



**BEYİN T M RLERİNİN DERİN   RENME YAKLA IMLARIYLA
TESPİTİ**

Mehmet Ali ATICI

**DOKTORA TEZİ
BİLGİSAYAR M HENDİSLİ İ ANA BİLİM DALI**

**GAZİ  NİVERSİTESİ
FEN BİLİMLERİ ENSTİT S **

TEMMUZ 2020

Mehmet Ali ATICI tarafından hazırlanan “BEYİN TÜMÖRLERİNİN DERİN ÖĞRENME YAKLAŞIMLARIYLA TESPİTİ” adlı tez çalışması aşağıdaki jüri tarafından OY BİRLİĞİ ile Gazi Üniversitesi Bilgisayar Mühendisliği Ana Bilim Dalında DOKTORA TEZİ olarak kabul edilmiştir.

Danışman: Prof. Dr. Şeref SAĞIROĞLU

Bilgisayar Mühendisliği Ana Bilim Dalı, Gazi Üniversitesi

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

.....

Başkan: Prof. Dr. İlyas ÇİÇEKLİ

Bilgisayar Mühendisliği Ana Bilim Dalı, Hacettepe Üniversitesi

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

.....

Üye: Prof. Dr. Refik SAMET

Bilgisayar Mühendisliği Ana Bilim Dalı, Ankara Üniversitesi

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

.....

Üye: Prof. Dr. Hasan Şakir BİLGE

Elektrik Elektronik Mühendisliği Ana Bilim Dalı, Gazi Üniversitesi

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

.....

Üye: Dr. Öğr. Üyesi Emrah ÇELTİKÇİ

Beyin Ve Sinir Cerrahisi Ana Bilim Dalı, Gazi Üniversitesi

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

.....

Tez Savunma Tarihi: 24/07/2020

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 çalışmada;

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

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

Mehmet Ali ATICI

24/07/2020

BEYİN TÜMÖRLERİNİN DERİN ÖĞRENME YAKLAŞIMLARIYLA TESPİTİ
(Doktora Tezi)

Mehmet Ali ATICI

GAZİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Temmuz 2020

ÖZET

Glioblastoma MultiForme (GBM) yüksek seviyeli beyin tümörleri arasında olup erken tespit edilmesi hayati öneme sahiptir. Literatürde beyin tümörlerinin derin öğrenme ile yüksek performansla tespitine yönelik çalışmalar mevcuttur ancak beyin tümörlerinin ve özellikle GBM tümörünün hızlı, etkin, daha kolay, daha düşük riskle, daha düşük maliyetle ve otomatik tespitine yönelik bütüncül çözümler bulunmamaktadır. Bu tez çalışmasında meyil artırıcı makineler, evrişimli sinir ağları ve kapsül ağları gibi güncel teknolojiler kullanılarak beyin cerrahlarının erken teşhisine olanak sağlayacak yapay zekâ çözümleri geliştirilmiştir. Bu kapsamda hem literatürde sıklıkla kullanılan bir kıyaslama veri seti hem de Gazi Brains Dataset 2020 veri setinin de temellerini oluşturan yerel bir veri seti kullanılmıştır. Yerel veri seti üzerinde yapılan deneysel çalışmalarda Xception modeliyle %98'e varan sınıflandırma oranı ile %94'e varan GBM tümörü hassasiyet oranı elde edilirken, kıyaslama veri seti üzerinde farklı tümör tiplerinin sınıflandırılması için yapılan çalışmalarda ise %91,4 ile %98,7 arasında değişen genel sınıflandırma oranları elde edilmiştir. Ayrıca, problem uzayına önerilen çözümlerimiz kapsamında literatürde – bildiğimiz kadarıyla- ilk defa bir MR görüntüsünün normal vakaya veya GBM vakasına ait olup olmadığının otomatik tespiti de gerçekleştirilerek %94'e varan GBM vakası hassasiyet oranları elde edilmiştir. Tez kapsamında mevcut modellerin probleme uyarlanarak uygulanmasının yanı sıra yeni modeller de geliştirilmiştir. Bu kapsamda Xception modelinde tam bağlantılı katman yerine Kapsül ağları dinamik yönlendirme katmanı kullanılarak XCaps olarak adlandırdığımız yeni bir model önerilmiş, bu sayede yaklaşık 23 milyon olan eğitilebilir parametre sayısı yaklaşık 21 milyona indirilerek sınıflandırma kesinliği %96,3'den %96,7'ye yükseltilmiştir. Bununla birlikte Kapsül Ağları dinamik yönlendirme katmanının ağırlık güncelleme işlemi önerdiğimiz değişikliklerle optimize edilebilir hale getirilmiş ve ESA-Kapsül modelinde uygulanarak sınıflandırma kesinliği %90,07'den %91,42'ye yükseltilmiştir.

Bilim Kodu : 92432
Anahtar Kelimeler : Beyin tümör tespiti, MR görüntüleme, makine öğrenmesi, derin öğrenme, evrişimli sinir ağları, kapsül ağları
Sayfa Adedi : 139
Danışman : Prof. Dr. Şeref SAĞIROĞLU

DETECTING BRAIN TUMORS USING DEEP LEARNING APPROACHES

(Ph. D. Thesis)

Mehmet Ali ATICI

GAZİ UNIVERSITY

GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCES

July 2020

ABSTRACT

Early detection of Glioblastoma MultiForme (GBM) that is among high-level brain tumors is vital. There are studies in the literature for the detection of brain tumors by deep learning with high performance, but there are no holistic solutions for rapid, effective, easier, less risky, lower cost and automatic detection of brain tumors and especially GBM tumor. In this thesis, artificial intelligence solutions have been developed to enable early diagnosis of neurosurgeons by using current technologies such as Gradient Boosting Machines, Convolutional Neural Networks and Capsule Networks. In this context, both a benchmark dataset frequently used in the literature and a local dataset that constitutes the basis of the Gazi Brains Dataset 2020 dataset were used. In experimental studies conducted on the local data set, the classification rate of up to %98 with the Xception model and up to %94 GBM tumor sensitivity rate were achieved, and the general classification accuracy ranging from %91,4 to %98,7 in the studies conducted for the classification of different tumor types on the benchmark data set were obtained. In addition, within the scope of our solutions proposed to problem space, - to the best of our knowledge - for the first time in the literature, automatic detection of whether an MR image belongs to the normal case or GBM case has been achieved and GBM case sensitivity rates have been achieved up to %94. In the scope of the thesis, besides applying the existing models to the problem, new models were also developed. In this context, a new model, which was called as XCaps, was proposed by using the Capsule Networks dynamic routing layer instead of the fully connected layer in the Xception model, thereby reducing the number of trainable parameters from about 23 million to about 21 million, thus increasing the classification accuracy from %96,3 to %96,7. In addition, weight update process of the Capsule Networks dynamic routing layer was modified such that it became optimizable and the classification accuracy has been increased from %90,07 to %91,42 when applied in the CNN-Capsule model.

Science Code : 92432

Key Words : Brain tumor detection, MR imaging, machine learning, deep learning, convolutional neural networks, capsule networks

Page Number : 139

Supervisor : Prof. Dr. Şeref SAĞIROĞLU

TEŞEKKÜR

Bu tez çalışmasında bana destek olan, başta değerli danışmanım Prof. Dr. Şeref SAĞIROĞLU, Dr. Emrah ÇELTİKÇİ ve Doç. Dr. Alp Özgün BÖRCEK olmak üzere tüm hocalarıma, tez çalışmalarımı güncel teknolojilerle desteklemek amacıyla aldığım yapay zekâ eğitimlerinde bana farklı vizyonlar sağlamış olan Dr. Satya P. MALLICK'e ve tüm eğitim hayatım boyunca destek ve teşviklerini hiçbir zaman esirgemeyen, kırılma noktalarında vazgeçmeyip devam etmeme yardımcı olan babam İsmail ATICI'ya teşekkürlerimi sunarım.

İÇİNDEKİLER

	Sayfa
ÖZET.....	iv
ABSTRACT	v
TEŞEKKÜR	vi
İÇİNDEKİLER	vii
ÇİZELGELERİN LİSTESİ	x
ŞEKİLLERİN LİSTESİ	xiii
RESİMLERİN LİSTESİ.....	xvi
SİMGELER VE KISALTMALAR.....	xvii
1. GİRİŞ.....	1
2. LİTERATÜR ARAŞTIRMASI.....	7
3. MATERYAL VE METOT	13
3.1. MR Görüntüleme ve Veri Setleri.....	13
3.1.1. MR görüntüleme	13
3.1.2. Veri setleri	16
3.2. Makine Öğrenmesi ve Derin Öğrenme Algoritmaları ve Yapıları	18
3.2.1. Geleneksel makine öğrenmesi algoritmaları ve yapıları	19
3.2.2. Derin öğrenme algoritmaları ve yapıları	23
4. MEVCUT YÖNTEMLERİN PROBLEME UYGULANMASI	33
4.1. Uygulanan Yöntemler	37
4.1.1. Varsayılan yöntem	37
4.1.2. ESA modeli.....	39
4.1.3. ESA-Kapsül modeli	47
4.1.4. XCeption modeli	55

	Sayfa
4.1.5. CapsNet modeli.....	58
5. GELİŞTİRİLEN ALGORİTMA VE MODELLER	61
5.1. Önerilen Piksel Histogram Tabanlı Algoritma.....	61
5.1.1. Deney#18.....	63
5.2. Önerilen Yerel İkili Desenler Tabanlı Algoritma	64
5.2.1. Deney#19.....	66
5.2.2. Deney#20	67
5.2.3. Deney#21.....	68
5.2.4. Deney#22.....	69
5.3. Önerilen Geliştirilmiş ESA-Kapsül Modeli	69
5.3.1. Deney#23.....	72
5.4. Önerilen XCaps Modeli	74
5.4.1. Deney#24.....	75
5.5. MR Görüntülerinin Sekans Bazlı Analizi	77
5.6. Beyin Tümörü Erken Uyarı Sistemi ve Yöntemi	79
6. SONUÇLARIN LİTERATÜR İLE KIYASLANMASI	85
6.1. Sonuçların Orijinal Makale ile Karşılaştırılması.....	85
6.2. 5-Kat Çapraz Doğrulama Yapan Çalışmalarla Karşılaştırma	86
6.3. Rastgele Veri Bölme İle Doğrulama Yapan Çalışmalarla Karşılaştırma	87
6.4. Axial Veri Seti Kullanan Çalışmalarla Karşılaştırma	89
6.5. Lokal Veri Setinde Yapılan Çalışmaların Karşılaştırılması	90
7. TARTIŞMA VE SONUÇ.....	93
7.1. Tartışma.....	93
7.2. Sonuç ve Öneriler	97

	Sayfa
KAYNAKLAR	103
EKLER	111
EK-1. Kesinlik ve kayıp eğrileri	112
EK-2. Ara katman görselleştirilmesi	136
ÖZGEÇMİŞ	138

ÇİZELGELERİN LİSTESİ

Çizelge	Sayfa
Çizelge 2.1. Literatür özeti.....	11
Çizelge 3.1. Ce-mri veri seti özeti	17
Çizelge 4.1. Karışıklık matrisi	35
Çizelge 4.2. Lokal veri seti için örnek karışıklık matrisi	35
Çizelge 4.3. Ce-mri veri seti için örnek karışıklık matrisi	36
Çizelge 4.4. Varsayılan tespit algoritması sözde kodu.....	37
Çizelge 4.5. Deney#1 sonuçları	38
Çizelge 4.6. Deney#2 sonuçları	41
Çizelge 4.7. Deney#3 sonuçları	42
Çizelge 4.8. Deney#4 sonuçları	43
Çizelge 4.9. Deneysel çalışma sonuçları karşılaştırması.....	44
Çizelge 4.10. Deney#5 sonuçları	45
Çizelge 4.11. Deney#6 sonuçları	46
Çizelge 4.12. Deney#7 sonuçları	47
Çizelge 4.13. Deney#8 sonuçları	49
Çizelge 4.14. Deney#9 sonuçları	50
Çizelge 4.15. Deney#10 sonuçları	51
Çizelge 4.16. Deney#11 sonuçları	51
Çizelge 4.17. Deney#12 sonuçları	53
Çizelge 4.18. Deney#13 sonuçları	54
Çizelge 4.19. Axial veri seti sonuçlarının karşılaştırılması	54
Çizelge 4.20. Deney#14 sonuçları	56
Çizelge 4.21. Deney#15 sonuçları	57
Çizelge 4.22. Deney#16 sonuçları	57

Çizelge	Sayfa
Çizelge 4.23. Karışıklık matrisi (deney#17).....	58
Çizelge 4.24. Deney#17 sonuçları	59
Çizelge 5.1. Piksel histogram dağılımı temelli sınıflandırma algoritması sözde kodu..	61
Çizelge 5.2. Deney#18 sonuçları	63
Çizelge 5.3. Yerel ikili desenler temelli algoritma sözde kodu	64
Çizelge 5.4. Deney#19 sonuçları	66
Çizelge 5.5. Deneysel çalışma sonuçları karşılaştırması.....	66
Çizelge 5.6. Axial veri setindeki sonuçların karşılaştırılması	68
Çizelge 5.7. Deney#21 sonuçları	68
Çizelge 5.8. Deney#22 sonuçları	69
Çizelge 5.9. Ağırlık güncelleme formülasyonu	70
Çizelge 5.10. Deney#23 sonuçları	73
Çizelge 5.11. Deneysel çalışma sonuçları karşılaştırması.....	74
Çizelge 5.12. Deney#24 sonuçları	76
Çizelge 5.13. Deneysel çalışma sonuçları karşılaştırması.....	77
Çizelge 5.14. Deneysel çalışma sonuçları	80
Çizelge 6.1. Deneysel çalışma sonuçları literatür karşılaştırması	85
Çizelge 6.2. Deneysel çalışma sonuçları literatür karşılaştırması	86
Çizelge 6.3. Deneysel çalışma sonuçları literatür karşılaştırması	87
Çizelge 6.4. Deneysel çalışma sonuçları literatür karşılaştırması	88
Çizelge 6.5. Deneysel çalışma sonuçları literatür karşılaştırması	88
Çizelge 6.6. Deneysel çalışma sonuçları literatür karşılaştırması	88
Çizelge 6.7. Deneysel çalışma sonuçları literatür karşılaştırması	88
Çizelge 6.8. Model karmaşıklık karşılaştırması.....	89

Çizelge	Sayfa
Çizelge 6.9. Axial veri seti sonuçlarının literatür karşılaştırması	89
Çizelge 6.10. Deney sonuçlarının karşılaştırılması	91
Çizelge 6.11. Deney sonuçlarının karşılaştırılması.....	91

ŞEKİLLERİN LİSTESİ

Şekil	Sayfa
Şekil 3.1. Mr görüntü düzlemleri	13
Şekil 3.2. Yapay zekâ - derin öğrenme ilişkisi	18
Şekil 3.3. Dvm doğrusal dağılım örneği.....	21
Şekil 3.4. Dvm doğrusal olmayan dağılım örneği	22
Şekil 3.5. Dvm yeni boyut ekleme örneği	22
Şekil 3.6. En basit algılayıcı (perceptron) modeli.....	24
Şekil 3.7. Algılayıcı genel modeli.....	24
Şekil 3.8. Çok katmanlı yapay sinir ağı.....	25
Şekil 3.9. Esa filtreleme işlemi	26
Şekil 3.10. Maksimum havuzlama işlemi.....	28
Şekil 3.11. Artık blok yapısı.....	28
Şekil 3.12. Xception mimarisi	29
Şekil 3.13. Esa sınıflandırma örneği	30
Şekil 3.14. Capsnet mimarisi	31
Şekil 4.1. Matris-vektör dönüşümü	37
Şekil 4.2. Uygulanan esa modeli.....	39
Şekil 4.3. Evrişimli katman yapısı	39
Şekil 4.4. Tam bağlantılı katman mimarisi	40
Şekil 4.5. Uygulanan esa mimarisi.....	40
Şekil 4.6. Karışıklık matrisi (deney#2)	41
Şekil 4.7. Karışıklık matrisi (deney#3)	42
Şekil 4.8. Karışıklık matrisi (deney#4)	43
Şekil 4.9. Karışıklık matrisi (deney#5)	45
Şekil 4.10. Karışıklık matrisi (deney#6)	46

