**MARMARA ÜNİVERSİTESİ**
**FEN BİLİMLERİ ENSTİTÜSÜ**

# DERİN ÖĞRENME YAKLAŞIMI İLE FINDIK MEYVESİNİN SINIFLANDIRILMASI

ENGİN GÜNEŞ

**YÜKSEK LİSANS TEZİ**
Bilgisayar Mühendisliği Anabilim Dalı

Bilgisayar Mühendisliği Yüksek Lisans Programı

**DANIŞMAN**

Dr. Eyüp Emre ÜLKÜ

**EŞ-DANIŞMAN**

Doç. Dr. Kazım YILDIZ

İSTANBUL, 2022

# ÖNSÖZ

Tez çalışmamın araştırılmasında ve yürütülmesinde her daim destek olan, her fırsatta yardımını esirgemeyen değerli danışmanım Dr. Eyüp Emre ÜLKÜ' ye ve eş danışmanım Doç. Dr. Kazım YILDIZ' a

Tez çalışmam boyunca desteği ve sabrı için ailemin bütün fertlerine

Teşekkürlerimi sunarım.

**HAZİRAN, 2022** **Engin GÜNEŞ**

# İÇİNDEKİLER


| | SAYFA |
|---|---|
| **ÖNSÖZ** | **i** |
| **İÇİNDEKİLER** | **ii** |
| **ÖZET** | **iv** |
| **ABSTRACT** | **v** |
| **SEMBOLLER** | **vi** |
| **KISALTMALAR** | **vii** |
| **ŞEKİL LİSTESİ** | **viii** |
| **TABLO LİSTESİ** | **x** |
| **1. GİRİŞ** | **1** |
| **1.1. Literatür Çalışması** | **3** |
| **1.2. Problemin Tanımı** | **8** |
| **1.3. Tezin Amacı** | **9** |
| **1.4. Tezin Organizasyonu** | **9** |
| **2. DERİN ÖĞRENME** | **10** |
| **2.1. Yapay sinir ağları** | **11** |
| **2.2. Derin Öğrenme Mimarileri** | **12** |
| 2.2.1. Tekrarlayan Sinir Ağı | 12 |
| 2.2.2. Uzun-Kısa Süreli Hafıza Ağları | 13 |
| 2.2.3. Kısıtlı Boltzmann Makinesi | 14 |
| 2.2.4. Derin İnanç Ağı | 15 |
| 2.2.5. Derin Oto Kodlayıcılar | 15 |
| 2.2.6. Evrişimsel Sinir Ağları | 16 |
| 2.2.6.1. Evrişimsel Sinir Ağı katmanları | 17 |
| 2.2.6.1.1. Evrişim Katmanı | 17 |
| 2.2.6.1.2. Havuzlama Katmanı | 19 |
| 2.2.6.1.3. Tamamen Bağlı Katman | 20 |
| 2.2.6.1.4. Dropout Katman | 21 |

**2.3. Derin Öğrenme Algoritmaları-Modelleri** **22**

2.3.1. VGG16 22

2.3.2. VGG19 23

2.3.3. ResNet50 24

2.3.4. EfficientNet 26

2.3.5. InceptionV3 27

**3. MATERYAL VE YÖNTEM** **29**

**3.1. Veri seti** **29**

3.1.1. Veri toplama **29**

3.1.2. Veri Hazırlama **32**

**3.2. Algoritmalar** **34**

**4. SONUÇ VE ÖNERİLER** **36**

**4.1. Deney ortamı** **36**

**4.2. Performans metrikleri** **36**

**4.3. Çalışma sonuçları** **37**

**KAYNAKLAR** **44**

**ÖZGEÇMİŞ**

# ÖZET

## DERİN ÖĞRENME YAKLAŞIMI İLE FINDIK MEYVESİNİN SINIFLANDIRILMASI

Bilgi teknolojileri alanında yaşanan gelişmeler sayesinde insan hayatına etki eden yeni teknolojilerin ortaya çıkışı da hızlanmıştır. Özellikle son 10 yılda çok hızlı bir gelişme ve ilerleme sağlanan derin öğrenme teknolojisi, sağlık, haberleşme, günlük yaşam, tarım gibi birçok farklı alanda hayatın içine dahil olmuştur. Derin öğrenmenin son yıllarda tarımsal faaliyetlerle entegre edilmesi oldukça popüler bir yaklaşımdır. Bu tez çalışmasında fındıkların kalitesine göre sınıflandırılması işleminde derin öğrenme algoritmalarından yararlanılmaktadır. Derin öğrenme için gerekli olan veri seti uzman bir kişi tarafından oluşturulmuş ve etiketlenmiştir. Veri seti üç farklı sınıftan toplam 15770 görüntüden oluşmaktadır. Çalışma için derin öğrenme modellerinden VGG16, InceptionV3 ve Resnet50 olmak üzere üç farklı model kullanılmaktadır. Modellerin fındık veri setindeki başarıları karşılaştırılmıştır. Sonuçta VGG16 modeli %99'a yakın bir başarı, Inceptionv3 modeli %96'dan biraz fazla bir başarı ve Resnet50 modeli de %89'a yakın bir doğruluk başarısına ulaşmıştır. Çalışmanın ikinci aşamasında ise veri setindeki veri sayısının modellerin başarısına etkisi incelenmektedir. Veri seti kademeli olarak %50, %25 ve %10 oranında azaltılmıştır. Veri setinin boyutunun küçültülmesi ile modellerin başarısında önemli bir düşüş gözlenmiştir. Veri setinin %10'u kullanıldığında VGG16'nın başarısı %88'e, InceptionV3'ün başarısı %72'ye ve Resnet50'nin başarısı da %56 ya düştüğü tespit edilmiştir.

**HAZİRAN, 2022** **Engin GÜNEŞ**

# ABSTRACT

## CLASSIFICATION OF HAZELNUT FRUIT WITH A DEEP LEARNING APPROACH

Thanks to the developments in the field of information technologies, the emergence of new technologies that affect human life has also accelerated. Especially in the last 10 years, deep learning technology, which has made a very rapid development and progress, has been included in many different areas such as health, communication, daily life and agriculture. Integrating deep learning with agricultural activities is a very popular approach in recent years. In this thesis, deep learning algorithms are used in the classification of hazelnuts according to their quality. The data set required for deep learning was created and labeled by an expert. The data set consists of a total of 15770 images from three different classes. Three different models of deep learning, VGG16, InceptionV3, and Resnet50, are used for the study. The success of the models in the hazelnut dataset was compared. As a result, the VGG16 model achieved an accuracy of close to 99%, the Inceptionv3 model achieved a success of just over 96%, and the Resnet50 model achieved an accuracy of close to 89%. In the second stage of the study, the effect of the number of data in the data set on the success of the models is examined. The dataset is gradually reduced to 50%, 25% and 10%. It was observed that the success of the models decreased significantly with the reduction of the data set. When 10% of the data set is used, the success of VGG16 drops to 88%, the success of InceptionV3 to 72%, and the success of Resnet50 to 56%.

**JUNE, 2022** **Engin GÜNEŞ**

# SEMBOLLER

| | | |
|---|---|---|
| **i** | **:** | Nöron sayısı |
| **x** | **:** | Girdi vektörü |
| **w** | **:** | Nöronun ağırlık vektörü |
| ∑ | **:** | Toplam |
| **y** | **:** | Çıktı vektörü |

# KISALTMALAR

**CNN** : Convulational Neural Network

**CSV** : Comma Seperated Values

**DBN** : Deep Belief Network

**ICML** : International Conference on Machine Learning

**IDE** : Integrated Development Environment

**ILSVRC** : ImageNet Large Scale Visual Recognition Challenge

**LSTM** : Long short-term memory

**RBM** : Restricted Boltzmann machine

**RNN** : Recurrent Neural Network

**VGG** : Visual Geometry Group

**YSA** : Yapay Sinir Ağları

# ŞEKİL LİSTESİ

SAYFA

**Şekil 1.1.** Farklı alanlarda palmiye ağacı tespit sonuçları [5]. (a) Palmiyenin çok olduğu alanda, (b) farklı tür bitkilerin bulunduğu alanda, (c) palmiyenin seyrek olarak bulunan alanda, (d) birkaç palmiyenin bulunduğu sınır alanında ……..…..……..4

**Şekil 1.2.** Kavunların tespiti ve verim tahmini için sistem hattı [9] ….…… 5

**Şekil 1.3.** Çalışmada ele alınan Evrişimsel sinir ağının üç katmanlı versiyonunu [16] .6

**Şekil 1.4.** Ürün fidelerinin farklı alanlarda tespiti [18] ……..…….6

**Şekil 2.1.** (a) nöron hücresi [38], (b) yapay nöron hücresi [38] ..…….…….11

**Şekil 2.2.** Tekrarlayan sinir ağı yapısı …….……12

**Şekil 2.3.** Tekrarlayan sinir ağı yapısından gelen verilerin kaybolması durumu ….…13

**Şekil 2.4.** Uzun kısa süreli hafıza mimarisi ……..14

**Şekil 2.5.** Kısıtlı Boltzman makinası ……15

**Şekil 2.6.** Derin inanç ağları yapısı ……..15

**Şekil 2.7.** Derin oto kodlayıcı yapısı ……16

**Şekil 2.8.** Basit evrişimsel sinir ağı blok diyagramı ….……16

**Şekil 2.9.** Evrişimsel sinir ağı ……...17

**Şekil 2.10.** (a) orijinal görsel, (b) köşe filtresi uygulanmış görsel ……17

**Şekil 2.11.** Farklı katmanlardan alınmış özellik haritaları ……18

**Şekil 2.12.** (a) siyah beyaz resim, (b) resmin sayısallaştırılmış hali ……18

**Şekil 2.13.** Görüntüye filtre uygulaması ……..19

**Şekil 2.14.** Havuzlama işlemi ……..20

**Şekil 2.15.** Özellik haritasının düzleştirilmesi …….……21

**Şekil 2.16.** Tamamen bağlı katman gösterimi …….21

**Şekil 2.17.** Dropout katmanı uygulaması, (a) normal derin ağ yapısı, (b) dropout uygulanmış derin ağ yapısı [21] ……..22

**Şekil 2.18.** VGG16 model mimarisi ……23

**Şekil 2.19.** VGG19 model mimarisi ……24

**Şekil 2.20.** Resnet50 model mimarisi ……..25

**Şekil 2.21.** Resnet bloğunun gösterimi ……25

**Şekil 2.22.** EfficientNet B0 model mimarisi ……27

**Şekil 2.23.** MB Evrişim blokları ……..27

**Şekil 2.24.** InceptionV3 model mimarisi ……28

**Şekil 3.1.** Veri seti için oluşturulan platform ……30

**Şekil 3.2.** Farklı açılardan çekilmiş fındık resimleri, (a) sağlam fındık, (b) kötü fındık, (c) iç fındık ……...31

**Şekil 3.3.** Veri hazırlama sürecinin akış şeması ……32

**Şekil 3.4.** (a) 3024x3024 piksel kırpılmamış görüntü, (b) 1000x1000 piksel kesilmiş görüntü, (c) 224x224 piksel görüntü ……....33

**Şekil 3.5.** Evrişimsel sinir ağı yapısı ……..34

**Şekil 4.1.** (a) VGG16, (b) InceptionV3 ve (c) Resnet50 gerçek ve tahmin değerleri .38

**Şekil 4.2**. (a) VGG16, (b) InceptionV3 ve (c) Resnet50 sayısal verilerin 0-1 arasına indirgenmiş halleri ……...38

**Şekil 4.3.** (a) modellerin doğruluk değerleri, (b) modellerin kayıp değerleri ……..39

**Şekil 4.4.** Modellerin test veri setindeki başarıları ..……41

**Şekil 4.5.** Başarısız sınıflandırılmış fındık resimleri ……42

# TABLO LİSTESİ

SAYFA

**Tablo 1.1.** Modelin sınıflandırma performansının karşılaştırmaları [4] ….……3

**Tablo 1.2.** Çalışmanın sınıflandırma sonuçları [14] …….……..5

**Tablo 1.3.** Gerçek domates görüntülerinde sayım [26]; (G) gerçek, (T) tahmin …..…..7

**Tablo 1.4.** Algoritmaların sınıflandırma performansı [30] ……8

**Tablo 3.1.** Fındıklardan alınan görüntü sayıları ……..30

**Tablo 4.1.** Karmaşıklık matrisi …….……..…….36

**Tablo 4.2.** VGG16 modelinin sonuçları …….…….37

**Tablo 4.3.** InceptionV3 modelinin sonuçları …….……..38

**Tablo 4.4.** Resnet50 modelinin sonuçları …….……...38

**Tablo 4.5.** Modellerin eğitim ayarları …….39

**Tablo 4.6.** Modellerin eğitim sonucunda oluşan değerleri …….…….39

**Tablo 4.7.** Bölümlenmiş veri seti ……40

**Tablo 4.8.** Veri seti boyutuna göre test verisinin değişimi ……. …….40

**Tablo 4.9.** Veri seti boyutuna göre modellerin test verisindeki sonuçları. ……..41

# 1.GİRİŞ

Tarım sektörü, toplumların ekonomik ve sosyal kalkınmalarında önemli rolü olan ve bu önemi gün geçtikçe artan bir alandır. Tarım sektörünün öneminin artmasında, insan nüfusunun ve şehirleşme oranının yükselmesi, tarımda çalışan işçi oranının azalması gibi faktörlerin etkili olduğu görülmektedir [1]. Nüfusta yaşanan artış tarım ürünlerine olan arzın artması anlamına gelmektedir. Bu durum da daha fazla tarım üretimi yapma ihtiyacını beraberinde getirmektedir. İnsan nüfusundaki yükseliş, şehirleşme oranını da doğrudan etkilemektedir. Şehirleşme oranındaki artış da tarım ile ilgili işlerde çalışan insanların oranının azalmasına neden olmaktadır. Kısacası, oransal olarak azalan tarımsal insan gücüne karşılık tarım ürünü ihtiyacı gün geçtikçe artmaktadır. Bu doğrultuda, önemi her geçen gün artan tarım sektöründe verimliliği yükseltmek amacıyla bu sektörün teknoloji ile entegrasyonu için geliştirilen uygulamalar da giderek yaygınlaşmaktadır.

İnsanlar temel ihtiyaçlarının başında gelen beslenme gereksinimlerini karşılayabilmek amacıyla tarımsal faaliyetler yapmaya başlamışlardır. Tarım uygulamaları gerçekleştirilirken ilk olarak insan gücünden faydalanılmış sonrasında ise hayvanların gücünden yararlanılmıştır. Daha sonrasında ise sanayi devrimi ile başlayan makineleşme ile birlikte makineler tarım alanlarında kullanılmaya başlanmıştır. Son yüzyılda teknoloji de yaşanan hızlı gelişmeler, tarım uygulamalarında da önemli değişiklikleri ve yenilikleri beraberinde getirmiştir. Tarımsal faaliyetlerin önemli bir bölümünde teknolojinin imkânlarından yararlanılmaya başlanmıştır. Teknolojinin tarımda kullanılması ile birlikte yeni bir kavram olan akıllı tarım kavramı ortaya çıkmıştır. Akıllı tarım, teknolojiden yararlanarak; verimi arttırmayı ve zaman tasarrufu sağlamayı amaçlamaktadır. Bir başka ifade ile akıllı tarım, var olan kaynaklardan en iyi şekilde yararlanmak olarak açıklanabilir. Ülkemiz tarım alanları bakımından oldukça zengin bir ülkedir. Türkiye de farklı bölgelerde farklı tarımsal ürünler yetişmektedir. Son yıllarda akıllı tarım uygulamalarında da ülkemizde önemli bir atılım gerçekleştirilmektedir. Bu gerçekleştirilen atılım tarımda dijitalleşme olarak adlandırılmaktadır. Tarımda dijitalleşme ile birlikte ürünlerden elde edilen verimin ve kalitenin yükseltilmesi amaçlanmaktadır. Ülkemizden, diğer ülkelere birçok farklı tarım ürününün ihracatı yapılmaktadır. Bu ürünleri sebze, meyve, bakliyat ve kuru çerez başlıkları altında çeşitlendirebiliriz. İhracattan en çok gelir elde edilen ürünlerin başında ise fındık gelmektedir.

Fındık, Karadeniz Bölgesinde yetişen, kabuklu çerez sınıfından, ağaç gövdeye sahip çok yıllık bir bitkidir [2]. Genellikle engebeli arazilerde yetişen bir tarım ürünüdür. Yetiştirildiği arazilerin koşulları, teknoloji kullanımını zorlaştırması sebebiyle, teknolojiden diğer tarım ürünlerine göre daha az faydalanmaktadır. Fındık tarımında hali hazırda bazı makineli araçlar kullanılmakla birlikte bunların yaygınlaşması uzun zaman almıştır. Bu makineli araçlar; bahçeyi temizlemek için motorlu tırpan, zararlı böceklere karşı fındıkları ilaçlamak için ilaçlama aleti, fındık ağaçlarını budama ve temizlemek için ağaç kesme motoru, fındığı üzerindeki kabuktan ayırmak için patoz denilen alet ve genel kullanım için traktör, lombardini gibi motorlu aletlerdir. Motorlu aletlerden fındık tarımında yararlanılmakla birlikte bu aletler insan gücü yardımı ile kullanılabilmektedir. Bu nedenle fındık çoğunlukla insan emeği gerektiren bir tarım ürünüdür.

Son yıllarda tarım alanlarında teknoloji tabanlı yeni uygulamaların ve makinelerin kullanımı giderek yaygınlaşmaktadır. Günümüzde yapay zekâ, teknoloji tabanlı tarım uygulamalarında en popüler yenilik olarak karşımıza çıkmaktadır. Tarım alanlarında son yıllarda yapay zekâ teknolojisinin aktif ve yaygın olarak kullanılmasının nedeni bu teknolojinin elde ettiği yüksek başarım oranlarıdır. Derin öğrenme kavramı ile birlikte yapay zekâ tabanlı uygulamaların elde ettiği başarım oranları da hızlı bir şekilde yükselmektedir. Bu tez çalışmasında, fındık üreticilerinin önemli problemlerinin başında gelen fındığın sınıflandırma problemini ortadan kaldırmaya yönelik teknoloji tabanlı bir çözüm sunulmaktadır. Mevcut durumda üreticiler fındığın sınıflandırma problemini çözümlemek için insan gücünden faydalanarak, sağlam fındıklar içerisinden kötü fındıkları ve iç fındıkları ayıklamaktadırlar. Bu süreçte insan hatalarından kaynaklı kötü ve iç fındıkların sağlam fındıklar içerisinde kaldığı durumlar olabilmektedir. Ayıklama işlemi sonrasında sağlam fındıklar içerisinde kalan kötü ve iç fındıklar fındığın kalitesini düşürmektedir. Kalite düştüğünde fındığın randımanı düşük gelmekte bunun sonucunda da fındık daha düşük bir fiyata satılmaktadır. Bu duruma çözüm olarak derin öğrenme yaklaşımını kullanarak fındığın kalitesine göre sınıflandırılmasını insan kaynaklı hatalardan arındırmak ve sağlam fındıklar içerisinden kötü ve iç fındıkları daha hızlı ve verimli bir şekilde ayıklamak çalışmanın temel amacını oluşturmaktadır. Bu duruma ek olarak, bu çalışma ile son yıllarda önemi giderek artan tarımda dijitalleşme süreçlerine önemli bir katkı sunulması hedeflenmiştir.

### 1.1. Literatür Çalışması

Çalışma için gerçekleştirilen literatür araştırmasında bu alanda yapılmış birçok farklı çalışma incelenmiştir. Teknoloji tabanlı tarım uygulamaları ile ilgili farklı alanlarda farklı ürünler üzerine farklı teknikler kullanılarak çok çeşitli çalışmalar gerçekleştirilmektedir. Literatür araştırma sürecini sistematik olarak yapabilmek adına çalışmalar gruplanarak incelenmiştir. İlk olarak uzaktan algılama yöntemi yani uydu üzerinden ve insansız hava araçları yardımıyla elde edilmiş görüntüler üzerinden yapılan tespit çalışmaları incelenmiştir. Chiu M. T. ve arkadaşları tarafından geliştirilen çalışmada, havadan çekilmiş görüntüler kullanılarak tarım alanlarının tespiti gerçekleştirilmiştir [3]. Nguyen T.T. ve arkadaşlarının gerçekleştirdiği çalışmada ise, uydu görüntülerinden yararlanarak ekili çeltik alanlarının tespitinde %93'ün üzerinde bir başarı elde etmişlerdir [4]. Bu ağın sınıflandırma performansının karşılaştırma verileri tablo 1.1'de gösterilmektedir.

