

T.C.
SÜLEYMAN DEMİREL ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

DERİN ÖĞRENME YAKLAŞIMI İLE SAĞLAM VE ÇÜRÜK
ELMALARIN SINIFLANDIRILMASI

Ramazan DURSUN

Danışman
Dr. Öğr. Üyesi Fatih GÖKÇE

YÜKSEK LİSANS TEZİ
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI
ISPARTA - 2023



© 2023 [Ramazan DURSUN]

İÇİNDEKİLER

	Sayfa
İÇİNDEKİLER.....	i
ÖZET	ii
ABSTRACT	iv
TEŞEKKÜR	vi
ŞEKİLLER DİZİNİ	vii
ÇİZELGELER DİZİNİ	viii
SİMGELER VE KISALTMALAR DİZİNİ	ix
1. GİRİŞ	1
2. KAYNAK ÖZETİ.....	4
3. MATERYAL VE YÖNTEM.....	9
3.1. Veri Setinin Oluşturulması	9
3.2. Yapay Zekâ ve Makine Öğrenmesi.....	12
3.3. Yapay Sinir Ağları ve Derin Öğrenme	13
3.4. Evrişimsel Sinir Ağları.....	17
3.5. Önerilen CNN modelleri ve Li Modeli	22
4. ARAŞTIRMA BULGULARI.....	28
4.1. Araştırma Bulguları	28
4.1.1. Sınıf Aktivasyon Haritalama (CAM).....	31
5. TARTIŞMA VE SONUÇLAR.....	33
KAYNAKLAR	34
ÖZGEÇMİŞ.....	38

ÖZET

Yüksek Lisans Tezi

DERİN ÖĞRENME YAKLAŞIMI İLE SAĞLAM VE ÇÜRÜK ELMALARIN SINIFLANDIRILMASI

Ramazan DURSUN

**Süleyman Demirel Üniversitesi
Fen Bilimleri Enstitüsü
Bilgisayar Mühendisliği Anabilim Dalı**

Danışman: Dr. Öğr. Üyesi Fatih GÖKÇE

Dünyada meyve ticaretinin en önemli unsurlarından birisi meyve kalitesidir. Kalite olarak akla ilk başta raf ömrü gelmektedir. Meyve olarak elmayı temel alacak olursak birçok meyveden daha dayanıklı ve uzun süre soğuk hava depolarında uygun sıcaklıkta korunabilen bir meyve türüdür. Bu meyvelerin raf ömrünün daha uzun olabilmesi için soğuk hava depolarına koyulmalarından önce sağlam ve çürük ayrımı yapılması gerekmektedir. Bu ayırmanın yapılmasının temel amaçlardan bir tanesi çürük olan meyvelerin sağlam olanları da çürütmesini engellemektir. Bu amaçla endüstriyel cihazlar geliştirilmeye başlanmış olsa da bu cihazların kullandığı yöntemlerin genel olarak literatüre açılmamış olduğu görülmektedir. Bu açıdan literatürde çeşitli çalışmalar da olsa elmaların sağlık durumuna göre ayrıştırılması doğrultusunda kullanılabilir yöntemler açısından katkı bekleyen noktalar bulunmaktadır. Bu nedenle bu çalışmada elma meyvesi için bilgisayarla görmede çeşitli karmaşık problemlerde yüksek başarımlı sonuçlar alınmasını sağlayan derin öğrenme yöntemlerinden evrişimsel sinir ağıları yöntemi kullanılarak görüntü sınıflandırma problemi üzerinde çalışılmıştır. Tez kapsamında herhangi bir cihaz tasarımı gerçekleştirilmemiş olup; sadece bilgisayarla görme yazılımı üzerinde çalışılmıştır. Literatürde aynı zamanda veriseti eksikliği de göze çarptığından dolayı tez kapsamında öncelikle, 5 farklı türde elmadan (Granny Smith, Golden, Starking, Arap kızı ve Sarı İngiliz) 1036 adet sağlam 1040 adet çürük olmak üzere toplam 2076 adet elma görüntüsü çekilerek bir veriseti oluşturulmuştur. Veriseti oluşturulurken özel ışık ve kamera sistemleri kullanılmamış olup; değişik zaman ve arka planlarda mobil telefon kamerasıyla çekimler yapılmıştır. Veri setinin etiketleme işlemleri elmalar konusunda deneyimli bir kişi tarafından gerçekleştirilmiştir. Elmaların sınıflandırmasını zorlaştıran unsurlar olan sap ve çanak kısımlarının da içerildiği bu veriseti ile evrişimsel sinir ağına dayalı olarak önerilen modellerin elmaları sınıflandırma başarısı iki farklı sınıflandırma problemi kurgulanarak değerlendirilmiştir. Bu problemlerin birinde elmaların sağlam ve çürük olarak; diğerinde de sağlam, az çürük ve çok çürük olarak sınıflandırılması gerekmektedir. Tez kapsamında önerilen modellerin başarımı, literatürde güncel olarak yayınlanmış bir başka modelle kıyaslanmıştır. Bu kıyaslamanın sonucunda önerilen modellerin literatürdeki güncel modele kıyasla yakın başarımlı sağladığı ortaya konulmuştur.

Anahtar Kelimeler: Bilgisayarla Görme, Sayısal Görüntü İşleme, Derin Öğrenme, Görüntü Sınıflandırma, Elma

2023, 38 sayfa



ABSTRACT

M.Sc. Thesis

CLASSIFICATION OF HEALTHY AND DEFECTIVE APPLES WITH DEEP LEARNING APPROACH

Ramazan DURSUN

**Süleyman Demirel University
Graduate School of Natural and Applied Sciences
Department of Computer Engineering**

Supervisor: Asst. Prof. Dr. Fatih GÖKÇE

One of the most important elements of fruit trade in the world is fruit quality. In terms of quality, the first thing that comes to mind is shelf life. If we consider the apple as a fruit, it is a type of fruit that is more durable than many fruits and can be preserved at appropriate temperatures in cold storage for a long time. In order for these fruits to have a longer shelf life, it is necessary to separate healthy and defective fruits before placing them in cold storage. One of the main purposes of this separation is to prevent defective fruits from rotting healthy ones. Although industrial devices have begun to be developed for this purpose, it seems that the methods used by these devices have not been published in the literature in general. In this respect, although there are various studies in the literature, there are points that need contribution in terms of methods that can be used to sort apples according to their health status. For this reason, in this study, the image classification problem for apple fruit was studied using the convolutional neural networks method, one of the deep learning methods that provides high performance results in various complex problems in computer vision. No device design has been carried out within the scope of the thesis; only computer vision software has been studied. Since there is also a lack of a dataset in the literature, within the scope of the thesis, a dataset was first created by taking a total of 2076 apple images, 1036 of which were healthy and 1040 of which were defective, from 5 different types of apples (Granny Smith, Golden, Starking, Malus Domestica ve Yellow English). Special lighting and camera systems were not used when creating the dataset; shots were taken with a mobile phone camera at different times and backgrounds. The labeling of the data set was carried out by a person experienced in apples. With this dataset, which also includes the stem and calyx parts, which are the elements that make the classification of apples difficult, the success of the models proposed based on the convolutional neural network in classifying apples was evaluated by constructing two different classification problems. In one of these problems, apples are to be classified as healthy and defective; in the other case, they should be classified as healthy, slightly defective and very defective. The performance of the models proposed within the scope of the thesis was compared with another model currently published in the literature. As a result of this comparison, it was revealed that the proposed models provide close performance compared to the current model in the literature.

Keywords: Computer Vision, Digital Image Processing, Deep Learning, Image Classification, Apple

2023, 38 pages



TEŐEKKÜR

Tez süreci boyunca bilgi ve deneyimleriyle bana ışık tutan ve bu süreç boyunca gösterdiği ilgi ve alakadan dolayı değerli danışman hocam Dr. Öğr. Üyesi Fatih GÖKÇE'ye teşekkür ederim.

Her zaman yanımda olan ve destekleyen beni hiç yalnız bırakmayan, verdikleri motivasyon sayesinde hedeflerime ulaşabilmem için azmetmemi sağlayan sevgili aileme saygılarımı sunarım.

Ramazan DURSUN
ISPARTA, 2023



ŞEKİLLER DİZİNİ

	Sayfa
Şekil 3.1. Golden ve Granny Smith sağlam elmalardan örnekler	10
Şekil 3.2. Golden ve Granny Smith çürük ve ezik elmalardan örnekler.....	11
Şekil 3.3. Starking ve Arap kızı sağlam elmalardan örnekler	11
Şekil 3.4. Starking ve Arap kızı çürük elmalardan örnekler	12
Şekil 3.5. Yapay zekâ ve alt dallarının küme şeklinde gösterimi	13
Şekil 3.6. Tek bir algılayıcı (<i>İng.</i> perceptron).....	14
Şekil 3.7. Tek katmanlı algılayıcı (<i>İng.</i> perceptron) ağı	15
Şekil 3.8. İki katmanlı algılayıcı (<i>İng.</i> perceptron) ağı	16
Şekil 3.9. LeNet CNN modeli grafiksel gösterimi.	18
Şekil 3.10. Sigmoid fonksiyon grafiği	20
Şekil 3.11. ReLU fonksiyonu grafiği	21
Şekil 3.12. Softmax fonksiyonu grafiği.....	22
Şekil 3.13. Bütün aktivasyon fonksiyonlarının grafikleri.....	23
Şekil 3.14. Düzleştirme işlemi ile çok boyutlu verinin tek boyutlu veriye dönüştürülmesi işlemi	23
Şekil 3.15. Tez kapsamında ikili sınıflandırma problemi için önerilen CNN modelinin grafiksel gösterimi.....	24
Şekil 3.16. Tez kapsamında üçlü sınıflandırma problemi için önerilen CNN modelinin grafiksel gösterimi.....	25
Şekil 3.17. İkili sınıflandırma problemi için uyarlanan Li modelinin grafiksel gösterimi.....	26
Şekil 3.18. Üçlü sınıflandırma problemi için uyarlanan Li modelinin grafiksel gösterimi.....	27
Şekil 4.1. Tez kapsamında önerilen modelin ikili sınıflandırma probleminde 15 iterasyon başarımları ve kayıp grafikleri.....	28
Şekil 4.2. Li modelinin ikili sınıflandırma probleminde 15 iterasyon başarımları ve kayıp grafikleri.....	28
Şekil 4.3. Tez kapsamında önerilen modelin üçlü sınıflandırma probleminde 15 iterasyon başarımları ve kayıp grafikleri	29
Şekil 4.4. Li modelinin üçlü sınıflandırma probleminde 15 iterasyon başarımları ve kayıp grafikleri.....	29
Şekil 4.5. Tez kapsamında önerilen modelin üçlü sınıflandırma probleminde 30 iterasyon başarımları ve kayıp grafikleri	30
Şekil 4.6. Li modelinin üçlü sınıflandırma probleminde 30 iterasyon başarımları ve kayıp grafikleri.....	30
Şekil 4.7. Tez kapsamında önerilen modelin ikili sınıflandırma probleminde 100 iterasyon başarımları ve kayıp grafikleri	31
Şekil 4.8. Tez kapsamında önerilen modelin üçlü sınıflandırma probleminde 100 iterasyon başarımları ve kayıp grafikleri	31
Şekil 4.9. CAM uygulanacak görüntüler	32
Şekil 4.10. CAM uygulanmış görüntüler.....	32

ÇİZELGELER DİZİNİ

	Sayfa
Çizelge 2.1. Literatürde yapılmış olan çalışmalar	5
Çizelge 3.1. Verisetinin ikili sınıflandırma problemi için görüntü sayıları.....	12
Çizelge 3.2. Verisetinin üçlü sınıflandırma problemi için görüntü sayıları	12
Çizelge 3.3. Örnek görüntü	19
Çizelge 3.4. Uygulanacak filtre	19
Çizelge 3.5. Filtre uygulandığında elde edilen çıktı görüntü	19



SİMGELER VE KISALTMALAR DİZİNİ

<i>BG</i>	Bilgisayarla Görme
<i>CAM</i>	Sınıf Aktivasyon Haritalama
<i>CNN</i>	Evrişimsel Sinir Ağı
<i>GLCM</i>	Gri Seviye Eş Dizimli Matris
<i>HOG</i>	Yönlü Gradyan Histogramları
<i>LDC</i>	Doğrusal Ayırıcı Sınıflandırıcı
<i>R – CNN</i>	Alan Tabanlı Evrişimsel Sinir Ağı
<i>RELU</i>	Doğrultulmuş Lineer Birim
<i>SSD</i>	Single Shot Multibox Detector
<i>SVM</i>	Destek Vektör Makinesi
<i>YOLO</i>	You Only Look Once



1. GİRİŞ

Bilgisayarla görme (BG), kamera görüntülerinin bilgisayarda işlenerek anlamlandırılmasını otomatik olarak sağlamayı hedefleyen bir çalışma alanıdır (Szeliski, 2011; Prince, 2012; Chandaliya, 2020). BG çalışma alanı, yapay zeka, görüntü işleme ve makine öğrenmesi alanları ile ortak birçok kesişime sahip olup; bu alanlardan birçok yöntem ve algoritma bilgisayarla görme sistemleri içerisinde kullanılmaktadır.

