanlardan oluşarak veriyi işleyip, soyutlama seviyesini artırarak daha karmaşık görevleri yerine getirebilir. Bu katmanlar giriş verisinden, modelin tahminlerini yapan çıkışa kadar, her birinin belirli bir işlevi vardır ve modelin öğrenme kapasitesini artırır.

3.2.3.1. Evrişimli Sinir Ağı

Evrişimli Sinir Ağı (Convolutional Neural Network - CNN), derin öğrenme ve yapay zeka alanında, özellikle görüntü işleme, nesne tanıma, ses işleme ve doğal dil işleme gibi alanlarda yaygın olarak kullanılan bir yapay sinir ağı türüdür. CNN'ler, geleneksel sinir ağlarından farklı olarak, verilerdeki yerel özellikleri öğrenmek ve modellemek için evrişim (convolution) işlemi kullanırlar.

Temel Yapılar:

1. Evrişim Katmanı (Convolutional Layer):

Bu katman, giriş verisi üzerinde filtre (kernel) adı verilen küçük bir pencereyi

kaydırarak her bir bölgenin özelliklerini çıkarır.

Her bir filtre, giriş görüntüsünden yerel özellikleri öğrenir. Bu filtreler, ağırlıkları öğrenir ve modelin farklı nesne veya özellikleri tanımasına yardımcı olur.

Bu işlem, verilerin boyutunu azaltmak için genellikle aktivasyon fonksiyonlarıyla (ReLU gibi) birleşir.

2. Havuzlama Katmanı (Pooling Layer):

Havuzlama katmanı, özellik haritalarını (feature maps) daha küçük boyutlarda özetler ve modelin hesaplama yükünü azaltır.

En yaygın havuzlama türleri, max pooling (en büyük değeri seçme) ve average pooling (ortalama değeri hesaplama) olarak bilinir.

Havuzlama, modelin yerel hareketlenmelere karşı dayanıklı hale gelmesini sağlar.

3. Tam Bağlantılı Katman (Fully Connected Layer):

Evrişimsel ve havuzlama katmanlarından sonra genellikle tam bağlantılı (dense) katmanlar gelir. Bu katmanlar, öğrenilen özelliklerin birleşiminden daha yüksek seviyeli anlamlar çıkarır.

Sonuç olarak, modelin sınıflandırma ya da regresyon gibi hedef görevini gerçekleştirmesine yardımcı olur.

4. Aktivasyon Fonksiyonları:

CNN'lerde en yaygın kullanılan aktivasyon fonksiyonu ReLU (Rectified Linear Unit)'dur. ReLU, negatif değerleri sıfıra döndürür, bu da öğrenme hızını artırır.

Diğer aktivasyon fonksiyonları arasında Sigmoid ve Tanh yer alır, ancak ReLU genellikle daha iyi performans gösterir.

5. Çıktı Katmanı (Output Layer):

CNN'nin çıktısı, genellikle sınıflandırma problemleri için softmax fonksiyonu gibi fonksiyonlarla sonlanır. Bu, modelin tahmin ettiği sınıf olasılıklarını döndürür.

• CNN'in Avantajları:

1. Yerel Bağımlılıkları Öğrenme: Evrişim katmanları, yerel özellikleri öğrenerek görüntülerdeki nesneleri daha iyi tanır. Bu, özellikle görüntü tanıma ve ses işleme gibi alanlarda büyük bir avantaj sağlar.
2. Ağırlık Paylaşımı: CNN, aynı filtreyi tüm giriş verisi üzerinde kullanarak, ağırlıkların paylaşılmasını sağlar. Bu, modelin parametre sayısını büyük ölçüde azaltır ve hesaplama verimliliğini artırır.

3. Özellik Çıkartımı: CNN'ler, geleneksel yöntemlerin aksine, özellik mühendisliği gereksinimini ortadan kaldırır. Yani, model ham verilerden öğrenmeye başlar ve elle müdahale gerektirmez.

- **Uygulama Alanları:**


1. Görüntü Tanıma: CNN'ler, yüz tanıma, nesne tespiti, segmentasyon gibi görüntü işleme görevlerinde yaygın olarak kullanılır.
2. Doğal Dil İşleme (NLP): CNN'ler, metin sınıflandırma, duygu analizi ve hatta bazı dil modelleme görevlerinde de uygulanabilir.
3. Video Analizi: Görüntülerin yanı sıra video verileri üzerinde de kullanılabilir, özellikle hareket analizi ve nesne takibi gibi görevlerde etkilidir.
4. Medikal Görüntüleme: X-ray, MR ve CT taramaları gibi medikal görüntülerde anormalliklerin tespiti için CNN'ler kullanılır.

- **Örnek Mimariler:**

LeNet: 1980'lerin sonunda, Yann LeCun tarafından geliştirilmiş olan LeNet, ilk başarılı CNN mimarilerinden biridir ve genellikle el yazısı rakamlarını tanımak için kullanılmıştır.

AlexNet: 2012'de, AlexNet, ImageNet yarışmasında büyük bir başarı kazandı ve derin öğrenme alanındaki gelişmelere öncülük etti.

VGG, GoogLeNet ve ResNet: Daha derin ve daha karmaşık mimariler olup, özellikle görüntü sınıflandırma alanında etkili sonuçlar üretirler.



Şekil 3.3. Evrişimli sinir ağı yapısı (Panwar, 2018)

Evrişimli Sinir Ağı (CNN), derin öğrenme alanındaki önemli bir modeldir ve özellikle görüntü işleme alanında devrim yaratmıştır. CNN'ler, özellik çıkarımı, yerel bağımlılıkları öğrenme ve daha az parametreyle yüksek doğruluk elde etme gibi

avantajlara sahiptir. Bu yapıların öğrenme yetenekleri, farklı alanlardaki birçok problemi çözmede etkili bir araç haline gelmiştir.

3.2.3.2. Önceden Eğitilmiş CNN Modelleri

Önceden eğitilmiş CNN modelleri, daha önce büyük veri kümeleri üzerinde eğitilmiş ve belirli görevlerde yeniden kullanılabilen derin öğrenme modelleridir. Bu modeller, görüntü işleme ve sınıflandırma gibi görevlerde yaygın olarak kullanılır. Bu çalışmada ise MobileNet, Xception, ResNet50, ResNet101, ResNet152, DenseNet modelleri kullanılmıştır.