Şekil	Sayfa
Şekil 4.11. Karışıklık matrisi (deney#7)	47
Şekil 4.12. Esa-kapsül mimarisi.....	48
Şekil 4.13. Esa-kapsül mimarisi blok yapısı.....	48
Şekil 4.14. Esa-kapsül mimarisi 4.blok yapısı.....	48
Şekil 4.15. Karışıklık matrisi (deney#8)	49
Şekil 4.16. Karışıklık matrisi (deney#9)	50
Şekil 4.17. Karışıklık matrisi (deney#10).....	51
Şekil 4.18. Karışıklık matrisi (deney#11).....	51
Şekil 4.19. Deney#11 kesinlik ve kayıp eğrileri	52
Şekil 4.20. Karışıklık matrisi (deney#12).....	53
Şekil 4.21. Deney#12 kesinlik ve kayıp eğrileri	53
Şekil 4.22. Karışıklık matrisi (deney#13).....	54
Şekil 4.23. Karışıklık matrisi (deney#14).....	55
Şekil 4.24. Karışıklık matrisi (deney#15).....	56
Şekil 4.25. Karışıklık matrisi (deney#16).....	57
Şekil 4.26. Uygulanan capsnet mimarisi	58
Şekil 5.1. Piksel histogram dağılımı temelli algoritma akışı.....	62
Şekil 5.2. Örnek histogram	63
Şekil 5.3. Lbp hesaplama örneği.....	65
Şekil 5.4. Yerel ikili desenler temelli algoritma	65
Şekil 5.5. Dinamik yönlendirme algoritması.....	70
Şekil 5.6. Geliştirilmiş esa-kapsül mimarisi	71
Şekil 5.7. Esa-kapsül mimarisi blok yapısı	71
Şekil 5.8. Esa-kapsül mimarisi 4.blok yapısı.....	72

Şekil	Sayfa
Şekil 5.9. Karışıklık matrisi (deney#23)	72
Şekil 5.10. Kapsül optimizasyonu performans dağılımı	73
Şekil 5.11. Önerilen xcaps mimarisi	74
Şekil 5.12. Önerilen xcaps mimarisi çıkış akışı.....	75
Şekil 5.13. Karışıklık matrisi (deney#24).....	76
Şekil 5.14. Deney#24 kesinlik ve kayıp eğrileri.....	76
Şekil 5.15. İş akış şeması.....	78
Şekil 5.16. Erken uyarı sistemi mimarisi	82
Şekil 5.17. Tespit modülü mimarisi	83
Şekil 6.1. Ce-mri örnek dağılımı.....	90

RESİMLERİN LİSTESİ

Resim	Sayfa
Resim 3.1. Normal ve gbm için t2 ağırlıklı mr görüntüleri	14
Resim 3.2. Farklı düzlemlerde mr görüntü örnekleri	14
Resim 3.3. T2 mr görüntü serisi.....	15
Resim 3.4. Mr görüntü örnekleri.....	16
Resim 3.5. Beyin tümör tipleri.....	16
Resim 7.1. Tahmin örnekleri	96

SİMGELER VE KISALTMALAR

Bu çalışmada kullanılmış kısaltmalar, açıklamaları ile birlikte aşağıda sunulmuştur.

Kısaltmalar	Açıklamalar
AİK	Alıcı İşletim Karakteristiği
DVM	Destek Vektör Makineleri
DICOM	Digital Imaging and COmmunications in Medicine
ESA	Evrişimli Sinir Ağları
XgBoost	eXtreme Gradient Boosting
GA	Genetik Algoritma
GiÜ	Grafiksel İşlem Ünitesi
GBM	Glioblastoma MultiForme
KA	Karar Ağaçları
K-EYK	K-En Yakın Komşuluk
LightGBM	Light Gradient Boosting Machines
LR	Lojistik Regresyon
MR	Manyetik Resonans
MAM	Meyil artırımı makinalar
BRATS	Multimodal Brain Tumor Segmentation
Türkrad	Türk Radyoloji Derneği
YSA	Yapay Sinir Ağları

1. GİRİŞ

Dünya Sağlık Örgütü'nün merkezi sinir sistemi tümör sınıflandırmasına göre beyin tümörleri 4 farklı seviyede sınıflandırılmakta olup, 4. seviye tümörler en hızlı yayılan ve en ölümcül olanlarıdır. Glioblastoma MultiForme (GBM) ve bunun alt kategorileri yüksek dereceli tümör-gliomas olarak sınıflandırılmakta olup bunların erken teşhisi hasta için hayati öneme sahiptir. Manyetik Rezonans (MR) görüntüleme birçok hastalığın teşhisinde etkili şekilde kullanılmakta olan yöntemlerden birisi olup, beyin tümörlerinin tespitinde de başarılı sonuçlar vermektedir.

Literatür çalışmalarını incelediğimizde bir MR görüntüsünde beyin tümörü olup olmadığının veya beyin tümör bölgesinin tespitine yönelik, gerek geleneksel makine öğrenmesi algoritmaları ve gerekse son yıllarda derin öğrenme algoritmalarını esas alan çözümler önerildiği ve özellikle derin öğrenme ile yüksek performans değerleri elde edilebildiği görülmektedir. Ancak bu çalışmaların çoğunlukla, kısıtlı sayıdaki kıyaslama veri seti üzerinde yapılmış olduğu, veri çeşitliliğinin yerel veri setleri kullanılarak nadiren sağlanabildiği, vakaya ön tanı konmasından kesin teşhise kadar tüm süreçleri kapsayan bütüncül çözümler önerilmediği, teşhis için gerekli MR görüntü sayısının azaltılmasına yönelik yaklaşımlar geliştirilmediği, MR görüntü düzlemi ve tipi açısından, MR görüntü farklılıklarının otomatik tespiti ve dolayısıyla teşhise etkisinin analiz edilmediği ve özellikle 2017 yılından sonra önerilen LightGBM ve Kapsül Ağları gibi güncel algoritmaların bu problem üzerinde nadiren uygulandığı görülmektedir. Literatürdeki araştırmaya açık bu konular da dikkate alınarak problemin detaylı tanımı ve çözüm önerileri takip eden paragraflarda sunulmaktadır.

Problemin tanımı

Dünya Sağlık Örgütü çalışmalarına göre, merkezi sinir sistemi tümör sınıflandırmasında beyin tümörleri 4 farklı dereceye ayrıştırılmış ve en tehlikeli olanı ise hem hızlı yayılmaları hem de en ölümcül olmaları açısından 4. seviye tümörler olarak belirlenmiştir. 4. seviye tümörler, GBM ve bunun alt kategorileri olan ve yüksek dereceli tümör-gliomas grubundadır. Dolayısıyla GBM tümörünün erken teşhisi hayati öneme sahiptir. Beyin cerrahisi uzmanları kendilerine başvuran kişilerin şikayetlerini dinledikten sonra duruma

göre beyin tümörü olup olmadığının tespiti için MR çekimine karar vermektedir. Beyin tümörlerinin tespitinde, MR görüntüleme etkili bir şekilde kullanılmaktadır. MR görüntüleme ile beyin anatomisinin detayları üç farklı düzlemde görselleştirilmektedir. Bunlar axial, coronal ve sagittal düzlemler olarak adlandırılmaktadır. MR görüntü serileri T1 ağırlıklı, T1C ağırlıklı, T2 ağırlıklı ve Flair olmak üzere 4 temel tipte olabilmektedir. Beyin hastalıklarının tespitinde T1C ve T2 ağırlıklı görüntüler sıklıkla kullanılmaktadır. T1C ağırlıklı MR görüntüleme yapılabilmesi için hastaya damardan ilaç verilmesi gerekirken, T2 ağırlıklı görüntülemeye buna ihtiyaç duyulmamaktadır.

Bir MR görüntüsünde beyin tümörünün manuel tespiti için görüntünün tümör bölgesine ait kısımları içermesi gerekir. GBM başta olmak üzere bazı beyin tümörlerinin belirgin bir şekli ve sabit bir yeri bulunmamaktadır. Dolayısıyla tümör bölgesini yakalayabilmek için mümkün olduğunca fazla sıklıkta kesit taranması veya alınması gerekecektir. MR çekimi sonrasında oluşan görüntüler radyolog incelemesine gönderilmektedir. Radyoloji uzmanları bir vaka için çekilen MR görüntülerinin her birini inceleyerek hazırladıkları raporu Beyin Cerrahlarına iletmekte ve kesin teşhis konularak, durumun aciliyetine göre hasta cerrahi operasyona alınmakta ve tedaviye başlanmaktadır.

Türkrad verilerine göre Türkiye’de radyoloji uzmanlarının MR görüntülerini değerlendirme süreleri, hasta yoğunluğu ve uzman eksikliği nedeniyle, ortalama 5 dakika olabilmekte ve bu iş yükü GBM gibi önemli patolojilerin tespitinde gecikmeye sebep olabilmektedir. Bu yoğunluk nedeniyle MR çekimi yapıldıktan sonra bunun radyologlar tarafından raporlanması bir hafta sürebilmekte özellikle taşra hastanelerinde bu süre 15 güne kadar da uzayabilmektedir. Bu ise bazı vakalara müdahale edilmesinde gecikmeye ve dolayısıyla hastanın hayatını kaybetmesine neden olabilmektedir. Tüm bu hususlar dikkate alındığında, bu tez çalışmasında ele alınacak problem uzayı aşağıdaki başlıklarda özetlenmiştir. Bunlar;

1. Beyin tümörlerinin ve özellikle GBM tümörünün yüksek performans ile tespit edilmesi,
2. Beyin tümörü tespitinde kullanılan MR görüntü düzlemlerindeki farklılıkların otomatik tümör tespitinde ne gibi etkilerinin olduğunun tespiti,
3. GBM tümörü olup olmadığının tespiti için ihtiyaç duyulacak T2 ağırlıklı MR görüntü sayısının azaltılması,

4. MR çekiminden kesin teşhise kadarki süreçlerin hızlandırılmasını ve insan hatalarının minimize edilmesini sağlayacak bütüncül bir mimari tasarlanması, gibi hedeflerdir.

Problem uzayındaki bu hususlara çözüm olarak tez çalışması kapsamında;

1. MR çekiminden sonra oluşan DICOM veya benzeri formattaki dosyaların veya doğrudan MR görüntülerinin, LigthGBM ve Kapsül Ağları da dahil, literatürde başarılı sonuçlar veren yapay zekâ algoritmaları ile analiz edilerek özellikle GBM tümörlerinin otomatik tespit edilmesini ve tümör tespit edilmesi durumunda hastaya acil müdahale edilebilmesi için ilgili hekimin kısa mesaj servisi veya mobil uygulama aracılığıyla anında bilgilendirilmesini sağlayacak bir sistem önerilmiş ve bunun için patent başvuru süreci (2020/13244) başlatılmıştır.
2. Literatürde kullanılan kıyaslama veri setleri haricinde yerel bir veri seti de hazırlanarak veri çeşitliliği artırılmış ve dolayısıyla probleme çözüm için farklı analizler de gerçekleştirilebilmiştir.
3. Söz konusu sistem dahilinde kullanılabilecek derin öğrenme modelleri eğitilerek, T2 ağırlıklı bir MR görüntüsünde GBM tümörü olup olmadığının veya tümör olduğu bilinen T1C ağırlıklı bir MR görüntüsündeki beyin tümörü tipinin otomatik tespiti gerçekleştirilmiştir.
4. Çekim düzlemi açısından MR görüntü farklılıkları analiz edilmiş, coronal ve sagittal görüntüler boyun, boğaz ve yutak gibi beyin harici organları da içermekleyen axial görüntüler ise sadece beyin bölgesini içermekte ve daha homojen bir desene sahip olmasından yola çıkılarak axial görüntülerin modellerin eğitilmesinde kullanılmasının sınıflandırma kesinliğini artıracığı şeklinde bir hipotez geliştirilmiş ve bunu desteklemeye yönelik analizler gerçekleştirilmiştir.
5. Bildiğimiz kadarıyla literatürde ilk defa, T2 ağırlıklı MR görüntüsünde GBM tümörü belirgin bir şekilde manuel olarak tespit edilemese bile bu görüntünün normal vakaya veya GBM vakasına ait olup olmadığının otomatik tespiti için de modeller eğitilmiştir.
6. Derin öğrenme kapsamında güncel bir teknoloji olan kapsül ağları incelenerek, dinamik yönlendirme katmanında ağırlık güncelleme işleminde önceki ağırlık değerinin yeni ağırlık değerine etkisinin, öğrenilmeye çalışılan niteliklerin temsil gücünü etkileyeceğinden bu etkinin optimize edilebilir hale getirilmesiyle sınıflandırma performansının artacağına yönelik bir hipotez geliştirilmiş, bunu

desteklemek için ağırlık güncelleme işlemi, önceki ağırlık değerinin yeni ağırlık değerinin belirlenmesine etkisi açısından skalar bir değişken ile kontrol edilerek optimize edilebilir hale getirilmiş ve sonuçta ESA-Kapsül mimarisinde sınıflandırma kesinliği artırılmıştır.

7. Literatürde mevcut Xception modelinde tam bağlantılı katman yerine Kapsül ağırları dinamik yönlendirme katmanı kullanılarak XCaps ismini verdiğimiz yeni bir model geliştirilmiş ve kıyaslama veri seti üzerinde yapılan sınıflandırmada Xception modeline göre eğitilmesi gereken parametre sayısı azaltılırken sınıflandırma kesinliği artırılmıştır.

Araştırmanın önemi

Türkrad verilerine göre Türkiye’de radyoloji uzmanlarının MR görüntülerini değerlendirme süreleri, hasta yoğunluğu ve uzman eksikliği nedeniyle, ortalama 5 dakika olabilmekte ve bu iş yükü yüksek seviyeli glioma gibi önemli patolojilerin tespitinde gecikmeye sebep olabilmektedir. Bu yoğunluk nedeniyle MR çekimi yapıldıktan sonra bunun radyologlar tarafından raporlanması duruma göre 15 güne kadar uzayabilmektedir. Bu ise bazı vakalara müdahale edilmesinde gecikmeye ve dolayısıyla hastanın hayatını kaybetmesine neden olabilmektedir. Ancak güncel yapay zekâ teknikleri kullanılarak radyoloji incelemesindeki bu yoğunluktan kaynaklı gecikmenin önüne geçilerek hızlı teşhis imkanı sağlayacak çözümler üretilmesi mümkündür.

Tez çalışmaları sırasında yapılan deneysel çalışmalarda kullanılan beyin MR görüntüleri, *Gazi Brains 2020* veri setinin de temelini oluşturan, Gazi Üniversitesi Tıp Fakültesi Beyin Cerrahisi Ana Bilim Dalı’nda tedavi edilen ve gerekli etik onayı alındığı belirtilen 114 normal, 65 GBM olmak üzere toplam 179 vakadan toplanan verilerdir. Bu verilere ilave olarak, geliştirilen modelleri literatür ile karşılaştırmak için 233 vakadan toplanmış olan ve açık kaynak olarak yayımlanan beyin MR görüntüleri de eğitim ve test veri seti olarak kullanılmıştır.