BG sistemleri, derin öğrenme (Goodfellow vd., 2016; Ahmed vd., 2023) yaklaşımlarının geliştirilmesinden önce insan eliyle tasarlanmış yöntemlerle problem çözümüne odaklanmaktaydı (Gonzalez ve Woods, 2018). Artık günümüzde derin öğrenme yaklaşımları, verisetlerinin yeterli olduğu karmaşık problemlerde oldukça başarılı sonuçlar ortaya koymakta ve insan eliyle yöntem geliştirme gereksinimini azaltmaktadır. Derin öğrenme yaklaşımları verisetinin yetersiz olduğu durumlarda öğrenme düzeyinin düşük olması, yüksek işlem gücü gereksinimi, sistemin bir karakutu şeklinde çalışması nedeniyle nasıl öğrendiğini anlamanın çok mümkün olmaması, sistem modeli ve parametrelerinin seçilmesinin zorlu olması gibi dezavantajlara sahip olsa da; birçok gerçek dünya probleminin çözümünde yüksek performanslı sonuçlar elde edilmesine olanak sağlamaktadır.

BG sistemleri, plaka ve yüz tanıma sistemlerinden, ürün kalite kontrol sistemlerine; tıbbi görüntüleme sistemlerinden, otonom araçlara; depolarda otomatik paketleme sistemlerinden, sinema sektörüne kadar birçok alanda gerçek dünya problemlerinin çözümünde aktif olarak kullanılmaktadır (Szeliski, 2011). BG sistemleri, birçok sektörde olduğu gibi gıda sektöründe de kalite ve sağlık güvencesi açısından git gide daha fazla kullanılmaktadır (Balkır vd., 2019). Bu tür sistemler, gıdaların kalitesinin değerlendirilmesi için insan denetiminin yerini giderek alma potansiyeli taşımaktadır. Bunu mümkün kılan ve bu sürecin hızlanmasını sağlayacak olan en önemli etmenlerden birisi hızlı, güvenilir ve düşük maliyetle hayata geçirilebilecek yöntemlerin geliştirilmesidir.

Gıda sektörü içerisinde meyvelerin kalitelerinin korunması ve kalitelerinin sınıflandırılması önemli bir konudur. Bu tez kapsamında elma meyvesi özelinde çalışma yürütülmüştür. Elma bir kış meyve türüdür ve diğer meyvelere göre daha dayanıklı bir meyve türü olsa da belirli koşullar sağlanmadığı müddetçe uzun süre muhafaza edilemez.

Bu kořullar uygun sıcaklık ve bakterilerden arınıklık olarak tanımlanabilir. Her yıl eylül ve ekim aylarında hasat edilen elmalar, yıl boyunca tazeliklerini ve raf ömürlerini koruyabilmeleri için özel olarak tasarlanan soğuk hava depolarında korunmaktadır. Bu soğuk hava depoları her ne kadar özel olarak yapılmıř olsalar dahi, depoya konulan sađlam elmaların yanında çürük olan elmalar bulunursa, bu çürük elmalar sađlam elmaları da çürütmektedir. Bu durum hem maliyet ađısından zarara neden olmakta, hem de kalite ve sađlık ađısından olumsuz etkilere sebep olma potansiyeli tařımaktadır. Bu sorunun yařanmasını önlemek için elmalar depolara konulmadan önce insan gücü yardımı ile sađlam ve çürük olarak ayrıştırma işlemleri gerçekleştirilmektedir. Bu ayrıştırma işleminin sonunda sađlam olarak ayrılan elmalar soğuk hava depolarına konulmaktadır. Ayırma işlemlerinin insan gücüyle yapılması hem belli sayıda insana gerek duyularak zaman ve iş gücü almakta hem de hata ihtimaline ađık bir yöntem olarak karřımıza çıkmaktadır.

Elmaların sınıflandırması ve ayrıştırılması için endüstriyel cihazlar yakın geđmiřte gerçekleştirilmeye başlanmıřtır (Greefa, 2014; GreenSort, 2019; Aweta, 2020; Sofu vd., 2016). Ancak, Sofu vd. (2016) tarafından sunulan çalıřmadaki cihaz haricinde, bu cihazların kullandıkları yöntemler bildiđimiz kadarıyla řirketlerin kendilerine özel bilgisi olarak kapalı tutularak literatüre ađılmamıřtır. Bu alandaki literatür Bölüm 2'de detaylı řekilde aktarılacađı üzere çeřitli çalıřmaları iđerse de, henüz tam olarak çözüme ulařıldıđını söylemek pek mümkün deđildir. Bu nedenle bu tez kapsamında, literatürdeki bu ađıđa bir katkı sunabilmek adına önce bir veriseti hazırlanmıř ve ardından bu veri seti kullanılarak, eđitilen bir derin öđrenme modeli ile sınıflandırma çalıřmaları gerçekleştirilmiřtir. Tez kapsamında herhangi bir fiziksel cihaz tasarımı gerçekleştirilmemiř olup; literatüre yapılan katkılar veriseti ve yazılım boyutunda olmuřtur. Bu bađlamda literatüre sađlanan katkılar ařađıda listelenmiřtir.

- 5 farklı elma türünden görüntüler iđereren bir veriseti oluřturulmuřtur. Bu kadar farklı elma türünü iđereren bir veriseti literatür için oldukça kıymetlidir. Zira elma türlerinin hem renk hem de doku olarak farklı özellikleri sebebiyle problem zorlařmaktadır. Literatürde bilgimiz dahilinde tez kapsamında oluřturulan verisetindeki kadar farklı çeřit ve sayıda görüntü iđereren bir bařka veriseti

bulunmamaktadır.

- Veriseti oluşturulurken standart bir telefon kamerası kullanılmış olup, özel bir ortam hazırlığı olmaksızın görüntüler çekilmiştir. Literatürde ve endüstride, endüstriyel ölçekte veya hiperspektral kameraların, özel hazırlanmış ortamlarda kullanımı da göze çarpmakta olup, düşük maliyetli ekipmanlarla herhangi bir özel ışıklandırma ortamı oluşturulmaksızın hazırlanmış veriseti ile çalışılmış olması sınıflandırma problemini güçleştirerek, tezin literatür açısından önemini arttırmaktadır. Ayrıca verisetindeki görüntülerde elmaların sınıflandırmasını güçleştiren sap ve çanak kısımlarının yer alması engellenmemiş; rastgele açılarda yapılan çekimlerde bu kısımların yer aldığı görüntüler de verisetine dahil edilmiştir.
- Literatürde bulunan güncel ve güçlü bir model ile kıyaslanabilir performansa sahip bir model önerilmiştir. Bu model ile 2 ve 3 sınıflı karşılaştırmalar sunularak modelin başarımı ortaya konulmuştur.

2. KAYNAK ÖZETİ

Görüntü sınıflandırma bir görüntünün ait olduğu sınıfı belirleme işlemidir. Nesne bulma, görüntülerdeki belli sınıf(lar)a ait nesnelere içeren sınırlayıcı kutuların bulunmasını ifade eder. Nesne bulma hem sınıflandırma hem de sınırlayıcı kutunun çıkarımını içermektedir. Nesnenin sınırlayıcı kutusunu değil de görüntü içerisinde hangi pikselleri kapladığının bulunma işlemine de bölütleme adı verilir. Görüntü sınıflandırma (Gavali ve Banu, 2019; Liu vd., 2023b; Xiao vd., 2023; Liu vd., 2023a), nesne bulma (Zou vd., 2023; Chen vd., 2023; Kaur ve Singh, 2023; Guo vd., 2016; Liu vd., 2016; Redmon vd., 2016; Jiang vd., 2022; Ren vd., 2015) ve bölütleme (Luo vd., 2023; Sultana vd., 2020; Zhang vd., 2021) BG'nin üzerinde aktif olarak hala çalışılan önemli görüntü anlamlandırma problemlerindedir.

Bu tez kapsamında, oluşturulan verisetindeki görüntülerdeki elmaların sağlık durumlarına göre sınıflandırma problemi üzerinde çalışılmıştır. Bölüm 3.1'de verisetinin detaylarında anlatılacağı üzere, görüntüler elmalardan başka bir nesne içermeyecek şekilde hazırlanmış olup, nesne bulma gibi bir problemle uğraşılmamıştır. Bu bağlamda tez, üzerinde çalışılan problem itibarıyla görüntü sınıflandırma kategorisine girmektedir.

Elmaları sınıflandırmak ve ayırtmak amacıyla endüstriyel ölçekte cihazlar yakın geçmişte gerçekleştirilmeye başlanmış olsa da (Greefa, 2014; GreenSort, 2019; Aweta, 2020; Sofu vd., 2016); Sofu vd. (2016) tarafından gerçekleştirilen çalışmadaki cihaz haricinde bu cihazların kullandığı yöntemler bildiğimiz kadarıyla şirketlerin kendi bünyesinde tutularak literatüre açılmamıştır. Elmaların sınıflandırılması problemini bir BG problemi olarak ele aldığımızda literatürde, aşağıda özetleneceği üzere Çizelge 2.1'de de listelenen çeşitli çalışmalar bulunmakla birlikte, hala katkı bekleyen noktalar mevcuttur.

Mohana ve Prabhakar (2015), Jonagold türü 200 farklı elmadan alınan toplamda 600 farklı görüntü üzerinde elmaların sap-çanak kısımlarının kusurlu kısımlarından ayırt edilmesini sağlamaya çalışmışlardır. Bu çalışmada, çoklu eşikleme ile bölütleme yöntemi kullanılarak tespit edilen aday bölgelerin şekilsel tanımlamaları Fourier, Multifractal ve Radon tanımlayıcıları kullanılarak çıkarılmıştır. Bu özelliklerin sınıflandırılması için destek vektör makinası (SVM), yapay sinir ağları (ANN), k -en yakın komşu sınıflandırıcı (k -NN), doğrusal seçici sınıflandırıcı (LDC) ve AdaBoost

yöntemlerini denemişler; SVM'in %94 ortalama doğruluk ile en iyi sınıflandırma performansı sağladığı sonucuna varmışlardır. Bu çalışmada, sap ve çanak kısımlarını tespit ederek elma derecelendirme sistemleri için yardımcı bir sistem gerçekleştirilmiş olup; elmaları sınıflandırma üzerine komple bir yöntem önerisi bulunmamaktadır.

Çizelge 2.1. Literatürde yapılmış olan çalışmalar

Yazar	Yıl	Amaç	Yöntem	Başarım Oranı
Mohanna ve Prabhakar	2015	Elmada sap çanak bölgelerinin tanınması	Multifractal, Fourier ve Radon dönüşümleri, SVM, ANN, k-NN, LDC ve AdaBoost	94
Dubey ve Jalal	2016	3 farklı türde hastalığı bulunan elmaların ve normal elmaların renk, şekil, doku özellikleriyle birbirinden ayırt edilmesi	k-means kümeleme, Destek vektör makinesi (SVM)	95,95
Sofu vd.	2016	Elmaların ayrıştırılması ve kalite kontrolü	k-means kümeleme, geometrik analiz, C4.5	73–96 arası
Lu ve Lu	2017	Histogram tabanlı otomatik eşikleme yöntemiyle elmada çürük tespiti	Ridler, Otsu yöntemleri	90
Cömert vd.	2019	Elmaların çürük ve sağlam olarak sınıflandırılması	Faster R-CNN	84,95
Siddiqi	2019	Elma üzerindeki çürük bölgeyi tespit etme	YOLO-v2 ve SSD	
Kayaalp ve Metlek	2020	Sağlam ve çürük elmaların derin öğrenme algoritması ile sınıflandırılması	CNN	91,25
Valdez	2020	Elma üzerinde çürük tespiti	YOLO-v3 ve SSD	
Li vd.	2021	Elma kalite tespiti ve sınıflandırması	CNN, Google inception V3, HOG/GLCM+SVM	95,33 91,33 77,67

Dubey ve Jalal (2016), 3 farklı türde hastalığı bulunan elmalarla normal elmaların birbirinden ayırt edilmesi üzerine çalışmışlardır. Çalışma her sınıftan 80 tane olmak üzere toplam 320 görüntü bulunan veriseti ile gerçekleştirilmiştir. Farklı tür ve

renklerde elmalar verisetinde bulunmakla birlikte kaç farklı türü içerdiği belirtilmemiştir. Sap ve çanak kısımları verisetindeki bazı görüntülerde bulunmakta; bazılarında bulunmamaktadır. Bu kısımların getirdiği zorlukları bu kısımlara özel herhangi bir ekstra işlem yapmadan aşmaya çalışmışlardır. Hasta olan kısımları k-ortalamlar kümeleme algoritması yardımı ile tespit edip; Destek Vektör Makinesi (SVM) yardımı ile sınıflandırma gerçekleştirmişler ve %95,94 doğruluk elde etmişlerdir.

Sofu vd. (2016) tarafından gerçekleştirilen çalışmada, endüstriyel bir elma ayırma ve kalite kontrol cihazı sunulmuştur. Bu çalışmada elmaların üzerindeki kusurların bulunması için geleneksel görüntü işleme tekniklerine dayalı bir yöntem önerilmiştir. Çeşitli ön işlemlerden sonra elde edilen bitmap görüntülerdeki bölgeler eksantriklik değerine göre sap-çanak veya kusur olarak değerlendirilmektedir. Sınıflandırma için C4.5 karar ağacı yönteminin kullanıldığı çalışmada, sistemin Golden, Starking Delicious ve Granny Smith türünde 183 elma ile yapılan testlerde % 73-96 arası doğrulukla çalıştığı belirtilmiştir.

