
GAZİ ÜNİVERSİTESİ
Gazi
1926

KAROTİS ARTER INTIMA MEDIA KALINLIĞININ DERİN ÖĞRENME İLE SINIFLANDIRILMASI

Serkan SAVAŞ

DOKTORA TEZİ
BİLGİSAYAR MÜHENDİSLİĞİ ANA BİLİM DALI

GAZİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

EKİM 2019

Serkan SAVAŞ tarafından hazırlanan "KAROTİS ARTER INTIMA MEDIA KALINLIĞININ DERİN ÖĞRENME İLE SINIFLANDIRILMASI" adlı tez çalışması aşağıdaki jüri tarafından OY BİRLİĞİ ile Gazi Üniversitesi Bilgisayar Mühendisliği Ana Bilim Dalında DOKTORA TEZİ olarak kabul edilmiştir.

Danışman: Prof. Dr. Nurettin TOPALOĞLU

Bilgisayar Mühendisliği Ana Bilim Dalı, Gazi Üniversitesi ...……

Bu tezin, kapsam ve kalite olarak Doktora Tezi olduğunu onaylıyorum.

Başkan: Prof. Dr. Fırat HARDALAÇ

Elektrik Elektronik Mühendisliği Ana Bilim Dalı, Gazi Üniversitesi ……..……

Bu tezin, kapsam ve kalite olarak Doktora Tezi olduğunu onaylıyorum.

Üye: Prof. Dr. Recep DEMİRCİ

Bilgisayar Mühendisliği Ana Bilim Dalı, Gazi Üniversitesi ..……...

Bu tezin, kapsam ve kalite olarak Doktora Tezi olduğunu onaylıyorum.

Üye: Prof. Dr. İlyas ÇANKAYA

Elektrik Elektronik Mühendisliği Ana Bilim Dalı, Ankara Yıldırım Beyazıt Üniversitesi ……..…

Bu tezin, kapsam ve kalite olarak Doktora Tezi olduğunu onaylıyorum.

Üye: Doç. Dr. Baha ŞEN

Bilgisayar Mühendisliği Ana Bilim Dalı, Ankara Yıldırım Beyazıt Üniversitesi ……

Bu tezin, kapsam ve kalite olarak Doktora Tezi olduğunu onaylıyorum.

Tez Savunma Tarihi: 02/10/2019

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

……..……

Prof. Dr. Sena YAŞYERLİ

Fen Bilimleri Enstitüsü Müdürü

ETİK BEYAN

Gazi Üniversitesi Fen Bilimleri Enstitüsü Tez Yazım Kurallarına uygun olarak hazırladığım bu tez çalışmasında;

- Tez içinde sunduğum verileri, bilgileri ve dokümanları akademik ve etik kurallar çerçevesinde elde ettiğimi,
- Tüm bilgi, belge, değerlendirme ve sonuçları bilimsel etik ve ahlak kurallarına uygun olarak sunduğumu,
- Tez çalışmasında yararlandığım eserlerin tümüne uygun atıfta bulunarak kaynak gösterdiğimi,
- Kullanılan verilerde herhangi bir değişiklik yapmadığımı,
- Bu tezde sunduğum çalışmanın özgün olduğunu,

bildirir, aksi bir durumda aleyhime doğabilecek tüm hak kayıplarını kabullendiğimi beyan ederim.

Serkan SAVAŞ
02/10/2019

KAROTİS ARTER INTIMA MEDIA KALINLIĞININ DERİN ÖĞRENME İLE SINIFLANDIRILMASI

(Doktora Tezi)

Serkan SAVAŞ

GAZİ ÜNİVERSİTESİ

FEN BİLİMLERİ ENSTİTÜSÜ

Ekim 2019

ÖZET

Gelişmiş ülkelerde ölümle sonuçlanan hastalıkların başında sırasıyla kalp hastalığı, kanser ve Karotis Arter hastalığının yol açtığı Serebrovasküler Olaylar gelmektedir. Aterosklerozun güvenilir erken tespiti için, Intima Media Thickness (IMT) ölçümü ve sınıflandırması önemlidir. Bu doktora tezinde IMT'nin sınıflandırılması için karar destek amaçlı yeni bir yöntem önerilmiştir. IMT ölçümleri için ultrason görüntüleri kullanılır. Görüntüler uzmanlar tarafından sınıflandırılır ve değerlendirilir. Bu manuel bir prosedürdür. Bu yüzden IMT sınıflandırmasında değişkenliğe ve öznelliğe sebep olur. Bunun yerine, bu tezde IMT sınıflandırması için yapay zekâ yöntemlerine dayanan bir yöntem önerilmektedir. Bu amaçla, çoklu gizli katmanlara sahip derin bir öğrenme stratejisi geliştirilmiştir. Önerilen modeli oluşturmak için, görüntü sınıflandırma problemlerinde sıkça kullanılan Evrişimsel Sinir Ağı algoritması kullanılmıştır. Modeli test etmek için 153 hastadan elde edilen 501 ultrason görüntüsü kullanılmıştır. Görüntüler önce iki uzman tarafından sınıflandırılmış, daha sonra model eğitilerek sınıflandırılmış görüntüler üzerinde test edilmiş ve sonuçlar açıklanmıştır. Çalışmadaki derin öğrenme modeli IMT sınıflandırılmasında %89 duyarlılık ve %88 özgüllük ile %89,1 doğruluk sağlamıştır. Dolayısıyla, bu doktora tezinde yapılan değerlendirmeler bu yöntemin IMT sınıflandırması için makul sonuçlar verdiğini kanıtlamıştır.

Bilim Kodu	:	92432
Anahtar Kelimeler	:	Derin öğrenme, evrişimsel sinir ağları, intima media kalınlığı, yapay zekâ, makine öğrenmesi, karar destek sistemleri, serebrovasküler hastalıklar, karotis arter
Sayfa Adedi	:	138
Danışman	:	Prof. Dr. Nurettin TOPALOĞLU

CLASSIFICATION OF CAROTID ARTERY INTIMA MEDIA THICKNESS WITH DEEP LEARNING

(Ph. D. Thesis)

Serkan SAVAŞ

GAZİ UNIVERSITY

GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCES

October 2019

ABSTRACT

The leading causes of death in developed countries are heart disease, cancer and Cerebrovascular Events caused by Carotid Artery disease, respectively. For a reliable early detection of atherosclerosis, Intima Media Thickness (IMT) measurement and classification are important. A new method for decision support purpose for the classification of IMT was proposed in this Ph.D. thesis. Ultrasound images are used for IMT measurements. Images are classified and evaluated by experts. This is a manual procedure. Therefore, it causes variability and subjectivity in the IMT classification. Instead, this thesis proposes a method based on artificial intelligence methods for IMT classification. For this purpose, a deep learning strategy with multiple hidden layers has been developed. In order to create the proposed model, Convolutional Neural Network algorithm, which is frequently used in image classification problems, is used. 501 ultrasound images which are taken from 153 patients were used to test the model. The images are classified by two specialists, then the model is trained and tested on these classified images, and the results are explained. The deep learning model in the study achieved an accuracy of 89.1% in the IMT classification with 89% sensitivity and 88% specificity. Thus, the assessments in this paper have proved that the proposed method performs reasonably for IMT classification.

Science Code	:	92432
Key Words	:	Deep learning, convolutional neural networks, intima media thickness, artificial intelligence, machine learning, decision support systems, cerebrovascular diseases, carotid artery
Page Number	:	138
Supervisor	:	Prof. Dr. Nurettin TOPALOĞLU

TEŞEKKÜR

Bu tezin hazırlanması sırasında değerli fikirleri ve engin bilgisi ile bana yol göstererek yardım ve desteğini hiç bir zaman esirgemeyen, zaman gözetmeksizin ilgisini, alakasını, bilgi ve tecrübesini esirgemeyen kıymetli hocam Sayın "Prof. Dr. Nurettin TOPALOĞLU"na, tez izleme komitesinde bulunarak çalışmalarıma katkıda bulunan, görüş ve önerilerini esirgemeyen değerli hocalarım Sayın "Prof. Dr. Recep DEMİRCİ" ve Sayın "Doç. Dr. Baha ŞEN"e saygılarımı sunar, teşekkür ederim.

Tez çalışmamda önerileri ve yol göstericiliğiyle desteğini her zaman yanımda hissettiğim, bilimsel bakış açısıyla doğru yönde ilerlememi sağlayan, kıymetli hocam Sayın "Prof. Dr. Fırat HARDALAÇ"a saygı ve teşekkürlerimi sunarım.

Çalışmalarımda gerekli altyapı desteği ve donanım ortamını sağlayan Gazi Üniversitesi Bilgisayar Mühendisliği Bölüm Başkanlığına, çalışmada kullanılan görüntülerin teminiyle sınıflandırma çalışmalarındaki özverili ve gönülden çalışmalarından dolayı "Dr. Ömer KAZCI"ya, görüntülerin elde edilmesinde gerekli ortamı sunan Ankara Eğitim ve Araştırma Hastanesi Radyoloji Bölümü Ana Bilim Dalı Başkanı Sayın "Doç. Dr. Pınar Nercis KOŞAR" ve bölüm doktorlarına teşekkürlerimi sunarım. Doktora çalışmalarım sırasında veri elde etme aşamalarındaki önemli yardımlarından dolayı kıymetli ağabeyim "Tolga ALTAY"a ve doktora çalışmam boyunca her türlü desteği sunarak, moral ve motivasyonumu korumama yardımcı olan kıymetli aileme teşekkür ederim.

Tezimi varlığı ile hayatımda en büyük destekçim olan, tezin hazırlanma süresince her şartta verdiği sürekli ve sınırsız manevi destekle, yaptığı fedakârlıklar adına sevgili eşim "Tuğba SAVAŞ" ve çocuklarım "Sertuğ Efe SAVAŞ" ile "Tuğse SAVAŞ"a ithaf ederim.

İÇİNDEKİLER

Sayfa

ÖZET iv

ABSTRACT v

TEŞEKKÜR vi

ÇİZELGELERİN LİSTESİ x

ŞEKİLLERİN LİSTESİ xi

RESİMLERİN LİSTESİ xiii

SİMGELER VE KISALTMALAR xiv

1. GİRİŞ 1

2. SEREBROVASKÜLER HASTALIKLAR 15

2.1. Risk Faktörleri 17

2.1.1. Değiştirilemeyen faktörler 17

2.1.2. Değiştirilebilir risk faktörleri 17

2.2. Risk Faktörlerinin Dağılım Oranları 18

2.3. SVH Belirtileri 19

2.4. SVH Tanı ve Tedavisi 20

2.5. İnme Süreci 20

2.5.1. Geçici iskemik atak 20

2.5.2. Tamamlanmış inme 21

2.5.3. İlerleyen inme 21

2.6. İnme Sınıflaması 22

2.6.1. İskemik inme 22

2.6.2. Hemorajik inme 22

2.7. Karotis Arter 23

Sayfa

2.7.1. Karotis arter hastalığı 24
3. YAPAY ZEKÂ 27
3.1. Makine Öğrenmesi 29
3.1.1. Denetimli öğrenme 31
3.1.2. Denetimsiz öğrenme 38
3.1.3. Yarı denetimli öğrenme 39
3.1.4. Takviyeli öğrenme 43
3.1.5. Makine öğrenmesinin sınırlılıkları 48
3.2. Derin Öğrenme 49
3.2.1. Derin öğrenme mimarileri 56
3.2.2. Derin öğrenme algoritmaları 63
3.2.3. Derin öğrenme kütüphaneleri 71
4. ÖNERİLEN STRATEJİ 79
4.1. Materyaller 80
4.2. Metodoloji 81
4.2.1. Tanımlama 81
4.2.2. Görüntü Ön-İşleme 82
4.2.3. Model 84
4.2.4. Görselleştirme 89
5. DENEYSEL SONUÇLAR 91
6. SONUÇLAR VE TARTIŞMA 111
7. ÖNERİLER 115
KAYNAKLAR 117
EKLER 129

Sayfa

ÖZGEÇMİŞ.....137

ÇİZELGELERİN LİSTESİ

Çizelge **Sayfa**

Çizelge 2.1. Ölümle sonuçlanan ilk beş hastalık 15

Çizelge 3.1. Naive Bayes teoremi avantaj ve dezavantajları 33

Çizelge 3.2. Karar ağaçlarının avantaj ve dezavantajları....34

Çizelge 3.3. K-Ortalama kümeleme algoritması avantaj ve dezavantajları....38

Çizelge 3.4. Kendi kendine eğitim tekniğinin avantaj ve dezavantajları 40

Çizelge 3.5. Üretken karışım modellerin avantaj ve dezavantajları 41

Çizelge 3.6. Yarı denetimli destek vektör makinesinin avantaj ve dezavantajları 41

Çizelge 3.7. Grafik tabanlı algoritmaların avantaj ve dezavantajları 42

Çizelge 3.8. Yapay zekâ ve derin öğrenme görev tanımlama....53

Çizelge 3.9. RNN mimarisinin avantaj ve dezavantajları....67

Çizelge 3.10. Farklı RNN uygulama yapıları 68

Çizelge 4.1. Veri tabanı özeti....81

Çizelge 4.2. Modelin özeti....88

Çizelge 5.1. Performans ölçümleri....96

Çizelge 5.2. Test ve tahmin değerleri 96

Çizelge 5.3. Doğruluk ve kayıp oranları....101

Çizelge 5.4. Karışıklık matrisi sonuçları....107

Çizelge 5.5. Modellerin performans sonuçları....107

Çizelge 5.6. Modellerin test ve tahmin sonuçları 108

Çizelge 6.1. Karotis arter görüntü işleme çalışmaları....112

ŞEKİLLERİN LİSTESİ

Şekil **Sayfa**

Şekil 1.1. Karotis Arter duvar katmanları 2
Şekil 1.2. Doppler US Görüntüleme 4
Şekil 2.1. a) Tıkayıcı inme b) beyin kanaması 16
Şekil 2.2. Hemorajik inme 22
Şekil 2.3. Karotis arter 24
Şekil 2.4. Karotis arter iç yapıları 24
Şekil 2.5. Karotis arterlerde plak ve daralma 25
Şekil 3.1. Yapay zekâ kullanım alanları 27
Şekil 3.2. Linear ayrılma (a) ve ayrılamama (b) durumlarında SVM 36
Şekil 3.3. Yapay sinir ağı 37
Şekil 3.4. Takviyeli öğrenme sistemi 44
Şekil 3.5. Derin öğrenme zaman çizelgesi 50
Şekil 3.6. Derin öğrenme yapısı 52
Şekil 3.7. Derin öğrenme yelpazesi 55
Şekil 3.8. Derin sinir ağı yapısı 55
Şekil 3.9. Aktivasyon fonksiyonları 56
Şekil 3.10. AlexNet mimarisi 57
Şekil 3.11. AlexNet katmanları a) 1. katman b) 2. katman c) 6. Katman 57
Şekil 3.12. ZFNet mimarisi 59
Şekil 3.13. GoogLeNet mimarisi 60
Şekil 3.14. a) RestNet 34 katmanlık mimari b) Residual blok 61
Şekil 3.15. VGGNet mimarisi 62
Şekil 3.16. a) Evrişimsel katman (3x3) b) Havuzlama (2x2) 63
Şekil 3.17. Basit bir RNN yapısı 67

Şekil **Sayfa**

Şekil 3.18. Kısıtlı Boltzmann makineleri diyagramı 69

Şekil 4.1. Modelde görüntü ön-işleme aşaması. a) Giriş görüntüsü b) Ön-işleme sonrası 82

Şekil 4.2. Sınıflandırılmış KA US görüntüleri. a) IMT var b) IMT yok 83

Şekil 4.3. Model genel görünüm.....84

Şekil 5.1. a) Modelin doğruluk grafiği b) Modelin kayıp grafiği 91

Şekil 5.2. Modelin karışıklık matrisi.....93

Şekil 5.3. Modelin ROC eğrisi.....96

Şekil 5.4. Doğruluk grafikleri a) AlexNet b) ZFNet c) VGG16 d) VGG19 e) CNNcc.....98

Şekil 5.5. Kayıp grafikleri a) AlexNet b) ZFNet c) VGG16 d) VGG19 e) CNNcc 101

Şekil 5.6. Karışıklık matrisleri a) AlexNet b) ZFNet c) VGG16 d) VGG19 e) CNNcc..105

Şekil 5.7. ROC eğrileri.....109

RESİMLERİN LİSTESİ

Resim **Sayfa**

Resim 1.1. Intima Media Kalınlığı bölgesi 3

Resim 5.1. Özellik çıkarımı 97

SİMGELER VE KISALTMALAR

Bu çalışmada kullanılmış simgeler ve kısaltmalar, açıklamaları ile birlikte aşağıda sunulmuştur.

Simgeler	**Açıklamalar**
Hz	Hertz
kHz	Kilohertz
MHz	Megahertz
mm	Milimetre
µm	Mikrometre
%	Yüzde

Kısaltmalar	**Açıklamalar**
AsKA	Asemptomatik Karotis Ateroskleroz
AHA	American Heart Association
AKA	Ana Karotis Arter
API	Application Programming Interface
ASYE	Alt Solunum Yolu Enfeksiyonları
AUC	Area Under Curve
BAIR	Berkeley Artificial Intelligence Research
CAD	Computer Aided Diagnosis
CHAID	Chi- Squared Automatic Interaction Detector
CEUS	Kontrastlı Ultrason
CNN	Convolutional Neural Network
CNNcc	Convolutional Neural Network Carotid Classifier
CPU	Central Processing Unit
CRT	Classification and Regression Trees
DALY	Disability Adjusted Life Years
DBN	Deep Belief Nets
DÖ	Derin Öğrenme

Kısaltmalar	Açıklamalar
DVM	Desktek Vektör Makineleri
EKA	Eksternal Karotis Arter
ESA	Evrişimsel Sinir Ağları
GEMV	General Matrix Vector Multiply
GİA	Geçici İskemik Atak
GPU	Graphical Processing Unit
HDL	High Density Lipoprotein
IKA	Internal Karotis Arter
IMT	Intima Media Thickness
IVUS	Intravascular Ultrasound
İKH	İskemik Kalp Hastalığı
KA	Karotis Arter
KE	Karotis Endarterektominin
KNN	K Nearest Neighbor
KOAH	Kronik Obstrüktif Akciğer Hastalığı
MARS	Multivariate Adaptive Regression Splines
MR	Magnetic Resonance
QUEST	Quick, Unbiased, Efficient Statistical Tree
RARM	Rapid Association Rule Mining
RBM	Restricted Boltzmann Machines
ReLU	Rectified Linear Unit
RFD	Renal Failure Disease
RNN	Recurrent Neural Network
ROC	Reciever Operator Characteristics
SA	Sinir Ağları
SACI	Semptomatik/Asemptomatik Karotis İndeksi
SAK	Subaraknoid Kanama
SLIQ	Supervised Learning in Quest
SPRINT	Scalable Paralleizable Induction of Decision Trees
SVH	Serebrovasküler Hastalık
S^3VM	Semi-Supervised Support Vector Machine
SVM	Support Vector Machine

Kısaltmalar	Açıklamalar
TD	Temporal Difference
TIA	Transient Ischemic Attack
US	Ultrasound
VBA	Vertebro Basiller Arter
YSA	Yapay Sinir Ağları
YZ	Yapay Zekâ

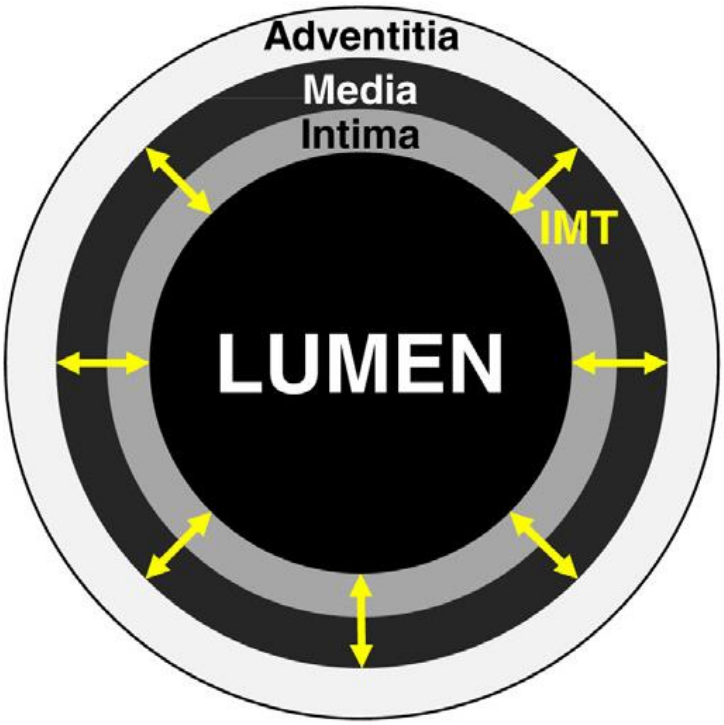
1. GİRİŞ

Serebrovasküler hastalıklar (SVH) ölümle veya sakatlıklarla sonuçlanması sebebiyle en tehlikeli hastalıkların ilk sıralarında yer almaktadır (Seçil, 2013). Gelişmiş ülkelerde ölüme sebep olan hastalıkların başında kalp hastalıkları, kanser ve Karotis Arter (KA) hastalığının sebep olduğu SVH gelmektedir (CDCP, 2001). Kardiyovasküler riskler ve yaşın ilerlemesiyle birlikte, KA hastalığının görülme sıklığı da artmaktadır. SVH riski, KA darlığının ebadına, hastalık semptomlarına ve damardaki plağın boyutuna bağlı olarak değişmektedir. Bunlara ek olarak, hastanın SVH geçmişi, daha önceden iskemik atak geçirip geçirmediği, aterosklerotik risk faktörleri gibi durumlar da, SVH risk faktörlerindendir. Kuzey Amerika Semptomatik Karotis Endarterektomi'nin çalışmasında belirtildiğine göre, %70 ile 79 arasında KA darlığı varsa ilk yıl iskemik SVH riski %11 olup damar darlığı %90'dan fazla oluştuğunda ise SVH riski %35'e çıkmaktadır (Barnett ve diğerleri, 1991), (Henry ve diğerleri, 1998).

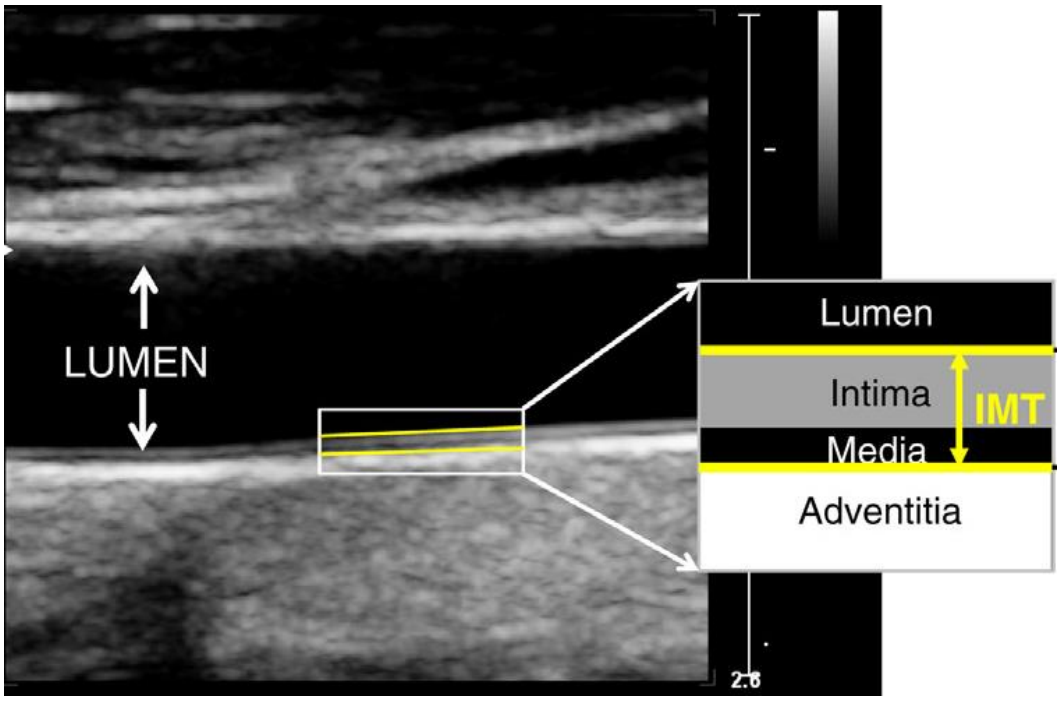
KA daralması bulunan hastaların yaklaşık %75'inde belirti bulunmamaktadır. Bu hastalar asemptomatik hastalardır. İnme riski, belirtisi olsun veya olmasın tüm hastalarda darlığın derecesine göre değişmektedir. Yapılan bir çalışmada asemptomatik hastaların darlık derecesi %50-75, %75-90, %90 üstü olarak gruplandırılmış ve inme riski bu hastalarda sırasıyla %1-2, %6 ve %8 olarak belirlenmiştir (Benjamin ve Dean, 1995). Asemptomatik hastalarla ilgili yapılan birçok çalışma mevcuttur. Aspirine karşı Asemptomatik Daralma Operasyonu ile KA Stenozu çalışmasında Karotis Endarterektominin (KE) aspirin kullanılmasına karşın yararı olmamasının yanında %6,9 oranında ameliyat öncesi risk taşıdığı belirtilmiştir. The Veterans Affair çalışmasında, KE uygulaması yapılan hastalar ile aspirin tedavisi uygulanan hastalar arasında ölüm oranı ve inme riski oranında fark görülmediği belirtilmiştir. Çalışmalarda KA darlığı hızla artarak %90'ın üzerine çıkan hastalara acil olarak cerrahi müdahale edilmesi gerektiği belirtilmiştir (Koçak, 2009).

Belirtileri bulunmayan hastalarla ilgili yapılan en kapsamlı çalışma Asemptomatik Karotis Ateroskleroz'dur (AsKA) (Burns ve diğerleri, 2003). Bu çalışmada koroner arter hastalığı olmayan sağlıklı bireylerden %60 ve üzeri KA damar darlığı olanlara cerrahi müdahale yapılması gerektiği belirtilmiştir. Bu hastalardan aspirin tedavisi uygulanan grupta beş yıl sonunda %66 oranında risk azalması görülmüş olup KE'nin kadınlardaki durumu net

değildir. Kadınlarda %3,6 oranla cerrahi müdahale öncesi komplikasyon geçirme oranı erkeklerden (%1,7) daha yüksektir. Bu sonuçlar ışığında, asemptomatik hastalardan %60 ve üstünde stenozu olanlarının cerrahi tedavi edilmesi gerektiği söylenebilir. AsKA çalışmasında belirtilene göre ölüm riski %1,5 ve operatif mortalite %0,14'dur. KE sonuçlarına kıyasla bu oranlar, düşük değerler olarak ortaya çıkmaktadır. Oranların bu denli düşük olması sebebiyle bazı çalışmalarda KE'nin %80 ve üzeri oranlardaki stenozlarda uygulanması tavsiye edilmektedir. İleri düzeyde stenoz görülmeyen hastaların yıllık Doppler Ultrason (US) kontrolleriyle tedavi edilmesi ve uygun müdahalelere rağmen ilerleme görülüyorsa ancak bu durumda cerrahi müdahale yapılması önerilmektedir. Tüm bu çalışmalar semptomluk durumlarına göre, %50-99, %60-99 ve %70-99 Internal KA (IKA) damar darlığı olan hastaların medikal tedaviye göre endarterektomiden yararlandıklarını belirtmişlerdir. IKA darlıkları iskemik beyin felcinin en önemli sebeplerinden biridir (Phatouros ve diğerleri, 2000). KA duvarının katmanları Şekil 1.1.'de gösterilmiş ayrıca Intima Media Kalınlığı bölgesi Resim 1.1'de gösterilmiştir (Menchón-Lara ve diğerleri, 2016).



Şekil 1.1. Karotis Arter duvar katmanları (Menchón-Lara ve diğerleri, 2016)



Resim 1.1. Intima Media Kalınlığı bölgesi (Menchón-Lara ve diğerleri, 2016).

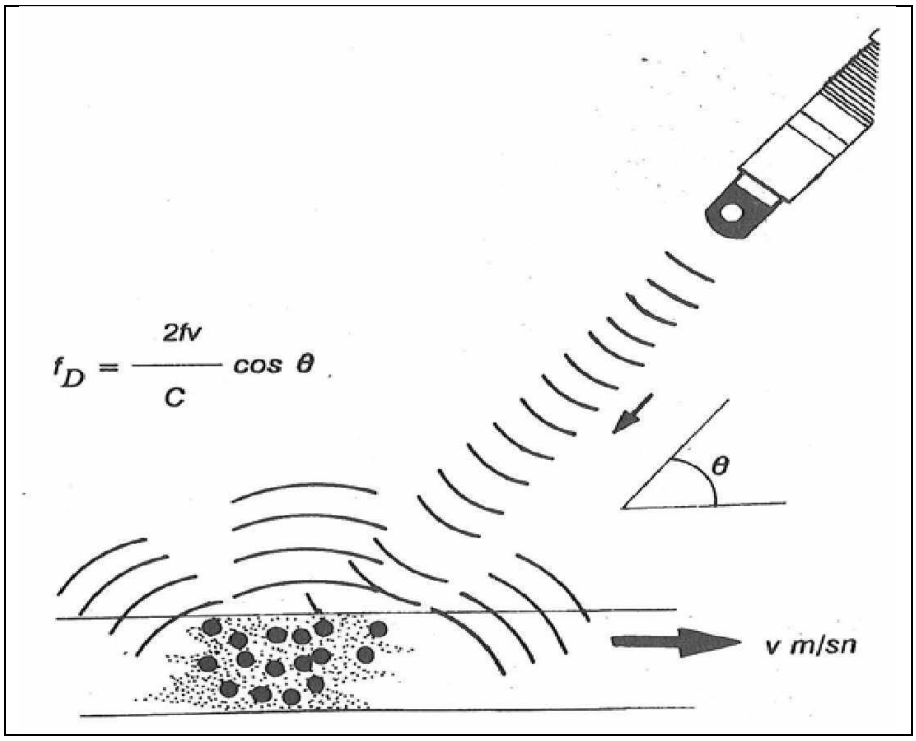
Aterosklerotik değişikliklerin çoğunluğu, karotis ayrılma düzeyinde olup, iskemin süreçlerin %80 oranında oluşma sebebi ise aterosklerozdur. US ile yüksek çözünürlükte KA görüntüleme gerçekleştirilebilir çünkü konumları, ilerlediği alan ve ses dalgalarına uygunluğu görüntülemeye uygun şartları sağlamaktadır. Bu sebeple KA'nın morfolojik değerlendirmesi için en güvenilir ve duyarlı yöntem US olarak belirtilmektedir. Ayrıca renkli Doppler US ile damardaki akım değişikliklerinin gerçek zamanlı olarak izlenmesi de mümkündür. Bütün bunlar göz önüne alındığında US, ateroskleroz için önemli bir tarama yöntemi ve tanılama aracıdır. US görüntülemenin en önemli sınırlılığı, görüntülemeyi yapan uygulayıcıya bağlı olarak hata riski taşımasıdır (Seçil, 2013).

Doppler US, ses dalgaları göndererek damar yapılarını inceleme yöntemidir. Beyni besleyen damarlardaki (KA ve Vertebral Arter) dolaşım hareketlerine yönelik basınç, hız, damar direnci, debi vb. bilgilerin ölçülmesini sağlar. Anjiyografi için altın standart olup duyarlığı %92,6 ve özgüllüğü %97'dir (Yurdakul ve Aytekin, 2011).

İnsan kulağının duyduğu sesler 20Hz ile 20kHz arasında yer almaktadır. US duyulabilir sınırların ötesindeki ses dalgaları anlamına gelir. Ultrasonun tanısal uygulamalarında 1-10 MHz arasında frekanslar kullanılır. Hasta elektrik enerjisini mekanik enerjiye çeviren bir prop aracılığıyla incelenir. Vücuda çeşitli açılarda yollanan ses dalgasının organlarda

yansıma, soğurulma ve saçılması sonucu dönen sinyal miktarı başlangıçtaki sesten daha zayıftır. Kısa bir zamanda, çok sayıda anatomik görüntü gerçek zamanlı olarak elde edilir. Birçok US uygulaması kısa pulslar halinde sesin dokuya iletilmesi ve sesin geri alınmasından oluşur (S-Ansert, 2004).

Doppler US ile KA'nın görüntülemesi, boynun en altından başlayıp KA'nın çatallandığı yerin yaklaşık 6 cm kadar üstündeki bölgede sonlandırılır. Görüntüleme sırasında boyun görüntüleme yapıldığı açıdan ters yöne doğru yaklaşık 45 derece döndürülerek transdüser damar duvarının yönüne paralel olarak tutulur. Görüntüleme sırasında önce KA çatallanma bölgesi, sonra Ana Karotis Arter (AKA) görüntülenir. Daha sonra iç ve dış yönde hareketlerle IKA ve Eksternal Karotis Arter (EKA) görüntülenebilir. Bu görüntülemeler sırasında AKA, IKA ve EKA'daki stenozlar, varsa plaklar ve özellikleri, IMT ve kan akış özelliklerinin bilgileri elde edilebilir. Bu incelemelerin ardından da anatomisi karmaşık KA'lar varlığında, IKA ve EKA'yı ayırt etmek için kullanılan uzak posterolateral longitudinal inceleme gerçekleştirilebilir. Limen daralmasının derecesi ve plak kalınlığının kesin olarak belirlenmesi bu yöntemle yapılabilir. Daha sonra da Transvers inceleme yapılarak KA'nın Doppler US görüntülemesi tamamlanır (Yurdakul ve Aytekin, 2011). Doppler US ile görüntüleme, Şekil 1.1'de gösterilmiştir (Koçak, 2009).



Şekil 1.2. Doppler US Görüntüleme

Doppler denklemi şöyle tanımlanır:

$$f_D = f_t - f_r = 2f_t v \cos\theta / c \quad (1)$$

burada f_t ve f_r iletilen ve alınan ultrason frekansları olduğunda, v hedefin hızıdır, c ortamdaki sesin hızıdır ve θ ultrason ışını ile hedefin hareket yönü arasındaki açıdır (Öztürk ve diğerleri, 2008).

Bu açıklamalar ışığında, KA hastalığının erken teşhis ve tedavisi için çeşitli yöntemlerin denendiği çalışmalar incelenmiştir. Bu çalışmalardan bazıları şöyledir:

Uğurhan Kutbay ve arkadaşları tarafından 2016 yılında yapılan bir çalışmada, KA Doppler görüntülerinde ayarlanabilir uzak bulanık c-ortalama bölümlendirmesi, Kuaterniyon tabanlı konvolüsyon filtreleri ve çıkıntı haritalama prosedürleri araştırılmıştır. Çıkıntı haritalama görüntülerinde KA Intima Media Thickness (IMT) ölçümlerini basitleştirebilecek bir görüntüleme yazılımı geliştirmişlerdir. Çalışmada Fırat Üniversitesi'nden sağlanan 25 Karotis doppler görüntüsü kullanılmış ayrıca bu görüntüler uzmanlar tarafından yorumlanarak, çıkıntı haritalama görüntüleriyle karşılaştırılmıştır. Tüm görüntülere bulanık c-ortalama uygulandıktan ve kuaterniyon tabanlı konvolüsyon uygulandıktan sonra, doktorlar tarafından aşağıdan yukarıya sapma modeli kullanarak kolayca uygulanabilecek bir model oluşturulmuştur. Renkli görüntüler elde etmek için görüntü filtreleme yöntemleri kullanılmıştır. Bu görüntüler üzerinde de tasarlanan model kullanılmıştır ve ham görüntüler ile renklendirilen görüntüler karşılaştırılmıştır. Tüm görüntülerde ortalama karesel hata ölçümü yapılmış ve Kuaterniyon Tabanlı Çıkıntı Haritalamanın daha iyi sonuç verdiği görülmüştür. Çalışmada bilgisayar destekli görüntü işlemenin, doktorlara karar destek amaçlı kullanılabileceği görülmüştür (Kutbay ve diğerleri, 2016).

Rosa-María Menchón-Lara ve arkadaşları tarafından gerçekleştirilen çalışmada, aterosklerozun erken tespiti için tam otomatik bir segmentasyon tekniği önerilmiştir. Önerilen yöntem, görüntülerdeki IMT yoğunluk modellerinin tanımlanması için makine öğrenmesi ve yapay sinir ağlarına dayanmaktadır. Bu amaçla, çoklu gizli katmanlara sahip otomatik kodlayıcılarla soyut ve etkili veri sunumları elde etmek için derin bir öğrenme stratejisi geliştirilmiştir. Tasarlanan derin mimari, aşırı makine öğrenmesi kavramı altında tasarlanmıştır. Sistemin geçerliliği için 67 US görüntüsü içeren bir veri tabanı kullanılmıştır. Her görüntü için ortaya çıkan otomatik konturlar, iki farklı gözlemci tarafından yapılan dört manuel segmentasyonun ortalaması ile karşılaştırılmıştır. Spesifik olarak, önerilen algoritma

ile ölçülen IMT, 0.625 ± 0.167 mm (ortalama ± standart sapma) iken buna karşılık gelen gerçeklik değeri 0.619 ± 0.176 mm olmuştur. Böylece, yöntem ile otomatik ve manuel ölçümler arasında sadece 5.79 ± 34.42 μm'lik bir fark göstermiştir (Menchón-Lara ve diğerleri, 2016).

André Miguel F. Santos ve arkadaşları tarafından gerçekleştirilen çalışmada B-modlu ultrason görüntülerinde KA'nın lümen ve bifurkasyon sınırlarının segmentasyonu için yeni bir algoritma önerilmiştir. Bu algoritma lümenlerin görüntü kontrast özelliklerini ve karotis atardamarının bifurkasyonunu, diğer dokulara ve yapılara göre tanımlamaları için kullanmaktadır. Giriş görüntüsünde sunulan atardamar ile ilgili US verileri, morfolojik operatörler kullanılarak tanımlanmış ve benekli gürültü giderme için anizotropik difüzyon filtresi ile işlenmiştir. Elde edilen veriler daha sonra, Chan-Vese seviyeli küme bölümlemesi modelinin uygulanması için kullanılmıştır. AKA'nın uzunlamasına ultrason B-modlu gri tonlama görüntüleri elde edilmiştir. Sonuçlar, yeni algoritmanın etkili ve sağlam olduğunu ve ana avantajının, geleneksel algoritmaların bilinen sınırlamalarını aşan karotis lümeninin otomatik tanımlanmasına dayandığını ortaya koymuştur (Santos ve diğerleri, 2013).

Da-Chuan Cheng ve arkadaşları tarafından yapılan çalışmada, plaklı ve plaksız dinamik B-mod radyofrekans görüntü dizilerinde, AKA'nın hem yakın hem de uzak duvarlarının yapısal katmanlarını otomatik olarak tespit edebilen yeni bir çerçeve önerilmiştir. Bu otomatik sistem vasıtasıyla, kalp çevrimi boyunca lümen çapı değişiklikleri tespit edilebilmektedir. Çalışmada üç görüntü dizisi test edilmiş ve tüm sonuçlar iki profesyonel uzman tarafından yapılan manuel izlerle karşılaştırılmıştır. Yakın ve uzak duvar algılama için ortalama hatalar sırasıyla 0,058 mm ve 0,067 mm olmuştur (Cheng ve diğerleri, 2010).

Alessandro C. Rossi ve arkadaşları tarafından gerçekleştirilen bir çalışmada kullanıcı etkileşimini ortadan kaldırmak ve hem gerçek zamanlı hem de çevrim dışı uygulamaların işlemesini hızlandırmak için, AKA'nın uzunlamasına US taramalarında otomatik arter tanıma için bir algoritma geliştirilmiştir. Arteryel yapının bilgi içeriğini düzgün bir şekilde kullanmak için, eko sisteminin iki boyutlu çözünürlük özelliklerine göre zarflar kesilerek böylece hesaplama yükü büyük ölçüde azaltılmıştır. Ardından, beklenen çap aralığına ve arteryal duvar-lümen kompleksinin eko zarfındaki tipik modelin öncül bilgisine dayanarak, parametrik şablon eşleştirmesi gerçekleştirilirmiştir. Böylece, düşünülen her eko çizgisi boyunca lümen konumu oluşturulmuştur. Son olarak, hatalı tahminleri reddetmek için

mekânsal ve zamansal bir kümeleme yöntemi uygulanmıştır. İşleme dâhil olan parametreler için uygun değerler, 45 denekten gelen 128 eko veri kaydı üzerinde önerilen algoritmanın off-line testiyle elde edilmiştir. Sağlam parametre değerlerini kullanarak, arterin doğru ve hızlı tanınması, 6185 işlem gören çerçevelerin %98'inden fazlasında elde edilmiştir (Rossi ve diğerleri, 2008).

P. Melillo ve arkadaşları tarafından yapılan bir çalışmada vasküler olayların risk değerlendirmesi ve hipertansif hastalardaki inme için biyomedikal sinyaller toplama ve otomatik analiz için geliştirilen bir platformun ön doğrulama işlemleri yapılmıştır. Bulut bilişimine dayanan bu m-sağlık platformu, esnek, genişletilebilir ve şeffaf olacak şekilde ve veri madenciliği yoluyla proaktif uzaktan izleme sağlamak için tasarlanmıştır. Geliştirilen sistem, 12 aylık bir süreçte bir vasküler olayı %84'lük bir doğruluk oranı ile öngörebilmiş ve %72'lik bir doğruluk oranına sahip olarak belirleyebilmiştir. Devam eden bir prospektif çalışmada, hemen hemen tüm hastalar, veri kayıplarına sebep olan sınırlı bir orantısızlık oranı (<% 20) ile sistemi olumlu olarak kabul etmişlerdir. Geliştirilen platform, uzaktan gözetimli veri işleyerek ve vasküler olayların ve düşmelerin hızlı ve doğru bir şekilde risk değerlendirmesiyle klinik karar vermeyi desteklemiştir (Melillo ve diğerleri, 2015).

M.C. Bastida-Jumilla ve arkadaşları tarafından yapılmış bir çalışmada, AKA'nın arter katmanlarını US görüntüleri üzerinden kesmek için tam otomatik bir yöntem geliştirilmiştir. Önerilen teknik, yumuşak son konturlar sunarken, orijinal alan formülasyonundan hesaplamalı olarak daha hızlı olan aktif konturların frekans-alan uygulamasına dayanmaktadır. 0.029 mm/piksel ile 0.081 mm/piksele uzamsal çözünürlük aralığında üç farklı prob ile çalışırken, bu yöntem, 46 görüntü içeren bir veri tabanı üzerinde test edildiğinde, sadece 13.8 ± 31.9 μm (ortalama ± standart sapma) IMT hatası vermiştir. Otomatik sonuçlar, veri tabanındaki her bir görüntü üzerinde 2 gözlemci tarafından gerçekleştirilen 2 manuel gözlemin ortalaması ile karşılaştırılmıştır (Bastida-Jumilla ve diğerleri, 2015).

Filippo Molinari ve arkadaşları tarafından gerçekleştirilen bir çalışmada, bilgisayarlı otomatik karar desteği sırasında, üç bölümlendirme stratejisi geliştirilmiştir: (a) CULEXsa sinyal işleme yaklaşımı, (b) tohum ve hat algılamaya dayalı entegre yaklaşım, ardından olasılığa dayalı bağlantı ve sınıflandırma (CALEXsa) ve (c) morfolojik yaklaşım (WS). Çalışmada, iki karotis duvar sınırını kullanarak birleştiren önyargıların giderilmesine

yardımcı olan bir füzyon tekniği geliştirilmiştir. Bu çoklu sınırların, yani Inter-Greedy (IG) yaklaşımından yararlanarak bu füzyon konsepti genişletilmiştir. IMT bu kaynaşmış sınırlardan ve çoklu kaynaklardan tahmin edilmiştir. Teknikte en az sistem hatası ile başlayarak, zemin gerçeğine göre toplam mesafesini en alt düzeye indirene kadar profillerin köşeleri tekrar tekrar takas edilmiştir. Performans değerlendirmesi ve hata minimizasyonu için polyline mesafe metriği kullanılmıştır. Segmentasyon protokolü 200 Karotis longitudinal B-mode US görüntüsü veri tabanında yayınlanmış ve dört tekniğin performansı (CALEXia, CULEXsa, WS, IG) karşılaştırılmıştır. Greedy arası tekniğin ortalama hatası, 0.32 ± 0.44 piksel (20.0 ± 27.5 μm) olmuştur. Greedy yöntemi için IMT ölçüm hatası 0.74 ± 0.75 piksel (46.3 ± 46.9 μm),% 43.5 ±% 2.4 artış olmuştur (Molinari ve diğerleri, 2011).

Christos P. Loizou ve arkadaşları tarafından yapılan çalışmada, normal kişiler ve böbrek yetmezliği (Renal Failure Disease-RFD) hastalarında ultrasonografide AKA'nın IMT ve çap ölçümlerindeki farklılıkları araştırılmıştır. İki uzman tarafından manuel ölçümler ve otomatik lezyon ölçümleri, 73 normal kişi ve 80 RFD hastası üzerinde gerçekleştirilmiştir. İstatistiksel analiz, $p < 0.05$ Wilcoxon sıra-toplam testi kullanılarak gerçekleştirilmiştir. Sonuçlar ortalama IMT ve yarıçap ölçümlerinin RFD grubunda normal gruba göre anlamlı derecede yüksek olduğunu göstermiştir. Ek olarak, manuel ve otomatik ölçümler arasında anlamlı bir farklılık olmadığı ortaya çıkmıştır (Loizou ve diğerleri, 2014).

Rui Rocha ve arkadaşları tarafından hazırlanmış bir çalışmada US görüntülerinde, AKA'nın hem yakın hem de uzaktaki intima ortam bölgelerinin segmentasyonu için yeni bir yaklaşım önerilmiştir. Algoritma, küresel bir pürüzsüzlük sınırı kullanarak diğer kenarlarla çekimi azaltmak için adventivitenin ayırdedici özelliklerini bütünleştirmiştir. Daha sonra, adventivya lokalizasyonunun bilgisi kullanılarak, dinamik programlama, pürüzsüz yoğunluk eşikleme yüzeyleri ve geometrik yılanlar birleştirilerek lümen sınırı tespit edilmiştir. Plakların çeşitli sınıfları, ebatları ve şekilleri dâhil olmak üzere 24 farklı semptomatik hastadan alınan 47 görüntü kümesi kullanılarak istatistiksel değerlendirme yapılmıştır. İki tıbbi uzmanın elle segmentasyonu için ortalama IMT aralığında olan Bland-Altman grafikleri, gözlemciler arası görüşmelerde yüksek bir oranda (ortalama -0.10 mm ve 0.18 mm arasında) farklılık arz etmiştir. Farklılıkların büyük çoğunluğu uyum sınırları içinde (0.10 mm ile 0.12 mm arasındaki standart sapma) olmuştur. Benzer çizimler, otomatik ve manuel ayırma arasında iyi bir uyum olduğunu ortaya koymuştur (ortalama -0.07 mm ile

0.11 mm arasında ve standart sapma 0.11 mm ile 0.12 mm arasında) (Rocha ve diğerleri, 2010).

Hamid R. Tahmasebpour ve arkadaşları tarafından KA hastalıklarının genel hatlarıyla tanı ve tedavi yöntemlerini belirten bir çalışmada KA US'un, hastalığın tanısı için yaygın bir görüntüleme çalışması olduğu belirtilmiştir. Karotis US sonuçlarının doğruluğunu etkileyebilecek teknik parametreler, doppler açısı, örnek hacim kutusu, renkli doppler örnekleme penceresi, renk hızı ölçeği ve renk kazancıdır. Ekstrakraniyal KA'da aterosklerotik hastalığın tanısında önemli faktörler şunlardır: IMT, plak morfolojisi, stenoz derecelendirmesine ilişkin ölçütler, diseksiyon veya kalp anormalliklerinin varlığı gibi sınırlayıcı faktörler, yakın oklüzyon ile toplam oklüzyon arasındaki ayrım ve bir subklavian çalmanın varlığı. Karotis US sonuçlarının tutarlılığına yönelik, standart bir protokol eksikliği, kötü Doppler tekniği ve Doppler dalga formunda yansıyan hemodinamik değişikliklerin yorumlanması, fiziksel zorlukları içerebilir. Problemli KA stenozlarının sınıflandırılmasındaki engeller, standart bir protokol izlenerek ve tarama tekniklerini ve doppler ayarlarını optimize ederek üstesinden gelinebilir (Tahmasebpour ve diğerleri, 2005).

Rajendra U. Acharya ve arkadaşları tarafından gerçekleştirilmiş bir çalışmada US görüntülerini analiz eden ve bunları semptomatik özelliklere göre semptomatik ve asemptomatik olarak sınıflandırmak için bilgisayar destekli bir tanı (Computer Aided Diagnosis-CAD) sistemini tanımlanmıştır. Önerilen CAD sistemi üç modülden oluşur. Birinci modül, sonraki öznitelik çıkarımı için görüntüleri önişleme işlemidir. Özellik çıkarma aşaması, standart sapmayı, Entropi, simetri ve koşu yüzdesini hesaplamak için görüntü dokusu analizini kullanır. Son olarak, otomatik karar vermede AdaBoost ve Destek Vektör Makineleri (DVM-Support Vector Machine-SVM) kullanılarak sınıflandırma yapılır. Adaboost için, bu algoritmanın beş farklı konfigürasyonunun performansını (En Küçük Kareler, Maksimum Olabilirlik, Normal Yoğunluk Ayrımcılık Ayırımı Fonksiyonu, Cep ve Kütükler) karşılaştırılmıştır. SVM için, beş farklı konfigürasyon (doğrusal çekirdek, farklı siparişlerin polinom çekirdeği konfigürasyonları ve radyal temel fonksiyonu çekirdeği) kullanarak performansı karşılaştırılmıştır. SVM için radyal taban fonksiyonu çekirdeği, en iyi sınıflandırma sonucunu vermiştir: Sınıflandırma doğruluğu %82.4, duyarlılık %82.9 ve özgüllüğü %82.1. Semptomatik ve asemptomatik karotis US görüntülerini tek bir indeks veya sayı kullanarak ayırt etmek için semptomatik/asemptomatik karotis indeksi (SACI) olarak adlandırılan entegre indeks doku özelliklerini kullanarak

önerilmiştir. Bu SACI'nin günlük tarama için vasküler cerrahlar tarafından bir yardımcı araç olarak kullanılabileceği belirtilmiştir (Acharya ve diğerleri, 2012).