**Tablo 1.1.** Modelin sınıflandırma performansının karşılaştırmaları [4]

| | **F1 skor** | **F1 gerçek zamanlı** | **Eğitim** | **Test** |
|---|---|---|---|---|
| **Bu model** | 94.6% | 91.1% | 1230 | 10 |
| **Spectral** | 90.7% | 88.4% | 1425 | 18 |
| **SVM** | 90.4% | 87.7% | 580 | 7 |
| **Threshold** | 87.19% | 88.22% | 60 | 60 |
| **CNN** | 90.48% | 88.69% | 370 | 8 |
| **VGG** | 85.1% | 85.1% | 1320 | 12 |
| **InceptionNet** | 82.4% | 83.6% | 1380 | 13 |

Liu X. ve arkadaşları insansız hava araçlarından (İHA) alınan görüntüleri kullanılarak ortaya koydukları derin öğrenme modeli ile elde edilen görüntülerden palmiye ağaçlarını %97 doğrulukla tespit ettikleri görülmüştür [5]. Çalışmada elde edilen bazı sonuçlar şekil 1.1'de gösterilmektedir.

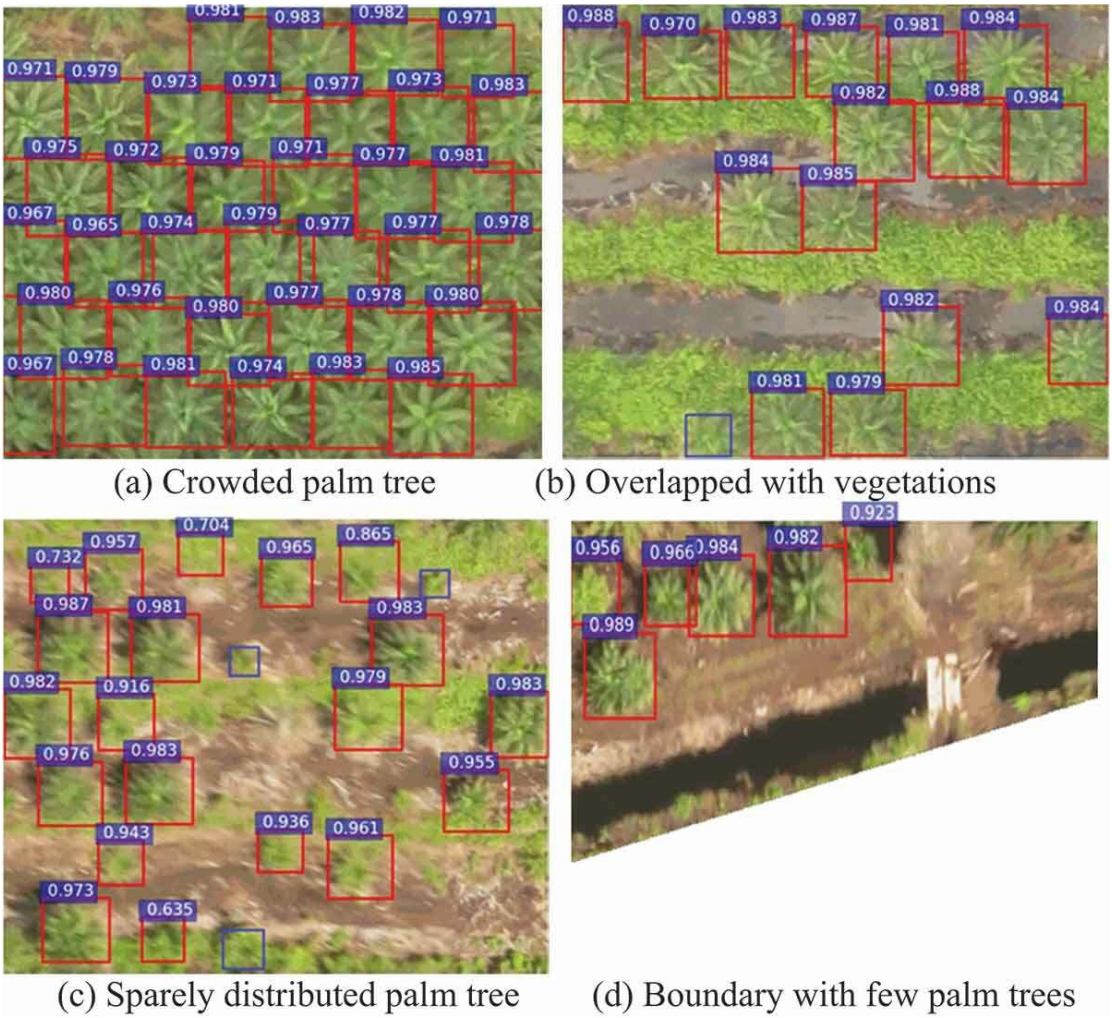


**Şekil 1.1.** Farklı alanlarda palmiye ağacı tespit sonuçları [5]. (a) Palmiyenin çok olduğu alanda, (b) farklı tür bitkilerin bulunduğu alanda, (c) palmiyenin seyrek olarak bulunduğu alanda, (d) birkaç palmiyenin bulunduğu sınır alanında

Aguiar A. S. ve arkadaşları tarafından yapılan diğer bir çalışmada ise eğimli araziler üzerinde bulunan asma gövdelerinin tespiti gerçekleştirilmiştir [6]. Bu çalışmaların yanında soya, mısır, arpa, buğday, şeker pancarı, yonca gibi tarımsal ürünlerin sınıflandırma işlemi Sun Z. ve arkadaşlarının ortaya koydukları çalışmada %82'nin üzerinde bir başarı oranı ile gerçekleştirilmiştir [7]. Yamaguchi T. ve arkadaşları ise İHA görüntülerinden yararlanarak pirinç verimini yaprak alanı indeksleri kullanılarak hesaplamışlardır [8]. Kalantar A. ve arkadaşları, İHA'lardan elde edilen görüntüleri kullanarak kavun ekili tarım alanlarında, hasattan önce kavunların sayısının ve her bir kavunun ağırlığının belirlenebilmesi için derin öğrenme tabanlı bir model geliştirmişler ve bu model ile %90'ın üzerinde bir başarı oranı ile tahmin süreçlerini gerçekleştirmişlerdir [9]. Şekil 1.2'de bu sistemin işleyişi gösterilmektedir.

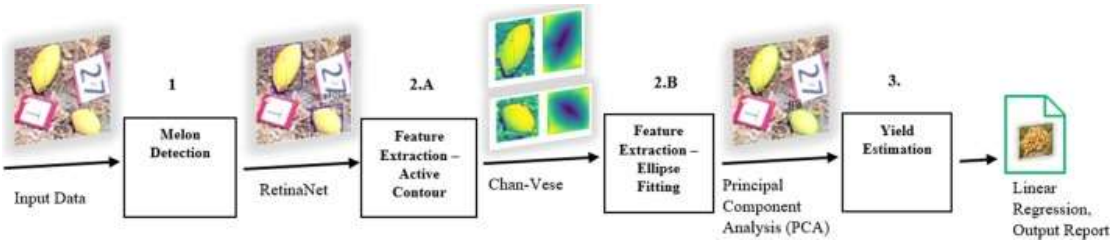


**Şekil 1.2.** Kavunların tespiti ve verim tahmini için sistem hattı [9].

İkinci olarak ise açık tarım uygulamalarında gerçekleştirilen çalışmalar incelenmiştir. Jin X. B. ve arkadaşlarının gerçekleştirdiği çalışmada sıcaklık, rüzgâr hızı ve nem gibi verilerin tahmin edilmesinde derin öğrenme yaklaşımı kullanılmıştır [10]. Yağmur, mahsul verimini doğrudan veya dolaylı yoldan etkileyen bir olaydır. Basha C. Z. ve arkadaşları yağmur yağışını tahmin edebilmek için derin öğrenme yaklaşımından yararlanmışlardır [11]. Mahsulde önemli derecede zarar meydana getiren don olaylarının önceden tahmin edilmesi ve önlem alınmasını sağlamak amacıyla Guillén-Navarro M. A. ve arkadaşları derin öğrenme yaklaşımını kullanmışlardır [12].

Seracılıkla ilgili yapılan çalışmaları da bir başka grupta toplayabiliriz. Derin öğrenmenin tarımsal faaliyetlerde en verimli ve yaygın olarak kullanıldığı alanların başında seracılık faaliyetleri gelmektedir. Somov A. ve arkadaşları seralarda yetişen domateslerin büyüme oranının tespit edilmesinde yapay zekâ tabanlı bir model geliştirmişlerdir [13]. Diğer bir çalışmada Esgario J. G. ve arkadaşları kahve yapraklarında haşerelerin meydana getirdiği zararların tespitinde ve tahmininde yapay zekâ yaklaşımını kullanmışlardır [14]. Tablo 1.2'de bu çalışmanın sınıflandırma sonuçları ayrıntılı şekilde gösterilmektedir.

**Tablo 1.2.** Çalışmanın sınıflandırma sonuçları [14]

| | **Kesinlik (%)** | **Duyarlılık (%)** | **F1 skor** |
|---|---|---|---|
| **Sağlıklı elma** | 0.988679 | 0.96679 | 0.977612 |
| **Genel elma kabuğu** | 0.711538 | 0.770833 | 0.74 |
| **Ciddi elma kabuğu** | 0.742857 | 0.764706 | 0.753623 |
| **Elma gri nokta** | 0.979798 | 0.989796 | 0.984772 |
| **Genel Sedir Elma Pası** | 0.914286 | 0.969697 | 0.941176 |
| **Ciddi Sedir Elma Pası** | 0.857143 | 0.666667 | 0.75 |
| **Ağırlıklı ortalama** | 0.935596 | 0.933063 | 0.933859 |

Zhong Y. ve Zhao M. ortaya koydukları çalışmada elma yapraklarında meydana gelen hastalıkların tespitinde derin öğrenme yaklaşımını kullanmış ve %93'ün üzerinde bir başarı elde etmişlerdir [15]. Grinblat G. L. ve arkadaşları yaprak üzerindeki damar yapısından bitkinin tanımlanmasını sağlayan bir çalışma yürütmüşlerdir [16]. Bu çalışmada ele alınan Evrişimsel sinir ağının üç katmanlı versiyonunun diyagramı şekil 1.3'te gösterilmektedir.

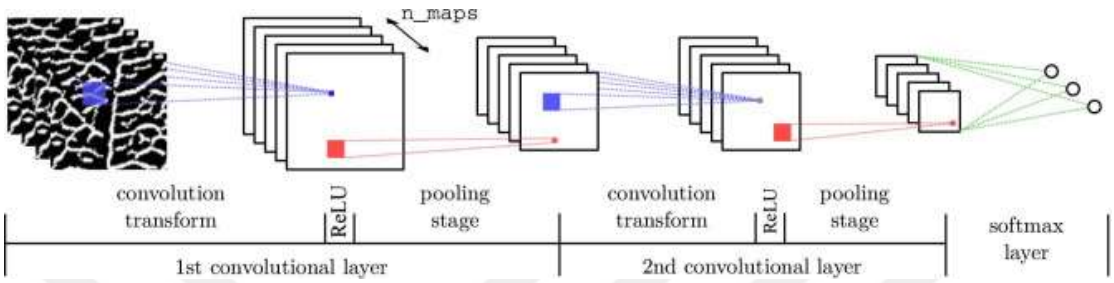


**Şekil 1.3.** Çalışmada ele alınan Evrişimsel sinir ağının üç katmanlı versiyonunu [16]

Yine yaprak şeklinden yararlanılarak ürün fideleri ve yabancı otların ayrıştırılmasında yapay zekâ yaklaşımı Aitkenhead M. ve arkadaşları, gerçekleştirdikleri çalışmada kullanmışlardır [17]. Jin X. ve arkadaşlarının yaptığı ürün fideleriyle otları birbirinden ayıran çalışmada renk farklılıkları kullanılarak derin öğrenmeden yararlanılmıştır [18]. Çalışmada kullanılan modelin farklı koşullardaki ürün fidelerini tespiti şekil 1.4'te gösterilmektedir.

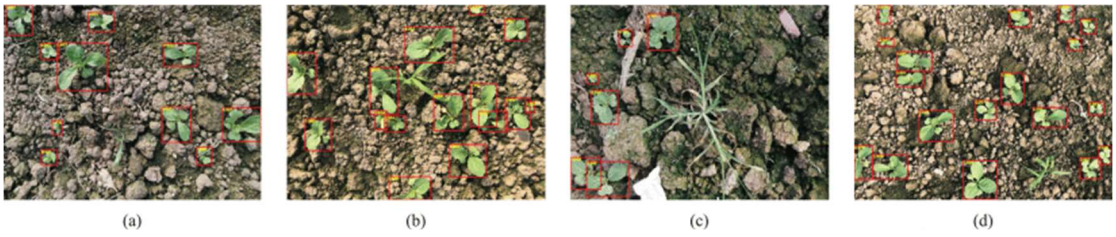


**Şekil 1.4.** Ürün fidelerinin farklı alanlarda tespiti [18]

Xiong J. ve arkadaşları derin öğrenme yaklaşımını kullanarak geliştirdikleri modelle bitki türlerini tanıma işlemini dijitalleştirmeyi hedeflemişlerdir [19]. Loey M. ve arkadaşları ise bitki görüntülerinden bitki hastalıklarının tespitini gerçekleştirmişlerdir [20]. Türkoğlu M. ve arkadaşları kayısı hastalıklarının sınıflandırılmasında derin öğrenme yaklaşımından yararlanmışlardır [21]. Derin öğrenme yaklaşımı kullanılarak yürütülen bir başka çalışmada Hossain M. S. ve arkadaşlarının meyve çeşitlerinin sınıflandırılmasında %99'dan fazla başarı elde ettikleri görülmektedir [22]. Kang H. ve Chen C. yaptığı derin öğrenme tabanlı çalışmada meyve bahçelerinde gerçek zamanlı olarak elma tespitini %85 doğrulukta gerçekleştirilmiştir [23]. Diğer bir çalışmada

AlZamily J. Y. ve Naser S. S. A. limon meyvesinin sınıflandırma işlemini %99 doğrulukla gerçekleştirmiştir [24]. Mansour A. I. gerçekleştirdiği çalışmada armutların sınıflandırılmasında derin öğrenme tabanlı bir model sunmuştur [25]. Derin öğrenme yaklaşımı kullanılarak Rahnemoonfar M. ve Sheppard C. yaptıkları çalışmada bir ağaçtaki ve tüm bahçedeki meyve sayısını %91 doğrulukta tahmin etmeyi başarmışlardır [26]. Tablo 1.3'te domates olan gerçek görüntülerde, kaç adet domates olduğunu göstermektedir.

**Tablo 1.3.** Gerçek domates görüntülerinde sayım [26]; (G) gerçek, (T) tahmin

| | T | G | | T | G | | T | G |
|---|---|---|---|---|---|---|---|---|
|  | 36 | 38 |  | 27 | 24 |  | 18 | 17 |
|  | 22 | 25 |  | 21 | 23 |  | 15 | 14 |
|  | 22 | 22 |  | 13 | 12 |  | 14 | 14 |
|  | 20 | 25 |  | 19 | 19 |  | 38 | 39 |
|  | 22 | 22 |  | 16 | 17 |  | 16 | 19 |

Agarwal S. ve Tarar S. arazinin toprak yapısı ve bulunduğu bölgenin iklim koşullarına göre bu araziden elde edilebilecek ürün miktarını derin öğrenme ile tahmin edebilen bir model ortaya koymuşlardır [27]. Tarımın diğer bir ürün çeşidi olan kabuklu kuruyemiş türlerinin sınıflandırmasında Dheir I. M. ve arkadaşları derin öğrenmeyi başarılı şekilde kullanarak %98 doğruluk elde etmişlerdir [28]. Han Y. ve arkadaşlarının kuruyemiş üzerine yaptığı diğer çalışmada ise kuruyemiş kalite tahmininde derin öğrenme ile ortalama %95 başarı ortaya konmuştur [29]. Bir başka çalışmada ise kuruyemiş olan fındığın, sivri, kara ve tombul olarak türlerine göre sınıflandırılması işlemini gerçekleştirilmiştir. Bu çalışmayı Caner K. ve arkadaşları makine öğrenimi ve derin öğrenme kullanarak geliştirmiş yüksek bir başarım elde etmişlerdir [30]. Çalışmada farklı algoritmaların kullanılması sonucu oluşan değerler tablo 1.4'te gösterilmektedir.

Tablo 1.4. Algoritmaların sınıflandırma performansı [30]

| | **Algoritma** | **Doğru** | **Yanlış** | **Doğruluk (%)** | **Hata (%)** | **F1 skor** |
|---|---|---|---|---|---|---|
| **Sivri** | DL4J | 71 | 4 | 95% | 5.333 | 0.923 |
| **Kara** | | | | | | 0.936 |
| **Tombul** | | | | | | 0.98 |
| **Sivri** | Random Forest | 75 | 0 | 100% | 0 | 1 |
| **Kara** | | | | | | 1 |
| **Tombul** | | | | | | 1 |
| **Sivri** | Gradient Boosting | 71 | 4 | 95 % | 5.333 | 0.96 |
| **Kara** | | | | | | 0.958 |
| **Tombul** | | | | | | 0.923 |

Detaylı bir literatür incelemesinin sonucunda ülkemizin en önemli ihracat ürünlerinin başında gelen fındık bitkisinin sınıflandırması ile ilgili teknoloji tabanlı bir sistem ile karşılaşılmamıştır. Bu doğrultuda fındık bitkisinin sınıflandırma sürecini daha verimli yapılmasını sağlayacak teknoloji tabanlı bir sistemin geliştirilmesine karar verilmiştir.

## 1.2. Problemin Tanımı

Karadeniz bölgesinde fındık tarımı halkın geçim kaynaklarının başında gelmektedir. Fındık tarımında, ürünlerin hasadından sonra çiftçilerin fındıkları kalitesine göre temizlemesi gerekmektedir. Üreticiler fındığı satarken kalitesiz fındıklar randımanı düşürmekte bu durum da üreticinin gelir kaybı yaşamasına neden olmaktadır. Bu gelir kaybının önlenmesi adına temizleme işlemi fındık tarımında önemli bir süreçtir. Bir diğer durumda, fındığın depolarda bekleme sürecinde, kabuklu fındıklar arasında kalan

iç fındıkların bozulmasıdır. Üreticilerin, fındığı satmadan veya depolamadan önce kötü fındıkların ve iç fındıkların ayıklanması oldukça önemlidir. Günümüzde bu ayıklama işlemi insan gücüne dayalı olarak yapılmaktadır. Fındığın temizlenme işleminde, insan hatalarından kaynaklı hatalı sınıflandırmalar olabilmektedir. Bu sınıflandırma işlemi sonucunda fındığın kalitesini düşüren birçok kötü fındık ve iç fındık kalabilmektedir. Sonuçta da bu durum üreticiler için hem zaman kaybı hem de maddi kayıplara neden olabilmektedir.

### 1.3. Tezin Amacı

Bu tez çalışmasında, fındıkların sağlam (kaliteli), kötü (kalitesiz) ve iç fındık olarak sınıflandırma işlemini gerçekleştirebilecek derin öğrenme tabanlı bir model geliştirilmiştir. Böylelikle, fındıkların sınıflandırma işlemini yüksek doğrulukla, hızlı ve verimli bir şekilde gerçekleştirebilen bir model ortaya konmuştur. Bu tezin temel amacı, Karadeniz bölgesinde yetişen ve çiftçiler için önemli bir gelir kaynağı olan fındığın kalitesine göre sınıflandırılma işleminin geliştirilen algoritma ile insan gücüne ihtiyaç duyulmadan gerçekleştirilebilmesini sağlamaktır.

### 1.4. Tezin Organizasyonu

Tez dört ana bölümden oluşmaktadır. İlk bölümde problemin tanımı ve çalışmanın amacı ile ilgili bilgiler sunulmuştur. İkinci bölümde ise Derin Öğrenme yaklaşımı detaylı olarak açıklanmıştır. Derin öğrenme nedir, derin öğrenmenin mimarileri, katmanları ve modelleri ile ilgili açıklamalar bu bölümde yer almaktadır. Üçüncü bölümde kullanılan materyal ve yöntem ile ilgili bilgiler sunulmuştur. Çalışmada kullanılan veri seti ve algoritmalar ile ilgili bilgiler bu bölümde yer almaktadır. Son bölüm olan sonuç ve değerlendirmeler kısmında ise çalışmada elde edilen sonuçlar grafik ve tablolar yardımıyla sunulmuş, çalışma genel hatları ile özetlenerek ileride yapılabilecek çalışmalar ile ilgili bilgilere yer verilmiştir.