Lu ve Lu (2017), histogram tabanlı otomatik eşikleme yöntemiyle elmalarda çürük tespiti üzerinde çalışmışlardır. Çok spektrumlu bir görüntüleme sistemiyle 730 nm dalga boyunda, 4 farklı türde (Golden Delicious, Granny Smith, Royal Gala, Delicious) elmadan alınan 120 görüntüyü ve Fuji türünde elmalardan alınan 40 görüntüyü kullanmışlardır. Bu görüntülerde yapay veya doğal olarak oluşmuş çürükler yer alabilmekte olup; elmaların çanak kısımları yer almamakta; sap kısımları da sadece sapı varsa yandan görünmektedir. Çürük bölgenin tespiti amaçlanan çalışmada 9 farklı otomatik eşikleme yöntemi denenmiş ve en iyi başarıya sahip olan yöntemler yapay çürüklerde %90 üzerinde doğruluk sağlayan *yinelemeli eşikleme*, *kümeleme tabanlı eşikleme* ve *histogram vadisi vurgulu eşikleme* teknikleri olmuştur.

Cömert vd. (2019) tarafından gerçekleştirilen çalışmada 100'er adet sağlam ve çürük elmanın 6 farklı yönünden çekilerek elde edilen toplamda 1200 görüntü kullanılmıştır. Çürük bölgelerin tespitini hedefleyen çalışmada Faster R-CNN metodu (Ren vd., 2015) metodu kullanılmış olup; % 84,95 oranında bir başarı elde edilmiştir. Çalışmada sap ve çanak kısımlarının görüntülerde bulunduğu ve bu durumun başarımı düşürdüğü belirtilmiştir.

Siddiqi (2019) tarafından gerçekleştirilen çalışmada, sadece Golden türü elmalardan sap ve çanak kısımlarını da içerecek şekilde alınan 244 tane görüntü kullanılarak çürük bölgenin tespiti amaçlanmıştır. You Only Look Once (YOLO-v2) (Redmon vd., 2016) ve Single Shot Multibox Detector (SSD) (Liu vd., 2016) yöntemleri kullanılmış ve SSD tabanlı sistemin YOLO-v2 tabanlı sisteme göre daha başarılı olduğu belirtilmiştir.

Kayaalp ve Metlek (2020), Kleynen vd. (2005) tarafından Jonagold türü elmalar ile oluşturulan bir verisetindeki 280 sağlam, 246 çürük elma görüntüsünü kullanarak bir sınıflandırma çalışması gerçekleştirmişlerdir. Kullanılan görüntülerde elmaların sap-çanak kısımları bulunmamaktadır. Görüntüler 450 nm, 500 nm, 750 nm ve 800 nm dalga boylarında alınmış olup, bu görüntülerden oluşturulan RGB görüntüler de kullanılmıştır. Çalışmada evrişimsel sinir ağı yöntemi tercih edilmiştir. Farklı dalga boyunda alınan görüntülerle, 16 farklı kombinasyon oluşturularak yapılan testlerde, 450 nm ve 500 nm dalga boylarındaki görüntülerin birlikte kullanımının, % 91,25 başarı oranı ile en iyi sonucu verdiği belirtilmiştir.

Valdez (2020) tarafından gerçekleştirilen çalışmada, You Only Look Once (YOLO-v3) (Redmon ve Farhadi, 2018) ve Single Shot Multibox Detector (SSD) (Liu vd., 2016) yöntemlerinin elma üzerindeki çürükleri tespitinde kıyaslaması sunulmuştur. 452 görüntülük bir veriseti kullanılmış olup; SSD sağlam elmaları bulmada, YOLO-v3 ise kusurlu elmaları bulmada daha iyi olarak rapor edilmiştir.

Li vd. (2021) tarafından gerçekleştirilen makalede, Yantai Red Fuji türü elmalardan çekilen 3600 görüntü kullanılarak, elma kalite tespiti ve sınıflandırması problemi üzerinde çalışılmıştır. Veri çoğaltma teknikleriyle bu görüntüler artırılarak 3 farklı model eğitilmiş ve bunların başarımları 300 farklı elma kullanılarak oluşturulan ayrı bir veriseti üzerinde test edilmiştir. Eğitilen 3 modelden birincisi çalışmada önerilen CNN tabanlı bir model; ikincisi Google Inception V3; üçüncüsü de yönlü gradyan histogramları (HOG), gri seviye eş dizimli matris (GLCM) ve SVM tabanlı bir klasik görüntü işleme modelidir. Bu yöntemlerin doğruluk oranları sırasıyla % 95,33, % 91,33 ve % 77,67 olarak bulunmuştur.

Yukarıda özetlenen literatürdeki çalışmalar değerlendirildiğinde elmaların sınıflandırılması problemiyle ilgili olarak bu tez ile de bağlantılı olarak şu noktalar vurgulanabilir:

- Elmanın anatomik olarak yapısında bulunan sap ve çanak kısımları, elmaların çürük olup olmadığını ayırt etmeyi önemli ölçüde zorlaştırabilmektedir. Literatürde bu sorunu çözmeye yardımcı olmak için sadece sap-çanak kısımlarını bulmaya yönelik çalışmalar olduğu gibi, bu kısımların bulunmadığı görüntülerin kullanımı da söz konusudur. Ancak sap-çanak kısımları elmalar için kaçınılmaz bir durumdur ve bu kısımların görüntülerde içerilerek çözüm üretilmesi gerçek hayata aktarılabilir bir çözüm üretme adına önemlidir. Literatürde sap-çanak kısımlarının dahil edildiği ve gerçek şartlar için çözüm hedefi olan çalışmalar da bulunmaktadır. Bu tez kapsamında problemi zor haliyle ve gerçek hayata uygun şekilde çözebilmek adına sap-çanak kısımlarının bulunduğu elma görüntüleri kullanılmıştır.
- Literatürde kullanılan verisetleri ya sayıca az elma içermekte ya da farklı türde elmaları içermek bakımından zayıf kalabilmektedir. Hem elma türü çeşitliliği hem de görüntü sayısı açısından zengin bir verisetiyle çalışma gerçekleştirilmesi literatüre önemli bir katkı sağlayacaktır. Bu nedenle tez kapsamında oluşturulan veriseti hem elma türü hem de görüntü sayısı açısından kapsamlı şekilde hazırlanmaya çalışılmıştır.
- Geçmişten günümüze doğru gelindiğinde geleneksel yöntemlerin yerine, daha başka BG problemlerinde de gözlemlendiği üzere, derin öğrenme tabanlı yöntemlerin kullanılmaya başlandığı ve yüksek başarımlar elde edildiği görülmektedir. Bu açıdan literatürde bildiğimiz kadarıyla en kapsamlı ve güncel çalışmada (Li vd., 2021) CNN yöntemi başarımla öne çıkmakta ve bu tespitlerimizin geçerliliğini göstermektedir. Ancak Li vd. (2021) tarafından gerçekleştirilen çalışmada tek türde elma görüntüleri ile çalışılmıştır. Farklı elma türleriyle derin öğrenme tabanlı yaklaşımların denenmesi literatürde eksik olarak göze çarpmaktadır. Bu tez kapsamında gerçekleştirilen çalışmalar, bu boşluğu da doldurma amacı taşımaktadır. Bu bağlamda tez kapsamında, kullanımı önerilen CNN modelinin, Li vd. (2021) tarafından önerilen modelle kıyaslaması da sunulmuştur. Li vd. (2021) tarafından önerilen model tezin geri kalan kısmında *Li modeli* olarak adlandırılacaktır.

3. MATERYAL VE YÖNTEM

Tez için gerekli olan veriseti, herhangi bir kaynaktan alınmamış; farklı türlerde ve sağlamlık derecelerinde elmalar mobil telefon kamerasıyla çekilerek çalışma kapsamında oluşturulmuştur. Bölüm 3.1’de verisetinin detayları hakkında bilgi verilmiştir.

BG sistemleri içerisinde yüksek başarılı sonuçlar elde etme potansiyelinden dolayı, derin öğrenme yöntemlerinden CNN tercih edilmiş olup; makine öğrenmesi, derin öğrenme ve CNN ile ilgili teknik detaylar Bölüm 3.2 ve sonrasındaki bölümlerde aktarılmıştır.

3.1. Veri Setinin Oluşturulması

Literatürde verilen verisetlerinin gerek yetersizliği, gerekse erişim konusunda yaşanan sorunlar nedeniyle tez kapsamında orijinal bir veriseti oluşturularak kullanılmıştır. Bu amaçla, Granny Smith, Golden, Starking, Arap kızı ve Sarı İngiliz olmak üzere toplam 5 farklı türden yaklaşık 700 elmanın farklı açılardan, farklı zamanlarda ve farklı arka planlarda fotoğrafları iPhone® 5s model bir mobil telefon ile çekilmiştir. Toplamda 2076 tane 3264×2448 piksel çözünürlüğünde fotoğraf çekilmiştir. Çekimler sırasında kamera ile elmalar arası mesafeyi sabit ve ortam ışık şartlarını eşit tutmak özel için bir düzenek kullanılmamış; bu sebeple elmaların görüntüler içerisinde kapladığı alanın oranı ve görüntülerin parlaklık seviyesi değişebilmektedir. Çoğu bütün olarak yer alsa da, bazı fotoğraflarda elmaların tamamı görüntü içerisinde değildir. Az sayıda fotoğrafta elmanın bulanık olarak çıkması da söz konusudur. Elmaların çekim öncesi özel olarak temizlenmemiştir; bazı elmalar temiz olup bazılarının üzerinde toz, yaprak parçası, çürük elmalardan kopan parçalar ve benzeri şeyler bulunabilmektedir. Elmalar çekim sırasında rastgele konulmuş olup; görüntülerde elmaların sap ve çanak kısımlarının yer aldığı ve almadığı durumlar karışık olarak bulunmaktadır.

Verisetindeki görüntülerin iki farklı kopyası;

- Çürük ve sağlam şeklinde iki sınıfa,
- Az çürük, çok çürük ve sağlam şeklinde üç sınıfa,

elma konusunda deneyimli bir kiři tarafından ayrılarak iki farklı sınıflandırma problemi için etiketlenmiştir. Bu problemler tezin ilerleyen kısımlarında sırasıyla *ikili sınıflandırma* ve *üçlü sınıflandırma* şeklinde adlandırılacaktır. Deneyimli kiři elmaları etiketlerken soğuk hava deposuna konulmaları uygun olanları sağlam olarak kategorize etmiştir. Üçlü sınıflandırma problemi için, sağlam olmayan elmaları çürük miktarlarının az veya çok olmasına göre etiketlemiştir. Değerlendirme yapılırken elmaların görünen kısmına göre karar verilmiş olup; bir tarafı çürük, ama diğeri sağlam olan elmanın çürük kısmı görüntüde hiç görünmüyorsa bu fotoğraf sağlam olarak etiketlenmiştir. Üzerinde çürük elmalardan parçalar bulunan ve bu durumun elma hakkında net karar vermeyi engellediği durumlarda elma sağlam olarak etiketlenmemiştir.

Verisetindeki Golden ve Granny Smith sağlam elmalardan örnekler Şekil 3.1’de; Golden ve Granny Smith çürük ve ezik elmalardan örnekler Şekil 3.2’de; Starking ve Arap kızı sağlam elmalardan örnekler Şekil 3.3’te; Starking ve Arap kızı çürük elmalardan örnekler Şekil 3.4’te verilmiştir.



Şekil 3.1. Golden ve Granny Smith sağlam elmalardan örnekler



Şekil 3.2. Golden ve Granny Smith çürük ve ezik elmalardan örnekler



Şekil 3.3. Starking ve Arap kızı sağlam elmalardan örnekler



Şekil 3.4. Starking ve Arap kıızı çürük elmalardan örnekler

Çizelge 3.1. Verisetinin ikili sınıflandırma problemi için görüntü sayıları

	SAĞLAM	ÇÜRÜK	TOPLAM
EĞİTİM	836	840	1676
TEST	200	200	400
TOPLAM	1036	1040	2076

Çizelge 3.2. Verisetinin üçlü sınıflandırma problemi için görüntü sayıları

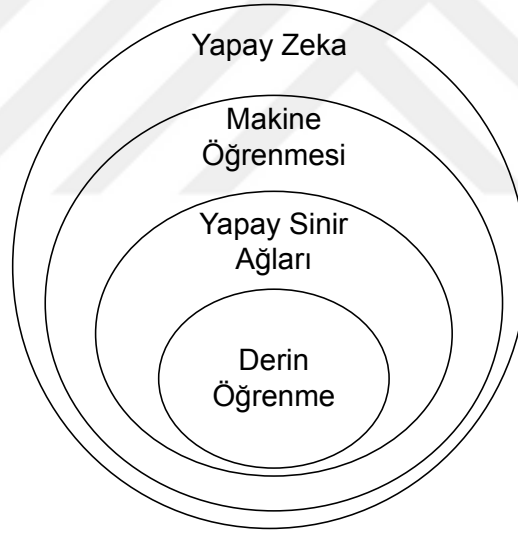
	SAĞLAM	AZ ÇÜRÜK	ÇOK ÇÜRÜK	TOPLAM
EĞİTİM	836	428	412	1676
TEST	200	100	100	400
TOPLAM	1036	528	512	2076

3.2. Yapay Zekâ ve Makine Öğrenmesi

Günümüzde popüler olan yapay zekânın başlangıcı El-Cezeri'nin (1136-1206) robot çizimlerine kadar dayandırılmaktadır (Coşkun ve Gülleroğlu, 2021). Yapay zekânın tarihçesi her ne kadar El-Cezeri'ye kadar dayansa da, bu alandaki çalışmaların önem kazanır hale gelmesi II. Dünya Savaşı sonrası gerçekleşmiştir (Coşkun ve Gülleroğlu, 2021). İkinci dünya savaşından sonra birçok araştırmacı bilimsel çalışmalar yapmıştır. Bu araştırmacıların başında Alan Turing gelmektedir. İlk defa yapay zeka hakkında konferans düzenleyen kişi Alan Turing'dir. Alan Turing yapay zekanın fikir babası sayılmaktadır lakin "yapay zekâ" terimi ilk olarak John McCarthy tarafından 1956 yılında bir çalıştayda söylenmiştir (Arslan, 2017).