Tez araştırmaları kapsamında, LightGBM temelli algoritmalar lokal ortamda, derin öğrenme temelli modeller ise Google Colab Research ortamında, sadece 1 Grafiksel İşlem Ünitesi (GIÜ) tahsisi ve her 12 saatte bir sistemin sıfırlanması kısıtlarıyla tamamlanmıştır. Ayrıca lokal veri seti oluşturma çalışmaları başlangıç aşamasında olup vaka sayısı ve

görüntü çeşitliliği açısından henüz yeterli miktarda veri bulunmamaktadır. Hem ortam kısıtlaması hem de veri seti boyutundaki yetersizlik nedeniyle literatürde sunulan, önceden eğitilmiş GoogleNet, VGG19 vb. gibi karmaşık derin öğrenme mimarileri çalışmamızda kullanılamamıştır. Orijinal CapsNet mimarisi de karmaşıklığı azaltılarak kullanılabilmiş olup veri setlerindeki görüntü boyutları da bellek kısıtları nedeniyle küçültülerek modeller eğitilebilmiştir. Buna ilave olarak, çalışma kapsamında hasta veri mahremiyetine saygı duyulması sebebiyle Colab Research ortamında sadece anonimleştirilmiş veriler kullanılmıştır.

Bu tez çalışması 7 bölümden oluşmaktadır. Bölüm 2’de literatür araştırması yapılmış, Bölüm 3’de materyal ve metot kapsamında MR görüntüleme ve bunun tıbbi teşhiste ve özellikle beyin tümörü tespitinde kullanımı hakkında bilgiler verilmiş, bununla birlikte veri setleriyle literatürde mevcut makine öğrenmesi ve derin öğrenme algoritma ve modelleri incelenmiş, Bölüm 4’de, tez kapsamındaki problem uzayına çözüm üretmek için uygulanan yöntemler anlatılmış, Bölüm 5’de literatürde mevcut yöntemlerin uygulanmasından farklı olarak tez kapsamında geliştirilen yeni algoritma ve modeller açıklanmış, Bölüm 6’da bir önceki bölümlerde uygulanan ve önerilen algoritma ve modellerle elde edilen performans değerlerinin literatür çalışmalarıyla kıyaslanması gerçekleştirilmiş ve Bölüm 7’de tez kapsamında elde edilen sonuç ve bulgular tartışılıp değerlendirilerek özetlenmiştir.

2. LİTERATÜR ARAŞTIRMASI

Yapay zekâ konusundaki çalışmalar son zamanlarda oldukça ilerlemiş olup bazı problemlerin çözümünde uzman insanlar tarafından gerçekleştirilen doğru tespit oranlarını yakalayan çözümler sunabilmektedir [1-5]. Yapay zekâ konusunun bir alt dalı olan makine öğrenmesi kapsamında yer alan geleneksel makine öğrenmesi algoritmaları özellikle tabular veri setleri üzerinde başarılı sonuçlar veren algoritmalarlardır [6-7]. Bu algoritmalarla yapay zekâ modeli eğitmek için *nitelik mühendisliği* yapılarak girdi vektörünün tasarlanması gerekmektedir. K-En Yakın Komşuluk (K-EYK), Destek Vektör Makineleri (DVM), Lojistik Regresyon (LR), Karar ağaçları (KA) gibi algoritmaların yanı sıra 2017'den sonra özellikle Kaggle (www.kaggle.com) yarışmalarında popüler hale gelen LightGBM [8] ve XgBoost [9] algoritmaları bu kapsamda sıklıkla kullanılan algoritmalarlardır. LightGBM bilgi kazanımı hesaplamasında küçük eğilimleri dikkate almayarak modelin eğitilmesini hızlandırmaktadır. LightGBM ve XgBoost algoritmaları tez kapsamındaki çeşitli deneysel çalışmalarda en iyi sonuçları alan geleneksel makine öğrenmesi algoritmalarıdır. Geleneksel makine öğrenmesi algoritmalarının çalışması için Grafiksel İşlem Ünitesi destekli donanım kullanımı zorunluluğu yoktur.

Derin öğrenme de makine öğrenmesinin bir alt dalı olup en yaygın kullanılan yöntem Evrişimli Sinir Ağları (ESA) modelidir. Modern ESA algoritmasının kökeni 1998'e dayansa da [10], ESA 2012 yılında ImageNet yarışmasında önerilen AlexNet [1] mimarisi ile meşhur hale gelmiştir. AlexNet sonrasında sırasıyla, VGG16 [2], GoogleNet [3], ResNet [4] ve Xception [5] ağları sunulmuştur.

ESA düşük seviyeli özelliklerden yüksek seviyeli özellikleri öğrenirken, öğrendiği özelliklerin birbirine karşı göreceli konumlarını dikkate almamaktadır. Buna çözüm olarak Kapsül Ağları [11] önerilmiştir.

Beyin MR görüntüleri üzerinde yapay zekâ ile yapılan çalışmaların geçmişi sadece son birkaç yıla dayanmakta olup özellikle 2017'den sonra bu çalışmaların yoğunluk kazanmaya başladığı görülmektedir. Gliomas derecelerini sınıflandırmak için yapılan bir çalışmada [12] bir ESA önerilmiştir. Önerilen ESA mimarisini şekillendiren parametreleri ise Genetik Algoritma (GA) ile optimize ederek açık veri setleri üzerinde yaptıkları

değerlendirme sonucunda %90,9 oranında çoklu sınıflandırma kesinliği elde edilmiştir. Normal vakalarla 4 farklı beyin hastalığı vakalarını (cerebrovascular, inflammatory, degenerative, neoplastic) sınıflandıran bir çalışmada [13] Fourier dönüşüm yöntemiyle elde edilen nitelik vektörü Adaboost ile T2 ağırlıklı MR görüntüleri üzerinde eğitilerek, 10-kat çapraz doğrulama ile %98 civarında genel sınıflandırma kesinliği elde edilmiştir. 4 farklı beyin tümörünün (granuloma, meningioma, metastasis, glioblastoma) sınıflandırma ve lokalizasyonu için yapılan diğer bir çalışmada [14] makine öğrenmesi teknikleri kullanılmıştır. Bu kapsamda tespit edilen tümör bölgesinden 86 nitelik çıkarımı yapılarak Random Forest algoritmasıyla %96-%98 arasında değişen özgüllük (specificity) performansı elde edilmiştir. Diğer bir çalışmada normal beyin ve 4 farklı beyin hastalığını sınıflandırmak için bir U-net ağı önerilmiştir [15]. CombiRx veri seti üzerinde Dice benzerlik katsayısı ölçütünü kullanarak %85-%97 arasında değişen performans değerleri elde edilmiştir. Bu çalışmalara benzer şekilde sınıflandırma üzerine çok sayıda çalışma bulunmaktadır [16-27].

Sınıflandırma haricinde lokalizasyon üzerine de çalışmalar bulunmaktadır [28-34] üzerine yoğunlaşmaktadır. Beyin tümör bölgesinin tespiti için yapılan bir çalışmada [28] ise bir ESA tasarlanarak eğitimde 2-fazlı ağırlıklı metot isminde bir yöntem önerilmiştir. Açık kaynak kıyaslama veri setleri üzerinde benzer çalışmalara göre daha iyi sonuçlar alındığı belirtilmiştir. Başka bir çalışmada optimal eşik değeri ve Markov rastgele değer yaklaşımı kullanılarak tümör bölgesinin konumunu tespit eden bir metot sunulmuştur [29]. T1 ve T2 ağırlıklı görüntüler üzerinde %88-%98 arasında değişen özgüllük performansı elde edilmiştir. MR görüntülerinde lezyon seviyesinde tümör lokalizasyonu ve tespiti gerçekleştirilen çalışmada [30] ise resim ön-işleme tekniklerinin ardından tespit edilen bölgeden desen, şekil ve yoğunluk bilgilerini içeren nitelikler elde edilerek farklı DVM modelleriyle açık kaynak kıyaslama veri setleri ve yerel veri setleri üzerinde çapraz doğrulamalar yapılarak %98 civarında özgüllük değerine ulaşılmıştır. Görüntü seviyesindeki analizlerde gri-seviyeli formata dönüştürme sonrası eşik değer yöntemiyle bölge tespiti yapılırken, lezyon seviyesindeki analizlerde LAB renk formatına dönüştürme sonrası K-ortalama kümeleme (K=3) algoritması kullanılmıştır. Diğer bir çalışmada, MR görüntüleri üzerinde Bayesian bulanık kümeleme yöntemiyle tümör bölgesi tespit edilerek bu bölgeden çıkartılan niteliklerle Çoklu-Destek Vektör Sinir Ağı modeli eğitilmiştir [31]. Modelin ağırlık değerleri Harmony arama ve Crow arama algoritmalarının birleşiminden faydalanılarak önerilen algoritmayla optimize edilmiştir. Model eğitilirken T1, T2, T1C ve

Flair görüntülerin tamamından faydalanılmış olup kıyaslama veri seti üzerinde %96 civarında hassasiyet değeri elde edilmiştir. Çoklu-Destek Vektör Sinir Ağı algoritması, K-EYK, Sinir Ağları gibi algoritmaların yansira benzer çalışmalardaki kullanılan yöntemlere göre hassasiyet değeri açısından daha başarılı sonuç yakalayabilmiştir. Başka bir çalışmada, T1, T1C, T2 ve flair görüntüler kullanılarak her bir vokselle için Maksimum arka olasılığı etiketi atanmış ve problem optimum olasılık tahminini yapmaya dönüştürülmüştür [32]. Açık kaynak kıyaslama veri seti üzerinde 5 sınıflı sınıflandırma gerçekleştirilmiş olup performans değerlendirmesinde önerilen bu yöntem veri seti üzerinde 2. en iyi sonucu yakalayabilmiştir.

T1C ağırlıklı MR görüntülerinin 5 farklı kategoride sınıflandırıldığı bir çalışmada [33] öncelikle tümör bölgesi tespit edilmiş olup sonrasında 7 farklı yöntemle toplamda 71 nitelikten oluşan bir set elde edilmiştir. Daha sonra GA ile nitelik setinden seçim yapılarak girdi vektörü elde edilmiş ve buna göre DVM ve YSA algoritmalarıyla sınıflandırma modelleri eğitilmiştir. 448 görüntüden oluşan lokal bir veri setiyle, 260 görüntüden oluşan başka bir veri seti üzerinde yapılan deneysel çalışmalarda %94'e ulaşan genel sınıflandırma performansı elde edilmiş olup, GA ile nitelik seçiminin, performansı önemli oranda artırdığı görülmüştür. Başka bir çalışmada GBM için bilgisayar destekli tespit sistemi önerilmiştir [34]. T1, T2, T1C ve Flair MR görüntülerinin tamamı kullanılarak öncelikle ESA modelleriyle MR görüntüsünde tümör olup olmadığı tespit edilmekte, tümör olması durumunda ise farklı bir ESA modeli ile tümör bölgesini içeren dikdörtgenin koordinatları (4 parametre) belirlenmektedir. Son aşamada ise koordinatları belirlenen dikdörtgen alan içerisinde GrowCut yöntemiyle tümör bölgesinin tespiti gerçekleştirilmektedir. Sınıflandırma performansını değerlendirmek için Alıcı İşletim Karakteristiği (AİK) eğrisi alanı, kesinlik, hassasiyet ve özgüllük kullanılırken, tespit performansı için Mutlak hata ortalaması ve Dice katsayısı kullanılmıştır. Açık kaynak bir kıyaslama veri seti üzerindeki deneysel çalışmalarda sınıflandırma için %98 üzerinde AİK eğrisi alanı elde edilirken segmentasyon için %86 civarında Dice değeri elde edilebilmiştir.

Literatürde, beyin MR görüntülerindeki tümör tiplerinin sınıflandırılmasına yönelik çalışmaların [16-27,30,35-40] sayısı artmaktadır. Bu çalışmaların genellikle 3 farklı tümör tipine ait 3064 MR görüntüsünden oluşan CE-MRI veri seti üzerinde gerçekleştirildiği görülmektedir [17]. Bu çalışmada tümör bölgesinin yeri tespit edilerek bu bölgeler üzerinde veri artırma yöntemi uygulanmış, elde edilen nitelik seti ve DVM kullanılarak

sınıflandırma gerçekleştirilmiş ve %91,12 sınıflandırma kesinliği elde edilmiştir. CE-MRI veri seti üzerinde GoogleNet ile DVM mimarisi ve transfer öğrenme tekniği kullanılarak yapılan çalışmada [22] %97,9 sınıflandırma kesinliği elde edilmiştir. VGG19 mimarisi ve transfer öğrenme tekniği kullanılarak yapılan çalışmada [27] ise CE-MRI veri seti üzerinde %94,8 sınıflandırma kesinliğine erişildiği görülmektedir. Diğer bir çalışmada [37] nitelik mühendisliği için hibrit bir yöntem kullanılmış ve CE-MRI veri seti üzerinde %92,6 sınıflandırma kesinliği elde edilmiştir.

Literatürde bazı çalışmaların CE-MRI 5-kat çapraz doğrulama indislerini kullanmak yerine rastgele oranlarda eğitim verisi belirleyerek önerdikleri modellerin sınıflandırma performansını değerlendirdiği görülmektedir [19-20,24,26,36,37]. İstatistiksel nitelikler ve YSA kullanılarak CE-MRI veri setinin %70'i üzerinde gerçekleştirilen eğitim sonucunda %91,9 sınıflandırma kesinliği elde edilmiştir [19]. CE-MRI veri setinin %70'i eğitimde kullanılarak ESA çıktılarını girdi olarak alan Ekstrem öğrenme makineleri ile yapılan çalışmada [20] %93,7 sınıflandırma kesinliği yakalanabilmiştir. ESA kullanılarak CE-MRI veri setinin yaklaşık %70'i üzerinde eğitim gerçekleştirilen bazı çalışmalarda ise %96,1 sınıflandırma kesinliği [26] ve %94,4 sınıflandırma kesinliği [36] elde edildiği görülmektedir. Yine CE-MRI veri setinin %70'i eğitimde kullanılarak VGG16 ve VGG19 mimarileri kullanılarak yapılan bazı çalışmalarda [24-25] ise sırasıyla %98,7 ve %94,6 sınıflandırma kesinliğine ulaşıldığı anlaşılmaktadır. CE-MRI veri seti üzerinde eğitilen Xception modeliyle [35] %68,6 sınıflandırma kesinliği elde edilirken Kapsül Ağları modeliyle ise %86,7 sınıflandırma kesinliğine erişildiği görülmektedir [21]. Bazı modellerin eğitilmesinde sadece axial MR görüntülerinin kullanıldığı [18] ve bu durumda ESA ile %91 sınıflandırma kesinliği yakalanabildiği anlaşılmaktadır.

CE-MRI veri seti haricinde Kaggle'da paylaşılan bir beyin MR görüntüleri veri setini kullanan bazı sınıflandırma çalışmaları da mevcut olup [38-39] bu çalışmalarda derin öğrenme modelleriyle %96 üzerinde ikili sınıflandırma kesinliği elde edilebilmiştir. Yüksek ve düşük dereceli glioma sınıflandırması yapılan bir çalışmada [40] GoogleNet ve AlexNet modelleri ve transfer öğrenme ve veri artırma teknikleri de kullanılarak 113 vakaya ait MR görüntüleri üzerinde deneysel çalışmalar yapılmıştır. Sonuçta GoogleNet üzerinde transfer öğrenme ile %94,5 sınıflandırma kesinliği elde edilmiştir.