# 2. DERİN ÖĞRENME

İnsanların hayatlarını kolaylaştıracak ve geliştirecek buluşlar ortaya koyma çabası yüzyıllardır süren bir süreçtir. Ortaya çıkan her yeni buluş bir başka gelişmeyi de beraberinde getirmektedir. Sanayi devrimi [31], bilgisayarın keşfi [32] ve yapay zekânın ortaya çıkışı [33] ortaya konan buluşların temel yapı taşları olarak gösterilebilir. Sanayi devrimi ile birlikte insan gücüne dayalı işler yerini makine işçiliğine bırakmıştır. Bilgisayarın icadı ile matematiksel hesaplamalar, elle yazılan dokümanlar gibi birçok işlem bilgisayarlar üzerinde yapılarak insan hayatını kolaylaştırmaya ve verimliliği arttırmaya yönelik çalışmalar gerçekleştirilmiştir. Bir başka ifade ile insan gücüne duyulan ihtiyacı azaltmaya yönelik yenilikler ortaya konmuştur. Yapay zekanın ortaya çıkışı ile öğrenme, çıkarım yapma gibi insanın bilgiye dayalı yönleri de taklit edilerek makinelere insansı özellikler kazandırılmıştır. Makineler bu yapılarla birlikte nesne tespiti, sınıflama, sonuç çıkarımı, harf tespiti, öğrendiği bilgilere dayalı yeni bilgiler üretmek gibi birçok insansı özellik kazamaya başlamışlardır.

Son yıllarda, gerçekleştirilen teknolojik gelişmelerin büyük çoğunluğunu bilişim alanında yaşanan gelişmelerin oluşturduğunu söyleyebiliriz. Bilişim alanındaki gelişmeler oldukça hızlı ve birçok farklı alanı etkileyerek gerçekleşmektedir. Yapay zekâ alanında yaşanan gelişmeler, bilgi teknolojilerinde son yıllarda yaşanan en önemli ilerlemeler olarak görülmektedir. Yapay zekâ teknolojisinden önce daha çok fiziksel olarak insanların hayatlarını kolaylaştıran gelişmeler olurken yapay zekâ ile birlikte makinelere öğrenme, yorumlama, çıkarım yapma gibi yetenekler kazandırılarak insanların hayatlarını daha da kolaylaştıran teknolojiler ortaya çıkmaya başlamıştır. Gönümüzde oldukça popüler olan akıllı robot süpürge [34], yapay zekâ ile donatılmıştır. Robot süpürge evin planını hiçbir yardım almaksızın çıkarmaktadır. Daha sonrada otomatik olarak evi temizlemekte işi bittiğinde de yerine geri dönmektedir. Başka bir örnek olarak ta birçok yapay zekâ özellikleriyle donatılmış mobil telefonlar gösterilebilir. Özellikle mobil telefonların kameralarında yapay zekanın açık örnekleri bize kendisini göstermektedir. Örneğin bir fotoğraf çekmek istediğinizde istediğiniz kişiyi veya nesneyi netleştirip diğerlerini bulanıklaştırabilmesi yapay zekâ yardımıyla gerçekleşmektedir. Günümüzde yapay zekâ, bilişim teknolojilerinin en popüler alanı olarak görülmektedir. Bunun nedeni araştırmacıların yapay zekâ çalışmalarını, çalışılabilecek her alanda yaparak yapay zekanın mutlak derecede başarılı olması gösterilebilir. Buna ek olarak ta kullanıldığı alanlarda insanlara yüksek derecede

yardımının dokunmasıdır. Örneğin, yaygın kullanım alanı olan sağlık alanında doktorlar yardımcı karar mekanizması olarak yapay zekâ teknolojisinden yararlanmaktadırlar. Yapay zekânın başarısında alt dallarının rolü büyüktür. Bu alt dalların başında makine öğrenmesi [35] ve derin öğrenme [36] gelmektedir. Makine öğrenmesi ile başlayan bu başarı derin öğrenme kavramının ortaya çıkmasıyla çok daha başarılı uygulamaların gelişmesine olanak sağlamaktadır. Bu teknolojiler üzerinde yapılan çalışmalar yaygınlaştıkça daha istikrarlı ve yüksek doğruluk veren yaklaşımlar ortaya çıkmaya başlamaktadır. Özellikle derin öğrenme çalışmalarının sonucunda oldukça yüksek doğruluk oranına sahip sonuçlar elde edilebilmektedir. Derin öğrenme yaklaşımının elde ettiği yüksek başarımda yapay sinir ağlarının [37] önemli etkisi bulunmaktadır.

## 2.1. Yapay sinir ağları (YSA)

Yapay zekâ teknolojisini hızlı gelişiminde yapay sinir ağlarının önemli etkisi vardır. YSA, insan beyninin biyolojik nöral yapısının matematiksel olarak örneklenmesiyle geliştirilmiş bir yapıdır [38]. İnsan biyolojik nöron hücresinin yapısı şekil 2.1 (a)'da, yapay sinir ağlarının kullandığı yapay nöron hücresinin yapısı ise şekil 2.1 (b)'de gösterilmektedir.

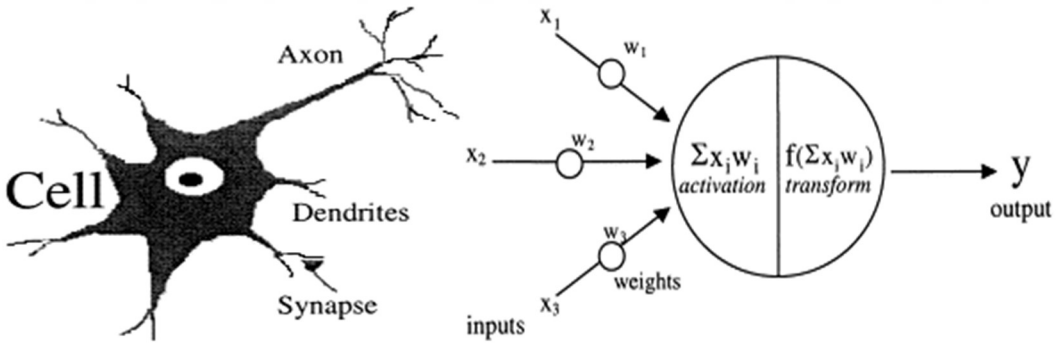


a b

**Şekil 2.1.** (a) nöron hücresi [38], (b) yapay nöron hücresi [38]

İnsan beyninde olduğu gibi YSA da nöron adı verilen yapılarla oluşturulmuştur. Bu nöronlar birbirlerine bağlı şekilde insan beynindeki nöral yapı gibi geliştirilmiştir. İnsan nöral yapısından farklı olarak YSA katmanlı bir nöron yapısına sahiptir. Bu katmanlı yapıda her katmandaki nöronlar diğer katmandaki nöronlar ile birbirlerine bağlı haldedirler. Ama aynı katmandaki nöronlar birbirlerine bağlı değillerdir. Her nöron bağlı olduğu nörondan bilgi almakta ve kendine bağlı olan diğer nöronlara da bu bilgileri iletmektedir. Bu gelişmelerin amacı makinelerin eğitilmesi, öğrenmesi ve karar

vermesi gibi insan yeteneklerini kazanmasını sağlamaktır. YSA'nın elde ettiği başarılar sonucunda derin öğrenme ağları bu ağlar temel alınarak geliştirilmiştir.

## 2.2. Derin Öğrenme Mimarileri

Derin öğrenme günümüzün en popüler ve en yaygın kullanıma sahip teknolojilerinin başında gelmektedir. Bunun nedeni derin öğrenme ile birlikte makinelerin çevrelerinde gerçekleşen olaylara insanlar gibi tepki verebilir duruma gelmiş olmalarıdır. Derin öğrenme yaklaşımında farklı durumlarda yüksek başarım oranları elde edebilmek amacıyla farklı mimariler ortaya konmuştur. Bu mimarilerin her biri farklı türde durumlar için başarılı süreçler sağlamak amacıyla oluşturulmuş mimarilerdir.

### 2.2.1. Tekrarlayan sinir ağı (Recurrent Neural Network)

Tekrarlayan sinir ağları 1980'lerde geliştirilmiştir. Hopfield J.J. [39] tarafından 1982 yılında tanıtılan Hopfield Ağı, tekrarlayan bağlantılara sahip ilk ağ olarak kabul edilmektedir. Bu derin öğrenme algoritmaları genellikle dize şeklindeki sıralı veya zamansal sorunlar için kullanılabilen ağlardır. Tekrarlayan sinir ağları her bir basamağın kendinden önce gelen basamağın bilgisini almakta, en son basamakta ise tüm ondan önceki basamaktaki bilgileri barındırmaktadır. Tekrarlayan sinir ağı yapısı Şekil 2.2'de gösterilmektedir.

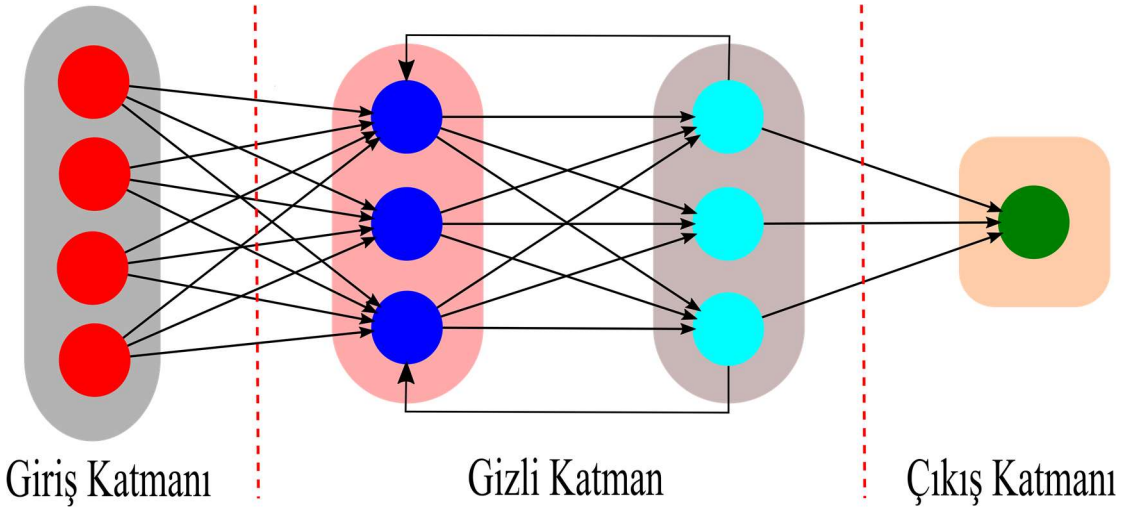


**Şekil 2.2.** Tekrarlayan sinir ağı yapısı

Bir olayın gerçekleşme sırası bilinirse bu olayın içinden seçilen bir noktadan sonra gerçekleşmesi muhtemel olayda tahmin edilebilir. Örnek olarak bir harf dizimiz olduğunu düşünelim. Bu harf dizisi "A, B, C, D, E" şeklinde olsun. Harflerin sıralı bir

harf dizisi olması tekrarlayan sinir ağların kullanılması için uygundur. İlk olarak ağ A harfini öğrenir ve bunu tutar daha sonra B harfini öğrenirken ondan önce öğrendiği A harfini de öğrenmiş olur. En son E harfini öğrendiğinde E harfinden önce gelen tüm harfleri de burada öğrenmiş olur. Sonuç olarak biz bu harf dizisinde C harfini verdiğimizde C harfinden önceki seriyi bildiği için bize D harfini rahatlıkla bulacaktır. Tekrarlayan sinir ağları yapısında seri uzadıkça daha önce öğrendiği veriler unutmaya başlamaktadır. Bu durumu gösteren bir örnek Şekil 2.3' de sunulmuştur. Örneğin, mobil telefonlarda mesajlarda yazılan kelimeler sonucunda klavyenin üst bölgesinde bu kelimeden sonra cümleyi tamamlayabilecek kelimeler getirilmesinde tekrarlayan sinir ağları yapısı kullanılmaktadır. Konuşma tanıma, doğal dil işleme, dil çevirisi gibi sorunların çözümünde genellikle tekrarlayan sinir ağları kullanılmaktadır. Bu ağların en büyük sorunlarından biri kısa süreli belleğe sahip olmalarıdır. Bu da uzun dizilerde ilk verilerin kaybolmasına neden olmaktadır.

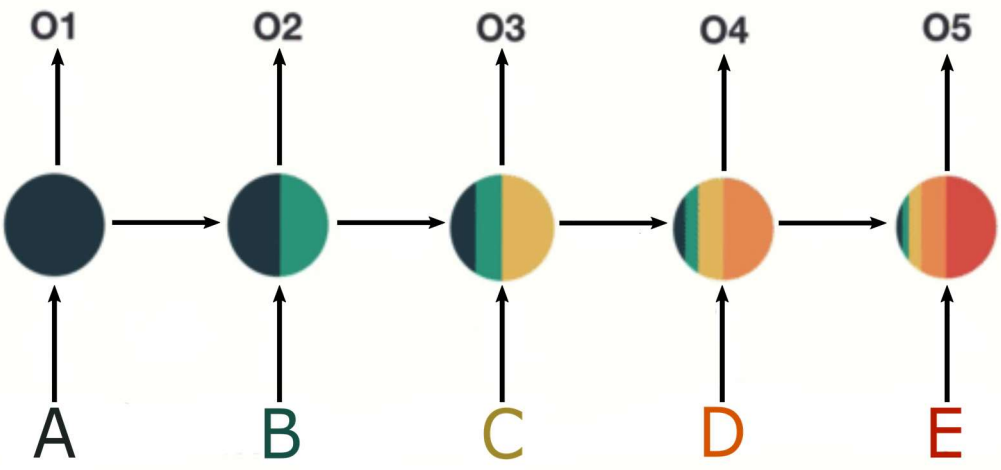


**Şekil 2.3.** Tekrarlayan sinir ağı yapısında gelen verilerin kaybolması durumu [62]

### 2.2.2. Uzun-Kısa süreli hafıza ağları (LSTM- Long Short-Term Memory)

Uzun-kısa süreli hafıza ağları 1997 yılında Hochreiter S. ve Schmidhuber J. [40] tarafından geliştirilmiş bir derin öğrenme mimarisidir. Uzun-kısa süreli hafıza ağları tekrarlayan sinir ağlarında olan kısa bellek probleminin ortaya çıkardığı uzun vadeli bağımlılıkların öğrenilmesi sorununu ortadan kaldırmıştır. Sıralı ve zaman serisi problemlerinde yaygın olarak kullanılmaktadır. Temel bir LSTM mimarisi giriş kapısı, unut kapısı ve çıkış kapısından oluşmaktadır. Unut kapısı hangi bilgilerin gereksiz olduğunu ya da geçmiş bilgilerin ne kadarının hatırlanacağına karar veren kapıdır. Giriş

kapısı mevcut girişten hangi yeni bilgilerin ekleneceğine ve ne kadarının ekleneceğine karar verir. Çıkış kapısı ise geçerli olan hücrenin hangi bölümünün çıktıya ulaşması gerektiğine karar veren mekanizmadır. Şekil 2.4'te LSTM mimarisi gösterilmektedir. Dil modelleme, makine çevirisi, resim altyazısı, el yazısı tanıma ve sorulan sorulara cevap veren chatbotlar gibi uygulamalarda sıklıkla tercih edilen bir mimaridir.

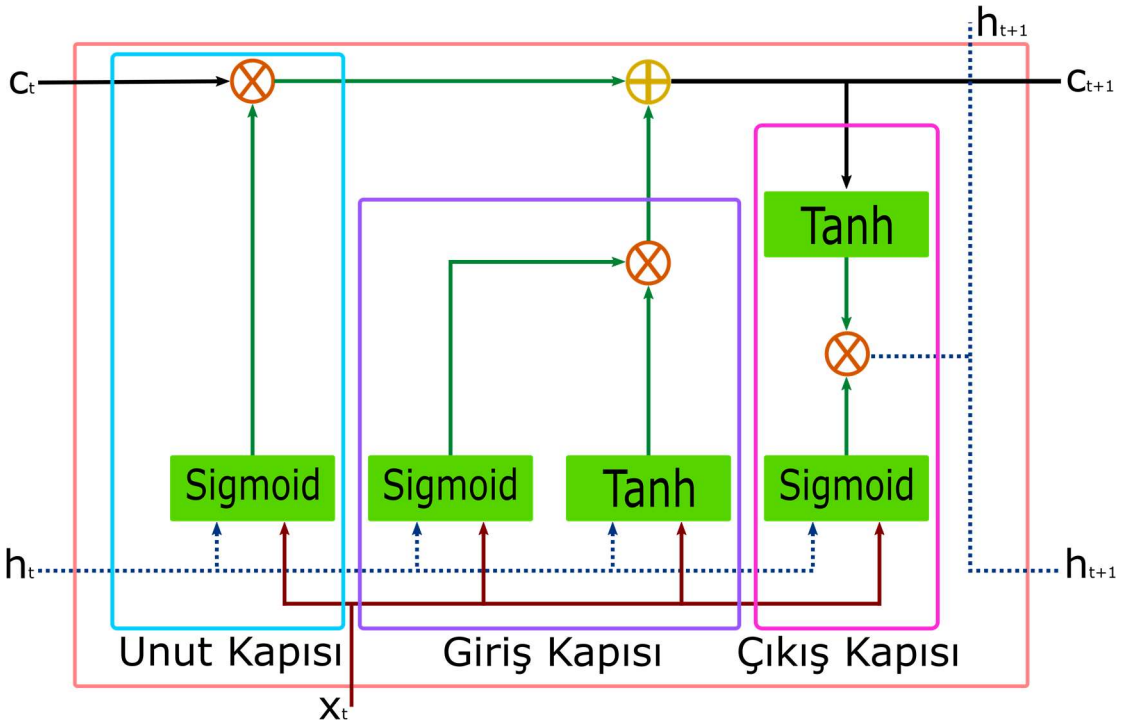


**Şekil 2.4.** Uzun kısa süreli hafıza mimarisi

### 2.2.3. Kısıtlı Boltzmann makinesi (RBM-Restricted Boltzmann Machine)

Smolensky P. [41] tarafından 1986'da öne sürülmüş ve ilk ismi "harmonium" olarak açıklanmıştır. Daha sonra 2000'lerin ortasında Hinton G. E. [42] tarafından kısıtlı boltzman makineleri olarak tekrar ele alınarak ön plana çıkmıştır. Kısıtlı Boltzman makinaları iki katmanlı kısıtlı bir nöral ağ yapısına sahiptir. İlk katman görünür katman (visible layer) ikinci katman ise gizli katman (hidden layer) olarak adlandırılır. İletişim sadece katmanlar arasında gerçekleşmektedir. Aynı katmanlar arasında iletişim yoktur. Görünür katmandaki düğünler sadece gizli katmandakilerle bağlantı kurabilirler. Gizli katmandaki düğümler de sadece görünür katmanlarla bağlantı kurabilirler. Görünür katmandaki tüm düğümler gizli katmandaki düğümlerin hepsiyle bağlantılıdır. Bu yapı, Netflix için 2007 de kullanılarak pratiğe dönüştürülmüştür [43]. Kısıtlı Boltzmann makinesinin yapısı Şekil 2.5'te gösterilmiştir.

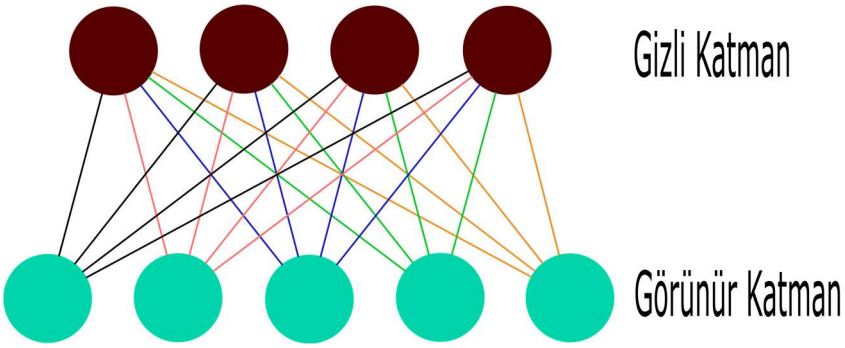


**Şekil 2.5.** Kısıtlı Boltzman makinası

### 2.2.4. Derin inanç ağı (DBN-Deep Belief Network)

Derin inanç ağları çok sayıda Kısıtlı Bolzmann makineleri katmanlarının birleşiminden oluşmuş bir ağ yapısıdır [44]. Her bir RBM katmanı hem kendinden önce hem kendinden sonra gelen katmanlarla iletişim kurabilir bir yapıdadır. Bu yüzden birçok tek katmanlı ağdan oluşan bir ağdır. Derin inanç ağlarında her katman kendinden önceki katman için gizli katman, kendinden sonra gelen katman için ise giriş katmanı işlevini üstlenmektedir. Giriş ve çıkış katmanı bu açıklamanın dışındadır. Şekil 2.6'te derin inanç ağlarının yapısı gösterilmektedir.