Makine öğrenmesi ise, yapay zekanın bir alt alanıdır(Şekil 3.5). Makine öğrenmesi terimi ilk olarak Arthur Samuel tarafından, dama oyunu ile ilgili olarak yayınladığı ve bilgisayarın insanı yenecek şekilde programlanabileceğini açıkladığı öncü makalesinde kullanılmıştır (Samuel, 1959). Arthur Samuel, makine öğrenmesini "Bilgisayarlara onları doğrudan programlamaksızın öğrenme kabiliyeti veren çalışma alanıdır." (Samuel, 1959) şeklinde tanımlamaktadır. Bu bağlamda makine öğrenmesi, tecrübelerden veya eldeki diğer verilerden çıkarımlar yaparak kendini geliştiren bir programın nasıl yazılabileceği ile ilgilenir.

Dama konusunda uzman bir oyuncu olan Robert Nealey, 1962 yılında Arthur Samuel'in programına (Samuel, 1959) karşı oynamış ve yenilmiştir. 1960'larda bu şekilde hayatımıza giren makine öğrenmesi çalışma alanı, o yıldan bu yana sürekli gelişerek hayatımızın birçok noktasında kullanılabilir hale gelmiştir (Sammut ve Webb, 2017; Johri vd., 2020).




Şekil 3.5. Yapay zekâ ve alt dallarının küme şeklinde gösterimi

3.3. Yapay Sinir Ağları ve Derin Öğrenme

Makine öğrenmesinin bir alt alanı yapay sinir ağlarıdır. Yapay sinir ağları insan sinir hücrelerinin ağa benzeyen yapısından esinlenerek öğrenme problemlerine çözüm elde etmeyi hedefler. Yapay sinir ağlarına ilişkin ilk çalışma McCulloch ve Pitts (1943) tarafından sinir hücrelerinin ikili eşikleme cihazları olarak modellendiği çalışmadır. O tarihten bu yana yapay sinir ağları inişli çıkışlı bir gelişim süreci (Irwin, 1996) izledikten sonra; yapay sinir ağlarının bir alt alanı olarak ortaya çıkıp gelişen derin

öğrenme kavramının başarılı sonuçlar (Hinton GE, 2006; Krizhevsky vd., 2012) ortaya koymasıyla birlikte artık birçok karmaşık makine öğrenmesi probleminin çözümünde kullanılmaktadır.


McCulloch ve Pitts (1943) tarafından gerçekleştirilen öncü çalışmadan sonra Rosenblatt (1962) tarafından önerilen algılayıcı (*İng.* perceptron) yapılarının doğrusal olarak bölünebilen eğitim verileriyle sonlu sayıda iterasyonda öğrenme yeteneklerinin ortaya konulması yapay sinir ağlarından beklentiyi yükseltmiştir. Ancak bu basit algılayıcı yapısının karmaşık problemleri çözmek için yetersiz olması bu alandaki ilerlemelerin inişli çıkışlı bir trend izlemesindeki ilk duraklama dönemini oluşturmuştur.



Şekil 3.6. Tek bir algılayıcı (*İng.* perceptron)

Şekil 3.6'da tek bir algılayıcı görülmektedir. Burada $\xi_{1...n}$ girişlerdir. ξ_0 , sabit biyas olup, değeri -1 olarak alınmıştır. Giriş sinyalleri ve biyas $w_{0...n}$ ile ifade edilen ağırlıklarla çarpılarak toplanmakta; bu toplam değer ardından g ile ifade edilen aktivasyon fonksiyonuna tabi tutulmakta ve çıkış değeri elde edilmektedir. Bir denetimli öğrenme metodu olan algılayıcı öğrenme algoritması (*İng.* Perceptron learning algorithm (Gonzalez ve Woods, 2018)) ile doğrusal olarak bölünebilen eğitim verileriyle yinelemeli şekilde eğitim süreci gerçekleştirilen algılayıcının ağırlıkları sürekli olarak güncellenerek öğrenmesi sağlanır. Bu süreçte girişe uygulanan değerlere karşılık olarak algılayıcının vermesi gereken çıktı ile verdiği çıktı arasındaki hataya bağlı olarak ağırlıklar güncellenir. Eğitim için elde bulunan tüm verilerin tamamının bir kere girişe uygulanarak ağırlıkların güncellenmesine bir iterasyon (*İng.* epoch) adı verilmektedir.

Yukarıda anlatılan algılayıcı kavramı insan nöron hücresinin çalışmasına benzer şekilde kurgulanmıştır. Bir insan nöron hücresinde dendrit, akson ve sinaps olmak üzere üç ana bölüm vardır. Bir nörona gelen sinyal dendritten alınır aksonlar yardımıyla sinaps keseciklerinden iletilir. Dendritten alınan sinyaller bir dizi kimyasal süreçten geçerek aksonlar aracılığıyla iletilir aksonlardan gelen sinyal ise diğer nöronlara dağıtılmak üzere sinaps keseciklerine gider. Bu sinyal sinaps keseciklerinde yine bir kimyasal süreç geçirerek diğer nörona iletilir.




Şekil 3.7. Tek katmanlı algılayıcı (İng. perceptron) ağı

Algılayıcılar her zaman tek çıkış sahip olmak zorunda değildir. Şekil 3.7’de m sayıda çıkışı olan bir tek katmanlı algılayıcı ağı verilmiştir. Burada tüm girişler tüm çıkışlara ağırlıklı şekilde bağlıdır. Tüm çıkışlara değeri -1 olan sabit biyas uygulanmıştır. Burada gradyan azalma tabanlı olarak gerçekleştirilen delta kuralı (Rumelhart ve McClelland, 1987) ile denetimli öğrenme gerçekleştirilmektedir.

Şekil 3.7’de verilen tek katmanlı algılayıcı ağının öğrenme yetenekleri sınırlıdır. Karmaşık problemleri bu ağa öğretmek mümkün değildir. Bunu mümkün kılabilmek için giriş ile çıkış arasına gizli katman olarak adlandırılan katmanlardan yerleştirmek gerekir. Bu şekilde oluşturulmuş tek gizli katmana sahip olan iki katmanlı bir algılayıcı ağı Şekil 3.8’de verilmiştir. Bu ağın eğitilmesi için geri yayılma (İng. backpropagation) (Gonzalez ve Woods, 2018) algoritması kullanılmaktadır. Bu

algoritma öğrenme aşamasında belli bir girdiye karşılık olarak hesaplanan hataya bağlı olarak, çıkıştan girişe doğru tüm ağırlıkların hatayı azaltacak şekilde güncellenmesini sağlar.



Şekil 3.8. İki katmanlı algılayıcı (İng. perceptron) ağı

Çok katmanlı algılayıcı ağları ile karmaşık problemlerin öğrenilmesi mümkündür. Burada gizli katman sayısının artması öğrenmeyi olumlu etkileme potansiyeline sahip olmakla birlikte, çok aşırı sayılara arttırılması her zaman daha iyi öğrenmeyle sonuçlanmaz. Gizli katman sayısının artması aynı zamanda öğrenme sürecinin çok uzamasına neden olacaktır. Bir diğer problem de geri yayılma algoritmasıyla girişe çok yakın katmanlara doğru hatanın yayılması ciddi bir problem haline gelecektir.

Çok katmanlı algılayıcılardaki katman sayısının fazlaca olması bir nevi ağın derin bir yapıda olmasına yol açtığından dolayı bu durum derin öğrenme teriminin oluşmasında etkisi olan önemli bir faktördür.

Çok katmanlı algılayıcıları görüntü gibi iki boyutlu ve piksel komşuluklarının önemli olduğu tipte verilerle eğitmek gerektiği zaman mecburen görüntüdeki piksel verilerinin tek boyutlu bir dizi haline getirilerek ağı uygulanması gerekmektedir. Bu durumda piksellerin yakın komşuluklarındaki piksellerle birlikte oluşturdukları örüntülerin öğrenilmesinde zorluklar yaşanabilecektir. Bu problemin aşılması amacıyla evrimsel sinir ağları (İng. Convolutional Neural Networks, CNN) (LeCun vd., 1989) metodu

önemli bir katkı sağlamıştır. İlk ortaya çıkışından bu yana bu yöntem, bir çok karmaşık bilgisayarla görme probleminde yüksek başarılı sonuçlar alınmasına olanak sağlamıştır. Bu nedenle bu tez çalışmasında derin öğrenme yöntemlerinden birisi olan CNN kullanılarak elma görüntülerinin sınıflandırılması problemi çözülmeye çalışılmıştır.

3.4. Evrimsel Sinir Ağları


- Bu bölümde CNN kavramı LeNet (Lecun vd., 1998; Gonzalez ve Woods, 2018) mimarisine dayalı olarak anlatılacaktır. Şekil 3.9’te LeNet mimarisine sahip bir CNN görülmektedir. Burada girdi görüntü üzerinde öncelikle belli bir boyuta sahip bir filtre çekirdeği ile katlama (*İng.* convolution) işlemi gerçekleştirilir. Normalde katlama işleminde önce filtre 180 derece döndürülmektedir. Ancak CNN’lerle ilgili olarak burada katlama işlemi korelasyon şeklinde yani herhangi bir döndürme işlemi yapılmadan gerçekleştirilir. Bu işlemde filtre görüntü üzerinde gezdirilirken herhangi bir bölge üzerinde iken; filtre katsayıları ile görüntüdeki ilgili alandaki üst üste gelen piksel değerleri çarpılarak toplanır. Bu işlem, Çizelge 3.3’te verilen örnek görüntüye, Çizelge 3.4’te verilen filtre uygulandığında, Çizelge 3.5’te verilen görüntünün elde edilmesini sağlamaktadır. Bu değere *biyas* değeri eklenir ve ardından *aktivasyon* fonksiyonu uygulanır. Aktivasyon fonksiyonu çıktı olarak elde edilen değer bir sonraki katman için artık bir girdi haline gelir. Farklı katsayılara sahip filtre çekirdekleriyle elde edilen bu çıktılar *öznitelik haritalarını* oluşturur. Filtre çekirdeğinin görüntü üzerinde her defasında kaç piksel hareket ettirildiği *adım* değeri ile belirlenir.

Derin öğrenme yaklaşımında birden çok aktivasyon fonksiyonu kullanılmaktadır.

Yaygın olarak kullanılan bazı aktivasyon fonksiyonları şunlardır:

- Step Fonksiyonu
- Sigmoid Fonksiyonu
- Tanh Fonksiyonu
- ReLU Fonksiyonu
- Softmax Fonksiyonu
- ELU Fonksiyonu

- PReLU Fonksiyonu
- Swish Fonksiyonu



Şekil 3.9. LeNet CNN modeli grafiksel gösterimi.