3.2.3.3. MobileNET

MobileNet, Google tarafından mobil ve gömülü cihazlarda derin öğrenme modellerinin kullanımını kolaylaştırmak amacıyla geliştirilmiş hafif bir sinir ağı mimarisidir. Bu modelin temel özelliği, hesaplama maliyetlerini önemli ölçüde azaltırken yüksek doğruluğu korumasıdır. MobileNet, geleneksel evrişim katmanlarını, parametre ve hesaplama maliyetlerini düşürmek için "derin ayrılabilir evrişimler" (depthwise separable convolutions) ile değiştirir. Bu yöntem, evrişim işlemi uzamsal (spatial) ve derinlik (depth) boyutlarında ayrı ayrı gerçekleştirilerek işlemi iki aşamaya böler: depthwise convolution ve pointwise convolution. Böylece daha az parametre kullanılarak benzer doğruluk seviyelerine ulaşılır.

Model, esnekliği artırmak için genişlik (width multiplier) ve çözünürlük (resolution multiplier) olmak üzere iki hiperparametre içerir. Bu sayede, hem kanal sayısı hem de giriş görüntüsünün çözünürlüğü azaltılarak farklı cihazların işlem gücüne göre model ölçeklenebilir. MobileNet'in ilk sürümü (MobileNetV1), 2017 yılında tanıtılmıştır ve hafif bir yapı ile gerçek zamanlı görüntü işleme gibi görevlerde başarılı sonuçlar elde etmiştir. Daha sonra MobileNetV2, "ters rezidüel" (inverted residual) bloklar ve doğrusal aktivasyon kullanılarak performansı artırmıştır. MobileNetV3 ise NAS (Neural Architecture Search) ile optimize edilmiş ve H-Swish aktivasyon fonksiyonu gibi yenilikler eklenerek daha verimli bir model ortaya konmuştur.

Bu mimariler, yüz tanıma, nesne algılama ve artırılmış gerçeklik gibi uygulamalarda yaygın olarak kullanılmaktadır. MobileNet, düşük enerji tüketimi ve

hızlı çalışması nedeniyle mobil cihazlarda derin öğrenme modellerinin uygulanabilirliğini büyük ölçüde artırmıştır.



Şekil 3.4. MobileNet ağ mimarisi (Singhal, 2020)

3.2.3.4. Xception

Xception (Extreme Inception), François Chollet tarafından geliştirilen ve 2017 yılında tanıtılan, derin öğrenme modellerinde verimliliği artırmayı amaçlayan bir sinir ağı mimarisidir. Xception, Google'ın Inception mimarisini genişleterek, derin ayrılabilir evrişimler (depthwise separable convolutions) üzerinde yoğunlaşır. Bu mimari, standart Inception bloklarını terk eder ve tamamen derin ayrılabilir evrişimler kullanarak ağı daha basit ve etkili hale getirir. Derin ayrılabilir evrişimler, uzamsal (spatial) ve kanal (channel) boyutlarındaki işlemleri birbirinden ayırarak parametre sayısını ve hesaplama maliyetini büyük ölçüde düşürür. Xception'ın yeniliği, derin ayrılabilir evrişimlerin, geleneksel evrişimlerden daha güçlü bir öğrenme kapasitesine sahip olduğunu göstermesidir.

Xception, geleneksel evrişim katmanları yerine, her bir kanalın uzamsal özelliklerini bağımsız olarak işleyen depthwise convolution ve ardından kanallar arasında birleştirme yapan pointwise convolution kullanır. Bu yaklaşım, ağı daha esnek ve güçlü hale getirir. Özellikle ImageNet veri setinde yapılan deneylerde, Xception, InceptionV3'ten daha yüksek doğruluk seviyelerine ulaşarak bu mimarinin avantajlarını kanıtlamıştır. Ayrıca, Xception'ın basit yapısı, karmaşık Inception modüllerine kıyasla daha anlaşılır ve uygulanabilir bir model sunar.

Xception, görüntü sınıflandırma, nesne algılama ve yüz tanıma gibi görevlerde yaygın olarak kullanılmaktadır. Günümüzde, hafifliği ve doğruluğu dengeleyen bir


mimari olarak, mobil cihazlarda ve düşük hesaplama gücüne sahip platformlarda bile etkili bir şekilde kullanılabilir (Chollet, 2017).

3.2.3.5. ResNet-50

ResNet-50 (Residual Network), 2015 yılında Kaiming He ve ekibi tarafından tanıtılan ve derin öğrenme alanında büyük bir yenilik getiren bir sinir ağı mimarisidir. ResNet, özellikle derin ağlarda karşılaşılan "gradyan kaybolması" (vanishing gradient) problemini çözmek için tasarlanmıştır. Bu problemin üstesinden gelmek için ağ, her birkaç katmanda bir, giriş ve çıkışı doğrudan bağlayan "rezidüel bağlantılar" (residual connections) kullanır. Bu bağlantılar, katmanlar arasında doğrusal olmayan dönüşümleri bypass ederek, bilgi akışını kolaylaştırır ve daha derin ağların eğitilmesini mümkün kılar.

ResNet-50, toplamda 50 katmana sahip bir varyanttır ve derin ağların yüksek doğrulukla çalışabileceğini kanıtlamıştır. Model, her biri birkaç evrişim katmanından oluşan "rezidüel bloklar" ile yapılandırılmıştır. Bu bloklar, girişten çıkışa kısa yol (shortcut) bağlantıları içerir. Bu yapı, daha derin ağlarda bile öğrenme sürecinin etkin bir şekilde devam etmesini sağlar. ResNet-50, hesaplama açısından verimli bir mimari sunarken, ImageNet gibi büyük veri setlerinde üstün doğruluk sonuçları elde etmiştir. Bu model, derin öğrenme topluluğunda standart bir temel haline gelmiş ve birçok başka modelin geliştirilmesine ilham vermiştir.

ResNet-50, sadece görüntü sınıflandırma için değil, aynı zamanda nesne algılama, segmentasyon ve transfer öğrenme gibi birçok görevde yaygın olarak kullanılmaktadır (He ve ark., 2016).




Şekil 3.5. Resnet 50 Mimarisi

3.2.3.6. ResNet-101

ResNet-101 (Residual Network), derin öğrenmede derin ağların performansını artırmayı hedefleyen ve 2015 yılında Kaiming He ve ekibi tarafından tanıtılan ResNet mimarisinin 101 katmanlı bir varyantıdır. ResNet'in temel yeniliği, çok derin sinir ağlarında meydana gelen "gradyan kaybolması" (vanishing gradient) problemine çözüm getiren "rezidüel bağlantılar" (residual connections) kullanmasıdır. Bu bağlantılar, giriş ve çıkışlar arasında kısa yollar (shortcuts) oluşturarak, öğrenme sırasında bilgi akışını kolaylaştırır ve daha derin modellerin eğitilmesini mümkün kılar. Rezidüel bloklar sayesinde, model, her katmanda öğrenilmesi gereken dönüşümü, sadece farkı (residual) öğrenmeye indirger ve böylece optimizasyon sürecini hızlandırır.