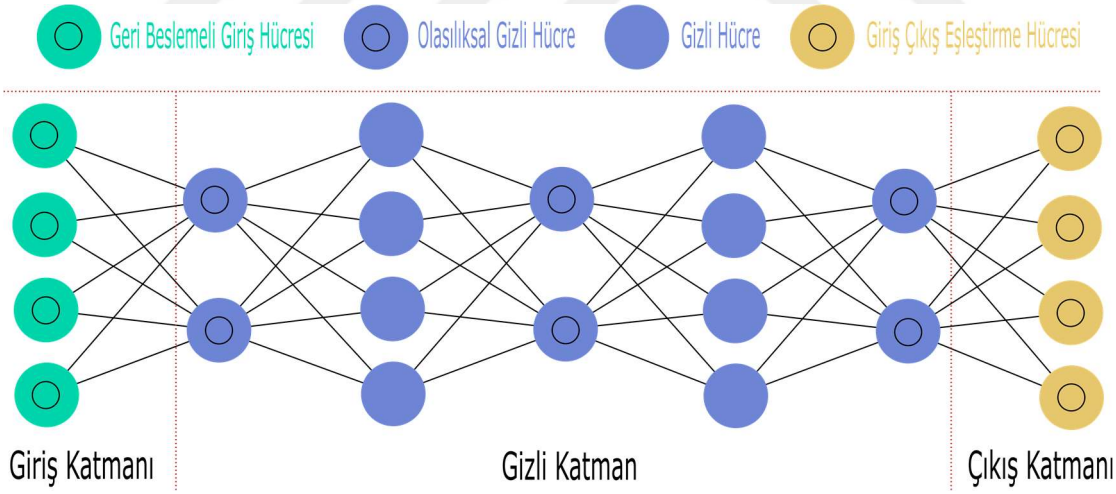


**Şekil 2.6.** Derin inanç ağları yapısı

### 2.2.5. Derin oto kodlayıcılar (Deep Auto Encoder)

Derin oto kodlayıcılar en az 3 katmana sahip simetrik iki derin inanç ağından oluşmuş bir modeldir. Ağlardan ilki ağın kodlama kısmını oluştururken ikinci yarısı da kod çözücü olarak oluşturulmuştur. Oto kodlayıcıların en önemli farkı daha fazla katmana sahip olmaları, bu durum sonucunda da daha detaylı özellikleri öğrenebilmeleridir.

Şekil 2.7'de örnek bir derin oto kodlayıcısı gösterilmektedir. Derin oto kodlayıcılar bir öğenin daha küçük parçalarından o öğenin orijinal halini oluşturmayı gerçekleştirmektedir. Bu nedenle öğenin orijinal görüntüsüne en yakın görüntüyü oluşturabilirler. Bunlar için örnek olarak bmp uzantılı oluşturulmuş bir resmin jpeg olarak oluşturulması gösterilebilir. Burada bazı özellikler kaybedilse de orijinal resme en yakın resim oluşmuş olur.

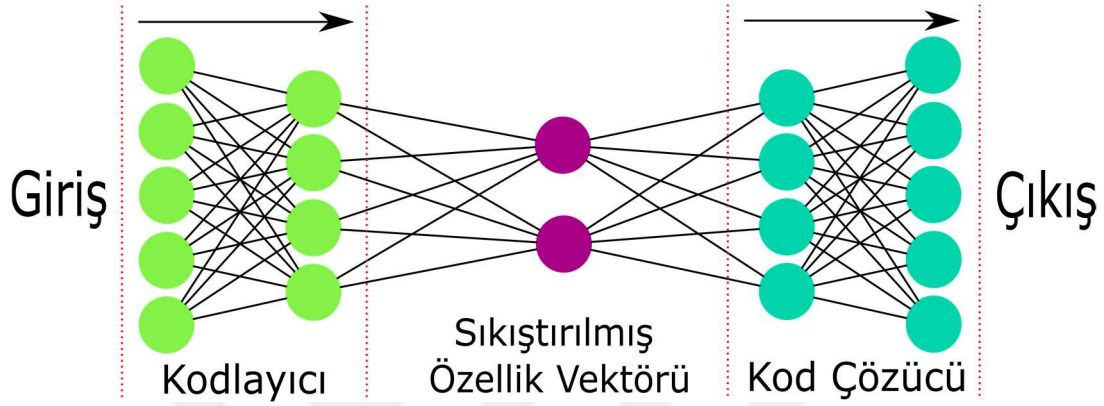


**Şekil 2.7.** Derin oto kodlayıcı yapısı

### 2.2.6. Evrişimsel sinir ağları (Convulational Neural Network)

Derin öğrenme denilince ilk akla gelen ağ modellerinin başında evrişimsel sinir ağları modeli gelmektedir. Bu ağların başarısı ses ve görüntü tabanlı uygulamalarda öne çıkmaktadır. Katmanlı bir mimariye sahip olan Evrişimsel sinir ağının diğer ağlardan en büyük farkı gizli katmanlara sahip olmasıdır. Bu ağlarda farklı modeller farklı sayıda gizli katmana sahip olabilmektedir. Evrişimsel sinir ağı yapısı veriyi çeşitli katmanlarda işlemektedir. Şekil 2.8'de örnek bir Evrişimsel sinir ağı blok diyagramı gösterilmektedir.

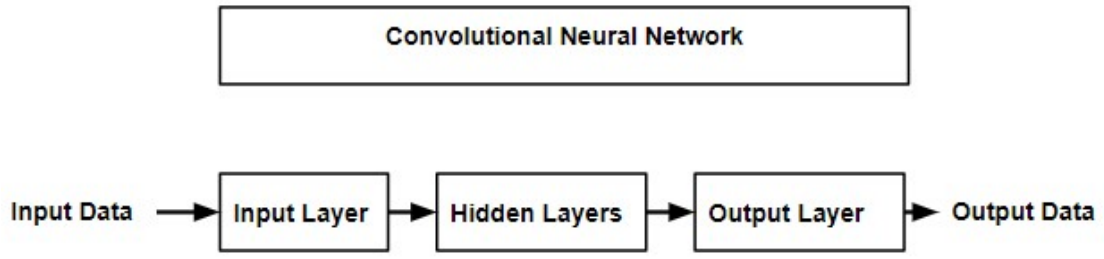


**Şekil 2.8.** Basit Evrişimsel sinir ağı blok diyagramı [65]

### 2.2.6.1. Evrişimsel sinir ağı katmanları

Farklı ve karmaşık yapıda birçok modeli bulunan Evrişimsel sinir ağlarını basit bir şekilde özetleyecek olursak, evrişim katmanı, havuzlama katmanı ve tamamen bağlı katman olmak üzere bir çok farklı katmandan oluşmaktadır. Evrişim ve havuzlama (pooling) katmanı öznitelik çıkarmak için kullanılırken, tamamen bağlı katmanda çıkarılan özniteliklere göre çıktıya eşleme işlemi gerçekleştirilir [45]. Şekil 2.9'de örnek bir Evrişimsel sinir ağı gösterilmektedir.

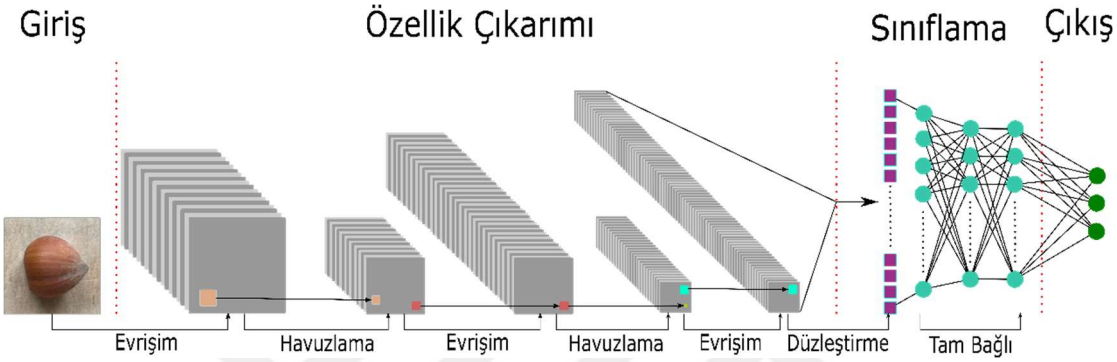


**Şekil 2.9.** Evrişimsel sinir ağı

#### 2.2.6.1.1. Evrişim katmanı

Evrişim katmanı, Evrişimsel sinir ağı yapısının en önemli katmanıdır. Bu katmanda görüntünün öznitelikleri çıkartılmaktadır. Öznitelikleri çıkarabilmek için görüntüye farklı filtreler uygulamaktadır. Filtrelerin uygulanma amacı resmin farklı filtrelerle değişik özelliklerini yakalamaktır. Filtrelere kenar filtresi, keskinleştirme filtresi, bulanıklaştırma filtresi örnek olarak gösterilebilir. Kenar filtreleri resimlerde kenar olan bölgeleri net olarak ortaya çıkmasını sağlamaktadır. Şekil 2.10'da eski bir ev görselinin, (a) orijinal görseli ve (b) kenar filtresi uygulanmış görseli gösterilmektedir.



a b

**Şekil 2.10.** (a) orijinal görsel, (b) köşe filtresi uygulanmış görsel

Filtrelerin görüntüye uygulanması sonucunda özellik haritaları oluşmaktadır. Her bir filtreyle farklı bir özellik haritası ortaya çıkmaktadır. Bu özellik haritaları bir sonraki işleme geçene kadar korunurlar. Şekil 2.10a'da gösterilen resmin farklı filtreler sonucunda oluşan örnek özellik haritaları şekil 2.11'da gösterilmektedir.

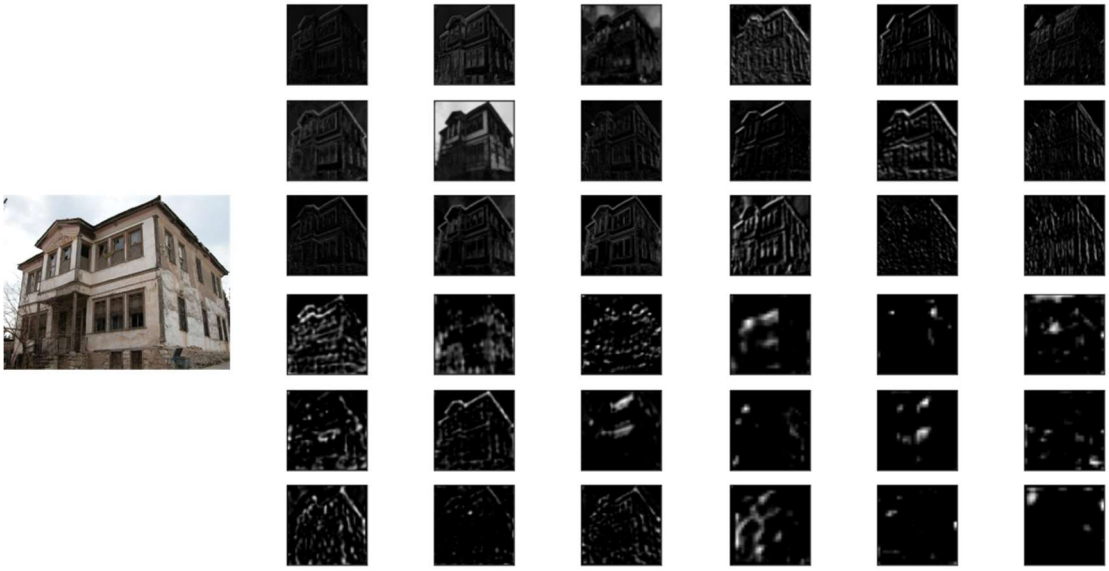

**Şekil 2.11.** Farklı katmanlardan alınmış özellik haritaları

Görseller, işlem görmeden önce sayısal veriye çevrilmektedirler. Bunun nedeni bilgisayar sistemleri sayısal verilerle işlem yapabilmektedirler. Şekil 2.12' de 7x7 piksel boyutunda (a) orijinal siyah beyaz resim, (b) orijinal görselin sayısallaştırılmış şekli gösterilmektedir. Görselde her bir kare tek bir pikseli temsil etmektedir.

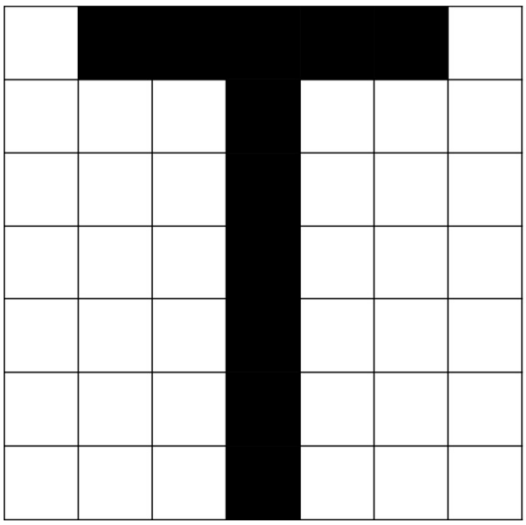

a

| | | | | | | |
|---|---|---|---|---|---|---|
| 0 | 1 | 1 | 1 | 1 | 1 | 0 |
| 0 | 0 | 0 | 1 | 0 | 0 | 0 |
| 0 | 0 | 0 | 1 | 0 | 0 | 0 |
| 0 | 0 | 0 | 1 | 0 | 0 | 0 |
| 0 | 0 | 0 | 1 | 0 | 0 | 0 |
| 0 | 0 | 0 | 1 | 0 | 0 | 0 |
| 0 | 0 | 0 | 1 | 0 | 0 | 0 |

b

**Şekil 2.12.** (a) siyah beyaz resim, (b) resmin sayısallaştırılmış hali

Şekil 2.13'de sayısallaştırılmış örnek görüntüye filtre uygulaması yapılmaktadır. Görüntü 7x7 piksel, filtre ise 3x3 piksel boyutundadır. Filtre görüntüye sol üst köşeden başlayacak şekilde uygulanmaya başlar ve sağa doğru tek adım olacak şekilde kaydırılır. İlk satırın sonuna geldiğinde bir adım alt tarafa en sola kaydırılır ve bu şekilde tüm görüntü taranmaktadır. Filtrenin görüntü üzerinde denk geldiği bölge, filtrenin her bir piksel değeri ile teker teker çarpılmaktadır. Çarpım sonucu oluşan yeni değerlerin hepsi toplanarak özellik haritasında tek piksel değeri olarak ilgili yere eklenmektedir. Bu işlem tüm görüntü için yapılarak özellik haritası oluşturulmuş olmaktadır. Özellik haritasının boyutu da 5x5 piksel olarak işlem sonucunda oluşmaktadır.

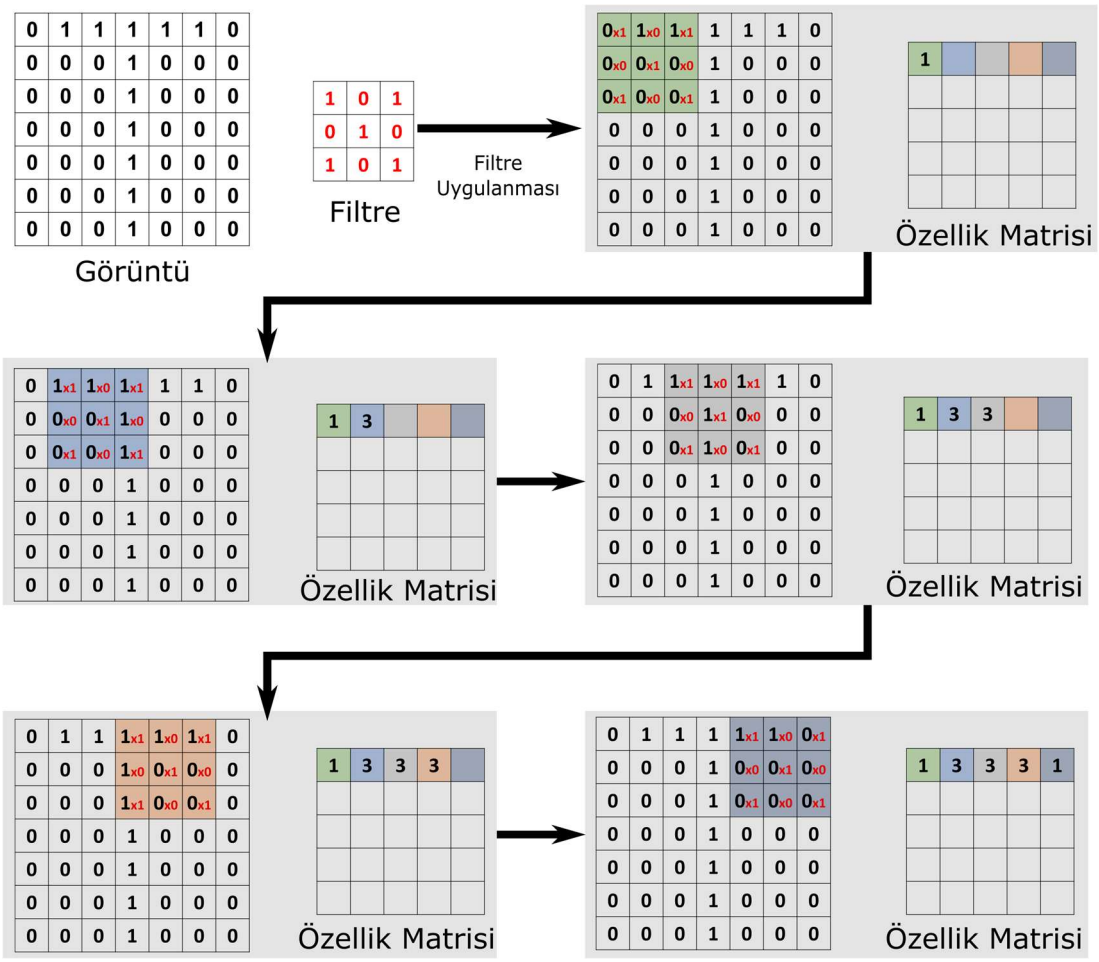


**Şekil 2.13.** Görüntüye filtre uygulaması

### 2.2.6.1.2. Havuzlama katmanı

Evrişimli sinir ağı mimarisinde önemli katmanlardan biri de havuzlama katmanıdır. Bu katmanda, evrişim katmanı sonucunda oluşan özellik matrisine havuzlama işlemi uygulanmaktadır. Havuzlama katmanında öznitelik matrisinin boyutunu azaltmaya yönelik bir katmandır. Boyut azaltma işlemi sonucunda bazı özellikler yok olmaktadır.

Üç adet havuzlama yöntemi bulunmaktadır. Bunlar maksimum havuzlama, minimum havuzlama ve ortanca havuzlama yöntemleridir. Evrişimsel sinir ağı yapısında havuzlama katmanında genellikle maksimum havuzlama yöntemi kullanılmaktadır. Şekil 2.14'te örnek bir maksimum havuzlama gösterilmektedir.

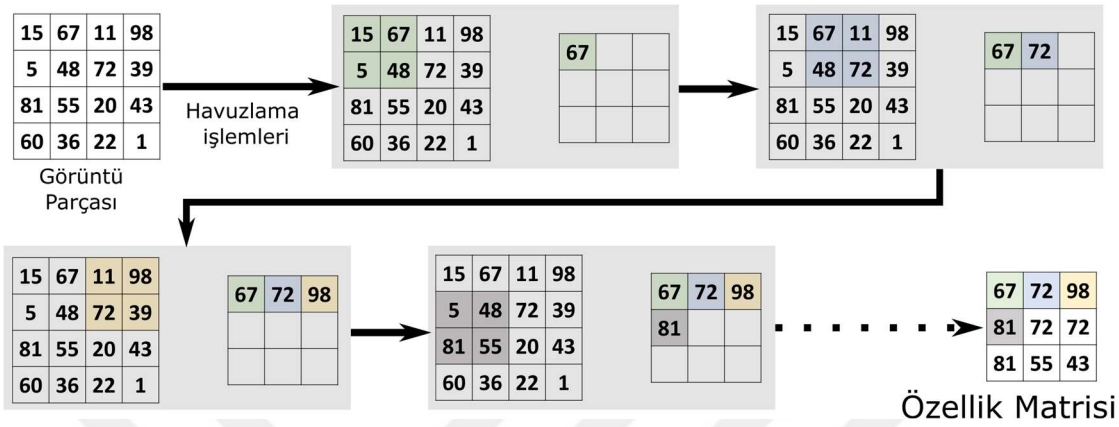


**Şekil 2.14.** Havuzlama işlemi

Havuzlama katmanında, özellik matrisine havuzlama yöntemi sol üst köşeden başlayarak sağa doğru hareket ettirilmektedir. Burada en sağa geldiğinde bir alt kademeye geçerek en soldan tekrar başlayarak matrisin sonuna kadar devam etmektedir. Örnek yöntem olarak maksimum havuzlama yöntemi kullanılan örnekte 2x2 bir filtre kullanılmaktadır. Burada filtrenin içinde denk gelen verilerden en büyük olan değer yeni matrise yazılır. Sonra atlama değerine göre filtre kaydırılmaktadır. Burada atlama değeri olarak 1 kademe alınmaktadır. Bir kademe atladıktan sonra tekrar filtrenin içinde kalan alanın en büyük değeri alınarak yeni matrise geçirilir. Tüm matris bu şekilde gezilerek yeni matris oluşturulmuş olur. Eski matrise göre yeni oluşan matrisin boyutu düşüktür.