Çizelge 3.3. Örnek görüntü

a	b	c	d
e	f	g	h
j	k	l	i
m	n	r	o

Çizelge 3.4. Uygulanacak filtre

q	w
z	s

Çizelge 3.5. Filtre uygulandıında elde edilen çıktı görüntü

$a*q+b*w+e*z+f*s$	$b*q+c*w+f*z+s*g$	$c*q+d*w+g*z+s*h$
$e*q+f*w+j*z+k*s$	$f*q+g*w+k*z+l*s$	$g*q+h*w+l*z+i*s$
$j*q+k*w+m*z+n*s$	$k*q+l*w+n*z+r*s$	$l*q+i*w+r*z+o*s$

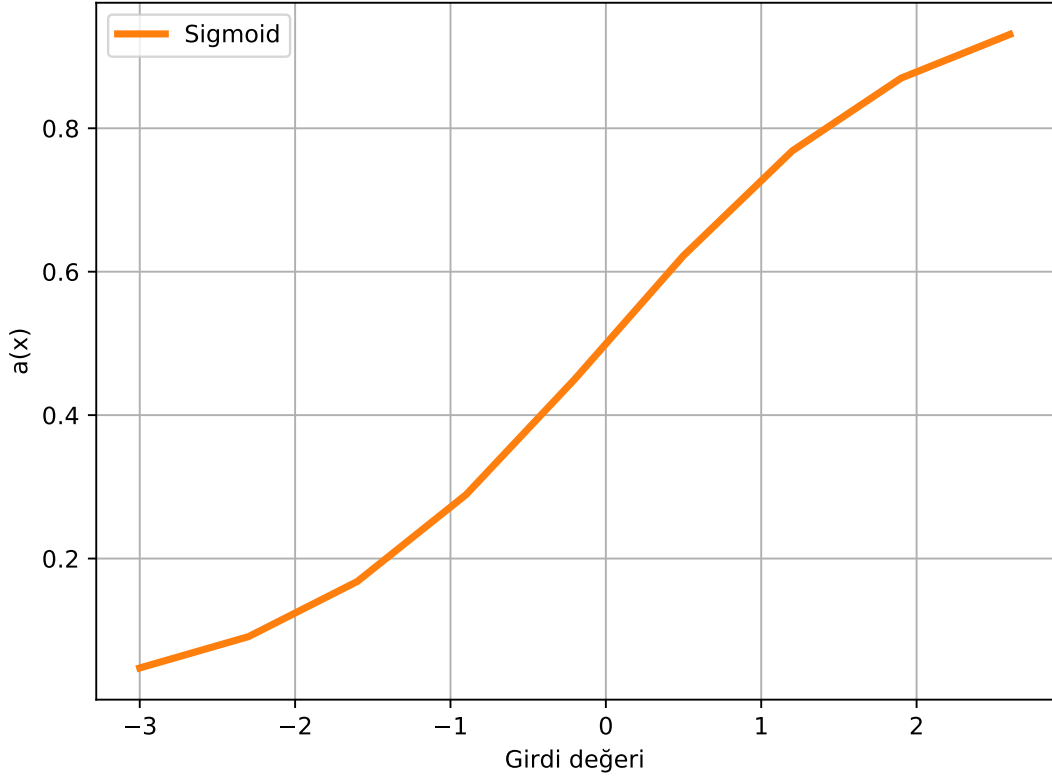
Yaygın olarak kullanılan aktivasyon fonksiyonları arasından bu çalışmada ReLU, Sigmoid, Softmax aktivasyon fonksiyonları kullanılmıştır.

Sigmoid fonksiyonu derin öğrenme yaklaşımlarında çokça rastlanılan bir fonksiyon olup 0 ve 1 aralığında değerler üretmektedir (Şekil 3.10). Bu fonksiyon adını uzayda çizilen grafiğinin aldığı S (sigma) şeklinden almıştır.

$$s(x) = \frac{1}{1 + e^{-\alpha x}} \quad (3.1)$$

Denklem 3.1'de α değeri sayesinde fonksiyon üzerinde denetlemeler yaparak daha esnek çözümler sağlanabilmektedir. Bu esnek çözümler sayesinde nöronların sinyalleri daha belirgin düzeylere ulaşabilmektedir.

ReLU fonksiyonu doğrultulmuş lineer birimler olarak adlandırılmaktadır. Şekil 3.11'de verilen ReLU fonksiyonu, 0 ile $+\infty$ aralığında sabit türevlenebilen sonuçlar üretmektedir. Sabit türevlenen değerler sayesinde algoritma daha hızlı çalışarak daha hızlı sonuçlar vermektedir.



Şekil 3.10. Sigmoid fonksiyon grafiği

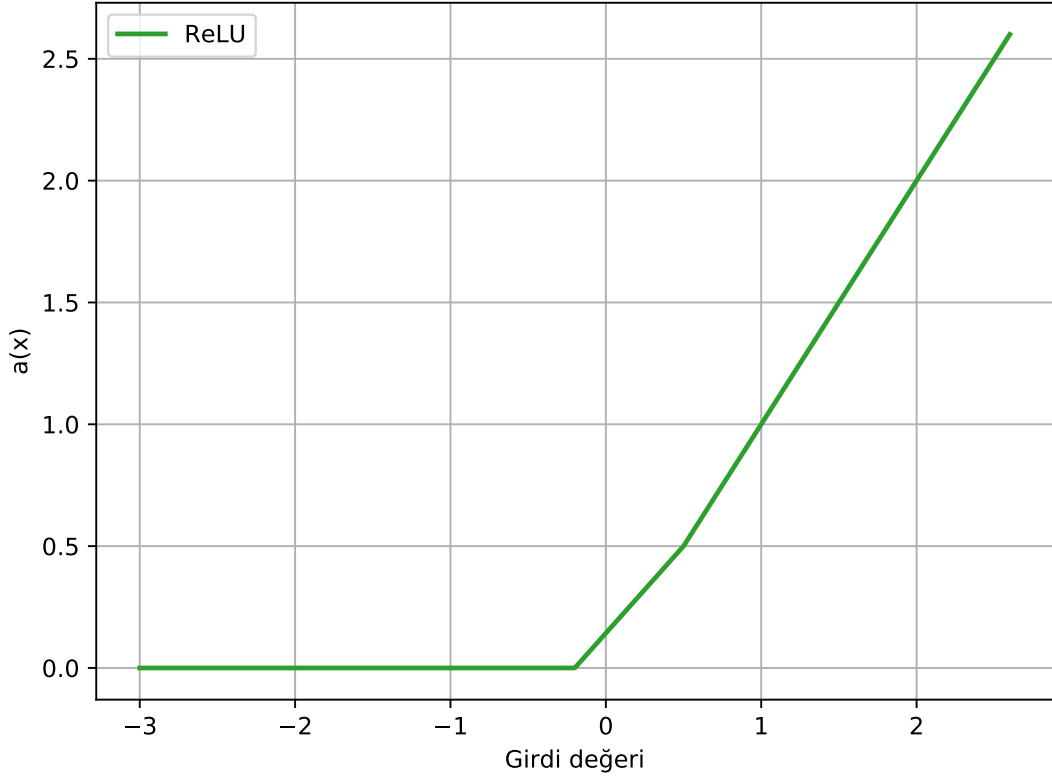
ReLU fonksiyonuna giren değer eğer 0'dan küçükse sonuç 0; eğer giren değer 0 ve 0'dan büyükse sonuç giren değere eşit olmaktadır. Bu da küçük değerlerin çıkarılmasını sağlayarak algoritmaya kolaylık sağlamaktadır.

Softmax fonksiyonu ve sigmoid fonksiyonu sınıflandırma problemlerinde oldukça sık kullanılmaktadır. Softmax fonksiyonu da aynı sigmoid fonksiyonu gibi [0,1] aralığında değerler üretmektedir. Bu fonksiyonun sigmoid'den farkı değerler çıkarken normalizasyon işlemi yapılıyor olmasıdır. Bu iki fonksiyonun bir diğer farkı ise sigmoid'in ikili sınıflandırmalarda kullanılmasının daha elverişli olması ve softmax'ın çoklu sınıflandırmalarda kullanımının daha elverişli olmasıdır.

$$\sigma(x_i) = \frac{e^{x_i}}{\sum_{j=1}^k e^{x_j}} \quad (3.2)$$

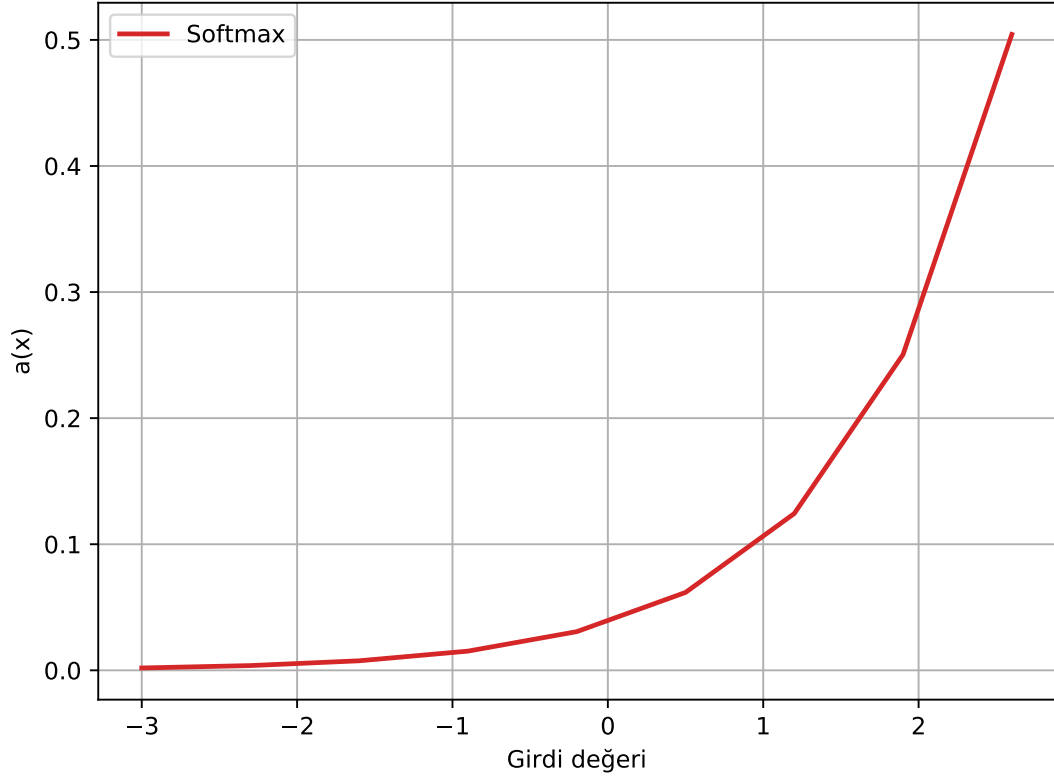
Denklem 3.2'te k , çoklu sınıflayıcıdaki sınıf sayısını ifade etmektedir.

Şekil 3.13'te sık kullanılan aktivasyon fonksiyonlarının grafikleri hep birlikte verilmiştir.



Şekil 3.11. ReLU fonksiyonu grafiği

- Ardından *alt-örnekleme* veya *havuzlama* olarak adlandırılan işlem gelmektedir. Burada amaç hem insan görsel algılama sistemindekine benzer bir işlem gerçekleştirmek hem de üzerinde çalışılan veriyi azaltmaktır. Burada görüntü üzerinde yine belli bir alana bakacak şekilde gezinilir. Görüntü üzerinde bakılan bu bölgedeki tüm piksellerin karşılığı bir piksel değeri belirlenir ve havuzlanmış öznitelik haritaları elde edilir. Burada piksel değerinin belirlenmesi için farklı yöntemler kullanılabilir. *Ortalama havuzlama* yönteminde belli bir alandaki komşu piksellerin değerlerinin ortalaması kullanılır. *Maksimum havuzlama* yönteminde komşu piksellerin değerlerinin en büyük olanı kullanılır. L_2 havuzlama yönteminde ise komşu piksellerin değerlerinin karelerinin toplamının karekökü kullanılır. Bu çalışma kapsamında maksimum havuzlama yöntemi kullanılmıştır.
- Katlama, biyas ve aktivasyon işlemlerinin uygulandığı işlem dizisi ve havuzlama işlemleri modelin yapısına göre farklı sayıda ve konfigürasyonda yer alabilir. Şekil 3.9'da ilk havuzlama işleminden sonra tekrar katlama, biyas ve aktivasyon işlemleri ve ardından yine bir havuzlama işlemi gerçekleştirilmiştir.



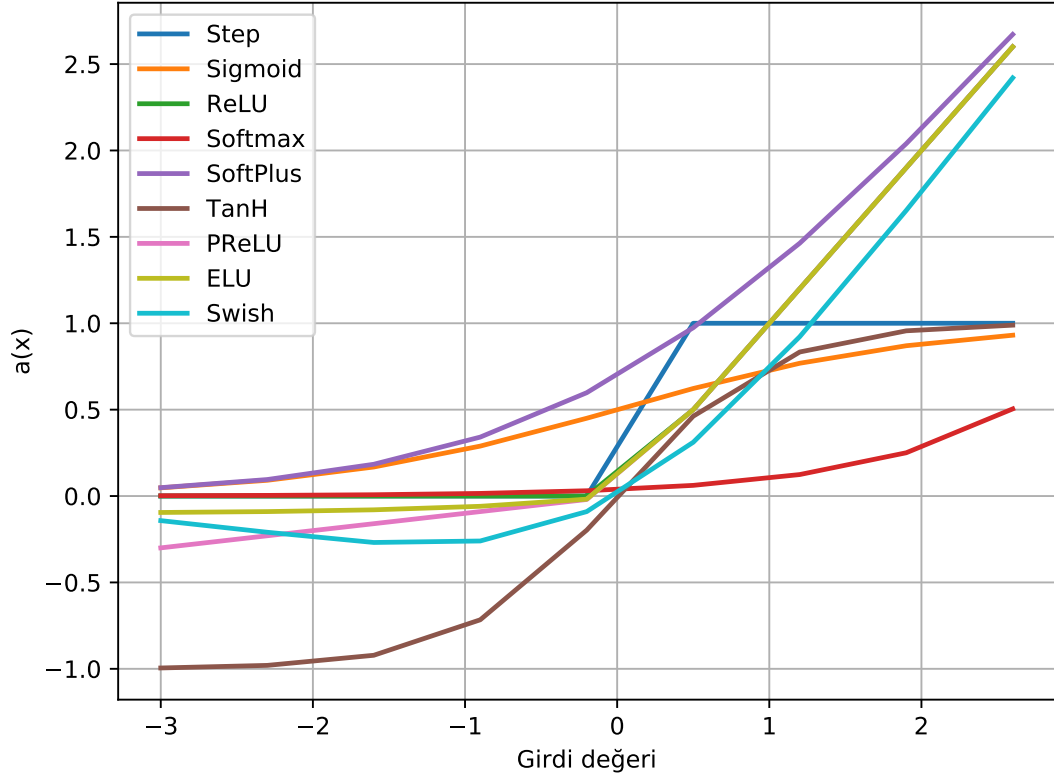
Şekil 3.12. Softmax fonksiyonu grafiği

- *Düzleştirme* işleminde iki boyutlu öznitelik haritalarının değerlerinin bir dizi halinde tek boyutlu veriye dönüştürülmesi (Şekil 3.14) ve bu değerlerin çıktı değerini oluşturmak üzere çok katmanlı sinir ağına yönlendirilmesi sağlanır.