ResNet-101, 101 katman derinliğine sahip bir modeldir ve daha fazla katman içeren yapısı sayesinde daha karmaşık özellikleri öğrenebilir. Bu derinlik, görüntü sınıflandırma, nesne algılama ve segmentasyon gibi birçok bilgisayarlı görü görevi için üstün performans sağlar. Örneğin, ResNet-101, ImageNet veri setinde yüksek doğruluk oranları elde etmiş ve daha derin modellerin daha yüksek performans sergileyebileceğini kanıtlamıştır. Ayrıca, model, transfer öğrenme için güçlü bir temel sunar ve birçok modern derin öğrenme modelinin temel yapı taşı olarak kullanılmaktadır.

ResNet-101, hesaplama maliyeti ve doğruluk arasında bir denge kurar. Daha derin bir ağ olması nedeniyle, ResNet-50 gibi daha küçük varyantlara göre daha yüksek hesaplama gücü gerektirir ancak daha karmaşık görevlerde daha iyi sonuçlar sunar (He ve ark. 2016).




Şekil 3.6 ResNet 101 Mimarisi

3.2.3.7. ResNet-152

Net-152 (Residual Network), derin sinir ağlarının performansını artırmak için tasarlanmış, toplam 152 katmana sahip bir varyanttır. 2015 yılında Kaiming He ve ekibi tarafından tanıtılan ResNet mimarisi, derin ağlarda sıkça karşılaşılan "gradyan kaybolması" (vanishing gradient) problemini çözmek için "rezidüel bağlantılar" (residual connections) kullanır. Bu bağlantılar, giriş ve çıkış arasında kısa yollar oluşturarak, öğrenme sürecinde bilgi akışını kolaylaştırır ve daha derin modellerin verimli bir şekilde eğitilmesini sağlar. Rezidüel bloklar, ağın her katmanda öğrenmesi gereken dönüşümü, yalnızca farkı (residual) öğrenmeye indirger ve böylece optimizasyon sürecini hızlandırır.

ResNet-152, derin öğrenme modellerinde yüksek doğruluk seviyelerine ulaşmak için daha fazla katman sunar ve derinliği sayesinde daha karmaşık özellikleri öğrenebilir. Özellikle ImageNet veri setinde yapılan testlerde ResNet-152, daha küçük varyantlara kıyasla daha yüksek performans elde etmiş ve çok derin modellerin, uygun mimari tasarım ile etkili bir şekilde çalışabileceğini göstermiştir. Bu model, görüntü sınıflandırma, nesne algılama ve semantik segmentasyon gibi birçok bilgisayarlı görü görevinde yaygın olarak kullanılmaktadır. Bunun yanı sıra, transfer öğrenme için güçlü bir temel oluşturur ve daha karmaşık modellerin geliştirilmesine ilham vermiştir.


ResNet-152, ResNet ailesindeki en derin modellerden biri olarak, doğruluk ve hesaplama maliyeti arasında bir denge kurar. Daha fazla katmana sahip olması, daha yüksek doğruluk sağlar ancak hesaplama gereksinimlerini de artırır. Bu model, özellikle büyük ölçekli veri kümelerinde etkili sonuçlar sunar ve modern derin öğrenme uygulamalarında bir referans noktası olarak kabul edilir (He ve ark., 2016).



Şekil 3.7. ResNet 152 Mimarisi

3.2.3.8. DenseNet

DenseNet-152 (Dense Convolutional Network), derin sinir ağlarının performansını artırmak ve parametre verimliliğini sağlamak amacıyla geliştirilmiş bir mimaridir. 2017 yılında Gao Huang ve ekibi tarafından tanıtılan DenseNet, her katmanını, önceki tüm katmanların çıktısına bağlayan yoğun bağlantılar (dense connections) kullanır. Bu bağlantılar, bilgi akışını ve gradyan yayılımını kolaylaştırır, böylece derin ağlarda karşılaşılan "gradyan kaybolması" (vanishing gradient) sorununu azaltır. DenseNet ayrıca parametre verimliliğini artırır; her katmanın doğrudan önceki katmanların özellik haritalarına erişimi olduğundan, bu haritaları yeniden hesaplamaya gerek kalmaz.



Şekil 3.8. DenseNet mimarisi (Zhangve ark., 2021)

DenseNet-152, 152 katmanlı bir varyant olup, daha derin mimarilerin öğrenme kapasitesini artırmayı hedefler. Her bir katman, önceki katmanların çıktılarıyla birlikte çalışarak daha zengin ve çeşitli özellik haritaları öğrenir. Bunun sonucunda, model hem düşük parametre sayısı ile yüksek doğruluk sağlar hem de overfitting riskini azaltır. DenseNet-152, özellikle büyük veri setlerinde etkileyici sonuçlar elde etmiş ve

ImageNet gibi geniş ölçekli veri setlerinde üstün performans göstermiştir. Ayrıca, transfer öğrenme için güçlü bir temel sunar ve görüntü sınıflandırma, nesne algılama ve tıbbi görüntü analizi gibi alanlarda yaygın olarak kullanılır.

DenseNet mimarisinin bir diğer avantajı, derinliğe rağmen daha az parametreye ihtiyaç duymasıdır. Bu durum, hesaplama maliyetlerini düşürerek daha verimli bir yapı sağlar. DenseNet, derin öğrenmede parametre verimliliğini artırma ve performansı iyileştirme konusundaki önemli bir yeniliği temsil etmektedir (Huang ve ark., 2017).

3.2.4. Derin öğrenme ile makine öğrenmesi arasındaki fark

Derin öğrenme ve makine öğrenmesi, her ikisi de yapay zeka (YZ) alanında yer alan ve veriden öğrenmeye dayalı yöntemlerdir, ancak bu iki kavram arasında bazı önemli farklar vardır. Makine öğrenmesi, verilerden öğrenmek için genellikle daha basit algoritmalar ve modeller kullanırken, derin öğrenme, bu süreçte daha karmaşık yapılar olan yapay sinir ağlarını ve çok katmanlı ağları kullanır. Makine öğrenmesi algoritmaları, genellikle daha küçük veri setleriyle iyi sonuçlar verebilir ve daha az hesaplama gücü gerektirir. Buna karşın, derin öğrenme büyük veri setleri ve yüksek işlem gücü gerektirir, çünkü sinir ağları çok sayıda katmandan oluşarak veriyi daha derinlemesine ve soyut bir şekilde işler. Derin öğrenme, özellik mühendisliğine olan ihtiyacı büyük ölçüde ortadan kaldırarak, ham veriden (örneğin, görüntülerden veya seslerden) anlamlı özellikleri otomatik olarak öğrenebilirken, makine öğrenmesi genellikle önceden belirlenmiş özellikler üzerinden çalışır. Bu nedenle derin öğrenme, özellikle görüntü işleme, ses tanıma ve doğal dil işleme gibi karmaşık ve büyük veri gerektiren görevlerde üstünlük sağlar. Makine öğrenmesi ise genellikle daha küçük, daha basit problemler için daha verimli olabilir.