### 2.2.6.1.3. Tamamen bağlı katman

Evrişim katmanı ve havuzlama katmanları birden fazla kullanılabilmektedir. Bu katmanlar sonucunda oluşan en son matris tek boyutlu bir sütun haline getirilip tam bağlı katmana gönderilmektedir. Ama her zaman matrisler tek sütun haline getirilemeyebilirler. Bu durumda son oluşan matrise düzleştirme işlemi uygulanarak matris tek boyutlu dize haline getirilmektedir. Şekil 2.15'te örnek bir düzleştirme işlemi gösterilmektedir.

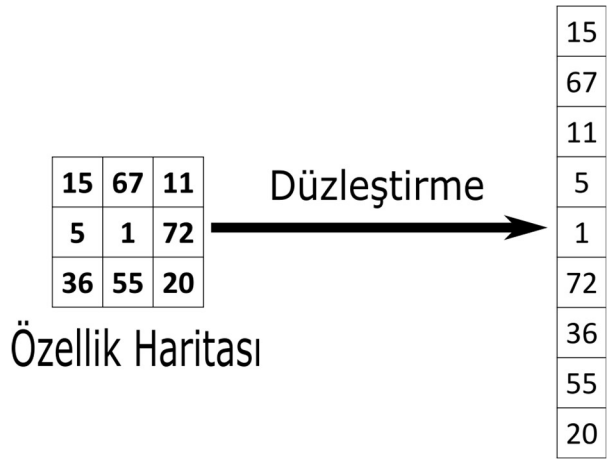


**Şekil 2.15.** Özellik haritasının düzleştirilmesi

Son olarak, oluşan düzleştirilmiş matris tek boyutlu şekle gelmiş olur. Bu oluşan tek boyutlu matris tamamen bağlı katmanda istenilen işlenerek istenilen boyuta kadar indirgenir. Örneklemek gerekirse bu oluşan matriste 1000 adet veri var olduğunu düşünelim. Bu 1000 adet veri bir sonraki adımda 100 adet veriye düşürülür. Daha sonraki adımda 50 adet veriye düşürülür. Ve son olarak ta çıkış katmanında kaç adet sınıflama verisi var ise o kadar adet veriye kadar düşürülmektedir. Şekil 2.16'te tamamen bağlı katman gösterilmektedir.

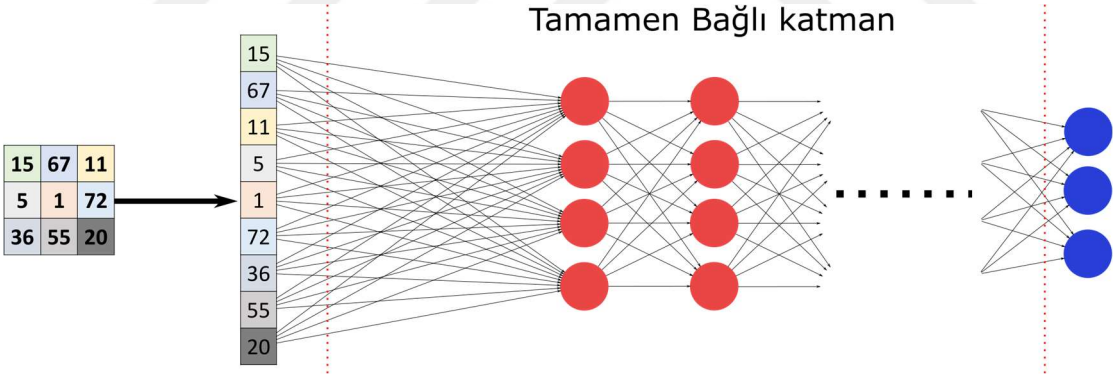


**Şekil 2.16.** Tamamen bağlı katman gösterimi

### 2.2.6.1.4. Dropout Katmanı

Derin öğrenme uygulamalarında modelin aşırı öğrenmesini yani modelin verilen veri setindeki verileri ezberlenmesini önlemek için kullanılan bir katmandır. Bu katman ile model içerisindeki bazı nöronlar kaldırılarak modelin ezber yapmasının önüne geçilir. Bu işlem sonucunda sistem performansı da artmaktadır [21]. Dropout işlemi şekil 2.17'te gösterilmektedir.




**Şekil 2.17.** Dropout katmanı uygulaması, (a) normal derin ağ yapısı, (b) dropout uygulanmış derin ağ yapısı [21]

## 2.3. Derin Öğrenme Algoritmaları-Modelleri

Derin öğrenme farklı ve çeşitli mimarilere sahiptir. Çeşitlilik ve farklılık mimarilerin kullanım yerlerine göre oluşmaktadır. Görüntü bazlı uygulamalar da en popüler mimari Evrişimsel sinir ağı mimarisidir. Bu mimari yapısına sahip birçok model bulunmaktadır. Modellerin derinliği ve yapısı sonucunda daha farklı özellikler tespit edilebilmektedir. VGG16 [46], VGG19 [46], Resnet50 [47], EfficientNet [48] ve InceptionV3 [49] derin öğrenme modellerinden birkaçıdır.

### 2.3.1. VGG16

Oxford üniversitesinden Simonyan K. ve Zisserman A. [46] tarafından 2014 yılında ortaya konulmuş bir derin öğrenme modelidir. Görüntü geometri grubu (visual geometry group) kısaltması olan VGG, modelin 16 katmanlı olduğunun ifadesi olarak 16 ile birleştirilmiş ve VGG16 ismini almıştır. Buradaki katman tanımı sadece evrişim ve tamamen bağlı katman dikkate alınarak oluşturulmuştur. VGG16 138 milyondan fazla bir parametreye sahiptir [61]. 2014 yılında ImageNet Büyük Ölçekli Görsel Tanıma Yarışmasında (ILSVRC) %91,8 doğruluk başarısına ulaşmıştır [46]. Bu yarışmada kullanılan ImageNet [64], 14 milyondan fazla görüntü içeren 1000 sınıflı bir veri setidir. Şekil 2.18'da VGG16 modelinin mimarisi gösterilmektedir.

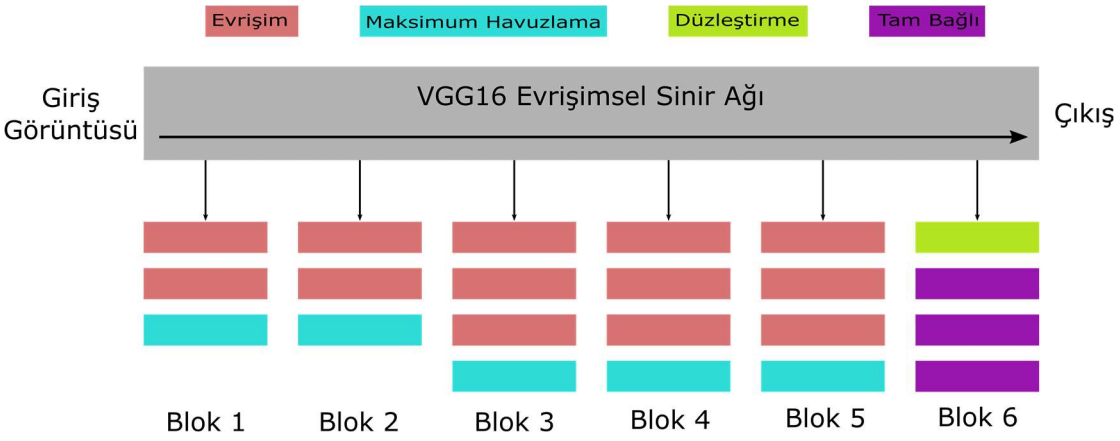


**Şekil 2.18.** VGG16 model mimarisi

VGG16 modelinin giriş görüntüsü renkli ve sabit boyutlu olacak şekilde 224x224 pikseldir. Giriş görüntüsü verildikten sonra ilk evrişim bloğunda 64 adet 3x3 boyutunda evrişim filtresi uygulanan 2 evrişim katmanı ve takibinde 2x2 boyutlu bir maksimum havuzlama filtresi bulunmaktadır. İkinci evrişim bloğunda ise 3x3 boyutunda 128 adet evrişim filtresi uygulanan 2 evrişim katmanı ve 2x2 boyutlu maksimum havuzlama katmanı içermektedir. Sonraki blokta ise 256 adet filtre uygulanan 3 evrişim katmanı ve maksimum havuzlama katmanına sahiptir. Dördüncü ve son evrişim bloğunda, 512 adet filtre içeren 3 evrişim katmanı ve maksimum havuzlama katmanı bulunmaktadır. Son blok tamamen bağlı katman bloğudur. Bu blokta sırası ile düzleştirme ve 3 adet tamamen bağlı katman bulunmaktadır.

VGG16 derin öğrenmede uygulama kolaylığı, basit yapısı ve görüntü sınıflamadaki başarısı nedeniyle yaygın olarak kullanılmaktadır. Günümüzde de popülerliğini korumaktadır.

### 2.3.2. VGG19

Çok katmanlı bir diğer mimaride VGG19 modelidir. Bu mimari VGG16 mimarisinin geliştirilmiş bir versiyonu olarak karşımıza çıkmaktadır. VGG16 mimarisinden farklı olarak daha derin bir ağ yapısına sahiptir. VGG19 mimarisi 143 milyondan fazla bir parametreye sahiptir [61]. Ağ mimarisinin derinleşmesinin en büyük avantajı farklı özelliklerin çıkartılması ve daha derin bilgileri ortaya çıkarmasıdır. Ama bununla birlikte işlem gücü gereksinimleri artmaktadır. Şekil 2.19'de VGG19 mimarisi gösterilmektedir.

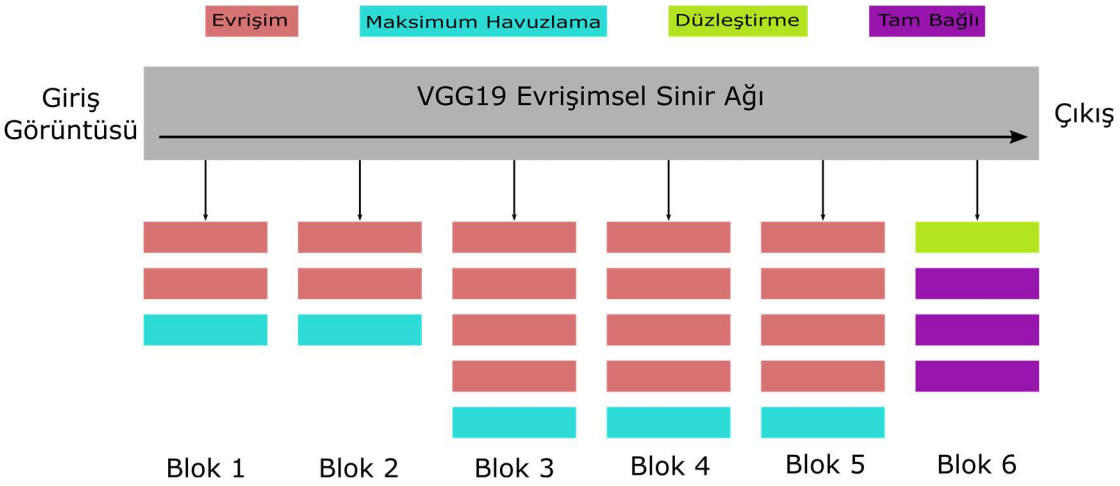


**Şekil 2.19.** VGG19 model mimarisi

Modelin giriş görüntüsü standart olarak renkli ve 224x224 piksel boyutunda olacak şekildedir. Modele görüntü verildikten sonra ilk olarak görüntünün boyutu kontrol edilmektedir. Görüntünün boyutu eğer gereken boyutta değilse yeniden boyutlandırılarak işleme alınmaktadır. Modelin filtreleri sabit boyutlu 3x3 piksel ve havuzlama filtreleri de 2x2 piksel boyutundadır. Bu model 6 blok olarak tasarlanmıştır. İlk evrişim bloğunda 64 filtre uygulanan 2 evrişim katmanı ve 1 adet maksimum havuzlama katmanı bulunmaktadır. Diğer bloktaki 2 evrişim katmanı 128 adet filtre ve peşine maksimum havuzlama katmanı uygulanmaktadır. Bir sonraki blokta ise 256 evrişim filtresinin uygulandığı 4 evrişim katmanı ile bir maksimum havuzlama katmanı bulunmaktadır. Dördüncü ve beşinci blokta ise 512 adet filtre uygulanan 4 adet evrişim katmanı ve maksimum havuzlama katmanı bulunmaktadır. Son katmanda ise düzleştirme katmanı ve 3 adet tamamen bağlı katman bulunmaktadır.

Günümüzde popüler ağlardan biri olan VGG19, görüntü sınıflamada başarısından dolayı sıklıkla kullanılmaktadır.

### 2.3.3. ResNet50

Resnet mimarisi diğer mimarilere göre daha derin bir ağ yapısına sahiptir. Bu ağ yapısı derinliğine göre --az karmaşıktır. İleri atlamalı bir yapıya sahiptir. 2015 yılında yapılan ILSVRC sınıflandırma yarışmasında en üst sırada yer almıştır [47]. Bu başarının sonucunda popüler hale gelmiştir. Resnet mimarisi katman sayısına göre isminde değişiklik olabilmektedir. Resnet50 modelinde 50 adet sinir ağı katmanı bulunmaktadır. Bu ağ yaklaşık olarak 26 milyon parametreye sahiptir [61]. Şekil 2.20'de modelin mimarisi gösterilmektedir.

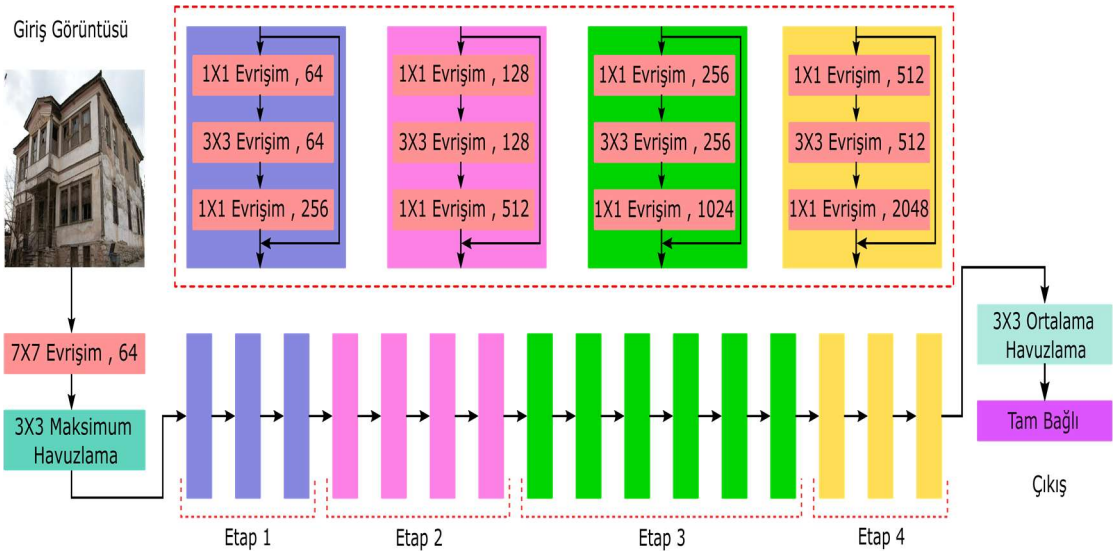


**Şekil 2.20.** Resnet50 model mimarisi

Bu modelde giriş görüntüsü renkli ve 224x224 piksel standardındadır. Görüntü verileri renkli veya renksiz olabilirler. Model 4 etap ve 18 blok olarak tasarlanmıştır. İlk blokta 7x7 piksel boyutunda 64 filtre uygulanan bir evrişim katmanı ve 3x3 piksel boyutlu bir maksimum havuzlama filtresi uygulanmaktadır. Bloktan sonra ilk etap gelmektedir. Bu etapta peş peşe aynı katmanların bulunduğu 3 blok bulunmaktadır. Bu bloklarda 1x1 piksel boyutlu 64 filtre uygulanan evrişim katmanı, 3x3 piksel boyutlu 64 filtre uygulanan evrişim katmanı ve 1x1 piksel boyutlu 256 adet filtre uygulanan evrişim katmanı bulunmaktadır. Bu bloka gelen özellik matrisinin bloğa girmeden önce bir kopyası alınmaktadır. Matris bloğa girmekte ve yeni oluşan ağırlıklarla çıkış matrisi oluşmaktadır. Bu modelde bir sonraki bloğa matris geçmeden önce bloğa girmeden önce alınan örneği ile toplanarak diğer bloğun giriş matrisi oluşturulmaktadır. Şekil 2.21'de örnek olarak verilen bir bloğun giriş ve çıkış matrisi gösterilmektedir.

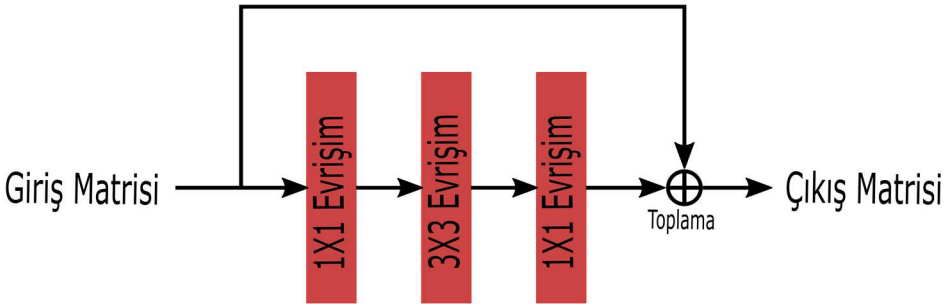


**Şekil 2.21.** Resnet bloğunun gösterimi

Bir sonraki etapta aynı katmanların bulunduğu 4 bloğa sahiptir. Blokların her birinde 1x1 piksel boyutlu 128 filtre, 3x3 piksel boyutlu 128 filtre ve 1x1 piksel boyutlu 512 filtre bulunduran evrişim katmanları bulunmaktadır. Her bloğun giriş matrisi ilk etapta

gösterilen şekilde oluşturulmaktadır. Üçüncü etapta ise aynı katman yapısına sahip 6 blok bulunmaktadır. Bu blokların her birinde 1x1 piksel boyutunda 256 filtreli evrişim katmanı, 3x3 piksel boyutlu 256 filtrenin uygulandığı evrişim katmanı ve 1x1 piksel boyutlu 1024 filtreli evrişim katmanı vardır. Her blok arasındaki matris diğer bloklarda olduğu gibidir. Son etapta ise 3 adet aynı blok bulunmaktadır. Bu blokların her birinde 1x1 boyutlu 512 filtre uygulanan evrişim katmanı, 3x3 boyutlu 512 filtreli evrişim katmanı ve 1x1 piksel boyutlu 2048 filtre bulunan evrişim katmanına sahiptir. Her bir blok için giriş matrisi diğer bloklarda hesaplandığı gibi hesaplanmaktadır. Son blokta ise havuzlama katmanı, düzleştirme katmanı ve tam bağlı katman bulunmaktadır. Havuzlama katmanında ortalama havuzlama filtresi uygulanmaktadır.

### 2.3.4. EfficientNet

EfficientNet çalışmasına kadar ortaya çıkan modeller karmaşıklığı ve model derinliğini arttırarak daha başarılı sonuçlar almışlardır. Ama ortaya çıkan modeller işlem verimliliği konusunda aynı başarıda değillerdir. Modellerin derinliği arttıkça başarı artmakta işlem verimliliği düşmektedir. Aynı veri setiyle daha uzun işlem gücüne gerek duymaktaydılar. EfficientNet, hem model başarısını arttırmayı hem de verimliliği arttırmayı bir arada sunmaktadır. Model verimliliğini üç ana parametrede gerçekleştirmektedir. Bunlar derinlik, genişlik ve çözünürlük parametreleridir [48]. Derinlik, ağların derinliğini ifade eden katmanların sayısına işaret etmektedir. Derin ağlar daha karmaşık ve ince özellikleri yakalayabilmekte, buda doğruluğu arttırmakta ama daha fazla işlem gücü gerektirmektedir. Genişlik, her bir ağ katmanındaki nöron sayısını göstermektedir. Her katmanın nöron sayısı ne kadar fazlaysa o kadar farklı özellik yakalanabilmektedir. Ama nöron sayısının modele göre belirli bir seviyeden sonra aynı doğruluk oranı doygunluğuna ulaşmaktadır. Çözünürlük, modelin giriş görüntüsünün boyutunu ifade etmektedir. Giriş görüntüsünün boyutu ne kadar yüksekse o kadar çok farklı ayırıcı özellik yakalanabilmektedir. Tabi ki boyut arttırıldığında işlem yükü de buna paralel olarak artacaktır. EfficientNet mimarisi, bu parametrelerin en optimum verimlilikte kullanılmasıyla ortaya çıkmıştır. Bu mimari modüler bir yapıya sahiptir. Şekil 2.22'de EfficientNet B0 mimarisi gösterilmektedir.