Tadashi Araki ve arkadaşları tarafından gerçekleştirilmiş çalışma hipotezi, ateroskleroz hastalığının genetik yapısına, koroner ateroskleroz hastalığı ile karotis plak arasında bir bağlantı olduğuna dair kanıt bulunduğuna dayanmaktadır. Çalışmada koroner risk değerlendirilmesi ve hastaların yüksek riskli veya düşük riskli kişiler olarak sınıflandırılması için bu yeni fikir araştırılmıştır. Koroner risk değerlendirmesi için Intravascular Ultrasound (IVUS) gri skala plak morfolojisi ve subklinik aterosklerozun bir belirteci olan karotis B modlu US karotis IMT kombinasyonu ile bir strateji sunulmuştur. SVM öğrenme paradigması, hem öğrenme hem de test aşamalarının, altı özelliğin kombinasyonel alanlarından türetilen kullanım karakteristiği özelliklerinin varıldığı, daha sonra beş farklı çekirdek seti ile SVM sınıflandırıcı tarafından kullanılan, risk katmanlandırması için uyarlanmıştır. Bu altı özellik kombinasyonel boşlukları, 56 yeni özellik kümesi kullanılarak tasarlanmıştır. En iyi SVM çekirdeği ve en iyi özellik kombinasyon kümesinin optimizasyonu için 10 deneme yapılmıştır. K katlama çapraz doğrulama protokolü kullanılmıştır. Onaylanmış koroner IVUS ve karotis B modlu US 15 hasta üzerinden toplanmıştır: Hasta başına 2865 kare (toplam 42.975 kare) toplanmıştır. Belirtilen protokolü kullanarak sistem optimize edilmiş özellik birleşimi kullanılarak sınıflandırma doğruluğu %94.95 ve AUC'nin 0.95 olduğunu göstermiştir. Bunun, iki hipotezi onaylarken aşırı maliyet yükünü ve daha iyi hastaların kardiyovasküler hastalık yönetimini önlemek için bir tarama aracı olarak risk katmanlandırması için kendi türünün ilk sistemi olduğu belirtilmiştir (Arakia ve diğerleri, 2016).

Nobutaka Ikeda ve arkadaşları gerçekleştirdikleri bir çalışmada, ampul kenarının bir referans işareti olarak yerleştirilmesi için otomatik bir sistem sunmuştur. Önerilen yöntem, karotis geometrisini ve piksel sınıflandırma paradigmalarını birleştiren entegre bir yaklaşım kullanmaktadır. Sistem ilk önce ampul kenarını bulur ve ardından IMT'yi ampul kenarının yakınında ölçer. Sistem aynı zamanda ampul alanındaki IMT'yi de tahmin eder. 649 görüntü veritabanı değişik plak (hafif, orta ila ağır), görüntü çözünürlüğü, şekil, boyut ve etnisiteden oluşmaktadır. Farklı karotis segmentlerindeki IMT bulguları: %34 bulb - IMT, %29,46 s1 - IMT, %11,48 s2 - IMT ve %12,75 s3 – IMT olmuştur. Otomatik sonuçlar, gözlemcinin izleriyle karşılaştırılmıştır. Ortalama lümen intima hatası: 0,01235 ± 0,01224 mm, ortalama medya-adventivite hatası: 0,020933 ± 0,01539 mm ve ortalama IMT hatası: 0,01063 ±

0,0031 mm. Sistem Hassasiyeti: %98,23, otomatik ve gözlemci IMT arasındaki korelasyon katsayısı: 0,998 (p-değeri <0,0001). Tam otomatik ampul algılama sistemi, ampul geçiş bölgesinde okuyucu tarafından işaretlenen ideal ampul kenar konumlarına karşı %92,67 hassasiyet ortaya koymuştur (Ikeda ve diğerleri, 2017).

R.M. Menchón-Lara ve J.L. Sancho-Gómez tarafından yapılmış bir çalışmada AKA US görüntülerinden IMT ölçümleri için makine öğrenmesi ve istatistiksel örüntü tanımaya dayalı tam otomatik bölümlendirme önerilmiştir. Pikseller, IMT sınırlarını belirlemek için yapay sinir ağları vasıtasıyla sınıflandırılmıştır. Ek olarak, Auto-Encoders ve derin öğrenme kavramları sınıflandırma stratejisine dâhil edilmiştir. Önerilen yaklaşım, otomatik segmentasyon ile dört manuel işaretleme karşılaştırılarak, AKA'nın 55 boylamasına US görüntüsü setinde test edilmiştir (Menchón-Lara ve Sancho-Gómez, 2015).

Fausto Milletari ve arkadaşları tarafından yapılmış bir çalışmada, evrişimsel sinir ağlarının (ESA-Convolutional Neural Networks-CNN) soyutlama kapasitelerini kullanarak segmentasyon yapmak için yeni bir yaklaşım önerilmiştir. Yöntem, anatomilerin tam otomatik lokalizasyonu ve segmentasyonunu sağlayan bir strateji olan Hough oylamaya dayanmaktadır. Bu yaklaşım yalnızca CNN sınıflandırma sonuçlarını kullanmakla kalmayarak, aynı zamanda ağın en derin kısmı tarafından üretilen özelliklerden istifade ederek oylamayı uygulamaktadır. Öğrenme tabanlı segmentasyon yönteminin sağlam, çok bölgeli, esnek ve farklı yöntemlere kolayca uygulanabileceği gösterilmiştir. Tıbbi görüntü analizine uygulandıklarında CNN algoritmasının yeteneklerini ve davranışlarını göstermeye çalıştıklarında, çeşitli durumlarda, en yeni kriterlere göre tasarlanmış altı farklı ağ mimarisinin performansları sistematik bir şekilde incelenmiştir. Farklı miktarlarda eğitim verilerinin ve farklı veri boyutlarının (2D, 2.5D ve 3D) son sonuçlara olan etkisini değerlendirilmiştir (Milletari ve diğerleri, 2017).

Derin öğrenme, makine öğrenmesinde yeni ve gelecek vadeden bir alan olarak yapay zekâ problemlerine çözüm için ortaya çıkmıştır. Bu tür yeni yaklaşımlar, otomatik medikal karar verme sistemlerinde gereklidir, çünkü otomatik olmayan süreçler daha pahalıdır, yoğun emek ister ve bu yüzden de insan-kaynaklı hatalara maruzdur. Literatürde derin öğrenme yaklaşımları bilgisayar tanımlama, görüntü işleme, doğal dil işleme ve konuşma tanıma gibi alanlarda yaygın olarak kullanılır. Derin mimarilerin bu alanlardaki performansının

etkileyici olduğu bildirilmiş olsa da, biyomedikal alanda derin öğrenme kullanımı oldukça azdır.

Derin öğrenme algoritmaları kullanılarak tıp alanında farklı çalışmalar gerçekleştirilmeye başlanmıştır. Otomatik abdominal çoğul organ segmentasyonu (Hu ve diğerleri, 2017), mikroskop görüntülerinin sınıflandırılması ve segmentasyonu (Kraus ve diğerleri, 2016), biyomedikal görüntülerin segmentasyonu (Ronneberger ve diğerleri, 2015), beyin tümörünün segmentasyonu (Thillaikkarasi ve Saravanan, 2019), metastatik meme kanserinin tanımlanması (Wang ve diğerleri, 2018), meme kanseri histolojisinde mitoz algılama (Cireşan ve diğerleri, 2013), retina fundus fotoğraflarında diyabetik retinopati tespiti (Gulshan ve diğerleri, 2016), melanom cilt lezyonlarının teşhisi (Premaladha, ve Ravichandran, 2016), pulmoner nodüllerin tespitinde yanlış pozitif indigeme (Dou ve diğerleri, 2017) ve ensefalogram sinyalleri kullanılarak otomatik nöbet tespiti/teşhisi (Acharya ve diğerleri, 2018) bu çalışmalardan bazılarıdır. Söz konusu alanlardaki derin mimarilerin performansının etkileyici olduğu bilinmesine rağmen, tıbbi alanda derin öğrenme kullanımı henüz yeterli değildir.

Günümüze kadar, KA görüntüleri üzerinde çeşitli çalışmalar gerçekleştirilmiştir. Bu çalışmalar iki farklı bölümde incelenebilir:

- KA Intima Media Segmentasyon Çalışmaları,
- KA Intima Media Sınıflandırma Çalışmaları,

Bu araştırmalara göre, henüz KA IMT sınıflandırmasında, derin öğrenme yöntem ve teknikleriyle birlikte yapılan çalışma olmamakla beraber, derin öğrenme çalışmaları şimdiye kadar sadece görüntü segmentasyonu seviyesinde gerçekleştirilmiştir. Sınıflandırma çalışmaları daha çok, makine öğrenmesi yöntemlerinden Destek Vektörü Makineleri ve Sinir Ağları yoluyla gerçekleştirilmiştir.

Bu çalışmada, dünyada ölüme sebep olan hastalıklar sıralamasında 3. sırada, kalıcı sakatlıklar ortaya çıkarma sıralamasında ise en başta olan SVH'ın başlıca sebebi, KA Intima Media Kalınlığı sınıflandırmasına yönelik iyileştirici bir çalışma gerçekleştirilmiştir. Tezde, daha önce uygulanmamış olan derin öğrenme yöntemlerinden CNN kullanılmaktadır. Ankara Eğitim ve Araştırma Hastanesi Radyoloji Bölümünden KA Doppler US görüntüleri

elde etmek için Etik Kurul Belgesi alınmış ve 153 hastadan 501 US görüntüsü elde edilmiştir. Bu görüntüler uzman doktorlar tarafından “Intima Media Kalınlığı Var” ve “Intima Media Kalınlığı Yok” şeklinde sınıflandırıldıktan sonra veriler üzerinde çalışmak için bir derin öğrenme modeli oluşturulmuştur. IMT sınıflandırmasının otomatikleştirilmesi için, oluşturulan model veriler üzerinde test edilmiş ve sonuçları açıklanmıştır.

Tezin ikinci bölümünde SVH ve KA hastalığı, üçüncü bölümünde ise yapay zekâ, makine öğrenmesi ve derin öğrenme kavramları açıklanmıştır. Dördüncü bölümde önerilen strateji ve model açıklanmış, beşinci bölümde deneysel sonuçlar açıklanmıştır. Tezin son bölümlerinde ise sonuçlar, tartışma ve öneriler yer almıştır.

2. SEREBROVASKÜLER HASTALIKLAR

SVH, iskemi veya kanama sebebiyle beyinde herhangi bir bölgenin geçici veya kalıcı olarak hasar görmesi ve/veya beyne giden kan damarlarının patolojik olarak hasar görmesi anlamına gelmektedir (Demirci Şahin ve diğerleri, 2015). SVH, beyne kan taşıyan damarlardaki tıkanıklıklar ve kanamalar sebebiyle ortaya çıkar. Bunun sonucunda hasar gören beyin bölgesinde belirtiler gösterir. İnme ve strok da aynı amaçla kullanılan isimlerdir.

Kanser, kalp hastalıkları ve inme, dünyada en sık ölüme sebep olan hastalıklardır (Strong ve diğerleri, 2007). Sakat bırakan hastalıklar sıralamasında ise eğer erken teşhis edilip tedavi gerçekleştirilmezse, ilk sıradadır (Bousser, 2012). Dünyada her yıl yaklaşık 16 milyon insan inme geçirmektedir (Demirci Şahin ve diğerleri, 2015). Türkiye'de ise SVH sebebiyle ölüm sayısı Çizelge 2.1.'de görüldüğü üzere 2000'li yılların başında 64780 olarak tespit edilmiştir (Ünüvar ve diğerleri, 2004).

Çizelge 2.1. Ölümle sonuçlanan ilk beş hastalık

S. No	Hastalık	Ölüm Sayısı	Yüzde (%)
1	İskemik Kalp Hastalığı (İKH)	93260	21,7
2	Serebrovasküler Hastalıklar (SVH)	64780	15
3	Kronik Obstrüktif Akciğer Hastalığı (KOAH)	25104	5,8
4	Perinatal Sebepler	24756	5,8
5	Alt Solunum Yolu Enfeksiyonları (ASYE)	18225	4,2

Çizelge 2.1.'de görüldüğü gibi İKH %21,7 oranla ilk sırada, %15 ile ikinci sırada SVH ve %5,8 ile üçüncü sırada KOAH ölüme sebep olmaktadır. Perinatal sebepler dördüncü, ASYE ise beşinci sırada yer almaktadır.

Disability Adjusted Life Years (DALY) ölçeği, inme dâhil olmak üzere kronik hastalıklara bağlı mortalite ve özürlülük için kullanılır. DALY varsayımlarına göre 2020 yılında inmenin sebep olduğu ölümlerin sayısının 61 milyona çıkacağı düşünülmektedir (Lackland ve diğerleri, 2012).

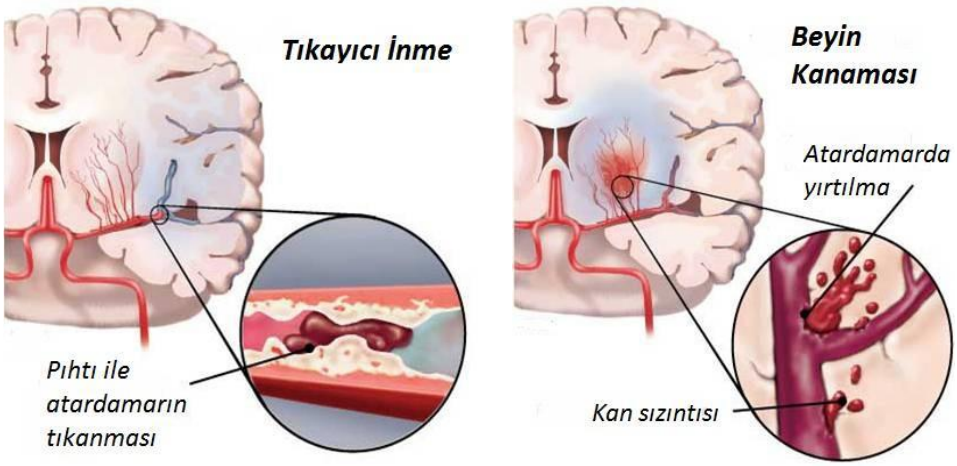
SVH görülme oranı bir toplumdan diğerine, bir cinsiyetten diğerine göre farklı olmaktadır. Buna ek olarak genetik ve yaşam tarzları gibi etmenler de bu oranı etkilemektedir. Hastalığın

görülme oranı, yüz binde 120-200 arası değişmektedir. Türkiye'de ise her yıl yaklaşık 60 bin insan bu hastalığa yakalanmaktadır (Varol, 2018). Bu oran da, Çizelge 2.1.'de belirtilen hastalık sayısı ile örtüşmektedir. SVH'ın ilk günlerinde ölüm oranı %7, birinci hafta sonunda ise %30′dur. Hayatta kalanlarda ise çok az oranda canlılık yeterliliği bulunmaktadır (Varol, 2018).

İnme iki ana tipe ayrılır (Demirci Şahin ve diğerleri, 2015):

- Tıkayıcı inme (iskemik inme)
- Beyin kanaması (hemorajik inme)

Tüm inmelerin %80'i tıkayıcı inme, %20'si ise beyin kanaması şeklindedir (Caplan, 2009). Tıkayıcı inme ve beyin kanaması türleri Şekil 2.1'de gösterilmiştir (Neu, 2018).



a) b)

Şekil 2.1. a) Tıkayıcı inme b) beyin kanaması (Neu, 2018)

Tıkayıcı inme: Bir pıhtının beyni besleyen atardamarlardaki kan akımını bozması, emboli, tromboz veya sistemik hipoperfüzyon sonucu oluşur.

Beyin kanaması: Beyin zarlarında veya dokusunda; hipertansiyon, kan sulandırıcı ilaçlar, baloncuk, sarsıntı, gibi sebeplerden kanama oluşması ve atardamarlardaki yırtılma sebebiyle kan toplanmasıdır.

Kalp veya kan hastalıkları, hipertansiyon, diyabet, kolesterol rahatsızlığı, KA darlığı, sigara içmek, yaşın ilerlemesi, genetik özellikler ve cinsiyet gibi faktörler de SVH'a sebep olan etkenlerdendir.

2.1. Risk Faktörleri

SVH için değiştirilebilir ve değiştirilemez risk faktörleri bulunmaktadır. Bunlardan değiştirilebilecek olanları belirleyerek önlemek, hastalığın önüne geçmek için büyük önem arz etmektedir.

2.1.1. Değiştirilemeyen faktörler

Yaşlanma: İlerleyen yaşlarda SVH sıklığı ve ciddiyeti artar. Gençlerde inme, coğrafi özellikler, cinsiyet ve sosyoekonomik yapıdan etkilenmektedir (Öztürk Ş. , 2009). İnme riskinin erkeklerde her on yaşta 1,66 kat, kadınlarda ise 1,93 kat arttığı belirtilmektedir (Wolf ve diğerleri, 1992).

Cinsiyet: Erkeklerde kadınlara oranla daha sıktır. Ayrıca ateroskleroz kadınlara göre erkeklerde 10 – 15 yıl daha erken ortaya çıkmaktadır (Turgut, 2005).

Irk ve Genetik Faktörler: Bazı toplumlarda SVH daha sıktır. Örneğin siyahilerde, Japon ve Çinlilerde (Turgut, 2005) inme oranı daha yüksektir. Kalıtımsal sebepler de inme riskini %30 arttırmaktadır (Meschia, ve diğerleri, 2014).

2.1.2. Değiştirilebilir risk faktörleri

Hipertansiyon: Hipertansiyon büyük arter tıkanma ve embolizmini kolaylaştırır. Kan basıncının yükselmesiyle birlikte, inme riski de artar (Turgut, 2005). Yüksek kan basıncı damarları yırtarak beyin içine kanamalara sebep olabilir. Hipertansiyon rahatsızlıkları damarlarda plak oluşumu yoluyla daralmalara sebep olabilir veya damarlara zarar verebilir.

Hiperlipidemi: Kan yağlarının yüksekliği bir risk faktörüdür.

Diabetes mellitus: Diabetli hastalarda insülin düzeyinin artması ateroskleroz için önemli bir risk faktörüdür. Diabetes mellituslu hastalarda 3-5 kat daha fazla kardiyovasküler olay görülebilir (Turgut, 2005). Yüksek kan şekeri, damar yapılarında bozulmalara ve kanın pıhtılaşmasının fonksiyon bozukluklarıyla birlikte SVH'a sebep olabilir.

Kalp hastalıkları: Kardiyak embolizm, iskemin inmelerin %20'sini oluştururken, gençlerdeki kriptojenik inmelerin ise %40'ını oluşturur (Turgut, 2005). Kalp ritmindeki bozukluklar, kalp yetmezliği ve kalp kapakçıklarındaki hastalıklar da SVH'a sebep olabilir.

Sigara: En yaygın SVH risk faktörüdür.

Obezite: Kan basıncı, glikozu ve serum lipitleri, inmenin risk faktörleri arasındadır (Demirci Şahin ve diğerleri, 2015). Bel çevresi erkeklerde ve kadınlarda sırasıyla 102 ve 88 cm üzerinde ise ateroskleroz için risk teşkil etmektedir (Turgut, 2005).

Alkol: Sık kullanılan veya aşırı miktarda alınan alkol, kalp hastalıklarına veya damar hasarlarına sebep olduğu için, risk taşımaktadır.

Bunlardan başka; beslenme, yetersiz hareket, ilaç kullanımı ve bağımlığı, hormonal tedavi, orak hücreli anemi vb. risk faktörleri de bulunmaktadır (Turgut, 2005). İnmeyi oluşmadan önce önlemek en önemli hedeftir. Bu sebeple değiştirilebilir olan risk faktörlerini önlemek, sağlık için çok önemlidir.

2.2. Risk Faktörlerinin Dağılım Oranları

Amerikan Kalp Derneği (American Heart Association – AHA) verilerine göre 2006 yılında hipertansiyon prevalansı genel oranda %33,3 olarak belirlenmiştir (Lloyd-Jones ve diğerleri, 2009). Bu verilere göre kardiyovasküler hastalıkların ortak risk faktörü olan hipertansiyon birinci sıradaki risk faktörüdür.

2004'te Avrupa'da yapılan kardiyovasküler risk faktörleri araştırmasında 44 - 65 yaş için (Bovet ve diğerleri, 2006):

- Hipertansiyon %39,6

- Yüksek kolesterol %24,2
- Düşük High Density Lipoprotein (HDL) kolesterol %20,8
- Diabetes mellitus %9,3
- Sigara %17,5
- Obezite %25,1
- Metabolik sendrom %22,1

oranlarında riskli bulunmuştur.

Kardiyovasküler hastalıklar ve inme yaygınlığı, yüksek kan basıncı birlikte ortaya çıkması önemli bir belirtidir. Hipertansiyonun tedavi ile kontrol altına alınabilir olması, değiştirilebilir risk faktörlerinden arasında bulunması ve en yaygını olması, SVH'ın önlenebilmesi yolunda nasıl etkili bir yol izlenebileceğine yönelik politika belirlemede en önemli imkânlardan biri olma özelliği de taşımaktadır (Öztürk Ş. , 2009).

2.3. SVH Belirtileri

Beyinde etkilenen bölgeden bölgeye, SVH belirtileri farklılık göstermekte ve bunlardan önce de uyarıcı bir takım belirtiler ortaya çıkabilmektedir. Örneğin geçici baş dönmeleri, konuşmada bozulmalar, görme kayıpları, zihinsel problemler, vücutta bölgesel uyuşmalar ve karıncalanmalar, beyindeki kan akımında azalmalar sebebiyle ortaya çıkabilir. Böyle durumlarda SVH riski göz önüne alınırsa, hasta atak geçirmeden koruyucu tedaviler uygulanabilir.

Hastanın sorulara cevap verememesi, insanları ve bulunduğu yeri tanımaması, uyku hali gözlenmesi gibi bilinçsel bozukluklar, hastalık belirtileri olabilir. Ayrıca duyu ve denge kayıpları, bulantı ve kusma gibi geçici belirtiler olabileceği gibi, bu belirtiler ilerleme de gösterebilir. Bunları fark eden hastanın kendisi veya yakını hemen hastaneye başvurması gerekmektedir.

2.4. SVH Tanı ve Tedavisi

SVH tanısı yapılabilmesi için hastanın ve/veya yakınının belirtiler ilgili bilgi vermesi gerekmektedir. Bilgi verebilmek için de hastanın yaşadığı olayların gelişim sürecinin iyi bilinmesi gerekmektedir.

Hasta muayenesinde, kranial tomografi, kranial magnetic resonanc (MR), anjiografi gibi görüntüleme teknikleri kullanılabilir. Ayrıca kardiak tetkikler ve beyin tomografisi ile beyin MR da diğer tetkik yöntemlerindendir.

Beyin kanamasına bağlı inme tedavisinde öncelikle hastanın yüksek tansiyon kontrol altına alınır. Eğer hastanın kan inceltici ilaçları varsa kesilir. Bu inme türünde erken tedavi uygulanması önemli olup, trombolik tedaviye uygun hastalara damar açıcı tedavi süreci belirtilerden itibaren ilk 4.5 saattir (neu, 2018).

Damar tıkanıklığına bağlı inmelerde Doppler US, tomografi veya MR anjiografi teknikleri kullanılarak kalp, boyun ve beyin damarları incelenerek uzun sürecek tedavi seçenekleri belirlenebilir. Hastanın büyük damar tıkanıklığı varsa ve stent uygulamaya uygunsa, anjiografik yöntem ile stent uygulanabilir veya damar cerrahisi yapılarak tıkanıklık olan damar açılabilir (neu, 2018).

Önleyici tedaviler olarak aspirin, warfarin gibi ilaçlar, fizik tedavi uygulamasıyla şeker, kolesterol ve yüksek tansiyon hastalıklarının önlenmesi gösterilmektedir (neu, 2018).

2.5. İnme Süreci

2.5.1. Geçici iskemik atak

Akut başlayan ve en çok bir saat içinde tamamen düzelen, serebral, spinal kord veya retinal iskemiye bağlı fokal nörolojik defisite geçici iskemik atak (GİA) adı verilir (Topçuoğlu, 2017). GİA genelde 5 ile 15 dakika içerisinde kendisini gösterir ancak 24 saate kadar sürmesi de mümkündür. Bölgesel Serebral Kan Akımı 15-20 ml/ 100gr/dk.'nın altına düşer (Varol, 2018).

GİA olguları minör inmeler gibi tedavi edilir. Çok hızlı ve zamanında bir yaklaşımla olayın sebebinin ve inme risk faktörlerinin belirlenmesi ve tedavisine başlanması gerekir. Risk yüksek ise hospitalize edilmesi uygundur. GİA sonrası majör inme riski ilk 30 gün içinde %10-%30 olup riskin yaklaşık yarısı ilk 48 saat içinde hayata geçer (Topçuoğlu, 2017).

Aterosklerotik plaklardan kopan emboli, kardiyak kökenli emboliler, kan hastalıkları, hemodinamik kriz gibi sebepler, GİA sebepleri arasında yer almaktadır. %25 oranında sebep ise bilinmeyen sebeplerdir (Varol, 2018).

2.5.2. Tamamlanmış inme

Tipik olarak 3 Ana mekanizmayla oluşur (Uçar, 2011):

- Beyne uzak bir damardaki pıhtının kopup beyindeki bir damarı tıkması.
- Karotis, Vertebral, Serebral gibi beyne yakın damarlarda oluşan aterom plakların beyindeki damarı tıkaması.
- Beyin kanması.

Bunlardan daha az görülen diğer sebepler ise, toplardamarda emboli, beyin damarı yırtığına bağlı kanama, yağ ve hava karışımı gibi sebeplerden dolayı kan yoğunluğu, Multipl Skleroz hastalığı ve tümörler olarak sıralanabilir (Uçar, 2011).

2.5.3. İlerleyen inme

İlerleyen inme, adından da anlaşılacağı gibi nörolojik hastalık bulgularının artarak ilerlemesidir. Bulgular eğer Karotis alanında olursa 18 ile 24 saat arasında, Vertebro Basiller Arterde (VBA) ise 72 saate kadar sürebilir. Distal alan infarktı ve intraserebral hemoraji sebepleriyle büyük arterlerde tıkanmalar yaşanabilir (Varol, 2018).

2.6. İnme Sınıflaması

2.6.1. İskemik inme

Beyine giden kan akışının durması ile oluşan inme türüdür. Bunun sebepleri ise beyne kan taşıyan damarlarda kan pıhtısı veya zamanla oluşan plakların damarda yarattığı tıkanıklıklar veya damar daralmasıdır ve acil müdahale gerektiren bir durumdur. Trombotik ve Embolik olmak üzere iki tür iskemik inme vardır.

Trombotik iskemik inme: Genellikle bir atardamarda aterosklerozun etkisiyle oluşan kan pıhtısının kan akışını durdurması ile oluşur. İskemik inmelerin %60'ı bu türde oluşmaktadır ve bunlardan %70'i büyük, %30'u ise küçük veya penetran arterlerdir (Yavuz, 2018).

Embolik iskemik inme: Bir damardaki kan pıhtısının veya plaktan kopan bir parçanın beyne ulaşarak, beyindeki daha küçük bir damarı tıkamasıyla oluşur.

2.6.2. Hemorajik inme

Hemorajik inme, beyin damarlarındaki kanama sebebiyle ortaya çıkar ve %15-20 oranında gerçekleşir (Tek, 2016). Diğer inme türlerinden farkı, ölüm oranının daha yüksek olması ve daha genç insanlarda görülmesidir. Hemorajik inme Şekil 2.2'de gösterilmiştir (Tek, 2016).



Şekil 2.2. Hemorajik inme (Tek, 2016)

Hipertansiyon, koagulasyon bozuklukları, sarsıntılar, madde kullanımı ve tümörler, hemorajik inmenin sebepleri arasında yer almaktadır. Trombolitik tedavi uygulanmış iskemik inme hastaları, ikincil olarak hemorajik inme geçirebilir. Hemorajik inmeler kanama bölgesine göre isimlendirilir. Bunlar arasında intraserebral, subaraknoidal ve subdural kanamalar en sık karşılaşılan inmelerdir (Tek, 2016). Oluşan kanamalardan %75'i beyin dokusu içine gerçekleşir. Geri kalan %25 oranında kanama ise beyin zarlarının altına kanama yani beynin çevresinedir. Öncesinde GİA öyküsü bulunmayan bu kanamalar aniden ortaya çıkar, şiddetli baş ağrısı, bulantı ve kusma ile birlikte hızlı bir şekilde gelişir ve komaya sebep olabilir.

Subaraknoid kanama (SAK): Beynin yüzeysel damarlarındaki yırtık sebebiyle kanama beyin ile beyin zarları arasında gerçekleşir. Kan damarlarının çeperlerindeki zayıflama dolayısıyla bir balon şeklinde genişleme, yüksek kan basıncı, sarsıntı ve damar anormallikleri, SAK sebepleri arasında yer almaktadır (Pedia, 2006).

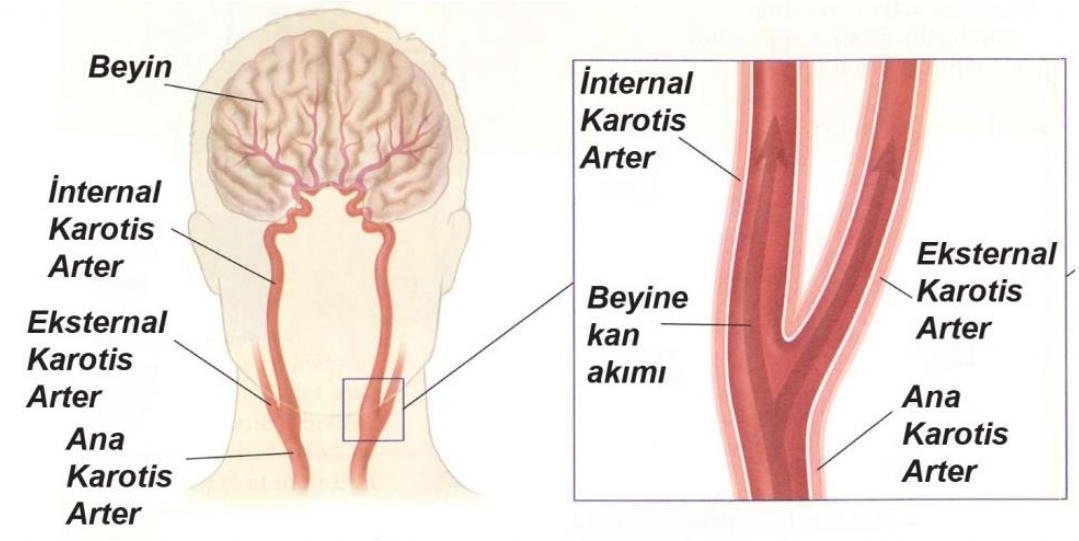
Intraserebral (intraparenkimal) kanama: Beyin dokusu içindeki küçük damarların, genellikle hipertansiyon sebebiyle yırtılması sonucu oluşan ve inmelerin %10-15'ini oluşturan inme türüdür (Varol, 2018).

2.7. Karotis Arter

Karotis Arter (KA), şah damarı olarak da bilinir ve beyne temiz kan taşır. Kalpten çıkan büyük damardan ilk ayrılan atar damarlar olup boynun iki tarafından geçer ve beyne ulaşır (Şekil 2.3). Beynin sağ tarafına giden damar ikiye ayrılarak sağ kola giden damar ve sağ KA şeklinde ilerler. Beynin sol tarafına giden damar ise sol KA olarak tek başına gider (Şekil 2.4). Boynun her iki yanında da elle hissedilen bu damarlar kafatasına girmeden önce iç ve dış dallar olarak ikiye ayrılır. İç damar kafatasın içine girerek beyne temiz kanı taşır (Kocamaz, 2016).



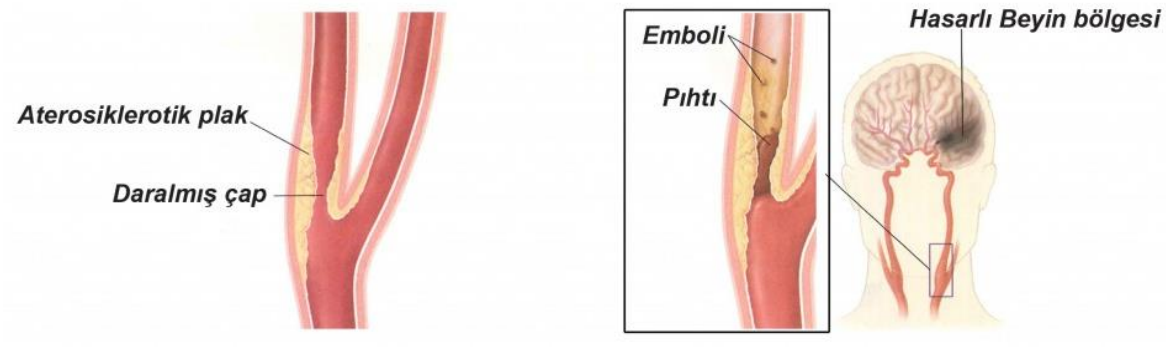
Şekil 2.3. Karotis arter (Civelek, 2014)



Şekil 2.4. Karotis arter iç yapıları (Civelek, 2014)

2.7.1. Karotis arter hastalığı

Kardiyovasküler hastalık grubunda olan KA'nın en önemli sebebi vücudun tüm damarlarında doğal yaşlanma ile oluşan Aterosikleroz'dur. Bu doğal süreç bazı sebeplerin etkisiyle hızlanabilir ve bazı arterler daha erken yaşlarda tıkanabilir. Arter duvarında biriken yağ parçacıkları veya kolesterol, kalsiyum gibi bazı sebeplerle plak oluşumu gerçekleşir ve zamanla hacimleri artarak tıkanmalar oluşur. Karotis arterin tamamen tıkanması ya da içinde oluşan parçacıkların veya kan pıhtılarının, beyne giderek beyin damarlarını tıkamasıyla inme gerçekleşir (Şekil 2.5) (Civelek, 2014).



Şekil 2.5. Karotis arterlerde plak ve daralma (Civelek, 2014)

Bu hastalığın teşhisinde en önemli aşama, kan akımının azaldığı zamanlarda tespit edebilmek ve hastalığı olmadan önlemektir. Çünkü gelişim sürecinde damar tıkanıklığı sebebiyle kan akımında azalma ve plaktan kopan parçacıkların beyin damarlarını tıkaması gerçekleşmektedir (Kocamaz, 2016).

İnme durumu bazen 24 saatten önce tamamen düzelebilen, nadir de olsa bazı hastalarda bir haftayı bulabilen geçici inme şeklinde olabilir. Bu inme durumuna tıpta Transient Ischemic Attack (TIA) denmektedir. Görme kayıpları ve bayılmalar geçici inmenin göstergesidir ve hemen önlem alınmalıdır aksi takdirde inme gerçekleşirse, oluşacak hasar geri dönüşümsüz olabilir (Civelek, 2014).

KA hastalığının her zaman belirtileri olacak diye kesin bir kural yoktur ve bazen rutin kontroller sırasında boyun bölgesinde üfürüm duyulması ile tespit edilebilir. Aterosikleroz tüm damar sistemini etkilediği için bir damar sisteminde rahatsızlığı bulunan hastaların diğer damar sistemlerinde de rahatsızlık görülmesi ihtimali bulunmaktadır (Civelek, 2014). Erken teşhis ve tedavi için, bu şekilde damar rahatsızlığı geçirmiş hastalar, TIA hastaları ve daha önce hiç muayene olmamış 50 yaş ve üzerindeki hastaların mutlaka Doppler US ile KA taraması yapılmalıdır. KA hastalığının belirtileri şöyle sıralanabilir:

- Yüz, kol, bacak gibi yerlerde uyuşma, hissizlik, güç kaybı ve denge kayıpları,
- Anlama ve konuşma güçlüğü, görme kaybı,
- Şiddetli baş dönmesi, baş ağrısı, bulantı ve kusma.

KA hastalığı tedavisi, hastalığın derecesi, hastanın yaşı ve genel sağlık durumuna göre yaşam tarzı değişiklikleri ve diyet uygulamaları, ilaç tedavisi ve bazı tıbbi cerrahi işlemlerle gerçekleştirilir. Böylece hastalığın ilerlemesinin önüne geçilerek inme önlenmeye çalışılır. Hastalığın tanı ve tedavisinde nöroloji uzmanları, beyin ve sinir cerrahisi ile girişimsel radyoloji uzmanları koordineli olarak çalışır. Uygulanan yöntemler şunlardır (TNDer, 2019).

- Yaşam tarzı değişiklikleri
- İlaçla tedavi
- İlaç dışı tedavi
    - Karotis Endarterektomi
    - Karotis Stent Uygulaması (Anjiyoplasti)

KA hastalığı tetkiki için:

- Karotis Ultrasonografisi
- Karotis Anjiografi(DSA)
- Manyetik Rezonans Anjiyografi(MRA)
- Bilgisayarlı Tomografi Anjiyografi (BT Anjiyografi)

sıklıkla kullanılır (TNDer, 2019).

3. YAPAY ZEKÂ

Yapay zekâ kavramı 1950'lerden bu yana kullanılmakla beraber, bu kavram bilgisayar bilimcilerini yeni ve gittikçe daha karmaşık teknolojiler geliştirmeye teşvik etmekte ve günlük hayatta bu teknolojileri kullananlar içinse heyecan yaratmaktadır. Bir nevi bilgisayarların insan davranışını taklit etmesini sağlayan teknikler bütünüdür. Özellikle son yıllarda hayal sınırlarının iyice zorlanmasında etken olan yapay zekâ çalışmaları, her geçen gün yeniliklerle insanların karşısına çıkmaktadır.

Son yıllarda Microsoft, Google, Apple, Facebook gibi dünyanın lider bilişim sektörü kuruluşları artık mobil öncelikli dünyada yaşanmadığını açıklamışlardır. Bunun yerine, dijital asistanların ve diğer hizmetlerin birincil bilgi kaynağı olacağı ve görevlerini yerine getireceği yapay zekâ öncelikli dünya olduğunu belirtmişlerdir. Hatta Birleşik Arap Emirlikleri, dünyada bir ilki gerçekleştirerek Yapay Zekâ Bakanlığı kurmuştur.



Şekil 3.1. Yapay zekâ kullanım alanları

Yapay zekâ kullanım alanları her geçen gün daha da artmakta, yapay zekâ evreni zamanla daha da genişlemektedir (Şekil 3.1).

Yapay zekâyı anlamak ve kullanmak için birçok farklı teknik hakkında düşünmek mümkün ve pek çok farklı yol varken, makine zekâsının anahtarı, hissetmek, mantıklı olmak ve hareket etmek, sonra da deneyime dayanarak uyum sağlamak zorunda olmasıdır (Singh, 2018).

- *Anlam*: Büyük verinin ortasında anlamlı nesneleri veya kavramları tanımlama ve tanıma. Örneğin bir araç stop lambası veya tümörlü/normal bir dokuyu ayırt etme.
- *Sebep*: Daha geniş bağlamı anlama ve bir hedefe ulaşmak için bir plan yapma. Örneğin amaç bir çarpışmayı önlemek ise; araç, araç davranışlarına, yakınlık, hız ve yol şartlarına göre çarpma olasılığını hesaplamalıdır.
- *Hareket*: En iyi hareket tarzını önerme ya da doğrudan başlatma. Örneğin araç ve trafik analizlerine dayanarak, emniyet mekanizmalarını frenleyebilir, hızlandırabilir veya hazırlayabilir.
- *Uyarlama*: Son olarak, her aşamada algoritmalar deneyime dayanarak uyarlanabilmeli ve daha akıllı hale getirilmeye çalışılmalı. Daha fazla kör nokta tanımak, yeni değişkenleri bağlama dâhil etmek ve önceki olaylara dayanarak eylemleri ayarlamak vb.

Hastaneler, klinikler ve tıp ve araştırma enstitüleri günlük olarak laboratuvar raporları, görüntüleme verileri, patoloji raporları, teşhis raporları ve ilaç bilgilerini içeren büyük miktarda veri üretmektedir (Marr, 2017). Sağlık hizmeti verilerinin hızlı bir şekilde genişlemesi, doktorlar için en büyük zorluklardan biridir. Mevcut literatür büyük veri ve yapay zeka çözümlerinin, sağlık hizmetinde sosyal, finansal ve teknolojik talepleri karşılamanın yanı sıra bu büyük veri patlamasını işlemenin çözümleri olduğunu göstermektedir. Bu kadar büyük ve karmaşık verilerin analizi genellikle zordur ve veri analizi için yüksek düzeyde beceri gerektirir. En zor olanı ise, tıbbi deneyime dayanan sonuçların ve tavsiyelerin yorumlanmasıdır. Bunlar yıllarca süren tıbbi çalışmalar, bilgi ve özel becerileri gerektirir (Saraf ve Mike, 2018).

Sağlık alanında veriler sayısal, metin, resimler, taramalar, sesler ve videolar dâhil olmak üzere birçok formatta üretilir, toplanır ve saklanır. Verilere yapay zekâ uygulanmak

isteniyorsa, öncelikle verilerin niteliği ve hedef veri setinden cevaplanmak istenilen tüm soruların anlanması gerekir. Veri türü yapay zekâ modellemesi için sinir ağı, algoritma ve mimarinin formüle edilmesine yardımcı olur (Saraf ve Mike, 2018).

Yapılan araştırmalara göre sağlık alanındaki yapay zekâ pazarı 2021 yılına kadar % 40'lık bir büyüme oranı olan 6,6 milyar dolara ulaşabilir ve tedavi maliyetini %50'ye kadar azaltma potansiyeline sahip olabilir (Sullivan, 2016). Yapay zekâ çalışmaları, sağlık sektöründe 2026 yılına kadar yıllık 150 Milyar dolarlık tasarruf sağlama potansiyeline sahiptir (Collier ve diğerleri, 2017). Yapay zekâ kullanılarak sağlık sektörüne sağlanan etkin çözümler sürekli gelişmektedir:

- Kliniklerdeki yükü hafifletmek ve tıp uzmanlarına işlerini daha etkin bir şekilde yapabilmelerini sağlamak için araçlar,
- Sağlık hizmetlerindeki artan işgücü ihtiyacı sırasındaki boşlukların doldurulması,
- Hastalar için verimliliği, kaliteyi ve sonuçları iyileştirme,
- Sağlık verilerini çeşitli platformlara entegre etmek ve erişim ağını genişletme,
- Daha fazla verimlilik, şeffaflık ve birlikte çalışabilirlik avantajları sağlama,
- Bilgi güvenliğini sağlama.

3.1. Makine Öğrenmesi

Makine öğrenmesi sayesinde, bilgisayarlar artık hava durumunu tahmin etme, borsa sonuçlarını belirleme, alışveriş alışkanlıklarını anlama, bir fabrikada robotları kontrol etmek vb. gibi durumlar için “eğitilebilir” durumdadırlar. Google, Amazon, Facebook, Netflix, LinkedIn gibi firmalar tüketiciye yönelik daha popüler hizmetlerin tümünü makine öğrenmesiyle desteklemektedir. Fakat tüm bu öğrenmelerin merkezinde bir algoritma olarak bilinen şey vardır. Özet olarak bir algoritma tam bir bilgisayar programı değil, tek bir problemi çözmek için sınırlı bir adım dizisidir. Algoritmada özel ve tek bir hedefe ulaşmak için belirli adımlar atılmaktadır.

Özünde makine öğrenmesi deneme yanılma esasına dayanır. Kendi kendini süren bir arabanın bir yayayı bir ağaçtan veya bir araçtan ayırt etmesine yardımcı olabilecek bir program el ile yazılamayabilir ancak verileri kullanarak bu sorunu çözebilecek bir program

için bir algoritma oluşturulabilir. Algoritmalar ayrıca programların bir kasırganın yolunu tahmin etmesine, Alzheimer'ın erken dönemini teşhis etmesine, dünyanın en fazla ödenen ve ödenmeyen futbol yıldızlarını belirlemesine yardımcı olmak için oluşturulabilir. Makine öğrenme algoritmaları temelde programların öngörülerde bulunmalarını sağlar ve zaman içinde deneme yanılma deneyimlerine dayanarak bu tahminlerde daha iyi sonuçlar alır.

Makine öğrenmesi algoritmalarının dört ana türü vardır (Parrish, 2018), (Fumo, 2017):

- Denetimli Öğrenme (Supervised Learning)
- Denetimsiz Öğrenme (Unsupervised Learning)
- Yarı Denetimli Öğrenme (Semi-supervised Learning)
- Takviyeli Öğrenme (Reinforcement Learning)

Denetimli öğrenmede etiketli verileri içeren bir bilgisayar programı sağlanır. Örneğin, görüntüleri sıralamak için bir algoritma kullanarak kedi ve köpek resimlerini ayırma görevi tanımlandığında, kedisi olanların bir "kedi" etiketi olur ve köpeği olan resimlerin "köpek" etiketi olur. Bu bir "eğitim" veri seti olarak kabul edilir ve etiketler, program görüntüleri kabul edilebilir bir oranda başarılı bir şekilde sıralayabilene kadar yerinde kalır. Sürecin sonunda girdi verilerini en iyi tanımlayan işlev seçilir ve verilen *"X"* (girdi) için en iyi tahmini *"y"* (çıktı) yapar. Denetimli öğrenme algoritmaları, hedef tahmin çıktısı ile girdi özellikleri arasındaki ilişkileri ve bağımlılıkları, önceki veri setlerinden öğrendiği ilişkilere dayanarak yeni veriler için çıktı değerlerini tahmin edebilecek şekilde modellemeye çalışır. En Yakın Komşu (Nearest Neighbor), Naive Bayes, Karar Ağaçları (Decision Trees), Doğrusal Regresyon (Linear Regression), Destek Vektör Makineleri (Support Vector Machines), Yapay Sinir Ağları (Artificial Neural Networks) gibi algoritmalar, denetimli öğrenme algoritmalarının başlıcalarıdır.

Denetimsiz öğrenme hiçbir şekilde etiket içermez. Bunun yerine, program iki yöntemden birini kullanarak kedi ve köpek görüntülerini iki gruba bölme görevine kör bir şekilde atılır. Kümeleme algoritmasında bacak boyu, gövde uzunluğu, gözler vb. gibi özelliklere dayalı olarak benzer nesneler bir araya getirilir. Diğer algoritmaya ise ilişkilendirme denir ve programın keşfettiği benzerliklere dayanarak kurallar oluşturulur. Başka bir deyişle, görüntüler arasında ortak bir kalıp belirlenir ve görüntüler buna göre sıralanır. Temel olarak

desen tespiti ve tanımlayıcı modellemede kullanılan makine öğrenme algoritmaları ailesidir. K-Ortalama Kümeleme (K-Means Clustering), Birliktelik Kuralları (Association Rules) gibi algoritmalar, denetimsiz öğrenme algoritmalarının başlıcalarıdır.

Yarı denetimli öğrenme, bilgisayarların hem etiketli hem de etiketsiz verilerin varlığında, insanlar gibi doğal sistemlerin nasıl öğrendiği üzerine yapılan çalışmalarla ilgili bir öğrenme paradigmasıdır (Zhu ve Goldberg, 2009). Yarı denetimli öğrenmede yalnızca birkaç resim etiketlenir. Bilgisayar programı daha sonra etiketlenmemiş görüntüler hakkında en iyi tahminde bulunmak için bir algoritma kullanır ve ardından veriler programa eğitim verileri olarak geri beslenir. Daha sonra sadece birkaç etiketi içeren yeni bir görüntü grubu sunulur. Program kedi ve köpekleri kendi arasında kabul edilebilir bir oranda ayırt edebilinceye kadar tekrarlayan bir işlemdir. Yarı denetimli öğrenme önceki ikisinin arasında yer alır. Etiketleme pek çok durumda uzmanları gerektirdiği için maliyeti oldukça yüksektir. Dolayısıyla, gözlemlerin çoğunda etiket yokluğunda ancak az sayıda mevcut olsa da, yarı denetimli algoritmalar model yapımı için en iyi adaylardır. Bu yöntemler, etiketlenmemiş verilerin grup üyeliğinin bilinmemesine rağmen, bu verilerin grup parametreleri hakkında önemli bilgiler taşıdığı fikrinden yararlanmaktadır.

Takviyeli öğrenmede program oyunun kurallarını ve nasıl oynanacağını bilir ve turu tamamlama adımlarını uygular. Satranç, bu tür bir algoritmaya örnek olabilir. Programa verilen tek bilgi maçı kazanıp kazanmamasıdır. Sonunda bir maç kazanana kadar başarılı hamlelerini takip ederek oyunu tekrarlamaya devam eder. Sürekli olarak yinelemeli bir şekilde çevreden öğrenir. Süreçte aracı, çevre konusundaki deneyimlerinden olası tüm durumları araştırana kadar öğrenir. Zamansal Fark (Temporal Difference (TD)), Q Öğrenme (Q Learning) ve Sarsa algoritmaları, başlıca takviyeli öğrenme algoritmalarındandır.

3.1.1. Denetimli öğrenme

En yakın komşu (nearest neighbor): En yakın komşu algoritmaları şu probleme çözüm arar: Bir X metrik uzayında, n veri noktalarının S kümesi verilir ve bu noktalar önceden işlenerek, verilen herhangi bir X uzayındaki q sorgu noktasının q'ya en yakın veri noktası hızlı bir şekilde raporlanabilmesidir. Bu aynı zamanda en yakın nokta sorunu ve postane sorunu olarak da adlandırılır (Arya ve diğerleri, 1998). En yakın komşu bulma problemi, görüntü

tanıma, örüntü bulma, veri madenciliği, makine öğrenmesi, veri sıkıştırma, istatistik vb. çeşitli uygulamalarda sıklıkla kullanılan bir problemdir.

Bu yöntem denetimli öğrenme yöntemleri içerisinde etkili sınıflandırma algoritmalarından bir tanesidir. Öğrenme kümesi içerisinde bulunan normal davranış benzerlikleri hesaplanarak, en yakın görülen "*k"* verinin ortalamasının oluşturduğu eşik değerine göre sınıflandırma işlemi gerçekleştirilir. Burada sınıflandırma işlemi için öncelikle, sınıf özelliklerinin belirlenmiş olması gerekmektedir. Ayrıca "*k*" komşu sayısı, benzerlik ölçümü, eşik değeri ve öğrenme kümesindeki normal davranışların yeterliliği, bu yöntemin performansını etkileyen faktörlerdendir (Kırmızıgül Çalışkan ve Soğukpınar, 2008).