3.2.5. Performans metrikleri ve karışıklık matrisi

3.2.5.1 Karışıklık matrisi

Karışıklık matrisi (Confusion Matrix), sınıflandırma algoritmalarının performansını değerlendirmek için kullanılan bir tablo biçimindeki araçtır. Bu matris, modelin doğru ve yanlış sınıflandırma sayılarını dört temel bileşen halinde özetler: Doğru Pozitif (True Positive-TP), Doğru Negatif (True Negative-TN), Yanlış Pozitif

(False Positive-FP) ve Yanlış Negatif (False Negative-FN). Bu bileşenler, bir sınıflandırma modelinin tahmin sonuçlarını karşılaştırmalı olarak analiz etmeye olanak sağlar. Karışıklık matrisi genellikle iki sınıflı (binary) sınıflandırmalarda kullanılır, ancak çok sınıflı (multiclass) problemler için de genişletilebilir.

Karışıklık matrisi, modelin doğruluk (accuracy), kesinlik (precision), geri çağırma (recall) ve F1 skoru gibi performans metriklerini hesaplamak için temel oluşturur. Örneğin, bir modelin doğru pozitif oranını ölçmek için $\text{precision} = \frac{TP}{TP+FP}$ formülü kullanılırken, modelin tüm gerçek pozitif örnekleri ne kadar iyi tespit ettiğini ölçmek için $\text{recall} = \frac{TP}{TP+FN}$ formülü kullanılır.

Karışıklık matrisi, özellikle dengesiz veri setlerinde (örneğin, bir sınıfın diğerine göre çok daha fazla olduğu durumlarda) model performansını anlamak için önemlidir. Bu tür durumlarda yalnızca doğruluk metriği, yanıltıcı olabilir. Karışıklık matrisi ile analiz, modelin eksikliklerini belirleyerek iyileştirme yapılabilecek alanların tespit edilmesine olanak tanır.

Tablo 3.2. Karışıklık Matrisi Örneği (İkili Sınıflandırma)

	Gerçek Pozitif (1)	Gerçek Negatif (0)
Tahmin 1	True Pozitive (TP)	False Positive (FP)
Tahmin 0	False Negative (FN)	True Negative (TN)

3.2.5.2 Performans Metrikleri

Performans metrikleri, bir organizasyonun, sistemin veya bireyin faaliyetlerinin ne kadar etkili ve verimli bir şekilde gerçekleştiğini ölçen göstergelerdir. Bu metrikler, hedeflerin gerçekleştirilmesi, verimlilik düzeylerinin belirlenmesi, süreçlerin optimizasyonu ve karar destek sistemlerinin güçlendirilmesi amacıyla kullanılır. Başarılı performans metrikleri, yalnızca organizasyonel stratejiye uygun hedeflerin belirlenmesine yardımcı olmakla kalmaz, aynı zamanda bu hedeflere ulaşılma düzeyini de somut verilerle ortaya koyar.

Performans metriklerinin çeşitleri, organizasyonun amacına ve faaliyet alanına göre değişkenlik gösterebilir. Örneğin, işletmelerde finansal performans metrikleri, gelir artışı, kar marjı ve varlık dönüşüm oranı gibi göstergelerle ölçülürken, operasyonel performans metrikleri verimlilik, kalite, hız ve müşteri memnuniyeti gibi alanlarda belirlenir. Ayrıca, dijital pazarlama gibi belirli sektörlerde, metrikler tıklama oranı (CTR), dönüşüm oranı (CVR) gibi daha özgül göstergelerle belirlenebilir.

Performans metriklerinin etkili bir şekilde uygulanabilmesi için iki ana öge ön plana çıkar: "Key Performance Indicators (KPI)" ve "Balanced Scorecard" (BSC). KPI, belirli bir hedefe ulaşmak için kullanılan ölçütlerdir ve performansı sürekli olarak izleyerek gerekli iyileştirmeleri yapmaya olanak tanır. Balanced Scorecard ise, yalnızca finansal göstergeleri değil, aynı zamanda iç süreçler, müşteri memnuniyeti ve öğrenme-gelişim alanlarında da ölçütler sunarak organizasyonun stratejik hedeflere ulaşmadaki genel performansını kapsamlı bir şekilde değerlendirir.

Performans metriklerinin doğru seçilmesi ve izlenmesi, bir organizasyonun sürdürülebilir büyümesini sağlamak ve verimliliği artırmak için kritik bir öneme sahiptir. Bu metrikler, organizasyonun stratejik hedeflerine uygun kararlar almasına yardımcı olmak için yol gösterici rol oynar.

Yaygın olarak kullanılan bazı performans metrikleri şunlardır:

Doğruluk (Accuracy): Doğruluk, toplam doğru tahminlerin toplam örnek sayısına oranı olarak hesaplanır. Genellikle dengeli sınıflandırma problemlerinde iyi bir metrik olarak kabul edilir. Ancak, dengesiz sınıflara sahip veri setlerinde yanıltıcı olabilir. Doğruluk Denklemi 3.1’de verildiği gibi hesaplanır:

$$\bullet \text{ Doğruluk} = \frac{TP+TN}{TP+TN+FP+FN} \quad (3.1)$$

Kesinlik (Precision): Modelin pozitif olarak tahmin edilen örneklerin gerçekten pozitif olma oranını ifade eder. Yanlış pozitiflerin etkilerini değerlendirmek için kullanılır. Kesinlik Denklemi 3.2’de verildiği gibi hesaplanır:

$$\text{Kesinlik} = \frac{TP}{TP+FP} \quad (3.2)$$

Duyarlılık (Recall veya Sensitivity): Gerçek pozitifleri doğru bir şekilde tanınma yüzdesidir. Duyarlılık, doğru pozitiflerin sayısı ile gerçek pozitiflerin sayısının toplamına bölünerek hesaplanır. Duyarlılık Denklemi 3.3’de verildiği gibi hesaplanır:

$$\text{Duyarlılık} = \frac{TP}{TP+FN} \quad (3.3)$$

- **Özgünlük/Seçicilik (Specificity):** Gerçek negatiflerin doğru bir şekilde tahmin edilme oranını ifade eder. Özgünlük Denklemi 3.4’de verildiği gibi hesaplanır:

$$\text{Özgünlük} = \frac{TN}{TN+FP} \quad (3.4)$$

- **F1 Puanı (F1 Score):** Duyarlılık ve hassasiyet birleştiren bir metriktir. F1 puanı, hassasiyet ve duyarlılık arasında bir denge kurar. Özellikle dengesiz sınıflandırma problemlerinde kullanışlıdır. F-1 Skoru 3.5’de verildiği gibi hesaplanır:

$$\text{F} - 1 \text{ Puanı} = \frac{2TP}{2TP+FP+FN} \quad (3.5)$$

4. BULGULAR VE TARTIŞMA

Gıda sektöründe izlenebilirlik ve standartlara uygunluk oldukça önemlidir. Derin öğrenme modelleri ile yapılan sınıflandırma sayesinde, her bir fıstık türünün (Siirt ve Antep fıstığı) ait olduğu kalite standardı korunur ve üretim süreçlerinde herhangi bir hile veya sapmanın önüne geçilebilir. Aynı zamanda, ürünlerin coğrafi işaretlerine ve kökenine göre ayırmak, yerel ekonomilerin desteklenmesi açısından da önem taşır. Siirt ve Antep fıstığı gibi yerel ürünler, dünya çapında bilinir ve yüksek ticari değere sahiptir. Derin öğrenme modelleriyle yapılan sınıflandırma, ürünlerin pazar değeri açısından da avantaj sağlar. Farklı kalitelerdeki ürünlerin doğru şekilde sınıflandırılması ve paketlenmesi, ihracat pazarlarında rekabet gücünü artırır. Doğru ürün doğru pazarda olacaktır.

Geleneksel sınıflandırma yöntemleri, genellikle uzman kişiler tarafından yapılan manuel gözlem ve değerlendirme süreçlerini içerir. Ancak derin öğrenme modelleri, geniş veri setleri ile eğitildiğinde bu süreci hızlandırarak büyük ölçekli tarımsal üretimlerde uygulanabilir hale getirir. Bu sayede üretimden satışa kadar olan süreçlerin hızlanması ve optimize edilmesi mümkün olur. Derin öğrenme, tarım sektöründe son yıllarda giderek daha fazla uygulama alanı bulan bir teknoloji haline gelmiştir. Siirt ve Antep fıstığı gibi tarımsal ürünlerin sınıflandırılması üzerine yapılan akademik çalışmalar, hem bilgisayar bilimi hem de tarım bilimi alanlarında önemli katkılar sağlar. Bu çalışmalar, aynı zamanda yapay zekâ tabanlı tarım teknolojilerinin daha da geliştirilmesine ve uygulanabilirliğinin artırılmasına katkıda bulunur. Bu tür çalışmalar tarımda dijitalleşme ve yapay zeka uygulamalarının yaygınlaşmasına katkı sağlayarak, sektördeki inovasyonun önünü açmaktadır.

Siirt ve Antep fıstığının sınıflandırılması, tarımsal verimlilik, kalite kontrol ve pazar değeri açısından büyük bir öneme sahiptir. Derin öğrenme teknolojileri, bu süreci otomatikleştirerek hızlandırmakta, insan hatasını minimize etmekte ve ürün standartlarını korumaktadır. Ayrıca, bu konu üzerine yapılan akademik çalışmalar hem yapay zeka ve derin öğrenme alanına, hem de tarımsal uygulamalara ve bölge ekonomisine önemli katkılar sağlayacaktır. Bu tez çalışmasında fıstık görüntülerinden sınıflandırma yapmak için ResNet50, ResNet101, ResNet152, MobileNet, Xception, DenseNet modelleri kullanılmıştır.

Bu çalışmada, derin öğrenme modelleri, deneme süreçlerinde belirlenen sabit hiperparametre değerleriyle uygulanmıştır. Optimizasyon yöntemi (optimizer), modelin ağırlıklarını güncelleyerek eğitime daha uygun bir yapı elde etmek için kullanılır. Bu algoritmalar, kayıp fonksiyonu tarafından belirlenen hataları azaltmayı hedefler. Gradient Descent, en yaygın optimizasyon algoritmalarından biri olup, modelin parametrelerini belirlenen bir öğrenme oranıyla (learning rate) kayıp fonksiyonunun negatif gradyanına doğru günceller. Stokastik Gradient Descent (SGD), her iterasyonda yalnızca bir örnekle işlem yaparken, mini-batch SGD belirli bir grup veriyle, Batch Gradient Descent ise tüm eğitim setiyle çalışır. Momentum, RMSprop ve Adam gibi gelişmiş algoritmalar, daha hızlı ve stabil bir optimizasyon süreci sağlar. Uygun optimizer seçimi, modelin performansında kritik bir rol oynar.

Bu çalışmada batch_size değeri 32 olarak belirlenmiştir. Batch size, modelin ağırlıklarını güncellemek için kullanılan veri parçacıklarının sayısını ifade eder. Eğitim süreci, veri setinin küçük gruplara (batch) bölünmesiyle gerçekleştirilir. Küçük batch size değerleri, daha sık güncellemeler yaparak detaylı bir öğrenme sağlarken, öğrenme süreci daha dalgalı olabilir. Büyük batch size ise daha stabil güncellemeler yapar; ancak daha fazla hesaplama kaynağı gerektirir ve genelleme yeteneği daha düşük olabilir. Batch size'in ideal değeri, donanım kapasitesine ve modelin karmaşıklığına bağlı olarak deneme-yanılma yoluyla belirlenir.

Bu çalışmada, kayıp fonksiyonu olarak “CategoricalCrossentropy” tercih edilmiştir. Kayıp fonksiyonu, modelin tahmin ettiği değerlerle gerçek değerler arasındaki farkı ölçerek modelin başarısını değerlendirmek ve iyileştirmek için kullanılır. Model parametreleri, eğitim sırasında bu fonksiyonu minimize edecek şekilde ayarlanır.

Kayıp fonksiyonu, çözülmekte olan problemin türüne ve veri yapısına göre farklılık gösterir. Örneğin, regresyon problemlerinde genellikle Mean Squared Error (MSE), sınıflandırma problemlerinde ise Categorical Crossentropy veya Binary Crossentropy tercih edilir. Bu çalışmada sınıflandırma hedeflendiği için “CategoricalCrossentropy” kayıp fonksiyonu uygun görülmüştür. Tablo 4.1.'de parametreler ve kullanıldığı değerler verilmiştir.