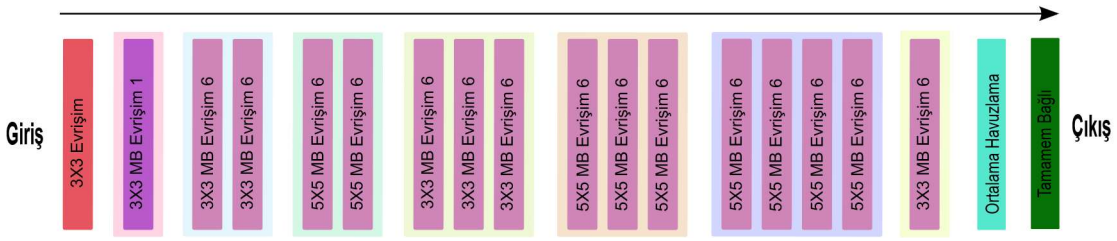


**Şekil 2.22.** EfficientNet B0 model mimarisi

Görselde giriş görüntüsünden sonra 1 adet evrişim katmanı ve onu takip eden MB Evrişim modülleriyle devam etmektedir. MB Evrişim bloklarının yapısı şekil 2.23'de gösterilmektedir.

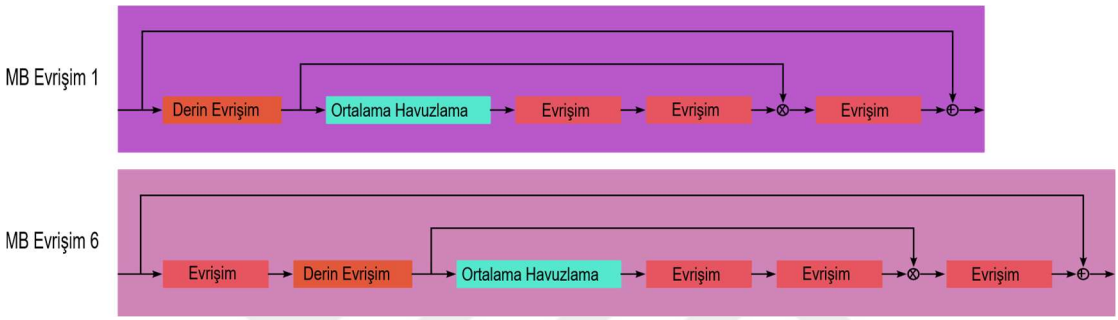


**Şekil 2.23.** MB Evrişim blokları

Model sırayla hangi MB Evrişim modülüne geliyorsa o blok işlemleri gerçekleştirilmektedir.

### 2.3.5. InceptionV3

InceptionV3 modeli kendinden önce geliştirilen inception mimarilerinin üzerine iyileştirilmeler yapılarak geliştirilmiş bir mimaridir. Önceki mimarilerine göre daha az kaynak ile daha çok işlem yapmaya odaklanmıştır. Bu mimariden önce iki adet inception modeli geliştirilmiştir. Bunlar InceptionV1 ve InceptionV2'dir. InceptionV3 modeli Szegedy C. ve arkadaşlarının [49] çalışması ile 2015 yılında "Rethinking the Inception Architecture for Computer Vision" adlı makale ile ortaya atılmış bir modeldir. InceptionV3 modeli yaklaşık 24 milyon parametreye sahip bir modeldir [61]. Bu modelinin diğer modellerden ayıran en önemli özelliği paralel yapıda işlem gerçekleştirmesidir. Diğer modellerde veriler sadece seri (peş peşe) işlenirken bu modelde bazı adımlar paralel de işlenebilmektedir. Örneğin bir resim 2 adet seri evrişim katmanından geçer bu işlem sonucunda oluşan matris, 3 paralel işlemden geçirilir. Bu paralel işlemlerden ilkinde tek evrişim katmanı, ikincisinde seri şekilde 2 evrişim katmanı ve havuzlama katmanı, üçüncüde ise seri olarak 1 evrişim katmanı ve 1

havuzlama katmanı olduğunu varsayalım. Paralel katmana gelen matris, her bir paralel katmanın girişi olur. Sonra bu katmanlardaki işlemler gerçekleştirilir. İşlemler sonucunda 3 farklı matris oluşur. Bu matrisler birleştirilir ve tek matris ortaya çıkar. Son oluşan matris kendinden sonra gelen katmana gider. Şekil 2.24'de InceptionV3 modelinin yapısı gösterilmektedir.

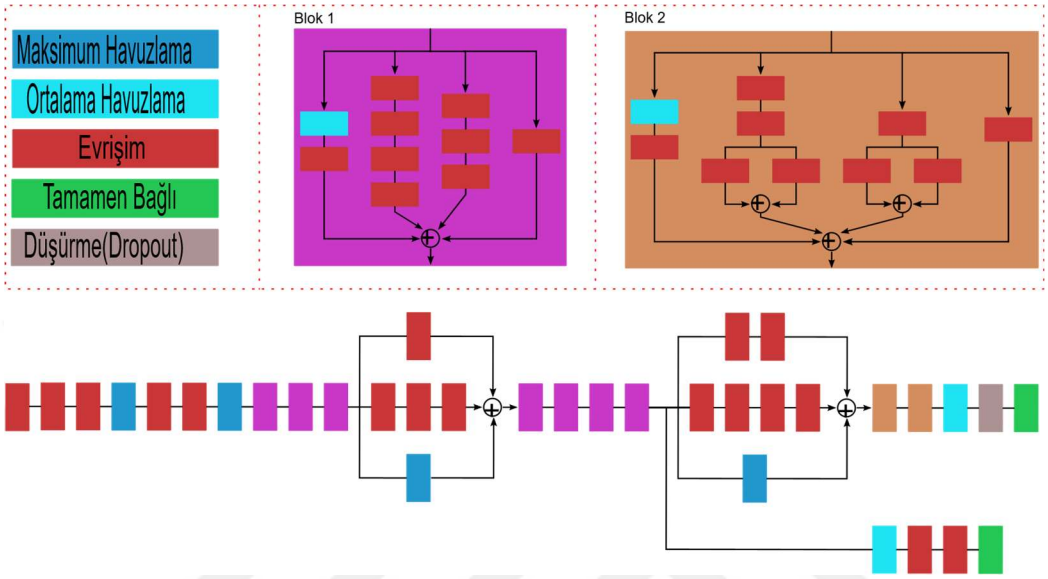


**Şekil 2.24.** InceptionV3 model mimarisi

# 3. MATERYAL VE YÖNTEM

Geliştirilen uygulama, python programlama dili [50] kullanılarak anaconda navigator ve spyder [51] programı yardımı ile gerçekleştirilmiştir. Anaconda navigator programı, yapay zekâ alanı başta olmak üzere yaygın olarak kullanılan birçok kütüphaneyi içermesi sebebiyle tercih edilmiştir. Anaconda navigator ile tüm python kütüphanelerine erişilebilir ve indirilebilir. İhtiyaç duyulan python kütüphaneleri indirildikten sonra gerekli python kodlarını yazmak için açık kaynak bir entegre geliştirme ortamı (Integrated Development Enviroment-IDE) olan spyder programı kullanılmıştır.

## 3.1. Veri Seti

Günümüzün ve geleceğin en önemli kaynaklarından bir tanesi olan veri, geliştirilen birçok uygulamanın başarıya ulaşmasında önemli rol oynamaktadır. Verilerin bir amaç doğrultusunda bir araya getirilmesi sonucu elde edilen yapılar veri seti olarak adlandırılmaktadır. Veri setleri ham verilerden oluşmaktadır. Analiz için hazır hale getirilmemiş veriler ham veri olarak tanımlanmaktadır [52]. Ham veriler, sayısal veriler, mantıksal veriler, ses verileri veya görüntü verileri gibi birçok farklı türde olabilmektedirler. Bu farklılığa bağlı olarak da birçok veri seti türü olabilmektedir. Veri setleri derin öğrenmenin en önemli parçalarından bir tanesidir. Derin öğrenme tabanlı uygulamaların başarısının altındaki en önemli parametrelerin başında veri seti gelmektedir. Veri setinin kapsamı, boyutu (veri çokluğu) ve çalışmaya uygunluğu oldukça önemlidir. Amacına uygun seçilmemiş veri setiyle yapılan çalışmalardan başarılı sonuç bekleyemeyiz. Bu nedenle, geliştirilen uygulama için doğru veri seti seçilmeli, eğer amaca uygun veri seti bulunamıyor ise çalışmanın amacına uygun yeni veri seti oluşturulmalıdır. Veri seti, veri toplama ve veri hazırlama olmak üzere 2 aşama sonucunda oluşturulmaktadır.

### 3.1.1. Veri Toplama

Çalışma için gerekli olan veriler, Aralık 2020 tarihinde 5 günlük bir süre içerisinde gündüz saatlerinde, 10 ile 18 saatleri arasında çekilen fındık meyvelerinin görüntülerinden elde edilmiştir. Bu verileri elde ederken “iphone 6s” telefonun arka kısmında bulunan ana kamerası kullanılmıştır. Kullanılan bu kamera 12 mega piksel

çözünürlüğe sahiptir. Görüntüler kare olarak 3024x3024 piksel çözünürlüğünde ve renkli olarak çekilmiştir. Bir platform yardımıyla telefonun kamerası dikey olarak aşağıya bakacak şekilde 10 cm ile 8 cm arasında yükseklikten el ile çekilmiştir. Kullanılan platform şekil 3.1'de gösterilmektedir.



**Şekil 3.1.** Veri seti için oluşturulan platform

Her bir görüntüde sadece 1 adet fındık görüntüsü bulunmaktadır. Fındıklar iyi fındık, kötü fındık ve iç fındık olmak üzere 3 farklı sınıfta uzman bir kişi tarafından seçilmiştir. İyi fındıktan 535 adet, kötü fındıktan 519 adet ve iç fındıktan ise 523 adet fındık veri setini oluşturmada kullanılmıştır. Bir fındıktan farklı açılarda olmak üzere 10 farklı görüntü alınmıştır. Toplamda 15770 adet fındık görüntüsünden meydana gelmiş bir veri seti oluşturulmuştur. Bu bilgileri gösteren bilgiler Tablo 3.1'de gösterilmektedir. Şekil 3.2'de ise her bir sınıftan seçilen bir fındığın farklı açılardan çekilmiş görüntüleri gösterilmektedir.

**Tablo 3.1.** Fındıklardan alınan görüntü sayıları

| | **Fındık sayısı** | **Her bir fındıktan alınan görüntü sayısı** | **Toplam alınan görüntü sayısı** |
|---|---|---|---|
| **İyi fındık** | 535 | 10 | 5350 |
| **Kötü fındık** | 519 | 10 | 5190 |
| **İç fındık** | 523 | 10 | 5230 |
| **Toplam** | | | 15770 |

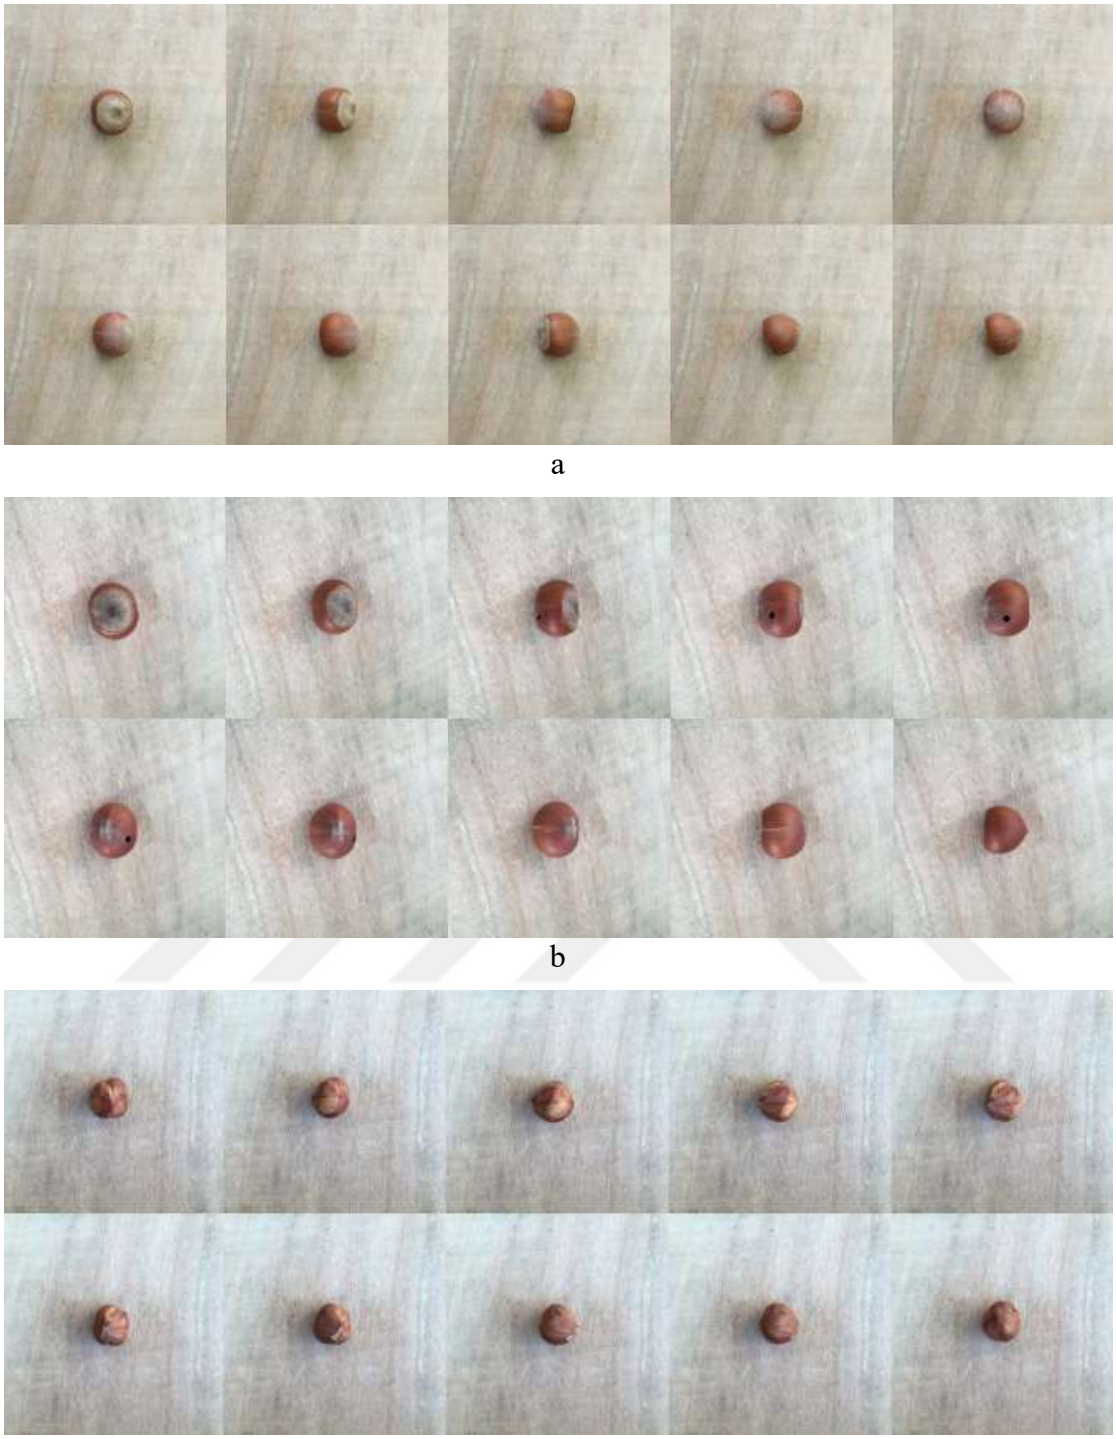

**Şekil 3.2.** Farklı açılardan çekilmiş fındık resimleri, (a) sağlam fındık, (b) kötü fındık, (c) iç fındık.

### 3.1.2. Veri Hazırlama

Görüntüler elde edildikten sonra oluşan veri setinin toplam boyutu 70 GB tan fazladır. Bu kadar yüksek boyuttaki veriyi işlemek hem zaman bakımından hem de çalışmada kullanılacak sistem açısından kullanılabilir düzeyde değildir. Verilerin elde edilip, boyut indirgeme ve etiketleme gibi işlemlerden geçirilerek modelin kullanımına hazır duruma getirilmesi için yapılan işlemler Şekil 3.3'te yer alana akış şemasında gösterilmektedir.

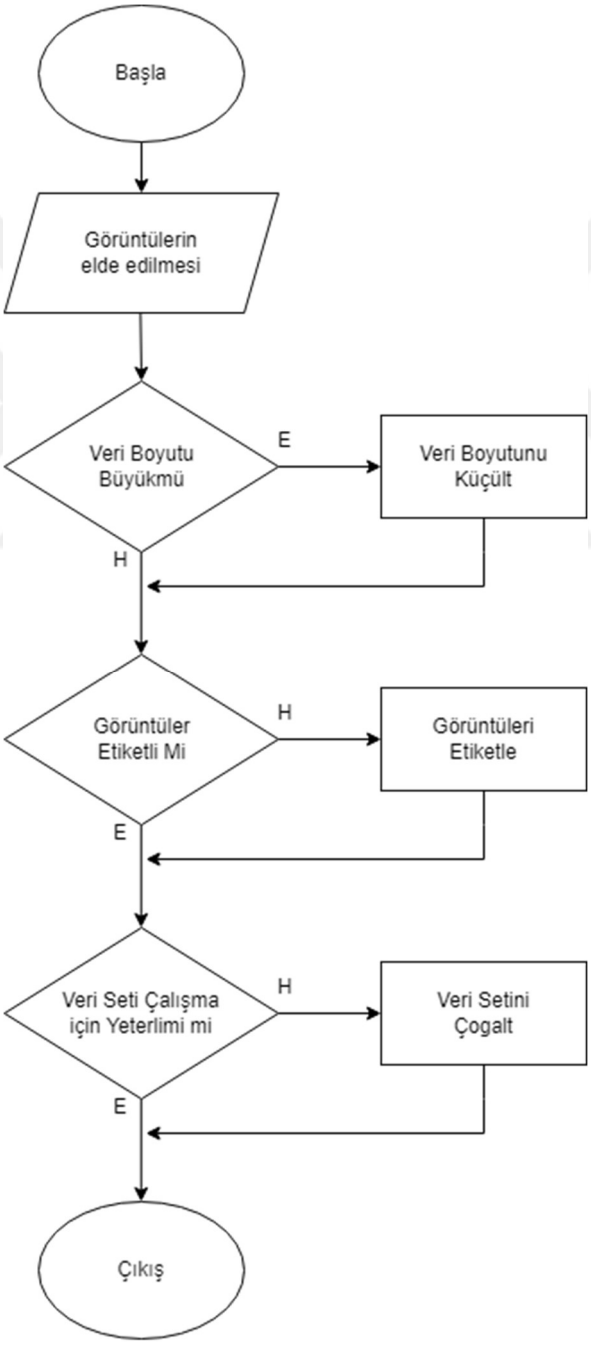


**Şekil 3.3.** Veri hazırlama sürecinin akış şeması

Veriler elde edildikten sonra, ilk olarak görüntülerden fazlalık alanlarının atılması için 1000x1000 piksel boyutunda kırpma işlemi gerçekleştirilmiştir. Kırpma işleminden sonra oluşan yeni görüntüler, çalışmada kullanılacak olan hazır modelin giriş görüntü boyutu olan 224x224 piksel değerlerinde yeniden boyutlandırma işlemine tabi tutulmuşlardır. Görüntünün rengi ile ilgili herhangi bir işlem gerçekleştirilmemiştir. Şekil 3.4'de veri setinden rasgele seçilmiş olan bir fındığın (a) 3024x3024, (b) 1000x1000 ve (c) 224x224 piksel çözünürlükteki görüntüleri gösterilmektedir.



a b c

**Şekil 3.4.** (a) 3024x3024 piksel kırpılmamış görüntü, (b) 1000x1000 piksel kesilmiş görüntü, (c) 224x224 piksel görüntü

Bu işlemler sonucunda kullanacağımız modele uygun toplam boyutu yaklaşık olarak 1.2 GB olan, renkli görüntülerden meydana gelen bir veri seti oluşturulmuştur. Görselleri yeniden boyutlandırmak için gerçekleştirilen işlemler "FSResizer" programı yardımıyla yapılmaktadır. Bu programın kullanım amacı toplu olarak görüntüleri işleme yeteneğidir. Görüntüleri etiketleme işlemi manuel olarak gerçekleştirilmektedir. Her resimde sadece bir adet fındık olduğu için R programı kullanılarak csv formatında hangi fındığın hangi türde olduğu işaretlenmiştir. Veri setindeki görüntülerin, %60'ı

eğitim (train), %28'i doğrulama (validation) ve %12'si de test verisi olarak kullanılmıştır. Veri setinde çok sayıda görüntü olması sebebiyle herhangi bir veri çoğaltma işlemi gerçekleştirilmemiştir. Gelecekte gerçekleştirilecek çalışmalara katkı sağlamak amacıyla çalışmada oluşturulan veri seti https://data.mendeley.com/datasets/dvvx6kst3f/2 linkinden paylaşıma sunulmuştur.