Literatürde öne çıkan çalışmalardan bazıları aynı zamanda Çizelge 2.1’de özetlenmiştir. Çizelge 2.1’den de görüleceği üzere çalışmaların daha çok tümör tiplerinin tespiti ve sınıflandırılması üzerine yoğunlaştığı, 2018 öncesinde geleneksel makine öğrenmesi yöntemleri sıklıkla kullanılırken 2018’den itibaren Kapsül ağları gibi yeni yöntemlerin de beyin tümörlerinin tespitinde kullanılmaya başlandığı ve son zamanlarda kompleks derin öğrenme mimarilerinin yoğunlukla tercih edildiği görülmektedir.

Çizelge 2.1. Literatür özeti

Ref.	Yıl	Konu	Algoritma
[17]	2015	Tümör tiplerinin sınıflandırılması	DVM
[33]	2016	Tümör bölgesinin tespiti ve sınıflandırılması	DVM + YSA
[14]	2016	Tümör tiplerinin sınıflandırılması ve lokalizasyonu	Random Forest
[29]	2016	Tümör bölgesinin tespiti	Markov model
[13]	2016	Beyin hastalıklarının sınıflandırılması	Adaboost
[18]	2016	Tümör tiplerinin sınıflandırılması	ESA
[30]	2017	Tümör bölgesinin tespiti ve sınıflandırılması	DVM
[31]	2018	Tümör bölgesinin tespiti ve sınıflandırılması	DVM
[15]	2018	Beyin hastalıklarının sınıflandırılması	U-net ağı
[34]	2018	Tümör tespiti ve lokalizasyonu	ESA + Growcut
[28]	2018	Tümör bölgesinin tespiti	ESA
[19]	2018	Tümör tiplerinin sınıflandırılması	YSA
[21]	2018	Tümör tiplerinin sınıflandırılması	Kapsül Ağı
[25]	2018	Tümör tiplerinin sınıflandırılması	VGG19
[20]	2018	Tümör tiplerinin sınıflandırılması	ESA
[24]	2019	Tümör tiplerinin sınıflandırılması	VGG16
[35]	2019	Tümör tiplerinin sınıflandırılması	Xception ve diğer.
[22]	2019	Tümör tiplerinin sınıflandırılması	GoogleNet + DVM
[26]	2019	Tümör tiplerinin sınıflandırılması	VGG19
[12]	2019	Tümör tiplerinin sınıflandırılması	ESA
[41]	2019	İçerik tabanlı sorgulama	VGG19
[23]	2019	Tümör tiplerinin sınıflandırılması	ESA
[38]	2020	Tümör varlığının tespiti	ESA
[39]	2020	Tümör varlığının tespiti	ESA

Bu çalışmaların yanı sıra içerik tabanlı görüntü sorgulamaya yönelik bazı çalışmalar da literatürde mevcuttur [41-42]. GBM tümörlerine ilişkin çalışmalar sadece sınıflandırma veya segmentasyon ile sınırlı olmayıp derin öğrenme yöntemleriyle çok farklı analizler de

literatürde bulunmaktadır. Örneğin GBM tümörü tespit edilen vakalara biçilen ortalama ömür süresinin tahmin edilmesinde nitelik mühendisliğinin yanı sıra transfer öğrenme ile derin nitelik çıkarımı da yapılarak tahmin performansının artırıldığı bilinmektedir [43]. Beyin MR görüntülerinden anormalliklerin otomatik olarak tespit edilmesinin pek çok avantajı vardır. Bilgisayar destekli yöntemlerin klinik olarak teşhis hatalarını azalttığı bilinmektedir [44-45]. Ayrıca bu algoritmalar, daha tutarlı sonuçlar üretmekte olup farklı zamanlarda farklı kararlar verme sorununa daha az maruz kalmaktadırlar [46].

3. MATERYAL VE METOT


Beyin tümörlerinin manuel tespitinde MR görüntüleri etkin bir şekilde kullanılmaktadır. Probleme çözüm olarak ise MR görüntülerinden beyin tümörünün yapay zekâ ile otomatik tespit edilip ilgili hekimin anında bilgilendirileceği ve böylece acil müdahalede bulunabilmesini sağlayacak bir sistem tasarlanmaktadır. Bu bölümde MR görüntüleme ve MR görüntülerinden oluşan veri setleri hakkında bilgilerin yanı sıra probleme uygulanan, uyarlanan ve esas alınarak üzerine yeni yöntemlerin geliştirildiği yapay zekâ teknikleri hakkında bilgiler sunulmaktadır.

3.1. MR Görüntüleme ve Veri Setleri

MR görüntüleri, MR cihazları tarafından farklı düzlemelerde ve farklı tiplerde çekilebilen ve beyin tümörlerinin de tespitinde etkin bir şekilde kullanılan görüntülerdir. Buna ilişkin detaylar ile MR görüntülerinden oluşan veri setlerine ilişkin bilgiler takip eden bölümlerde sunulmuştur.


3.1.1. MR görüntüleme

Beyin tümörlerinin tespitinde MR görüntüleme etkili bir şekilde kullanılmaktadır. MR görüntüleme ile beyin anatomisinin detayları üç farklı düzlemde görselleştirilmiş olup, Şekil 3.1’de axial, coronal ve sagittal MR görüntü düzlemlerine örnek verilmiştir. MR görüntü serileri T1 ağırlıklı, T1C ağırlıklı, T2 ağırlıklı ve Flair olmak üzere 4 temel tipte olabilmektedir. Beyin hastalıklarının tespitinde T1C ve T2 ağırlıklı görüntüler sıklıkla kullanılmaktadır.



Şekil 3.1. Mr görüntü düzlemleri

T2 ağırlıklı beyin MR görüntüleri tümör bölgesinin belirgin bir şekilde ortaya çıkarılmasında oldukça başarı sonuçlar vermekte olup, MR görüntüleme öncesi hastaya damar yoluyla ilaç verilmesine gerek olmaması da işlem zorluğu ve maliyeti azaltması açısından önemli bir avantaj sağlamaktadır.



Resim 3.1. Normal ve gbm için t2 ağırlıklı mr görüntüleri a) normal b) gbm c) gbm

Resim 3.1’de hem normal hem de GBM vakası için T2 ağırlıklı beyin MR görüntüleri verilmektedir. Resim 3.1 (b)’de verilen MR görüntüsünde tümör bölgesi daha parlak renkte mavi dikdörtgen içinde işaretlenmiştir. Resim 3.1 (c)’de verilen MR görüntüsü de GBM vakasına aittir ancak burada belirgin bir tümör bölgesi görülmemektedir.




Resim 3.2. Farklı düzlemlerde mr görüntü örnekleri a) axial b) coronal c) sagittal [17]

Resim 3.2’de ise farklı düzlemlerde çekilmiş MR görüntü örnekleri yer almaktadır. Bu görüntülerden de anlaşılacağı üzere coronal ve sagittal görüntüler boyun, boğaz ve yutak gibi beyin harici organları da içermekte olup bu durum gürültünün artmasına ve

sınıflandırma kesinliğinin azalmasına neden olabilir. Axial görüntüler ise sadece beyin bölgesini içermekte ve daha homojen bir desene sahip olduğundan sadece bu görüntülerin, probleme özel modellerin eğitilmesinde kullanılmasının sınıflandırma kesinliğini artırması beklenir. Bu hipotezimize yönelik analiz sonuçları sonraki bölümlerde yer almaktadır.

GBM, erişkinlerde en sık rastlanılan tümör çeşidi olup değişken şekli nedeniyle tespiti en zor tümör çeşitleri arasındadır. Radyologlar, T2 ağırlıklı MR görüntü serilerini inceleyerek GBM teşhisi koyabilmektedirler. Bu çalışmada kullanılan T2 ağırlıklı MR görüntü serileri genelde 20'şer görüntüden oluşmakta, S0-S19 arasında ardışık olarak numaralandırılmaktadır. GBM vakasına ait T2 ağırlıklı MR serisindeki her bir görüntü, belirgin bir şekilde tümör içermek zorunda değildir. Resim 3.3' (a) ve (b)'de sırasıyla normal vaka ve GBM hastası için örnek T2 ağırlıklı MR görüntü serisi verilmektedir:



Resim 3.3. T2 mr görüntü serisi a) normal b) gbml


Radyologlar, Resim 3.3'de verilen beyin MR görüntülerinden her birini sırasıyla incelemekte, görüntülerin en az birinde GBM teşhisini sağlayacak beyaz lezyon görebilirlerse bu teşhisi koyabilmektedirler. Örneğin Resim 3.3 (b)'de MR görüntü serisindeki bazı görüntülerde beyaz lezyon bulunmaktadır. Bu örnekte olduğu gibi bazı MR görüntülerinin beyaz lezyon içermesi GBM teşhisi konmasına yardımcı olan belirtilerden en önemlisidir.

3.1.2. Veri setleri


Tez çalışmalarının deneysel çalışmaları kapsamında 3 farklı veri seti (Set#1; Set#2; Set#3) kullanılmıştır. Set#1 ve Set#2 yapılan çalışmaları mevcut literatür çalışmalarıyla karşılaştırmak için kullanılan veri setlerini , Set#3 ise çalışma kapsamında oluşturulan lokal veri setini ifade etmektedir. Veri setlerine ilişkin ayrıntılı bilgiler aşağıdaki bölümlerde anlatılmaktadır.

Set#1: ce-mri veri seti

Bu veri seti 2005-2010 yılları arasında Çin’de 233 farklı vakadan toplanmış, axial, coronal ve sagittal tipinde, meningioma, glioma ve pituitary tümörlerini içeren toplam 3064 MR görüntüsünden oluşmaktadır [17]. Veri setindeki axial, coronal ve sagittal tipine ilişkin örnekler sırasıyla Resim 3.4’de sunulmuştur. Veri setindeki farklı tümör tiplerine ilişkin örnekler ise sırasıyla Resim 3.5’de yer almaktadır. Veri seti Matlab formatında paylaşılmıştır.



Resim 3.4. Mr görüntü örnekleri a) axial b) coronal c) sagittal [17]



Resim 3.5. Beyin tümör tipleri a) meningioma b) glioma c) pituitary [17]

Matlab formatındaki dosyalarda, 512x512 boyutundaki görüntülerin yanı sıra, tümör bölgesinin koordinatları ve sonuçların birebir karşılaştırılması için 5-kat çapraz doğrulamada kullanılan indeksler de sağlanmıştır. Bunu yaparken bir hastaya ait görüntüler 5 doğrulama alt kümesinin sadece bir tanesinde bulunacak şekilde veri seti ayrıştırılmıştır. Veri setinin tümör, görüntü ve vaka sayılarına göre dağılımı Çizelge 3.1’de verilmiştir.

Çizelge 3.1. Ce-mri veri seti özeti

Tümör Tipi	Vaka sayısı	Görüntü Tipi			Toplam
		Axial	Coronal	Sagittal	
Meningioma	82	208	269	231	708
Glioma	89	494	437	495	1426
Pituitary	62	291	319	320	930
Toplam	233	993	1024	1046	3064

Literatürdeki çalışmaları incelediğimizde bu konuda üzerinde çalışılabilecek kısıtlı sayıda veri seti olduğu görülmektedir. BRATS 2013 ve BRATS 2015 veri setleri tümör bölgesinin segmentasyonu çalışmalarında kullanılırken, sınıflandırmaya yönelik az sayıdaki çalışmada ise Harvard, RIDER [30] ve Kaggle [38-38] veri setleri kullanılmıştır. CE-MRI veri seti ise kolayca erişilebilmesi ve benzer veri setlerine göre çok daha fazla vaka ve görüntü içermesi açısından birçok çalışmada kullanılmıştır [17-27,35-37]. Bu tez çalışmasında da hem vaka çeşitliliği, hem görüntü sayısı, hem tümör tipi çeşitliliği hem de görüntü düzlemi çeşitliliği açısından problem uzayındaki konuların hepsinin birden test edilmesine olanak sağladığından CE-MRI veri seti tercih edilmiştir.

Set#2: ce-mri veri seti eksen görüntü alt kümesi


Bu veri seti sadece eksen görüntüler üzerinde tümör sınıflandırması yapılması durumunda daha iyi sonuçlar alınabileceğine ilişkin hipotezimize yönelik olarak CE-MRI kıyaslama veri setinin eksen görüntü alt kümesinden hazırlanmış olan veri setini ifade etmektedir. Çizelge 3.1’de görüldüğü üzere Meningioma için 208, Glioma için 494 ve Pituitary içinse 291 olmak üzere CE-MRI veri setinde 993 eksen MR görüntüsü yer almaktadır. Bu MR görüntüleri coronal ve sagittal görüntülerde olduğu gibi beyin harici bölgeleri içermeyen görüntüler olup bunlar da ayrı bir veri seti haline getirilerek deneysel çalışmalarda kullanılmıştır.

Set#3: lokal veri seti

Bu veri seti Gazi Üniversitesi Tıp Fakültesi Beyin Cerrahisi Anabilim Dalındaki çalışmalar kapsamında 114 normal, 65 GBM olmak üzere toplam 179 vakanın her biri için 20 sekans olmak üzere toplam 3580 T2 ağırlık MR görüntüsünden oluşmaktadır. Gazi Üniversitesi Tıp Fakültesi Beyin Cerrahi bölümü uzmanları 3580 görüntünün her birini analiz ederek vakanın normal veya GBM olduğuna karar vermişlerdir. Buna göre öncelikle her bir vakaya ait 20 MR görüntüsü sırasıyla incelenmiş, belirgin beyaz lezyon içeren görüntüler GBM tümörlü görüntü olarak etiketlenirken, GBM tümörü içeren en az bir kesit bulunan T2 ağırlıklı MR görüntü serisindeki her bir görüntü ise GBM vakasına ait görüntü olarak etiketlenmiştir. GBM vakasına ait T2 ağırlıklı MR serisindeki her bir görüntü belirgin bir şekilde tümör içermek zorunda değildir. 65 GBM vakasına ait 1300 MR görüntüsünün 649 tanesinde belirgin tümör olduğu ancak 651 tanesinin tümör içermeyen normal görüntülere benzediği uzman beyin cerrahları tarafından tespit edilmiştir. Sonuç olarak LOKAL veri setinde normal vakaya ait 2280, GBM vakasına ait 1300, tümör içeren 649 ve belirgin tümör içermeyen 2931 örnek yer almaktadır. Tez çalışmasında kullanılan LOKAL veri seti Gazi Brains 2020 veri seti çalışmalarının da temelini oluşturmaktadır.

3.2. Makine Öğrenmesi ve Derin Öğrenme Algoritmaları ve Yapıları

Yapay zekâ son yıllarda oldukça popüler hale gelmiş olsa da aslında geçmişi 1950’li yıllara kadar gitmektedir. Yapay zekâ kavramıyla birlikte makine öğrenmesi ve derin öğrenme de sıklıkla kullanılmaktadır. Bunları arasındaki ilişki Şekil 3.1’de gösterilmektedir:



Şekil 3.2. Yapay zekâ - derin öğrenme ilişkisi

Şekil 3.2’den de anlaşılacağı üzere makine öğrenmesi yapay zekânın, derin öğrenme ise makine öğrenmesinin bir alt dalıdır. Bu hususlar takip eden bölümlerde detaylı olarak açıklanmıştır.