Tablo 4.1. Derin öğrenme modellerinin hiperparametre değerleri

Hiperparametre	Değer
Epoch	100

Optimizer	Adam
Loses Fonksiyonu	CategoricalCrossentropy
Batch Size	32
Learning Rate	0.001
Metrikler	'accuracy', 'loss', 'precision', 'recall', 'f1_score'

Açık kaynak kodlu siteden indirilen fıstık veri seti eğitim ve test oranları %70-%30 olarak belirlenmiştir. Çalışma Intel i7 -1068NG7 2,3 GHz işlemciye, 16 GB RAM'e ve Intel İris Plus ekran kartına sahip laptop üzerinden gerçekleştirilmiştir. Modellerin eğitimi 100 epoch büyüklüğünde gerçekleştirildi. Tablo 4.2. kullanılan derin öğrenme modellerinin doğruluk, kesinlik, duyarlılık ve f1 ölçütü aldığı değerler verilmiştir.

Tablo 4.2. Test veri seti ile derin öğrenme modellerinin performans değerlendirmeleri


Model Adı	Doğruluk	Kesinlik	Duyarlılık	F1-Ölçütü	Support
MobileNet	0,98	0,98	0,98	0,98	645
Xception	0,98	0,98	0,98	0,98	645
ResNet 50	0,99	0,99	0,99	0,99	645
Resnet 101	0,98	0,99	0,98	0,98	645
Resnet 152	0,96	0,97	0,96	0,98	645
DenseNet 169	0,97	0,96	0,97	0,97	645

Tabloda belirtilen derin öğrenme modellerinden en yüksek doğruluk, kesinlik, duyarlılık ve F1 ölçütüne ResNet-50 (0.99) modeliyle ulaşmıştır. Tablo 4.2. incelendiğinde, bütün derin öğrenme modellerinde tüm metriklerde birbirine yakın başarımlar elde edilmiştir. Genel olarak derin öğrenme modelleri sınıflandırma konusunda yüksek başarıya ulaşmıştır.

Tablo 4.3.'te bu modellerin koşturulma süreleri verilmiştir. Çalışmada en uzun süre ResNet-152 modeli, en kısa süre de MobileNet modeliyle elde edilmiştir. Çalışmada kullanılan derin öğrenme modelleri ve çalışma esnasında kullandıkları süreler aşağıda tabloda belirtilmiştir.

Tablo 4.3. Derin öğrenme modelleri ile sınıflandırma başarı oranları ve harcanan süreler


Model Adı	Başarı Oranları	Süre
MobileNet	0,98	31 dakika
Xception	0,98	1 saat 41 dakika
ResNet-50	0,99	1 saat 38 dakika
ResNet-101	0,98	3 saat 15 dakika
ResNet-152	0,96	4 saat 11 dakika
DenseNet	0,97	1 saat 41 dakika




Şekil 4.1. Derin öğrenme modelleri ile sınıflandırma başarı oranları

Şekil 4.1' e bakıldığında fıstık sınıflandırma işleminde en başarılı derin öğrenme modeli ResNet-50 olmuştur.


Derin öğrenme modellerinin başarı grafikleri ve iterasyon değerleri Şekil 4.2' de gösterilmiştir.




ResNet-50 Başarı Oranı Grafiği




ResNet-101 Başarı Oranı Grafiği



ResNet-152 Başarı Oranı Grafiği




DenseNet Başarı Oranı Grafiği




Şekil 4.2. Modellerin başarı performansları ve iterasyon değerleri


Yukarıda verilen grafikler incelendiğinde bütün modellerin yaklaşık iterasyon değerleri 10 varınca başarı oranlarının maksimum seviyeye çıkıp, modellerin iterasyon değerleri 100 oluncaya kadar da başarı oranları maksimum seviyede kalmaya devam etmiştir. Derin öğrenme modellerinin Loss (hata) değerlerine ilişkin grafikler Şekil 4.3.'te gösterilmektedir.

MobileNet Loss Değeri Grafiği



Xception Loss Değeri Grafiği







Şekil 4.3. Modellerin Loss (Hata) Değer Grafikleri

Karışıklık matrisi, sınıflandırma algoritmalarının performansını değerlendirmek için kullanılan bir tablo biçimindeki araçtır. Karışıklık matrisi modellerin ne kadar doğru hesapladığını, ne kadar yanlış hesapladığını görsel olarak sunar. Şekil 11’de her modele ait karışıklık matrislerinde satır ve sütunlarda fıstık çeşitlerinin sınıflarına ait isimler yer almaktadır. Sol-üst köşeden sağ-alt köşeye doğru giden koyu çapraz hücreler doğru tahmin değerlerini vermektedir. Açık renkli hücreler ise hangi sınıfa ait yanlış değerleri vermektedir. Şekil 4.4’te derin öğrenme modellerinin karışıklık matrisleri grafikleri verilmiştir.


MobileNet




Xception




ResNet-50




ResNet-101



ResNet-152



DenseNet-50



Şekil 4.4. Modellerin karışıklık matrisi grafikleri

5. SONUÇLAR VE ÖNERİLER

Siirt fıstığının sınıflandırılması, hem tarımsal üretim hem de ticari ve bilimsel çalışmalar açısından kritik bir öneme sahiptir. Bu sınıflandırma, fıstığın genetik özelliklerini, kalite kriterlerini ve yetiştirme koşullarını belirlemek için bir temel sunar. Siirt fıstığı, özellikle yerel ve uluslararası pazarlarda, kendine özgü lezzeti, aroması ve besin değeriyle tanınır. Ancak, bu özelliklerin korunması ve daha iyi anlaşılması için bilimsel bir sınıflandırma gereklidir. Doğru bir sınıflandırma, fıstığın standardizasyonunu sağlayarak ticari değerini artırır ve tüketici güvenini destekler. Aynı zamanda, genetik çeşitliliğin belirlenmesi ve korunması, fıstığın hastalıklara, zararlılara ve çevresel değişimlere karşı dayanıklılığını artıracak yeni çeşitlerin geliştirilmesine olanak tanır. Bunun yanı sıra, sınıflandırma çalışmaları, bölgesel tarımsal planlamada etkili kararlar alınmasını sağlayarak Siirt fıstığı üreticilerinin ekonomik getirilerini artıracaktır. Dolayısıyla, Siirt fıstığının sınıflandırılması sadece ekonomik bir değer yaratmakla kalmaz, aynı zamanda sürdürülebilir tarım uygulamaları ve küresel gıda güvenliği açısından da stratejik bir rol oynar.

Çalışmada, ResNet50, ResNet101, ResNet152, MobileNet, Xception ve DenseNet gibi ileri düzey derin öğrenme modelleri kullanılmıştır. Modellerin performansları, doğruluk, kesinlik, duyarlılık, F1 skoru gibi metriklerle değerlendirilmiştir. Veri seti Kaggle platformundan temin edilmiş olup, eğitim ve test verileri %70 - %30 oranında ayrılmıştır. Görüntü boyutları 225x225 piksele dönüştürülerek eğitim ve test süreçlerinde kullanılmak üzere standart hale getirilmiştir. Model eğitimlerinde "Adam" optimizasyon algoritması ve "Categorical Crossentropy" kayıp fonksiyonu tercih edilmiş, batch size değeri 32 olarak belirlenmiştir. Eğitim süreçleri 100 epoch üzerinden gerçekleştirilmiştir.