3.5. Önerilen CNN modelleri ve Li Modeli

Tez kapsamında oluşturulan iki farklı sınıflandırma probleminin çözümü için sadece son katmanlarında farklılık bulunan iki CNN modelinin kullanımı önerilmiştir. Bu modellerin detaylı yapıları, ikili sınıflandırma için Şekil 3.15'te ve üçlü sınıflandırma için Şekil 3.16'da görselleştirilmiştir.

Önerilen modellerin literatürde bulunan bir modelle kıyaslanabilmesi için Li vd. (2021) tarafından önerilen ve Li modeli olarak adlandırdığımız model bu amaçla kullanılmıştır. Bu model üçlü sınıflandırma için önerilmiş olup, bu tez kapsamında yapılan kıyaslamada son katmanında değişiklik yapılarak ikili sınıflandırma için de uygun hale getirilerek kullanılmıştır. Ayrıca Li modelinin sonran ikinci havuzlama katmanı için 2 adımlık atlamalar belirtilmiş olsa da,




Şekil 3.13. Bütün aktivasyon fonksiyonlarının grafikleri

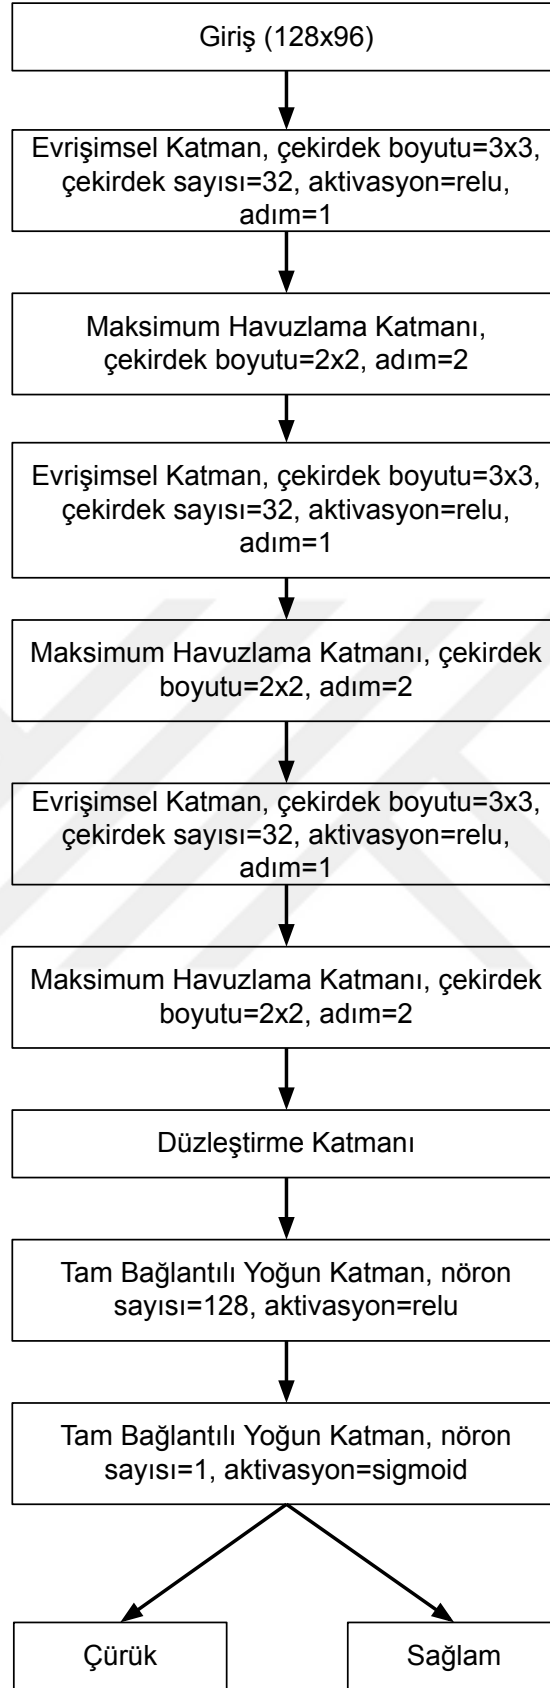
bu haliyle ilgili model kodunun çalışmasında sorun yaşandığı için bu değer 1 alınarak deneyler gerçekleştirilmiştir.

Li modellerinin detaylı yapıları, ikili sınıflandırma için Şekil 3.17’de ve üçlü sınıflandırma için Şekil 3.18’de görselleştirilmiştir.

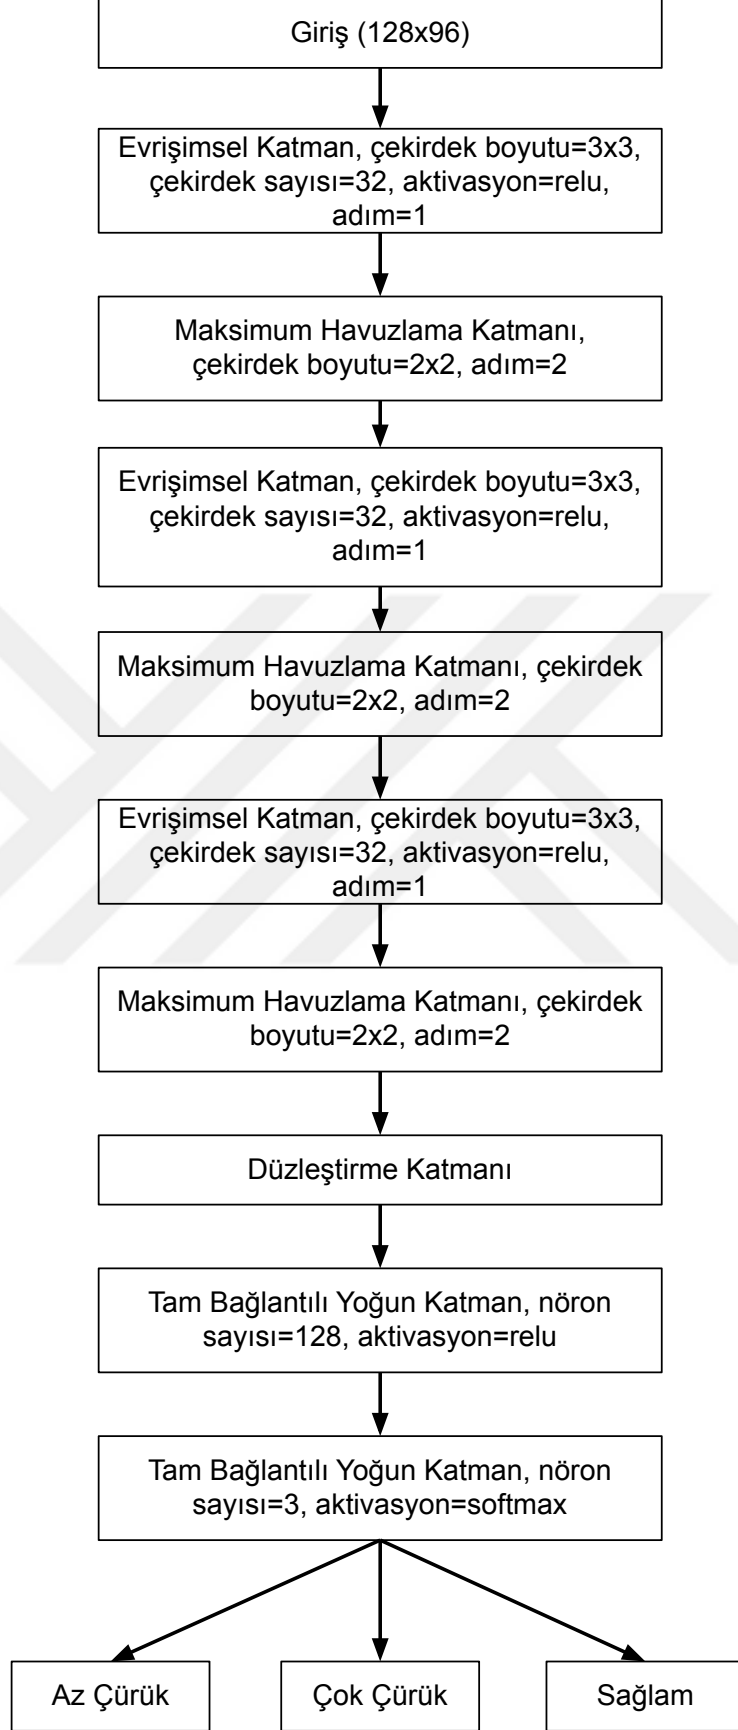
Hem tezde önerilen modellerde hem de Li modellerinde optimizasyon yöntemi olarak Adam optimizasyonu (Kingma ve Ba, 2017) yöntemi kullanılmıştır.



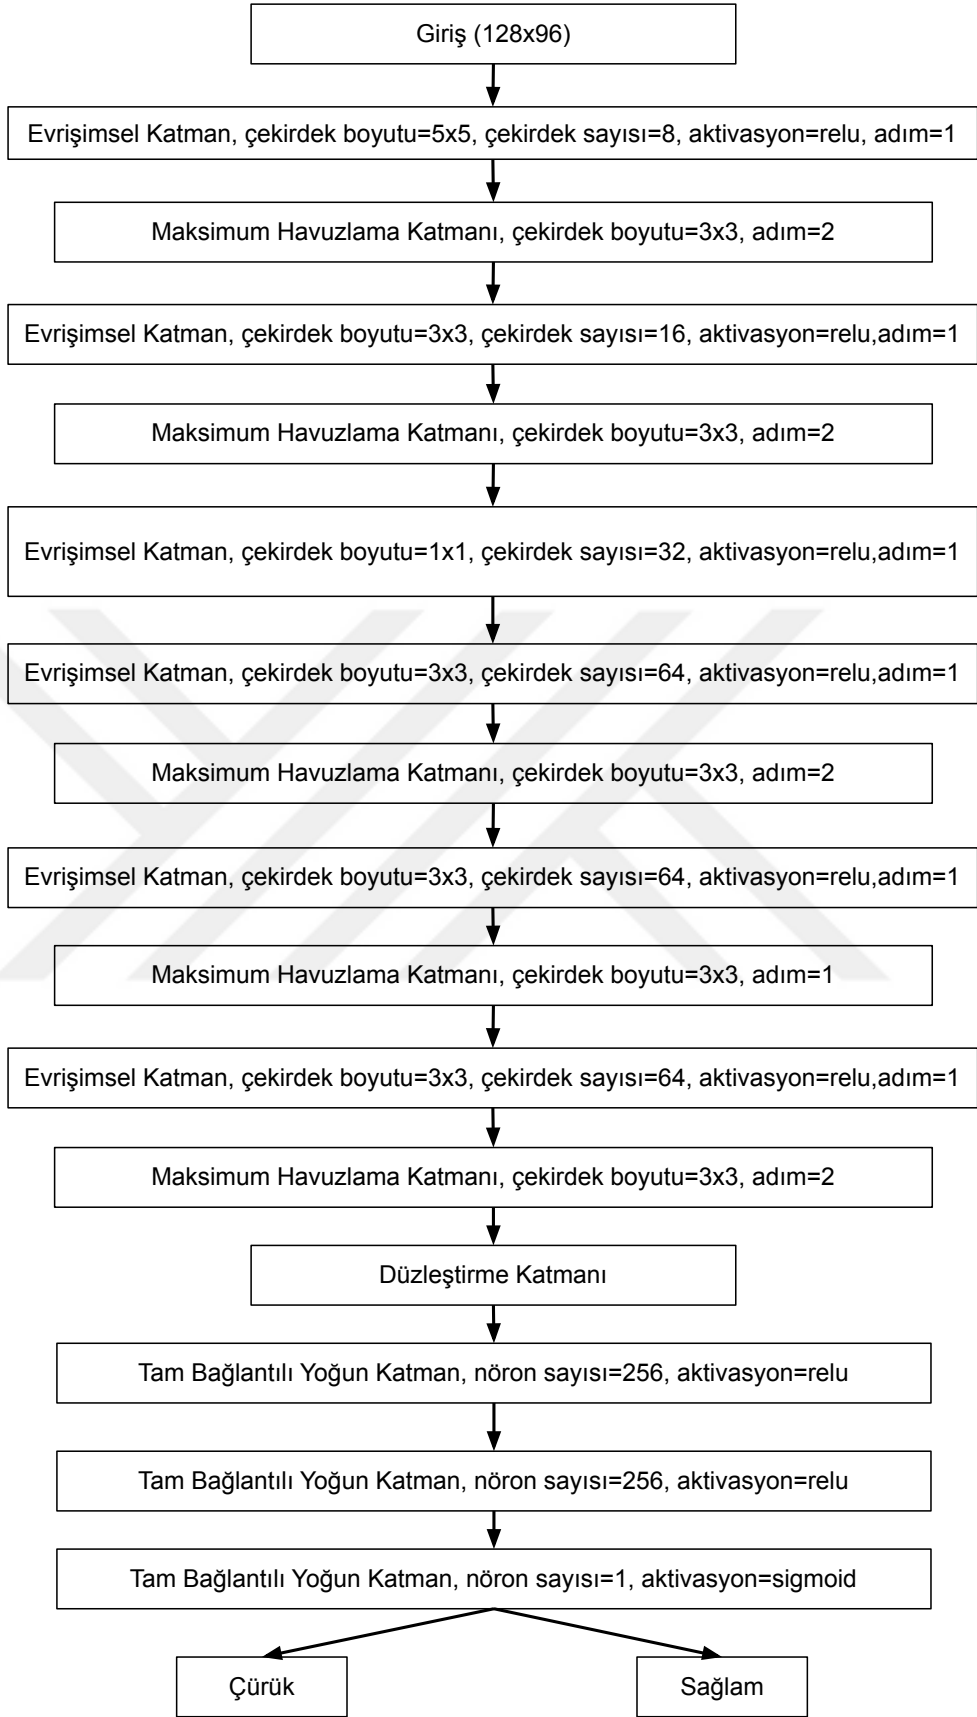
Şekil 3.14. Düzleştirme işlemi ile çok boyutlu verinin tek boyutlu veriye dönüştürülmesi işlemi