3.2.1. Geleneksel makine öğrenmesi algoritmaları ve yapıları

Geleneksel makine öğrenme algoritmaları, özellikle tabular veri setleri üzerinde başarılı sonuçlar veren algoritmalar [6-7]. Bu algoritmaları, yapay zekâ modellerini eğitmede kullanmak için *nitelik mühendisliği* yapılması, girdi-çıktı vektörlerinin tasarlanması, uygun yapıların hem oluşturulması hem de seçilmesi gerekmektedir. K-EYK, LR, DVM, KA gibi algoritmaların yanı sıra 2017’den sonra özellikle Kaggle yarışmalarında popüler hale gelen LightGBM ve XgBoost algoritmaları bu kapsamda sıklıkla kullanılan algoritmalar. Bilgi kazanımı hesaplamasında küçük eğilimleri dikkate almayarak modelin eğitilmesini hızlandıran LightGBM ile son dönemde popüler olan XgBoost algoritmaları da bu tez kapsamında kullanılan geleneksel makine öğrenmesi algoritmalarıdır. Bu tür algoritmalarının çalışması için, GİÜ destekli donanım kullanımı zorunluluğu yoktur. Bu çalışma kapsamında, Python Sci-kit Learn [47], Pandas [48], Matplotlib [49], XgBoost [50] ve LightGBM [51] kütüphaneleri kullanılmıştır. Takip eden alt başlıklarda, literatürde sıklıkla kullanılan ve bu tez kapsamında yapılan çalışmalarda da faydalanılan geleneksel makine öğrenmesi algoritmaları kısaca tanıtılmış ve özetlenmiştir:

Karar ağaçları

Karar ağaçları, en başarılı danışmanlı sınıflandırma algoritmaları arasında yer almakta ve karar düğümleri ve yapraklardan oluşmaktadır [52]. Karar düğümleri bölünmenin gerçekleştiği nitelikleri, yapraklar ise sınıflandırma sonucunu temsil etmektedir. Hangi düğümden bölünme gerçekleşeceği Eş. 3.1’de ifadesi verilen Gini indeksine [53] göre hesaplanmaktadır.

$$\text{Gini İndeks} = 1 - \sum_{k=0}^n P^2 \quad (3.1)$$

Burada n farklı sınıf sayısını, P ise sınıfa ait olma olasılığını ifade etmektedir. Karar ağaçları sürekli değere sahip niteliklerle çalışmadıklarından, sürekli veriler kategorik

veriye dönüştürülmekte ve aşırı öğrenme problemine maruz kalabilmektedir. Buna çözüm olarak MAM'lar [54] önerilmiş olup eğitim sürecinin her aşamasında farklı bir ağaç eğitilerek hatanın minimize edilmesi amaçlanmıştır.

K-en yakın komşuluk

K-En Yakın Komşuluk algoritması veri örneklerinin benzerliğini hesaplayarak çalışan ve parametrik olmayan bir algoritmadır. K-EYK algoritması işleminin her aşamasında tüm eğitim verisi üzerinde mesafe hesabı yapılması gerekmektedir. En yaygın kullanılan mesafe ölçütü Öklid mesafesi [55] olup Eş. 3.2'de verilmiştir.

$$d(x, y) = \sqrt{\sum_{i=1}^n x_i^2 - y_i^2} \quad (3.2)$$

K-En Yakın Komşuluk algoritmasında sırasıyla aşağıdaki işlemler gerçekleştirilmektedir.

1. Eğitim setindeki her bir örnekle aradaki mesafe ölçülür.
2. Ölçülen mesafelere göre örnekler sıralanır.
3. İlk K örneğin çoğunluğu hangi sınıfa ait ise bu sınıf etiketi sonuç olarak dönülür.

Lojistik regresyon

Lojistik Regresyon algoritması, isminde regresyon olmasına karşın danışmanlı sınıflandırma algoritmalarından olup başarılı sonuçlar vermektedir [56-57]. Sınıflandırma işleminde hedef sınıfa ait olma olasılığını tahmin etmektedir. Sigmoid fonksiyonun formülü [58] Eş.3.3'de yer almaktadır.

$$\theta = \frac{1}{1 + e^{-z}} \quad (3.3)$$


Lojistik Regresyon $z = a + bX$ şeklinde doğrusal bir fonksiyonda X bağımlı değişkeniyle b faktörü arasındaki ilişkiyi tespit etmektedir [56]. Buna göre Lojistik Regresyon yönteminin genel formülasyonu;

$$P = \frac{e^{a+bX}}{1 + e^{a+bX}} \quad (3.4)$$

olmaktadır [56]. Sigmoid fonksiyonu 0-1 arasında bir değer aldığından P değeri sınıflandırma sonucunda tahmin edilen etiket olasılığını verecektir.

Destek vektör makinaları

Destek Vektör Makineleri, derin öğrenme algoritmaları popüler hale gelmeden önce en etkin sonuçların alınabildiği bir sınıflandırma ve regresyon algoritmasıdır. Bazı sınıflandırma problemlerinde derin öğrenme kadar performans elde edebilirken aynı zamanda işlem süresini önemli ölçüde azalttığından, halen etkin bir şekilde kullanılmaktadır [6].




Şekil 3.3. Dvm doğrusal dağılım örneği

Şekil 3.3’de ok ile gösterilen siyah ve kırmızı örnekler destek vektörlerini, ortadaki örnek sınıflarını ayırt eden çizgi ise karar sınırını ifade etmektedir. DVM algoritmasının amacı sınıflandırmayı en iyi sağlayan karar çizgisini tespit etmektir. Bunun için de karar çizgisine en uzak destek vektörlerinin bulunup her örneğin kendi sınıfına ait bölgede kalma problemini optimize eder. Bunun için Eş. 3.5’de verilen optimizasyon işlemi gerçekleştirilmektedir [59]:


$$\text{minimize } \frac{1}{2} w \cdot w + C \sum_{i=1}^n \xi_i \quad (3.5)$$

Burada w düzlem oryantasyonunu belirleyen vektörü, ξ_i ise her bir veri örneğini ifade etmektedir. Her problemde veri dağılımı doğrusal olmayabilir. Şekil 3.4’de buna bir örnek verilmiştir:



Şekil 3.4. Dvm doğrusal olmayan dağılım örneği

Bu durumda ise veri örneklerine yeni bir boyut eklenerek sınıflandırma yapılmaktadır [60]. Yeni durumda veri örneklerinin dağılımı Şekil 3.5’de verilmiştir.



Şekil 3.5. Dvm yeni boyut ekleme örneği

Bu durumda, DVM algoritması Şekil 3.5’deki açık mavi ile gösterilen optimum ayırt edici düzlemin bulunmasına katkı sağlar.

Xgboost algoritması

XgBoost algoritması [9], MAM tabanlı Karar Ağaçları algoritmasının bir alt türü olup Kaggle yarışmalarında en iyi performans gösteren sınıflandırma algoritmalarındandır. Karar ağaçlarında her bir yaprak için en iyi bölünmeyi bulurken veri setindeki her bir örneğin her bir niteliği üzerinde işlem yapmak gerekecektir. N_{ϕ} örnek sayısını, N_n her bir örnekteki nitelik sayısını göstermek üzere, en iyi bölünmeyi bulma işleminin zaman karmaşıklığı $O(N_{\phi} \cdot N_n)$ olmaktadır.

Büyük veri setlerinde bu durum öğrenme süresini oldukça uzatmaktadır. XgBoost algoritması seyrek veriyi dikkate almayarak bu süreyi önemli ölçüde kısaltmaktadır.

Ayrıca karar ağaçlarının öğrenme süresini uzatan en önemli unsur verinin sıralanmasıdır. Buna çözüm olarak XgBoost algoritmasında blok ismi verilen bellek üniteleri kullanılmakta, buna göre blok içindeki veriler sıkıştırılmış formatta saklanmaktadır [9].

Lightgbm algoritması

LightGBM algoritması [8], XgBoost benzeri bir algoritma olup Microsoft tarafından 2017 yılında geliştirilmiştir. Sınıflandırma performansından taviz vermeksizin eğitim süresini kısaltmayı amaçlayan bu yaklaşım, Kaggle yarışmalarının popüler algoritması olmayı başarabilmiştir. LightGBM algoritması da XgBoost gibi MAM'ların bir alt türü olup, ağacın büyüme stratejisi olarak seviye esas yerine yaprak esasına göre işlem yapmaktadır.

LightGBM algoritması, temel olarak küçük veri kazanımı sağlayan veri örneklerini işleme dahil etmeme ve küçük veri kazanımı sağlayan nitelikleri ise birleştirme yöntemleriyle farklılık sağlamaktadır. Bunun için meyil temelli tek taraflı örnekleme gerçekleştirilmektedir. Buna göre varyans kazanımı daha küçük boyutta bir örnek kümesinde tahminen hesaplanmakta böylece işlem süresi azalmaktadır. Bu tahminlemede oluşan hata Eş. 3.6'da verilmektedir.

$$\epsilon(d) = |v_j^{\sim}(d) - v_j(d)| \quad (3.6)$$


Burada $v_j^{\sim}(d)$ alt örnek kümesindeki tahmini varyans kazanımını $v_j(d)$ ise tüm örneklerdeki varyans kazanımını ifade etmektedir. LightGBM algoritması meyil temelli tek taraflı örnekleme yöntemi sayesinde sınıflandırma kesinliğinden taviz vermeden işlem hızını artırabilmektedir. Bu avantajları nedeniyle son dönemdeki Kaggle yarışmalarında başarıyla uygulanarak ön plana çıkmaktadır.

3.2.2. Derin öğrenme algoritmaları ve yapıları

Bu bölümde öncelikle çok katmanlı yapay sinir ağlarına değinilmiş sonrasında ise derin öğrenme algoritmaları ve yapıları kapsamında sırasıyla evrişimli sinir ağları ve son yıllarda derin öğrenme kapsamında yeni bir teknoloji olarak popüler hale gelmeye başlayan kapsül ağları tanıtılmaktadır.

Yapay sinir ağıları

Yapay sinir ağıları konusundaki çalışmalar 1950’li yıllarda algılayıcı (perceptron) ile başlamıştır. Algılayıcı modeli Şekil 3.6’da verilmektedir:



Şekil 3.6. En basit algılayıcı (perceptron) modeli


Algılayıcı modelinde tek nöron bulunmakta ve girdi değeri bir ağırlık ile çarpılarak önyargı (bias) değerine eklenmektedir. Oluşan bu toplam değer ise bir aktivasyon fonksiyonuna verilerek çıktı üretilir. Aktivasyon fonksiyonu olarak genelde Eş. 3.7’de verilen sigmoid fonksiyonu, Eş. 3.8’de verilen tanjant fonksiyonu [61] veya Eş. 3.9’da verilen Relu fonksiyonu [61] kullanılmaktadır. Bunlar;

$$\text{Sigmoid} = \frac{1}{1 + e^{-z}} \quad (3.7)$$

$$\text{Tanjant} = \frac{e^z - e^{-z}}{e^z + e^{-z}} \quad (3.8)$$

$$\text{Relu} = \max(0, z) \quad (3.9)$$


Algılayıcı modelinin genelleştirilmiş hali Şekil 3.7’de verilmiştir.



Şekil 3.7. Algılayıcı genel modeli

Bu şekilde verilen değerler, $X = [X_1, X_2 \dots X_n]^T$, $W = [W_1, W_2 \dots W_n]^T$ olmak üzere, $f = X^T.W + b$ olarak verilebilir.

Algılayıcı modeli, XOR problemini çözemeyince yapay zekâ çalışmaları 1980'li yıllara kadar sekteye uğramış ancak saklı katman mimarisinin önerilmesiyle bu problem de çözülmüştür. Saklı katmanlar içeren tam bağlantılı bir yapay sinir ağı modeli Şekil 3.8'de verilmiştir:



Şekil 3.8. Çok katmanlı yapay sinir ağı

Çok katmanlı yapay sinir ağları öncelikle nitelik mühendisliğiyle girdi vektörü tasarlanmasını gerektirmektedir. Bununla birlikte girdinin bir görüntü olması durumunda girdi vektörü genelde piksel değerlerinin ardışık olarak sıralandığı bir dizi olmaktadır. Ancak bu durumda ağın eğitilmesi aşamasında piksellerin birbirine göre uzaysal pozisyonunu dikkate almadan öğrenmeye çalışmaktadır [62]. Bu ise sınıflandırma kesinliğini artıracak önemli bilgilerin kaybedilmesi anlamına gelmektedir. Ayrıca çok katmanlı yapay sinir ağlarında ara katman sayısını artırdıkça yani ağın derinliğini artırdıkça daha iyi öğrenmesi beklenirken belli bir aşamadan sonra bunun gerçekleşmediği, sınıflandırma performansının düştüğü görülmektedir. Bir sonraki bölümde anlatılan Evrişimli Sinir ağları bunlara çözümler sunmaktadır.


Evrişimli sinir ağları

Görüntü veri setlerinden oluşan problemlerde çok katmanlı yapay sinir ağlarıyla çalışırken bir önceki bölümde görüldüğü üzere görüntü matrisi vektöre dönüştürülerek ağ için girdi

oluşturulmaktadır. Örneğin 100x100 piksel boyutundaki bir görüntü 10 000 indisli bir vektör haline gelmektedir. Ancak bu durumda piksellerin birbirlerine göre göreceli konumlarına ilişkin bilgiler ile uzaysal bilgiler kaybedilmektedir. Çünkü 100x100 boyutundaki bir görüntü ile 10x1000 boyutundaki bir görüntü uzaysal olarak çok farklı olsalar da ağ açısından bakıldığında her ikisi de yapay sinir ağı için 10 000 uzunluğunda bir vektör anlamına gelmektedir.

Bir diğer konu ise, XOR probleminin ara katman eklenerek çözülmesi, diğer bir ifade ile ağı derinliğini artırarak çözüm bulunabilmesi, çok katmanlı yapay sinir ağlarında ara katman sayısını artırdıkça öğrenme performansının artması yönünde beklenti oluşturmuştur. Ancak ara katman sayısı arttıkça belli bir aşamadan sonra öğrenme performansının artmadığı görülmüştür [62]. Bunun sebebi ise, ara katman eklendikçe ağda eğitilmesi gereken ağırlık sayısının da katlamalı olarak artması olabilir.

Evrişimli Sinir Ağları, çok katmanlı yapay sinir ağlarında karşılaşılan bu problemlere çözüm üretmektedir. Filtreleme işleminde farklı filtreler kullanılarak görüntüdeki farklı özellikler öğrenilmekte, işlem esnasında uzaysal veri de kodlanmaktadır.



Şekil 3.9. Esa filtreleme işlemi


Şekil 3.9’da filtreleme işlemine örnek verilmektedir. Bu örnekte 28x28 boyutundaki bir görüntü 5x5 boyutundaki bir filtre ile sol üst köşeden başlayarak filtreleme işlemine tabi tutulmakta ve sonuçta 24x24 boyutunda bir matris elde edilmektedir. Filtreleme işlemi sonucundaki çıktı çok katmanlı yapay sinir ağlarından farklı olarak bir vektör veya sayısal değer değil, yine bir matris olmakta, böylece uzaysal veri korunmaktadır. İşlemi daha genel ifade edecek olursak, $M \times M \times D$ boyutundaki bir görüntü $N \times N \times D$ boyutundaki bir filtre ile her seferinde S piksel kayarak bir evrişim işlemine tabi tutulursa sonuçta oluşacak

çıktının boyutu $\frac{M+2P-N+S}{S} \times \frac{M+2P-N+S}{S}$ olacaktır. Burada P değeri çıktı boyutunun aynı kalması için girdinin sağ, sol, üst ve alttan ne kadar uzunlukta 0 ile doldurulacağını göstermektedir. Filtreleme işlemi sonrasında aktivasyon fonksiyonu ise Eş. 3.10'daki gibi ifade edilmektedir

$$y = f(i \otimes w + b) \quad (3.10)$$

Burada i , $M \times M \times D$ boyutundaki görüntünün filtre uygulanan kısmını, w ise $N \times N \times D$ boyutundaki filtre ağırlık değerlerini göstermektedir. Evrişim işleminde tüm nöronlar için aynı filtre ağırlık değerleri paylaşılmaktadır. Yani filtre uygulanan her parça için farklı ağırlık değerleri kullanılmamaktadır. Bu nedenle, eğitilmesi gereken ağırlık değeri sayısı $N \times N \times D$ olmaktadır. Eğer K adet filtre uygulanacaksa bu durumda eğitilmesi gereken ağırlık parametresi sayısı $K \times N \times N \times D$ olacaktır.