Sonuçlar, özellikle ResNet50 modelinin %99 doğruluk oranı ile en başarılı performansı sergilediğini göstermiştir. Diğer modeller de birbirine yakın performanslar sergileyerek genel olarak yüksek doğruluk oranlarına ulaşmıştır. MobileNet, en kısa işlem süresi ile dikkat çekerken, ResNet152 en uzun sürede eğitim tamamlamıştır. Bu durum, farklı modellerin performans ve işlem süresi açısından çeşitli avantaj ve dezavantajlara sahip olduğunu ortaya koymaktadır. Ayrıca, karışıklık matrisleri ve kayıp fonksiyonu grafikleri üzerinden yapılan analizlerde, modellerin sınıflandırma başarısı ve hata oranları detaylı şekilde değerlendirilmiştir.

Derin öğrenme yöntemlerinin bu alanda kullanılması, insan hatasını minimize etmekte ve ürün standartlarını korumakta kritik bir rol oynamaktadır. Özellikle tarımsal üretimde kalite kontrol süreçlerini otomatikleştirerek, hem üreticilere hem de tüketicilere büyük kolaylıklar sağlamaktadır. Bunun yanı sıra, yapay zeka ve derin öğrenme teknolojilerinin tarımsal uygulamalarda kullanımı, bu disiplinlere yönelik akademik çalışmaların artmasına ve teknolojinin daha geniş bir alanda uygulanabilirliğinin test edilmesine olanak tanımaktadır.

Bu çalışma, sadece bir teknik başarı olarak değil, aynı zamanda Siirt ve Antep fıstığı gibi bölgesel ürünlerin global pazardaki rekabet gücünü artırma ve yerel ekonomiye katkıda bulunma potansiyeli açısından da önemlidir. Aynı zamanda, sürdürülebilir tarım uygulamaları ve gıda güvenliği gibi küresel ölçekte stratejik konulara yönelik değerli bir katkı sunmaktadır. Derin öğrenme yöntemlerinin, Siirt fıstığı özelinde sağladığı başarılı sonuçlarla, gelecekte benzer tarımsal ürünlerin sınıflandırılmasında ve geliştirilmesinde bir rehber niteliği taşıyacağı düşünülmektedir.

5.1. Hedefler ve Kısıtlamalar

5.1.1. Hedefler

Bu tez çalışmasının temel hedefi, tarım ürünlerinin, özellikle Siirt fıstığının, sınıflandırılmasında derin öğrenme yöntemlerinin potansiyelini incelemek ve uygulamalı bir model geliştirmektir. Çalışma, geleneksel manuel yöntemlerin sınırlamalarını aşarak, daha hızlı, güvenilir ve otomatikleştirilmiş bir süreç oluşturmayı amaçlamaktadır. Ayrıca, geliştirilen derin öğrenme tabanlı modelin doğruluk oranını artırarak, kalite kontrol süreçlerini optimize etmek, üreticilere verimlilik sağlamak ve tüketici memnuniyetini artırması hedeflenmiştir. Çalışma, aynı zamanda tarım sektöründe yapay zeka tabanlı teknolojilerin uygulanabilirliğini test ederek, bu teknolojilerin diğer ürünlere uyarlanabilirliğini değerlendirmeyi amaçlamaktadır.

5.1.2. Kısıtlamalar

Çalışma, belirli sınırlamalara sahiptir. İlk olarak, kullanılan veri seti büyüklüğü ve çeşitliliği sınırlıdır; veri seti sadece belirli bir coğrafi bölgeden temin edilen Siirt fıstıklarına odaklanmıştır ve bu, genelleme yapmayı zorlaştırabilir. İkinci olarak, derin

öğrenme modellerinin eğitimi ve testi, mevcut donanımın işlem gücü ile sınırlıdır. Özellikle daha büyük veri setleri ve daha karmaşık modellerin eğitimi, yüksek işlem gücü gerektirdiğinden, bu durum çalışma kapsamını daraltabilir. Ayrıca, tarımsal ürünlerin sınıflandırılmasında kullanılan derin öğrenme modellerinin, gerçek zamanlı uygulamalarda performans ve maliyet etkinliği açısından sınırları olabilir. Gelecekteki çalışmalar, bu kısıtlamaların aşılması için daha büyük ve çeşitli veri setlerinin kullanılması, daha güçlü donanım altyapısının sağlanması ve modellerin gerçek zamanlı uygulamalarda test edilmesine odaklanmalıdır.

5.2. Gelecek Çalışmalar

Bu tez çalışması, tarım ürünlerinin sınıflandırılmasında derin öğrenme yöntemlerinin uygulanabilirliğini göstermiş olmakla birlikte, gelecekte yapılacak çalışmalar için çeşitli yönlendirmeler sunmaktadır. İlk olarak, çalışmada kullanılan veri setinin büyüklüğü ve çeşitliliği genişletilmelidir. Farklı coğrafi bölgelerden ve iklim koşullarından elde edilen daha büyük ve çeşitlendirilmiş veri setleri, modelin genelleme kabiliyetini artıracaktır. Bu, Siirt fıstığının yanı sıra diğer tarım ürünlerinin sınıflandırılmasında da modelin performansını değerlendirme fırsatı sunacaktır.

Son olarak, modelin tarımsal ürünlerin coğrafi işaretleme, izlenebilirlik ve tedarik zinciri yönetimi gibi farklı alanlarda uygulanabilirliği araştırılmalıdır. Böylece, tarım sektöründe kalite standartlarını artırmak ve sürdürülebilirlik hedeflerine ulaşmak için yapay zeka temelli sistemlerin daha geniş bir alanda kullanımı sağlanabilir.

Bu öneriler, hem akademik hem de endüstriyel perspektiflerden derin öğrenme tabanlı tarım teknolojilerinin gelişimini destekleyecek ve bu çalışmanın etkisini artıracaktır.