Basit bir yapıda olmasına rağmen özellikle büyük eğitim kümeleri için uzaklık-yakınlık belirleme işlemi maliyetli olabilmektedir. Bundan kaçınmak için bu algoritmada boyut azaltma yöntemi uygulanabilir veya arama ağaçları gibi daha güçlü veri yapıları ile birlikte kullanılabilir (Taşcı ve Onan, 2016).

K en yakın komşu algoritmasının performansı için önemli parametreler komşu sayısı "k", ağırlıklandırma yöntemi ve uzaklık ölçütüdür. Başlıca uzaklık ölçütleri olarak, Minkowski (Eşitlik 2), Öklid (Eşitlik 3) ve Manhattan (Eşitlik4), uzaklıklarından bahsedilebilir.

Minkowski

$$\left(\sum_{i=1}^{k}(|x_i - y_i|)^q\right)^{1/q} \quad (2)$$

Öklid

$$\sqrt{\sum_{i=1}^{k}(x_i - y_i)^2} \quad (3)$$

Manhattan

$$\sum_{i=1}^{k}|x_i - y_i| \quad (4)$$

Denklemlerde x ve y iki farklı noktayı ifade etmektedir. Minkowski uzaklığında, farklı q değerleri için çeşitli uzaklık ölçütleri tanımlanabilir.

Naive bayes sınıflandırıcı: Naive Bayes bir olasılık sınıflandırıcı algoritmasıdır. Bu algoritmada veri içerisinde bulunan değerlerin frekansları ve bunların aralarındaki

kombinasyonlar sayılarak bir olasılık kümesi oluşturulur (Patil & Sherekar, 2013). Algoritma matematikçi *Thomas Bayes teoremini* (Eşitlik 5) kullanır ve sınıf değişkeninin değeri göz önüne alındığında tüm değişkenlerin bağımsız olduğunu varsayar.

Bayes Teorem

$$p(c_j|\, d\,) = \frac{p(d\,|c_j)\, p(c_j)}{p(d)} \tag{5}$$

Denklemde d bilinen durum, c_j ise farklı koşullu durumları ifade etmektedir.

Naive Bayes teoremi, avantaj ve dezavantajları olarak aşağıdaki özelliklere sahiptir (Saharkhiz, 2009):

Çizelge 3.1. Naive Bayes teoremi avantaj ve dezavantajları

Avantajları	Dezavantajları
• Nicel ve ayrık verileri yönetir. • İzole edilmiş gürültü noktalarına dayanıklıdır. • Örneği yok sayarak eksik değerleri ele alır. • Olasılık sırasında tahmin hesaplamaları yapar. • Hızlı ve yerden verimlidir. • Alakasız özelliklere duyarlı değildir. • Kuadratik karar sınırı vardır.	• Şartlı olasılık sıfırsa, öngörülen olasılık sıfır olacaktır. • Özelliklerin bağımsızlığını varsayar.

Karar ağaçları (decision trees): Bir sınıflandırma ağacı, bir nesnenin sınıfını yordayıcı değişkenlerin değerlerinden tahmin etmek için deneysel bir kuraldır (SPSS, 1999). Tahminsel bir model olup ağaç yapısında ilerlediğinden bu isim verilmiştir. Ağacın dalları ve yaprakları, sınıflandırma probleminin çözümünü içeren parçalardır. Karar ağaçları avantaj ve dezavantajları olarak aşağıdaki özelliklere sahiptir (Pehlivan, 2006), (BÜ, 2019).

Çizelge 3.2. Karar ağaçlarının avantaj ve dezavantajları

Avantajları	Dezavantajları
• Sınıflandırma işlemi küçük hesaplamalarla gerçekleştirilir. • Kategorik veya sürekli değişkenler ile karmaşık veri kümelerine uygulanabilir. • Değişkenlerin önem sırası hem sınıflandırma hem de tahmin için açıkça belirtilir. • Bağımlı ve bağımsız değişkenlerin ilişkileri ağaç şeklindeki görselleştirmeden dolayı kolay anlaşılabilir ve yorumlanabilir. • Bağımlı değişkenler için tüm bağımsız değişken kombinasyonları hesaplanarak en doğru hesaplama yapılmaya çalışılır. • Değişkenlerdeki kayıplardan veya uç değerlerden etkilenmez.	• Sürekli nitelik değer tahmininde başarısı düşüktür. • Fazla sınıf sayısında ve az öğrenme kümesi örnekleminin olduğu modellerde başarı düşüktür. • Nitelik sayısı, ağaç yapısı ve öğrenme kümesi örnek sayısı, modelin zaman ve yer karmaşıklığını etkiler. • Zaman ve yer karmaşıklığı öğrenme kümesi örnekleri sayısına, nitelik sayısına ve oluşan ağacın yapısına bağlıdır. • Ağaç oluşturma ve budama karmaşıklıkları vardır.

Karar ağacı oluşturmak için geliştirilen algoritmalar arasında şunlar sayılabilir (Albayrak ve Koltan Yılmaz, 2009), (Emel ve Taşkın, 2005) (Uzgören ve diğerleri, 2005):

- CHAID (Chi- Squared Automatic Interaction Detector),
- C4.5,
- C5.0,
- CRT (Classification and Regression Trees),
- Exhaustive CHAID,
- ID3,
- MARS (Multivariate Adaptive Regression Splines),

- QUEST (Quick, Unbiased, Efficient Statistical Tree),
- SLIQ (Supervised Learning in Quest),
- SPRINT (Scalable Paralleizable Induction of Decision Trees)

Doğrusal regresyon (linear regression): Regresyon analizi istatistiksel bir tekniktir ve değişkenler arasındaki ilişkiyi araştırıp modellemek için kullanılır. (Montgomery, Elizabeth, Peck, & Vining, 2012). Bu teknikte tahmin edilmeye çalışılan "*Y*" değişkeni ile tahminleyici "$X_1, X_2, \ldots, X_n$" değişkenler arasında bir ilişki olduğu varsayılır. Doğrusal regresyon analizi basit ve çoklu doğrusal regresyon olmak üzere ikiye ayrılır (Arı ve Önder, 2013).

Basit ve çoklu doğrusallığı, yanıt değişkeni ile açıklayıcı değişken arasındaki ilişki açıklamaktadır. Bu ilişkide tek bir açıklayıcı değişken varsa basit regresyon, birden fazla açıklayıcı değişken varsa çoklu regresyon analizi kullanılabilir (Okur, 2009), (Weisberg, 2005). Basit ve Çoklu regresyon için aşağıdaki eşitlikler kullanılmaktadır (Kutner ve diğerleri, 2005).

Basit Regresyon

$$Y = \beta_0 + \beta_1 X_{1i} + \in_i \quad i = 1,2,\ldots,n \tag{6}$$

Çoklu Regresyon

$$Y_i = \beta_0 + \beta_1 X_{i1} + \beta_2 X_{i2} + \cdots + \beta_p X_{ip} + \in_i \quad i = 1,2,\ldots,n \tag{7}$$

Destek vektör makineleri (support vector machines-SVM): Doğrusal ve doğrusal olamayan veriler için sınıflandırma yapabilen özellikle sınıflandırma ve regresyon için kullanılan bir algoritmadır (Çomak ve diğerleri, 2007; Santhanam ve Padmavathi, 2015). 1979 yılında Vapnik ve Lerner tarafından tanıtılan SVM, kısıtlı durumlarda eğitim verilerine hatasız olarak uygulanabilirken, Cortes ve Vapnik 1995 yılında ayrılmayan eğitim verilerine de uygulanarak genişletilmiştir (Cortes ve Vapnik, 1995). SVM hedef verileri sınıflandıran en uygun ayırma hiper düzlemini bulmaya odaklanır. Doğrusal ve doğrusal olmayan iki tipik varyasyonu kullanarak regresyon ve sınıflandırma problemlerini ele alır (Calp, 2018).

SVM ile ampirik risk minimizasyonu prensibine göre değil de, istatistiksel öğrenme teorisindeki yapısal risk minimizasyonu niteliğinde çalışılır (Yakut ve diğerleri, 2014).

SVM'de temel olarak eğitim kümesindeki örneklerin bağımsız ve benzer olarak dağıtıldığı varsayılır (Song ve diğerleri, 2002).

SVM, problemlerin çözümüne ulaşmak için çekirdek fonksiyonlarını kullanır. Sıklıkla kullanılan çekirdek fonksiyonları şöyledir (Çankaya ve diğerleri, 2018):

Doğrusal Fonksiyon

$$K(x_i, x_j) = x_i^T x_j \tag{8}$$

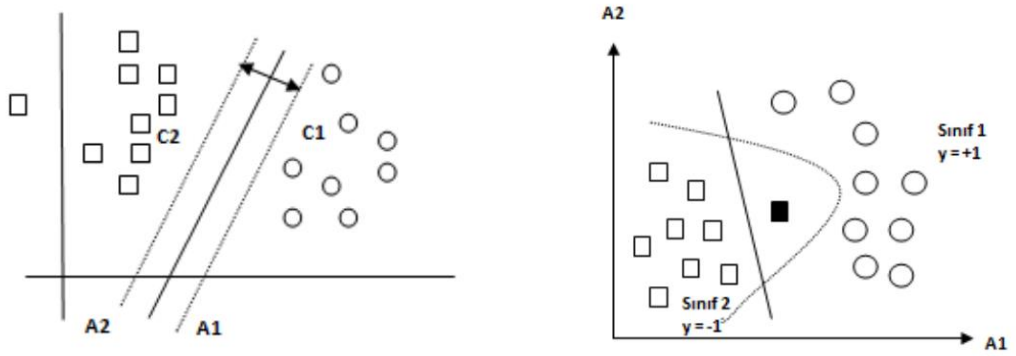
Polinom Fonksiyon

$$K(x_i, x_j) = (1 + x_i^T x_j)^p \tag{9}$$

Gauss (RBF) Fonksiyon

$$K(x_i, x_j) = e^{\frac{||x_i - x_j||^2}{2\sigma^2}} \tag{10}$$

Lineer ayrılabilme durumunda optimum ayırıcı aşırı düzlem (Yakut ve diğerleri, 2014) ile, birbirinden doğrusal olarak ayrılamayan verilerin olduğu durumdaki düzlemler (Özkan, 2008), Şekil 3.2'de gösterilmiştir.

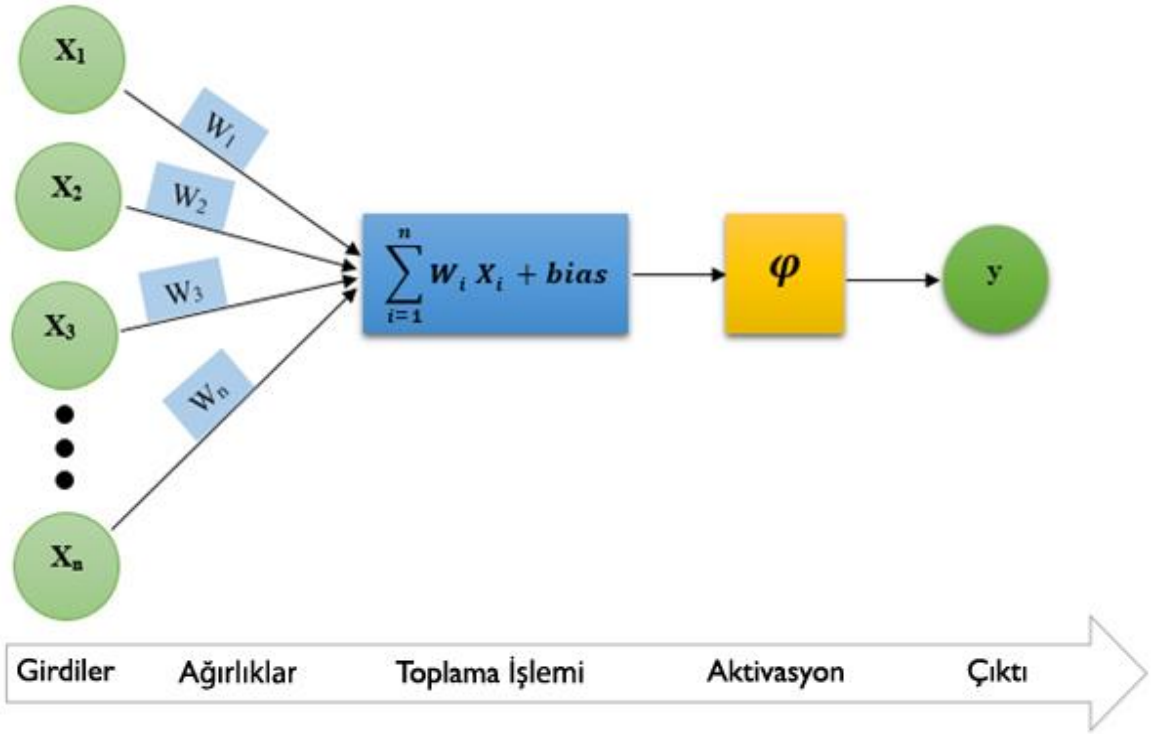


a) b)

Şekil 3.2. Linear ayrılma (a) ve ayrılamama (b) durumlarında SVM (Yakut ve diğerleri, 2014; Özkan, 2008)

Yapay sinir ağları (artificial neural networks): Yapay sinir ağları (YSA), değişen ağırlıklarda bağlantılarla birbirine bağlanan ve her biri kendi belleğine sahip işlem elemanlarından oluşan, insan beyninden esinlenerek geliştirilen bilgi işleme yapılarıdır.

Şekil 3.3'te görüldüğü gibi YSA, kendisine verilen girdiye ağırlıklar ve aktivasyon fonksiyonunu kullanarak bir çıktı üretmektedir.



Şekil 3.3. Yapay sinir ağı

Sinir hücreleri, girdi katmanı, ara katmanlar ile çıktı katmanı olmak üzere 3 katman halinde ve her katman içinde paralel olarak bir araya gelir ve ağı oluştururlar. Bu katmanlar (Öztemel, 2003):

- Girdi katmanı: İşlem elemanlarının dışarıdan alınarak ara katmanlara transfer edildiği, bilgi işlemenin gerçekleştirilmediği katmandır.
- Ara katmanlar: Girdi katmanından gelen bilgilerin işlendiği katmanlardır ve birden fazla olabilirler.
- Çıktı katmanı: Ara katmandan gelen bilgi işlenir ve girdi için üretilen çıktı dışarıya gönderilir.

Yapay sinir ağları, öğrenme ve genelleme, veriye uyum, paralel çalışabilme, doğrusal olmama, hata toleransı gibi çeşitli üstünlüklere sahiptir. Mühendislik, tıp, finans, endüstri vb. gibi pek çok uygulama alanlarında kullanım örnekleri de mevcuttur (Arı ve Berberler, 2017).

3.1.2. Denetimsiz öğrenme

K-ortalama kümeleme (k-means clustering): K-Ortalama Kümeleme (MacQueen, 1967), bir veri setini otomatik olarak k adet gruba ayırmak için yaygın olarak kullanılan bir yöntemdir. İlk olarak k adet küme merkezi seçilir ve sonrasında yinelemeli olarak şu şekilde yeniden düzenlenir (Wagstaf ve diğerleri, 2001):

1. Her bir örnek d_i, en yakın küme merkezine atanır.
2. Her küme merkezi C_j, kendisini oluşturan örneklerinin ortalaması olarak güncellenir.

Algoritma, kümelere örnek atanmasında başka bir değişiklik olmadığında birleşir. En yakın küme merkezine atama işlemi için hesaplamada, Eşitlik 3'te gösterilen Öklid mesafesi hesabı kullanılır (Dinçer, 2006).

Çizelge 3.3. K-Ortalama kümeleme algoritması avantaj ve dezavantajları

Avantajları	Dezavantajları
• Kolay uygulanabilen ve büyük veri kümelerinde de çalışan bir algoritmadır. • Veri seti büyük olan çalışmalarda eğer az sayıda küme varsa, hiyerarşik algoritmalardan daha hızlı sonuç verebilir.	• Otomatik olarak küme sayısı bulunamadığı için deneme yanılma süreci, zaman kaybına sebep olur. • Gürültülü verilerin de kümelere dâhil edilmesi mümkündür.

Birliktelik kuralları (association rules): Birliktelik kuralları, büyük veri kümeleri arasındaki ilişkileri bulmak için kullanılır. Bu teknik, 1993 yılında Agrawal, Imielinski ve Swami tarafından geliştirilmiştir (Agrawal vd., 1993):

$I = \{i_1, i_2, \dots, i_n\} \rightarrow$ n tane ürünün öznitelikler kümesi,

$D = \{t_1, t_2, \dots, t_m\} \rightarrow$ veri tabanı olarak adlandırılan işlemler kümesi,

D kümesi içerisindeki her işlem, eşsiz bir işlem ID numarasına sahiptir ve I kümesi içindeki öğelerin bir alt kümesini içerir. Kural olarak: $X => Y, \quad X, Y \subseteq I$ şeklinde tanımlanmıştır.

Birliktelik kuralı, aynı alışveriş sepetindeki iki nesne arasındaki ilişki olarak tanımlanabilir. Bir sepette, öncül kalem olarak bilinen bir nesnenin varlığı, ardıl (bağlı) kalem olarak bilinen diğer nesnenin olma ihtimalini arttırdığında, iki nesne arasında pozitif birliktelik kuralı vardır denir. Ayrıca bir sepette öncül nesnenin varlığı, ardıl nesnenin aynı sepette veya işlemde olmaması olasılığını arttırdığında ise n-öncül nesnenin ardıl nesne ile negatif birliktelik kuralından söz edilir. Birliktelik kuralları, simetrik değildir, dolayısıyla, X nesne ile Y nesne arasında belli bir birliktelik kuralının olması, ters yönde de yani Y'nin X ile bir birliktelik kuralı olmasını gerektirmez (MALIK ve diğerleri, 2018). Birliktelik kuralları için kullanılan farklı algoritmalar bulunmaktadır ve Apriori algoritması, bu algoritmalar arasında en çok bilinenidir:

- AIS
- Apriori
- CHARM
- FP-Growth
- Partition
- RARM (Rapid Association Rule Mining)
- SETM

3.1.3. Yarı denetimli öğrenme

Kendi kendine eğitim (self training): Yarı denetimli öğrenmede sıklıkla kullanılan bir tekniktir. Bu teknikte sınıflandırıcı öncelikle küçük boyutta bir etiketlenmiş veri ile eğitilir. Daha sonra bu sınıflandırıcı, etiketlenmemiş veri üzerinde kullanılarak sınıflandırma denenir. Tipik olarak en güvenli etiketlenmemiş noktalar, öngörülen etiketleriyle birlikte, eğitim setine eklenir. Bu işlem tekrar edilerek sınıflandırıcı eğitilmeye devam edilir (Zhu ve diğerleri, 2005).

Kendi kendine eğitim algoritması (Xia, 2006):
L etiketli veri kümesi, U etiketlenmemiş veri seti iken;

TEKRAR:

- Bir h sınıflandırıcısı eğitim verilerini L ile eğit,
- U içerisindeki verileri h ile sınıflandır,
- En güvenli skorlara sahip bir U alt kümesi olan U' kümesini bul,
- L + U' → L
- U – U' → U

Çizelge 3.4. Kendi kendine eğitim tekniğinin avantaj ve dezavantajları (Zhu, 2007)

Avantajları	Dezavantajları
• En basit yarı denetimli öğrenme yöntemidir. • Bir sarmalayıcı yöntemi, mevcut (karmaşık) sınıflandırıcılara uygulanır • Genellikle doğal dil işleme gibi gerçek görevlerde kullanılır.	• Erken hatalar kendilerini güçlendirebilir. • Yakınsama açısından kapsamlı yorumlanamaz.

Üretken karışım modelleri (generative mixture models): En eski yarı denetimli öğrenme yöntemlerinden birisidir. Bir üretken modeli: $P(x,y) = p(y)p(x|y)$ => burada $p(x|y)$ tanımlanabilir bir karışım dağılımıdır. Örneğin Gaussian karışımı modelleri. Büyük miktarda etiketlenmemiş verilerle, karışım bileşenleri tanımlanabilir; o zaman ideal olarak karışım dağılımını tam olarak belirlemek için her bileşen için yalnızca bir etiketli örneğe ihtiyaç vardır. Karışım bileşenleri "yumuşak kümeler" olarak düşünülebilir. Bu yöntemde şunlara dikkat edilmelidir (Zhu, 2005):

- Tanımlanabilirlik,
- Model doğruluğu,
- Beklenti-maksimizasyonu,
- Küme ve etiket.

Çizelge 3.5. Üretken karışım modellerin avantaj ve dezavantajları (Zhu, 2007)

Avantajları	Dezavantajları
• Açık, iyi çalışılmış olasılık çerçevesi. • Model doğruya yakınsa, son derece etkili olabilir.	• Genellikle modelin doğruluğunu onaylamak zor. • Model tanımlanabilirliği. • Üretken model yanlışsa etiketlenmemiş veriler zarar görebilir.

Yarı denetimli destek vektör makinesi (semi-supervised support vector machine-S^3VM): Yarı denetimli destek vektör makinesi, küme varsayımına dayanan yarı denetimli bir öğrenme yöntemi olarak Bennett ve Demiriz tarafından önerilmiştir (Bennett & Demiriz, 1999). S^3VM'nin en temel amacı etiketli verileri ve etiketlenmemiş verileri kullanarak sınıflandırıcı oluşturmaktır. SVM fikrine benzer şekilde S^3VM, etiketli verileri ve etiketlenmemiş verileri ayırmak için maksimum marjı gerektirir ve yeni optimal sınıflandırma sınırı, orijinal etiketlenmemiş verilerdeki sınıflandırmanın en küçük genelleme hatasına sahip olduğunu karşılamalıdır (Ding, Zhu, & Zhang, 2015).

Yarı denetimli destek vektör makineleri, bazı sınıflandırma problemlerinde yaygın olarak kullanılabilir. Potansiyel uygulamalar görüntü sınıflandırma ve metin sınıflandırma olmakta ve bu iki konuda, yarı denetimli destek vektör makineleri iyi sonuçlar göstermektedir (Ding ve diğerleri, 2015). Yarı denetimli destek vektör makinesinin avantaj ve dezavantajları Çizelge 3.6'da verilmiştir (Zhu, 2007).

Çizelge 3.6. Yarı denetimli destek vektör makinesinin avantaj ve dezavantajları

Avantajları	Dezavantajları
• Destek Vektör Makinelerinin uygulanabildiği her yerde kullanılabilir. • Anlaşılır matematiksel çerçeveye sahiptir.	• Optimizasyonu zor ve sıkışıp kalabilir. • Üretken model veya grafik tabanlı yöntemlerden daha mütevazı varsayım, potansiyel olarak daha az kazanç.

Grafik tabanlı algoritmalar (graph-based algorithms): Grafik tabanlı yarı denetimli yöntemler, düğümlerin veri kümesinde etiketli ve etiketsiz örnekleri gösterdiği ve kenarların (ağırlıklı olabilir) örneklerin benzerliğini yansıttığı bir grafiği tanımlar. Bu yöntemler genellikle grafik üzerinde etiket düzgünlüğü varsaymaktadır. Grafik yöntemleri parametrik olmayan, ayırt edici ve doğada transdüktiftir (Zhu, 2005).

Grafik tabanlı yöntemlerde, her bir numunenin etiket bilgisi, tüm veri setinde global bir stabil duruma ulaşılana kadar komşu örneğine yayılır. Burada, düğümlerin etiketsiz ve etiketli örneklerle belirtildiği düğüm ve kenarlardan oluşan bir grafik oluşturulur, kenarlar etiketsiz ve etiketsiz örnekler arasındaki benzerlikleri belirtir. Burada her veri örneğinin etiketi, komşu noktalarına ilerletilir (Sheikhpour ve diğerleri, 2017).

Grafik yapısı: $G = (V, E)$ olarak yapılandırılır.
Burada:
V: etiketli ve etiketsiz veri örneklerini belirten bir dizi köşe,
E: etiketli ve veri setinden etiketlenmemiş örnekler arasındaki benzerlikleri gösteren bir kenar kümesidir (Sawant ve Prabukumar, 2018).

Çizelge 3.7. Grafik tabanlı algoritmaların avantaj ve dezavantajları (Zhu, 2007)

Avantajları	Dezavantajları
• Anlaşılır matematiksel çerçeveye sahiptir. • Grafik göreve uygun hale gelirse performans güçlüdür. • Laplacianın tersi (sözde) bir çekirdek matrisi olarak görülebilir. • Yönlendirilmiş grafiklere genişletilebilir.	• Grafik kötü ise performansı da kötüdür. • Grafik yapısına ve kenar ağırlıklarına duyarlıdır.

Bazı grafik tabanlı yarı denetimli öğrenme algoritmaları şunlardır (Zhu, 2007):

- Harmonic,

- Local and global consistency,
- Manifold regularization,
- Mincut,

Çoklu görüntü algoritmaları (multiview algorithms): Aynı girdi verilerinin yedekli görünümlerinin talebi, çoklu görünüm ve tek görünüm öğrenme algoritmaları arasında büyük bir farktır. Bu çoklu görüntüler sayesinde, öğrenme görevi bol miktarda bilgi ile yapılabilir. Bununla birlikte, öğrenme metodu çoklu görüntülerle uygun şekilde başa çıkamıyorsa, bu görüntüler çoklu görüntülü öğrenmenin performansını düşürebilir (Xu ve diğerleri, 2013).

3.1.4. Takviyeli öğrenme

Bu öğrenmede kendi ortamını algılayan ve ortamında hareket yapan özerk bir etmenin, amacını gerçekleştirmek için en uygun hareketleri yapmayı nasıl öğrenebileceği sorusuna cevap verilir (Kaelbling ve diğerleri, 1996). Robotik, oyun programlama, hastalık tanı ve teşhisi, otomasyon gibi sistemlerde yaygın olarak kullanılmaktadır.

Takviyeli öğrenme ortamında etmendeki bir hareketinin karşılığı olarak eğitici veya yazılım, yeni durumun istem durumunu belirtmek için bir ödül veya ceza ile etmeni takviye işlemi gerçekleştirir. Böylece bu sistemde, amaca ulaşmak için gerçekleştirilebilecek en iyi eylem seçilmeye çalışır (Hoshino ve Kamei, 2003).

Takviyeli öğrenme ile problemleri çözmek için iki ana yöntem vardır: Bunlardan ilki, ortamı iyiye götüreni bulmak için eğitim uzayında bir arama yapmak, ikincisi ise faydalı hareketi tahmin etmek için istatistik ve dinamik programlama yöntemlerini kullanmaktır (Sutton ve Barto, 1998).

Takviyeli öğrenmenin amacı optimal politikayı bulmaktır. Optimal politika, etmenin problemi optimal yönden çözmesini ve sonuca ulaşmasını sağlar. Böylece etmen hedefi olan en yüksek ödül değerine de ulaşmış olur. Optimal politika rasgele bir s_t durumundan başlanmış indirgenmiş toplam ödül miktarının maksimum değeri şeklinde ifade edilebilir. Takviyeli öğrenmede etmenin amacına ulaşması için eğitmen veya yazılım tarafından belirlenen amaç ve ödüller büyük önem taşımaktadır. Bu sebeple takviyeli öğrenme

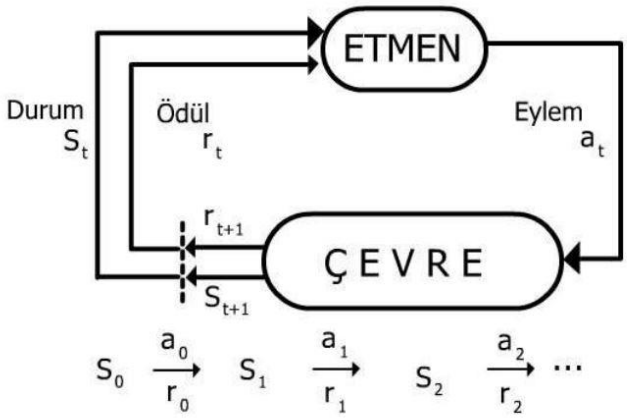
metoduyla tasarlanan sistemlerde amaç ve ödüllendirmenin, etmenin başarısını etkilediği ve ne kadar önemli olduğu görülmektedir. (Hacıbeyoğlu, 2006).

Maksimize Edilmiş Toplam Ödül

$$\prod = \arg\max(V^{\Pi}(s_t)) \qquad (11)$$

Burada Π davranış politikası, V ise değer fonksiyonu olup s_t ise t anındaki davranış durumudur.

Takviyeli öğrenmenin denetimli öğrenmeden en belirgin farkı, etmenin tahminleri için etmene sadece bir kısım geribildirim verilir. Ayrıca buradaki tahminler kontrol edilen sistemin gelecekteki durumu üzerinde uzun vadeli etkili olabilir. Böylece zaman önemli bir faktör olmaktadır (Szepesvari, 2010). Takviyeli öğrenme sistemi Şekil 3.4'te gösterilmiştir (Hacıbeyoğlu, 2006).



Şekil 3.4. Takviyeli öğrenme sistemi

Bir takviyeli öğrenme sisteminde etmen ve çevre dışında biri opsiyonel olmak üzere dört unsur bulunur (Kayaoğlu ve diğerleri, 2018):

- Politika (policy)
- Ödül (reward signal)
- Değer/Durum Değeri (value function)
- Çevre modeli (model)

Politika**;** etmenin içinde bulunduğu durumda alabileceği aksiyonu belirler. Ödül**;** etmenin gerçekleştirmiş olduğu bir aksiyona karşılık çevreden aldığı puandır. Durum değeri**;** etmenin içinde bulunduğu durumdan ve o durumu takip eden diğer durumlardan bekleyebileceği ödüllerin toplamıdır. Model**;** isteğe bağlı olarak sisteme dâhil edilen bir unsurdur (Kayaoğlu ve diğerleri, 2018).

Zamansal fark öğrenimi (temporal difference learning – TD learning): Zamansal fark öğrenmenin açıklanmasından önce, temel bir değer fonksiyonları anlayışı ile başlamak gerekir. Değer fonksiyonları, belirli bir eylemin belirli bir durumda ne kadar iyi olacağını tahmin eden durum-eylem çifti işlevleridir veya bu eylemin geri dönüşünün ne olacağını tahmin eder. Değer fonksiyonları gösterimi (Eden ve diğerleri, 2019):

$V^{\pi}(s)$ – π politikasındaki s durumunun değeri.
$Q^{\pi}(s,a)$ - π politikasındaki s durumunun, a hareketini gerçekleştirme değeri (Q değeri).

Burada bulunan problem, belirli bir politika için bu değer işlevlerini tahmin etmektir. Bu değer işlevlerini tahmin etmenin sebebi, verilen durumda gerçekleştikten sonra, mümkün olan en iyi toplam ödülü sağlayacak bir işlemi, doğru bir şekilde seçmek için kullanılabilecek olmalarıdır (Eden ve diğerleri, 2019).

TD öğrenim yöntemi, ortamın dinamikleri modeli olmadan doğrudan ham deneyimlerden öğrenebilen bir takviyeli öğrenme algoritmasıdır. Bu yöntemde, nihai bir sonuç beklemeden, diğer öğrenilmiş tahminlere dayanan tahminler kısmen güncellenir (önyükleme yapılır) (Sutton ve Barto, 1998). TD öğrenim yönteminde tahminler öğrenme sürecinde hedef olarak kullanılır. Modelsiz bir öğrenme algoritması olan TD öğrenimin iki önemli özelliği vardır:

- Model dinamiğinin önceden bilinmesini gerektirmez.
- Epizodik olmayan görevler için de uygulanabilir.

TD öğrenim değer fonksiyonlarını tahmin etmek için kullanılabilir. Değer fonksiyonları tahmin edilmeksizin hesaplanacak olsaydı, herhangi bir durum-eylem çifti değerleri güncellenmeden önce, son ödülün alınmasını beklemek gerekirdi. Nihai ödül alındıktan sonra, nihai duruma ulaşmak için alınan yolun geri dönülmesi ve her değerin buna göre güncellenmesi gerekirdi. Bunun yerine TD öğrenim yöntemleriyle, her bir durumda nihai

ödülün bir tahmini hesaplanır ve durumun her adımı için durum-eylem değeri güncellenir. Bu hesap şöyle ifade edilir (Eden ve diğerleri, 2019):

$$V(s_t) \leftarrow V(s_t) + \alpha\,[r_{t+1} + \gamma V(s_{t+1}) - V(s_t)] \quad (12)$$

Burada: r_{t+1}, $t + 1$ zamanında gözlenen ödüldür. γ ise 0 ile 1 arasında bir indirim oranı değeridir. Değer ne kadar yüksek olursa, o kadar az indirim yapılır.

TD öğrenim yöntemi "önyükleme" yöntemi olarak adlandırılır, çünkü değer, nihai bir ödül değil, mevcut bir tahmin kullanılarak kısmen güncellenir. TD öğrenme "Politikalı" ve "Politika Dışı" Öğrenme olarak iki şekilde düzenlenebilir. Politikalı öğrenmede yöntemler karar vermek için kullanılan politikanın değerini öğrenir. Değer işlevleri, bazı politikaların belirlediği eylemleri gerçekleştirmenin sonuçları kullanılarak güncellenir. Bu politikalar genellikle yumuşak (her zaman politikaya bir keşif unsuru olduğunu garanti eder) ve determinist değildir. Politika katı değildir ve her zaman en fazla ödülü veren eylemi seçer. Soft, greedy ve softmax olmak üzere üç çeşit sıklıkla kullanılan politika vardır. Politika Dışı yöntemler, davranış ve tahmin için farklı politikalar öğrenebilir. Davranış politikası genellikle yumuşaktır. Politika dışı algoritmalar, aslında denenmemiş olan varsayımsal eylemleri kullanarak tahmini değer işlevlerini güncelleyebilir. Politika dışı algoritmalar araştırmayı kontrolden ayırabilir ve politika içi algoritmalar yapamaz. Politika dışı bir yöntem kullanılarak eğitilmiş bir ajan, öğrenme aşamasında mutlaka göstermemesi gereken öğrenme taktikleri ile sonuçlanabilir.

Q öğrenme: En sık kullanılan takviyeli öğrenme algoritmalarındandır. Q öğrenme çevre hakkında bilgi sahibi olunamayan ortamlarda çevrimiçi olarak öğrenebilen bir algoritmadır. Rasgele bir ortam içinde etmene, optimal politikayı nasıl öğrenebileceği gösterilir. Etmenin optimal politikayı doğrudan öğrenmesi zordur. Çünkü etmen için kullanabileceği eğitim verileri bulunmamaktadır. Etmen için kullanılabilir eğitim verisi sadece anlık ödüllerdir. Bu eğitim verilerini kullanarak sayısal bir değerlendirme fonksiyonunu öğrenmek ve daha sonra bu fonksiyon yardımıyla optimal politikayı belirlemek daha kolaydır (Hacıbeyoğlu, 2006).

TD öğrenme için politika dışı bir algoritmadır. Q öğrenme algoritmasının temel amacı bir sonraki hareketleri inceleyip yapacağı hareketlere göre kazanacağı ödülü görmek ve bu

ödülü en çok hale getirecek şekilde hareket etmektir. Bu algoritmada bir nevi, ajanın geleceğe dair plan kurması beklenmektedir. Bu algoritma labirent ve arama gibi problemlere sıklıkla uygulanmaktadır.

Algoritmanın temel olarak iki matris üstüne kurulmuştur. İlk matris **R**eward (Ödül) matrisi, diğeri ise **S**tate (durum) matrisidir. Belirli bir tekrar süresince hareket eden robot bu hareketler sırasında *R* matrisindeki değerler yoluyla *S* matrisini tamamlar. Tüm tekrarlar sonucunda oluşan *S* matrisinin son değerleri ise optimal sonucu gösterir.

Q öğrenme, sonlu durumlu Markov Karar Süreci olarak modellenebilen alanlara kolaylıkla uygulanabilecek modelden bağımsız bir Takviyeli Öğrenme algoritmasıdır. Takviyeli öğrenme problemleri matematiksel olarak Markov karar süreçleri gibi modellenebilirler. Markov karar süreci şu parametrelere bağlı olarak tanımlanır (Kaya, 2003).

- Sonlu durumlar kümesi, S
- Hareketler kümesi, A
- Bir ödül fonksiyonu, R: S x A → R
- Durum geçiş fonksiyonu, T: S x A → π(S)

Burada π(S), S kümesi üzerinde bir olasılık dağılımı olarak tanımlanabilir. Durum geçiş fonksiyonu, etmenin o andaki durum ve hareketinin bir fonksiyonu olarak, bir olasılıkla ortamın sonraki durumunu belirler. Ödül fonksiyonu ise anlık ödülleri verir. Bu özellik Markov Özelliği olarak bilinir. Buna göre, geçmiş durum, hareket ve takviye arasında bir bağımlılık söz konusu değildir. Bu yüzden, Markov karar süreci ortamın sadece bir adım için dinamiğini tanımlar (Kaya, 2003).

Q öğrenme prosedürü şöyle sıralanabilir:

- Q-değerleri tablosunu (Q (s, a)) başlat.
- Mevcut durumu gözlemle, s.
- Eylem seçimi politikalarından birine dayalı bir eylem seç. (soft, greedy veya softmax).
- Harekete geç ve ödülü (r) ve yeni durumu (s') izle.

- Gözlemlenen ödülü ve bir sonraki durum için mümkün olan maksimum ödülü kullanarak durum için Q değerini güncelle.
- Durumu yeni durumuna ayarla ve terminal durumuna ulaşana kadar işlemi tekrarla.

SARSA: Sarsa algoritması, TD öğrenme için bir politika algoritmasıdır. Sarsa ile Q öğrenme arasındaki en büyük fark, bir sonraki durum için maksimum ödülün mutlaka Q değerlerini güncellemek için kullanılmamasıdır. Bunun yerine, yeni bir eylem ve dolayısıyla ödül, orijinal eylemi belirleyen politika kullanılarak seçilir. Mevcut durumda, S bir eylem, "A" alınır ve ajan bir ödül alır, "R" ve bir sonraki durumda sona erer, "S1" ve aksiyon alır, S1'de A1. Buradan yola çıkarak (S, A, R, S1, A1) adını almıştır.

SARSA prosedürü şöyle sıralanabilir:

- İlk olarak, Q değerlerini bazı keyfi değerlere sıfırla,
- Epsilon-greedy politikasına göre bir eylem seç ve bir durumdan diğerine geç,
- Güncelleme kuralını izleyerek önceki durumdaki Q değerini güncelle.

3.1.5. Makine öğrenmesinin sınırlılıkları

Makine öğrenimi sistemlerinin sağladığı fırsatlar ve faydalarla beraber, sınırlılıkları ve zorlukları da bulunmaktadır. Bu sınırlılıklar şöyle açıklanabilir:

Öğrenme problemine uygun algoritmanın belirlenmesi, makine öğrenimi için en önemli problemlerden birisidir. Araştırmacılar, problemin ihtiyacına yönelik algoritmayı belirleyebilmesi, bunun için de farklı pek çok algoritmayı deneyerek test etmesi gerekmektedir. Algoritma ile birlikte model parametrelerinin de belirlenmesi gerekmektedir. Metin işlemleri için bazı algoritmalar iyi performans gösterirken, görüntü işleme için farklı algoritmalar daha iyi performans gösterebilmektedir.

Eldeki veriler içerisinde bulunan gürültüler, makine öğrenmesinin bir başka sınırlılığıdır. Özellikle büyük veri kavramıyla birlikte ortaya çıkan, veri yığınları arasında yapılandırılmış ve/veya yapılandırılmamış verilerin aynı anda bulunması, makine öğrenmesinde baş edilmesi gereken diğer bir sorundur. Verideki gürültü; bir görüntünün boyut, renk,

çözünürlük gibi özelliklerindeki farklılıklar, bir metin verisindeki yanlış yazım, noktalama işaretleri, kullanılan özel simge ve kısaltmalar gibi farklı şekillerde karşımıza çıkabilir.

Özellik çıkarımı, sistemin doğru çalışması, doğru özelliklerin ve özellik sayılarının seçilmesine bağlı olarak değiştiği için makine öğrenimi sisteminin en önemli adımlarındandır. Özellik çıkarım işlemi işlemin gerçekleştirildiği probleme bağlıdır ve özeldir. Daha açık belirtmek gerekirse, bir sağlık probleminde belirlenen özellikler, otonom bir araç için kullanılacak özelliklerden farklı olacaktır. Farklı disiplinlerde, farklı problem çözümlerine üretilen ortak bir özellik çıkarımı, gelecekte çok büyük problem çözümlerine fayda sağlayabilecektir.

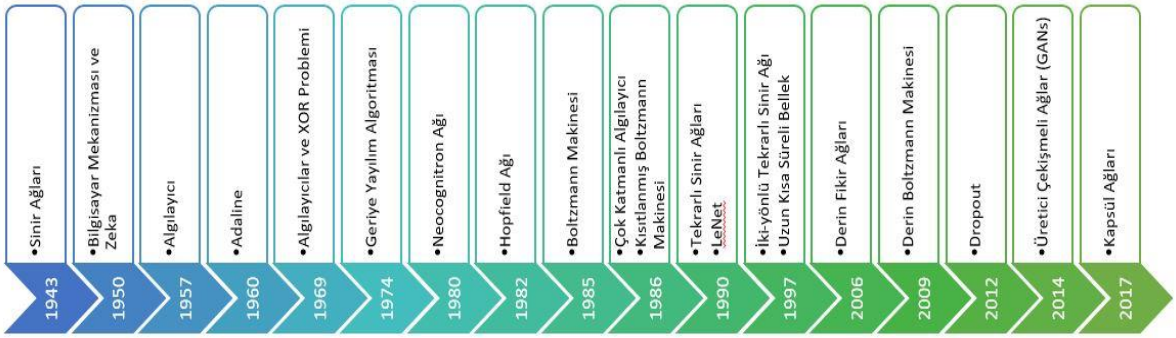
Aşırı öğrenme bir diğer makine öğrenimi sınırlılığıdır. Oluşturulan model, eğitim sırasında yüksek performans gösterirken, test verisi üzerinde düşük performans gösterebilir veya beklenildiğinden daha az performansta olabilir. Bu durumda, eğitim verilerinin model tarafından ezberlendiği, bir diğer deyişle modelin aşırı öğrendiği düşünülmektedir. Bunun önüne geçmek için, eğitim sırasında modelin karmaşıklığı arttırılmakta, çeşitli yöntemler denenmektedir.

Denetimli makine öğrenmesi yöntemlerinde etiketlenmiş veriler üzerinden model eğitilerek tespit ve teşhisler gerçekleştirilir. Bu modeli kurgulamak için de elde hatırı sayılır miktarda büyük bir veri bulunmalıdır. Böyle bir veri etiketleme işi için uzman kişiler ve yoğun mesai gerekmektedir. Ayrıca insan kaynaklı hatalara da sebebiyet verilmesi mümkündür. Özel problemlerin çözümünde, uzman personel eksikliği de yaşanabilir. Tüm bunlar bir araya gelerek, veri etiketleme sınırlılığını ortaya çıkarmaktadır.

3.2. Derin Öğrenme

ImageNet isimli dünyanın en önemli nesneleri tanıma yarışmasında 2012 yılında Krizhevsky ve arkadaşları tarafından AlexNet isimli Derin Konvolüsyonel Yapay Sinir Ağları (Deep Convolutional Neural Netrowks) (Krizhevsky ve diğerleri, 2012) yoluyla yapılan sınıflandırma sonucunda elde edilen başarı, derin öğrenmenin dünya literatüründeki en büyük etkisi olmuştur. Bu başarı sonrasında derin öğrenme yükselişe geçmiştir. Literatürde derin öğrenme ile ilk olarak 2006 yılında derin fikir ağları olarak adlandırılan bir metot (Hinton ve diğerleri, 2006) ile tanışılmıştır. Derin Fikir Ağları (Deep Belief Nets - DBN),

her bir görüntü tanıma yönteminin doğruluğunu ölçmek ve tahmin etmek için tercih edilen MNIST (0-9 sayıları arasında değişen 70.000 tane 28 x 28 piksel el yazısı karakterlerinin görüntü verileri) veri tabanı kullanılarak test edilmiştir. Derin öğrenmenin zamanla gelişimi Şekil 3.5'te gösterilmiştir (Ay Karakuş, 2018).



Şekil 3.5. Derin öğrenme zaman çizelgesi (Ay Karakuş, 2018)

Son yıllarda, derin öğrenme araştırmalarında geliştirilen teknikler, makine öğrenmesi ve yapay zekânın en etkili ve önemli yönleri dâhil olmak üzere hem geleneksel hem de yeni biçimlerde, genişletilmiş kapsamlar içinde büyük bir yelpazede bilgiyi işleme çalışmalarını etkilemektedir.

Derin öğrenme, makine öğrenmesinin bir alt alanı olmakla beraber derin sinir ağlarının gün geçtikçe yaygınlaşan uygulama alanıdır. Bu alanda her bir çalışmaya ait özelleştirilmiş algoritmalar yerine, verileri öğrenmeye dayanan ve çözümlerin daha geniş veri kümesini kapsaması amaçlanmaktadır. Derin öğrenme, makine öğrenmesindeki yapay zekâ problemlerini çözmek için gelecek vaat eden bir yaklaşımdır.

Derin öğrenmenin çeşitli tanımları bulunmaktadır (Deng ve Yu, 2013):

Tanım 1: Denetimli veya denetimsiz özellik çıkarımı ve dönüşümü, model analizi ve sınıflandırma için birçok doğrusal olmayan bilgi işlem katmanını kullanan bir makine öğrenme teknikleri sınıfı.

Tanım 2: Makine öğrenmesi içinde, veriler arasındaki karmaşık ilişkileri modellemek için çoklu temsil seviyelerini öğrenmek için algoritmalara dayanan bir alt alan. Böylece üst düzey özellikler ve kavramlar alt düzey özellikler olarak tanımlanır ve bu tür özellikler

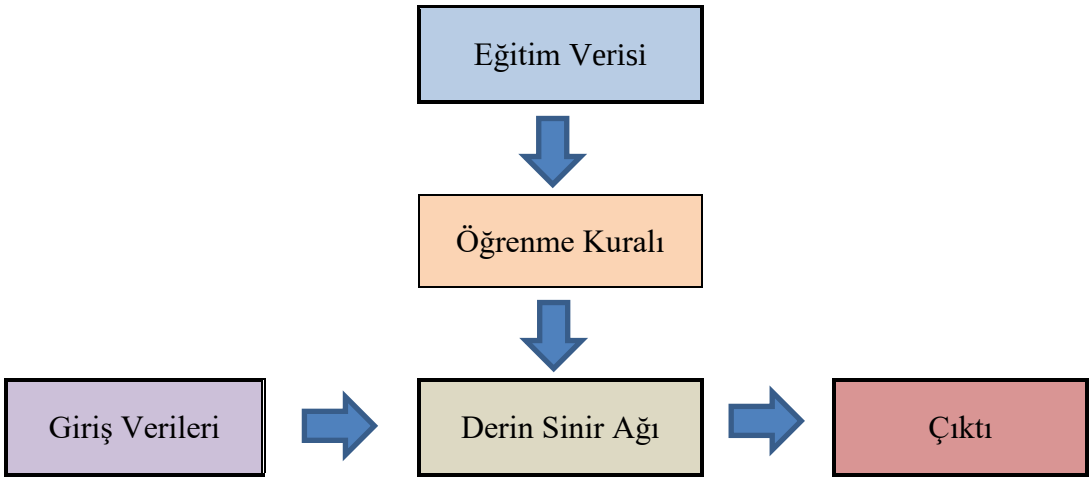
hiyerarşisine derin bir mimari denir. Bu modellerin çoğu denetlenmeyen temsillerin öğrenilmesine dayanmaktadır.

Tanım 3: Daha üst düzey kavramların daha düşük seviyeli olanlardan tanımlandığı özelliklerin veya faktörlerin veya kavramların hiyerarşisine tekabül eden birkaç temsil seviyesinin öğrenilmesine dayanan bir makine öğrenme alt alanıdır ve aynı düşük seviyeli kavramlar birçok üst seviye kavramın tanımlanmasına yardımcı olabilir. Derin öğrenme, öğrenme temsillerine dayalı daha geniş bir makine öğrenme yöntemleri ailesinin bir parçasıdır. Bir gözlem (örn., bir görüntü) birçok şekilde gösterilebilir (örn., bir piksel vektörü), ancak bazı gösterimler ilgi çekici görevleri öğrenmeyi kolaylaştırır (örn., bu bir insan yüzünün görüntüsü müdür?) Örneklerden ve bu alandaki araştırmalardan, neyin daha iyi temsil edilebileceğini ve nasıl öğrenileceğini belirlemeye çalışır.

Tanım 4: Derin öğrenme, makine öğreniminde farklı soyutlama seviyelerine karşılık gelen çoklu seviyelerde öğrenmeye çalışan bir dizi algoritmadır. Genellikle yapay sinir ağları kullanılır. Bu öğrenilen istatistiksel modellerde seviyeler, daha yüksek seviyeli kavramların düşük seviyeli kavramlardan tanımlandığı ve aynı düşük seviyeli kavramların daha yüksek seviyeli kavramları tanımlamaya yardımcı olabileceği farklı kavram seviyelerine karşılık gelir.

Tanım 5: Derin Öğrenme, makine öğrenmesini orijinal amaçlarından birine (yapay zekâ) yaklaştırmak amacıyla tanıtılan makine öğrenimi araştırmasının yeni bir alanıdır. Derin öğrenme, görüntüler, sesler ve metinler gibi verileri anlamada yardımcı olan çoklu temsil ve soyutlama seviyelerini öğrenmekle ilgilidir.

Derin öğrenme, derin sinir ağını kullanan bir makine öğrenme tekniğidir. Derin sinir ağları ise iki veya daha fazla gizli katman içeren çok katmanlı sinir ağlarıdır (Şekil 3.6) (Phil, 2017).