Evrişimli Sinir Ağlarında diğer bir işlem ise maksimum havuzlama işlemidir. Maksimum havuzlamada girdinin genişlik ve yüksekliği düşürülmekte, derinliği değiştirilmemektedir. Girdinin uzaysal boyutunun bu şekilde azaltılması ağırlık öğrenmesinin engellenmesine yardımcı olmaktadır. Maksimum havuzlama işleminin örnek gösterimi Şekil 3.10'da verilmektedir.




Şekil 3.10. Maksimum havuzlama işlemi

Burada yine $M \times M \times D$ boyutundaki bir görüntü $N \times N \times D$ boyutundaki bir filtre ile her seferinde S piksel kayarak bir maksimum havuzlama işlemine tabi tutulursa sonuçta oluşacak çıktının boyutu $\left\lceil \frac{M-N}{S} + 1 \right\rceil \times \left\lceil \frac{M-N}{S} + 1 \right\rceil \times D$ olacaktır. Şekil 3.10'da verilen örnekte, $M=4$, $N=2$, $S=2$ ve $D=1$ için çıktının boyutu 2×2 olmuştur.


Evrişimli Sinir ağlarının son kısmında ise genelde tam bağlantılı yapay sinir ağı yapısı yer almakta olup buna ilişkin detaylar daha önce anlatıldığı için burada detay verilmemiştir.

2012 yılında Imagenet yarışması düzenlenene kadar derin öğrenme yöntemleri literatürde yer alsa bile yeterli performans sağlayamıyordu. Imagenet yarışmasına sunulan AlexNet [1] makalesinden sonra, bugün bildiğimiz haliyle derin öğrenme yöntemleri popüler hale gelmeye başladı. Imagenet yarışmasında 1000 farklı sınıfa ait görüntünün sınıflandırılması hedeflenmiştir. AlexNet makalesinde buna çözüm olarak bir Evrişimli Sinir ağı önerilmiş olup, bu modelde Top-5 hata oranı %26'dan %15'e düşürülebilmektedir. AlexNet sonrasında performansı daha da artırabilmek için VGG modeli önerilmiştir [2]. VGG Top-5 hata oranını %7,3'e kadar düşürebilmektedir. VGG AlexNet modelinden farklı olarak evrişimli katmanda 11x11 boyutundaki pencereler yerine 3x3 boyutunda pencereler kullanmış, bununla birlikte girdinin doğrusal dönüşümünü sağlayan 1x1 boyutunda filtrelerden faydalanmış ve ağı derinliğini daha da artırmıştır. GoogLeNet (Inception V1) 2014 yarışmasının kazananı olup hata oranını %6 civarına indirebilmiştir. Önceki önerilen modellerden farklı olarak 1x1 evrişimli katmanı işlem hacmini azaltmak, böylece daha derin mimariler oluşturabilmek için kullanmış olup bunun yanı sıra VGG den farklı olarak son katmanda tam bağlantılı ağ kullanmak yerine Global ortalama havuzu yapısı kullanmıştır. Modelin temelini oluşturan Inception yapısında ise farklı boyutlardaki filtreler kullanılarak girilen resimden daha farklı niteliklerin de öğrenilmesi sağlanmaktadır. Imagenet kapsamında önerilen derin öğrenme modellerinde, derinlik arttıkça öğrenme performansının azaldığı görülmektedir. Bu durum kaybolan meyiller [61] problemi olarak tanımlanmaktadır. Bu problemde daha fazla katman eklendikçe kayıp fonksiyonun meyili 0'a yaklaşmakta ve öğrenme zorlaşmaktadır. ResNet modeli, bu probleme çözüm olarak önerilmiştir. ResNet modellerinin önerdiği en önemli farklılık, Şekil 3.11'de sunulan Artık Blok yapısıdır.



Şekil 3.11. Artık blok yapısı [4]

Bu yapıların normal yapay sinir ağı yapılarından en önemli farkı, bir katmanın çıktısının, sadece bir sonraki katmana girdi olarak değil aynı zamanda 2 veya 3 sonraki katmana da girdi olarak sunulması olup bunun sınıflandırma kesinliğini önemli oranda artırdığı görülmektedir.



Şekil 3.12. Xception mimarisi [5]


ImageNet kapsamında daha birçok önemli derin öğrenme modelleri önerilmiştir. Bunlar arasında Xception modeli, Inception V3 modelinin geliştirilmiş versiyonudur. Farklı olarak her bir kanal için önce uzaysal sonra noktasal katlama operasyonu gerçekleştirilmektedir. Şekil 3.12’de Xception mimarisi yer almaktadır. Şekil 3.12’deki modüller soldan sağa doğru, giriş akışı, orta akış ve çıkış akışı olarak adlandırılmaktadır. Orta akış 8 defa tekrarlanmaktadır.

Literatürde derin öğrenme kapsamında farklı modeller önerilmeye devam etmektedir. Bunlar arasında DenseNet [63], MobileNet [64], NasNet [65], Se-Resnet [66], MobileNetV2 [67] ve EfficientNet [68] ön plana çıkmaktadır.

Kapsül ağları


Kapsül ağları 2017 yılında önerilmiştir [11]. Kapsül ağlarının önerilmesindeki motivasyonu anlamak için ESA ile karşılaştırmak gerekmektedir. ESA, nitelik vektörüne ihtiyaç duymamakta, gerekli nitelikleri katmanlarda kendisi öğrenebilmektedir. Normal

yapay sinir ağlarından farklı olarak piksellerin birbirine karşı göreceli konumunu da yani uzaysal veriyi de hesaba katmaktadır. Girdi katmanına yakın katmanlarda düşük seviyeli özellikleri mesela yüzdeki göz bölgesini vb. öğrenirken çıktı katmanına doğru yüksek seviyeli özellikleri yani sınıf etiketlerini öğrenmektedir [69]. Ancak ESA düşük seviyeli özelliklerden yüksek seviyeli özellikleri öğrenirken, öğrendiği özelliklerin birbirine karşı göreceli konumlarını dikkate almamaktadır. Örneğin, Şekil 3.13'deki her iki resim de ESA modeli için geçerli bir yüz resmi olmaktadır [69].



Şekil 3.13. Esa sınıflandırma örneği

Bununla birlikte objeler beynimizde bakış açısına bağlı olmadan tanınabilmektedir. Örneğin farklı açılardan çekilmiş beyin görüntülerinin hepsi uzmanı için beyin objesini ifade etmektedir. Birkaç örneği görmesi insan beyninin öğrenmesi için yeterlidir. Ancak ESA bunu benzer açılardan görüntülenmiş çok fazla sayıda örnekle öğrenebilmektedir. Kapsül ağlarının sunulmasındaki temel motivasyonu bunlar oluşturmaktadır [69]. Yani ağ modelleri beynimize benzer şekilde bakış açısından bağımsız olarak nesneleri az sayıda örnekle tanımlamayı öğrenebilmelidir. Bunun için de öğrenilen düşük seviyeli niteliklerin bağıl konumları da dikkate alınarak yüksek seviyeli özellikler öğrenilmelidir. Önerilen kapsül yapıları buna çözüm sunabilmektedir. Bir görüntüde objenin yeri kısmen değişse de yapay zekâ modelinin objenin varlığına ilişkin tahmininin değişmemesi gerekir. Bu durum *çeviri değişmezliği* ile sağlanmaktadır. ESA modelinde bunun için maksimum havuzlama kullanılmaktadır. Fakat maksimum havuzlama mekanizmasında nöron sadece bir sayısal değer oluşturmakta, bazı değerli bilgileri kaybetmekte ve objelerin birbiriyle göreceli durumlarına ilişkin bir bilgi de barındırmamaktadır. Kapsül ise sayısal değer yerine vektör üretmekte, vektörün uzunluğuyla objenin varlığının olasılığını tutmakta, vektörün kendisiyle de göreceli durumuna ilişkin bilgileri kodlamaktadır [70]. CapsNet mimarisi Şekil 3.14'de verilmiştir:



Şekil 3.14. Capsnet mimarisi [11]

Bu nedenle, resimdeki yüzün sadece yeri değil bakış açısında değişirse bu bölge halen yüz içerdiğinden çıktı vektörünün uzunluğu değişmeyecek fakat vektörün yönü değişecektir. ESA modelinde kullanılan nöronlar, sayısal ağırlık değerleri ve bunlara karşılık gelen sayısal girdilerin çarpımlarının toplamını alarak aktivasyon fonksiyonu ile yine sayısal bir çıktı üretirler. Kapsüllerde ise alt seviye kapsüllerden gelen çıktılar birer vektördür. Her girdi vektörü ilgili ağırlık matrisiyle çarpılır. Bunun sonucunda oluşan vektörler de karşılık gelen sayısal ağırlıklarla çarpılarak toplanır. Sonuçta ise doğrusal olmayan aktivasyon işlemiyle yine bir vektör çıktı olarak üretilir. Kapsül çıktı vektörü, girdi vektöründe hangi olasılıkla ilgili çıktının temsil edildiğini göstermesi için *squash* işlemine tabi tutulmaktadır. Bunun sonucunda vektör uzunluğu en fazla 1 olurken yönü değişmemektedir. Bir kapsül çıktısı *dinamik yönlendirme* algoritmasıyla belirlenmektedir [11].

Daha önce de açıklandığı gibi alt seviyedeki bir kapsül çıktısı üst seviyedeki tüm kapsüllere ilgili sayısal ağırlık değerlerinin çarpımıyla girdi olarak gönderilir. l seviyesindeki i kapsülünden $l+1$ seviyesindeki j kapsülüne giden çıktının ağırlık değeri c_{ij} ile gösterilmektedir. l seviyesindeki bir i kapsülü için, $l+1$ seviyesinde n tane kapsül varsa n adet c_{ij} değeri olacaktır. Bu ağırlık değerlerinin hiçbiri negatif değer alamamakta, toplamaları ise 1 olmaktadır. Bu durumda c_{ij} değeri l seviyesindeki bir kapsülün çıktısının hangi olasılıklarla üst seviyedeki kapsüllere gönderileceğini ifade etmektedir. Algoritma [11] girdi olarak l seviyesindeki tüm kapsülleri, bunların çıktıları ve döngü sayısını (r) almakta, sonuçta ise $l+1$ seviyesindeki bir kapsülün çıktı vektörünü oluşturmaktadır. Algoritmada c_{ij} değerini belirleyecek olan geçici bir b_{ij} katsayısı da kullanılmakta ve tüm b_{ij} değerleri başlangıçta 0 olmakta, her döngü sonunda ise c_{ij} değerini belirlemek için güncellenmektedir. Algoritmada her bir döngüde 4-7 satırlarındaki işlemler tekrarlanmaktadır. 4. satırda b_i vektörü kullanılarak l seviyesindeki her bir kapsül için c_i

vektörü hesaplanır. Softmax kullanılmasıyla her bir c_{ij} değerinin negatif olmaması ve toplamalarının 1 olması sağlanmış olur. b_{ij} değerleri başlangıçta 0 olduğu için c_{ij} değerleri de başlangıçta eşit olacak, yani ilk döngüde tüm üst kapsüllere çıktı eşit oranda dağıtılacaktır. 5. ve 6. satırlarda $l+1$ seviyesindeki her kapsülün çıktı vektörü hesaplanmaktadır. 7. satır ağırlık güncelleme işlemi yapıldığı en önemli işlemi içermektedir. l seviyesindeki her bir kapsül için b_{ij} değerleri bu satırda güncellenir. Güncelleme yapılırken b_{ij} mevcut değerine j kapsülünün çıktı vektörü ile i kapsülünün j kapsülüne gönderdiği girdi vektörünün nokta çarpımı eklenir. İki vektör arasında nokta çarpımı işlemi aralarındaki *benzerliği* ifade eder. Yani b_{ij} değeri l ve $l+1$ seviyesindeki i ve j kapsüllerinin benzerliğiyle güncellenir.

Dinamik yönlendirme algoritmasından anlaşıldığı üzere b_{ij} değerleri her bir döngüde, önceki döngülerdeki değerlerinin toplamına eşit olmaktadır. İlk döngü sonucu oluşan benzerlik rastgele dağılımla belirlendiğinden b_{ij} değerleri önceki döngülerdeki benzerliklere ve özellikle de ilk döngüde eğitim olmaksızın elde edilen başlangıç benzerliğine karşı ön yargılı (biased) olmaktadır. Dolayısıyla önceki b_{ij} değerlerinin yeni hesaplama katılmaması veya katılma oranının azaltılması, l seviyesindeki kapsüllerin her bir döngüde öğrendiği özelliği daha etkin vurgulamasını sağlayabilir. Bu hipotezimizden yola çıkılarak kapsül ağırları dinamik yönlendirme algoritmasının ağırlık güncelleme işleminin optimize edilebilir hale getirildiği geliştirilmiş ESA-Kapsül modeli önerilmiş olup detayları Bölüm 5’de anlatılmıştır.

4. MEVCUT YÖNTEMLERİN PROBLEME UYGULANMASI

Giriş bölümünde de anlatıldığı üzere, bu tez çalışması kapsamında çözüm üretmeye çalıştığımız problem uzayı şu hususları içermektedir:

1. Beyin tümörlerinin ve özellikle GBM tümörünün yüksek performans ile tespit edilmesi,
2. Beyin tümörü tespitinde kullanılan MR görüntü düzlemlerindeki farklılıkların otomatik tümör tespitinde ne gibi etkilerinin olduğunun tespiti,
3. GBM tümörü olup olmadığının tespiti için ihtiyaç duyulacak T2 ağırlıklı MR görüntü sayısının azaltılması,
4. MR çekiminin kesin teşhise kadarki süreçlerin hızlandırılmasını ve insan hatalarının minimize edilmesini sağlayacak bütüncül bir mimari tasarlanması.

Problem uzayındaki birinci konu yani Beyin MR görüntüleri kullanılarak beyin tümörlerinin ve özellikle GBM tümörünün varlığının hızlı ve etkin bir şekilde tespit edilmesi kapsamında hem geleneksel makine öğrenmesi yöntemlerini hem de derin öğrenme yöntemlerini ve özellikle yeni bir teknoloji olan Kapsül ağlarını esas alan yeni modeller geliştirilmesi ve literatürdeki mevcut bazı modeller de problemimize uyarlanarak deneysel çalışmalar yapılması,

Problem uzayındaki ikinci konu yani beyin tümörü tespitinde kullanılan MR görüntü düzlemlerindeki farklılıkların otomatik tümör tespitindeki etkilerinin analiz edilmesi kapsamında, düzlem açısından MR görüntü farklılıkları analiz edilmiş, coronal ve sagittal görüntüler boyun, boğaz ve yutak gibi beyin harici organları da içermekteyken axial görüntüler ise sadece beyin bölgesini içermekte ve daha homojen bir desene sahip olmasından yola çıkılarak axial görüntülerin modellerin eğitilmesinde kullanılmasının sınıflandırma kesinliğini artıracığı şeklinde bir hipotez geliştirilerek bunun kanıtlanmaya çalışılması,

Problem uzayındaki üçüncü konu yani GBM tümörü olup olmadığının tespitinde ihtiyaç duyulacak T2 ağırlıklı MR görüntü sayısının azaltılmasına yönelik yaklaşımlar geliştirilmesi kapsamında, literatürden farklı olarak, GBM tümörü tespitinde MR

görüntüsünde bariz tümör olmasa da vakanın tespit edilebiliyor olması, tümör bölgesinin yakalanabilmesi için görüntüleme sırasında daha kısa aralıklarla daha çok kesit taranması ihtiyacını dolayısıyla teşhis için gereken görüntü sayısını azaltacağından bir MR görüntüsünün GBM vakasına mı yoksa normal vakaya mı ait olup olmadığını tespiti yönelik yeni çalışmalar yapılması,

Problem uzayındaki dördüncü konu yani MR çekiminden kesin teşhise kadar ki süreçlerin hızlandırılmasını ve insan hatalarının minimize edilmesini sağlayacak tespit sistemlerinin tasarlanması konusunda, tez çalışması kapsamında uygulanan veya geliştirilen modellerin kullanılarak MR görüntülerinin otomatik analiz edilerek özellikle GBM tümörü tespiti durumunda ilgili hekimin anlık bilgilendirilerek hastaya acil müdahale edilmesine yardımcı olacak bir erken uyarı sistemi tasarlanması buna ilişkin patent başvuru süreci başlatılması planlanmıştır.