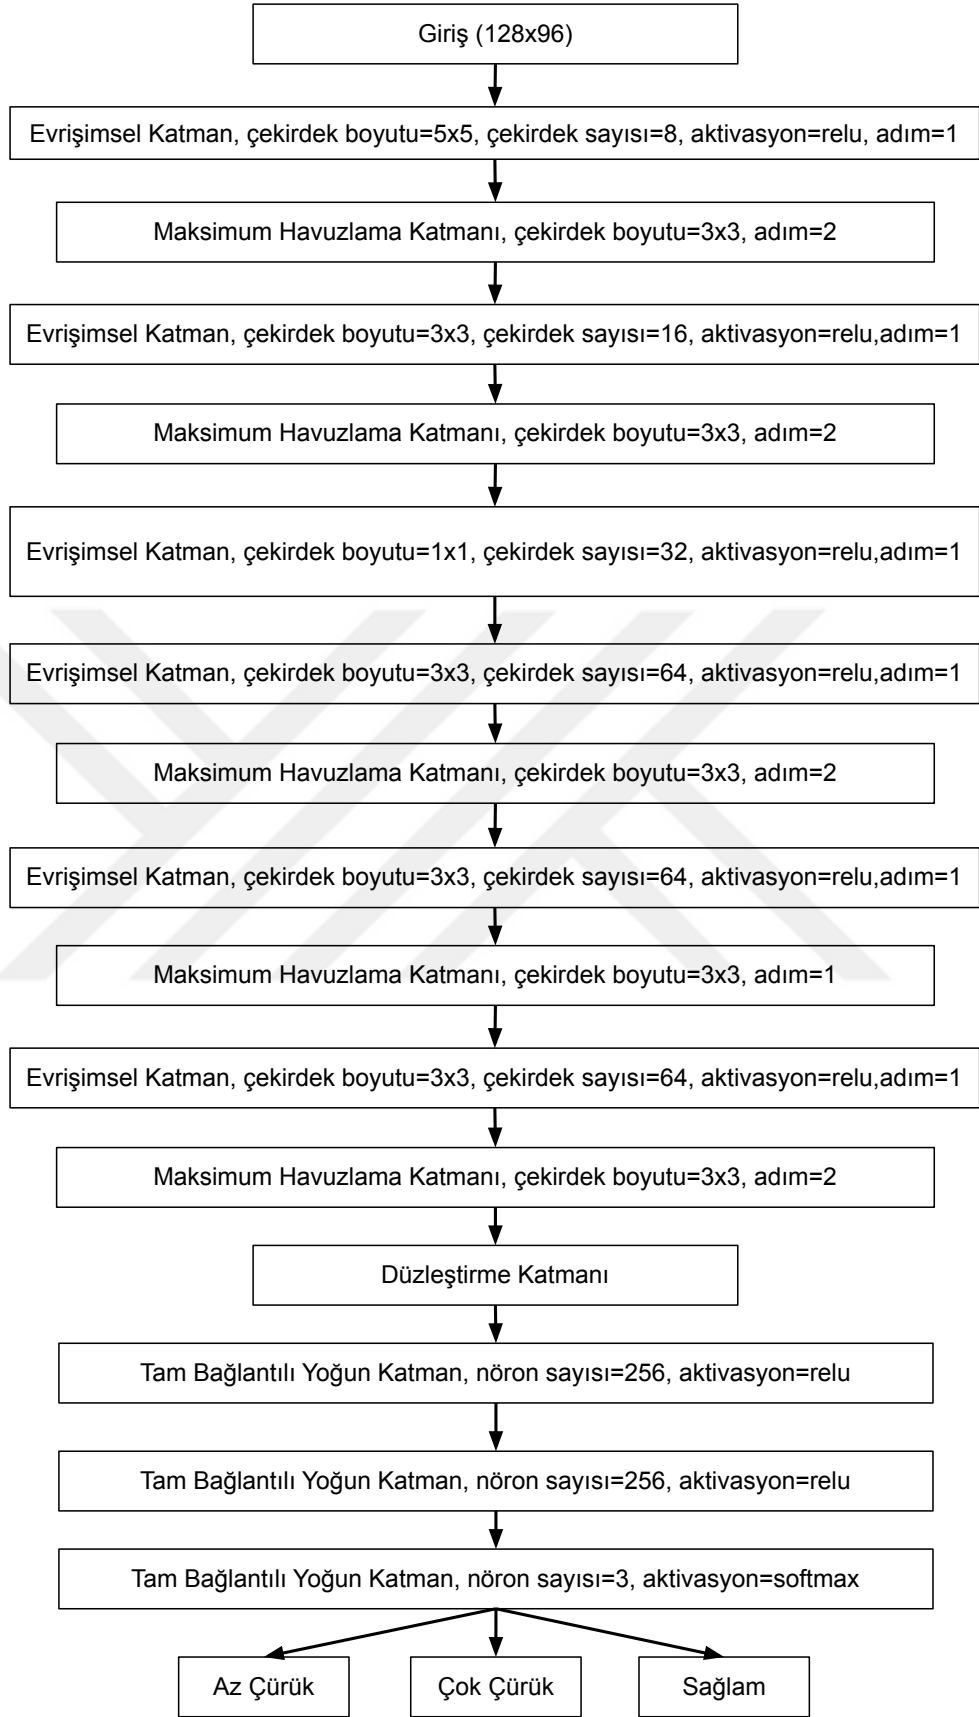
Şekil 3.15. Tez kapsamında ikili sınıflandırma problemi için önerilen CNN modelinin grafiksel gösterimi



Şekil 3.16. Tez kapsamında üçlü sınıflandırma problemi için önerilen CNN modelinin grafiksel gösterimi



Şekil 3.17. İkili sınıflandırma problemi için uyarlanan Li modelinin grafiksel gösterimi.



Şekil 3.18. Üçlü sınıflandırma problemi için uyarlanan Li modelinin grafiksel gösterimi.


4. ARAŞTIRMA BULGULARI

Bu bölümde önerilen modellerin ve Li modelinin iki varyasyonu çalışma kapsamında oluşturulan veriseti kullanılarak kıyaslamasına ilişkin deneysel sonuçlar aktarılacaktır.


4.1. Araştırma Bulguları

Önerilen modeller ve Li modelinin varyasyonları Python dilinde, Keras (Chollet vd., 2015) kütüphanesi kullanılarak gerçekleştirilmiştir. Modeller Bölüm 3.1’de detayları aktarılan verisetiyle Çizelge 3.1 ve 3.2’de belirtilen sayılarda görüntü ile eğitim ve testleri gerçekleştirilmiştir.

Öncelikle ikili sınıflandırma probleminde düşük sayıda iterasyonla eğitim sonucunda modellerin başarımları değerlendirilmiştir. Bu amaçla 15 iterasyon ile deneyler gerçekleştirilmiş olup; bunlara ilişkin sonuçlar tez modeli ve Li modeli için sırasıyla Şekil 4.1 ve 4.2’de verilmiştir. İki model kıyaslandığında tez kapsamında önerilen modelin çok az bir farkla daha iyi başarımlar sağladığı görülmektedir. Kayıp değerlerine bakıldığında da modellerin birbirine yakın performans sergiledikleri görülmektedir.




Şekil 4.1. Tez kapsamında önerilen modelin ikili sınıflandırma probleminde 15 iterasyon başarımları ve kayıpları




Şekil 4.2. Li modelinin ikili sınıflandırma probleminde 15 iterasyon başarımları ve kayıpları

İkili sınıflandırma probleminde yapılan 15 iterasyon deneyi, üçlü sınıflandırma için de gerçekleştirilmiştir. Bu deneye ilişkin sonuçlar tez modeli ve Li modeli için sırasıyla Şekil 4.3 ve 4.4'de verilmiştir. Tez kapsamında önerilen model daha az iterasyon sayısında daha yüksek başarımlara ulaşmış ve ayrıca genel olarak sonuç grafikleri değerlendirildiğinde Li modeline göre biraz daha iyi başarımlara sahip olduğu söylenebilir. Kayıp değerlerine bakıldığında da ise Li modelinin biraz daha kötü performans sergilediği görülmektedir.

İkili sınıflandırma problemindeki modellerin sonuçlarıyla üçlü sınıflandırma problemindeki sonuçları karşılaştırıldığında, üçlü sınıflandırmada her iki model de daha kötü performans sergilemiştir. Bunun temel nedeni üçlü sınıflandırma probleminin doğası gereği daha zor olmasıdır.




Şekil 4.3. Tez kapsamında önerilen modelin üçlü sınıflandırma probleminde 15 iterasyon başarımları ve kayıp grafikleri




Şekil 4.4. Li modelinin üçlü sınıflandırma probleminde 15 iterasyon başarımları ve kayıp grafikleri

Bir sonraki deneyde iterasyon sayısı 30'a çıkarılarak üçlü sınıflandırma probleminde modellerin başarımları kıyaslanmıştır. Bu deneye ilişkin sonuçlar tez modeli ve Li modeli için sırasıyla Şekil 4.5 ve 4.6'de verilmiştir. Bu deneyde tez modeli eğitim başarımları olarak daha yüksek değerlere ulaşsa da, Li modeli test başarımlarıyla biraz daha

önde görülmektedir. Kayıp değerlerine bakıldığında da yine tez modeli eğitimde iyi performans gösterse de Li modelinin testlerde daha iyi sonuç verdiği görülmektedir.




Şekil 4.5. Tez kapsamında önerilen modelin üçlü sınıflandırma probleminde 30 iterasyon başarımları ve kayıp grafikleri




Şekil 4.6. Li modelinin üçlü sınıflandırma probleminde 30 iterasyon başarımları ve kayıp grafikleri

İterasyon sayısının daha fazla artırılması durumunda tez modelinin nasıl sonuç vereceğini değerlendirmek için, ikili ve üçlü sınıflandırma problemlerinde 100 iterasyon için deneyler gerçekleştirilmiştir. Bu deneye ilişkin sonuçlar sırasıyla ikili ve üçlü sınıflandırma problemi için Şekil 4.8 ve 4.7 ve y de verilmiştir. Modelin uzun bir eğitim sürecinde performansına baktığımız zaman ikili sınıflandırmada yüksek başarımlar değerlerine hem eğitim hem de test için erişildiği görülmektedir. Ancak kayıp değerlerinin test performansı kötü bir trend izlemektedir. Üçlü sınıflandırmada hem eğitimde ikili sınıflandırma kadar yüksek değerlere ulaşamadık; hem de eğitim ile test arası fark artmıştır. Kayıp grafiğinde test performansı değerlerin yükselmesi yönünde kötü bir trend izlemektedir. Üçlü sınıflandırmada kategorik çapraz entropi kullanıldığından dolayı değerler 1.0'ın üzerine çıkabilmektedir. Bu durum ikili çapraz entropi kullanılan ikili sınıflandırma için geçerli değildir.