Şekil 3.6. Derin öğrenme yapısı

Derin öğrenmede, verilerin birden fazla özellik seviyesinin veya temsillerinin öğrenilmesine dayanan bir yapı söz konusudur. Üst düzey özellikler, alt düzey özelliklerden türetilerek hiyerarşik bir temsil oluşturur (Bengio, 2009). Bir görüntü için temsil, piksel başına yoğunluk değerlerinin bir vektörü veya kenar kümeleri, özel şekiller gibi özellikler olabilir. Bu özelliklerin içinden bazıları veriyi daha iyi temsil etmektedir. Derin öğrenme yöntemlerinde, elle çıkarılan özellikler yerine veriyi en iyi temsil eden hiyerarşik özellik çıkarımı için etkin algoritmalar kullanılmaktadır (Song ve Lee, 2013).

Derin öğrenmenin çeşitli üst düzey tanımları arasında ortak olan iki temel husus vardır (Deng ve Yu, 2013):

- Çoklu katmanlardan veya doğrusal olmayan bilgi işlem aşamalarından oluşan modeller,
- Ard arda daha yüksek, daha soyut katmanlarda özellik gösteriminin denetimli veya denetimsiz bir şekilde öğrenilmesine yönelik yöntemler.

Derin öğrenme algoritmalarının çalıştırılması ve problemlerin çözüme ulaştırılması için, kapasitesi yüksek (özellikle GPU) makineler ve büyük miktarda veriye ihtiyaç vardır. Problemleri parçalara ayıran ve ayrı ayrı çözen standart makine öğrenme algoritmalarının aksine, derin öğrenmede problem baştan sona çözülür. Daha da önemlisi, derin bir öğrenme algoritması ne kadar çok veri ile beslenirse, görevin yerine getirilmesi de o kadar iyi olur. Ayrıca zaman faktörü de önemlidir. Zaman kısıtlı olmayan çalışmalar, büyük veri ile beslendiğinde daha iyi sonuçlar ortaya çıkarabilir.

Günümüzde derin öğrenmenin popülaritesinin üç önemli sebebi, büyük ölçüde artan işlemci yetenekleri (örn., grafik işlemciler (GPU)), eğitim için kullanılan verilerin büyük ölçüde artması ve makine öğrenmesi ve sinyal/bilgi işleme araştırmalarındaki son gelişmelerdir. Bu gelişmeler, derin öğrenme yöntemlerinin karmaşık, bileşimli doğrusal olmayan işlevlerden etkin bir şekilde yararlanmasını, dağıtılmış ve hiyerarşik özellik gösterimlerini öğrenmesini ve hem etiketli hem de etiketlenmemiş verileri etkili bir şekilde kullanmasını sağlamıştır. (Deng ve Yu, 2013).

Çizelge 3.8. Yapay zekâ ve derin öğrenme görev tanımlama

Hangi probleme çözüm aranıyor? Yapay Zekâ (YZ) / Derin Öğrenme (DÖ) Görevi Tanımlama			
Girdi	Problem	YZ/DÖ Görevi	Örnek Çıktılar
Fotoğraf	Mevcut mu? Değil mi?	Keşfetme	Kanser Tespiti
Metin	Ne tür bir şey?	Sınıflandırma	Tümör Sınıflandırma
Ses	Ne kadar uzanıyor?	Segmentasyon	Tümör Boyutu ve Şeklini Analiz Etme
	Olası sonuç nedir	Tanımlama	Hayatta Kalma Tahmini
Video	Hedefi ne karşılayacak?	Tavsiye	Terapi Tavsiyesi

Makine öğrenmesinde algoritma, insanlar tarafından sağlanan bilgilere dayanarak bir kare ile üçgen arasında ayrım yapmaktadır. Derin öğrenmede, program önceden beslenen bilgilerle başlamaz. Bunun yerine, şekillerin kaç köşeye sahip olduğunu, bu köşelerin bağlı olup olmadığını ve dik olup olmadıklarını belirlemek için bir algoritma kullanır. Algoritma sonuç olarak eklenen bir dairenin kare ve üçgen sıralamalarına uyup uymadığını anlamaktadır.

İnsanlar tarafından kolaylıkla yapılabilen imge ve/veya ses tanımlama gibi problemlerin çözülmesi, yapay zekâ yöntemleri için zor olmaktadır. Bu sezgisel problemler, birbirleri ile ilişkisi tanımlanabilen en basit konseptlerin hiyerarşik olarak dünyayı anlama ve deneyimleme yetisinin bilgisayarlar tarafından öğrenilmesiyle çözülebilmektedir. Deneyimlerle kazanılan bilgilerle birlikte, bilgisayarların kullandığı her bir probleme özgü formüllere ve hesaplama işlemlerine gerek kalmamaktadır. Hiyerarşik yapı bir grafik olarak

düşünüldüğünde, her birisi diğerinin üzerinde kurulu çok katmanlı derin bir yapı oluşmaktadır. Bu sebeple, hiyerarşik yapıya dayalı yapay zekâ yöntemleri, derin öğrenme olarak ortaya çıkmaktadır (Goodfellow ve diğerleri, 2016).

Derin öğrenme sinir ağlarının araştırma alanları, yapay zeka, grafik modelleme, optimizasyon, örüntü tanıma ve sinyal işleme arasındaki kesişme noktalarındadır (Deng ve Yu, 2013). Bu algoritmalar günümüzde sürücüsüz araçlar, sağlık hizmetleri, film önerileri, çeviri hizmetleri, chatbotlar, sayfa önerileri, reklam hizmetleri gibi pek çok uygulamada kendini göstermeye başlamıştır.

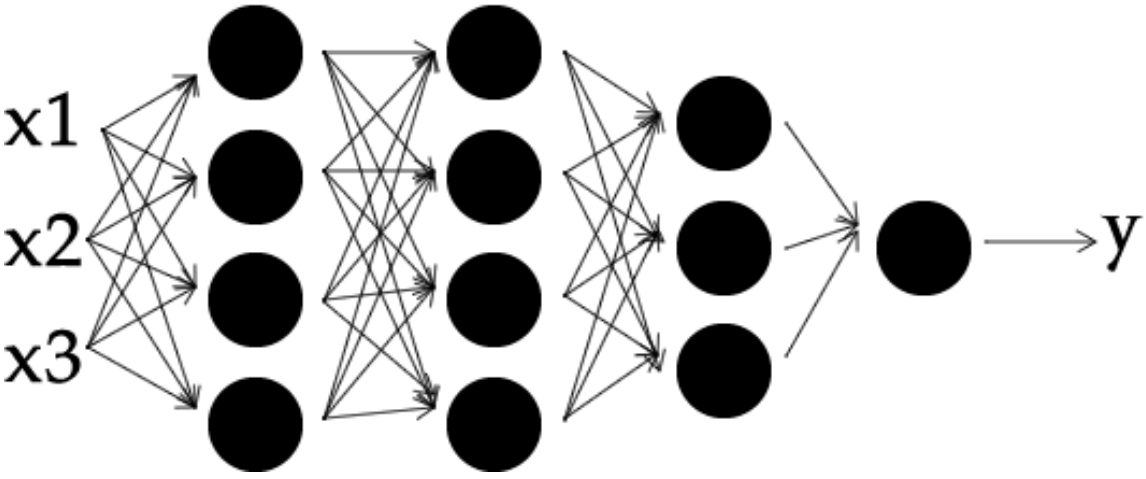
Derin öğrenme mimarilerinin bu denli ilgi gören bir çalışma alanı olmasındaki unsurlar şöyledir:

- Dünya çapında yaygın metin, görüntü ve ses veri setlerinin araştırmalar için kullanıma sunulması.
- Yüksek işlem güçlü grafik kartlarının (GPU) üretilmeye başlanması.
- AlexNet, ZFNet, ResNet, GoogLeNet, VGG16-19, Inception vb. gibi derin mimarilerin kullanıma sunulması.
- Keras, Tensorflow, Theano, Caffe, Pytorch, MatConvNet vb. gibi derin öğrenme platformları ve kütüphanelerinin kullanılmaya başlanması.
- Aktivasyon fonksiyonları, veri eğitimi ve veri arttırma yöntemleri ve etkili optimazörlerin araştırmacılar tarafından geliştirilerek kullanıma sunulması.



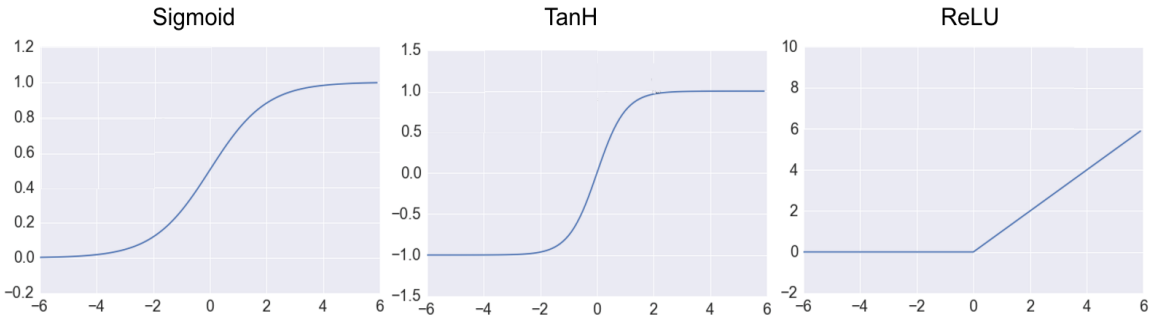
Şekil 3.7. Derin öğrenme yelpazesi

Derin sinir ağlarında ise iki veya daha fazla gizli sinir ağı katmanı bulunmaktadır. Derin sinir ağlarında veri içerisinde basitten karmaşığa doğru daha kapsamlı ilişkiler kurulur. Her katman bir önceki katmanla kendi arasında bir ilişki kurmaya çalışır. Böylece girdiler hakkında daha detaylı inceleme yapılarak daha doğru karar verilmesi sağlanır. Şekil 3.8'de üç gizli katmalı bir derin sinir ağı yapısı görülmektedir.



Şekil 3.8. Derin sinir ağı yapısı

Derin sinir ağları yapısı oluşturulurken farklı aktivasyon fonksiyonları kullanılabilir. Bu fonksiyonlar verinin türüne, yapısına, büyüklüğüne ve modeli oluşturan kişiye göre değişebilir. Aktivasyon fonksiyonu hücreye gelen girdiye karşılık olarak bu hücrenin üreteceği çıktıyı belirler. Genellikle doğrusal olmayan bir fonksiyon seçilir. Başlıca aktivasyon fonksiyonları, Sigmoid, TanH ve ReLU'dur (Şekil 3.9.) ve hesaplamaları sırasıyla Eşitlik 13, 14 ve 15'te verilmiştir.



Şekil 3.9. Aktivasyon fonksiyonları

Sigmoid

$$f(x) = \frac{1}{1 + e^{-x}} \tag{13}$$

TanH

$$\tanh(x) = \frac{2}{1 + e^{-2x}} - 1 \tag{14}$$

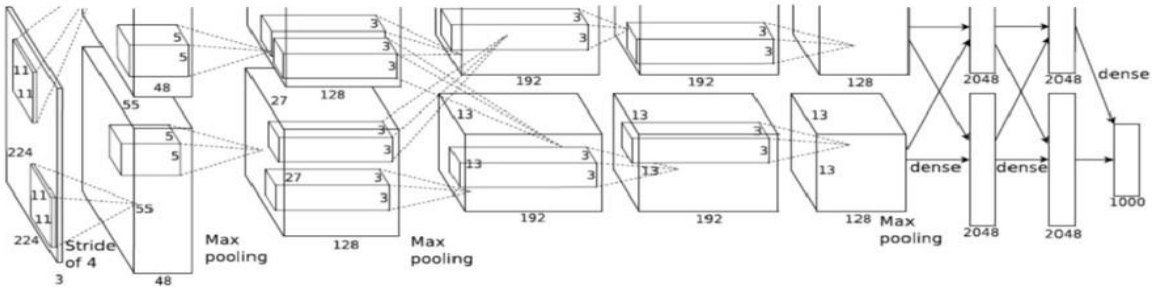
ReLU

$$f(x) = \begin{cases} 0 \; için \; x < 0 \\ x \; için \; x \geq 0 \end{cases} \tag{15}$$

3.2.1. Derin öğrenme mimarileri

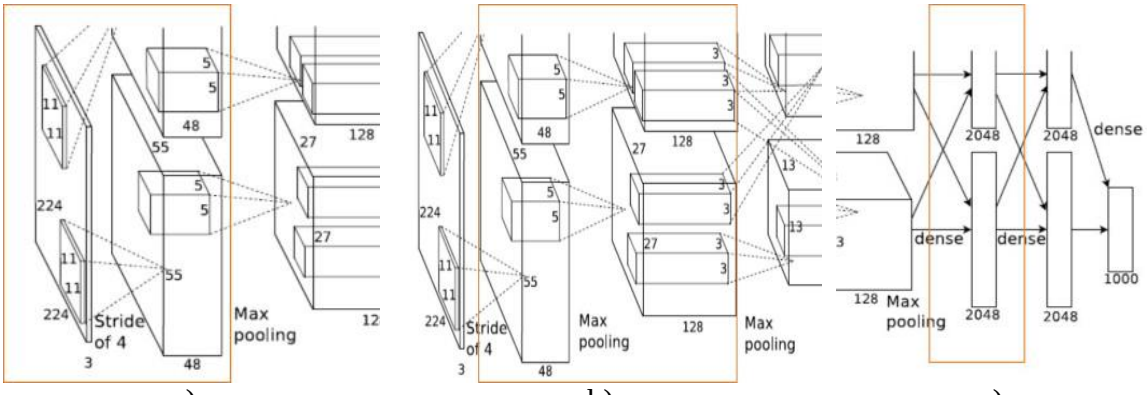
Dünya çapında bir yarışma olan ImageNet yarışması ile birlikte daha da rekabetçi bir hale gelen derin öğrenme mimarileri, her geçen yıl değişen katman sayıları ve başarım oranlarıyla gittikçe daha da artmaktadır. Bu yarışın fitilini AlexNet mimarisi ateşlemiştir demek yanlış bir söylem olmayacaktır. Bu sebeple aşağıda örnek katman açıklaması AlexNet mimarisi üzerinde gerçekleştirilmiş, diğer mimarilerde ise genel açıklama yapılmıştır.

AlexNet: ILSVRC-2012 yarışmasını kazanan görüntü sınıflandırması için derin konvolüsyonel sinir ağıdır. İlk beş tanesi konvolüsyonel, son üç tanesi ise tam bağlı katman olan sekiz katmandan oluşmaktadır. Bu katmanlar arasında "pooling" ve "aktivasyon" katmanları da bulunmaktadır. Ayrıca giriş ve çıkış katmanları da bulunmaktadır. AlexNet mimarisi, 1000 nesneyi sınıflandıracak şekilde tasarlanmış ve nesne tanımlamada hata oranı %26,2'den %15,3'e düşürülmüştür. Şekil 3.10'da AlexNet mimarisi gösterilmiştir (Krizhevsky ve diğerleri, 2012).



Şekil 3.10. AlexNet mimarisi (Krizhevsky ve diğerleri, 2012)

AlexNet diyagramında problemin iki bölüme ayrılarak yarısının GPU1 ve diğer yarısının da GPU2 üzerinde çalıştırıldığı görülmektedir. Böylece iletişim yükü düşük tutulur ve bu da genel olarak iyi bir performans elde edilmesine yardımcı olur. İki kanaldan işleyen veriler sadece üçüncü özellik çıkarımı katmanında çaprazlanır.



a) b) c)

Şekil 3.11. AlexNet katmanları a) 1. katman b) 2. katman c) 6. Katman (Krizhevsky ve diğerleri, 2012)

Birinci katman (Şekil 3.11.a) konvolüsyonel katmandır.

- Giriş görüntü boyutu: 224 x 224 x 3
- Filtre sayısı: 96

- Filtre boyutu: 11 x 11 x 3
- Adım uzunluğu: 4

Katman Çıktısı

- 224/4 x 224/4 x 96 = 55 x 55 x 96
- 2 GPU ile bölününce her bir GPU için 55 x 55 x 48

İkinci katman (Şekil 3.11.b), konvolüsyon ile takip edilen bir Max Pooling katmanıdır.

- Giriş görüntü boyutu: 55 x 55 x 96
- Max Pooling: 55/2 x 55/2 x 96 = 27 x 27 x 96
- Filtre sayısı: 256
- Filtre boyutu: 5 x 5 x 48

Katman Çıktısı

- 55/2 x 55/2 x 96 = 27 x 27 x 96
- 2 GPU ile bölününce her bir GPU için 27 x 27 x 128

Üçüncü, dördüncü ve beşinci katmanlar benzer şekilde ilerlemektedir. Altıncı katman tam bağlı katmandır.

Altıncı katmanda (Şekil 3.11.c) giriş, 13 x 13 x 128 olarak bir vektöre dönüştürülür ve 2048 ile çarpılır:

(13 x 13 x 128) x 2048

Burada GEMV (General Matrix Vector Multiply) kullanılır.

Vektör X = 1 x (13x13x128)

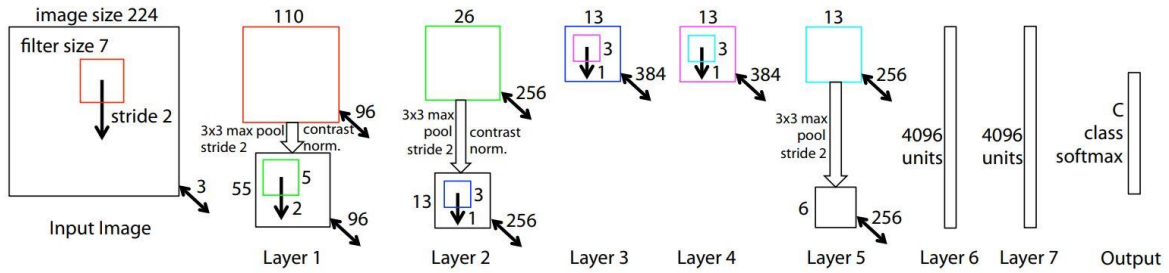
Matrix A = (13x13x128) x 2048

Çıktı: 1 x 2048

Yedinci ve sekizinci katmanlar da benzer şekilde ilerler.

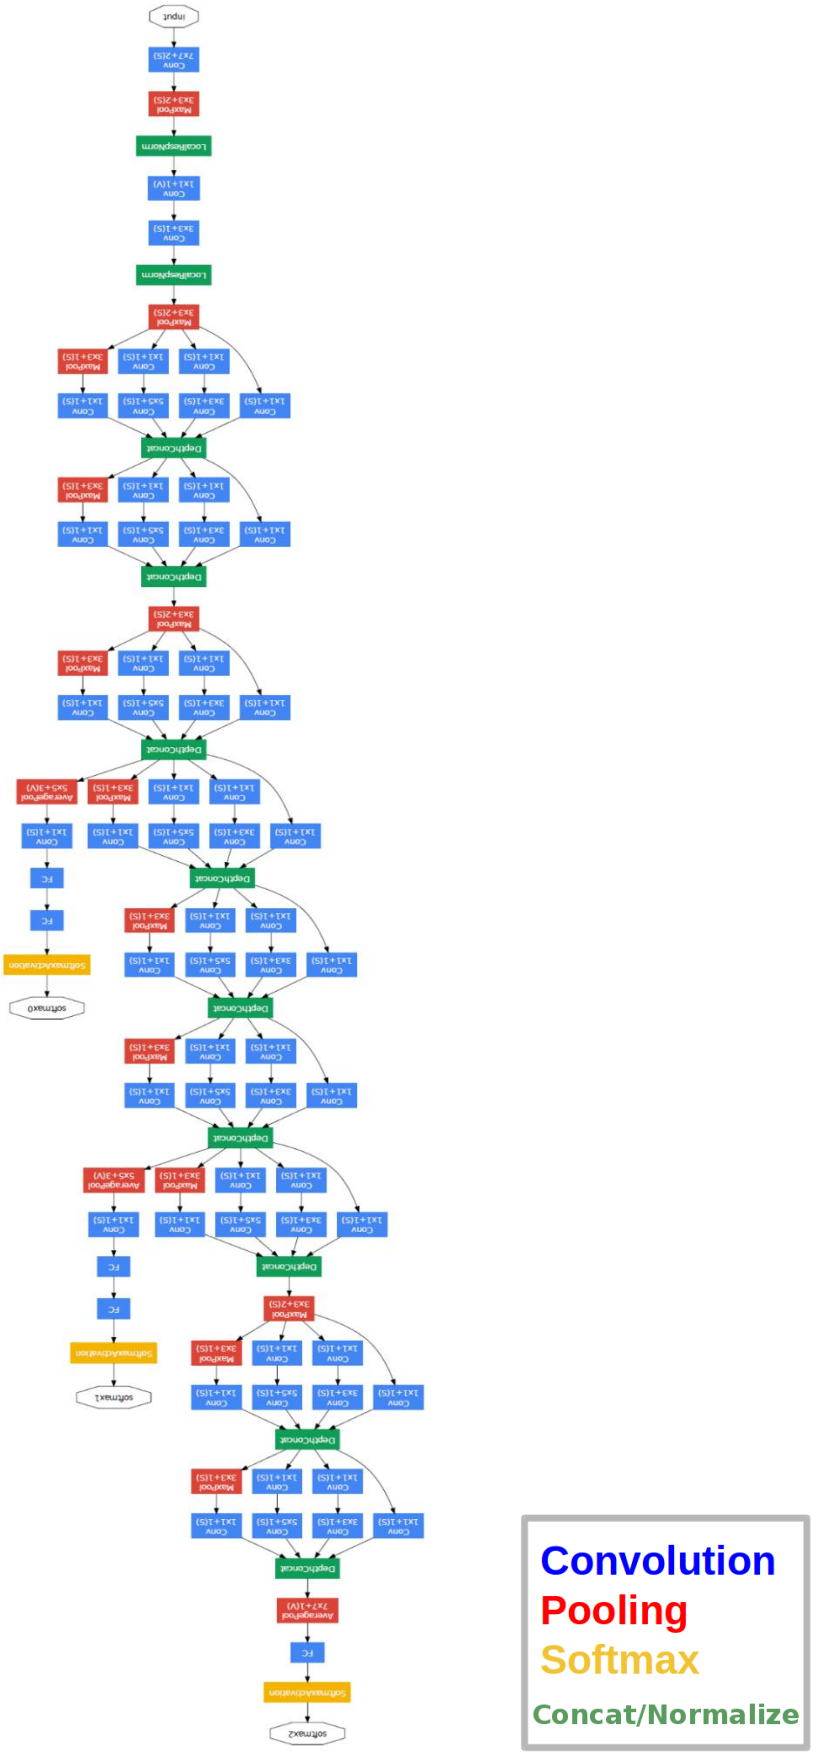
ZFNet: AlexNet'in ImageNet yarışmasını kazanmasından sonra, bu mimariden esinlenerek geliştirilen ZFNet (Zeiler ve Fergus, 2014) 2013 yılında ImageNet yarışmasının kazananı olmuştur. Bu mimariyle nesne tanımada hata oranı %11,2'ye indirilmiştir. AlexNet'ten

farkı; filtre boyutunu 7x7 ve adım sayısını iki olarak belirlemesidir. Burada, birinci konvolüsyon katmanındaki daha küçük bir filtre boyutunun, giriş boyutundaki birçok orijinal piksel bilgisinin korunmasına yardımcı olması amaçlanmıştır. Ek olarak, "Çapraz Entropi", "Olasılıksal Eğim İniş" ve "ReLU" algoritmalarını kendi mimarisinde kullanmıştır. ZFNet mimarisi 7 katmandan oluşmaktadır. Şekil 3.12'de ZFNet mimarisi gösterilmiştir (Zeiler ve Fergus, 2014).



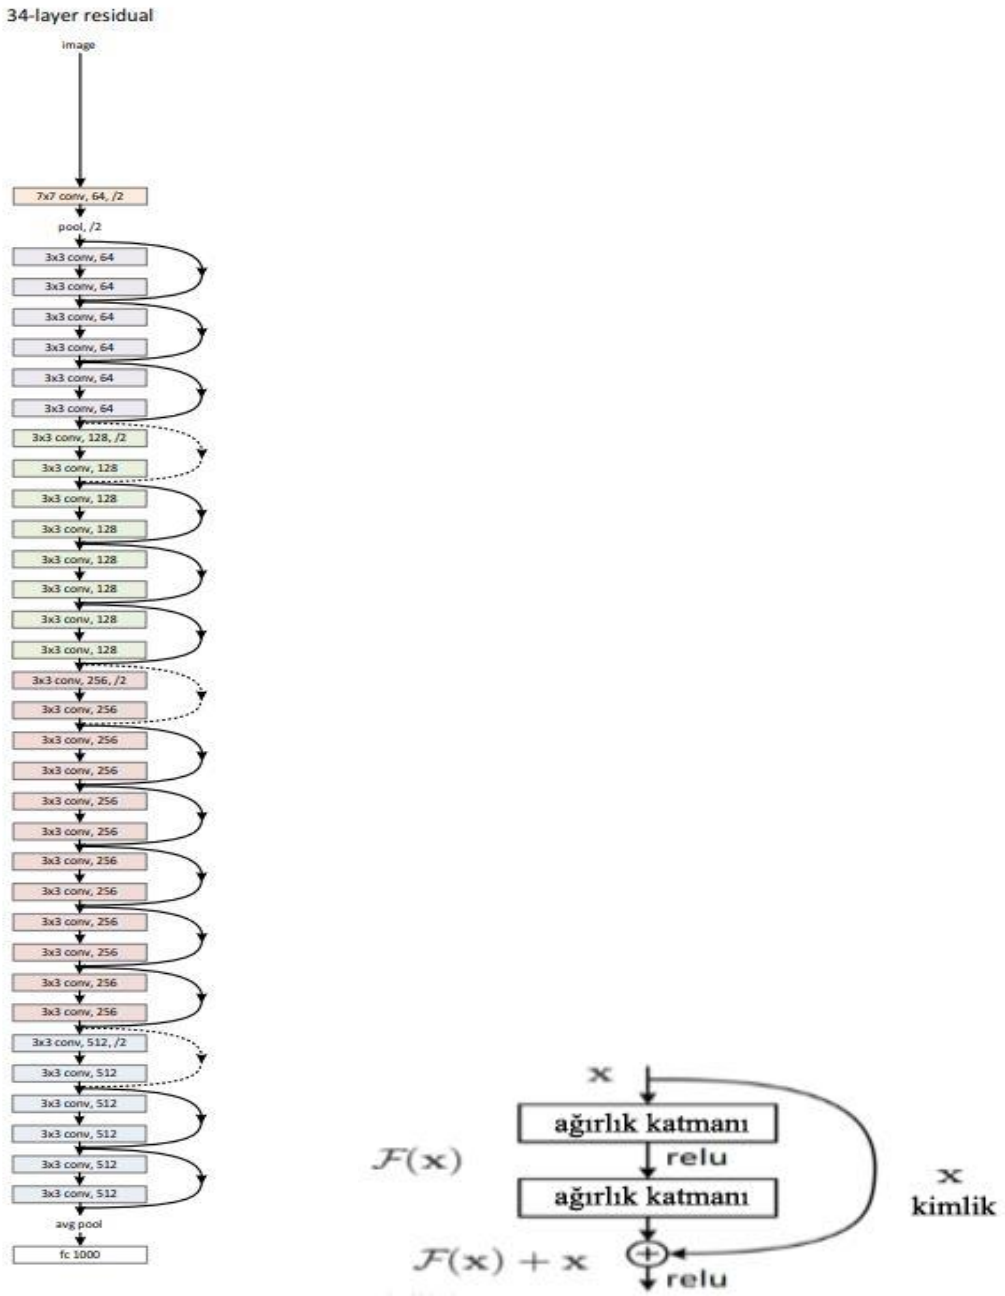
Şekil 3.12. ZFNet mimarisi (Zeiler ve Fergus, 2014)

GoogLeNet: GoogleNet, Inception modüllerinden oluşturulan karmaşık bir yapıda olup ImageNet yarışmasının 2014 yılı kazananıdır (Szegedy ve diğerleri, 2015). Daha önceki çalışmalardan farklı olarak hazırlanan ağın derinliği ve genişliği arttırılırken hesaplama maliyeti de düşük tutulmuştur. Mimari 22 katmandan oluşmaktadır. Kaliteyi optimize etmek için, mimari kararlar Hebbian ilkesine ve çok ölçekli işlemenin sezgisine dayandırılmıştır. Yarışmada %6,67 oranında top-5 hata oranı elde etmiştir. Şekil 3.13'de GoogLeNet mimarisi gösterilmiştir (Szegedy ve diğerleri, 2015).



Şekil 3.13. GoogLeNet mimarisi (Szegedy ve diğerleri, 2015)

RestNet: 152 katmandan oluşan ResNet daha önceki mimarilerden daha derin bir yapıya sahiptir. ImageNet yarışmasında 2015 yılında %3,57 top-5 hata oranı elde ederek kazanan olmuştur (He ve diğerleri, 2016). Bu oran, insan hata oranını da geçerek büyük bir başarı anlamına gelmektedir. Mimariyi oluşturan Residual bloklarda, *x* girişi konvolüsyon-ReLU-konvolüsyon serisinden sonra bir *F(x)* sonucu üretmektedir. Bu sonuç daha sonra orijinal *x* girişine eklenerek $H(x) = F(x) + x$ olarak ifade edilir. 34 Katmanlık örnek bir ResNet mimarisi ve Residual blok yapısı Şekil 3.14'te sırasıyla gösterilmiştir (He ve diğerleri, 2016).

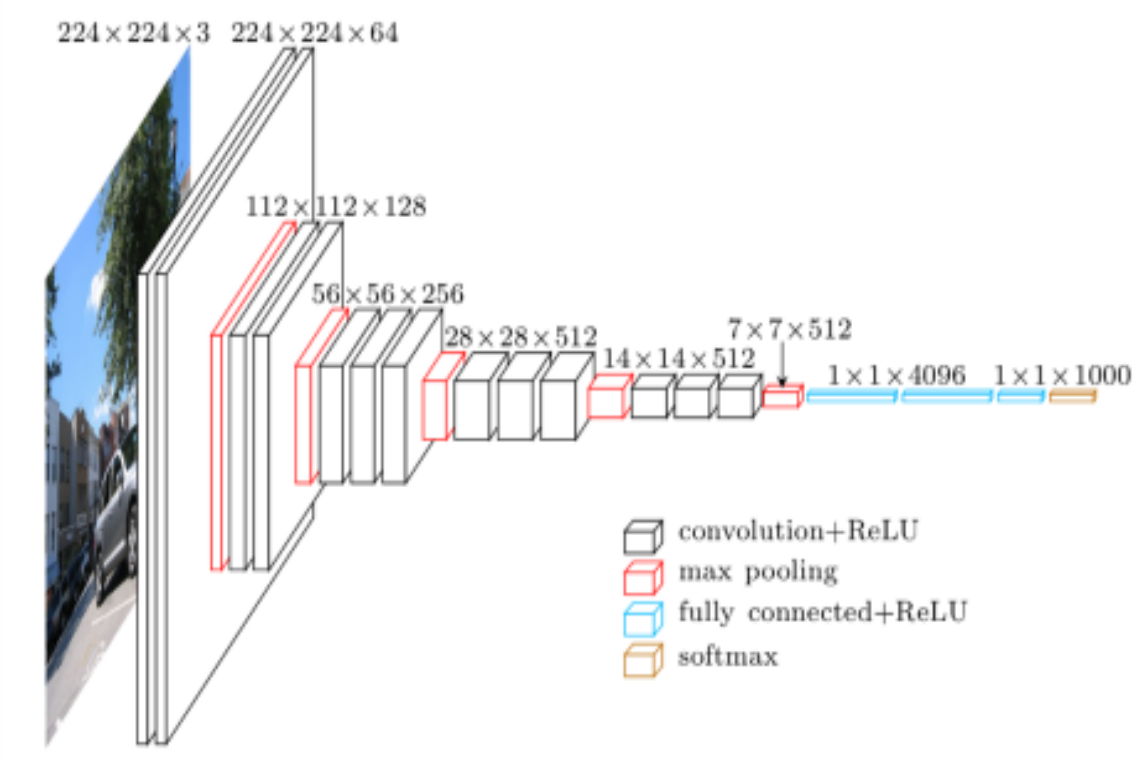


a) b)

Şekil 3.14. a) RestNet 34 katmanlık mimari b) Residual blok (He ve diğerleri, 2016)

VGG16 – VGG19: VGGNet mimarisi 16 ve 19 katmanlı olmak üzere iki farklı türü vardır; VGG16, VGG19. Katman sayısı ağırlık katmanlarının sayısına göre belirlenmiştir. VGG16 mimarisi ImageNet 2014 yarışmasında daha iyi sonuçlar elde etmek için kullanılan 13 konvolüsyon 3 tam bağlı katmanından oluşmakta olan bir mimaridir (Simonyan ve Zisserman, 2014). MaxPooling, FullyConnectedLayer, ReLULayer, DropOutLayer ve SoftmaxLayer katmanlarıyla birlikte toplamda 41 katman yer almaktadır. Girdi katmanında yer alacak görüntü 224x224x3 boyutundadır. Son katman ise sınıflandırma katmanıdır (Doğan ve Türkoğlu, 2018).

VGGNet mimarisi tüm katmanlarında 3x3 filtre kullanır ve Konvolüsyon-ReLU katmanlarını havuzlama katmanından önce üst üste kullanır. Diğer derin mimarilerdeki gibi VGG mimarisinde de giriş katmanından çıkışa doğru matrislerin yükseklik ve genişlik boyutları azalırken derinlik değeri artar. 2014 yılında %7,3 top-5 hata oranı elde etmiştir. Şekil 3.16'da VGGNet mimarisi gösterilmiştir (Simonyan ve Zisserman, 2014).

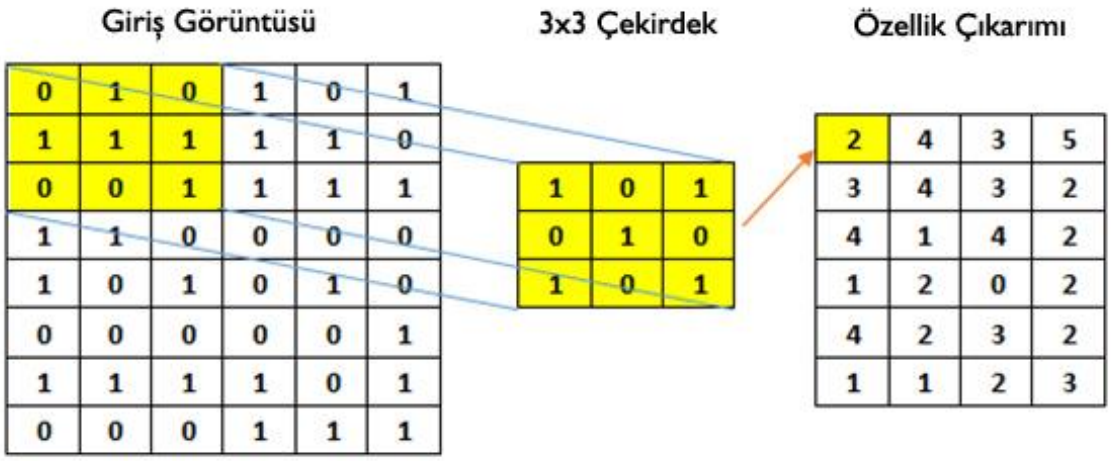


Şekil 3.15. VGGNet mimarisi (Simonyan ve Zisserman, 2014)

3.2.2. Derin öğrenme algoritmaları

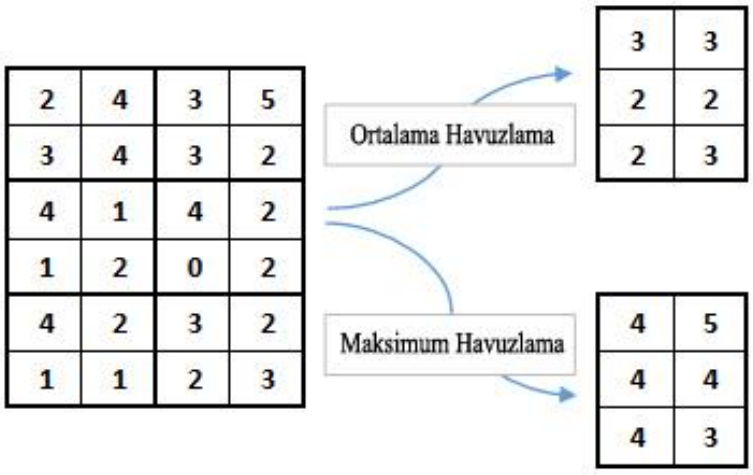
Derin öğrenme mimarileri oluşturulurken, kullanılacak algoritma büyük önem taşımaktadır. Bu algoritmalar verinin türüne, boyutuna, hacmine ve yapısına, kullanılacak olan parametrelere göre farklılık gösterebilmektedir. Evrişimsel Sinir Ağları (ESA-Convolutional Neural Network – CNN), Tekrarlayan Sinir Ağı (Recurrent Neural Network-RNN), Kısıtlı Boltzmann Makineleri (Restricted Boltzmann Machines-RBM) ve Derin İnanç Ağları (Deep Belief Nets-DBN) bunlardan başlıcalarıdır.

Evrişimsel sinir ağları: Derin öğrenme algoritmalarının içinde en bilineni CNN'dir. Görüntü sınıflandırma problemlerinde sıklıkla kullanılmaktadır. CNN'de her bir katmanda matris üzerinde işlem yapan genellikle boyutları 3x3, 5x5, 7x7 olan filtreler (çekirdekler) kullanılmaktadır. Daha sonra bu filtrelerin çıktılarının üzerinde havuzlama (pooling) işlemi yapılmaktadır. Havuzlama ile çekirdekte bulunan veriler filtrelenir. Max pooling yöntemi sıklıkla kullanılan havuzlama yöntemi olup bu yöntemde matris içindekilerden en büyüğü alınır.



a)

Şekil 3.16. a) Evrişimsel katman (3x3) b) Havuzlama (2x2)



b)

Şekil 3.16. (devam) a) Evrişimsel katman (3x3) b) Havuzlama (2x2)

CNN'de, bazı filtreler çok katmanlı bir sinir ağındaki *w* parametresi gibi öğrenme parametreleri olarak işlev görür. Genelde evrişim işlemlerinde kullanılırlar. Evrişim sırasında seçilen filtre, her seferinde görüntü üzerinde kaydırılır (Şekil 3.16.a). İşlem sırasında filtrenin değerleri, o pencere boyutundaki görüntünün değerleri ile çarpılır. Sonucunda ise görüntünün tüm değerlerini bu pencere boyutunda temsil eden tek bir sayı oluşur.

CNN'de işlem yapılan görüntü matris formatındadır. Şekil 3.16.a'da 6x8 boyutunda bir görüntü matrisi ve 3x3 boyutunda bir çekirdek matrisi görülmektedir. Görüntü matrisine uygulanan filtre sayesinde görüntü üzerinden belli özellikler üzerinde karşılaştırma yapılarak görüntüden veriler elde edilmektedir. Algoritmayı kullanırken seçilen kütüphaneler, çekirdek filtrelerini otomatik olarak seçebilmektedir. Parametrelerin doğru olarak tanımlanması da önemlidir. Bu işlem ile görüntü üzerinde bazı özellikler yakalanmaya çalışılır. Bu sayede belli bir olasılıkla resmin görüntünün hangi sınıfa ait olduğu tespit edilir. Bu işlemler diğer görüntüler üzerinde de uygulanarak, benzerlikler kurulmaya çalışılır. Belirlenen filtre görüntü üzerinden kaydırılarak resmin tamamına uygulanır. Bu kaydırma işlemi "stride" denilen adım sayısına göre gerçekleştirilir (Okumuş, 2019).

Havuzlama katmanında ise öğrenilen parametre yoktur. Burada girdi olarak verilen matrisin kanal sayısını sabit kalır ancak yükseklik ve genişlik bilgisi indirgenir. Bu adımda hesaplama karmaşıklığı azaltılır. Şekil 3.16.b.'de 4x6 boyutundaki matrise, 2x2 boyutunda maksimum

ve ortalama havuzlama işlemleri uygulanmış, bunun sonucunda her bir 4 elemanın 1 çıkışı olmuştur. Böylece matris dörtte üç oranında küçültülmüş olur.

İki fonksiyonun (f & g) sonlu aralıktaki [0, t] evrişimi (Weisstein, 2019):

$$[f * g](t) \equiv \int_0^t f(\tau)g(t-\tau)d\tau \tag{16}$$

Burada $[f * g](t)$, f ve g fonksiyonlarının evrişimi anlamına gelmektedir. Evrişim daha çok sonsuz bir aralıkta alınır (Weisstein, 2019):

$$[f * g] \equiv \int_{-\infty}^{\infty} f(\tau)g(t-\tau)d\tau \tag{17}$$

$$= \int_{-\infty}^{\infty} g(\tau)f(t-\tau)d\tau \tag{18}$$

Bir CNN modelinin iki önemli avantajı vardır. Bunlardan ilki, önemli ölçüde öğrenilmesi gereken filtrelerin parametrelerine indirgemedir. Çok fazla nöronun öğrenilmesi ve ihtiyaç duyulması için birçok parametre olduğunda, birçok sorun ortaya çıkmaya başlayabilir. Giriş olarak yüksek çözünürlüğe sahip bir görüntü varsa, piksellere göre bir milyon değere sebep olur. Aşırı öğrenmeye sebep olabilecek ve çok fazla hesaplama gücü gerektiren çok derin ve tam olarak bağlı katmanlara ihtiyaç duyacaktır. Bununla birlikte CNN, özellikle bilgisayarla görme işlemlerde, aşırı öğrenme olasılığını azaltabilir ve hesaplama gücünü koruyabilir (Satar, 2018).

İkinci ana avantaj parametre paylaşımıdır. CNN ile öğrenilen parametreler bir sonraki katmana girdi olarak paylaşılır. Bu sebeple, aynı ağırlıklar katmandan tekrar kullanılır, bu da katmanlarda tekrar öğrenmeye gerek olmadığı anlamına gelir. Bu şekilde, daha sonraki katmanlar daha karmaşık özellik ve kalıpları öğrenebilir (Satar, 2018).

Veriyi işleyerek öğrenen modelleri tasarlarken, tasarımcılar kullanılacak algoritmaya ve tekniklere de karar vermektedir. Bu karar beraberinde bazı parametreleri de getirir. K en yakın komşu (K Nearest Neighbor-KNN) algoritmasındaki *"k"* değeri, SVM algoritmasında kullanılacak çekirdek fonksiyonu ve derin öğrenme modellerinde seçilen "seyreltme (Drop

Out)" değerleri gibi bazı parametreler, modeli tasarlayan tarafından belirlenir. Bu belirleme işlemi verinin türüne, ele alınan konuya ve verinin boyutuna bağlı olarak değişebilmektedir.

Bu açıklamalardan yola çıkarak, hiper-parametre kavramı ortaya atılmıştır. Ne olması gerektiği, modeli tasarlayan kişiye bırakılmış, probleme, veri setine göre değişiklik gösteren parametreler hiper-parametre (hyperparameters) olarak adlandırılmaktadır (Çarkacı, 2018).

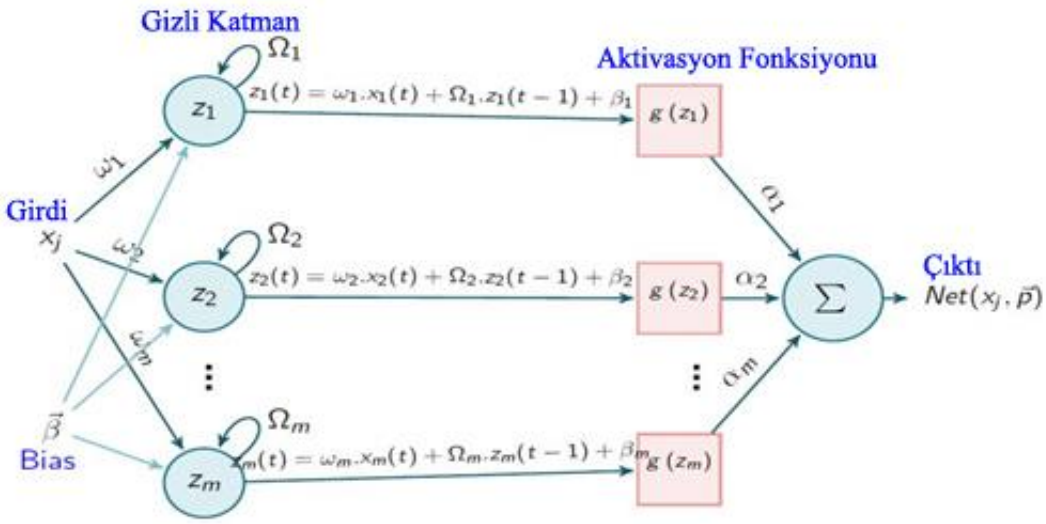
Oluşturulacak modelde kullanılacak hiper-parametreler, derin öğrenme uygulamalarındaki en önemli problemlerden birisidir. Hiper-parametreler ve bunların değerlerinin seçimi, verinin türüne, programcının tecrübesine ve sezgisine, yeni çalışmalara, farklı uygulamalarda elde edilen sonuçlar vb. gibi pek çok duruma bağlı olarak değişmektedir. Model tasarlanırken kullanılabilecek parametrelerden başlıcaları şunlardır:

- Ağda Kullanılacak Çekirdek Boyutu
- Parti büyüklüğü sayısı (Batch-size)
- Çevrim Sayısı
- Katman Sayısı
- Kullanılacak Aktivasyon Fonksiyonu
- Optimizasyon Algoritması
- Öğrenme Hızı (Learning Rate)
- Seyreltme (Drop Out) Değeri
- Seyreltme Kullanılacak Yerler
- Veri Setinin Büyüklüğü

Pek çok çalışmada bu hiper-parametreler, test et/sonucu yorumla yöntemiyle defalarca tekrarlanan çalışmalar sonucunda belirlenir. Modele en uygun olanı ve en iyi sonuç vereni, programcı tarafından belirlenerek, modelin son hali kaydedilir.

Tekrarlayan sinir ağı (RNN): Tipik sinir ağlarında genel olarak, her girdi ve çıktının diğerlerinden bağımsız olduğu varsayılır ancak bu varsayım bazı problemlerde doğru sonuç vermemektedir. Sıralı girdilerin kullanıldığı problemlerde (cümle-kelime ilişkisi gibi) önceki girdi bilgilerine ihtiyaç duyulmaktadır. Tekrarlayan sinir ağları, girdiler dizisindeki tüm elemanların hesaplamasını ayrı ayrı yapar ve her çıktı elemanı da mevcut girdiye ek

olarak önceki hesaplamalara bağlıdır. Şekil 3.17'de basit bir RNN yapısı gösterilmiştir (Günel ve diğerleri, 2018). Ayrıca geleneksel bir RNN mimarisinin artıları ve eksileri Çizelge 3.9'da verilmiştir (Amidi A. ve Amidi S., 2019).



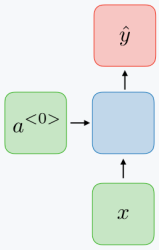
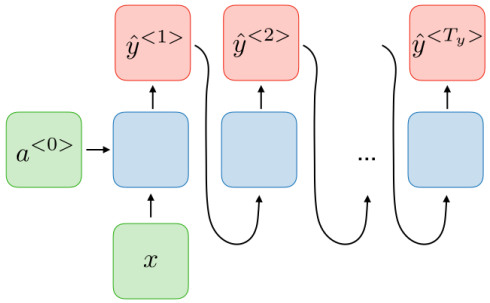
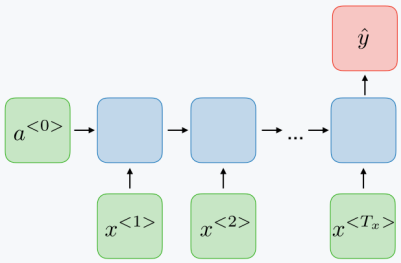
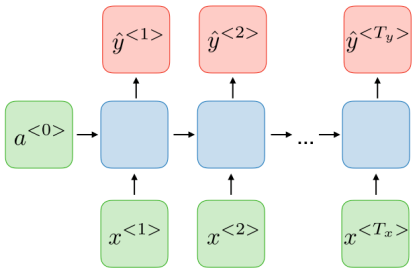
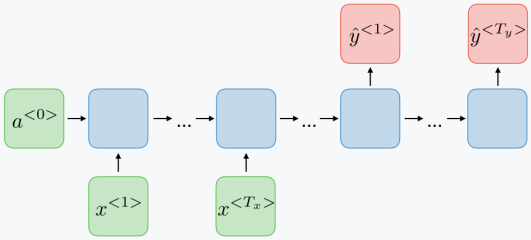
Şekil 3.17. Basit bir RNN yapısı (Günel ve diğerleri, 2018)

Çizelge 3.9. RNN mimarisinin avantaj ve dezavantajları (Amidi A. ve Amidi S, 2019)

Avantajları	Dezavantajları
• Değişken uzunluklarda girdiyi işleyebilme • Girdi boyutuna bağlı değişmeyen model boyutu • Hesaplamada geçmişten faydalanma Zamana dayalı paylaşımlı ağırlıklar	• Hesaplaması yavaş • Zaman geçtikçe önceki bilgilere erişim zorluğu • Mevcut durum halinde gelecekteki girdi tahmin zorluğu

RNN modelleri çoğunlukla doğal dil işleme ve konuşma tanıma alanlarında kullanılır. Farklı uygulamalar aşağıdaki tabloda özetlenmiştir (Amidi A. ve Amidi S, 2019):

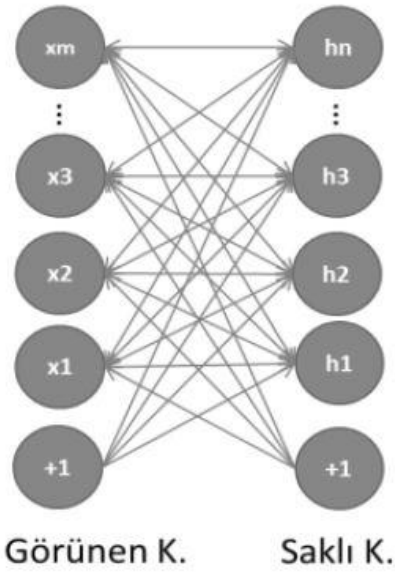
Çizelge 3.10. Farklı RNN uygulama yapıları (Amidi A. ve Amidi S, 2019)

RNN Türü	Örnekleme	Örnek
Bire bir $T_x=T_y=1$		Geleneksel sinir ağı
Bire çok $T_x=1, T_y>1$		Müzik üretimi
Çoka bir $T_x>1, T_y=1$		Duygu sınıflandırma
Çoka çok $T_x=T_y$		İsim varlık tanıma
Çoka çok $T_x \neq T_y$		Makine çevirisi

Uzun Kısa Süreli Bellek ağları, RNN'lerin uzun süreli hatırlama problemlerini çözmek amacıyla ortaya çıkmıştır.