Planlanan bu çalışmaları gerçekleştirebilmek için Bölüm 3’de anlatılan veri setleri üzerinde öncelikle makine öğrenmesi ve derin öğrenme yöntemleri, veri setine ve çalışma ortamına uygun şekilde uyarlanarak uygulanmış olup detayları Bölüm 4.1 de verilmektedir. Bununla birlikte hem geleneksel makine öğrenmesi hem de derin öğrenme yöntemleri ve kapsül ağırları esas alınarak 4 yeni algoritma ve model geliştirilmiş olup detayları ayrı bir bölüm halinde Bölüm 5’de anlatılmaktadır. Beyin tümörü erken uyarı sistemine ilişkin detaylar ise Bölüm 5.6’da yer almaktadır.

Gerek Bölüm 4.1’de uygulanan mevcut algoritma ve modellerin gerekse Bölüm 5’de önerilen yeni modellerin performansı, hem lokal veri seti hem de literatürde benzer çalışmalarda kullanılan bir kıyaslama veri seti üzerinde gerçekleştirilen deneysel çalışmalarda kullanılan bir kıyaslama veri seti üzerinde gerçekleştirilen deneysel çalışmalarda ölçülerek kıyaslanmış ve iyileştirilmiştir. Deneysel çalışmalar belli bir sistematik içinde gerçekleştirilmiştir. Buna göre bir deneysel çalışma için veri seti, doğrulama yöntemi, eğitimde kullanılacak model ve model için parametreler belirlenmekte, deneyin sonucunda kesinlik eğrileri, kayıp eğrileri ve karışıklık matrisi elde edilmektedir. Veri setleri olarak CE-MRI kıyaslama veri seti, CE-MRI veri setinin eksen görüntü alt kümesi ve LOKAL veri seti seçilebilmektedir. Doğrulama yöntemleri arasında indeksli 5-kat çapraz doğrulama, rastgele 5-kat çapraz doğrulama ve rastgele bölme ile doğrulama yer almaktadır. İndeksli 5-kat çapraz doğrulamada CE-MRI veri seti ile birlikte sağlanan doğrulama indeksleri kullanılarak sonuçların birebir kıyaslaması yapılmaktadır.

Rastgele bölme ile doğrulamada test oranı olarak 0,1, 0,3 ve 0,5 gibi oranlar belirlenmiştir. Algoritma ve model olarak bir sonraki bölümde detaylı anlatılan önerilen yöntemlerden birisi seçilirken, parametre seti olarak ise modele ilişkin çeşitli parametre değerleri belirlenmektedir.

Deneysel çalışmalarda eğitilen yapay zekâ modellerinin performans değerlendirilmesi Çizelge 4.1’de verilen değerlerle hesaplanan metriklere göre gerçekleştirilmiştir [71].

Çizelge 4.1. Karışıklık matrisi

	Diğer (Tahmin)	Hedef Sınıf (Tahmin)
Diğer	TN (Doğru Negatif)	FP (Yanlış Pozitif)
Hedef Sınıf	FN (Yanlış Negatif)	TP (Doğru Pozitif)

Hassasiyet, kesinlik ve sınıflandırma kesinliği değerleri sırasıyla aşağıdaki gibi hesaplanmaktadır:

$$\frac{TP}{TP+FP} \quad (4.1)$$

$$\frac{TP}{TP+FN} \quad (4.2)$$

$$\frac{TP+TN}{TP+FN+TN+FP} \quad (4.3)$$

LOKAL veri seti için örnek bir karışıklık matrisi ve bu matris kullanılarak performans metriklerinin nasıl hesaplandığı Çizelge 4.2’de verilmektedir.

Çizelge 4.2. Lokal veri seti için örnek karışıklık matrisi

	Tahmin Edilen	
	Normal	GBM
Normal	680	4
GBM	13	276

Normal etiketler için;

$$\text{Hassasiyet} = 680/(680 + 4) = 0,994$$

$$\text{Kesinlik} = 680/(680+13) = 0,981$$

GBM etiketler için;

$$\text{Hassasiyet} = 276/(276+13) = 0,955$$

$$\text{Kesinlik} = 276/(276+4) = 0,985$$

$$\text{Sınıflandırma kesinliği} = (680+276)/(680+4+13+276)=0,982 \text{ olmaktadır.}$$

LOKAL veri seti üzerinde yapılan çalışmalarda ikili sınıflandırma yapılmakta olup hedef sınıf GBM vakaları olurken CE-MRI veri seti üzerinde yapılan çalışmalarda ise üçlü sınıflandırma yapılmış ve hedef sınıf yapılacak hesaplama göre meningioma, glioma veya pituitary olmaktadır. CE-MRI kıyaslama veri seti için örnek bir karışıklık matrisi ve bu matris kullanılarak performans metriklerinin nasıl hesaplandığı da Çizelge 4.3’de verilmektedir:

Çizelge 4.3. Ce-mri veri seti için örnek karışıklık matrisi

	Tahmin Edilen		
	Meningioma	Pituitary	Glioma
Meningioma	531	53	124
Pituitary	23	891	16
Glioma	113	22	1291

Meningioma etiketler için;

$$\text{Hassasiyet} = 531/(531+53+124) = 0,75$$

$$\text{Kesinlik} = 531/(531+23+113) = 0,796$$

Pituitary etiketler için;

$$\text{Hassasiyet} = 891/(23+891+16) = 0,958$$

$$\text{Kesinlik} = 891/(53+891+22) = 0,922$$

Glioma etiketler için;

$$\text{Hassasiyet} = 1291/(113+22+1291) = 0,905$$

$$\text{Kesinlik} = 1291/(124+16+1291) = 0,902$$

Sınıflandırma kesinliği = $(531+891+1291)/(531+53+124+23+891+16+113+22+1291) = 0,885$ olmaktadır. Yukarıdaki örnek hesaplamalarda bulunan ondalıklı değerler 100 ile çarpılarak yüzdelik karşılığı hesaplanmaktadır. Deneysel çalışmalara ilişkin çizelgelerde veya literatür karşılaştırmasında verilen metriklerin değerlerinin yüzdelik karşılığı bazı durumlarda yuvarlanarak verilmiştir.

4.1. Uygulanan Yöntemler

Tez çalışması kapsamında belirlenen problemleri çözmek için literatürde mevcut olan modeller, veri setleri, sonuçlar, algoritmalar, çözümler, metrikler ve başarı kriterleri gözden geçirilmiştir. Belirlenen problemleri çözmek için, önceki bölümde anlatılan derin öğrenme yapıları ve algoritmaları ile sahip olunan üç farklı veri seti üzerinde deneysel çalışmalar yapılmıştır. Uygulanan bu yöntemlerin detayları aşağıdaki alt bölümlerde sırasıyla anlatılmaktadır.


4.1.1. Varsayılan yöntem

Bu yöntem görüntü dosyalarını kullanarak geleneksel makine öğrenmesi algoritmalarıyla sınıflandırma yapılacağı zaman uygulanan varsayılan yöntemlerdendir. Buna göre MR görüntü dosyası öncelikle gri seviyeli görüntüye dönüştürülmekte, ardından piksel matrisi vektör haline getirilerek sınıflandırma algoritmasına gönderilmektedir. Yöntemin aşamaları Çizelge 4.4’de verilmiştir:

Çizelge 4.4. Varsayılan tespit algoritması sözde kodu

Algoritma: Temel Tespit Yöntemi
Girdi: I_{jpeg} : JPEG formatında MR görüntüsü
Çıktı: $I_{prediction}$: Sınıflandırma etiketi
Adım1: $I_{scaled} \leftarrow I_{jpeg}$ JPEG görüntüsü 128x128x3 boyutuna ölçeklendirilir.
Adım2: $I_{gray} \leftarrow I_{scaled}$ Görüntü gri seviyeli dosyaya dönüştür
Adım3: $I_{inputVector} \leftarrow \text{Reshape}(I_{gray})$ iki boyutlu görüntü matrisi vektöre dönüştürülür
Adım4: $I_{prediction} \leftarrow \text{Sınıflandırma Algoritması}(I_{inputVector})$
Sonuç: $I_{prediction}$

Çizelge 4.4’de anlatılan yöntemin 3. adımında matris formatında tutulan piksel değerleri vektöre dönüştürülmektedir. Bu işlem Şekil 4.1’de verilmiştir.



Şekil 4.1. Matris-vektör dönüşümü

Şekil 4.1'den görüldüğü üzere görüntü matrisindeki her bir satır ardışık olarak birleştirilmektedir. Sonuçta 4x4 boyutundaki piksel matrisi 16 uzunluğunda bir vektöre dönüşmektedir. CE-MRI veri setindeki MR görüntüleri 512x512 boyutunda olmasına karşın bellek yetersizliği ve işlem hızı gibi nedenlerle 128x128 boyutuna ölçeklendirilerek deneysel çalışmalarda kullanılmıştır. Bu yöntemde de 128x128 boyutundaki bir MR görüntüsü vektöre dönüştürme işlemi sonrası sınıflandırma algoritması için 16384 uzunluğunda bir girdi vektörüne dönüştürülmüştür.

Deney#1

Bu deneysel çalışmada varsayılan temel yöntem ile sınıflandırma yapılmıştır. Yöntemin son adımında farklı makine öğrenmesi algoritmaları kullanılmış ve veri setinde sağlanan çapraz doğrulama indeksleri kullanılarak 5-kat çapraz doğrulama ile eğitim gerçekleştirilmiştir. Kullanılan algoritmalar ve elde edilen performans değerleri Çizelge 4.5'de sunulmuştur.


Çizelge 4.5. Deney#1 sonuçları

	Meningioma		Glioma		Pituitary		Genel Kesinlik (%)
Algoritma	P (%)	R (%)	P (%)	R (%)	P (%)	R (%)	
K-EYK	52	28	64	81	74	71	65
LR	45	44	66	67	73	72	64
KA	53	53	74	74	68	67	67
XGBoost	62	64	79	75	75	79	74
DVM	50	51	70	70	74	74	67
LightGBM	63	67	81	76	76	79	75

Çizelge 4.5'de yer alan sonuçlar incelendiğinde glioma hassasiyet metriği açısından en iyi sonucu K-en yakın komşuluk algoritmasının elde ettiği, bunun haricinde 7 performans metriğinin 6'sında LightGBM algoritmasının en iyi sonucu yakaladığı, Pituitary hassasiyet metriği açısından ise XgBoost algoritması ile birinciliği paylaştığı görülmektedir. Xgboost algoritmasının diğer metrikler açısından da LightGBM algoritmasına yakın sonuçlar verdiği dikkate alındığında, varsayılan yöntem ile en iyi sonuçları boosting temelli algoritmaların elde ettiğini, özellikle LightGBM algoritmasının daha başarılı sonuçlar verdiğini söyleyebiliriz.


4.1.2. Esa modeli

Bu bölümde sınıflandırma modeli olarak, derin öğrenme yöntemlerinden biri olan ESA kullanılmıştır. ESA modelinin uygulanmasında internette açık paylaşılan kodlardan faydalanılmıştır [72]. Bu model daha önce Kaggle yarışmalarında başarılı sonuçlar verdiğinden beyin tümör tiplerinin sınıflandırılmasında da küçük tasarım değişiklikleriyle uygulanmaktadır. Tasarlanan ESA modeli Şekil 4.2’de verilmektedir:



Şekil 4.2. Uygulanan esa modeli

Bu modelde 128x128 boyutlarındaki gri seviyeli MR görüntüsü girdi olarak alınmakta ardışık 5 farklı evrişimli bloktan geçerek tam bağlantılı katman ile sonuç üretilmektedir. Modelde kullanılan evrişimli katman yapısının detayı Şekil 4.3’de verilmektedir:



Şekil 4.3. Evrişimli katman yapısı

Evrişimli bloklardaki katman sayıları sırasıyla 32, 64, 96, 64 ve 32 olarak belirlemiştir. Bu katmanlarda 3x3 filtreler kullanılırken, havuz katmanında 2x2 filtreler kullanılmıştır. Ara katmanlardaki girdileri de normalleştirmek için yığın normalizasyonu işlemi de uygulanmış olup bu işlemde sırasıyla aşağıdaki adımlar gerçekleştirilmiştir [73]:

1.) Eş. 4.4'e göre ortalama ve sapma hesaplanır:

$$\mu_B = \frac{1}{m} \sum_{i=1}^m x_i \quad (4.4)$$


2.) Katman girdileri 1. adımdaki sonuçlara göre Eş. 4.5 ile normalleştirilir:

$$\hat{x}_i = \frac{x_i - \mu_B}{\sqrt{\sigma_B^2 + \epsilon}} \quad (4.5)$$

3.) Katman çıktısı Eş. 4.6'ya göre hesaplanır:


$$y_i = \gamma \hat{x}_i + \beta \quad (4.6)$$

Tam bağlantılı katman mimarisi Şekil 4.4'de verilmektedir:



Şekil 4.4. Tam bağlantılı katman mimarisi

Tam bağlantılı katman öncesindeki blokları gösteren ESA mimarisi ise Şekil 4.5'de yer almaktadır.




Şekil 4.5. Uygulanan esa mimarisi

Bu ESA mimarisiyle yapılan deneysel çalışmaların detayları ve elde edilen sonuçların değerlendirilmesi takip eden alt bölümlerde verilmektedir:

Deney#2

Bu deneysel çalışmada Bölüm 4.1.2’de anlatılan ESA modeli kullanılmış ve modelin eğitilmesinde de CE-MRI kıyaslama veri setinde sağlanan çapraz doğrulama indeksleri kullanılarak 5-kat çapraz doğrulama gerçekleştirilmiştir. Modelde eğitilebilir parametre sayısı 608 067’dir. Modelin eğitilmesi için 300 döngü belirlenmiş olup doğrulama kesinliğinin 10 ardışık döngü boyunca %89 üzerinde olması durumunda ise 300 döngünün tamamlanması beklenmeden eğitim sonlandırılmıştır. Deneysel çalışma sonucunda elde edilen karışıklık matrisi Şekil 4.6’da verilmiştir:



Şekil 4.6. Karışıklık matrisi (deney#2)

Karışıklık matrisine göre elde edilen performans değerleri ise Çizelge 4.6’da verilmiştir.


Çizelge 4.6. Deney#2 sonuçları

Meningioma		Glioma		Pituitary		Genel Kesinlik (%)
P (%)	R (%)	P (%)	R (%)	P (%)	R (%)	
79,6	75	90,2	90,5	92,2	95,8	88,54

Deneysel çalışmada 5-kat çapraz doğrulamada elde edilen kesinlik ve kayıp eğrileri ise EK-1’de yer almaktadır.