### 3.2. Algoritmalar

Derin öğrenme denilince ilk akla gelen ağ modellerinin başında Evrişimsel sinir ağları gelmektedir. Bu ağların başarısı ses ve görüntü tabanlı uygulamalarda öne çıkmaktadır. Katmanlı bir mimariye sahip olan Evrişimsel sinir ağının diğer ağlardan en büyük farkı gizli katmanlara sahip olmasıdır. Bu ağlarda değişik modeller farklı sayıda katmana sahip olabilmektedir. Farklı ve karmaşık yapıda birçok modeli bulunan Evrişimsel sinir ağları en basit haliyle giriş katmanı, 2 tane evrişim katmanı, 2 tane havuzlama katmanı, düzleştirme katmanı, tam bağlı katman ve çıkış katmanı olmak üzere toplamda 8 katmandan meydana gelmektedir [53]. Şekil 3.5' de basit bir Evrişimsel sinir ağının yapısı gösterilmektedir.

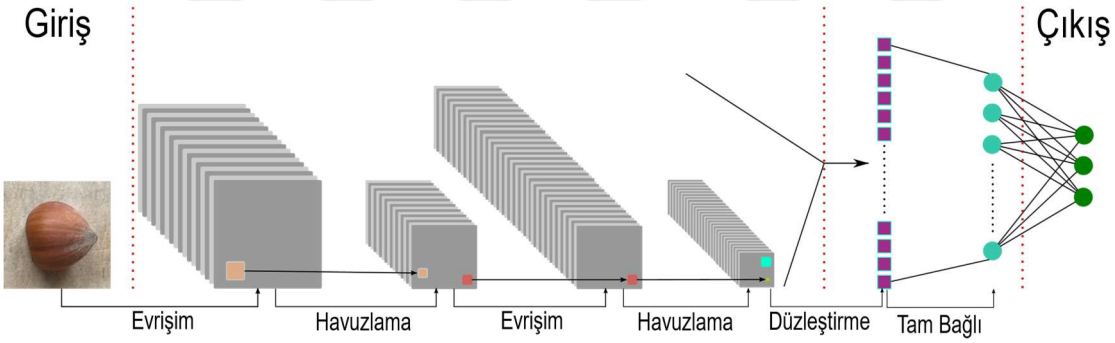


**Şekil 3.5.** Evrişimsel sinir ağı yapısı

Bu ağ için gösterilen model sıralı şekilde işlemleri yürütmektedir. Bir başka ifade ile bir katmanın çıktısı diğer katmanın girdisi olacak şekilde çalışmaktadır. Modelin giriş katmanına sayısallaştırılmış görüntü girdi olarak verilmektedir. Giriş katmanından sonra evrişim katmanına gelen görüntüye farklı filtreler uygulanarak farklı özellik çıkartma işlemi gerçekleştirilmektedir. Sonra havuzlama katmanına gelen görüntü burada uygulanan filtreye göre, piksel boyutu küçültülerek diğer katmana gönderilir. Tekrar evrişim katmanına gelen veri burada tekrar farklı özellikleri de çıkarılıp havuzlama katmanına gönderilir. Havuzlama katmanından sonra oluşan veri düzleştirilerek tek boyutlu bir diziye dönüştürülür. Bu işlemden sonra tam bağlı

katmanlarda istenilen boyut kadar otomatik olarak özellik seçme işlemi gerçekleştirilmektedir. Son olarak da bu özellikler yardımıyla sınıflama işlemi gerçekleştirilerek çıkış katmanına vermektedir.

Çalışmada VGG16, Resnet50 ve InceptionV3 olmak üzere 3 farklı model kullanılarak sonuçlar elde edilmiştir.

# 4. SONUÇ VE ÖNERİLER

Bu bölümde fındık meyvesinin derin öğrenme kullanılarak sınıflandırma işleminin yapıldığı sistem bilgisi, deneylerde kullanılan performans ölçütleri, kullanılan derin öğrenme modellerinin fındık veri seti üzerinde test edilmesi, deney sonuçları ve modellerin başarılarının karşılaştırılması durumlarından bahsedilmektedir.

## 4.1. Deney ortamı

Çalışmada kullanılan bilgisayar üzerinde Windows 10 işletim sistemi koşturulmaktadır. Bilgisayar, intel core i7-7700k 4.2 Ghz işlemci, Gtx 1080ti 11Gb grafik işlemci, 32 gb ram, 512 gb ssd ve 1 tb hdd donanım özelliklerine sahiptir. Derin öğrenme modeli için Python 3.8 programlama dili ve kütüphaneler kullanılarak deneysel ortam hazırlanmıştır. Deneysel ortamda tensorflow [54], keras [55], opencv [56], numpy [57], pandas [58], matplotlib [59], sklearn [60] gibi kütüphaneler kullanılmıştır.

## 4.2. Performans Metrikleri

Çalışmada modellerin performansını ayrıntılı şekilde ölçebilmek için karmaşıklık matrisi [63] kullanılmaktadır. Karmaşıklık matrisinden elde edilen doğruluk, kesinlik, duyarlılık ve f1 skor gibi ölçütlerden yararlanılmaktadır. Bu karmaşıklık matrisi tablo 4.1'de gösterilmektedir.

**Tablo 4.1.** Karmaşıklık Matrisi

| | | **Tahmin** | |
|---|---|---|---|
| | | **Pozitif** | **Negatif** |
| **Gerçek** | **Pozitif** | Doğru Pozitif (TP) | Yanlış Negatif (FN) |
| | **Negatif** | Yanlış Pozitif (FP) | Doğru Negatif (TN) |

Doğru pozitif (TP) ve doğru negatif (TN) değerleri tahmin edilen değerlerle gerçek değerlerin aynı olduğunu, yanlış pozitif (FP) ve yanlış negatif (FN) değerleri ise tahmin edilen değerlerle gerçek değerlerin birbirinden farklı olduğunu ifade etmektedir. Doğruluk, tüm doğru tahminlerin tüm tahminlere bölünmesinin sonucunda ortaya çıkan değerdir. Denklem 4.1'de doğruluk formülü gösterilmektedir.

$$Doğruluk = \frac{TP+TN}{TP+FP+FN+T} \tag{4.1}$$

Kesinlik, pozitif olarak tahmin edilen değerin tüm pozitif değerlere bölünmesi ile elde edilmektedir. Denklem 4.2'de kesinlik formülü gösterilmektedir.

$$Kesinlik = \frac{TP}{TP+FP} \tag{4.2}$$

Duyarlılık, doğru pozitif olarak tahmin edilen değerlerin toplam gerçek pozitif değerine bölünmesiyle ortaya çıkmaktadır. Denklem 4.3'te duyarlılık gösterilmektedir.

$$Duyarlılık = \frac{TP}{TP+FN} \tag{4.3}$$

F1 skor, bu metrik kesinlik ve duyarlılık metriklerini birleştirerek kullanılmaktadır. Kesinlik ve duyarlılığın çarpımının iki katının kesinlik ve duyarlılığın toplamına bölünmesiyle oluşan bir metriktir. Denklem 4.4'te f1 skor gösterilmektedir.

$$F1 - skor = 2 * \frac{Kesinlik * Duyarlılık}{Kesinlik + Duyarlılık} \tag{4.4}$$

### 4.3. Çalışma Sonuçları

Çalışma sonucunda geliştirilen algoritmaların fındıkların sınıflandırmasını yüksek doğruluk ile gerçekleştirdiği görülmüştür. Evrişimli sinir ağları kullanılarak geliştirilen çalışmalarda büyük bir veri setinin varlığı çok önemlidir. Bu çalışmada kullanılan büyük boyutlu (15 binden fazla görüntüden oluşan) veri seti, çalışma sonucunda yüksek doğruluğun elde edilmesinde önemli rol oynamıştır. Tablo 4.2'de görüldüğü gibi VGG16 modelinin F1 puanının 0.98'in üzerinde olduğu görülmektedir. Tablo 4.3'de ise InceptionV3 modelinin F1 puanının 0.96'dan yüksek olduğu görülmekte, Tablo 4.4'te ise Resnet50 modelinin F1 puanı gösterilmektedir.

**Tablo 4.2.** VGG16 modelinin sonuçları

| | **İyi Fındık** | **İç Fındık** | **Kötü fındık** |
|---|---|---|---|
| **Gerçek Pozitif** | 649 | 635 | 585 |
| **Yanlış Pozitif** | 10 | 9 | 5 |
| **Kesinlik (Precision)** | 0.9848 | 0.9922 | 0.9848 |
| **Duyarlılık (Recall)** | 0.9848 | 0.9860 | 0.9915 |
| **F1 skoru** | 0.9848 | 0.9891 | 0.9882 |

**Tablo 4.3.** InceptionV3 modelinin sonuçları

| | **İyi Fındık** | **İç Fındık** | **Kötü fındık** |
|---|---|---|---|
| **Gerçek Pozitif** | 639 | 621 | 566 |
| **Yanlış Pozitif** | 20 | 23 | 24 |
| **Kesinlik (Precision)** | 0.9411 | 0.9857 | 0.9692 |
| **Duyarlılık (Recall)** | 0.9697 | 0.9643 | 0.9593 |
| **F1 skoru** | 0.9552 | 0.9749 | 0.9642 |

**Tablo 4.4.** Resnet50 modelinin sonuçları

| | **İyi Fındık** | **İç Fındık** | **Kötü fındık** |
|---|---|---|---|
| **Gerçek Pozitif** | 582 | 581 | 519 |
| **Yanlış Pozitif** | 77 | 63 | 71 |
| **Kesinlik (Precision)** | 0.8805 | 0.8952 | 0.8902 |
| **Duyarlılık (Recall)** | 0.8832 | 0.9022 | 0.8797 |
| **F1 skoru** | 0.8818 | 0.8987 | 0.8882 |

Şekil 4.1'de VGG16, InceptionV3 ve Resnet50 modellerinin eğitim sonucunda oluşturdukları ağırlıklar kullanılarak test veri seti üzerinde doğru ve yanlış tahminleri, tahmin ettiği yanlış tahminlerin hangi sınıfta olduğunu göstermekte olup şekil 4.2'de ise bu değerlerin daha anlaşılır olması için sayıların 0 ile 1 arasına indirgenmiş hali gösterilmektedir.

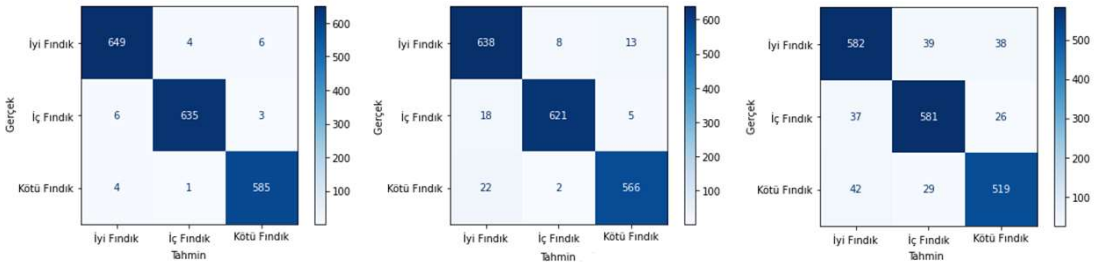


a b c

**Şekil 4.1.** (a) VGG16, (b) InceptionV3 ve (c) Resnet50 gerçek ve tahmin değerleri

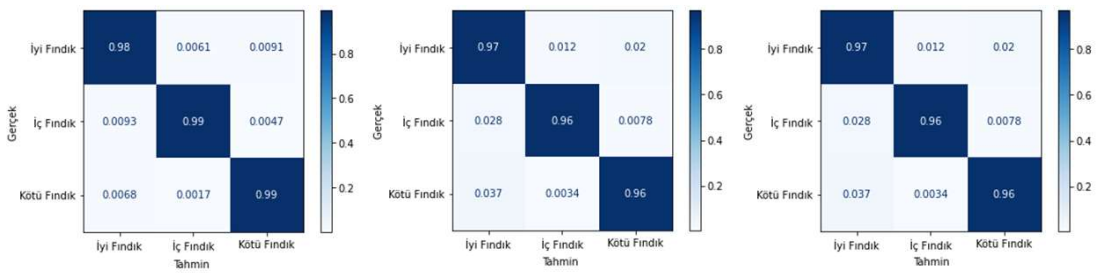


a b c

**Şekil 4.2**. (a) VGG16, (b) InceptionV3 ve (c) Resnet50 sayısal verilerin 0-1 arasına indirgenmiş halleri

Gerçekleştirilen uygulamada, çalışma için oluşturulan fındık veri seti VGG16, InceptionV3 ve Resnet50 derin öğrenme modelleri kullanılarak sınıflandırılmıştır. Kullanılan fındık veri setinde 3 farklı sınıftan toplam 15770 fındık görüntüsü bulunmaktadır. Tablo 4.5'te görüldüğü gibi modellerin öğrenme oranı (learning rate) 0.0000001, gruplama boyutu (batch size) 64 ve adım sayısı (epoch) 250 olarak eğitilmişlerdir.

**Tablo 4.5.** Modellerin eğitim ayarları

| Model ismi | Öğrenme Oranı | Gruplama Boyutu | Adım Sayısı |
|---|---|---|---|
| **VGG16** | 0.0000001 | 64 | 250 |
| **InceptionV3** | 0.0000001 | 64 | 250 |
| **Resnet50** | 0.0000001 | 64 | 250 |

VGG16 modelinin eğitimi sonucunda doğruluk 0.9938, doğrulama doğruluğu 0.9887, test doğruluğu 0.9873, kayıp 0.0281 ve doğrulama kaybı 0.0393 olarak bulunmuştur. InceptionV3 modelinin eğitimi sonucunda eğitim doğruluğu 0.9775, doğrulama doğruluğu 0.9701, test doğruluğu 0.9640, eğitim kaybı 0.0740 ve doğrulama kaybı 0.0878 olarak çıkmıştır. Son olarak Resnet50 modelinin doğruluğu 0.9220, doğrulama doğruluğu 0.8797, test doğruluğu 0.8885, kayıp 0.2225 ve doğrulama kaybı 0.3218 olarak ortaya çıkmıştır. Kullanılan modeller sonucunda elde edilen doğruluk ve kayıp değerleri tablo 4.6'te ve şekil 4.3'teki grafiklerde sunulmuştur.

**Tablo 4.6.** Modellerin eğitim sonucunda oluşan değerleri

| Modeller | Eğitim Doğruluğu | Doğrulama Doğruluğu | Eğitim Kaybı | Doğrulama Kaybı | Test Doğruluğu |
|---|---|---|---|---|---|
| **VGG16** | 0.9938 | 0.9887 | 0.0281 | 0.0393 | 0.9873 |
| **InceptionV3** | 0.9775 | 0.9701 | 0.0740 | 0.0878 | 0.9640 |
| **Resnet50** | 0.9220 | 0.8797 | 0.2225 | 0.3218 | 0.8885 |

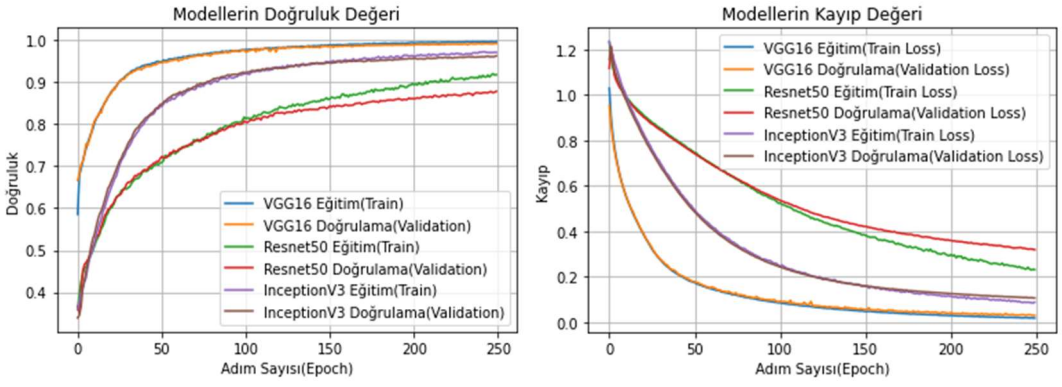


a b

**Şekil 4.3.** (a) modellerin doğruluk değerleri, (b) modellerin kayıp değerleri

Çalışmanın ikinci adımında, kullanılan veri seti boyutunun elde edilen sonuçlar üzerindeki etkisini gözlemlemek için veri seti Tablo 4.7'de gösterildiği gibi farklı boyutlarda yeniden oluşturulmuştur. Oluşturulan veri setleri içerisindeki test verilerinin ayrıntıları tablo 4.8'de gösterilmektedir. 15770 görüntüden oluşan veri setinin tamamı kullanıldığında elde edilen sonuçlara ek olarak, veri setinin %10'u, %25'i ve %50'si kullanılarak modellerin sonuçları alınmıştır. Böylece farklı sayıda görüntü kullanıldığında modeller ile elde edilen sonuçlar karşılaştırmalı olarak sunulmuştur.

**Tablo 4.7.** Bölümlenmiş veri seti

| | **Eğitim** | **Doğrulama** | **Test** | **Toplam** |
|---|---|---|---|---|
| **Veri setinin %10'u** | 946 | 441 | 190 | 1577 |
| **Veri setinin %25'i** | 2365 | 1103 | 474 | 3942 |
| **Veri setinin %50'si** | 4731 | 2207 | 947 | 7885 |
| **Veri setinin tamamı** | 9462 | 4415 | 1893 | 15770 |

**Tablo 4.8.** Veri seti boyutuna göre test verisinin değişimi

| | **İyi fındık** | **İç fındık** | **Kötü Fındık** | **Toplam** |
|---|---|---|---|---|
| **Veri setinin %10'u** | 64 | 73 | 53 | 190 |
| **Veri setinin %25'i** | 156 | 164 | 154 | 474 |
| **Veri setinin %50'si** | 316 | 334 | 297 | 947 |
| **Veri setinin tamamı** | 659 | 644 | 590 | 1893 |

Çalışmada kullanılan VGG16, InceptionV3 ve Resnet50 modelleri, farklı sayıda fındık görüntüsünden oluşan veri setleri kullanılarak test edilmektedir. Toplam veri seti içerisinde test için ayırılan veriler kullanılarak modellerin test verisi üzerindeki başarısı şekil 4.4'te ayrıntılı şekilde gösterilmektedir. Veri setinde 15770 görüntü bulunduğunda algoritmaların test verisi üzerindeki test doğruluğu oranları VGG16 için %99'a yakın, InceptionV3 için %96 ve Resnet50 de %89'a ulaşmıştır. Ancak veri setinin %50'si yani 7885 görüntü kullanıldığında test doğruluğu oranları sırasıyla %95, %92 ve %80'e düşmüştür. Veri setinin %25'i alınarak 3942 görüntü kullanıldığında test başarı oranları sırasıyla %92, %83, %70'tür. Son olarak 1577 görüntü ile veri setinin %10'u kullanıldığında doğru tahmin oranları sırasıyla %88, %72, %56'ya düştüğü görülmüştür. Tablo 4.9'ta bu sonuçlar karşılaştırmalı olarak sunulmaktadır. Sonuçlar, tüm veri kümesinin kullanılması ile veri kümesinin %10'unun kullanılması arasında, doğru tahmin oranının düştüğünü göstermektedir.