Kısıtlı Boltzmann makineleri: Boltzmann makinelerinin görünür ve gizli katmanda yer alan birimlerin katman içindeki bağlantılarının kaldırıldığı basitleştirilmiş yapılardır. En büyük avantajı katmanlara ait birimler diğer katmanın bilinmesi durumunda şartlı olarak bağımsızdır. Görünür veya gizli birimler dışarıda bırakıldığında diğer katmana ait birimlerin genel olarak çarpanlarına ayrılması mümkündür. Görünür katmanın tüm birimlerinin alabileceği olası tüm değerler üzerinden integrali tek boyutlu integral şeklinde hesaplanabilir. Bu durum tahmin çıkarımında örneklem yönteminin doğru sonuçlar üretmesine imkân sağlar (Özcan, 2014).

Gizli birimler ve giriş birimleri arasındaki bağlantı yönlendirilmez. Boltzmann makinelerinde uygulanan verimsiz örnekleme gibi pratik sınırlamalarını önlemek için, yapısal olarak Boltzmann makinelerinin sınırlandırılmış bir versiyonu olarak önerilmiştir (Özcan, 2014).



Şekil 3.18. Kısıtlı Boltzmann makineleri diyagramı

Kısıtlı Boltzmann makinelerinde öğrenme oranlarının seçiminde titiz teorik bir arka plan çalışması olmamasından dolayı genellikle her iki eşik değerini (bias) öğrenmek için nispeten daha küçük öğrenme oranları kullanılır. Kısıtlı Boltzmann makineleri, Boltzmann makinelerinden türetilmiş özel bir yapı olduğundan öğrenme işlemi için Boltzmann makinelerinde kullanılan Gibbs örneklemesinin kullanılması mümkündür. Kısıtlı yapısı

sayesinde Gibbs örneklemesi daha verimli olarak kullanılabilir, verilen katman ister görünür ister gizli katman olsun, diğer katmanlardaki birimlerden karşılıklı olarak bağımsız hale gelir. Kısıtlı Boltzmann makineleri, nöronların sayısı arttıkça, temsil edilen olasılık dağılımının daha derli toplu açıklanması için Gibbs örnekleme yöntemi tarafından daha fazla sayıda örnek toplanmak zorundadır. Ayrıca, Gibbs örnekleme yöntemi yapısı gereği, örnekler dağıtımın bazı kısımlarını gözden kaçırabilirler (Tiken, 2015).

Derin inanç ağları: Derin inanç ağları, giriş katmanı olan bir görünür katmandan ve birden çok gizli katmandan oluşur. Birden fazla kısıtlı Boltzmann makineleri katmanı istiflenerek oluşturulur. Derin inanç ağlarının üst iki katı bir kısıtlı Boltzmann oluşturur ve alt katmanlar yönlendirilmiş bir sigmoid inanç ağı oluşturur (Elitez, 2015).

Derin inanç ağları çoklu stokastik, gizli değişken katmanlarından oluşan olasılıksal üretici modellerdir. Gizli değişkenler tipik olarak ikili değerlere sahiptir ve genellikle gizli birimler veya özellik dedektörleri olarak adlandırılır. Üstteki iki katman, aralarında yönlendirilmemiş, simetrik bağlantılara sahiptir ve ilişkili bir hafıza oluşturur. Alt katmanlar, yukarıdaki katmandan yukarıdan aşağıya doğru yönlendirilmiş bağlantılar alır. En alt katmandaki birimlerin durumları bir veri vektörünü temsil eder. Derin inanç ağlarının en önemli iki özelliği (Hinton, 2009):

- Bir katmandaki değişkenlerin, yukarıdaki katmandaki değişkenlere nasıl bağlı olduğunu belirleyen, üretici ağırlıkları öğrenmek için yukarıdan aşağıya etkili bir katman-katman prosedürü vardır.
- Öğrenmeden sonra, her katmandaki gizli değişkenlerin değerleri, alt katmandaki gözlenen bir veri vektörüyle başlayan ve ters yönde üretici ağırlıkları kullanan tek, aşağıdan yukarıya bir geçişle çıkarılabilir.

Derin inanç ağları, bir kerede gizli değişkenlerin değerlerini işleyerek bir sonraki katmanı eğitmek için veriler olarak verilerden çıkarıldıkları zaman, bir seferde bir katman öğrenir. Bu verimli, açgözlü öğrenmeyi, tüm ağın üretici veya ayırt edici performansını iyileştirmek için tüm ağırlıklara ince ayar yapan diğer öğrenme prosedürleri izleyebilir veya bunlarla birleştirilebilir. İstenen çıktıları temsil eden son bir değişkenler katmanı ve geri yayılma hata türevleri eklenerek, ayırt edici ince ayar yapılabilir (Hinton, 2009).

3.2.3. Derin öğrenme kütüphaneleri

Derin öğrenme algoritmalarının çalıştırılması, çalışmaların gerçekleştirilmesi ve problemlerin çözülmesi için kullanılan pek çok kütüphane vardır. Günümüzde mevcut kütüphaneler sürekli güncellenmekte, ayrıca yeni kütüphaneler de kullanıma sunulmaktadır. Ancak bu kütüphaneler arasında tam anlamıyla baskın olanı da bulunmamaktadır. Kullanıcılar deneyimlerine dayalı olarak farklı kütüphanelerde çalışmalar yapmaktadırlar. Derin öğrenme çalışmalarını gerçekleştirmek için kullanılan kütüphanelerden bazıları şunlardır.

TensorFlow: Makine öğrenmesi için Google tarafından geliştirilen uçtan uca bir açık kaynak platformudur. Makine öğrenmesi uygulamaları için kapsamlı, esnek araçlar ve kütüphaneler ile topluluk kanyakları içeren bir ekosisteme sahiptir. Çok sayıda soyutlama seviyesi bulunduğu için çözülmek istenilen probleme uygun olanı seçme imkânı sunar. Keras API'si, yaygın olarak pek çok derin öğrenme probleminde kullanılmaktadır. Uygulama anında yineleme ve sezgisel hata ayıklama mümkündür. Büyük çaplı makine öğrenmesi eğitim görevleri için, model tanımını değiştirmeden farklı donanım yapılandırmalarında dağıtılmış eğitim için Dağıtım Stratejisi API (Distribution Strategy API) kullanımı mevcuttur (Google, 2019).

TensorFlow ile sunucularda, cihazlarda ve webde model oluşturup eğitme ve dağıtma imkanı bulunmaktadır. Extended, Lite ve TensorFlow.js gibi farklı ortamlarda çalıştırılabilecek yapıları bulunmaktadır. Google, Intel, Twitter, CocaCola, airbnb, DeepMind, GE Healtcare, NeRSC gibi büyük firmalar, TensorFlow ile makine öğrenmesi uygulamaları gerçekleştirmektedir. Ayrıca dünyada pek çok araştırmacı, bu açık kaynak kütüphanelerini kullanarak araştırmalarını sürdürmektedir. Öne çıkan özellikleri şunlardır:

- Hem GPU hem de CPU ile paralel çalışabilmesi,
- TensorBoard ile görselleştirme yapılabilmesi,
- Model ve veri paralelliği sağlaması,
- Hızlı derleme yapılabilmesi.

Theano: Çok boyutlu dizileri içeren matematiksel ifadeleri verimli bir şekilde tanımlayabilen, optimize ederek değerlendirmeye imkân sağlayan bir Python kütüphanesidir. Python'da yazılmış çok genel bir kütüphane doğrudan derin öğrenme için kullanıldığı gibi üzerine yazılmış keras veya lasagne gibi kütüphanelerle de kullanılabilir. 2007'den itibaren geliştirilerek pek çok makine öğrenmesi probleminin çözümünde kullanılmıştır. 2017 yılında, artık Theano kütüphanesinin geliştirilmeye devam etmeyeceği, Yoshua Bengio tarafından duyurulmuştur (LISA lab., 2017). Öne çıkan özellikleri şunlardır:

- NumPy ile sıkı entegrasyonu,
- GPU ile kullanılabilmesi,
- Sembolik türev almada etkililiği,
- Hız ve kararlılık optimizasyonları,
- Dinamik C kodu üretimi,
- Kapsamlı birim-testi ve kendini-doğrulama.

Caffe: İfade, hız ve modülerliği göz önünde bulundurarak yapılan derin bir öğrenme çerçevesidir. Berkeley AI Research (BAIR) ve topluluk katılımcıları tarafından geliştirilmiştir. Caffe projesi Yangqing Jia'nin UC Berkeley'deki doktora eğitimi sırasında başlatılmıştır (Berkeley AI Research, 2014).

Mimarisi, uygulamaları ve derin öğrenme problemlerinde kullanımı teşvik edici yapıdadır. Modeller ve optimizasyonlar, kodlama ihtiyacı hissetmeden yapılandırma üzerinde tanımlanabilir. Bir GPU makinesinde eğitmek için tek bir etiket ayarlayarak CPU ile GPU arasında geçiş yapılabilir ve bilgisayarlar ile mobil cihazlar üzerinde kullanılmak için dağıtılabilir. Genişletilebilir yapısı ve fonksiyonelliği sayesinde, pek çok araştırmacı tarafından yenilikler ve eklemeler yapılmıştır. Hızlı çalışma özelliği vardır. Öne çıkan özellikleri şunlardır:

- GPU desteği,
- Kod yazmadan model eğitimi,
- Kullanışlı Python arayüzü,
- Görüntü işleme hızı,
- Önceden eğitilmiş modelleri.

Caffe2: Hafif, modüler ve ölçeklenebilir bir derin öğrenme çerçevesidir. Caffe üzerine inşa edilen Caffe2, ifade, hız ve modülerlik düşünülerek tasarlanmıştır. Nvidia ve Facebook tarafından ortaklaşa tasarlanan Caffe2, yeni modellerin ve algoritmaların topluluk katkılarından yararlanarak derin öğrenmenin kullanılması için kolay ve anlaşılır bir yol sağlamayı amaçlamaktadır. Caffe2, birbiriyle değiştirilebilir şekilde çalışan Python ve C ++ API'leri ile birlikte gelir. Böylece hızlı bir şekilde prototip oluşturulup daha sonra optimize edilebilir (Nvidia, 2019).

Caffe2, masaüstü, sunucular ve yerleşik aygıtlar için yüksek performanslı, çoklu GPU hızlandırması sağlamak için en son NVIDIA Deep Learning SDK kitaplıklarından, cuDNN, cuBLAS ve NCCL'den tam olarak yararlanmak için ayarlanmıştır. Bulut hizmetlerinde veya Docker görüntülerinde kullanılabilir ya da Mac, Windows veya Ubuntu tabanlı bilgisayarlara yüklenebilir. Caffe2, mobil geliştirme için Android Studio, Microsoft Visual Studio veya XCode ile de bütünleşik olarak çalışmaktadır (Facebook, 2019). Öne çıkan özellikleri şunlardır:

- Dağıtılmış CNN eğitimi, tek veya birden fazla GPU ya da birden fazla makinede eğitim olsun, tek bir hesaplama grafiği ile temsil edilebilir. Bu, Facebook ölçeğinde derin öğrenme uygulamaları için çok önemlidir.
- Özel donanımda kolay heterojen hesaplama, (Örneğin, iOS'ta Caffe2 hesaplama grafiği CPU'dan bir görüntü alabilir, onu Metal GPU tampon nesnelerine dönüştürebilir ve maksimum verim için hesaplamayı tamamen GPU üzerinde tutabilir).
- Memonger ile statik bellek optimizasyonu veya en iyi performans için önceden paketlenmiş eğitimli ağlar gibi çalışma zamanı kaynaklarının daha iyi yönetimi.

Keras: Derin öğrenme uygulamaları için hazırlanmış Python dilini kullanan bir derin öğrenme kütüphanesidir. Keras, TensorFlow, CNTK veya Theano'nun üzerinde çalışabilen üst düzey bir sinir ağları API'sidir. GPU ya da CPU üzerinde çalışmasını bu kütüphaneler üzerinden sağlar. Daha üst düzey bir kütüphane olduğundan Theano ya da Tensorflow'a göre daha kolay uygulama geliştirilebilir olduğu için yaygın kullanım alanına sahiptir (ONEIROS, 2019). Öne çıkan özellikleri şunlardır:

- Kolay ve hızlı prototipleme sağlaması (kullanıcı dostu, modülerlik ve genişletilebilirlik aracılığıyla),
- CNN ve RNN ile ikisinin kombinasyonlarını desteklemesi,
- CPU ve GPU üzerinde çalışabilmesi.

Keras, kullanıcı deneyimini ön planda tutan, kullanıcı dostu bir arayüzü olan ve makineler için değil, insanlar için tasarlanmış bir API'dir. Hata ayıklama için geri bildirim sağlar. Birbiriyle tutarlı ve basit kullanımlı API'ler sunar. Yeni modüllerin eklenmesi kolay olup, mevcut örneklerle yapılabilecek çözüm kümesi geniştir. Bu özellikleri araştırmalar için uygun yapıda olmasını sağlar ve genişletilebilir.

Sinir ağı katmanları, maliyet fonksiyonları, optimize ediciler, başlatma şemaları, aktivasyon fonksiyonları ve düzenlileştirme şemaları, yeni modeller oluşturmak için birleştirilebilecek modüler tasarıma imkân sağlar. Bildirim biçiminde ayrı model yapılandırma dosyası yoktur. Modeller, kompakt, hata ayıklaması kolay ve genişletilebilirlik kolaylığı sağlayan Python kodunda açıklanmıştır.

PyTorch: GPU'ları ve CPU'ları kullanan derin öğrenme için optimize edilmiş bir tensör kütüphanesidir. İki üst düzey özellik sağlayan bir Python paketidir (PyTorch, 2019). Öne çıkan özellikleri şunlardır:

- Güçlü GPU hızlandırma ile tensör hesaplaması (NumPy gibi),
- Bant tabanlı bir otograd sistemi üzerine kurulu derin sinir ağları.

PyTorch, monolitik bir C++ çerçevesine bağlanan bir Python değildir. Python'a derinlemesine entegre olmak için inşa edilmiştir. Yeni sinir ağı katmanları Python'da çeşitli kütüphaneler kullanılarak yazabilir ve Cython ile Numba gibi paketler kullanılabilir. Dilimleme, indeksleme, matematik işlemleri, doğrusal cebir, indirgeme gibi bilimsel hesaplama gereksinimlerini hızlandırmak ve karşılamak için çok çeşitli tensör rutinleri sunmaktadır.

MXNet: Apache MXNet, esnek ve etkili bir derin öğrenme kütüphanesidir. MXNet gibi hızlandırma kütüphaneleri, geliştiricilerin GPU'ların ve bulut bilişimin tüm özelliklerinden

yararlanmasına yardımcı olacak araçlar sunar. Bu araçlar genellikle herhangi bir matematiksel hesaplama için faydalı ve uygulanabilir olsa da, MXNet, büyük ölçekli derin sinir ağlarının gelişimini ve yayılmasını hızlandırmaya özel bir önem vermektedir (ASF, 2019) . Öne çıkan özellikleri şunlardır:

- Mevcut GPU'ların sayısıyla hesaplamayı ölçeklendirmeyi kolaylaştırarak çoklu GPU eğitimi sunması,
- Bir zamanlar sinir ağı araştırmalarını engelleyen türev hesaplamaları otomatik hale getirmesi,
- Optimize edilmiş önceden tanımlanmış katmanlar ile kullanıcının katmanlarını harmanlayarak kodlayabilirken, önceden tanımlanmış katmanlar, hız kazandırarak iyi performans göstermesini sağlaması,
- Her bir veri yapısı için ona uygun aygıt yerleşimi.

MXNet, GPU'lar ve dağıtılmış ekosistemler için, Python ve R gibi üst düzey ortamların konforundan optimize edilmiş sayısal hesaplama sağlar. MXNet ortak iş akışlarını otomatik hale getirir, böylece standart sinir ağları yalnızca birkaç kod satırında tam olarak ifade edilebilir. MXNet, iki programlama stilini destekler: zorunlu programlama (NDArray API tarafından desteklenir) ve sembolik programlama (Symbol API tarafından desteklenir). Matematiksel işlemleri optimize etmek için genel amaçlı bir araç setinin yanı sıra, MXNet önceden tanımlanmış sinir ağı katmanları sağlar.

CNTK: Microsoft Bilişsel Araç Seti (Cognitive Toolkit-CNTK), ticari sınıfta dağıtılmış derin öğrenme için açık kaynaklı bir araç setidir. Yapay sinir ağlarını, yönlendirilmiş bir grafik aracılığıyla bir dizi hesaplama adımı olarak tanımlar. CNTK, kullanıcının ileri beslemeli DNN'ler, CNN'ler ve tekrarlayan sinir ağları (RNN'ler / LSTM'ler) gibi popüler model tiplerini kolayca gerçekleştirmesini ve birleştirmesini sağlar. CNTK, çoklu GPU'lar ve sunucular arasında otomatik farklılaşma ve paralelleştirme ile SGD, hata geri yayılımı öğrenimini uygular. Python, C# veya C++ programlara bir kütüphane olarak dahil edilebilir veya kullanıcının kendi model açıklama dili (BrainScript) aracılığıyla bağımsız bir makine öğrenme aracı olarak kullanılabilir. Ek olarak, Java programlarında CNTK model değerlendirme işlevselliği kullanılabilir (Microsoft, 2019).

CNTK ayrıca, çerçeve birlikte çalışabilirliği ve paylaşımlı optimizasyon için açık kaynaklı bir paylaşılan model temsili olan Açık Sinir Ağı Değişimi ONNX biçimini destekleyen ilk derin öğrenme araçlarından biridir. Microsoft tarafından ortaklaşa geliştirilen ve diğerleri tarafından desteklenen ONNX, geliştiricilerin CNTK, Caffe2, MXNet ve PyTorch gibi çerçeveler arasında modeller taşımasına imkân tanır.

KNet: Julia üzerinde Deniz Yüret ve ortakları tarafından uygulanan derin öğrenme çerçevesidir. Julia'da tanımlanan modeller için dinamik hesaplamalı grafikler kullanarak GPU çalışmasını ve otomatik farklılaşmayı destekler. Knet, otomatik gradyan hesaplaması için çalışma zamanında oluşturulan dinamik hesaplamalı grafikleri kullanır. Bu da, makine öğrenim modellerinin, Julia gibi yüksek seviyeli bir dilin tam gücünü ve açıklamasını kullanarak yalnızca ileriye dönük hesaplamayı tanımlayarak uygulanmasına imkân tanır (Yüret, 2016).

DIGITS: İnteraktif bir derin öğrenme GPU eğitim sistemidir. Nvidia DIGITS (Deep Learning GPU Training System-DIGITS), görüntü sınıflandırma, bölümleme ve nesne algılama görevleri için son derece hassas derin sinir ağını hızlı bir şekilde eğitmek için kullanılabilir. Verileri yönetme, çoklu GPU sistemlerinde sinir ağları tasarlama ve eğitme, gelişmiş görselleştirmelerle gerçek zamanlı performansı izleme ve dağıtım için sonuç tarayıcıdan en iyi performans gösteren modeli seçme gibi genel derin öğrenme görevlerini basitleştirir. Tamamen etkileşimlidir, böylece veri bilimcileri programlama ve hata ayıklama yerine ağları tasarlamaya ve eğitmeye odaklanabilirler (Nvidia, 2019). Öne çıkan özellikleri şunlardır:

- Caffe, Torch ve TensorFlow kullanarak görüntü sınıflandırma, segmentasyon ve nesne algılama için derin sinir ağları tasarlama, eğitme ve görselleştirme,
- DIGITS Model Mağazasından AlexNet, GoogLeNet, LeNet ve UNET gibi önceden eğitilmiş modelleri indirme,
- Gelişmiş model doğruluğu için öğrenme hızı ve parti büyüklüğü hiperparametresi taraması gerçekleştirme,
- Sinir ağı eğitim işlerini planlama, izleme, yönetme ve gerçek zamanlı olarak doğruluk ve kayıpları analiz etme,
- DIGITS eklentisi ile çok çeşitli görüntü formatlarını ve kaynaklarını içe aktarma,

- Birden fazla GPU'da eğitim işlerini otomatik olarak ölçeklendirme.

The VELES: Hızlı Derin öğrenme uygulama geliştirme için dağıtılmış bir platformdur. Python'da yazılmış, Apache 2.0 altında OpenCL veya CUDA kullanır, akış tabanlı programlama kullanılır. VELES motoru performans ve esnekliğe odaklanır. Tam bağlı ağlar, CNN, yinelenen ağlar gibi bilinen pek çok algoritma kullanılabilir. Tüm arka uçlar aynı arayüze sahiptir ve aynı hesaplama sonuçlarını veya doğruluğunu tek veya çift hassasiyetle sağlar (Samsung, 2015). Öne çıkan özellikleri şunlardır:

- VELES'i Notebook veya Küme'ye tek bir komutla yerleştirme,
- 250'den fazla optimize edilmiş birimden model oluşturma,
- Loaders kullanarak hareket halindeyken veri setini analiz etme ve sunma,
- PC veya Yüksek Performanslı Küme'de çalıştırma,
- Eğitim sürecini uygulamalı olarak izleme,
- Eğitilmiş modeli otomatik olarak uygulama olarak çıkarma,
- Bulutta çalıştırma.

Bunlardan başka, Chainer, PaddlePaddle, Covnetjs, Deeplearning4j, PyLearn2, Deep Learn Toolbox-Matlab, Sci-Kit Learn, Accord.NET, Apache Spark, AccordMachineLearning vb. gibi makine öğrenmesi kütüphaneleri ve araçları mevcuttur. Farklı kullanım alanlarında, kullanıcılara sunulmuştur.

4. ÖNERİLEN STRATEJİ

Farklı çalışmalarda KA hastalığının erken tanı ve tedavisi için çeşitli yöntemler denenmiştir. Bu çalışmalar çoğunlukla farklı makine öğrenme algoritmaları kullanılarak değişen sayılarda hasta görüntüleri üzerinde segmentasyon işlemleri yapmak için gerçekleştirilmiştir (Menchón-Lara ve diğerleri, 2016), (Rocha ve diğerleri, 2010), (Molinari ve diğerleri, 2011), (Bastida-Jumilla ve diğerleri, 2015), (Menchón-Lara ve Sancho-Gómez, 2015), (Kutbay ve diğerleri, 2016), (Milletari ve diğerleri, 2017), (Ikeda ve diğerleri, 2017).

Segmentasyon işlemi görüntü analizinde, görüntüyü işleme ve tanı aşamalarını göstermeye hazırlama sürecidir (Kızılkaya, 2008). Bu çalışmalara ek olarak, bazı çalışmalarda otomatik arter tanıma ve lümen çapı değişikliklerini öngörmek için Intima Media Kalınlığı (IMT) ölçümleri de yapılmıştır (Rossi ve diğerleri, 2008), (Cheng ve diğerleri, 2010), (Loizou ve diğerleri, 2014). Ayrıca, KA hastalarının risk değerlendirmesi ve inme takibi için bulut bilişim tabanlı bir platform oluşturma çalışması yapılmıştır (Melillo ve diğerleri, 2015). Risk değerlendirmesi hastalığın en önemli aşamasıdır. Bu aşamada, Sinir Ağları (Neural Network - NN) (Christodoulou ve diğerleri, 2003), (Kyriacou ve diğerleri, 2005), (Mougiakakou ve diğerleri, 2007), Destek Vektör Makinesi (Kyriacou ve diğerleri, 2009), (Acharya ve diğerleri, 2012) ve Gelişmiş Etkinlik İndeksi (Pedro ve diğerleri, 2013) gibi çeşitli yöntemler kullanılarak sınıflandırma çalışmaları yapılmıştır.

Derin öğrenme, yapay zekâ problemlerini çözmek için makine öğrenmesi alanında yeni ve gelecek vaat eden bir alandır. Makine öğreniminin bir alt alanı ve Derin Sinir Ağları (DSA) uygulama alanıdır. Bu alanda, her bir çalışma için özelleştirilmiş algoritmalar yerine, çözümlerin öğrenme veri kümelerine dayanması ve daha büyük veri kümelerini kapsaması amaçlanmaktadır. Yapay Sinir Ağları (YSA) insan beyninden ilham almıştır. Ağırlıkları değiştirilerek birbirine bağlanan ve her biri kendi hafızasına sahip olan işlem elemanlarından oluşan bilgi işlem yapılarıdır. Öğrenme, genelleme, doğrusal olmama, hata toleransı, uyum, paralellik gibi üstünlükleri olan YSA'lar, görüntü ve sinyal işleme, hastalık tahmini, mühendislik, üretim, finans, optimizasyon ve sınıflandırma gibi birçok farklı uygulama alanında kullanılmaktadır (Arı ve Berberler, 2017). DSA'da iki veya daha fazla gizli sinir ağı katmanı olup basitten karmaşık verilerle daha kapsamlı ilişkiler kurulur. Her katman, kendisiyle önceki katman arasında bir ilişki kurmaya çalışır. Böylece girdilerin daha detaylı

bir incelemesi yapılmakta ve daha doğru kararlar alınmaktadır. YSA, verilen girdilere ağırlık ve aktivasyon fonksiyonu uygulayarak bir çıktı üretir.

Derin öğrenme algoritmaları kullanılarak tıp alanında farklı çalışmalar yapılmaya başlanmıştır. Otomatik abdominal çoklu organ segmentasyonu (Hu ve diğerleri, 2017), mikroskop görüntülerinin sınıflandırılması ve segmentasyonu (Kraus ve diğerleri 2016), biyomedikal görüntülerin segmentasyonu (Ronneberger ve diğerleri, 2015), metastatik meme kanseri (Wang ve diğerleri, 2018), meme kanseri histolojisi görüntülerinde mitoz tespiti (Cireşan ve diğerleri, 2013), diyabetik Retina fundus fotoğraflarında tanı (Gulshan ve diğerleri, 2016), retinopati, pulmoner nodüllerin tespit edilmesinde yanlış pozitif indirgeme (Dou ve diğerleri, 2017) ve ensefalogram sinyalleri ile otomatik olarak nöbet tespit/tanısı (Acharya ve diğerleri, 2018) bu çalışmalardan bazılarıdır. Söz konusu alanlardaki derin mimari performansının etkileyici olduğu bilinmesine rağmen, tıbbi alanda derin öğrenme kullanımı henüz yeterli değildir. Derin öğrenme, bilgisayar tanımlama, görüntü işleme, doğal dil işleme ve konuşma tanıma gibi alanlarda yaygın olarak kullanılır. Bu tür yeni yaklaşımlar otomatik tıbbi karar alma sistemlerinde gereklidir çünkü otomatik olmayan işlemler daha pahalıdır, yoğun emek gerektirir ve bu sebeple insan kaynaklı hatalara maruz kalır.

Bu doktora tezinde, derin öğrenme algoritmalarından tezin önceki bölümünde ayrıntısı verilen CNN algoritması kullanılmış, KA hastalığının sebeplerinden biri olan IMT artışı ve arteriyel daralmayı tespit ederek hastalığın teşhis ve tedavisinde karar destek amaçlı bir model önerilmiştir.

4.1. Materyaller

Çalışmada kullanılmak üzere, Haziran 2018 - Ocak 2019 tarihleri arasında, Ankara Eğitim ve Araştırma Hastanesi Radyoloji Kliniğinde tedavi gören 153 hastadan 501 US görüntüsü alınmıştır. Görüntüler, 08/05/2018 tarihli ve 2018-217 sayılı Gazi Üniversitesi Etik Komisyonu Etik Onay Belgesi ile alınmıştır. Ultrason görüntülemesi için Toshiba Aplio 400 Ultrason cihazı kullanılmıştır. Görüntüler, Ankara Eğitim ve Araştırma Hastanesi Radyoloji Bölümünde uzman iki doktor tarafından “IMT: 1” ve “IMT: 0” olarak sınıflandırılmıştır. Veritabanının özeti ve özellikleri Çizelge 4.1'de gösterilmiştir.

Çizelge 4.1. Veri tabanı özeti

Hasta Sayısı	Görüntü Sayısı	Sınıflar		US Makinesi	Etik
		IMT:1	IMT:0		
153	501	203	298	Toshiba Aplio 400	Gazi Üniversitesi Etik Komisyonu Tarih: 08/05/2018 Sayı: 2018-217

Tezde oluşturulan derin öğrenme modelini görüntüler üzerinde kullanmak için aşağıdaki özelliklere sahip bir sistem toplanmıştır.

- Z170I PRO GAMING (ASUSTeK COMPUTER INC.)
- Intel(R) Core(TM) i5-6600K CPU @ 3.50GHz (Intel Corp.)
- 16 GB RAM 2400MHz (Kingston)
- GP102 [TITAN Xp] (NVIDIA Corporation)
- ATA Disk 256GB (Samsung SSD 850) + ST1000DM003-1SB1 1TB (Seagate)

Bu çalışmada, Ubuntu işletim sistemindeki Python programlama dilinde Tensorflow ile Keras derin öğrenme kütüphanesi kullanılarak derin bir öğrenme modeli oluşturulmuştur. The Scientific Python Development Environment (Spyder) arayüzü kullanılarak çalışmalar yapılmıştır.

4.2. Metodoloji

Görüntülerin sınıflandırılması için derin bir öğrenme modeli oluşturulmuştur. Modelin performansını iyileştirmek için, derin öğrenme modelindeki hiper parametreler tekrarlanan analiz/test çalışmaları ile optimize edilmiştir. Derin öğrenme modeli oluşturulurken aşağıdaki adımlar izlenmiştir.

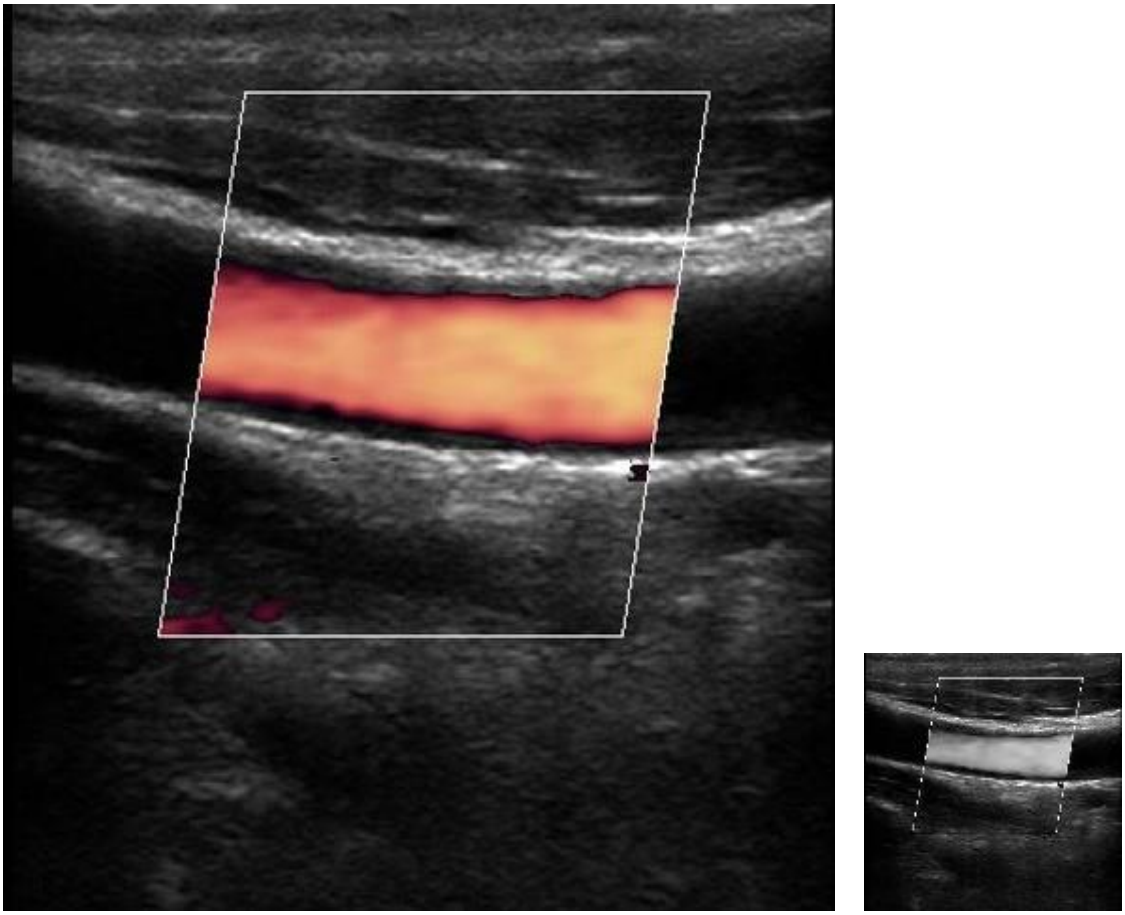
4.2.1. Tanımlama

İlk aşamada, keras, numpy, os, matplotlib ve sklearn gibi derin öğrenme modeli için gerekli kütüphaneler ve model parametreleri programa dâhil edilmiştir. Görüntü çözünürlüğü 128x128'de sabitlenmiş ve gri tonlu görüntü formatı kullanılacağından görüntü kanalı tek olarak belirlenmiştir. Görüntülerin alınacağı veri yolu tanımlanarak yeni görüntülerin ön

işleme işleminden sonra kaydedileceği ikinci bir veri yolu tanımlanmıştır. Modelde kullanılacak görüntü alma büyüklüğü, sınıf sayısı, çevrim sayısı, filtre sayısı, havuz büyüklüğü ve evrişim filtresi boyutu gibi parametreler burada tanımlanmıştır.

4.2.2. Görüntü Ön-İşleme

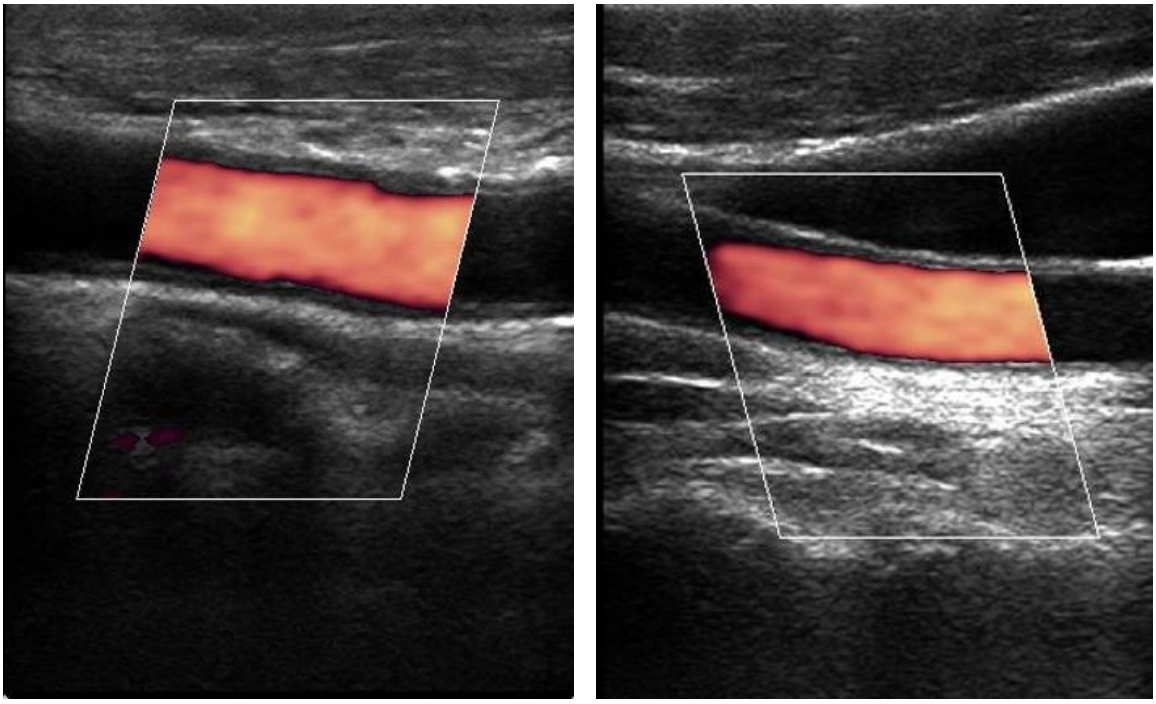
Bu aşamada, resim klasöründen alınan KA US görüntüleri 128x128 çözünürlükte yeniden boyutlandırılmıştır. Boyutlandırılan bu görüntüler daha sonra gri tonlamalı resim formatına dönüştürülerek tanımlama aşamasında belirlenen ikinci veri yolu klasörüne kaydedilmiştir. Görüntüler kaydedilirken, önceden sınıflandırıldıkları isimlerle sıralı bir liste halinde kaydedilmiştir. Örnek bir giriş görüntüsü (a) ve bu görüntünün ön-işleme aşamasından sonraki durumu (b) sırasıyla Şekil 4.1'de gösterilmiştir.



a) b)

Şekil 4.1. Modelde görüntü ön-işleme aşaması. a) Giriş görüntüsü b) Ön-işleme sonrası görüntü

Çözünürlük değiştirme ve görüntü formatı ayarlama işlemlerinden sonra tüm görüntüler bir matris üzerinde depolanmak için düzleştirilerek, bir dizi oluşturulmuştur. Diziye kaydedilen KA US görüntüleri ilk olarak 203. görüntüye kadar "1", 203. görüntüden sonraki görüntüler ise "0" olarak etiketlenmiştir. Bu etiketleme işlemi, Ankara Eğitim ve Araştırma Hastanesi, Radyoloji Bölümü'nde çalışmaya destek veren uzman doktoralar tarafından belirlenen "Intima Media Kalınlığı Var" ve "Intima Media Kalınlığı Yok" şeklindeki sınıflandırmaya uygun olacak şekilde gerçekleştirilmiştir (Şekil 4.2). Etiketleme işlemi tamamlandıktan sonra, bellekteki görüntüler rastgele karıştırılarak modelin verileri ezberlemesini önlemek ve doğruluğunu artırmak için daha önce sıralı olarak kaydedilen görüntüler listesi karıştırılmıştır.



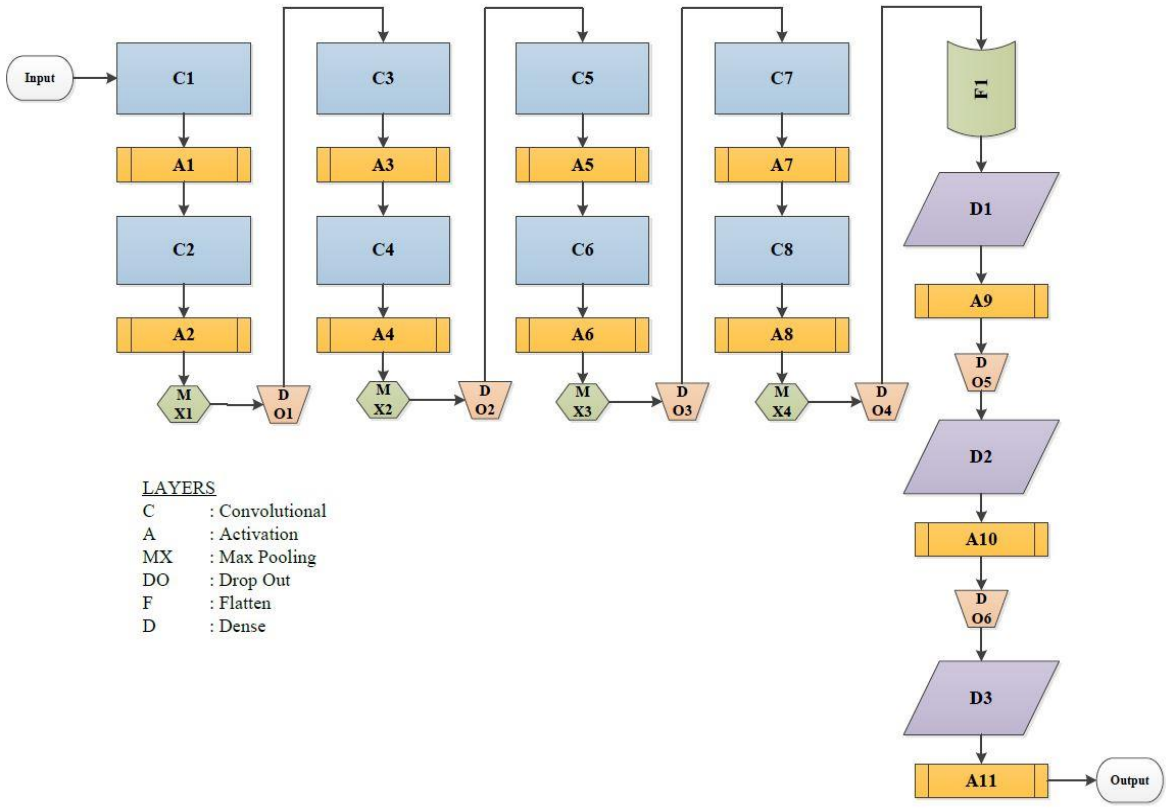
a) b)

Şekil 4.2. Sınıflandırılmış KA US görüntüleri. a) IMT var b) IMT yok

Görüntü ön-işleme aşamasının son basamağından elde edilen görüntü dizisi, eğitim ve test verileri olarak ikiye bölünmüştür. Dizideki görüntülerin %80'i eğitim için kullanılırken, kalan %20'si test için kullanılmıştır. Eğitim görüntülerinin tanımlanması sırasında, eldeki toplam görüntüdeki "1" etiketli ve "0" etiketli görüntülerin oranlarını koruyarak rastgele seçim yapılmıştır. Bu şekilde, çalışmadaki modelin eğitim kümesindeki görüntüler üzerindeki öğrenmeye duyarlılığını sağlamak ve modelin doğruluğunu arttırmak amaçlanmıştır. Ek olarak, verileri ezberleme veya verileri aşırı öğrenme olasılığı da önlenmiştir.

4.2.3. Model

Çalışmadaki model, tekrarlanan testlerden sonra optimum parametreler belirlenerek oluşturulmuştur. Oluşturulan modelde, sınıflandırma problemlerinde en çok bilinen ve en sık kullanılan algoritma olan CNN algoritması kullanılmıştır. Çalışmada oluşturulan derin öğrenme modelinin şeması Şekil 4.3'te gösterilmiştir.



Şekil 4.3. Model genel görünüm

Model sıralı olarak tasarlanmıştır. İlk katmanda öncelikle modele "*256*" filtre eklenmiş ve görüntüler "*3x3*" evrişim işleminden geçirilmiştir. Bu katmanın çıkış değerlerine "ReLU" aktivasyon fonksiyonu eklenmiş ve aktivasyon sonucu ikinci katmanın girişi olarak belirlenmiştir.

İkinci katmanda modele yine "*256*" filtre eklenmiş ve görüntüler "*3x3*" evrişim işleminden geçirilmiştir. Bu katmanın çıkış değerlerine "ReLU" aktivasyon fonksiyonu uygulanmıştır. Bu katmanın çıkışında modele "*Maxpooling*" yöntemiyle "*2x2*" boyutlarında bir havuzlama işlemi uygulayacak olan havuzlama katmanı ilave edilmiştir. Seyreltme (Drop Out) katmanı,

modelin verileri ezberlemesinin önüne geçmek ve aşırı öğrenmeyi engellemek için kullanılan bir katmandır. Modele bu aşamada "*0,5*" oranında bir "*Seyreltme*" katmanı eklenmiştir.

Üçüncü evrişimsel katman için modele "*256*" filtre eklenmiş ve görüntüler "*3x3*" evrişim işleminden geçirilmiştir. Bu katmanın çıkış değerlerine "ReLU" aktivasyon fonksiyonu eklenmiş ve aktivasyon sonucu dördüncü evrişimsel katmanın girişi olarak belirlenmiştir. Dördüncü evrişimsel katmanda modele yine "*256*" filtre eklenmiş ve görüntüler "*3x3*" evrişim işleminden geçirilmiştir. Bu katmanın çıkış değerlerine "ReLU" aktivasyon fonksiyonu uygulanmıştır. Bu katmanın çıkışında modele "*Maxpooling*" yöntemiyle "*2x2*" boyutlarında havuzlama katmanı eklenmiştir. Havuzlama işleminden sonra modele yine "*0,5*" oranında bir "*Seyreltme*" katmanı eklenmiştir.

Beşinci evrişimsel katmanda modele tekrar "*256*" filtre eklenmiş ve görüntüler "*3x3*" evrişim işleminden geçirilmiştir. Bu katmanın çıkış değerlerine "ReLU" aktivasyon fonksiyonu uygulanmış ve aktivasyon sonucu altıncı evrişimsel katmanın girişi olarak belirlenmiştir. Altıncı evrişimsel katmanda da modele "*256*" filtre eklenmiş ve görüntüler "*3x3*" evrişim işleminden geçirilmiştir. Bu katmanın çıkış değerlerine "ReLU" aktivasyon fonksiyonu uygulanmıştır. Bu katmanın çıkışında modele "*Maxpooling*" yöntemiyle "*2x2*" boyutlarında bir havuzlama katmanı ilave edilmiştir. Havuzlama işleminden sonra modele yine "*0,5*" oranında bir "*Seyreltme*" katmanı eklenmiştir.

Yedinci katmanda modele "*256*" filtre eklendikten sonra görüntüler "*3x3*" evrişim işleminden geçirilmiştir. Bu katmanın çıkış değerlerine "ReLU" aktivasyon fonksiyonu uygulanmış ve aktivasyon sonucu sekizinci ve son evrişimsel katmanın girişi olarak belirlenmiştir. Son evrişimsel katmanda da modele "*256*" filtre eklenmiş ve görüntüler "*3x3*" evrişim işleminden geçirilmiştir. Bu katmanın çıkış değerlerine "ReLU" aktivasyon fonksiyonu uygulanmıştır. Sekizinci katmanın çıkışında modele "*Maxpooling*" yöntemiyle "*2x2*" boyutlarında bir havuzlama katmanı ilave edilmiştir. Havuzlama işleminden sonra modele yine "*0,5*" oranında bir "*Seyreltme*" katmanı eklenmiştir.

Bu katmandan sonra, model "*Flatten*" yöntemiyle düzleştirilerek evrişim katmanlarından gelen matrix halindeki veriler tek boyutlu diziye çevrilmiştir. Düzleştirme işleminden sonra modele tam bağlı katmanlar eklenmiştir.

Modele daha sonra ağırlıklara bağlı olarak veriler sırasıyla "*256*" ve "128" çıkışa indirgenecek şekilde iki adet tam bağlı katman eklenmiştir. Her iki tam bağlı katmandan sonra da, yine aralara "*0,5*" oranında "*Seyreltme*" katmanları eklenmiştir. Son olarak model, çalışmadaki sınıf sayısı olan "2" sınıfa indirgenecek şekilde tam bağlı katman eklenmiş ve bu katmandan sonra "*softmax*" aktivasyon fonksiyonu uygulanmıştır.

Çalışmadaki verilerde iki sınıf bulunduğu için modele en uygun kayıp fonksiyonu ikili çapraz-entropi fonksiyonudur. Çapraz-entropi kaybı veya log kaybı, çıktısı "0" ile "1" arasında bir olasılık değeri olan bir sınıflandırma modelinin performansını ölçer. Öngörülen olasılık, gerçek etiketten ayrıldıkça, çapraz entropi kaybı artar. Bu sebeple modeli derlerken kayıp fonksiyonu, Eşitlik 19'daki (Hao, 2017) gibi hesaplanan ikili çapraz-entropi olarak seçilmiştir.

$$L = -\frac{1}{n}\sum_{i=1}^{n}[y^{(i)}\log(\hat{y}^{(i)}) + (1-y^{(i)})\log(1-\hat{y}^{(i)})] \quad (19)$$

Burada *n* örnek sayısı, *y* ise ilgili sinir hücresinin çıktısıdır.

Modelin iyileştirme algoritması olarak RMSprop (learning rate, lr = 0,00001) seçilmiştir ve metrik parametresi olarak "doğruluk" tanımlanmıştır. Öğrenme hızı, ağın ağırlıklarının kayıp gradyanına göre ne kadar ayarlanacağını kontrol eden bir hiper-parametredir. Değer ne kadar düşük olursa, aşağı eğim boyunca o kadar yavaş hareket edilir. RMSProp, son zamanlarda derin öğrenme algoritmalarında sıklıkla kullanılan ve performansını pek çok çalışmada kanıtlamış olan bir iyileştirme algoritmasıdır.

Bu aşamada ayrıca modelin derlenmesi sırasında iki farklı "callback" eklenmiştir. Bunlar eğitim prosedürünün belirli aşamalarında uygulanacak bir dizi işlevdir. Eğitim sırasında modelin içsel durumları ve istatistiklerini görmek için "callback" işlevleri kullanılabilir. Modelde kullanılan "callback" işlevlerinden birincisi; modelin son on çevrim boyunca öğrenmesinin gerçekleşmemesi durumunda eğitimi kesmesine yönelik bir kesmedir. Diğeri ise, eğitim sırasında doğruluğun arttığı çevrimlerde ağırlıkları kaydetmeye yönelik işlevdir. Bu kayıt işlemi için üçüncü bir veri yolu burada tanımlanmıştır. Kayıt ismi olarak ise "ÇevrimNumarası_DoğrulukOranı" şeklinde bir isim belirlenmiştir. Böylece model eğitilirken hangi çevrimde hangi doğruluk oranında ağırlıkların kaydedildiği belirlenmiştir.

Bu işlev, sadece doğruluk oranı arttığında kayıt yapacak şekilde tanımlanmıştır. Modelin genel yapısı şöyledir:

- Evrişim (Convolutional) Katmanı *X* 8
- Aktivasyon (Activation) Katmanı *X* 11
- Havuzlama (Max Pooling) Katmanı *X* 4
- Seyreltme (Drop Out) Katmanı *X* 6
- Düzleştirme (Flatten) Katmanı *X* 1
- Tam Bağlı (Fully Connected) Katman *X* 3

Modelde evrişim, aktivasyon, havuzlama, seyreltme, düzleştirme ve tam bağlı katmanlar dâhil olmak üzere toplam 33 katman bulunmaktadır. Modelin şeması ekler bölümünde gösterilmiştir (EK-1,2,3,4,5). Modelin giriş ve çıkış parametreleri ile özet bilgisi Çizelge 4.2'de gösterilmiştir.