KAYNAKLAR

- Aalami, N. (2020). Derin öğrenme yöntemlerini kullanarak görüntülerin analizi. *Eskişehir Türk Dünyası Uygulama ve Araştırma Merkezi Bilişim Dergisi*, 1(1), 17-20.
- Abbaszadeh, M., Rahimifard, A., Eftekhari, M., Zadeh, H. G., Fayazi, A., Dini, A., & Danaeian, M. (2019). Deep learning-based classification of the defective pistachios via deep autoencoder neural networks. *arXiv preprint arXiv:1906.11878*.
- Akın, E., & Şahin, M. E. Derin Öğrenme ve Yapay Sinir Ağı Modelleri Üzerine Bir İnceleme. *EMO Bilimsel Dergi*, 14(1), 27-38.
- Aktürk, B. (2024). *Derin Öğrenme Metotları ile Asma Yapraklarının Sınıflandırılması*. Batman Üniversitesi.
- Brosnan, T., & Sun, D. W. (2004). Improving quality inspection of food products by computer vision—a review. *Journal of food engineering*, 61(1), 3-16.
- Chollet, F. (2017). Xception: Deep learning with depthwise separable convolutions. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)* (pp. 1251-1258).
- Dini, A., Zadeh, H. G., Rahimifard, A., Fayazi, A., Eftekhari, M., & Abbaszadeh, M. (2020). Designing a hardware system to separate defective pistachios from healthy ones using deep neural networks. *Iran. J. Biosyst. Eng*, 51, 149-159.
- ER, M. B. (2021). Önceden Eğitilmiş Derin Ağlar İle Göğüs Röntgeni Görüntüleri Kullanarak Pnömoni Sınıflandırılması. *Konya Journal of Engineering Sciences*, 9(1), 193-204.
- Farazi, M., Abbas-Zadeh, M. J., & Moradi, H. (2017, November). A machine vision based pistachio sorting using transferred mid-level image representation of Convolutional Neural Network. In *2017 10th Iranian Conference on Machine Vision and Image Processing (MVIP)* (pp. 145-148). IEEE.
- Garcia-Garcia, A., Orts-Escolano, S., Oprea, S., Villena-Martinez, V., Martinez-Gonzalez, P., & Garcia-Rodriguez, J. (2018). A survey on deep learning techniques for image and video semantic segmentation. *Applied Soft Computing*, 70, 41-65.
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)* (pp. 770-778).
- Howard, A. G., et al. (2017). MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications. *arXiv preprint arXiv:1704.04861*.

- Köklü, M. (2022). Pistachio image dataset. Kaggle.
<https://www.kaggle.com/datasets/muratkokludataset/pistachio-image-dataset>
- Huang, G., Liu, Z., Van Der Maaten, L., & Weinberger, K. Q. (2017). Densely connected convolutional networks. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)* (pp. 4700-4708).
- İnik, Ö., & Ülker, E. (2017). Derin öğrenme ve görüntü analizinde kullanılan derin öğrenme modelleri. *Gaziosmanpaşa Bilimsel Araştırma Dergisi*, 6(3), 85-104.
- Kamilaris, A., & Prenafeta-Boldú, F. X. (2018). Deep learning in agriculture: A survey. *Computers and electronics in agriculture*, 147, 70-90.
- Kaplan, R. S., & Norton, D. P. (1992). The Balanced Scorecard: Measures that Drive Performance. *Harvard Business Review*, 70(1), 71-79.
- Keskenler, M. F., & Keskenler, E. F. (2017). Geçmişten Günümüze Yapay Sinir Ağları ve Tarihçesi. *Takvim-i Vekayi*, 5 (2), 8-18.
- Khan, M. A., Alqahtani, A., Khan, A., Alsubai, S., Binbusayyis, A., Ch, M. M. I., ... & Cha, J. (2022). Cucumber leaf diseases recognition using multi level deep entropy-ELM feature selection. *Applied Sciences*, 12(2), 593.
- Koklu, M., & Tutuncu, K. (2017). Classification of chronic kidney disease with most known data mining methods. *International Journal of Advanced Science and Engineering Technology*, 5, 14-18.
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2017). Imagenet classification with deep convolutional neural networks. *Communications of the ACM*, 60(6), 84-90.
- Kuru C., Uygur N., Tekin H., Karaca R., Akkök F., Hancı G., 1986. Anyepfistiği Yetiştiriciliği Ve Mücadelesi.
- Kuru, C. (1993). Dikimden Hasada Antepfistiği. Ar Ajans, Gaziantep.
- Mahdavi-Jafari, S., Salehinejad, H., & Talebi, S. (2008, December). A pistachio nuts classification technique: An ann based signal processing scheme. In *2008 International Conference on Computational Intelligence for Modelling Control & Automation* (pp. 447-451). IEEE.
- Omid, M., Firouz, M. S., Nouri-Ahmadabadi, H., & Mohtasebi, S. S. (2017). Classification of peeled pistachio kernels using computer vision and color features. *Engineering in agriculture, environment and food*, 10(4), 259-265.
- Ortaç, E (2024). *Derin Öğrenme Metotları İle Yüz İfadelerinden Down Sendromu Tespiti*. Batman üniversitesi.
- Parfitt, D. E., Kafkas, S., Batlle, I., Vargas, F. J., & Kallsen, C. E. (2012). Pistachio. *Fruit breeding*, 803-826.

- Parfitt, D., Kallsen, C., & Maranto, J. (1995). Pistachio cultivars. *Center for Fruit and Nut Crop Research and Information, Pomology Dept., Univ. Calif., Davis CA*, 43-46.
- Saglam, C.; Cetin, N. Prediction of Pistachio (*Pistacia vera* L.) Mass Based on Shape and Size Attributes by Using Machine Learning Algorithms. *Food Anal. Methods* 2022, 15, 739–750.
- Siirt il tarım ve orman müdürlüğü. <https://siirt.tarimorman.gov.tr/Menu/133/Siirt-Fistigi-Uretim-Verileri>
- Singh, D.; Taşpınar, YS; Kurşun, R.; Çınar, İ.; Köklü, M.; Özkan, İA; Lee, H.-N. Önceden Eğitilmiş Derin Öğrenme Modelleri ile Antep Fıstığı Türlerinin Sınıflandırılması ve Analizi. *Elektronik* 2022 , 11 , 981.
- Tarım Orman ve Köyişleri Bakanlığı Proje Uygulama Genel Müdürlüğü. Gaziantep Zirai Araştırma
- Tarım ve Orman Bakanlığı. (2023). *2023 yılı fındık üretim raporu*. Tarım ve Orman Bakanlığı Yayınları. <https://www.tarimorman.gov.tr>
- Tekin, H., Arpacı, S., Atlı, S., Açar, İ., Karadağ, S., Yükçeken, Y., Yaman, A. (2001). Antepfıstığı Yetiştiriciliği. Enstitüsü, Yayın No: 13, Gaziantep
- TÜİK, 2021. Bitkisel üretim verileri. http://www.tuik.gov.tr/PreTablo.do?alt_id=1001 Türkiye İstatistik Kurumu (TÜİK) Verileri <https://www.tuik.gov.tr>
- Zhang, Z. Zhang, Z., Liu, Y., Wang, L., & Xia, X. (2021). Deep learning-based image classification of gas coal. *International Journal of Global Energy Issues*, 43(4), 371-