**Tablo 4.9.** Veri seti boyutuna göre modellerin test verisindeki sonuçları.

| | VGG16 F1 Skoru | InceptionV3 F1 Skoru | Resnet50 F1 Skoru |
|---|---|---|---|
| **Veri setinin %10'u** | 0.8842 | 0.7211 | 0.5632 |
| **Veri setinin %25'i** | 0.9262 | 0.8376 | 0.7046 |
| **Veri setinin %50'si** | 0.9546 | 0.9261 | 0.8046 |
| **Veri setinin tamamı** | 0.9873 | 0.9646 | 0.8885 |

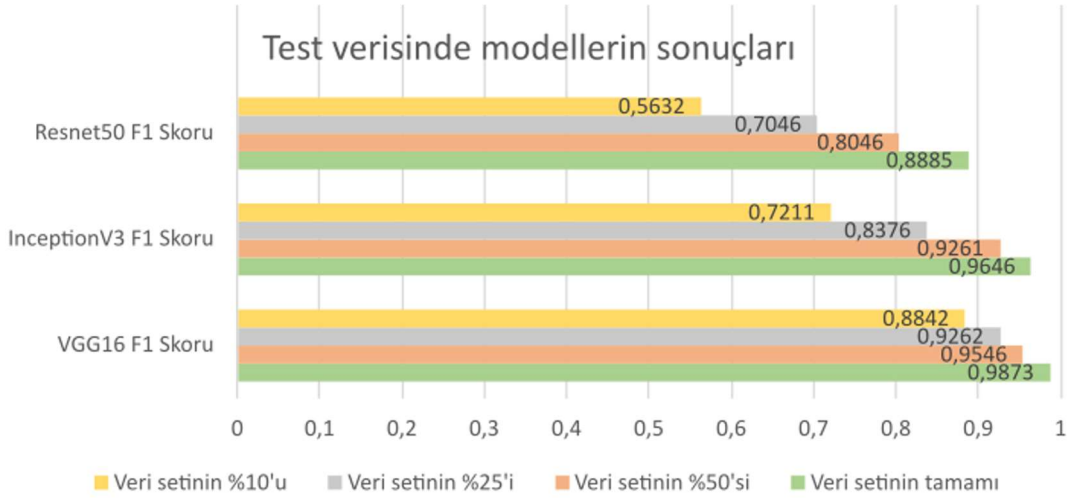


**Şekil 4.4.** Modellerin test veri setindeki başarıları

Çalışma sonucunda çalışma için hazırlanan veri seti için en uygun modelin VGG16 olduğu görülmüştür. VGG16 modelin diğer modellerden daha başarılı sonuç vermesinin en büyük nedeni parametre sayısının diğer modellerden oldukça fazla olmasıdır. Bu çalışma sonucunda diğer bir çıkarım ise veri seti boyutunun model başarısına olan etkisi olarak görülmektedir. Veri setini 15770 adetten 1500 adet veriye indirdiğimizde VGG16 modelinin başarısı %99'dan %88'e kadar düştüğü, InceptionV3 modelinin de başarısının %96'dan %72'ye ve Resnet50 modelinin başarısının da %89'dan %56'ya kadar düştüğü çalışma sonucunda ortaya çıkmaktadır. Son olarak şekil 4.5'te modellerin başarısız sınıflandırma yaptığı resimler gösterilmektedir. Şekil 4.5.a da iç fındık olarak tahmin edilen fındık gerçekte iyi fındık sınıfına aittir. Şekil 4.5.b de ise kötü fındık sınıfına sahip resmi model iyi fındık olarak tahmin emiştir. Son olarak şekil 4.5.c de model resmin sınıflandırmasını iyi fındık olarak yapmasına rağmen fındığın gerçek sınıfı iç fındıktır.

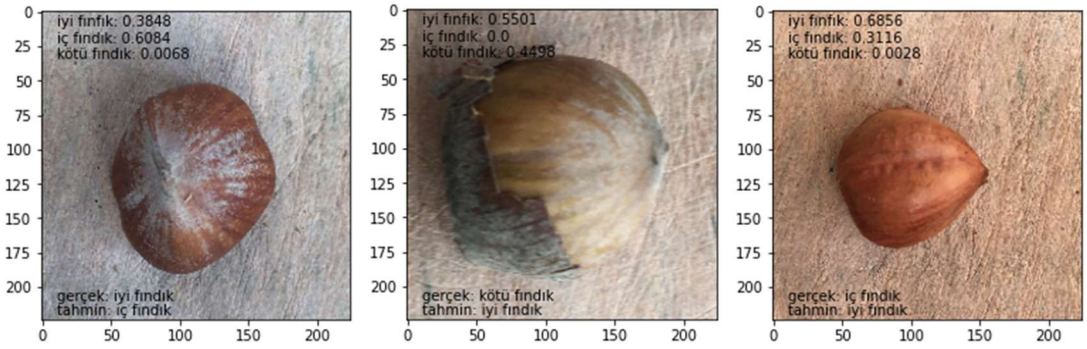


a b c

**Şekil 4.5.** Başarısız sınıflandırılmış fındık resimleri

Fındık tarımı Karadeniz bölgesi için önemli geçim kaynaklarında biridir. Karadeniz bölgesinin özellikle orta ve doğu bölgelerinin engebeli yapısı tarımda teknolojinin kullanılmasını sınırlandırmaktadır. Buna rağmen fındık tarımında teknolojinin faydalarından koşulların elverdiği ölçüde yararlanılmaktadır. Fındık tarımında üreticinin ürünü satmadan veya depolamadan önce en son yaptığı işlem fındıkların temizlenmesidir. Temizleme işlemini üç ana sınıfta düşünülebilir. Bunlar iyi fındık, iç fındık ve kötü fındıktır. Temizleme işleminde fındıkların içerisinden iç fındıklar ve kötü fındıklar temizlenmektedir. Eğer ki fındık kötü fındıklardan arındırılmaz ise satış zamanında randımanı düşük gelecek ve üretici gelir kaybına uğrayacaktır. İç fındıklar temizlenmez ise depolama yapıldığında bu fındıklar bozulacaktır ve satış yapılmadan önce temizlenmesi gerekebilmektedir. Bu işlem, insan gücünden yararlanılarak yapılmaktadır. Her fındığa tek tek insanın bakması uzun zaman alan, yapılması zor bir iştir. Bu yüzden genellikle temizleme işleminde temizleme işlemi üstünkörü (çok dikkat edilmeden) yapılmaktadır. Bu yüzden fındıkların içerisinde iç fındık ve kötü fındıkların kalması kuvvetle muhtemeldir. Buda maddi açıdan üreticilere satışta yansımaktadır. Bu tez çalışmasında akademik olarak fındık temizleme işlemi için derin öğrenme teknolojisinden yararlanılmak başarısını ölçmek ve uygulanabilir olup olmadığını araştırmaktı. Çalışma sonucunda derin öğrenmenin bu işlem için kullanılabileceği deneysel veriler sonucunda ortaya çıkmıştır. Çalışma tamamen bilgisayar ortamında geliştirildiği için yüzde 100 bu işlem için kullanılabilir dememiz doğru olmayacaktır. Ama çalışmanın reel ortamda da bu başarıya ulaşması düşünülürse fındık üreticileri için daha az ücret kaybı ve zaman kaybının önüne geçme potansiyeline sahiptir.

Oluşturulan fındık veri setinin deneysel ortamda derin öğrenme modellerinde yüksek doğrulukta sınıflandırıldığı görülmektedir. Sonuçta, oluşturulan veri setinin

kullanılabilir olduğu görülmektedir. Derin öğrenme modellerinin ise deneysel ortamındaki başarıları sırasıyla VGG16 %98, InceptionV3 %96 ve Resnet50 modeli ise %88 olarak ölçülmüştür. Bu bilgiler ışığında derin öğrenme modelleri fındık veri setinde başarılı sonuçlar elde etmiştir. Gelecek çalışmada ise fındıkların sınıflandırılmasıyla ilgili gerçek bir test ortamı oluşturulup fındık veri setiyle eğitilmiş modellerin başarısını ölçmek ve bunları deneysel ortamdaki sonuçlarla karşılaştırmak olacaktır.

# KAYNAKLAR

[1] Görmüş, A., (2019). Türkiye'de tarımsal istihdamın cinsiyete dayalı yapısı ve sosyal politika önerileri. Eskişehir Osmangazi Üniversitesi İktisadi ve İdari Bilimler Dergisi, 14(3), 563-578.

[2] Harman, C., (2014). Karadeniz Bölgesindeki endemik tarım ürünleri: Fındık, çay ve kivinin üretimi, pazarlanması ve tüketimi. Yüksek Lisans Tezi, Giresun Üniversitesi Sosyal Bilimler Enstitüsü, Giresun, Türkiye, 1-39.

[3] Chiu, M. T., Xu, X., Wei, Y., Huang, Z., Schwing, A. G., Brunner, R., . . . Rose, G., (2020). Agriculture-vision: A large aerial image database for agricultural pattern analysis. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition.

[4] Nguyen, T. T., Hoang, T. D., Pham, M. T., Vu, T. T., Nguyen, T. H., Huynh, Q.-T., Jo, J., (2020). Monitoring agriculture areas with satellite images and deep learning. Applied Soft Computing, 95, 106565.

[5] Liu, X., Ghazali, K. H., Han, F., Mohamed, I. I., (2021). Automatic detection of oil palm tree from UAV images based on the deep learning method. Applied Artificial Intelligence, 35(1), 13-24.

[6] Aguiar, A. S., Dos Santos, F. N., De Sousa, A. J. M., Oliveira, P. M., Santos, L. C., (2020). Visual trunk detection using transfer learning and a deep learning-based coprocessor. IEEE Access, 8, 77308-77320.

[7] Sun, Z., Di, L., Fang, H., Burgess, A., (2020). Deep learning classification for crop types in north dakota. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 13, 2200-2213.

[8] Yamaguchi, T., Tanaka, Y., Imachi, Y., Yamashita, M., Katsura, K., (2020). Feasibility of combining deep learning and rgb images obtained by unmanned aerial vehicle for leaf area index estimation in rice. Remote Sensing, 13(1), 84.

[9] Kalantar, A., Edan, Y., Gur, A., Klapp, I., (2020). A deep learning system for single and overall weight estimation of melons using unmanned aerial vehicle images. Computers and Electronics in Agriculture, 178, 105748.

[10] Jin, X.-B., Yang, N.-X., Wang, X.-Y., Bai, Y.-T., Su, T.-L., Kong, J.-L., (2020). Hybrid deep learning predictor for smart agriculture sensing based on empirical mode decomposition and gated recurrent unit group model. Sensors, 20(5), 1334.

[11] Basha, C. Z., Bhavana, N., Bhavya, P., Sowmya, V., (2020). Rainfall prediction using machine learning & deep learning techniques. 2020 International Conference on Electronics and Sustainable Communication Systems (ICESC).

[12] Guillén-Navarro, M. A., Martínez-España, R., Llanes, A., Bueno-Crespo, A., Cecilia, J. M., (2020). A deep learning model to predict lower temperatures in agriculture. Journal of Ambient Intelligence and Smart Environments, 12(1), 21-34.

[13] Somov, A., Shadrin, D., Fastovets, I., Nikitin, A., Matveev, S., Hrinchuk, O., (2018). Pervasive agriculture: IoT-enabled greenhouse for plant growth control. IEEE Pervasive Computing, 17(4), 65-75.

[14] Esgario, J. G., Krohling, R. A., Ventura, J. A., (2020). Deep learning for classification and severity estimation of coffee leaf biotic stress. Computers and Electronics in Agriculture, 169, 105162.

[15] Zhong, Y., Zhao, M., (2020). Research on deep learning in apple leaf disease recognition. Computers and Electronics in Agriculture, 168, 105146.

[16] Grinblat, G. L., Uzal, L. C., Larese, M. G., Granitto, P. M., (2016). Deep learning for plant identification using vein morphological patterns. Computers and Electronics in Agriculture, 127, 418-424.

[17] Aitkenhead, M., Dalgetty, I., Mullins, C., McDonald, A. J. S., Strachan, N. J. C., (2003). Weed and crop discrimination using image analysis and artificial intelligence methods. Computers and Electronics in Agriculture, 39(3), 157-171.

[18] Jin, X., Che, J., Chen, Y., (2021). Weed identification using deep learning and image processing in vegetable plantation. IEEE Access, 9, 10940-10950.

[19] Xiong, J., Yu, D., Liu, S., Shu, L., Wang, X., Liu, Z., (2021). A review of plant phenotypic image recognition technology based on deep learning. Electronics, 10(1), 81.

[20] Loey, M., ElSawy, A., Afify, M., (2020). Deep learning in plant diseases detection for agricultural crops: a survey. International Journal of Service Science, Management, Engineering, and Technology (IJSSMET), 11(2), 41-58.

[21] Türkoğlu, M., Hanbay, K., Sivrikaya, I. S., Hanbay, D., (2021). Derin evrişimsel sinir ağı kullanılarak kayısı hastalıklarının sınıflandırılması. Bitlis Eren Üniversitesi Fen Bilimleri Dergisi, 9(1), 334-345.

[22] Hossain, M. S., Al-Hammadi, M., Muhammad, G., (2018). Automatic fruit classification using deep learning for industrial applications. IEEE Transactions on Industrial Informatics, 15(2), 1027-1034.

[23] Kang, H., Chen, C., (2020). Fast implementation of real-time fruit detection in apple orchards using deep learning. Computers and Electronics in Agriculture, 168, 105108.

[24] AlZamily, J. Y., Naser, S. S. A., (2020). Lemon Classification Using Deep Learning. International Journal of Academic Pedagogical Research (IJAPR), 3(12).

[25] Mansour, A. I., (2021). Classification of Pears Using Deep Learning. International Journal of Academic Information Systems Research (IJAISR), 5(1), 17-26

[26] Rahnemoonfar, M., Sheppard, C., (2017). Deep count: fruit counting based on deep simulated learning. Sensors, 17(4), 905.

[27] Agarwal, S., Tarar, S., (2021). A hybrid approach for crop yield prediction using machine learning and deep learning algorithms. Journal of Physics: Conference Series.

[28] Dheir, I. M., Abu Mettleq, A. S., Elsharif, A. A., (2020). Nuts types classification using deep learning. International Journal of Academic Information Systems Research (IJAISR), 3(12), 12-17.

[29] Han, Y., Liu, Z., Khoshelham, K., Bai, S. H., (2021). Quality estimation of nuts using deep learning classification of hyperspectral imagery. Computers and Electronics in Agriculture, 180, 105868.

[30] Caner, K., Gerdan, D., Eminoğlu, M. B., Yegül, U., Bulent, K., Vatandaş, M., (2020). Classification of hazelnut cultivars: comparison of DL4J and ensemble learning algorithms. Notulae Botanicae Horti Agrobotanici Cluj-Napoca, 48(4), 2316-2327.

[31] Ashton, T. S., (1997). The industrial revolution 1760-1830, OUP Catalogue, USA.

[32] Cortada, J. W. (2016). The computer in the United States: From laboratory to market, 1930-60 1st Edition, Routledge, USA.

[33] Dick, S., (2019). Artificial intelligence. Harvard Data Science Review, 1(1).

[34] Yakoubi, M. A., Laskri, M. T., (2016). The path planning of cleaner robot for coverage region using Genetic Algorithms. Journal of Innovation in Digital Ecosystems, 3(1), 37-43.

[35] Janković, R., (2019). Machine learning models for cultural heritage image classification: Comparison based on attribute selection. Information, 11(1), 12.

[36] Cai, L., Gao, J., Zhao, D., (2020). A review of the application of deep learning in medical image classification and segmentation. Annals of Translational Medicine, 8(11).

[37] Jain, A. K., Mao, J., Mohiuddin, K. M., (1996). Artificial neural networks: A tutorial. Computer, 29(3), 31-44.

[38] Agatonovic-Kustrin, S., Beresford, R., (2000). Basic concepts of artificial neural network (ANN) modeling and its application in pharmaceutical research. Journal of Pharmaceutical and Biomedical Analysis, 22(5), 717-727.

[39] Hopfield, J. J., (2007). Hopfield network. Scholarpedia, 2(5), 1977.

[40] Hochreiter, S., Schmidhuber, J., (1997). Long short-term memory. Neural Computation, 9(8), 1735-1780.

[41] Smolensky, P., (1986). Information processing in dynamical systems: Foundations of harmony theory. Colorado Univ at Boulder Dept of Computer Science.

[42] Hinton, G., (2007). Boltzmann machine. Scholarpedia, 2 (5), 1668.

[43] Salakhutdinov, R., Mnih, A., Hinton, G., (2007). Restricted Boltzmann machines for collaborative filtering. Proceedings of the 24th International Conference on Machine learning.

[44] Kuremoto, T., Kimura, S., Kobayashi, K., Obayashi, M., (2014). Time series forecasting using a deep belief network with restricted Boltzmann machines. Neurocomputing, 137, 47-56.

[45] Yamashita, R., Nishio, M., Do, R. K. G., Togashi, K., (2018). Convolutional neural networks: an overview and application in radiology. Insights into Imaging, 9(4), 611-629.

[46] Simonyan, K., Zisserman, A., (2014). Very deep convolutional networks for large-scale image recognition. 3rd International Conference on Learning Representations (ICLR 2015).

[47] He, K., Zhang, X., Ren, S., Sun, J., (2016). Deep residual learning for image recognition. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition.

[48] Tan, M., Le, Q., (2019). Efficientnet: Rethinking model scaling for convolutional neural networks. International Conference on Machine Learning.

[49] Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J., Wojna, Z., (2016). Rethinking the inception architecture for computer vision. Proceedings of the IEEE conference on computer vision and pattern recognition.

[50] Van Rossum, G., (2007). Python Programming Language. USENIX Annual Technical Conference.

[51] Kadiyala, A., Kumar, A., (2017). Applications of Python to evaluate environmental data science problems. Environmental Progress & Sustainable Energy, 36(6), 1580-1586.

[52] Najafabadi, M. M., Villanustre, F., Khoshgoftaar, T. M., Seliya, N., Wald, R., Muharemagic, E., (2015). Deep learning applications and challenges in big data analytics. Journal of Big Data, 2(1), 1-21.

[53] Gu, H., Wang, Y., Hong, S., Gui, G., (2019). Blind channel identification aided generalized automatic modulation recognition based on deep learning. IEEE Access, 7, 110722-110729.

[54] Dillon, J. V., Langmore, I., Tran, D., Brevdo, E., Vasudevan, S., Moore, D., . . . Saurous, R. A., (2017). Tensorflow distributions. arXiv preprint arXiv:1711.10604.

[55] Ketkar, N., (2017). Introduction to keras, In: Deep Learning with Python, Springer, USA.

[56] Bradski, G., (2000). The openCV library. Dr. Dobb's Journal: Software Tools for the Professional Programmer, 25(11), 120-123.

[57] Oliphant, T. E. (2006). A guide to NumPy, Trelgol Publishing, USA.

[58] McKinney, W., (2011). Pandas: a foundational Python library for data analysis and statistics. Python for High Performance and Scientific Computing, 14(9), 1-9.

[59] Hunter, J. D., (2007). Matplotlib: A 2D graphics environment. Computing in Science & Engineering, 9(03), 90-95.

[60] Hao, J., Ho, T. K., (2019). Machine learning made easy: a review of scikit-learn package in python programming language. Journal of Educational and Behavioral Statistics, 44(3), 348-361.

[61] Keras, https://keras.io/api/applications/, 10 Şubat 2022.

[62] Towards Data Science, https://towardsdatascience.com/illustrated-guide-to-recurrent-neural-networks-79e5eb8049c9, 10 Şubat 2022.

[63] Fawcett, T., (2006). An introduction to ROC analysis. Pattern Recognition Letters, 27(8), 861-874.

[64] Russakovsky, O., Deng, J., Su, H., Krause, J., Satheesh, S., Ma, S., . . . Bernstein, M., (2015). Imagenet large scale visual recognition challenge. International Journal of Computer Vision, 115(3), 211-252.

[65] Arif, R. B., Siddique, A. B., Khan, M. M. R., (2018). Study and Observation of the Variations of Accuracies for Handwritten Digits Recognition with Various Hidden Layers and Epochs using Convolutional Neural Network. 2018 4th International Conference on Electrical Engineering and Information & Communication Technology (iCEEiCT).

## ÖZGEÇMİŞ

**Adı Soyadı** : Engin GÜNEŞ

**Yabancı Dili** : İngilizce

### Öğrenim Durumu

| Derece | Bölüm/Program | Üniversite/Lise | Mezuniyet Yılı |
|---|---|---|---|
| Lise | Teknik Lisesi | Ünye | Haziran 2007 |
| Lisans | Bilgisayar Öğretmenliği | Marmara Üniversitesi | Eylül 2014 |
| Lisans | Bilgisayar Mühendisliği | Kocaeli Üniversitesi | Temmuz 2018 |

### İş Deneyimi

| Yıl | Firma/Kurum | Görevi |
|---|---|---|
| 2021 | Altamira Dijital | Derin Öğrenme Uzmanı |
| 2022 | Mobiliva Ar-ge | Yazılım Mühendisi |

### Bilimsel Eserler:

1. GÜNEŞ, E., YILDIZ, K., Anil, B., (2021). CNN-based Gender Prediction in Uncontrolled Environments. Düzce Üniversitesi Bilim ve Teknoloji Dergisi, 9(2), 890-898.