Çizelge 4.2. Modelin özeti

Katman (Türü)	Çıktı Şekli	Parametre #
conv2d_1 (Conv2D)	(None, 126, 126, 256)	2560
activation_1 (Activation)	(None, 126, 126, 256)	0
conv2d_2 (Conv2D)	(None, 124, 124, 256)	590080
activation_2 (Activation)	(None, 124, 124, 256)	0
max_pooling2d_1 (MaxPooling2D)	(None, 62, 62, 256)	0
dropout_1 (Dropout)	(None, 62, 62, 256)	0
conv2d_3 (Conv2D)	(None, 60, 60, 256)	590080
activation_3 (Activation)	(None, 60, 60, 256)	0
conv2d_4 (Conv2D)	(None, 58, 58, 256)	590080
activation_4 (Activation)	(None, 58, 58, 256)	0
max_pooling2d_2 (MaxPooling2D)	(None, 29, 29, 256)	0
dropout_2 (Dropout)	(None, 29, 29, 256)	0
conv2d_5 (Conv2D)	(None, 27, 27, 256)	590080
activation_5 (Activation)	(None, 27, 27, 256)	0
conv2d_6 (Conv2D)	(None, 25, 25, 256)	590080
activation_6 (Activation)	(None, 25, 25, 256)	0
max_pooling2d_3 (MaxPooling2D)	(None, 12, 12, 256)	0
dropout_3 (Dropout)	(None, 12, 12, 256)	0
conv2d_7 (Conv2D)	(None, 10, 10, 256)	590080
activation_7 (Activation)	(None, 10, 10, 256)	0
conv2d_8 (Conv2D)	(None, 8, 8, 256)	590080
activation_8 (Activation)	(None, 8, 8, 256)	0
max_pooling2d_4 (MaxPooling2D)	(None, 4, 4, 256)	0
dropout_4 (Dropout)	(None, 4, 4, 256)	0
flatten_1 (Flatten)	(None, 4096)	0
dense_1 (Dense)	(None, 256)	1048832
activation_9 (Activation)	(None, 256)	0
dropout_5 (Dropout)	(None, 256)	0
dense_2 (Dense)	(None, 128)	32896
activation_10 (Activation)	(None, 128)	0
dropout_6 (Dropout)	(None, 128)	0
dense_3 (Dense)	(None, 2)	258
activation_11 (Activation)	(None, 2)	0
Toplam parametre: 5,215,106 Eğitim parametresi: 5,215,106 Eğitim dışı kalan parametre: 0		

4.2.4. Görselleştirme

Modelin çalıştırılmasından sonra grafikler ve ağırlıklar kaydedilmiştir. Bu aşamada modelin doğruluk ve kayıp parametreleri görselleştirilmiştir. ROC Eğrisi ve Karışıklık Matrisi de oluşturulmuştur. Tahmin modelinde kullanılmak üzere modelin eğitimi sonrasında ağırlıklar kaydedilmiştir.

Bu aşamada ilk olarak tüm model şeması, "*plot_model*" fonksiyonu kullanılarak resim formatında kaydedilmiştir (EK-1,2,3,4,5). Modelin eğitimi sırasında her bir çevrimde elde edilen eğitim ve test bloklarına ait "doğruluk ve kayıp" sonuçları, "*history*" parametresi altında kayıt altına alınmaktadır. Modelin şemasının kayıt edilmesinin ardından bu sonuçlar da belirlenen iki değişkene aktarılmıştır. Kayıt aralığı olarak, çevrim sayısı tanımlanmıştır.

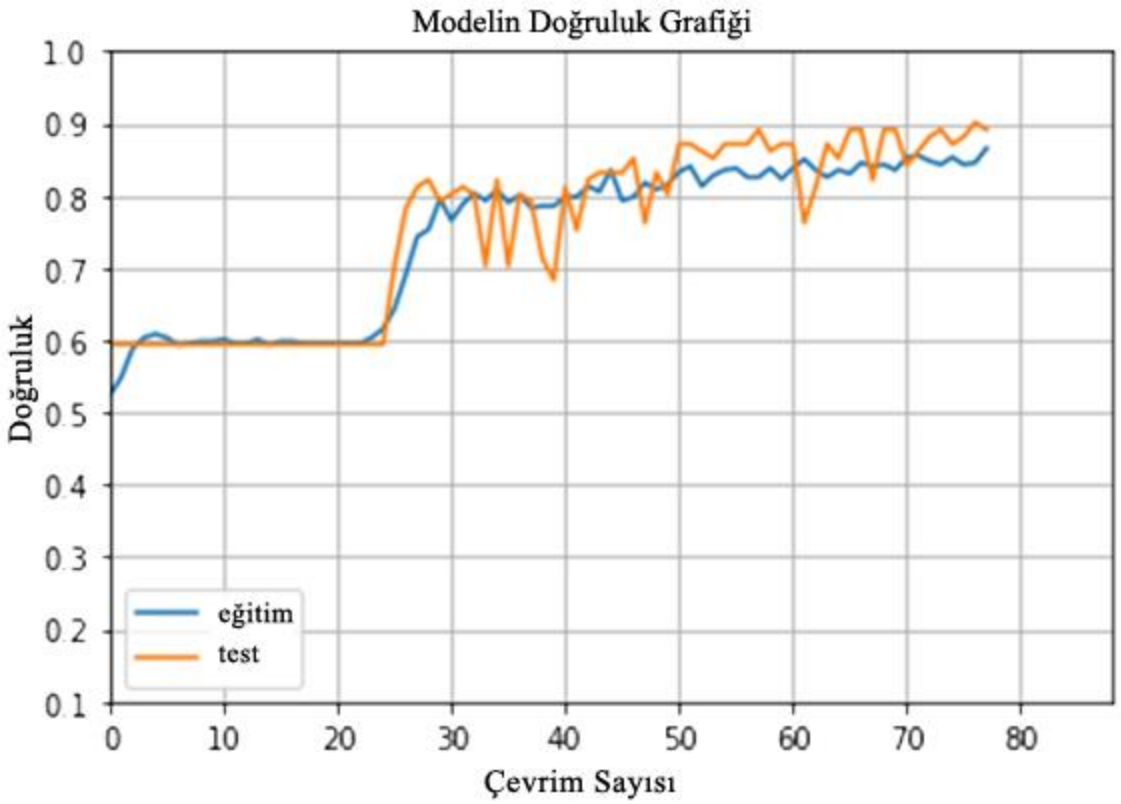
Kayıt altına alınan doğruluk ve kayıp değerleri "*plot*" fonksiyonu yardımıyla grafiğe dönüştürülmüştür. Grafiğin *x* ekseni çevrim sayısı olarak belirlenirken, *y* ekseni ise "*0,1 - 1*" aralığında belirlenmiştir.

Bir sonraki görselleştirme aşamasında, modelin elde ettiği skor parametreleri "doğruluk ve kayıp" kayıt altına alınarak ekrana yazdırılmıştır. Ardından test kümesi içerisinden dokuz görüntü rasgele seçilerek tahmin işlemi gerçekleştirilmiştir. Tahmin sırasında görüntülerin sınıfları yazdırılmış ve karşılığında modelin gerçekleştirdiği tahmin sonuçları yazdırılmıştır.

Modelin karışıklık matrisi (Confusion Matrix) de bu aşamada oluşturulmuştur. Karışıklık matrisi ve ROC eğrisi oluşturularak yazdırılmıştır. Modelin eğitimi sırasında özellik çıkarımına örnek teşkil etmesi için bir giriş görüntüsünün, *1. 5. 10.15.* ve *20.* katmanlardan sonraki durumunu göstermek amacıyla, çıkış görüntüleri kaydedilmiştir. Son olarak model ağırlıkları ve modelin kendisi bu aşamada kaydedilerek program sonlandırılmıştır.

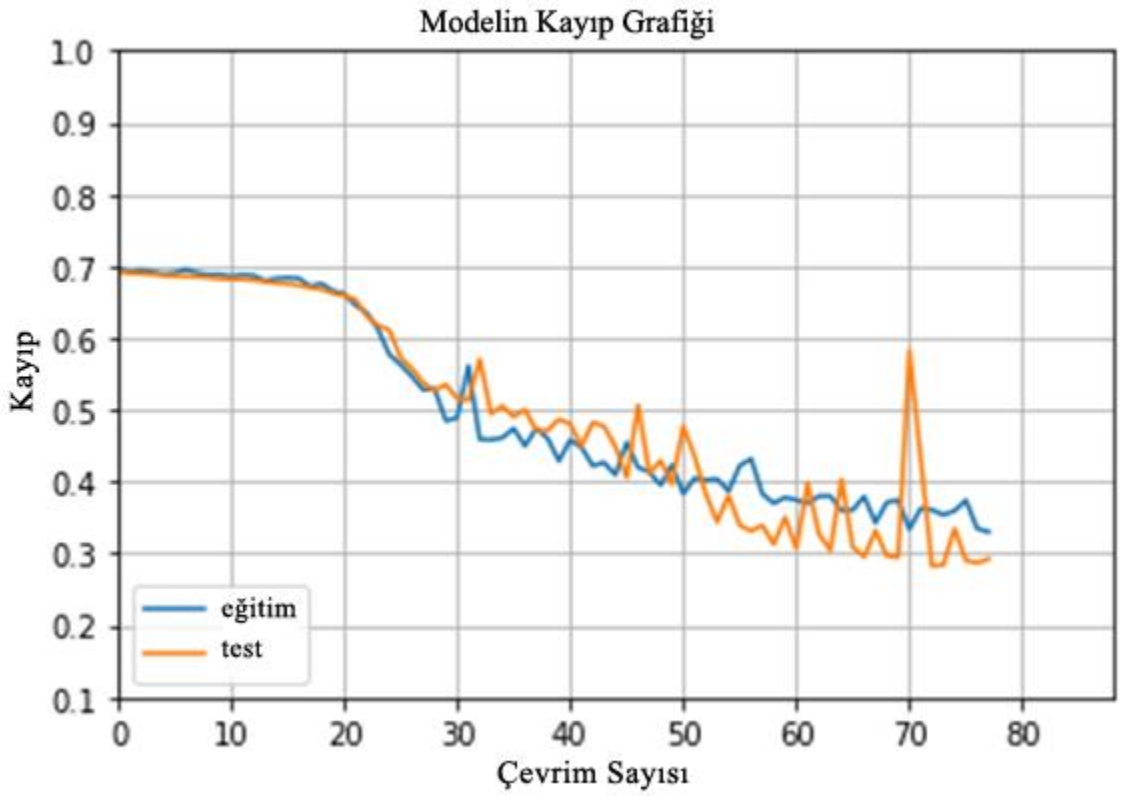
5. DENEYSEL SONUÇLAR

Bu doktora tezinde hiper-parametreleri tekrar tekrar yapılan test ve analiz çalışmalarından sonra optimum değerleri belirlenerek önerilen modelin doğruluk oranı %89,1 olarak ölçülmüştür. Model kayıp değeri 0,292'dir. Kayıp fonksiyonu, CNN modeli için önemli bir göstergedir, çünkü öngörülen değer ile gerçek etiket arasındaki tutarsızlığı ölçmek için kullanılır. Model sağlamlığı, kayıp fonksiyonunun değerinin azalması ile birlikte arttığı, negatif olmayan bir değerdir (Hao, 2017). Modelin doğruluk ve kayıp grafikleri Şekil 5.1'de sırasıyla verilmiştir.



a)

Şekil 5.1. a) Modelin doğruluk grafiği b) Modelin kayıp grafiği



b)

Şekil 5.1. (devam) a) Modelin doğruluk grafiği b) Modelin kayıp grafiği

Çalışmanın modeli 25 çevrimden sonra eğitim verilerinden öğrenmeye başlamaktadır. Modelin doğruluğu artarak ve bu çevrimin ardından kayıp parametresi düşmektedir. Sınıflandırma sonuçları ayrıca beklenmedik durum tablosu olarak da bilinen sözde karışıklık matrisinde de gösterilebilir (Ferri ve diğerleri, 2003), (Provost ve Domingos, 2003), (Rosset, 2004). Bu matris satırları ve sütunları sırasıyla eğitim ve tahmin sınıflarını temsil eden bir kare matristir (*G x G*). Karışıklık matrisi, örneklerin sınıf içindeki dağılımı ve sınıflandırma performansı ile ilgili tüm bilgileri içerir (Ballabio, 2018). Modelin karışıklık matrisinin sonuçları Şekil 5.2'de gösterilmiştir:

Sayı = 101		Tahmin Edilen		Toplam
		Negatif (IMT:0)	Pozitif (IMT:1)	
Gerçek	Negatif (IMT:0)	TN = 57	FP = 3	60
	Pozitif (IMT:1)	FN = 8	TP = 33	41
Toplam		65	36	

TN: True Negative, TP: True Positive, FN: False Negative, FP: False Positive

Şekil 5.2. Modelin karışıklık matrisi

Şekil 5.2'de gösterilen sonuçlara bağlı olarak Karotis sınıflandırıcı, 101 görüntüden 36'sını "*pozitif*" etiketli ve 65'ini "*negatif*" etiketli görüntü olarak tahmin etmiştir. Gerçekte, örneklemdeki 41 hastanın IMT görüntüsü "*kalınlık var (pozitif)*" ve 60 hastanın IMT görüntüsü ise "*kalınlık yoktur (negatif)*" durumundadır. Karışıklık matrisinde *TP*, gözlemin pozitif olduğu ve gerçeğin de pozitif olduğu belirtilmektedir. *FN*, gözlemin pozitif olduğu ancak gerçeğin negatif olduğu anlamına gelir. *TN*, gözlemin negatif olduğu ve gerçeğin de negatif olduğu tahmin edilir. *FP*, gözlemin negatif olduğu ancak gerçeğin pozitif olduğu anlamına gelir. Elde edilen karışıklık matrisi incelendiğinde, örneklemdeki 60 adet IMT:0 sınıfına ait görüntüden 57 tanesi doğru olarak tahmin edilmiş, 3 tanesi ise yanlış pozitif olarak tahmin edilmiş ve IMT:1 sınıfında yer almıştır. Örneklem içerisinde yer alan 41 adet IMT:1 sınıfına ait görüntüden 33 tanesi doğru olarak tahmin edilmiş, 8 tanesi ise yanlış negatif olarak tahmin edilerek IMT:0 sınıfında yer almıştır. Karışıklık matrisinde ortaya çıkan tüm değerlerin hesaplamaları Eşitlik 20-27'de sırasıyla gösterilmiştir.

Doğruluk hesaplaması, sınıflandırıcının ne sıklıkla doğru olduğunun genel sonuçlarını verir. Bu Karotis sınıflandırıcısı (*cc*) için doğruluk Eşitlik 20'deki gibi hesaplanır:

$$Doğruluk\ (Acc) = \frac{TP+TN}{TP+TN+FP+FN} \tag{20}$$

$$Acc_{cc} = \frac{90}{101} = 0{,}891$$

Genel olarak hata oranı, sınıflandırıcının yanlış olarak ne sıklıkla öngördüğünün bir ölçüsüdür. Ek olarak, yanlış sınıflandırma oranı olarak da bilinir. Hata oranı bir eksi doğruluğa eşdeğer olup Eşitlik 21'deki gibi hesaplanır:

$$Hata\ oranı\ (ER) = \frac{FP+FN}{TP+TN+FP+FN} \tag{21}$$

$$ER_{cc} = \frac{11}{101} = 0{,}108$$

Gerçek pozitif oranı, gerçekte ne zaman pozitif olduğunu ve ne sıklıkla pozitif tahmin ettiğini gösterir. Aynı zamanda "*Geri Çağırma*" veya "*Recall*" olarak da bilinir. Recall, toplam olarak sınıflandırılan pozitif örneklerin toplam sayısının, toplam pozitif örnek sayısına bölünmesi olarak tanımlanabilir. Yüksek Recall oranı (az sayıda FN), sınıfın doğru bir şekilde tanındığını gösterir. Recall, genellikle hedef FN sayısını sınırlamak olduğunda kullanılır ve Eşitlik 22'deki gibi hesaplanır:

$$Geri\ Çağırma\ (Recall) = \frac{TP}{TP+FN} \tag{22}$$

$$Recall_{cc} = \frac{33}{41} = 0{,}804$$

Yanlış pozitif oran, negatif gerçek değerin pozitif tahmininin sonuçlarını verir. Eşitlik 23'deki formülle hesaplanır:

$$Yanlış\ Pozitif\ Oran\ (FPR) = \frac{FP}{FP+TN} \tag{23}$$

$$FPR_{cc} = \frac{3}{60} = 0{,}05$$

Gerçek negatif oran, aslında ne zaman negatif olduğunu ve ne sıklıkta negatif olabileceğini gösterir. Aynı zamanda "*Özgüllük veya Seçicilik*" olarak bilinir ve bir eksi FPR'ye eşdeğerdir. Özgüllük Eşitlik 24'deki gibi hesaplanır:

$$Özgüllük\ (TNR) = \frac{TN}{FP+TN} \tag{24}$$

$$TNR_{cc} = \frac{57}{60} = 0{,}95$$

Hassasiyet, tüm sınıfların ne kadar doğru tahmin edildiğinin bir ölçüsüdür. Pozitif prediktif değer, hassasiyet ve duyarlık olarak da bilinir. Hassasiyet değerini elde etmek için, doğru sınıflandırılmış pozitif örneklerin toplam sayısı, öngörülen pozitif örneklerin toplam sayısına bölünür. Yüksek hassasiyet, pozitif olarak gerçekten pozitif (örneğin az sayıda FP) olarak etiketlenmiş bir örneği gösterir. Hassasiyet Eşitlik 25'deki gibi hesaplanır:

$$Hassasiyet = \frac{TP}{TP+FP} \tag{25}$$

$$Hassasiyet_{cc} = \frac{33}{36} = 0{,}916$$

Yaygınlık, tahmin sonunda ne kadar sıklıkla "pozitif" değer bulunduğunun göstergesidir. Eşitlik 26'daki gibi hesaplanır:

$$Yaygınlık = \frac{TP+FN}{TP+TN+FP+FN} \tag{26}$$

$$Yaygınlık_{cc} = \frac{41}{101} = 0{,}405$$

F1 puanı, hassasiyet ve geri çağırmanın harmonik ortalamasıdır. Sınıflandırıcının ne kadar iyi performans gösterdiğinin bir ölçüsüdür ve sınıflandırıcıları karşılaştırmak için sıklıkla kullanılır. Sadece geri çağırma optimize edilmeye çalışılırsa, algoritma çoğu örneğin pozitif sınıfa ait olduğunu tahmin eder ancak bu birçok yanlış pozitif ve dolayısıyla düşük hassasiyetle sonuçlanır. Öte yandan hassasiyeti optimize etmeye çalışırsa, model çok az örneği pozitif sonuç olarak tahmin eder ancak geri çağırma çok düşük olacaktır. Bu sebeple, F1 puanı hem hassasiyeti dikkate almak hem de geri çağırmayı dikkate almak gerektiğinde kullanışlıdır. F1-Puanı Eşitlik 27'deki gibi hesaplanır:

$$F1\ puanı = \frac{2TP}{2TP+FP+FN} \tag{27}$$

$$F1_{cc} = \frac{66}{77} = 0{,}857$$

Tüm karışıklık matrisi parametrelerinin hesaplanmasından sonra, "*IMT:0*" ve "*IMT:1*" sınıfları için modelin genel ortalama performans ölçümleri Çizelge 5.1'de gösterilmiştir.

Çizelge 5.1. Performans ölçümleri

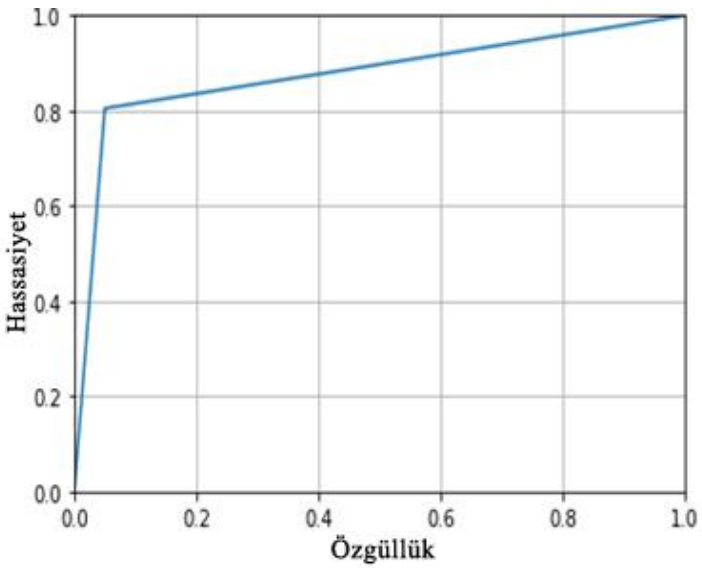
	Hassasiyet	Geri Çağırma	F1 Puanı	Örneklem
IMT:0	0,88	0,95	0,91	60
IMT:1	0,92	0,80	0,86	41
Mikro Ortalama	0,89	0,89	0,89	101
Makro Ortalama	0,90	0,88	0,88	101
Ağırlıklı Ortalama	0,89	0,89	0,89	101

Karışıklık matrisinde modelin hassasiyet ortalamasının %89, geri çağırma ortalamasının ise %88 olduğu görülmektedir. Modeli test etmek için 101 görüntü kullanılmıştır. Modelin eğitiminden sonra test edilirken, her iki sınıftaki görüntülerin sayısı toplam görüntüdeki oran korunarak belirlenmiştir. Modelde, Çizelge 5.2'de görüldüğü gibi dokuz test görüntüsü sınıfından sekizi doğru olarak tahmin edilmiştir.

Çizelge 5.2. Test ve tahmin değerleri

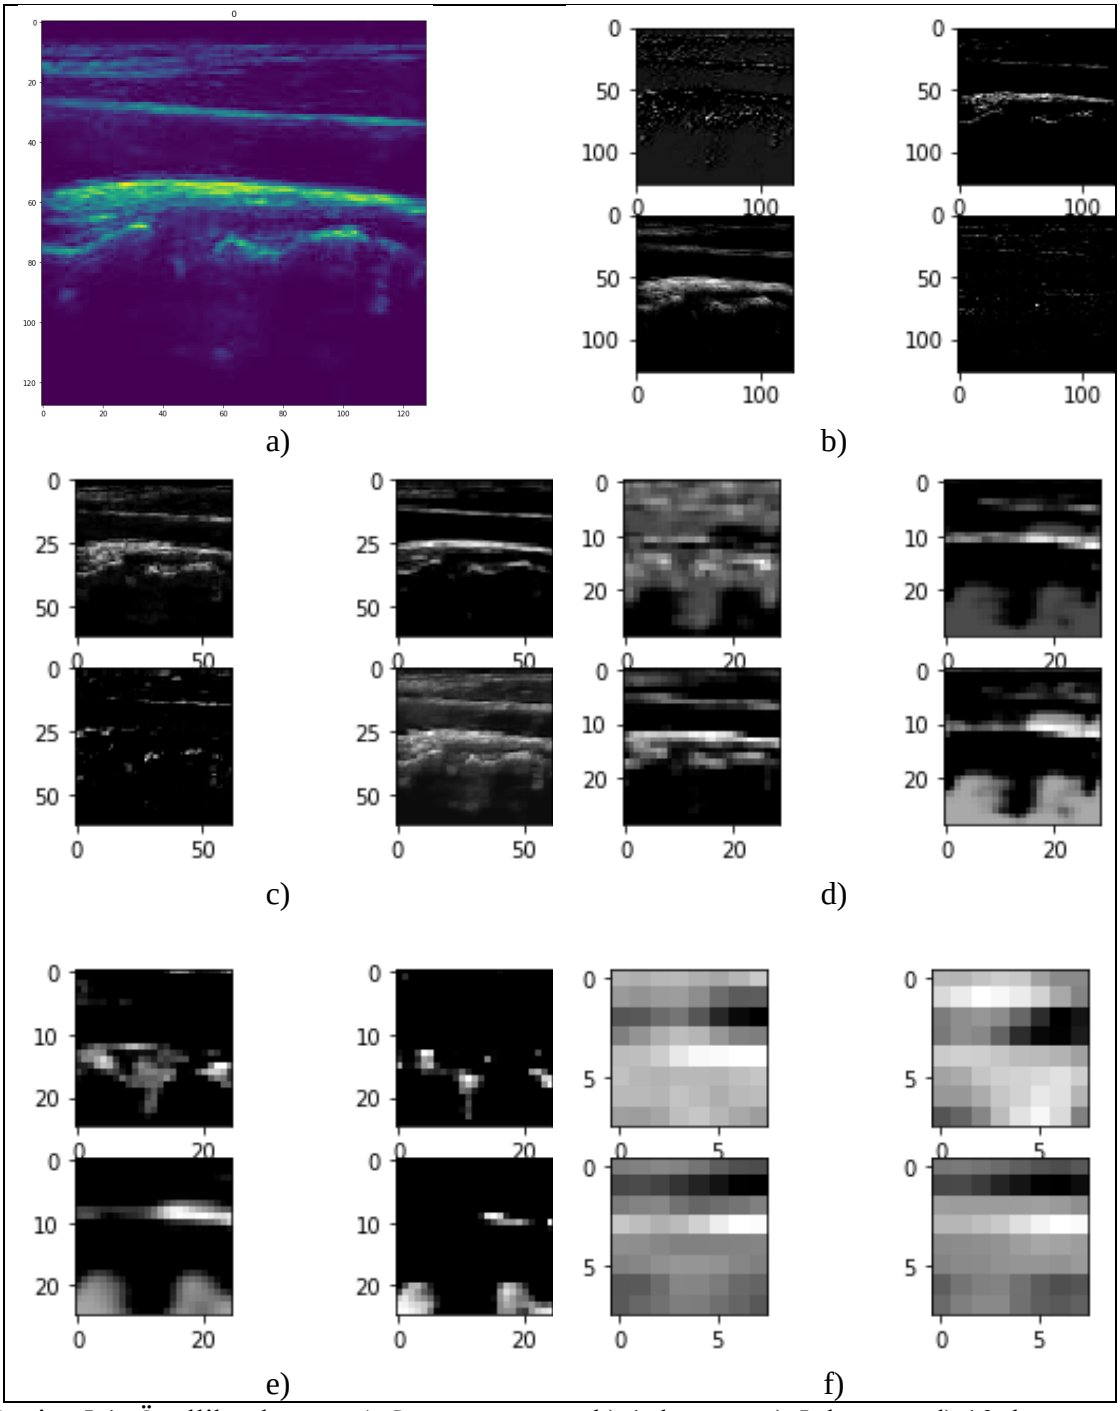
Test değerleri	0	1	0	0	1	0	0	0
Tahmin değerleri	[0. 1.] X	[0. 1.] √	[1. 0.] √	[1. 0.] √	[0. 1.] √	[1. 0.] √	[1. 0.] √	[1. 0.] √

ROC analizi, tanı sürecinin uzun süreceği klinik karar verme sürecine katkıda bulunur (Kılıç, 2013). Hassasiyet ve özgüllük eğrileri, farklı klinik testlerindeki başarıların karşılaştırılmasını sağlar. Çalışmadaki KA IMT durumunda, ROC eğrisi Şekil 5.3.'te gösterilmiştir.



Şekil 5.3. Modelin ROC eğrisi

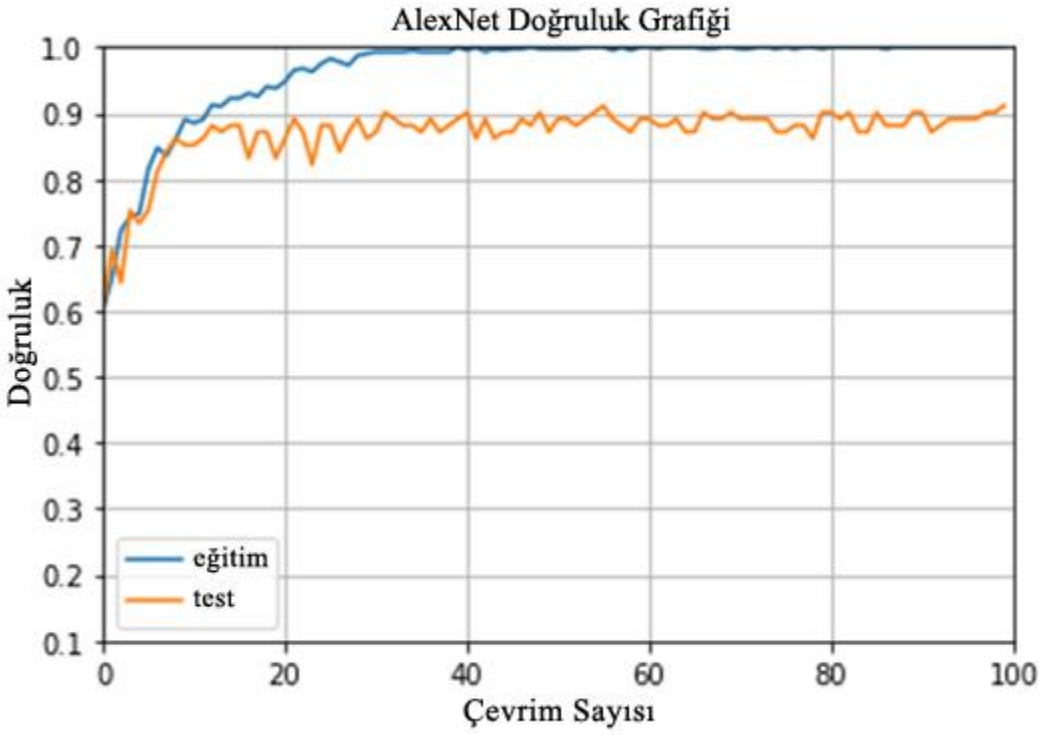
Modelin eğitimi sırasında katmanların çıktıları, IMT US görüntüleri üzerinde çalışan CNN modelinde örnek özellik çıkarımını göstermek için kaydedilmiştir. Orijinal giriş görüntüsü ve 1., 5., 10., 15. ve 20. katman aktivasyon çıktıları, Resim 5.1'de sırasıyla gösterilmiştir. Her bir katmanda görüntünün hangi aşamalardan geçtiği ve özellik çıkarımının nasıl gerçekleştiği görülmektedir.



Resim 5.1. Özellik çıkarımı a) Giriş görüntüsü b) 1. katman c) 5. katman d) 10. katman e) 15. katman f) 20. katman

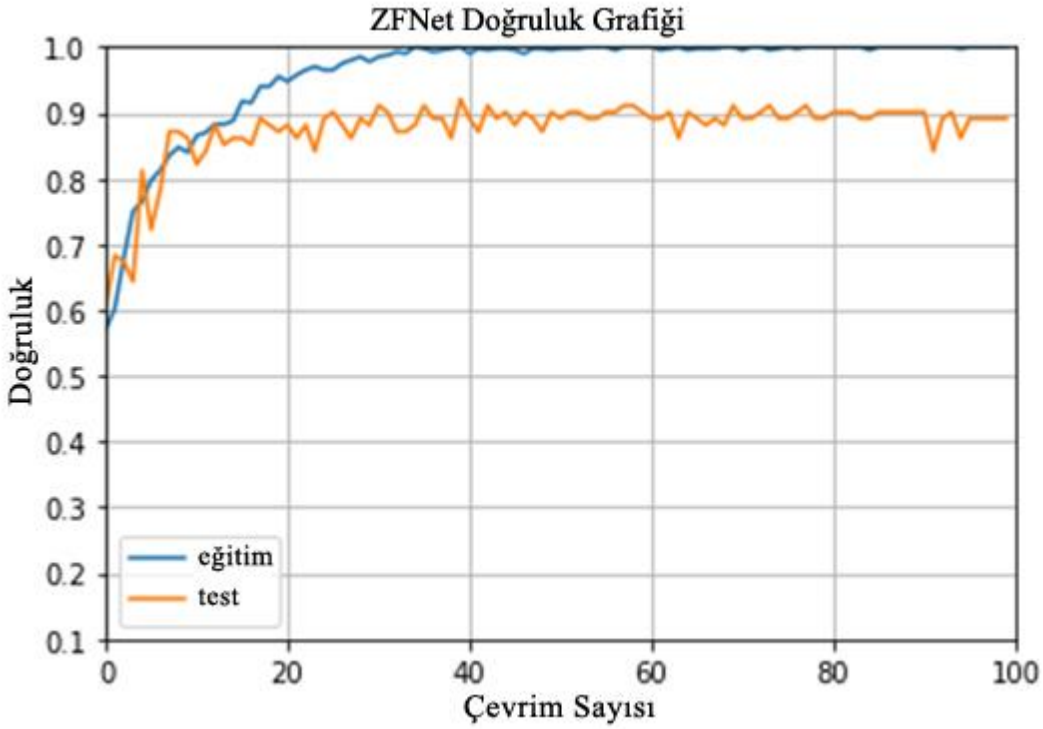
Çalışmada ayrıca derin öğrenme mimarilerinin, biyomedikal alandaki performansları da karşılaştırılmıştır. Tıp alanında gerçekleştirilen çalışmalarda birbirinden farklı görüntüleme teknikleri ve farklı görüntü türleri kullanıldığı için, henüz ortak modeller ve algoritmalarla çözüm üretme aşamasına gelinmemiştir. Oysa ImageNet yarışmasında oluşturulan mimariler, binlerce farklı görüntü türü içerisinden sınıflandırma gerçekleştirebilmektedir.

Bu doktora tezinde tasarlanan model CNNcc ile AlexNet, ZFNet, VGG16 ve VGG19 modellerinin KA IMT US görüntülerini sınıflandırmadaki başarım performansları karşılaştırılmıştır. Veri tabanındaki görüntüler üzerinde eğitilen ve test edilen derin öğrenme modellerinin doğruluk grafikleri Şekil 5.4'te ve sonuçları ise Çizelge 5.3'te gösterilmiştir.

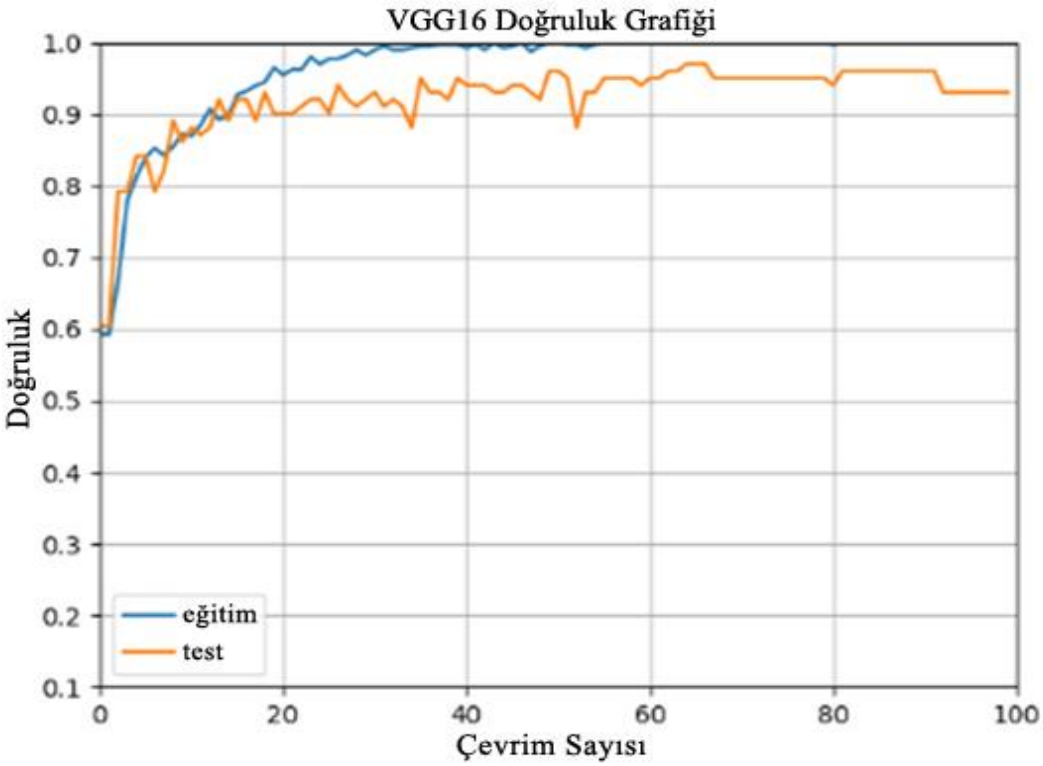


a)

Şekil 5.4. Doğruluk grafikleri a) AlexNet b) ZFNet c) VGG16 d) VGG19 e) CNNcc

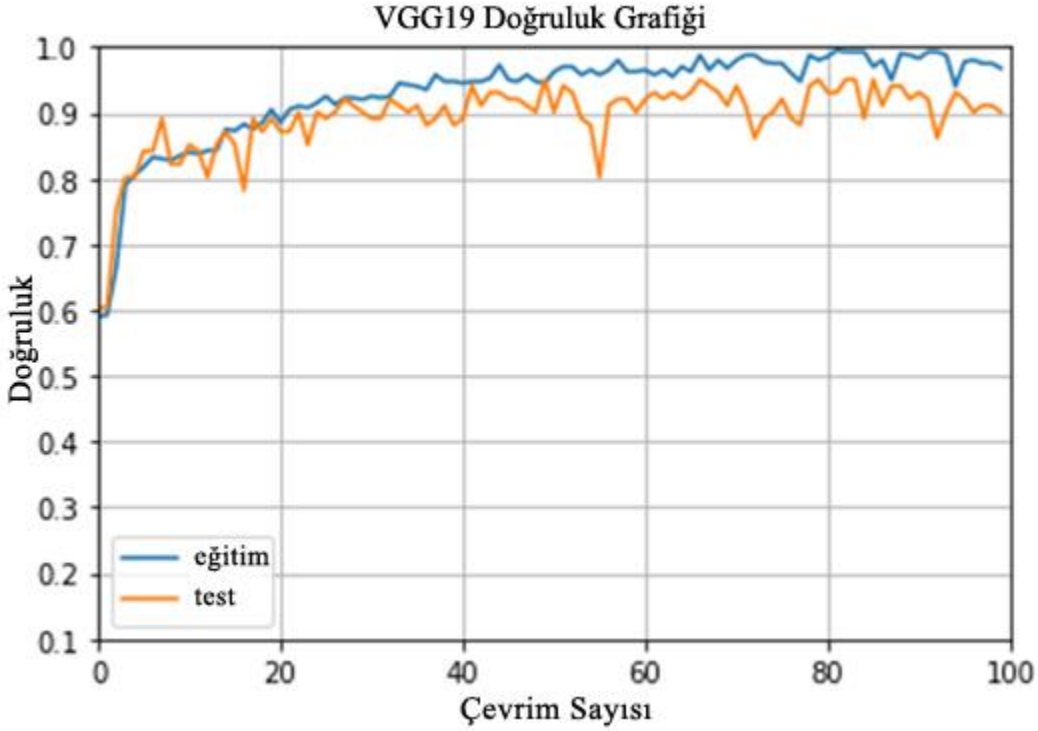


b)

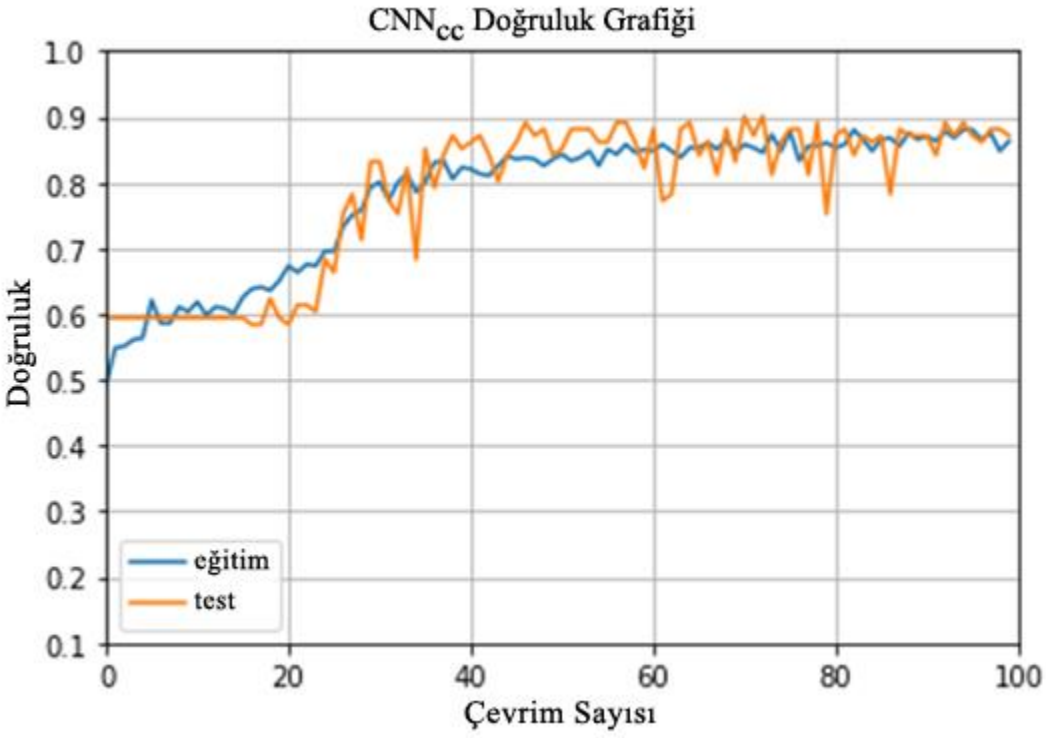


c)

Şekil 5.4. (devam) Doğruluk grafikleri a) AlexNet b) ZFNet c) VGG16 d) VGG19 e) CNNcc



d)



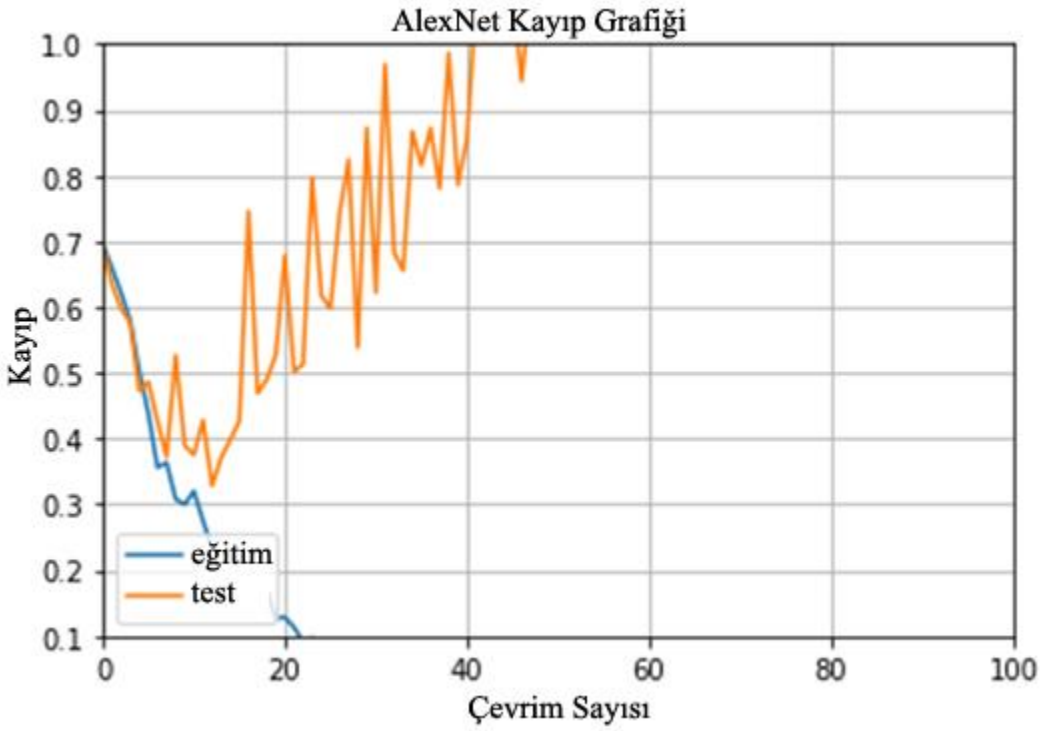
e)

Şekil 5.4. (devam) Doğruluk grafikleri a) AlexNet b) ZFNet c) VGG16 d) VGG19 e) CNNcc

Çizelge 5.3. Doğruluk ve kayıp oranları

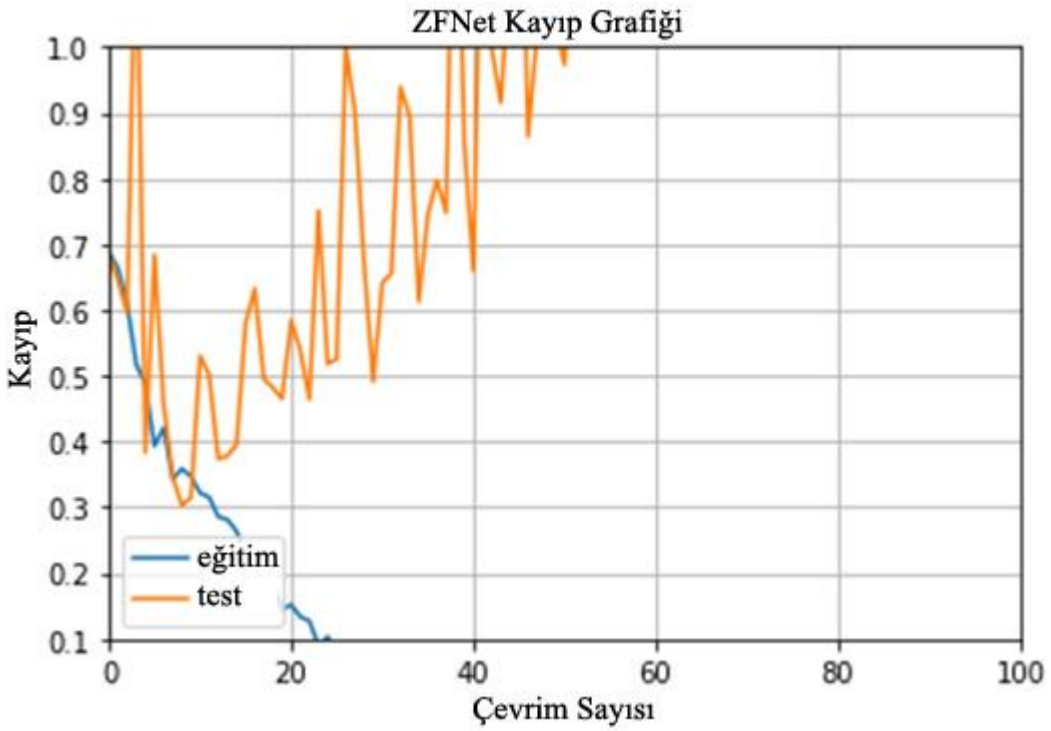
Model	Test Doğruluğu	Kayıp Değeri	Eğitim Doğruluğu
AlexNet	%91	1,32	%100
ZFNet	%89,1	1,33	%100
VGG16	%93	0,65	%100
VGG19	%90	1,46	%94,5
CNNcc	%89,1	0,29	%89,4

KA IMT US görüntüleri üzerinde sınıflandırma işleminde kullanılan modellerin grafikleri ve sonuçları incelendiğinde, AlexNet, ZFNet, VGG16, VGG19 ve CNNcc modellerinin sırasıyla; %91; %89,1; %93; %90 ve %89,1 doğruluk oranlarına ulaştığı görülmektedir. Derin öğrenme algoritmalarının kullanımı sırasında oluşturulan modelin eğitimindeki doğruluk oranlarını değerlendirirken, kayıp oranı da göz önüne alınmaktadır. Buradan yola çıkarak çalışmada karşılaştırılan derin öğrenme modellerinin kayıp değerleri de ölçülmüştür. Elde edilen kayıp grafikleri Şekil 5.5'te gösterilmiştir.