Şekil 4.7. Tez kapsamında önerilen modelin ikili sınıflandırma probleminde 100 iterasyon başarımları ve kayıpları



Şekil 4.8. Tez kapsamında önerilen modelin üçlü sınıflandırma probleminde 100 iterasyon başarımları ve kayıpları


4.1.1. Sınıf Aktivasyon Haritalama (CAM)

Sınıf aktivasyon haritalama yöntemi (Zhou vd., 2016) ısı haritaları oluşturarak odaklanılan alanların önem seviyesine göre renk dağılımları yapılmasını sağlamaktadır. Bu yöntem matematiksel olarak ağırlıklı giriş değerlerinin bir araya toplanarak ortak aktivasyon haritaları oluşturulmasını sağlamakta ve bu harita değerlerinden yola çıkarak ısı haritası oluşturmaktadır (Betül Ersöz, 2022).

Modelin açıklanabilirliğini görebilmek için model üzerinde sınıf aktivasyon haritalama yöntemi kullanılarak sağlam ve çürük elmalar görüntü üzerinde ayırt edilirken hangi bölgelerin daha kritik olduğu gözlemlenmiştir. Bunun için Şekil 4.9’da verilen görüntülere CAM yöntemi uygulanarak Şekil 4.10’da verilen sonuçlar elde edilmiştir. Bu görüntülerde çürük olan bölgelerin değerlerinin modelin karar vermesinde oldukça etkili olduğu; ancak arkaplanda yer alan bölgelerin de kararda etkili olabildiği gözlemlenmektedir.



Şekil 4.9. CAM uygulanacak görüntüler



Şekil 4.10. CAM uygulanmış görüntüler

5. TARTIŞMA VE SONUÇLAR

Bu tezde elma görüntülerinin sınıflandırılması problemi üzerinde çalışılmıştır. Elmaların sağlıklı olup olmadıklarını anlayabilmek için bilgisayarlı görme alanında birçok problemde yüksek başarımlı sonuçlar veren derin öğrenme yaklaşımlarından biri olan CNN temelli bir çözüm üzerinde çalışılmıştır.

Literatürdeki verisetlerinin yetersizliği ve erişimde yaşanan olumsuzluklar nedeniyle, tez kapsamında orijinal bir veri seti hazırlanarak kullanılmıştır. Bu veri seti 5 farklı türde elmayı içermesi, içerdiği toplam görüntü sayısı açısından literatürdeki birçok verisetinden daha büyük olması, görüntülerde elmaların sap ve çanak kısımlarının da bulunuyor olması gibi nedenlerle literatür açısından önemlidir.

CNN tabanlı olarak geliştirilen iki ve üç farklı sınıfta görüntüleri sınıflandırabilecek modeller tez kapsamında oluşturulan verisetinin öğrenmeye ayrılan kısmı ile eğitilerek, test için ayrılan kısmıyla test edilmiştir. Bu modeller literatürde bildiğimiz kadarıyla en güncel ve güçlü modellerden biriyle kıyaslanmıştır. Modellerin başarımlı güncel modele oldukça yakın çıkmıştır.

Geliştirilen modeller sadece elma verisiyle sınırlı kalmayıp diğer meyve ve sebzeler üzerinde de denenerek sonuçları ve başarımlı oranları incelenebilir. Bu nedenle bu tez çalışmasının başta gıda sanayisi olmak üzere birçok sektörde sağlam ve çürük meyve/sebze ayırımında yararlı olma potansiyeli bulunmaktadır.

Tez kapsamında oluşturulan veriseti bu alanda çalışma yürütecek araştırmacılar için faydalı olacaktır. Verisetinin zenginliği derin öğrenme yöntemleri için kritiktir. Verisetlerinin hazırlanması oldukça fazla zaman ve emek gerektirmektedir. Bu çalışma kapsamında oluşturulan veriseti önemli sayılabilecek miktarda veri içermekte olup; sonraki araştırmacıların katkılarıyla daha da zenginleştirilerek kullanımının devamı potansiyeli öngörülmektedir.

KAYNAKLAR

- Ahmed, S.F., Alam, M.S.B., Hassan, M., Rozbu, M.R., Ishtiak, T., Raza, N., Mofijur, M., Shawkat Ali, A.B.M., Gandomi, A.H., 2023. Deep learning modelling techniques: current progress, applications, advantages, and challenges. *Artificial Intelligence Review*.
- Arslan, K., 2017. Eğitimde Yapay Zeka ve Uygulamaları. *Eğitim Bilimleri Dergisi*, 11, 71–88.
- Aweta, 2020. AWETA | Apple sorting & grading line. <https://www.youtube.com/watch?v=7k9vIwh1QDc>. Erişildi: 2023-09-18.
- Balkır, P., Kemahlioğlu, K., Yücel, U., 2019. Machine Vision System: Food Industry Applications and Practices. *Turkish Journal of Agriculture - Food Science and Technology*, 7(7), 989–999.
- Betül Ersöz, H.I.B., 2022. Yorumlanabilir ve Açıklanabilir Yapay Zekâ ve Güncel Konular (Eğitimde Yapay Zekâ Sanal Gerçeklik Ve Sanal Evren (Metaverse)). Nobel Yayınevi.
- Chandaliya, R.A., 2020. Tele Stroke System for Stroke Detection.
- Chen, W., Li, Y., Tian, Z., Zhang, F., 2023. 2D and 3D object detection algorithms from images: A Survey. *Array*, 19, 100305.
- Chollet, F., vd., 2015. Keras.
- Coşkun, F., Gülleroğlu, H.D., 2021. Yapay Zekanın Tarih İçindeki Gelişimi ve Eğitimde Kullanılması.
- Cömert, O., Hekim, M., Adem, K., 2019. Faster R-CNN Kullanarak Elmalarda Çürük Tespiti.
- Dubey, S.R., Jalal, A.S., 2016. Apple disease classification using color, texture and shape features from images. *Signal, Image and Video Processing*, 10.1007/s11760-015-0821-1.
- Gavali, P., Banu, J.S., 2019. Chapter 6 - Deep Convolutional Neural Network for Image Classification on CUDA Platform. A.K. Sangaiah (Ed.), *Deep Learning and Parallel Computing Environment for Bioengineering Systems*, Academic Press. (pp. 99–122).
- Gonzalez, R., Woods, R., 2018. *Digital Image Processing, Global Edition*. Pearson Education.
- Goodfellow, I., Bengio, Y., Courville, A., 2016. *Deep Learning*. MIT Press. <http://www.deeplearningbook.org>.

- Greefa, 2014. GREEFA - Columbia Reach Pack - GeoSort 10 lane sorting and packing line for apples in the USA. <https://www.youtube.com/watch?v=K728e8A7V1o>. Erişildi: 2023-09-18.
- GreenSort, 2019. Apple sorting machine Green Sort Vision- work and production. <https://www.youtube.com/watch?v=WKBTacqiui0>. Erişildi: 2023-09-18.
- Guo, Y., Liu, Y., Oerlemans, A., Lao, S., Wu, S., Lew, M.S., 2016. Deep learning for visual understanding: A review. *Neurocomputing*, 187, 27–48. Recent Developments on Deep Big Vision.
- Hinton GE, Osindero S, T.Y., 2006. A fast learning algorithm for deep belief nets. *Neural Comput.*
- Irwin, W., 1996. A review of “Neural Network Applications in Control” IEE Control Engineering Series 53 G. W. Irwin, K. Warwick & K. J. Hunt, 1995 Stevenage, Institution of Electrical Engineers ISBN 0 85296 852 3 £45.00. *European Journal of Engineering Education*, 21(2), 216–216.
- Jiang, P., Ergu, D., Liu, F., Cai, Y., Ma, B., 2022. A Review of Yolo Algorithm Developments. *Procedia Computer Science*, 199, 1066–1073. The 8th International Conference on Information Technology and Quantitative Management (ITQM 2020 & 2021): Developing Global Digital Economy after COVID-19.
- Johri, P., Verma, J.K., Paul, S., 2020. *Applications of Machine Learning*. Springer Singapore, Singapore.
- Kaur, R., Singh, S., 2023. A comprehensive review of object detection with deep learning. *Digital Signal Processing*, 132, 103812.
- Kayaalp, K., Metlek, S., 2020. Classification of Robust and Rotten Apples by Deep Learning Algorithm. *Sakarya University Journal of Computer and Information Sciences*, 3, 111–119.
- Kingma, D.P., Ba, J., 2017. Adam: A Method for Stochastic Optimization.
- Kleynen, O., Leemans, V., Destain, M.F., 2005. Development of a multi-spectral vision system for the detection of defects on apples. *Journal of Food Engineering*, 69(1), 41–49.
- Krizhevsky, A., Sutskever, I., Hinton, G.E., 2012. ImageNet Classification with Deep Convolutional Neural Networks. F. Pereira, C. Burges, L. Bottou, K. Weinberger (Eds.), *Advances in Neural Information Processing Systems*. Curran Associates, Inc., Volume 25.
- LeCun, Y., Boser, B., Denker, J., Henderson, D., Howard, R., Hubbard, W., Jackel, L., 1989. Handwritten Digit Recognition with a Back-Propagation Network. D. Touretzky (Ed.), *Advances in Neural Information Processing Systems*. Morgan-Kaufmann, Volume 2.

- Lecun, Y., Bottou, L., Bengio, Y., Haffner, P., 1998. Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11), 2278–2324.
- Li, Y., Feng, X., Liu, Y., Han, X., 2021. Apple quality identification and classification by image processing based on convolutional neural networks. *Scientific Reports*, 11.
- Liu, L., Sun, H., Li, F., 2023a. A Lie group kernel learning method for medical image classification. *Pattern Recognition*, 142, 109735.
- Liu, S., Zhang, Q., Huang, L., 2023b. Graphic image classification method based on an attention mechanism and fusion of multilevel and multiscale deep features. *Computer Communications*, 209, 230–238.
- Liu, W., Anguelov, D., Erhan, D., Szegedy, C., Reed, S., Fu, C.Y., Berg, A.C., 2016. SSD: Single Shot MultiBox Detector. *Computer Vision – ECCV 2016*, Springer International Publishing. (pp. 21–37).
- Lu, Y., Lu, R., 2017. Histogram-based automatic thresholding for bruise detection of apples by structured-illumination reference imaging. *Biosystems Engineering*, 160.
- Luo, Z., Yang, W., Yuan, Y., Gou, R., Li, X., 2023. Semantic segmentation of agricultural images: A survey. *Information Processing in Agriculture*.
- McCulloch, W.S., Pitts, W., 1943. A logical calculus of the ideas immanent in nervous activity. *The bulletin of mathematical biophysics*, 5(4), 115–133.
- Mohana, S.H., Prabhakar, C.J., 2015. Stem-Calyx Recognition of an Apple using Shape Descriptors. *CoRR*, abs/1501.01083.
- Prince, S., 2012. *Computer Vision: Models Learning and Inference*. Cambridge University Press.
- Redmon, J., Divvala, S., Girshick, R., Farhadi, A., 2016. You Only Look Once: Unified, Real-Time Object Detection. *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. (pp. 779–788).
- Redmon, J., Farhadi, A., 2018. YOLOv3: An Incremental Improvement. *Cite arxiv:1804.02767Comment: Tech Report*.
- Ren, S., He, K., Girshick, R., Sun, J., 2015. Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks. C. Cortes, N. Lawrence, D. Lee, M. Sugiyama, R. Garnett (Eds.), *Advances in Neural Information Processing Systems*. Curran Associates, Inc., Volume 28.
- Rosenblatt, F., 1962. *Principles of Neurodynamics: Perceptrons and the Theory of Brain Mechanisms*. Spartan, Washington, D. C.

- Rumelhart, D.E., McClelland, J.L., 1987. Learning Internal Representations by Error Propagation. (pp. 318–362).
- Sammut, C., Webb, G.I., 2017. Encyclopedia of Machine Learning and Data Mining. Springer New York, NY, New York.
- Samuel, A.L., 1959. Some Studies in Machine Learning Using the Game of Checkers. IBM Journal of Research and Development, 3(3), 210–229.
- Siddiqi, R., 2019. Automated apple defect detection using state-of-the-art object detection techniques. SN Applied Sciences, 1.
- Sofu, M., Er, O., Kayacan, M., Cetişli, B., 2016. Design of an automatic apple sorting system using machine vision. Computers and Electronics in Agriculture, 127, 395–405.
- Sultana, F., Sufian, A., Dutta, P., 2020. Evolution of Image Segmentation using Deep Convolutional Neural Network: A Survey. Knowledge-Based Systems, 201-202, 106062.
- Szeliski, R., 2011. Computer vision algorithms and applications. Springer, London; New York.
- Valdez, P., 2020. Apple Defect Detection Using Deep Learning Based Object Detection For Better Post Harvest Handling.
- Xiao, Q., Li, G., Chen, Q., 2023. Complex image classification by feature inference. Neurocomputing, 544, 126231.
- Zhang, Y., Sidibé, D., Morel, O., Mériaudeau, F., 2021. Deep multimodal fusion for semantic image segmentation: A survey. Image and Vision Computing, 105, 104042.
- Zhou, B., Khosla, A., Lapedriza, A., Oliva, A., Torralba, A., 2016. Learning Deep Features for Discriminative Localization. 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). IEEE Computer Society, Los Alamitos, CA, USA, (pp. 2921–2929).
- Zou, Z., Chen, K., Shi, Z., Guo, Y., Ye, J., 2023. Object Detection in 20 Years: A Survey. Proceedings of the IEEE, 111(3), 257–276.