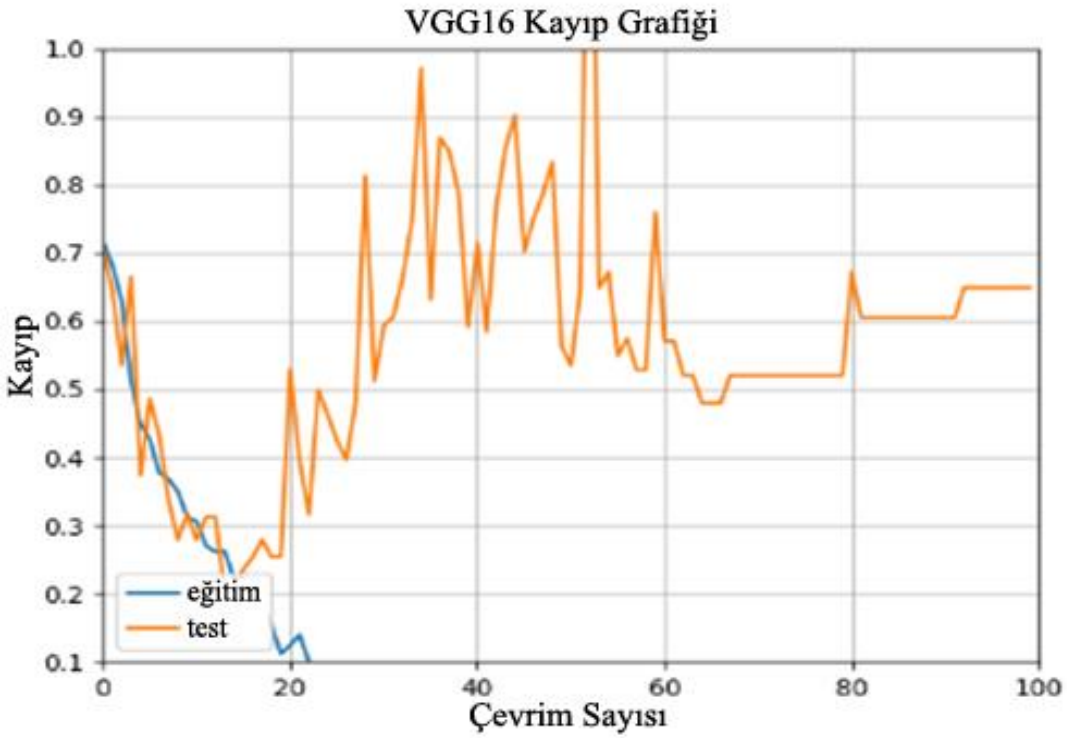


a)

Şekil 5.5. Kayıp grafikleri a) AlexNet b) ZFNet c) VGG16 d) VGG19 e) CNNcc

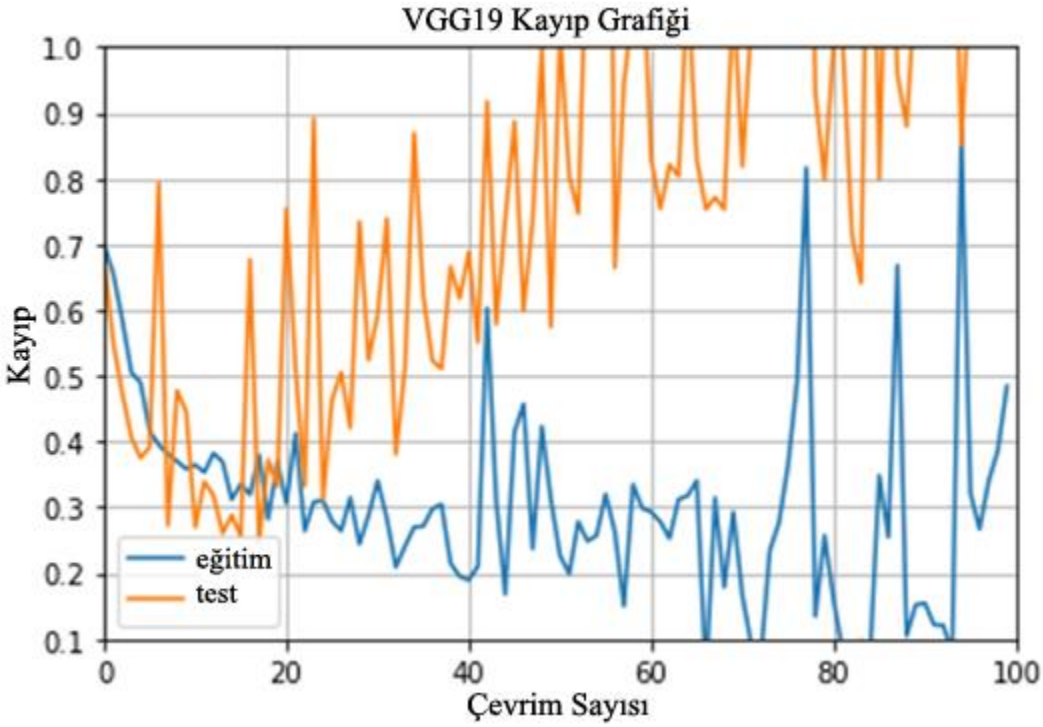


b)

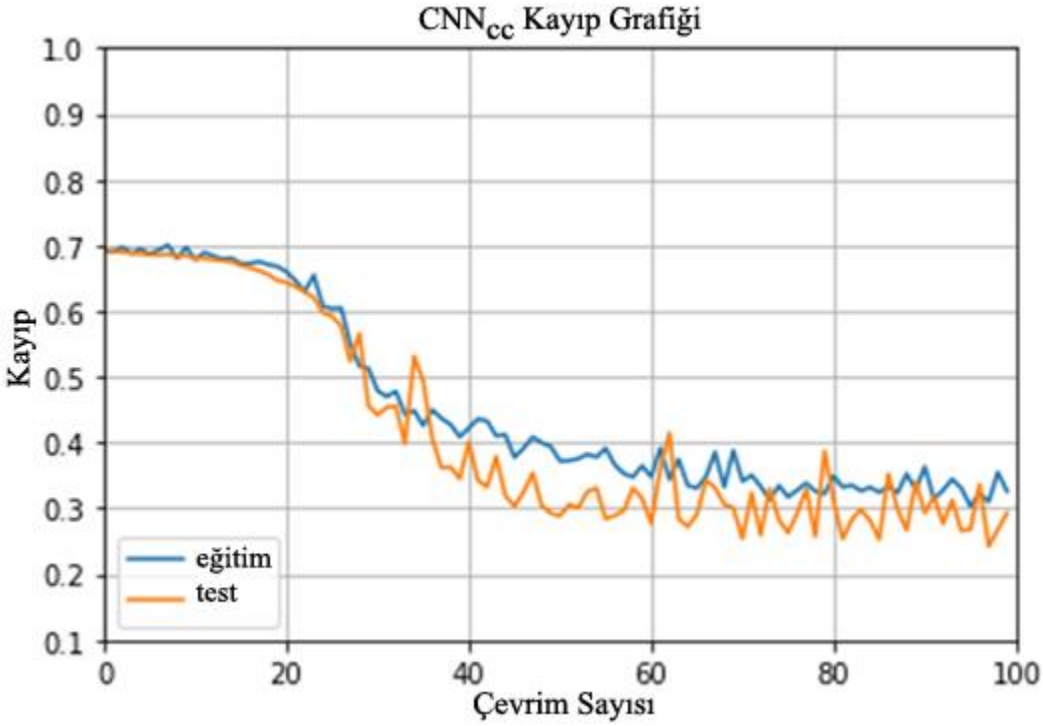


c)

Şekil 5.5. (devam) Kayıp grafikleri a) AlexNet b) ZFNet c) VGG16 d) VGG19 e) CNNcc



d)



e)

Şekil 5.5. (devam) Kayıp grafikleri a) AlexNet b) ZFNet c) VGG16 d) VGG19
e) CNNcc

Modellerin veri tabanındaki etiketli veriler üzerindeki tutarsızlık oranlarına bakıldığında ve grafikler incelendiğinde AlexNet, ZFNet, VGG16, VGG19 ve CNNcc modellerinin kayıp

değerlerinin sırasıyla; 1,33; 1,32; 0,65; 1,46 ve 0,29 olduğu görülmektedir. Modellerin doğruluk oranları ve kayıp parametreleri birlikte değerlendirilirken bu değerlendirilmeye son eklenmesi gereken parametre ise eğitim doğruluğu oranıdır. Modellerin etiketli veriler üzerinde eğitim için ayrılmış görüntülerde elde ettiği doğruluk oranı, model ile ilgili önemli ipuçları vermektedir. Bu oranlara bakıldığında AlexNet, ZFNet ve VGG16 modellerinin %100 doğruluk oranına ulaştığı görülmektedir. Bu oran eğitim sırasında istenilmeyen bir durumdur çünkü model veri kümesindeki görüntüleri aşırı öğrenmiş ve görüntüleri ezberlemiştir. Bu modellerin aşırı öğrenme durumuna düşmesinden dolayı sonuçların güvenirliği azalmıştır. Eğitim sonrasında elde edilen ağırlıkların, faklı biyomedikal görüntülerde kullanıldığında aynı sonuçları üretmeme ihtimali yüksektir. VGG19 ve CNNcc modellerinde ise durum diğerlerinden farklıdır. VGG19 modeli %90 doğruluk oranı ile CNNcc (%89,1) modeline yakın bir sonuç vermiştir. Eğitim sırasında elde edilen doğruluk oranı ise %94,5 ile kabul edilebilir bir oranda olup veriler üzerinde aşırı öğrenme gerçekleşmemiştir. Belirleyici diğer parametre olan kayıp parametresinde ise CNNcc modelinin çok üstünde 1,46 değeri elde edilmiştir. Tüm bu sonuçlar incelendiğinde oluşturulan CNNcc modelinin gerek aşırı öğrenme durumuna düşmemesi (doğruluk:%89,4), gerek doğruluk oranında VGG19 modeline yakın bir sonuç üretmesi ve kayıp parametresinde en düşük sonuç olan 0,29 ile birlikte tutarlılık yakalaması, biyomedikal görüntüler üzerinde en uygulanabilir model olarak öngörülmesini sağlamıştır. AlexNet, ZFNet ve VGG16 gibi ImageNet yarışmasında başarı yakalamış modellerin biyomedikal görüntüler üzerinde kullanılması için şu tespitler yapılmıştır:

- Modellerin katman sayıları düzenlenmelidir.
- Modellere seyreltme katmanları eklenerek kayıp parametresi düzenlenmelidir.
- Seyreltme katmanı eklenerek veriye aşırı uyum engellenmelidir.
- Görüntü sayıları artırılmalıdır.
- Modellerde kullanılan hiper-parametreler üzerinde ayarlamalar yapılmalıdır.

Modellerin görüntüler üzerindeki sonuçlarına daha derinlemesine inceleme gerçekleştirmek için karışıklık matrisi sonuçları da her bir model için ayrı ayrı hesaplanmıştır. AlexNet, ZFNet, VGG16, VGG19 ve CNNcc modelleri için karışıklık matrisi sonuçları sırasıyla Şekil 5.6'da gösterilmiştir.

AlexNet Sayı = 101		Tahmin Edilen		Toplam
		Negatif (IMT:0)	Pozitif (IMT:1)	
Gerçek	Negatif (IMT:0)	TN = 54	FP = 7	61
	Pozitif (IMT:1)	FN = 2	TP = 38	40
Toplam		56	45	

a)

ZFNet Sayı = 101		Tahmin Edilen		Toplam
		Negatif (IMT:0)	Pozitif (IMT:1)	
Gerçek	Negatif (IMT:0	TN = 55	FP = 6	61
	Pozitif (IMT:1	FN = 5	TP = 35	40
Toplam		60	41	

b)

VGG16 Sayı = 101		Tahmin Edilen		Toplam
		Negatif (IMT:0)	Pozitif (IMT:1)	
Gerçek	Negatif (IMT:0	TN = 56	FP = 5	61
	Pozitif (IMT:1	FN = 2	TP = 38	40
Toplam		58	43	

c)

Şekil 5.6. Karışıklık matrisleri a) AlexNet b) ZFNet c) VGG16 d) VGG19 e) CNNcc

VGG19 Sayı = 101		Tahmin Edilen		Toplam
		Negatif (IMT:0)	Pozitif (IMT:1)	
Gerçek	Negatif (IMT:0	TN = 59	FP = 2	61
	Pozitif (IMT:1	FN = 8	TP = 32	40
Toplam		67	34	

d)

CNNcc Sayı = 101		Tahmin Edilen		Toplam
		Negatif (IMT:0)	Pozitif (IMT:1)	
Gerçek	Negatif (IMT:0)	TN = 57	FP = 3	60
	Pozitif (IMT:1)	FN = 8	TP = 33	41
Toplam		65	36	

e)

Şekil 5.6. (devam) Şekil 5.6. Karışıklık matrisleri a) AlexNet b) ZFNet c) VGG16 d) VGG19 e) CNNcc

Modellerin oluşturulan karışıklık matrisleri sonucu ortaya çıkan; Doğruluk, Hata Oranı, Geri Çağırma, Yanlış Pozitif Oran, Özgüllük, Hassasiyet, Yaygınlık ve F1 Puanı değerleri hesaplanmış ve sonuçları Çizelge 5.4'te gösterilmiştir.

Çizelge 5.4. Karışıklık matrisi sonuçları

Değer	AlexNet	ZFNET	VGG16	VGG19	CNNcc
$Doğruluk$	$\frac{92}{101} = 0{,}91$	$\frac{90}{101} = 0{,}891$	$\frac{94}{101} = 0{,}93$	$\frac{91}{101} = 0{,}90$	$\frac{90}{101} = 0{,}891$
$Hata\ Oranı$	$\frac{9}{101} = 0{,}09$	$\frac{11}{101} = 0{,}108$	$\frac{7}{101} = 0{,}07$	$\frac{10}{101} = 0{,}10$	$\frac{11}{101} = 0{,}108$
$Geri\ Çağırma$	$\frac{38}{40} = 0{,}95$	$\frac{35}{40} = 0{,}88$	$\frac{38}{40} = 0{,}95$	$\frac{32}{40} = 0{,}80$	$\frac{33}{41} = 0{,}804$
$Yanlış\ Pozitif\ Oran$	$\frac{7}{61} = 0{,}11$	$\frac{6}{61} = 0{,}09$	$\frac{5}{61} = 0{,}08$	$\frac{2}{61} = 0{,}03$	$\frac{3}{60} = 0{,}05$
$Özgüllük$	$\frac{54}{61} = 0{,}885$	$\frac{55}{61} = 0{,}90$	$\frac{56}{61} = 0{,}918$	$\frac{59}{61} = 0{,}967$	$\frac{57}{60} = 0{,}95$
$Hassasiyet$	$\frac{38}{45} = 0{,}84$	$\frac{35}{41} = 0{,}85$	$\frac{38}{43} = 0{,}88$	$\frac{32}{34} = 0{,}94$	$\frac{33}{36} = 0{,}916$
$Yaygınlık$	$\frac{40}{101} = 0{,}40$	$\frac{40}{101} = 0{,}40$	$\frac{40}{101} = 0{,}40$	$\frac{40}{101} = 0{,}40$	$\frac{41}{101} = 0{,}405$
$F1\ Puanı$	$\frac{76}{85} = 0{,}894$	$\frac{70}{81} = 0{,}864$	$\frac{76}{83} = 0{,}916$	$\frac{64}{74} = 0{,}865$	$\frac{66}{77} = 0{,}857$

Modellerin etiketlenmiş veriler üzerinde her bir sınıf için tahmin performans sonuçları ise Çizelge 5.5'te gösterilmiştir.

Çizelge 5.5. Modellerin performans sonuçları

Özgüllük					
	AlexNet	ZFNet	VGG16	VGG19	CNNcc
IMT:0	0,96	0,92	0,97	0,88	0,88
IMT:1	0,84	0,85	0,88	0,94	0,92
Ortalama/Toplam	0,92	0,89	0,93	0,90	0,89
F1 Puanı					
	AlexNet	ZFNet	VGG16	VGG19	CNNcc
IMT:0	0,92	0,91	0,94	0,92	0,91
IMT:1	0,89	0,86	0,92	0,86	0,86
Ortalama/Toplam	0,91	0,89	0,93	0,90	0,89

Çizelge 5.5. (devam) Modellerin performans sonuçları

Geri Çağırma					
	AlexNet	ZFNet	VGG16	VGG19	CNNcc
IMT:0	0,89	0,90	0,92	0,97	0,95
IMT:1	0,95	0,88	0,95	0,80	0,80
Ortalama/Toplam	0,91	0,89	0,93	0,90	0,89
Örneklem					
	AlexNet	ZFNet	VGG16	VGG19	CNNcc
IMT:0	61	61	61	61	60
IMT:1	40	40	40	40	41
Ortalama/Toplam	101	101	101	101	101

Çizelge 5.5'de verilen performans kriterlerine göre modellerin etiketli veriler üzerindeki tahmin sonuçları Çizelge 5.6'da gösterilmiştir.

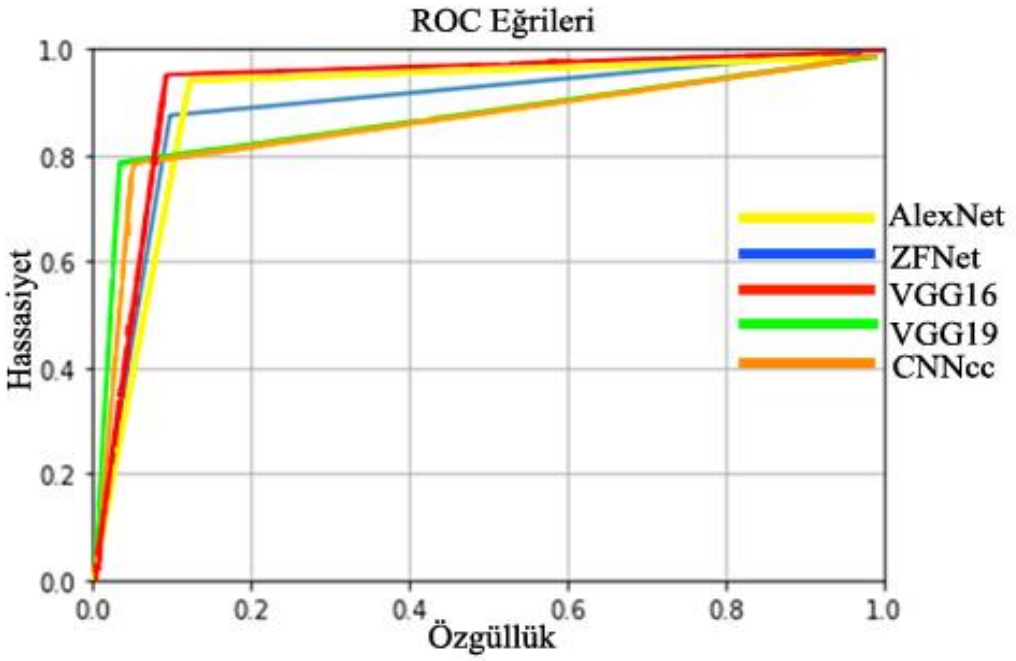
Çizelge 5.6. Modellerin test ve tahmin sonuçları

AlexNet								
Test Değerleri	0	0	1	0	1	0	0	0
Tahmin Değerleri	[1. 0.]	[1. 0.]	[0. 1.]	[0. 1.]	[0. 1.]	[1. 0.]	[1. 0.]	[1. 0.]
Sonuç	√	√	√	X	√	√	√	√
ZFNet								
Test Değerleri	0	0	1	1	1	0	0	0
Tahmin Değerleri	[1. 0.]	[1. 0.]	[0. 1.]	[0. 1.]	[0. 1.]	[1. 0.]	[1. 0.]	[1. 0.]
Sonuç	√	√	√	√	√	√	√	√
VGG16								
Test Değerleri	0	0	1	1	1	0	0	0
Tahmin Değerleri	[1. 0.]	[1. 0.]	[0. 1.]	[0. 1.]	[0. 1.]	[1. 0.]	[1. 0.]	[1. 0.]
Sonuç	√	√	√	√	√	√	√	√

Çizelge 5.6. (devam) Modellerin test ve tahmin sonuçları

VGG19								
Test Değerleri	0	0	1	1	0	0	0	0
Tahmin Değerleri	[1. 0.]	[1. 0.]	[0. 1.]	[0. 1.]	[0. 1.]	[1. 0.]	[1. 0.]	[1. 0.]
Sonuç	√	√	√	√	X	√	√	√
CNNcc								
Test Değerleri	0	1	0	0	1	0	0	0
Tahmin Değerleri	[0. 1.]	[0. 1.]	[1. 0.]	[1. 0.]	[0. 1.]	[1. 0.]	[1. 0.]	[1. 0.]
Sonuç	X	√	√	√	√	√	√	√

Çizelge 5.6 incelendiğinde, test verisi olarak rastgele seçilen sekiz görüntüden ZFNet ve VGG16 modelleri tamamını doğru tahmin etmiş, AlexNet, VGG19 ve CNNcc modelleri birer hata yapmışlardır. ZFNet ve VGG16 modelleri aşırı öğrenme durumunda oldukları için bu tahminleme işleminde güvenirlik bulunmamaktadır. Burada ilginç olan durum, AlexNet modeli de yine aşırı öğrenme durumunda olmasına rağmen tahmin işleminde bir hata yapmıştır. VGG19 ve CNNcc modelleri ise birer hata yapan diğer modeller olmuştur. Modellerin ROC eğrileri Şekil 5.7'de gösterilmiştir.



Şekil 5.7. ROC eğrileri

Tüm bu değerlendirmeler ışığında, VGG19 ve CNNcc modellerinin biyomedikal görüntüler üzerinde uygulama için uygun olduğu sonucu ortaya çıkmıştır. Bu iki model arasından CNNcc, etiketli verileri tahmin üzerindeki tutarsızlık oranı az olduğu ve doğruluk oranında da VGG19 modeline yaklaştığı için, en uygun model olarak öngörülmüştür.

6. SONUÇLAR VE TARTIŞMA

Bu tezde, US görüntülerinde KA IMT'nin sınıflandırılması için yeni bir yöntem önerilmiştir. Önerilen yöntem IMT'yi erken tanı ve SVH tedavisi için sınıflandırılması için önem arz etmektedir. Yöntem stratejisi, yeni bir makine öğrenmesi alanı olan derin öğrenme alanındaki bir modeli temel almaktadır.

Model, Ankara Eğitim ve Araştırma Hastanesi'nde 8 ay boyunca tedavi edilen 153 hastanın 501 görüntüsünden oluşan bir veri tabanında test edilmiştir. Modelde sınıflandırma problemlerinde sıklıkla kullanılan CNN algoritması kullanılmıştır. Modelin doğruluğu, doktorların sınıflandırmasıyla karşılaştırılmıştır. Sonuçlar, oluşturulan derin öğrenme modelinin %89,1'lik bir sınıflandırma performansı elde ettiğini göstermiştir. Önerilen model, IMT sınıflandırması için %89 duyarlılığa ve %88 özgüllüğe sahiptir. Oluşturulan CNN modelinin derin öğrenme yöntemine dayanan performansı, KA IMT'nin sınıflandırılmasında oldukça önemli olmuştur. Özet olarak önerilen yöntemin temel katkıları ve gelişmeleri; daha önceki segmentasyon çalışmalarının devam eden bir çalışması olduğu, sınıflandırma çalışmalarında çok sayıda görüntüde yüksek performans göstermesi, görüntü kalitesi farklılıklarında yüksek performans ve IMT sınıflandırmasında önemli güvenilirlik ve hassasiyet göstermesidir.

Literatürde KA görüntüleri üzerinde Çizelge 6.1'de görüldüğü gibi çeşitli çalışmalar yapılmıştır. Bu çalışmalar iki farklı bölümde incelenebilir:

- KA Intima Media Segmentasyon Çalışmaları
- KA Intima Media Sınıflandırma Çalışmaları

Çizelge 6.1. Karotis arter görüntü işleme çalışmaları

Yazar	Hasta/ Görüntü Sayısı	Metot	Sonuçlar
Segmentasyon Çalışmaları			
Menchón-Lara vd., (2016)	67	Derin Öğrenme - ELM	5,79 ± 34,42 µm (ortalama ± standart sapma)
Rocha vd., (2010)	47	Yeni bir segmentasyon yaklaşımı	Ortalama: 0.07 - 0.11 mm Standart sapma: 0.11 - 0.12 mm aralıklarında
Bastida-Jumilla vd., (2015)	46	Yeni bir segmentasyon algoritması	13,8 ± 31,9 µm (ortalama ± standart sapma)
Kutbay vd., (2016)	25	Quaternion Based Saliency Mapping	Ortalama kare hata: Arter çapı: 0,0014 mm2 Kütle çapı: 0,000191 mm2
Ikeda vd., (2017)	649	Tam otomatik ampül tespit sistemi	Hassasiyet: %92,67
Rossi vd., (2008)	128	Yeni bir AKA tespit algoritması	Başarım: %98,8
Cheng vd., (2010)	78, 111, 86	Yeni bir yöntem	Ortalama hata: Uzak kenar: 0,55 piksel (0,0583 mm) Yakın kenar: 0,63 pixel (0,0668 mm)
Sınıflandırma Çalışmaları			
Christodoulou vd., (2003)	230	Modüler NN	%73,1
Kyriacou vd., (2005)	274	NN – SVM	%71,2
Mongiakakou vd., (2007)	54	Hibrit NN	%99,1
Kyriacou vd., (2009)	274	SVM	%73,7
Acharya vd., (2012)	346	SVM/AdaBoost	SVM: %82,4 AdaBoost: %81,7
Pedro vd., (2013)	146	EAI	%77

Çizelge 6.1'e göre, KA'nın IMT sınıflandırma çalışması derin öğrenme yöntemleriyle yapılmamasına rağmen, derin öğrenme çalışmaları bugüne kadar sadece görüntü segmentasyon düzeyinde yapılmıştır. Sınıflandırma çalışmaları çoğunlukla makine öğrenme yöntemleri ile SVM ve NN ile yapılmış olup bu çalışmalar birbirinden farklı sonuçlar vermiştir. NN ile yapılan sınıflandırma çalışmaları, 200'den fazla görüntü ile çalışılırken %71 ile %73 arasında olup (Christodoulou vd., 2003), (Kyriacou vd., 2005), bu oran 54 görüntü ile yapılan bir çalışmada %99,1 olmuştur (Mongiakakou vd., 2007). Buradan NN ile çalışırken, görüntü sayısı arttıkça doğruluk oranının azaldığı anlaşılmaktadır. Bunun yerine, derin öğrenme yöntemleriyle çalışırken, daha fazla girdi verisi daha iyi doğruluk anlamına gelir, çünkü model özellikleri kendini girdi verilerinden öğrenir. Bu tezde önerilen CNN modeli, daha fazla görüntü verisinden %89,1 daha iyi doğruluk oranı elde etmiştir.

SVM kullanımı bu durumdan biraz farklıdır. Görüntü sayısı 270 ila 350 arasında değişen farklı çalışmalarda SVM ile %73 ile %83 arasında değişen farklı oranlarda performans oranları elde edilmiştir (Kyriacou vd., 2009), (Acharya vd., 2012). SVM yöntemleri, SA'dan daha iyi sonuçlar vermesine rağmen, bu çalışmada önerilen CNN yöntemi, SVM yöntemlerinden daha iyi sonuçlar elde etmiştir. Bu sonuçlar, Çizelge 5.3'te verilen sonuçlarla karşılaştırıldığında önceki çalışmalardan daha iyi bir başarının göstergesidir. Çizelge 6.1'de verilen tüm çalışmalarda hasta sayısı, görüntü sayısı, görüntü kalitesi vb. gibi parametreler farklı olmasına rağmen modelimizin diğer çalışmalardaki yöntemlere göre olumlu olduğu söylenebilir. Çalışmada elde edilen sonuçlar göstermiştir ki, derin mimarilerin biyomedikal alandaki performansları umut vericidir. Çalışmada kullanılan derin öğrenme modellerinin sınıflandırma sonuçları makine öğrenmesi algoritmalarına göre daha belirgin olmuştur. Özellikle biyomedikal alanında farklı görüntüleme tekniklerine uygulanabilecek belirli derin öğrenme modellerinin ortaya konulması açısından bu çalışma önem taşımaktadır. Böylece araştırmacılar ve kliniklerdeki uygulayıcılar her bir problem için ayrı çözümler ve algoritmalar kullanmak yerine, ortak bir model kullanabileceklerdir.

Ayrıca bu tezde önerilen yöntemin SVH'ın önlenmesine yardımcı olacak olumlu yönlerinin çok önemli olduğunu vurgulamak da önemlidir. Çalışma derin öğrenme yöntemlerinin tıbbi araştırmalarda etkili sonuçlar verebileceğini göstermiştir.

7. ÖNERİLER

Yapay Zekâ uygulamaları her geçen gün artmakta, makine öğrenmesi kullanımı gittikçe yaygınlaşmaktadır. Derin öğrenme uygulamaları ise makine öğrenmesinin özellikle son yıllarda en yaygın kullanım şekli olarak karşımıza çıkmaktadır. Derin öğrenme modelleri pek çok sektörde kullanılmakla beraber özellikle görüntü işleme, doğal dil işleme, ses tanıma ve otomasyon alanlarında yaygın olarak kullanılmaya başlanmıştır. Oluşturulan modellerin bu alanlardaki başarımı dikkate değer olsa da, biyomedikal görüntüler üzerinde henüz yeterli sıklıkta kullanılmamıştır.

Bu tezde önerilen yöntem, derin öğrenme modellerinin biyomedikal görüntüler üzerindeki başarımına örnek teşkil etmiştir. Biyomedikal görüntülerin elde edilmesi uzun, özel izinler gerektiren ve pek çok uzmanın koordineli çalışmasına ihtiyaç duyulan bir süreçtir. Derin öğrenme ise fazla miktarda veriye ihtiyaç duymaktadır çünkü derin öğrenmede özellikler verilerden otomatik olarak çıkarılmaktadır. Derin öğrenme modellerini tıp alanında kullanabilmek için ortak görüntü veri tabanlarına ihtiyaç duyulmaktadır. Ortaya çıkarılan modellerin daha geniş veri kümelerine uygulanabilmesi ve yaygınlaştırılabilmesi için başta klinikler olmak üzere araştırma merkezleri ve üniversitelerin böyle veri tabanlarına öncülük etmeleri gerekmektedir.

Görüntü yarışmalarında kullanılan derin öğrenme modelleri (AlexNet, ZFNet, VGG16-19, LeNet, ResNet vb.), milyonlarca görüntü arasında sınıflandırma yapmak için tasarlanmış, günlük hayatta karşılaşılan pek çok nesneyi sınıflandırabilen modellerdir. Tıp alanında da bu gibi modellere ihtiyaç duyulmaktadır. Bu modelleri oluşturabilmek için de veriler üzerinde modelleri eğitebilmek, dolayısıyla da bu verileri araştırmacıların kullanımına sunmak gerekmektedir. Çalışmada kullanılan KA US görüntüleri, normal bir tedavi prosedüründe kayıt altına alınmayan, uzmanlar tarafından ekran önünde inceleme yapılan bir görüntüleme türüdür. Gereksinim halinde kayıt altına alınan bu görüntülere, araştırmacıların ihtiyacı bulunmaktadır. Daha verimli karar destek sistemleri için biyomedikal alanda ortak görüntü veri tabanları oluşturulmalıdır. Bu veri tabanları üzerinde daha çok derin öğrenme modelleri oluşturulup eğitilebilir ve farklı problemlerin çözümlerinden kullanılabilir.

KAYNAKLAR

Acharya, R. U., Faust, O., Alvin, A., Sree, V. S., Molinari, F., Saba, L., and Suri, J. S. (2012). Symptomatic vs. Asymptomatic Plaque Classification in Carotid Ultrasound. *Journal of Medical Systems,* 36, 1861–1871.

Acharya, U. R., Oh, S. L., Hagiwara, Y., Tan, J. H., and Adeli, H. (2018). Deep convolutional neural network for the automated detection and diagnosis of seizure using EEG signals. *Computers in Biology and Medicine,* 100, 270–278.

Agrawal, R., Imieliński, T., and Swami, A. (1993). *Mining association rules between sets of items in large databases,* SIGMOD '93 Proceedings of the 1993 ACM SIGMOD international conference on Management of data. Washington, D.C., USA: ACM New York, NY, USA. doi: 10.1145/170035.170072

Albayrak, A. S., ve Koltan Yılmaz, Ş. (2009). Veri Madenciliği: Karar Ağacı Algoritmaları ve İMKB Verileri Üzerine Bir Uygulama. *Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi,* 14(1), 31-52.

Arakia, T., Ikeda, N., Shukla, D., Londhe, N. D., Shrivastavac, V. K., Banchhor, S. K., and Suri, J. S. (2016). A new method for IVUS-based coronary arterydisease risk stratification: A link between coronary & carotid ultrasound plaque burdens. *Computer Methods and Programs in Biomedicine,* 124, 161–179.

Arı, A., ve Berberler, M. (2017). Yapay Sinir Ağları ile Tahmin ve Sınıflandırma Problemlerinin Çözümü İçin Arayüz Tasarımı. *Acta Infologica,* 1(2), 55-73.

Arı, A., ve Önder, H. (2013). Farklı Veri Yapılarında Kullanılabilecek Regresyon Yöntemleri. *Anadolu Tarım Bilimleri Dergisi,* 28(3), 168-174.

Arya, S., Mount, D. M., Netanyahu, N. S., Silverman, R., and Wu, A. Y. (1998). An optimal algorithm for approximate nearest neighbor searching fixed dimensions. *Journal of the ACM*, 891-923.

Ay Karakuş, B. (2018). *Derin Öğrenme ve Büyük Veri Yaklaşımları ile Metin Analizi.* Doktora Tezi, Fırat Üniversitesi Fen Bilimleri Enstitüsü, Elazığ.

Ballabio, D., Grisoni, F., and Todeschini, R. (2018). Multivariate comparison of classification performance measures. *Chemometrics and Intelligent Laboratory Systems,* 174, 33-44. doi: 10.1016/j.chemolab.2017.12.004

Barnett, H., Taylor, D., Haynes, R., Sacket, D., Peerless, S., Ferguson, G., and Eliasziw, M. (1991). Beneficial effect of carotid endarterectomy in symptomatic patients with high-grade carotid stenosis. *The New England Journal of Medicine,* 325(7), 445-453.

Bastida-Jumilla, M., Menchón-Lara, R., Morales-Sánchez, J., Verdú-Monedero, R., Larrey-Ruiz, J., and Sancho-Gómez, J. (2015). Frequency-domain active contours solution to evaluate intima–media thickness of the common carotid artery. *Biomedical Signal Processing and Control,* 16, 68-79.

Bengio, Y. (2009). Learning Deep Architectures for AI. *Foundations and Trends in Machine Learning,* 2, 1-127. doi: 10.1561/2200000006

Benjamin, M., and Dean, R. (1995). Current Diagnosis & Treatment in Vascular Surgery. R. H. Dean, J. S. Yao, & D. C. Brewster içinde, *Current Diagnosis & Treatment in Vascular Surgery,*1st Edition, 1-5. Appleton & Lange.

Bennett, K. P., and Demiriz, A. (1999). Advances in Neural Information Processing Systems (NIPS). *Semi-supervised Support Vector Machines,* 368-374. MIT Press.

Bousser, M.G. (2012). Stroke prevention: an update. *Frontiers of Medicine,* 6(1), 22-34.

Bovet, P., Shamlaye, C., Gabriel, A., Riesen, W., and Paccaud, F. (2006). Prevalence Of Cardiovascular Risk Factors in a Middle-Income Country And Estimated Cost Of A Treatment Strategy. *BMC Public Health,* 6(9), 1-10.

Burns, P., Gough, S., and Bradbury, A. W. (2003). Management of peripheral arterial disease in primary care. *BMJ,* 326, 584-588.

Calp, M. H. (2018). Medical Diagnosis with a Novel SVM-CoDOA Based Hybrid Approach. *BRAIN – Broad Research in Artificial Intelligence and Neuroscience,* 9(4), 6-16.

Caplan, L. R. (2009). *Basic pathology, anatomy, and pathophysiology of stroke. In: Caplan's Stroke: A Clinical,* 4th edition. Philadelphia: Saunders Elsevier.

CDCP. (2001). *Prevalence of disabilities and associated health conditions.* United States: Centers for Disease Control and Prevention.

Cheng, D.C., Schmidt-Trucksäss, A., Liu, C.H., and Liu, S.-H. (2010). Automated Detection of the Arterial Inner Walls of the Common Carotid Artery Based on Dynamic B-Mode Signals. *Sensors,* 10, 10601-10619.

Christodoulou, C. I., Pattichis, C. S., Pantzaris, M., and Nicolaides, A. (2003). Texture-based classification of atherosclerotic carotid plaques. *IEEE Trans Med Imaging,* 902-912.

Cireşan, D. C., Giusti, A., Gambardella, L. M., and Schmidhuber, J. (2013). Mitosis Detection in Breast Cancer Histology Images with Deep Neural Networks. *Medical Image Computing and Computer-Assisted Intervention – MICCAI 2013,* 411-418.

Cortes, C., and Vapnik, V. (1995). Support-Vector Networks. *Machine Learning,* 20(3), 273-297. doi: 10.1023/A:1022627411411

Çankaya, Ş. F., Çankaya, İ. A., Yiğit, T., ve Koyun, A. (2018). Diabetes Diagnosis System Based on Support Vector Machines Trained by Vortex Optimization Algorithm. *Nature-Inspired Intelligent Techniques for Solving Biomedical Engineering Problems,* 203-218. doi: 10.4018/978-1-5225-4769-3.ch009

Çomak, E., Arslan, A., ve Türkoğlu, İ. (2007). A decision support system based on support vector machines for diagnosis of the heart valve diseases. *Computers in Biology and Medicine,* 37(1), 21-27. doi: 10.1016/j.compbiomed.2005.11.002

Demirci Şahin, A., Üstü, Y., ve Işık, D. (2015). Serebrovasküler Hastalıklarda Önlenebilen Risk Faktörlerinin Yönetimi. *Ankara Medical Journal,* 15(2), 106-113.

Deng, L., and Yu, D. (2013). Deep Learning Methods and Applications. *Foundations and Trends in Signal Processing,* 7, 197-387. doi: 10.1561/2000000039

Dinçer, E. (2006). *Veri Madenciliğinde K-Means Algoritması ve Tıp Alanında Uygulanması.* Yüksek Lisans Tezi, Kocaeli Üniversitesi, Fen Bilimleri Enstitüsü, Kocaeli.

Ding, S., Zhu, Z., and Zhang, X. (2015). An overview on semi-supervised support vector machine. *Neural Computing & Applications*. doi: 10.1007/s00521-015-2113-7

Doğan, F., ve Türkoğlu, İ. (2018). Derin Öğrenme Algoritmalarının Yaprak Sınıflandırma Başarımlarının Karşılaştırılması. *Sakarya Universıty Journal Of Computer And Informatıon Scıences,* 1, 10-21.

Dou, Q., Chen, H., Qin, J., and Heng, P. A. (2017). Multilevel Contextual 3-D CNNs for False Positive Reduction in Pulmonary Nodule Detection. *IEEE Transactions On Biomedical Engineering*, 64(7), 1558-1567.

Elitez, O. (2015). *Handwritten Digit String Segmentation And Recognition Using Deep Learning.* Yüksek Lisans Tezi, Middle East Technical University, Ankara.

Emel, G. G., ve Taşkın, Ç. (2005). Veri Madenciliğinde Karar Ağaçları ve Bir Satış Analizi Uygulaması. *Eskişehir Osmangazi Üniversitesi Sosyal Bilimler Dergisi,* 6(2), 221-239.

Ferri, C., Flach, P. A., and Hernández-Orallo, J. (2003). *Improving the AUC of Probabilistic Estimation Trees.* European Conference on Machine Learning. Berlin, Heidelberg: Springer. doi: 10.1007/978-3-540-39857-8_13

Gulshan, V., Peng, L., Coram, M., Stumpe, M. C., Wu, D., Narayanaswamy, A., and Webster, R. D. (2016). Development and Validation of a Deep Learning Algorithm for Detection of Diabetic Retinopathy in Retinal Fundus Photographs. *JAMA*, 316(22), 2402-2410.

Günel, K., İşman, G., ve Kocakula, M. (2018). Simple recurrent neural networks for the numerical solutions of ODEs with Dirichlet boundary conditions. *BAUN Fen Bil. Enst. Dergisi*, 143-153. doi: 10.25092/baunfbed.483922

Hacıbeyoğlu, M. (2006). *Çoklu Etmen Mimarisi ve Takviyeli Öğrenme.* Bilgisayar Mühendisliği Anabilim Dalı, Yüksek Lisans Tezi, Selçuk Üniversitesi Fen Bilimleri Enstitüsü, Konya.

He, K., Zhang, X., Ren, S., and Sun, J. (2016). 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). *Deep Residual Learning for Image Recognition*, 1-12. Las Vegas, NV, USA: IEEE. doi: 10.1109/CVPR.2016.90

Henry, J., Barnett, M., Taylor, D., Eliasziwq, M., Fox, A., Gary, G., and Meldrum, H. (1998). Benefit of Carotid Endarterectomy in Patients with Symptomatic Moderate or Severe Stenosis. *The New England Journal of Medicine*, 339(20), 1415-1425.

Hinton, G. E. (2009). *Deep belief networks*. doi:10.4249/scholarpedia.5947

Hinton, G. E., Osindero, S., and Teh, Y.-W. (2006). A fast learning algorithm for deep belief nets. *Neural Comput*, 1527–1554.

Hoshino, Y., and Kamei, K. (2003). SICE 2003 Annual Conference. *A proposal of reinforcement learning system to use knowledge effectively*, 1582-1585. IEEE Xplore.

Hu, P., Wu, F., Peng, J., Bao, Y., Chen, F., and Kong, D. (2017). Automatic abdominal multi-organ segmentation using deep convolutional neural network and time-implicit level sets. *International Journal of Computer Assisted Radiology and Surgery*, 399–411.

Ikeda, N., Dey, N., Sharma, A., Gupta, A., Bose, S., Acharjee, S., and Suri, J. S. (2017). Automated segmental-IMT measurement in thin/thick plaque with bulb presence in carotid ultrasound from multiple scanners: Stroke risk assessment. *Computer Methods and Programs in Biomedicine,* 141, 73-81.

İnternet: Amidi, A., and Amidi, S. *Tekrarlayan Yapay Sinir Ağları el kitabı*. Web: https://stanford.edu/~shervine/l/tr/teaching/cs-230/cheatsheet-recurrent-neural-networks adresinden 30 Nisan 2019'da alınmıştır.

İnternet: ASF. (2019). *MXNet: A Scalable Deep Learning Framework*. Web: https://mxnet.apache.org/ adresinden 30 Nisan 2019'da alınmıştır.

İnternt: Berkeley AI Research. (2014). *Caffe*. Caffe | Deep Learning Framework, Web: https://caffe.berkeleyvision.org/ adresinden 30 Nisan 2019'da alınmıştır.

İnternet: BÜ. (2019). *Karar Ağacı (Decision Karar Ağacı (Decision tree) nedir?* Başkent Üniversitesi, Web: http://mail.baskent.edu.tr/~20410964/DM_8.pdf adresinden 17 Şubat 2019'da alınmıştır.

İnternet: Civelek, A. (2014). *Karotis Arter Hastalığı*. Web: http://www.alicivelek.com/karotis-arter-hastaligi/ adresinden 24 Nisan 2018 tarihinde alınmıştır.

İnternet: Collier, M., Fu, R., Yin, L., and Christiansen, P. (2017). *Artıfıcıal Intellıgence: Healthcare's New Nervous System.* Web: https://www.accenture.com/t20171215T032059Z__w__/us-en/_acnmedia/PDF-49/Accenture-Health-Artificial-Intelligence.pdf adresinden 3 Mayıs 2019'da alınmıştır.

İnternet: Çarkacı, N. (2018). *Derin Öğrenme Uygulamalarında En Sık kullanılan Hiper-parametreler*. Web: https://medium.com/deep-learning-turkiye/derin-ogrenme-uygulamalarinda-en-sik-kullanilan-hiper-parametreler-ece8e9125c4 adresinden 11 Haziran 2019'da alınmıştır.

İnternet: Data Science. (2019). Web: https://towardsdatascience.com/types-of-machine-learning-algorithms-youshould- adresinden 14 Mart 2019'da alınmıştır.

İnternet: Eden, T., Knittel, A., and Uffelen, R. v. (2019). *Reinforcement Learning*. Web: http://www.cse.unsw.edu.au/~cs9417ml/RL1/tdlearning.html adresinden 25 Nisan 2019'da alınmıştır.

İnternet: Facebook. (2019). *Caffe2*. Facebook Research, Web: https://research.fb.com/downloads/caffe2/ adresinden 4 Mayıs 2019'da alınmıştır.

İnternet: Fumo, D. (2017). *Types of Machine Learning Algorithms You Should Know*. Web: https://towardsdatascience.com/types-of-machine-learning-algorithms-you-should-know-953a08248861 adresinden 15 Haziran 2019'da alınmıştır.

İnternet: Goodfellow, I., Bengio, Y., and Courville, A. (2016). *Deep Learning.* MIT Press. http://www.deeplearningbook.org adresinden 4 Şubat 2019'da alınmıştır.

İnternet: Google. (2019). *TensorFlow*. Web: https://www.tensorflow.org/ adresinden 1 Haziran 2019'da alınmıştır.

İnternet: Hao, Z. (2017). *Loss Functions in Neural Networks*. Isaac Changhau, Web: https://isaacchanghau.github.io/post/loss_functions/ adresinden 18 Şubat 2019'da alınmıştır.

İnternet: HSFC. (2018). What is stroke? https://www.heartandstroke.ca/stroke/what-is-stroke/ adresinden 1 Aralık 2018 tarihinde alınmıştır.

İnternet: Kayaoğlu, T., Bilgiç, T., Özkaynak, S., Çalışır, S., ve Güçkiran, K. (2018). *Pekiştirmeli Öğrenmeye Giriş Serisi-1*. Web: https://medium.com/deep-learning-turkiye/peki%CC%87%C5%9Fti%CC%87rmeli%CC%87-%C3%B6%C4%9Frenmeye-gi%CC%87ri%CC%87%C5%9F-seri%CC%87si%CC%87-1-8f5c35b6044 adresinden 5 Ocak 2019'da alınmıştır.

İnternet: Kızılkaya, A. (2008). *Image Segmentation.* Pamukkale University, Web: http://akizilkaya.pamukkale.edu.tr/B%C3%B6l%C3%BCm4_goruntu_isleme.pdf adresinden 1 Temmuz 2019'da alınmıştır.

İnternet: Kocamaz, Ö. (2016). *Şah Damar Tıkanıklığı "Karotis Arter Hastalığı"*. Kalp ve Damar Cerrahisi Uzmanı Dr. Kocamaz, Web: http://www.drkocamaz.com/karotis-arter-hastaligi adresinden 5 Ocak 2018'de alınmıştır.

İnternet: LISA lab. (2017). *theano 1.0*. Web: http://deeplearning.net/software/theano/ adresinden 26 Temmuz 2018'de alınmıştır.

İnternet: Microsoft. (2019). *The Microsoft Cognitive Toolkit*. Web: https://docs.microsoft.com/en-us/cognitive-toolkit/ adresinden 10 Mayıs 2019'da alınmıştır.

İnternet: Marr, B. (2017). *How AI And Deep Learning Are Now Used To Diagnose Cancer*. Web: https://www.forbes.com/sites/bernardmarr/2017/05/16/how-ai-and-deep-learning-is-now-used-to-diagnose-cancer adresinden 10 Ekim 2018 tarihinde alınmıştır.

İnternet: neu. (2018). *Serebrovasküler hastalıklar.* Web: https://neu.edu.tr/wp-content/uploads/2015/11/SVO-ba%C5%9Fa%C4%9Fr%C4%B1s%C4%B1-hareket-hastal%C4%B1klar%C4%B1-MS.pdf adresinden 21 Mart 2019 tarihinde alınmıştır.

İnternet: Nvidia. (2019). *Caffe2 Deep Learning Framework*. Web: https://developer.nvidia.com/caffe2 adresinden 20 Nisan 2019'da alınmıştır.

İnternet: Nvidia. (2019). *https://developer.nvidia.com/digits*. Web: https://developer.nvidia.com/digits adresinden 20 Nisan 2019'da alınmıştır.

İnternet: Okumuş, R. (2019). *Convolutional Neural Networks (Evrişimsel Sinir Ağları)*. Web: https://medium.com/@rabiaokumus96/convolutional-neural-networks-evri%C5%9Fimsel-sinir-a%C4%9Flar%C4%B1-cceb887a2979 adresinden 4 Ekim 2019'da alınmıştır.

İnternet: ONEIROS. (2019). *Keras Documentation*. Web: https://keras.io/ adresinden 10 Mart 2019'da alınmıştır.

İnternet: Parrish, K. (2018). *Deep learning vs. machine learning: What's the difference between the two?* Web: https://www.digitaltrends.com/cool-tech/deep-learning-vs-machine-learning-explained/ adresinden 8 Ağustos 2018'de alınmıştır.

İnternet: Pedia, B. (2006). *Hemorajik inme*. Web: http://www.boyutpedia.com/1362/61757/hemorajik-inme adresinden 4 Ekim 2018'de alınmıştır.

İnternet: PyTorch. (2019). *PyTorch*. Web: https://pytorch.org/ adresinden 30 Nisan 2019'da alınmıştır.

İnternet: Ramey, W. (2018). *Deep Learning Demystified*. Web: http://images.nvidia.com/content/technologies/deep-learning/images/nvidia-ai-big-bang.png adresinden 5 Eylül 2018'de alınmıştır.

İnternet: Saharkhiz, A. (2009). *Naive Bayes Theorem*. Web: https://www.codeproject.com/Articles/33722/Naive-Bayes-Theorem adresinden 1 Temmuz 2019'da alınmıştır.

İnternet: Samsung. (2015). *VELES*. Web: https://velesnet.ml/ adresinden 30 Nisan 2019'da alınmıştır.

İnternet: Saraf, M. K., and Mike, P. (2018). *Artificial Intelligence and Healthcare Data*. Web: https://software.intel.com/en-us/articles/artificial-intelligence-and-healthcare-data adresinden 10 Ağustos 2018'de alınmıştır.

İnternet: Simonyan, K., and Zisserman, A. (2014). *Very Deep Convolutional Networks for Large-Scale Image Recognition.* Web: https://arxiv.org/abs/1409.1556 adresinden 19 Şubat 2019'da alınmıştır.

İnternet: Singh, N. (2018). *How to Get Started as a Developer in AI*. Web: https://software.intel.com/en-us/articles/how-to-get-started-as-a-developer-in-ai adresinden 15 Ocak 2019'da alınmıştır.

İnternet: SPSS. (1999). *AnswerTree Algorithm Summary.* Web: https://s2.smu.edu/~mhd/8331f03/AT.pdf adresinden 10 Mart 2019'da alınmıştır.

İnternet: Sullivan, F. (2016). *From $600 M to $6 Billion, Artificial Intelligence Systems Poised for Dramatic Market Expansion in Healthcare*. Web: https://ww2.frost.com/news/press-releases/600-m-6-billion-artificial-intelligence-systems-poised-dramatic-market-expansion-healthcare adresinden 15 Nisan 2019'da alınmıştır.

İnternet: Tek, E. (2016). *Hemorajik İnme | Resusitasyon*. Web: https://www.resusitasyon.com/hemorajik-inme/ adresinden 4 Ekim 2018'de alınmıştır.

İnternet: TNDer. (2019). *Nörovasküler Cerrahi Öğretim ve Eğitim Grubu Karotis Arter Hastalığı Hasta Bilgilendirme Formu.* Web: http://www.turknorosirurji.org.tr/TNDData/Books/152/norovaskuler-cerrahi-ogretim-ve-egitim-grubu.pdf adresinden 5 Şubat 2018'de alınmıştır.

İnternet: Uçar, A. B. (2011). *İnme (Stroke) Nedir? Risk Faktörleri Nelerdir? Tedavisi Nasıldır?* Web: http://www.tibbiyardim.com/inme-stroke-nedir-risk-faktorleri-nelerdir-tedavisi-nasildir.html adresinden 4 Ocak 2018'de alınmıştır.

İnternet: Varol, S. (2018). *Serebrovasküler Hastalıklar.* Web: https://www.dicle.edu.tr/Contents/4e068ce2-625f-4aa9-8fae-34443073dd75.pdf adresinden 21 Mart 2018'de alınmıştır.

İnternet: Wang, D., Khosla, A., Gargeya, R., Irshad, H., and Beck, A. H. (2018). *Deep Learning for Identifying Metastatic Breast Cancer.* Web: https://arxiv.org/pdf/1606.05718.pdf adresinden 12 Mayıs 2019'da alınmıştır.

İnternet: Weisstein, E. W. (2019). *Convolution*. Web: http://mathworld.wolfram.com/Convolution.html adresinden 27 Ağustos 2018'de alınmıştır.

İnternet: Xia, F. (2006). *Semi-supervised learning and self-training.* Web: http://faculty.washington.edu/fxia/courses/LING572/self-training.ppt adresinden 30 Nisan 2019'da alınmıştır.

İnternet: Xu, C., Tao, D., and Xu, C. (2013). A Survey on Multi-view Learning. 1-59. arXiv:1304.5634 adresinden 30 Nisan 2019'da alınmıştır.

İnternet: Yavuz, Y. (2018). İnme-Acil Yaklaşım. Web: http://www.atuder.org.tr/FileOut.aspx?url=HwDAqdjJaEBlvny2AiWd adresinden 9 Nisan 2018'de alınmıştır.

İnternet: Yüret, D. (2016). *Knet: beginning deep learning with 100 lines of Julia*. Machine Learning Systems Workshop at NIPS 2016: http://denizyuret.github.io/Knet.jl/ adresinden 25 Mayıs 2019'da alınmıştır.

Kaelbling, L. P., Littman, M. L., and Moore, A. P. (1996). Reinforcement learning: A Survey. *Journal of Artificial Intelligence Research*, 237-285.

Kaya, M. (2003). *Çoklu Etmen Takviyeli Öğrenmeye Veri Madenciliği Tabanlı Yeni Yaklaşımlar,* Doktora Tezi, Fırat Üniversitesi Fen Bilimleri Enstitüsü. Elazığ.

Kılıç, S. (2013). Klinik Karar Vermede ROC Analizi. *Journal of Mood Disorders,* 3(3), 135-140. doi: 10.5455/jmood.20130830051624

Kırmızıgül Çalışkan, S., ve Soğukpınar, İ. (2008). KxKNN: K-Means ve K En Yakın Komşu Yöntemleri İle Ağlarda Nüfuz Tespiti. *EMO Yayınları,* 120-124.

Koçak, A. (2009). Karotis Arter ve Periferik Arter Lezyonlarının Değerlendirilmesinde Renkli Doppler Ultrasonongrafi, Manyetik Rezonans Anjiyografi,Çok Kesitli Bilgisayarlı Tomografi Anjiyografi ve Dijital Substraksiyon Anjiyografi Bulgularının Karşılaştırılması, T.C. Sağlık Bakanlığı Dr. Siyami Ersek Göğüs Kalp ve Damar Cerrahisi Eğitim ve Araştırma Hastanesi, İstanbul, Türkiye.

Kraus, O. Z., Ba, J. L., and Brendan, J. (2016). Classifying and segmenting microscopy images with deep multiple instance learning. *Bioinformatics*, 52-59.

Krizhevsky, A., Sutskever, I., and Hinton, G. E. (2012). 25th International Conference on Neural Information Processing Systems. *ImageNet Classification with Deep Convolutional,* 1097-1105. Lake Tahoe, Nevada: NIPS'12 Proceedings.

Kutbay, U., Hardalaç, F., Akbulut, M., ve Akaslan, Ü. (2016). A Computer Aided Diagnosis System for Measuring Carotid Artery Intima-Media Thickness (IMT) Using Quaternion Vectors. *Journal of Medical Systems,* 40(149).

Kutner, M. H., Nachtsheim, C. J., Neter, J., and Li, W. (2005). *Applied Linear Statistical Models.* New York: McGraw-Hill Irwin Companies Inc.

Kyriacou, E. C., Pattichis, M. S., Christodoulou, C. I., Pattichis, C. S., Kakkos, S. K., Griffin, M., and Nicolaides, A. (2005). Ultrasound imaging in the analysis of carotid plaque morphology for the assessment of stroke. *Studies in health technology and informatics,* 241-275.

Kyriacou, E. C., Pattichis, M. S., Pattichis, C. S., Mavrommatis, A., Christodoulou, C. I., Kakkos, S. K., & Nicolaides, A. (2009). Classification of atherosclerotic carotid plaques using morphological analysis on ultrasound images. *Applied Intelligence,* 3-23.

Lackland, D. T., Elkind, M. S., D'Agostino, R., Dhamoon, M. S., Goff, D. C., Higashida, R. T., and Wechsler, L. R. (2012). *Inclusion of Stroke in Cardiovascular Risk Prediction Instruments.* A Statement for Healthcare Professionals From the American Heart Association/American Stroke Association.

Lloyd-Jones, D., Adams, R., Carnethon, M., Simone, G. D., Ferguson, B., Flegal, K., and Hong, Y. (2009). Heart Disease and Stroke Statistics-2009 Update. *Circulation,* 119, e21-e181.

Loizou, C. P., Kasparis, T., Lazarou, T., Pattichis, C. S., and Pantziaris, M. (2014). Manual and automated intima-media thickness and diameter measurements of the common carotid artery in patients with renal failure disease. *Computers in Biology and Medicine,* 53, 220-229.

MacQueen, J. B. (1967). Proceedings of the Fifth Symposium on Math, Statistics, and Probability. *Some methods for classification and analysis of multivariate observations,* 281–297. Berkeley: CA: University of California Press.

MALIK, Z. M., AL-SHEHABI, S., and Dökeroğlu, T. (2018). Gözetimsiz Makine Öğrenme Teknikleri ile Miktara Dayalı Negatif Birliktelik Kural Madenciliği. *Düzce Üniversitesi Bilim ve Teknoloji Dergisi,* 6, 1119-1138.

Melillo, P., Orrico, A., Scala, P., Crispino, F., and Pecchia, L. (2015). Cloud-Based Smart Health Monitoring System for Automatic Cardiovascular and Fall Risk Assessment in Hypertensive Patients. *Journal of Medical Systems,* 39(109).

Menchón-Lara, R.M., and Sancho-Gómez, J.L. (2015). Fully automatic segmentation of ultrasound common carotid artery images based on machine learning. *Neurocomputing*, 161–167.

Menchón-Lara, R.M., Sancho-Gómez, J.L., and Bueno-Crespo, A. (2016). Early-stage atherosclerosis detection using deep learning over carotidultrasound images. *Applied Soft Computing*, 616-628.

Meschia, J. F., Bushnell, C., Boden-Albala, B., Braun, L. T., Bravata, D. M., Chaturvedi, S., and Wilson, J. A. (2014). Guidelines for the Primary Prevention of Stroke. *Stroke*.

Milletari, F., Ahmadi, S.A., Kroll, C., Plate, A., Rozanski, V., Maiostre, J., and Navab, N. (2017). Hough-CNN: Deep learning for segmentation of deep brain regions in MRI and ultrasound. *Computer Vision and Image Understanding*, 1–11.

Molinari, F., Zeng, G., and Suri, J. S. (2011). Inter-Greedy Technique for Fusion of Different Segmentation Strategies Leading to High-Performance Carotid IMT Measurement in Ultrasound Images. *Journal of Medical Systems*, 35, 905-919.

Montgomery, D. C., Elizabeth, A., Peck, G., and Vining, G. (2012). *Introduction to Linear Regression Analysis.* New Jersey, USA.: John Wiley & Sons Inc.

Mougiakakou, S., Golemati, S., Gousias, I., Nicolaides, A., and Nikita, K. (2007). Computer-aided diagnosis of carotid atherosclerosis based on ultrasound image statistics, laws' texture and neural networks. *Ultrasound in Medicine & Biology*, 26-36.

Okur, S. (2009). *Parametrik Ve Parametrik Olmayan Doğrusal Regresyon Analiz Yöntemlerinin Karşılaştırmalı Olarak İncelenmesi,* Yüksek Lisans Tezi, Çukurova Üniversitesi Fen Bilimleri Enstitüsü, Adana.

Özcan, H. (2014). *Çok Düşük Çözünürlüklü Yüz İmgelerinde Derin Öğrenme Uygulamaları.* İstanbul: T.C. Deniz Harp Okulu Deniz Bilimleri ve Mühendisliği Enstitüsü.

Özkan, Y. (2008). *Veri Madenciliği Yöntemleri.* İstanbul: Papatya Yayınları.

Öztemel, E. (2003). *Yapay Sinir Ağları.* İstanbul: Papatya Yayınları.

Öztürk, A., Arslan, A., ve Hardalaç, F. (2008). Comparison of neuro-fuzzy systems for classification of transcranial Doppler signals with their chaotic invariant measures. *Expert Systems with Applications*, 1044–1055.

Öztürk, Ş. (2009). Serebrovasküler Hastalık Epidemiyolojisi ve Risk Faktörleri Dünya ve Türkiye Perspektifi. *Turkish Journal of Geriatrics*, 13(1), 51-58.

Patil, T. R., and Sherekar, S. S. (2013). Performance Analysis of Naive Bayes and J48 Classification Algorithm for Data Classification. *International Journal Of Computer Science And Applications*, 256-261.

Pedro, L. M., Sanches, J. M., Seabra, J., Suri, J. S., & Fernandes, J. F. (2013). Asymptomatic Carotid Disease—A New Tool for Assessing Neurological Risk. *Echocardiography*, 353-361.

Pehlivan, G. (2006). *Chaid analizi ve bir uygulama*, Yüksek Lisans Tezi, Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü, İstanbul.

Phatouros, C. C., Higashida, R. T., Malek, A. M., Meyers, P. M., Lempert, T. E., Dowd, C. F., and Halbach, V. V. (2000). Carotid Artery Stent Placement for Atherosclerotic Disease: Rationale, Technique, and Current Status. *Radiology*, 26-41.

Phil, K. (2017). *MATLAB Deep Learning: With Machine Learning, Neural Networks and Artificial Intelligence.* Seoul, Soul-t'ukpyolsi, Korea: Apress.

Provost, F., and Domingos, P. (2003). Tree Induction for Probability-Based Ranking. *Machine Learning*, 52(3), 199–215. doi: 10.1023/A:1024099825458

Rocha, R., Campilho, A., Silva, J., Azevedo, E., and Santos, R. (2010). Segmentation of the carotid intima-media region in B-mode ultrasound images. *Image and Vision Computing*, 28, 614-625.

Ronneberger, O., Fischer, P., and Brox, T. (2015). *U-Net: Convolutional Networks for Biomedical Image Segmentation.* arXiv: https://arxiv.org/pdf/1505.04597.pdf adresinden 3 Nisan 2018'de alınmıştır.

Rosset, S. (2004). ICML '04 Proceedings of the twenty-first international conference on Machine learning. *Model selection via the AUC*, 89. Banff, Alberta, Canada: ACM New York, NY, USA. doi: 10.1145/1015330.1015400

Rossi, A. C., Brands, P. J., and Hoeks, A. P. (2008). Automatic recognition of the common carotid artery in longitudinal ultrasound B-mode scans. *Medical Image Analysis*, 12, 653-665.

S-Ansert, H. (2004). *Diagnostic Ultrasonography.* (O. Akhan, Çev.)

Santhanam, T., and Padmavathi, M. S. (2015). Application of K-Means and Genetic Algorithms for Dimension Reduction by Integrating SVM for Diabetes Diagnosis. *Procedia Computer Science*, 47, 76-83. doi: 10.1016/j.procs.2015.03.185

Santos, A. M., Santos, R. M., Castro, P. M., Azevedo, E., Sousa, L., and Tavares, J. M. (2013). A novel automatic algorithm for the segmentation of the lümen of the carotid artery in ultrasound B-mode images. *Expert Systems with Applications*, 40, 6570-6579.

Satar, B. (2018). *Deep Learning Based Vehicle Make And Model Classification,* Yüksek Lisans Tezi, Uludağ Üniversitesi Fen Bilimleri Enstitüsü, Bursa.

Sawant, S. S., and Prabukumar, M. (2018). A review on graph-based semi-supervised learning methods for hyperspectral image classification. *The Egyptian Journal of Remote Sensing and Space Science*. doi: 10.1016/j.ejrs.2018.11.001

Seçil, M. (2013). Karotis ve Vertebral Doppler. M. Seçil içinde, *Temel Ultrasonografi ve Doppler,* 479-498. Akademisyen Kitabevi.

Sheikhpour, R., Sarram, M. A., Gharaghani, S., and ZareChahooki, M. A. (2017). A Survey on semi-supervised feature selection methods. *Pattern Recognition,* 141-158. doi: 10.1016/j.patcog.2016.11.003

Song, H. A., and Lee, S.Y. (2013). International Conference on Neural Information Processing. *Hierarchical Representation Using NMF,* 466–473. Daegu, South Korea.

Song, Q., Hu, W., and Xie, W. (2002). Robust Support Vector Machine with Bullet Hole Image Classification. *IEEE Transactions on Systems, Man, And Cybernetics—Part C: Applications And Reviews,* 32(4), 440-448.

Strong, K., Mathers, C., and Bonita, R. (2007). Preventing stroke: saving lives around the world. *Lancet Neurol,* 6, 182-187.

Sutton, R. S., and Barto, A. G. (1998). *Reinforcement Learning: An Introduction.* Cambridge: MIT Press.

Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., and Rabinovich, A. (2015). 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). *Going deeper with convolutions,* 1-9. Boston, MA, USA: IEEE. doi: 10.1109/CVPR.2015.7298594

Szepesvari, C. (2010). *Algorithms for Reinforcement Learning.* Morgan & Claypool. doi: 10.2200/S00268ED1V01Y201005AIM009

Tahmasebpour, H. R., Buckley, A. R., Cooperberg, P. L., and Fix, C. H. (2005). Sonographic Examination of the Carotid Arteries. *RadioGraphics,* 25, 1561-1575.

Taşcı, E., ve Onan, A. (2016). *K-En Yakın Komşu Algoritması Parametrelerinin Sınıflandırma Performansı Üzerine Etkisinin İncelenmesi,* 102. Aydın: XVIII. Akademik Bilişim Konferansı - AB 2016.

Tiken, C. (2015). *Derin Öğrenme Uygulamaları,* Yüksek Lisans Tezi, İstanbul Üniversitesi Fen Bilimleri Enstitüsü, İstanbul.

Topçuoğlu, M. A. (2017). *Akut İnme: Tanı ve tedavi.* Ankara: Türk Dahili ve Cerrahi Bilimler Yoğun Bakım Derneği.

Turgut, C. (2005). *İskemik İnmede Risk Faktörleri Ve Toast Sınıflaması.* Taksim Eğitim ve Araştırma Hastanesi, Nöroloji Kliniği. İstanbul: T.C. Sağlık Bakanlığı.

Uzgören, N., Kara, H., ve Uzgören, E. (2005). Yöneticilerde Boyun Eğici Davranış Eğilimlerinin CHAID Analizi ile İncelenmesi: Yönetici Adayı Öğrenciler Üzerine Bir Araştırma. *EKEV Akademi Dergisi,* 19(61), 429-440.

Ünüvar, N., Mollahaliloğlu, S., Yardım, N., Bora Başara, B., Dirimeşe, V., Özkan, E., ve Varol, Ö. (2004). *Türkiye Hastalık Yükü Çalışması.* T.C. Sağlık Bakanlığı. Refik Saydam Hıfzıssıhha Merkezi Başkanlığı Hıfzıssıhha Mektebi Müdürlüğü.

Wagstaf, K., Cardie, C., Rogers, S., and Schroedl, S. (2001). Proceedings of the Eighteenth International Conference on Machine Learning. *Constrained K-means Clustering with Background Knowledge,* 577–584. San Francisco, CA, USA: Morgan Kaufmann Publishers Inc.

Weisberg, S. (2005). *Applied Linear Regression.* New Jersey: John Wiley & Sons Inc.

Wolf, P. A., D'Agostino, R. B., O'Neal, M. A., Sytkowski, P., Kase, C. S., Belanger, A. J., and Kannel, W. B. (1992). Secular trends in stroke incidence and mortality. The Framingham Study. *Stroke*, 23(11), 1551-1556.

Yakut, E., Elmas, B., ve Yavuz, S. (2014). Yapay Sinir Ağları ve Destek Vektör Makineleri Yöntemleriyle Borsa Endeksi Tahmini. *Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi,* 19(1), 139-157.

Yurdakul, S., ve Aytekin, S. (2011). Karotis ve vertebral arterlerin Doppler ultrasonografi ile görüntülenmesi. *Türk Kardiyoloji Derneği Arşivi*, 508-517.

Zeiler, M. D., and Fergus, R. (2014). Visualizing and Understanding Convolutional Networks. *Computer Vision – ECCV 2014*, 818-833. doi: 10.1007/978-3-319-10590-1_53

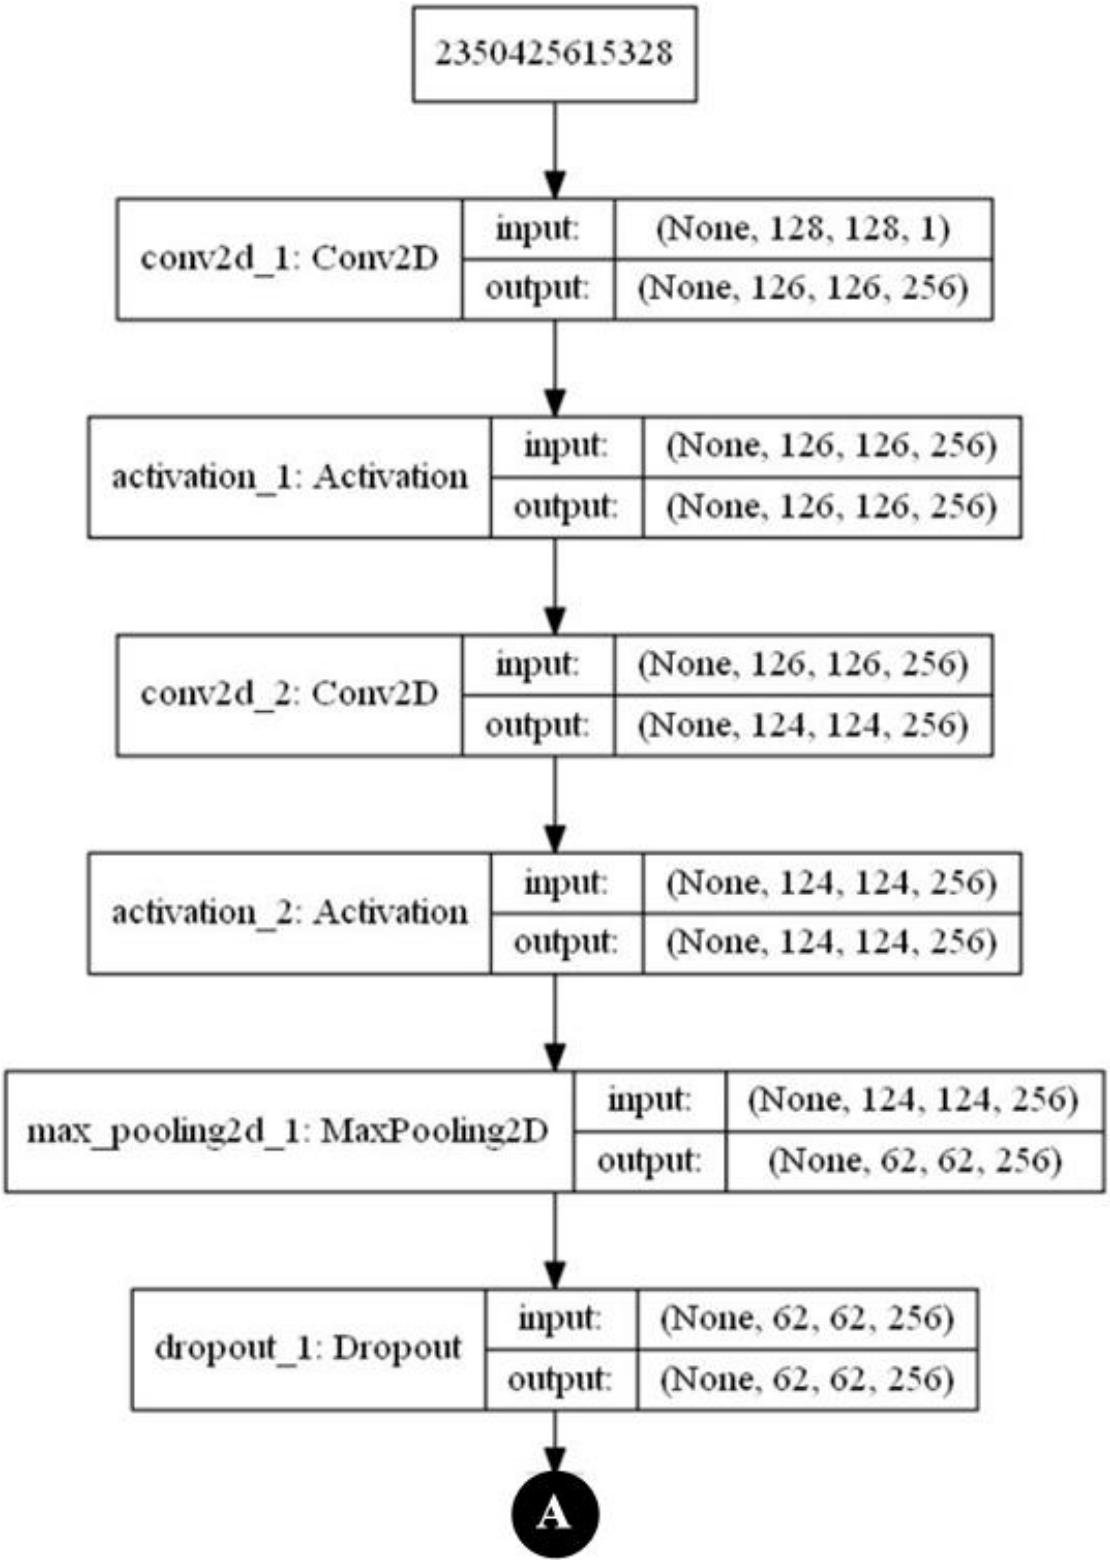
Zhu, X. (2005). *Semi-Supervised Learning Literature Survey.* University of Wisconsin Madison Computer Sciences Department.

Zhu, X. (2007). ICML. *Semi-Supervised Learning Tutorial*, 1-135. Madison, USA: University of Wisconsin Department of Computer Sciences.

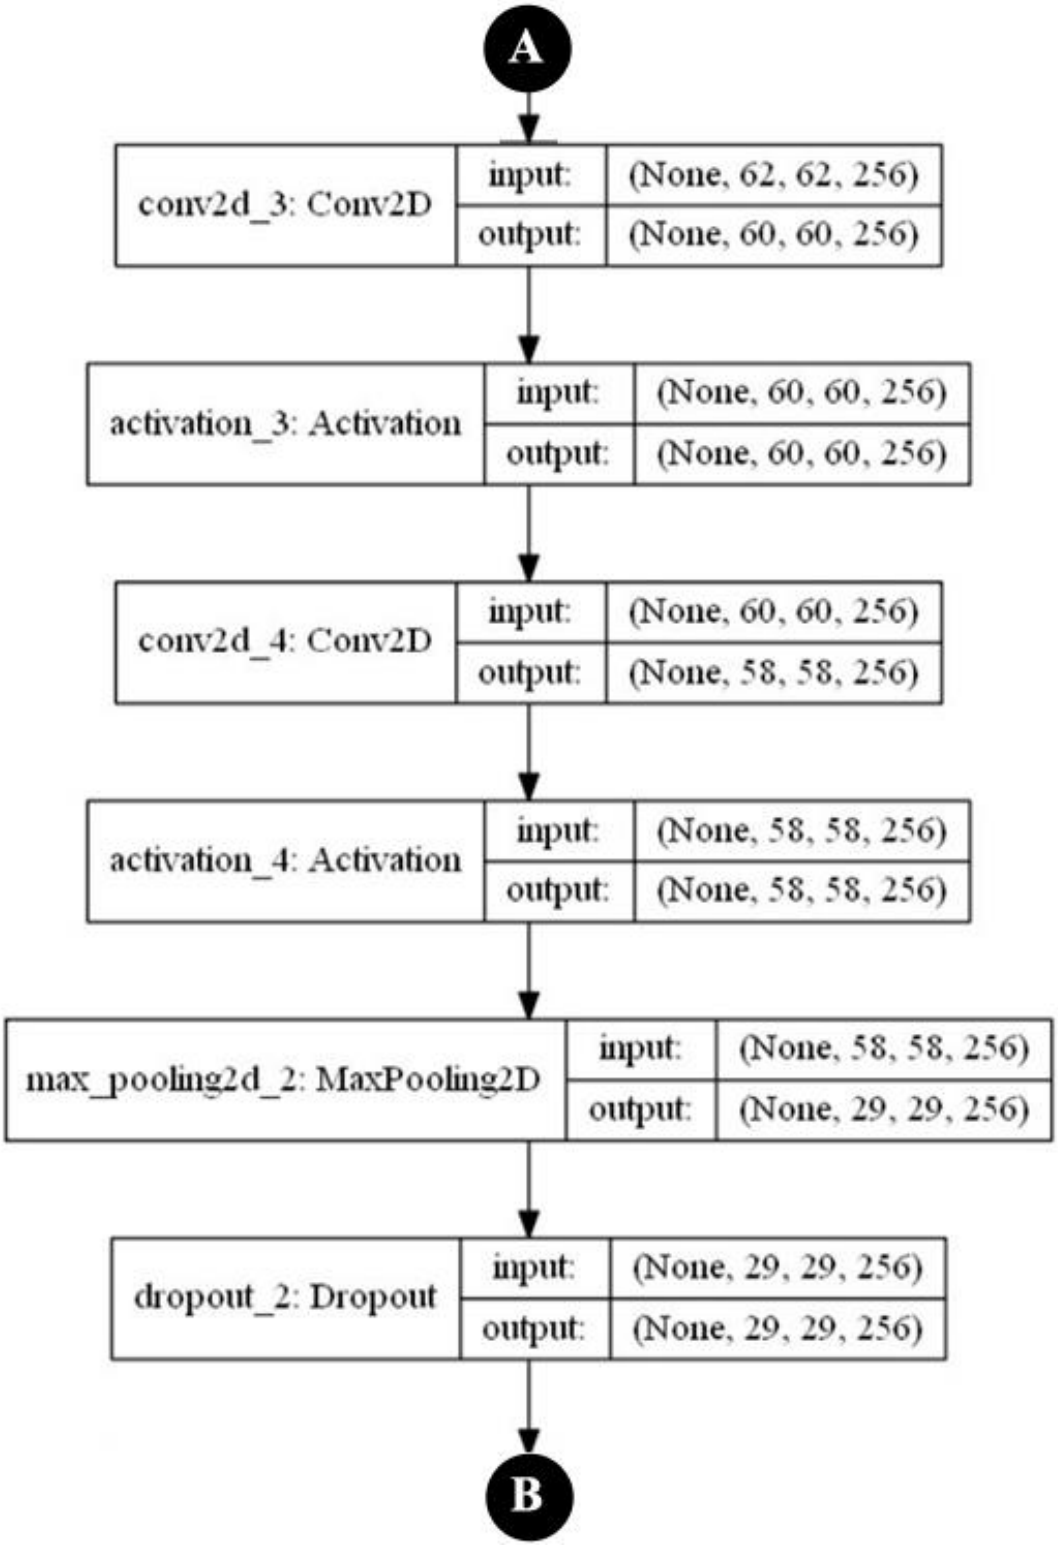
Zhu, X., and Goldberg, A. B. (2009). Introduction to Semi-Supervised Learning. *Artificial Intelligence and Machine Learning*, 130.
doi: 10.2200/S00196ED1V01Y200906AIM006

EKLER

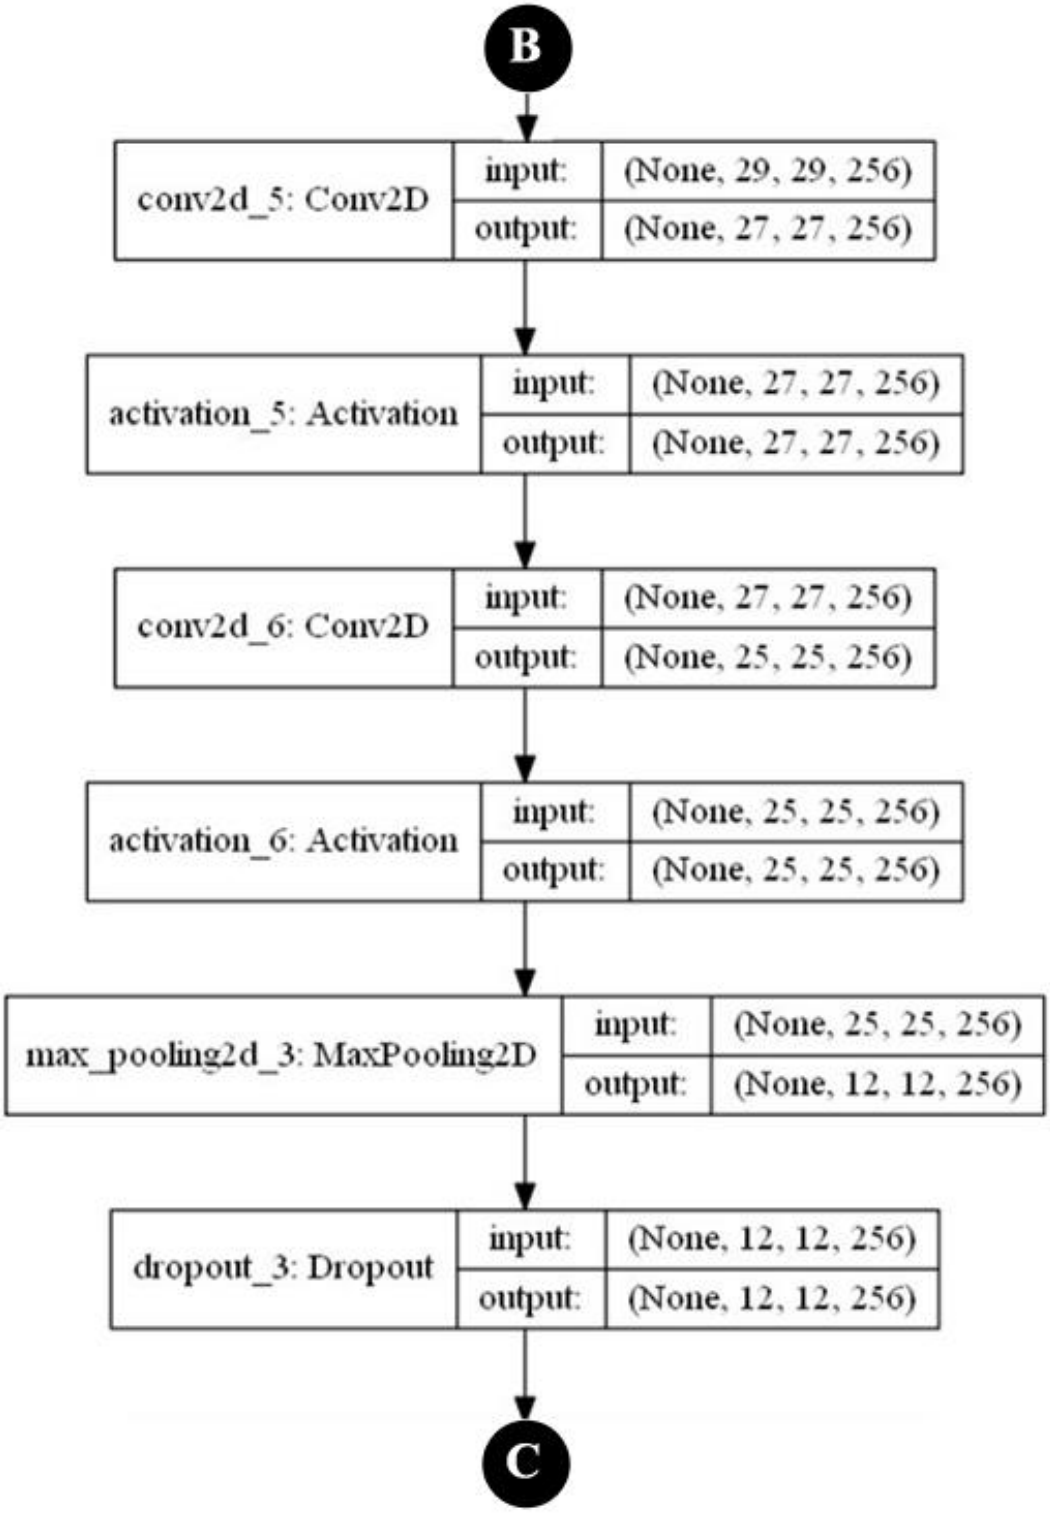
EK-1. Birinci ve ikinci evrişimsel katmanlar



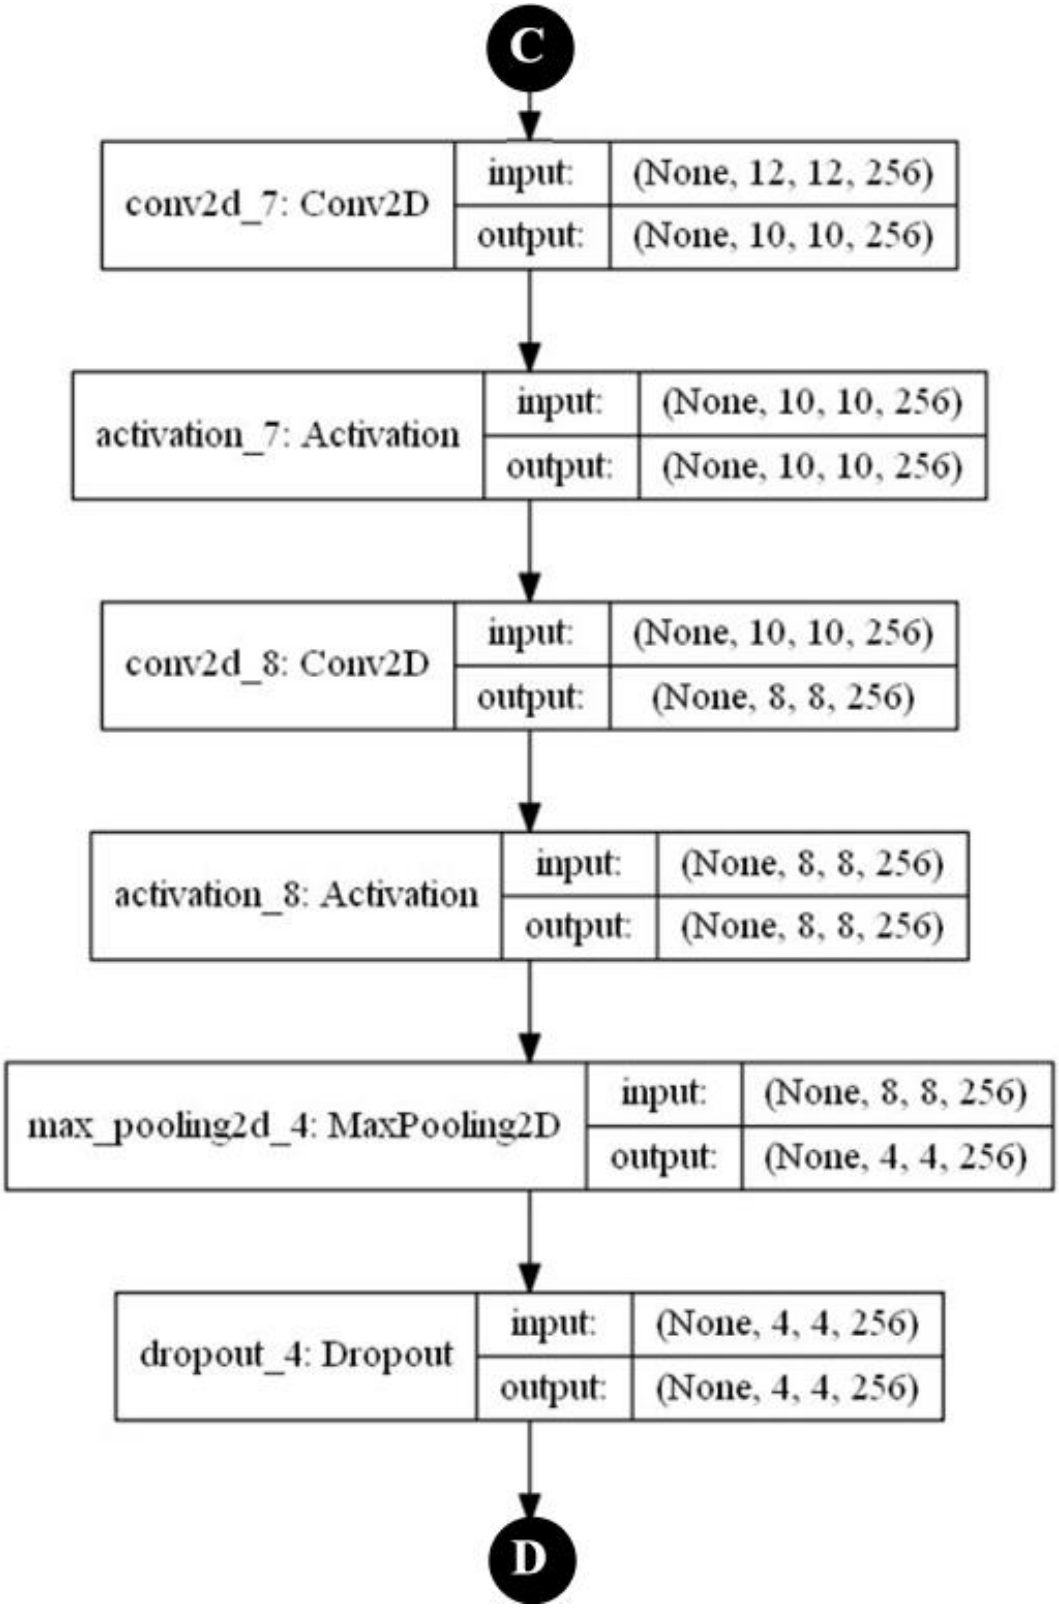
EK-2. Üçüncü ve dördüncü evrişimsel katmanlar



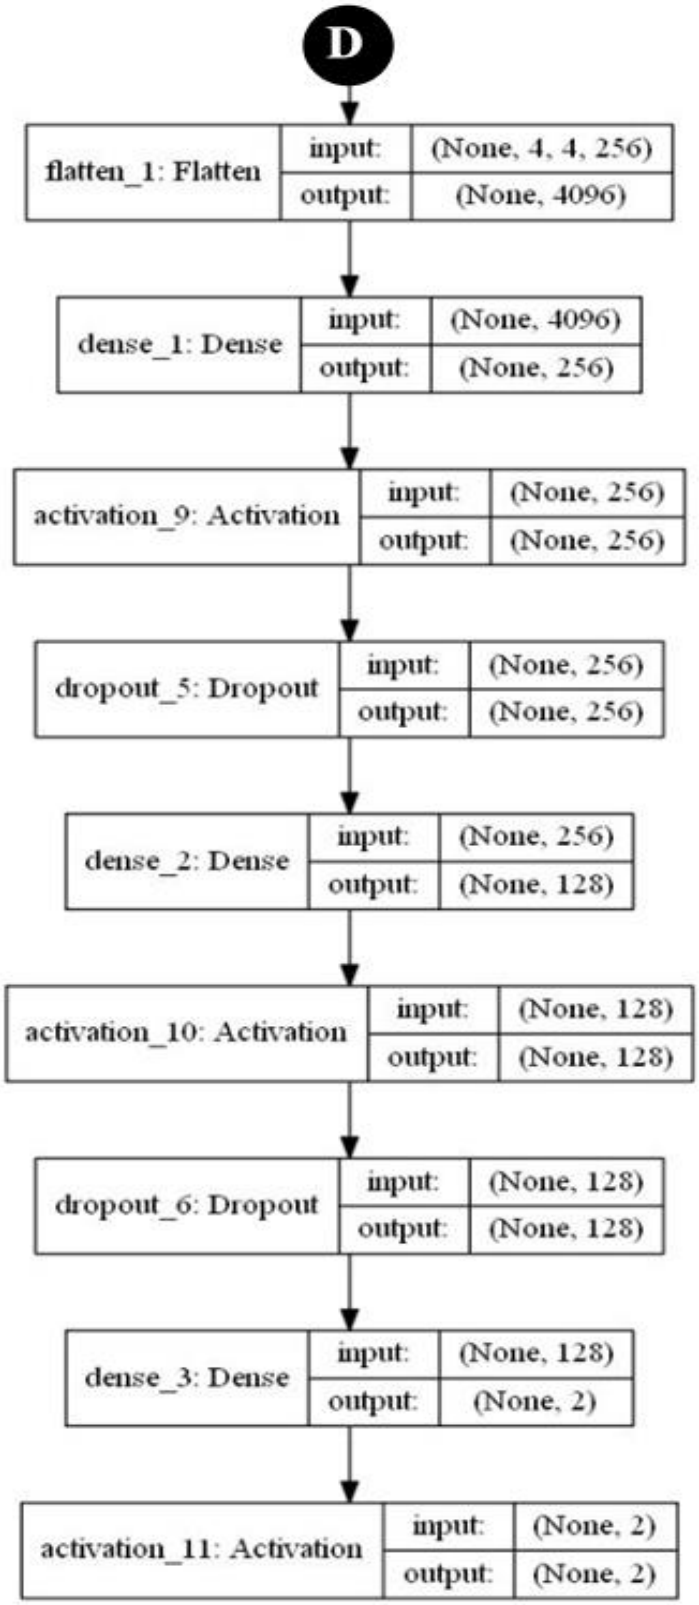
EK-3. Beşinci ve altıncı evrişimsel katmanlar



EK-4. Yedinci ve sekizinci evrişimsel katmanlar



EK-5. Düzleştirme ve tam bağlı katmanlar



EK-6. Etik İzni

Evrak Tarih ve Sayısı: 11/05/2018-E.75646

T.C.
GAZİ ÜNİVERSİTESİ
Etik Komisyonu

Sayı : 77082166-302.08.01-
Konu : Bilimsel ve Eğitim Amaçlı

FEN BİLİMLERİ ENSTİTÜSÜ MÜDÜRLÜĞÜNE

İlgi : a) 03/05/2018 tarihli ve 56497898-302.99- 70993 sayılı yazı.
b) 11/05/2018 tarihli ve 56497898-302.99- 75355 sayılı yazı.

İlgi yazınız ile göndermiş olduğunuz, Bilgisayar Mühendisliği Anabilim Dalı **Doktora Öğrencisi Serkan SAVAŞ'ın, Doç.Dr.Nurettin TOPALOĞLU'nun** danışmanlığında yürüttüğü ***"Karotis Arter Doppler Ölçümlerinde Derin Öğrenme Uygulamaları"*** adlı tez çalışması ile ilgili konu Komisyonumuzun **08.05.2018** tarih ve **04** sayılı toplantısında görüşülmüş olup,

İlgilinin çalışmasının, yapılması planlanan yerlerden izin alınması koşuluyla yapılmasında etik açıdan bir sakınca bulunmadığına oy birliği ile karar verilmiş ve karara ilişkin imza listesi ekte gönderilmiştir.

Bilgilerinizi ve gereğini rica ederim.

e-imzalıdır
Prof. Dr. Alper CEYLAN
Komisyon Başkanı

Araştırma Kod No: 2018-217

Ek:1 Liste

Ankara
Tel 0 (312) 202 20 57 - 0 (312) 2 Faks 0 (312) 202 38 76
İnternet Adresi http://etikkomisyon.gazi.edu.tr/

Bilgi için Ayfer Çekmez
Genel Evrak Sorumlusu
Telefon No 202 18 07

Bu belge 5070 sayılı Elektronik İmza Kanununun 5. Maddesi gereğince güvenli elektronik imza ile imzalanmıştır.

EK-7. Etik İzni İmza Sirküsü

GAZİ ÜNİVERSİTESİ
ETİK KOMİSYONU KATILIM LİSTESİ

TOPLANTI TARİHİ : 08/05/2018	TOPLANTI SAYISI : 04
ADI-SOYADI	İMZA
Prof.Dr.Alper CEYLAN BAŞKAN	
Prof.Dr.Mustafa N.İLHAN BAŞKAN YRD.	KATILAMADI
Prof.Dr.Mehmet KÜÇÜKKURT	KATILAMADI
Prof.Dr.Aymelek GÖNENÇ	
Prof.Dr.Rahmi ÜNAL	
Prof.Dr.Mehmet Sayım KARACAN	
Prof.Dr.Naciye YILDIZ	
Prof.Dr.Mustafa SARIKAYA	
Prof.Dr.İbrahim DOĞAN	
Prof.Dr.C. Haluk BODUR	
Prof.Dr.Mustafa İLBAŞ	
Prof.Dr.Füsun DEMİREL	
Doç.Dr.Nihan KAFA	

ÖZGEÇMİŞ

Kişisel Bilgiler



Soyadı, adı : SAVAŞ, Serkan

Uyruğu : T.C.

Doğum tarihi ve yeri : 14.10.1982, Ankara

Medeni hali : Evli

Telefon : 0 (505) 605 78 65

e-mail : serkan_savas@hotmail.com

Eğitim

Derece	Eğitim Birimi	Mezuniyet tarihi
Doktora	Gazi Üniversitesi/Fen Bilimleri Enstitüsü/ Bilgisayar Mühendisliği Ana Bilim Dalı	Devam Ediyor
Yüksek Lisans	Gazi Üniversitesi /Bilişim Enstitüsü/ Elektronik-Bilgisayar Eğitimi Ana Bilim Dalı	2011
Lisans	Gazi Üniversitesi/Elektronik-Bilgisayar Eğitimi/ Bilgisayar Sistemleri Öğretmenliği	2006

İş Deneyimi

Yıl	Yer	Görev
2016-Halen	Yenikent Ahmet Çiçek Mesleki ve Teknik Anadolu Lisesi	Müdür Yardımcısı
2015-2016	Kızılcahamam Mesleki ve Teknik Anadolu Lisesi	Müdür Yardımcısı
2006-2015	Kızılcahamam Mesleki ve Teknik Anadolu Lisesi	Bilişim Teknolojileri Öğretmeni

Yabancı Dil

İngilizce

Yayınlar

Savaş, S., (2011) *GSM şebekelerinin performanslarının veri madenciliğiyle analizi*, Yüksek Lisans Tezi, Gazi Üniversitesi Bilişim Enstitüsü, Ankara.

Savaş, S. ve Topaloğlu, N. (2011). GSM Şebekelerinin Performanslarının Veri Madenciliği Yöntemiyle Analizi. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 26(4), 741-751.

Savaş, S., Topaloğlu, N., ve Ciylan, B. (2012). Analysis Of Mobile Communication Signals With Frequency Analysis Method. *Gazi University Journal of Science*, 25(2), 447-454.

Savaş, S., Topaloğlu, N., ve Yılmaz, M. (2012). Veri Madenciliği ve Türkiye'deki Uygulama Örnekleri. *İstanbul Ticaret Üniversitesi Fen Bilimleri Dergisi*, 11(21), 1-23.

Savaş, S., Topaloğlu, N., ve Güler, O. (2015). Türkiye'deki Kullanıcıların Bazı Alan Adları Üzerine Tercihlerinin Belirlenmesi: Bir Anket Uygulaması. *Gazi Üniversitesi Bilişim Teknolojileri Dergisi*, 8(2), 51-58. doi: 10.17671/btd.20505

Savaş, S., Topaloğlu, N. (2015, 30-31 Ekim). *Sosyal Medya Verileri Üzerinden Siber İstihbarat Faaliyetleri*. VIII. Uluslararası Bilgi Güvenliği ve Kriptoloji Konferansı – ISCTurkey 2015, Orta Doğu Teknik Üniversitesi, Ankara.

Savaş, S., Topaloğlu, N. (2016, 30 Ocak-5 Şubat). *Siber Güvenlikte Yeni Bir Boyut: Sosyal Medya İstihbaratı*. XVIII. Akademik Bilişim Konferansı – AB2016, Adnan Menderes Üniversitesi, Aydın.

Savaş, S., Topaloğlu, N. (2017, 14-17 November). *Crime Intelligence from Social Media: A Case Study*. 2017 IEEE 14th International Scientific Conference on Informatics, Poprad, Slovakia. doi: 10.1109/INFORMATICS.2017.8327266

Savaş, S., Topaloğlu, N. (2018, 31 Ocak-2 Şubat). *R Programlama Dili ile Sosyal Medya Analizi: Örnek Olay İncelemesi*. XX. Akademik Bilişim Konferansı – AB2018, Karabük Üniversitesi, Karabük.

Güler, O., Savaş, S. (2018, 2-3 Kasım). *Etkileşimli Tahtalara Yönelik Stereoskopik 3 Boyutlu Eğitim Materyali Tasarımı ve Kullanılabilirliğinin Analizi*. Uluslararası FATİH Projesi Eğitim Teknolojileri Zirvesi, 580-585, Ankara.

Erensayın, E., Topaloğlu, N., Calp, M. H., ve Savaş, S. (2019). Effect of Cactus Plants on Magnetic Fields Bruited by Computer Screens. *Gümüşhane Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 9(1), 70-7. doi: 10.17714/gumusfenbil.393173.

Savaş, S., Topaloğlu, N. (2019). Data analysis through social media according to the classified crime. *Turk J Elec Eng & Comp Sci*, 27, 407-420. doi: 10.3906/elk-1712-17.

Savaş, S., Güler, O., Kaya, K., Çoban, G., ve Güzel, M. S. (2019, 13-15 Şubat). *Bilişim Teknolojileri Alanında Oyun ile Öğrenme*. XXI. Akademik Bilişim Konferansı – AB2019, Ordu Üniversitesi, Ordu.

Savaş, S., Topaloğlu, N., Kazcı, Ö., and Koşar, P. N. (2019) Classification of Carotid Artery Intima Media Thickness Ultrasound Images with Deep Learning. *J Med Syst*, 43, 273. doi: 10.1007/s10916-019-1406-2

Savaş, S., Topaloğlu, N., Kazcı, Ö., and Koşar, P. N. (2019, 5-7 July). *Performance Comparison Of Carotid Artery Intima Media Thickness Classification By Deep Learning Methods*. HORA 2019 - International Congress on Human-Computer Interaction, Optimization and Robotic Applications, SETSCI Conference Proceedings 4(5), 125-131 Urgup, Nevsehir, Turkey. doi: 10.36287/setsci.4.5.025

Hobiler

Teknoloji, Tarih, Spor, Müzik, Seyahat.



GAZİ GELECEKTİR…