Deney#3

Bir önceki deneysel çalışmada çapraz doğrulama aşamalarına ilişkin kayıp ve kesinlik eğrisi grafikleri incelendiğinde bazı aşamalarda erken sonlandırma olmadığı, belirlenen doğrulama kesinliği eşiğine ulaşamadığı görülmektedir. Yine bu grafiklerde doğrulama kesinliğinin zaman zaman keskin düşüşler yaşadığı, dolayısıyla bu noktalarda 300 döngünün tamamlanması durumunda genel sonuçların düşük çıkacağı anlaşılmaktadır. Bu nedenle her bir çapraz doğrulama aşaması için aynı eşik değeri yerine farklı eşik değerlerde erken sonlandırma sağlanarak modelin performansı artırılabilir. Bu nedenle önerilen bu ESA modeliyle her bir 5-kat çapraz doğrulama aşaması için farklı erken sonlandırma değerleri belirlenerek deneysel çalışma tekrarlanmıştır. Deneysel çalışmada elde edilen karışıklık matrisi Şekil 4.7’de verilmiştir:



Şekil 4.7. Karışıklık matrisi (deney#3)

Karışıklık matrisine göre elde edilen performans değerleri ise Çizelge 4.7’de verilmiştir.


Çizelge 4.7. Deney#3 sonuçları

Meningioma		Glioma		Pituitary		Genel Kesinlik (%)
P (%)	R (%)	P (%)	R (%)	P (%)	R (%)	
83,4	76,7	90,8	92,4	92,4	95,7	89,71

Deneysel çalışmada 5-kat çapraz doğrulamada elde edilen kesinlik ve kayıp eğrileri ise EK-1’de yer almaktadır.

Deney#4

ESA modeliyle gerçekleştirilen önceki her iki deneyde de 5-kat çapraz doğrulamanın her bir aşamasında modelin ağırlık değerleri sıfırlanmıştır. Bunun yerine birinci aşamadan sonraki aşamalarda bir önceki aşamada oluşan ağırlık değerleriyle model oluşturularak deneysel çalışma tekrarlanmıştır. Buna göre elde edilen sonuçlar Şekil 4.8’de verilmiştir:



Şekil 4.8. Karışıklık matrisi (deney#4)

Karışıklık matrisine göre elde edilen performans değerleri ise Çizelge 4.8’de verilmiştir.

Çizelge 4.8. Deney#4 sonuçları

Meningioma		Glioma		Pituitary		Genel Kesinlik (%)
P (%)	R (%)	P (%)	R (%)	P (%)	R (%)	
92,8	94,8	97,2	97,2	98,8	97,2	96,67

Deneysel çalışmada 5-kat çapraz doğrulamada elde edilen kesinlik eğrileri ise EK-1’de yer almaktadır.

Bu deneysel çalışmada 5-kat çapraz doğrulama aşamalarındaki kesinlik eğrilerini incelediğimizde ilk aşamada 300 döngü boyunca modelin eğitiminin devam ettiğini ancak 2. aşama ve sonrasında bir önceki ağırlık değerleriyle model eğitime başladığından çok kısa sürelerde yüksek doğrulama kesinliğini yakaladığı görülmektedir. Transfer öğrenme literatürde kullanılan bir yöntem olup [22,24,27,40,43] büyük derin öğrenme modellerinin ağırlık değerleriyle tamamen veya kısmen model eğitime başlatıldığında performans değerleri artmaktadır. Ancak burada ilk aşamada eğitimde kullanılan verinin bir kısmı

ikinci aşamada doğrulama verisi olmaktadır. Dolayısıyla modelin ağırlık değerleri doğrulama verisine karşı kısmen meyilli sonuçlar üretebilmektedir. Bu istenilen bir durum değildir, çünkü model eğitilirken doğrulama verisi doğrudan veya dolaylı olarak eğitim verisi olarak kullanılmamalıdır. Elde edilen sonuçlardaki iyileşmenin ne ölçüde transfer öğrenmeye bağlı ne ölçüde doğrulama verisine karşı önyargıdan kaynaklı olduğu ayırtılamayacağı için bu deneysel çalışmanın sonuçları literatür karşılaştırılmasında kullanılmamıştır. Uygulanan ESA modelleriyle bir önceki bölümde önerilen geleneksel makine öğrenmesi temelli modellerin karşılaştırılması Çizelge 4.9’da yer almaktadır.

Çizelge 4.9. Deneysel çalışma sonuçları karşılaştırması

	Meningioma		Glioma		Pituitary		Genel Kesinlik (%)
Yöntem	P (%)	R (%)	P (%)	R (%)	P (%)	R (%)	
Varsayılan	63	67	81	76	76	79	75
Piksel Histogram Dağılımı	52	50	82	83	82	82	75
Yerel İkili Desenler	54	51	84	85	82	85	77
ESA modeli	79,6	75	90,2	90,5	92,2	95,8	88,54
ESA modeli (erken sonlandırma)	83,4	76,7	90,8	92,4	92,4	95,7	89,71


Çizelge 4.9’da görüldüğü üzere derin öğrenme modelleri 7 performans metriğinin tamamı açısından önemli miktarda gelişme sağlamışlardır.

Deney#5

Uygulanan ESA modeliyle (Deney#2) orijinal 5-kat çapraz doğrulama sonucunda yanlış etiketlenen MR görüntülerinin sadece %22’si axial iken, önerilen ESA-Kapsül modeliyle (Deney#9) gerçekleştirilen eğitimde ise yanlış etiketlenen MR görüntülerinin sadece %19’u axial görüntülerdir. Burdan yola çıkarak ve bu konudaki hipotezimiz doğrultusunda axial veri seti üzerinde aynı zamanda önerilen derin öğrenme modelleriyle de eğitimler gerçekleştirilmiş olup yapılan deneysel çalışmalara ilişkin detaylar aşağıdaki bölümlerde anlatılmaktadır.

Bu çalışmada önerilen ESA modeli, veri setinin sadece axial görüntülerinden oluşan alt kümesi üzerinde yine veri setinde paylaşılan 5-kat çapraz doğrulama indeksleri

kullanılarak eğitilmiştir. Deneysel çalışma sonucunda elde edilen karışıklık matrisi Şekil 4.9'da verilmiştir:



Şekil 4.9. Karışıklık matrisi (deney#5)

Bu karışıklık matrisine göre elde edilen performans metrikleri ise Çizelge 4.10'da verilmektedir.


Çizelge 4.10. Deney#5 sonuçları

Meningioma		Glioma		Pituitary		Genel Kesinlik (%)
P (%)	R (%)	P (%)	R (%)	P (%)	R (%)	
80,9	75,5	92,4	93,9	92,9	94,8	90,33

Deneysel çalışmada 5-kat çapraz doğrulamada elde edilen kesinlik ve kayıp grafikleri ise EK-1'de yer almaktadır.

Deney#6

Bu sınıflandırma işleminde T2 ağırlıklı bir MR görüntüsünde GBM tümörü olup olmadığı, probleme uyarlanan ESA modeli kullanılarak 5-kat çapraz doğrulama ile tespit edilmiştir. Lokal veri setinde 65 GBM 114 normal olmak üzere toplam 179 vakaya ait 3580 T2 ağırlıklı MR görüntüsü bulunmaktadır. GBM vakalarına ait 1300 MR görüntüsünün 649 tanesinde belirgin tümör olduğu ancak 651 tanesinin tümör içermeyen normal görüntülere benzediği uzman beyin cerrahları tarafından tespit edilmiştir. Bu çalışmada 114 normal vakaya ait 2280 tümörsüz MR görüntüsüyle 65 GBM vakasına ait 649 tümörlü MR görüntüsü kullanılmıştır. Elde edilen karışıklık matrisi Şekil 4.10'da verilmiştir.



Şekil 4.10. Karışıklık matrisi (deney#6)

Bu karışıklık matrisine göre elde edilen performans değerleri ise Çizelge 4.11’de yer almaktadır. Deneysel çalışmada 5-kat çapraz doğrulamasına ilişkin kesinlik ve kayıp eğrileri ise EK-1’de verilmiştir.


Çizelge 4.11. Deney#6 sonuçları

GBM Tümörü		Normal		Genel Kesinlik (%)
P (%)	R(%)	P(%)	R(%)	
97,2	91,7	97,7	99,3	97,6

Deney#7

T2 ağırlıklı bir MR görüntüsü belirgin bir tümör içermese de GBM vakasına ait bir görüntü olabilir. GBM vakalarında çekilen MR görüntülerinin bazılarında tümör görülmesi teşhis için yeterlidir. Bu çalışmada T2 ağırlıklı bir MR görüntüsünün tümör içerip içermediğine bakılmaksızın GBM vakasına mı yoksa normal vakaya mı ait olup olmadığı önerilen ESA modeliyle 5-kat çapraz doğrulama yapılarak tespit edilmiştir.

Lokal veri setinde 65 GBM 114 normal olmak üzere toplam 179 vakaya ait 3580 T2 ağırlık MR görüntüsü bulunmaktadır. Bu deneysel çalışmada 1300 GBM olarak etiketlenmiş, 2280 ise normal vaka olarak etiketlenmiş toplamda 3580 MR görüntüsünün tamamı kullanılmıştır.



Şekil 4.11. Karışıklık matrisi (deney#7)

Elde edilen karışıklık matrisi Şekil 4.11’de sunulmuştur. Bu karışıklık matrisine göre elde edilen performans değerleri ise Çizelge 4.12’de yer almaktadır.

Çizelge 4.12. Deney#7 sonuçları

GBM Vakası		Normal Vaka		Genel Kesinlik (%)
P (%)	R(%)	P(%)	R(%)	
96	93	96	97,8	96


Deneysel çalışmada 5-kat çapraz doğrulamaya ilişkin kesinlik ve kayıp eğrileri ise EK-1’de yer almaktadır.

Elde edilen performans değerlerini daha da artırmak için ESA ile Kapsül ağlarının bir araya getirilmesiyle oluşturulan ESA-Kapsül ağı da problemimize uyarlanmış olup detayları Bölüm 4.1.3’de verilmektedir.

4.1.3. Esa-kapsül modeli


ESA modelinin son aşamasında tam bağlantılı yapay sinir ağı bulunmaktadır. ESA ile edilen performans değerlerini iyileştirmek için ESA ile Kapsül ağlarının bir araya getirilmesiyle ESA-Kapsül modeli oluşturulmuştur. Esa-kapsül modelinde ESA modelinden farklı olarak sondaki tam bağlantılı katman yerine Kapsül ağlarının dinamik yönlendirme algoritmasının çalıştığı katman kullanılmıştır. Kapsül ağı dinamik

yönlendirme katmanının çıktı sayısı problemimize uygun olarak 3 olacak şekilde değiştirilmiştir.




Şekil 4.12. Esa-kapsül mimarisi

Uygulanan modelin mimarisi Şekil 4.12’de verilmiştir. Şekil 4.12’de verilen ESA-Kapsül mimarisinin ilk üç bloğunun yapısı Şekil 4.13’de yer almaktadır:



Şekil 4.13. Esa-kapsül mimarisi blok yapısı


Bu bloklardaki katman sayıları sırasıyla 32, 64, 96 olarak belirlemiştir. Bu katmanlarda 3x3 filtreler kullanılırken, havuz katmanında 2x2 filtreler kullanılmıştır. ESA-Kapsül mimarisinin dördüncü bloğunun yapısı ise Şekil 4.14’de verilmiştir:



Şekil 4.14. Esa-kapsül mimarisi 4.blok yapısı

Deney#8

Bu deneysel çalışmada internette yer alan [74] kodlardan faydalanılarak ESA-Kapsül probleme uyarlanmış ve veri setinde sağlanan 5-kat çapraz doğrulama indekslerine göre eğitim gerçekleştirilmiş olup elde edilen karışıklık matrisi sonuçları Şekil 4.15’de yer almaktadır. Karışıklık matrisine göre elde edilen performans değerleri ise Çizelge 4.13’de verilmiştir.



Şekil 4.15. Karışıklık matrisi (deney#8)


Çizelge 4.13. Deney#8 sonuçları

Meningioma		Glioma		Pituitary		Genel Kesinlik (%)
P (%)	R (%)	P (%)	R (%)	P (%)	R (%)	
81,7	78,8	92	91,4	93,3	96,7	90,07

Deneysel çalışmada 5-kat çapraz doğrulamada elde edilen kesinlik ve kayıp eğrileri ise EK-1’de yer almaktadır.

Deney#9

Bir önceki deneysel çalışmada, problemimize uyarlayarak uyguladığımız ESA-Kapsül modeliyle CE-MRI veri seti üzerinde paylaşılan 5-kat çapraz doğrulama indeksleriyle doğrulama yapılmıştı. Bu çalışmada ise paylaşılan doğrulama indeksleri yerine rastgele 5-kat çapraz doğrulama indeksleriyle eğitim gerçekleştirilmiştir.



Şekil 4.16. Karışıklık matrisi (deney#9)

Elde edilen karışıklık matrisi Şekil 4.16’da verilmiştir. Şekil 4.16’da sunulan karışıklık matrisine göre hesaplanan performans metrikleri ise Çizelge 4.14’de yer almaktadır.

Çizelge 4.14. Deney#9 sonuçları


Meningioma		Glioma		Pituitary		Genel Kesinlik (%)
P (%)	R (%)	P (%)	R (%)	P (%)	R (%)	
93,3	92,2	96,7	96,5	98	99,1	96,3

Deneyisel çalışmada elde edilen kesinlik ve kayıp eğrileri grafikleri EK-1’de yer almaktadır.

Deney#10

Bu deneyisel çalışmada, Bölüm 4.1.3’de anlatılan ESA-Kapsül modeliyle 2-kat çapraz doğrulama yapılarak model eğitilmiştir. Bu durumda veri seti 2 parçaya ayrılarak her bir eğitimde bir parça eğitim verisi diğeri ise test verisi olarak kullanılmıştır.

Deneyisel çalışma sonucunda elde edilen karışıklık matrisi Şekil 4.17’de sunulmaktadır. Şekil 4.17’de verilen karışıklık matrisine göre hesaplanan performans değerleri ise Çizelge 4.15’de yer almaktadır. Deneyisel çalışmada elde edilen kesinlik ve kayıp eğrileri grafikleri EK-1’de yer almaktadır.




Şekil 4.17. Karışıklık matrisi (deney#10)

Çizelge 4.15. Deney#10 sonuçları

Meningioma		Glioma		Pituitary		Genel Kesinlik (%)
P (%)	R (%)	P (%)	R (%)	P (%)	R (%)	
91,4	87,6	95	95,9	97	98,9	94,88

Deney#11

Bu çalışmada önerilen ESA-Kapsül modeli veri setinin rastgele bölünmesi ile oluşan eğitim ve doğrulama setleri kullanılarak eğitilmiştir. Doğrulama seti oranı %30 olarak belirlenmiştir. Elde edilen karışıklık matrisi Şekil 4.18’de verilmiştir.




Şekil 4.18. Karışıklık matrisi (deney#11)

Çizelge 4.16. Deney#11 sonuçları

Meningioma		Glioma		Pituitary		Genel Kesinlik (%)
P (%)	R (%)	P (%)	R (%)	P (%)	R (%)	
97,2	89,1	95	98,6	98,5	99,6	96,52

Deneyssel çalışmada elde edilen kesinlik ve kayıp eğrileri grafikleri Şekil 4.19'da verilmiştir:




Şekil 4.19. Deney#11 kesinlik ve kayıp eğrileri a) kesinlik eğrisi b) kayıp eğrisi

Bu deneyssel çalışma kapsamında önerilen modelin ara katmanlarında öğrenilen niteliklerin görselleştirilmesi de gerçekleştirilmiştir. Bir MR görüntüsünden eğitim esnasında 2-13. katmanları arasındaki katmanlarda öğrenilen niteliklere ilişkin görseller sırasıyla EK-2'de verilmiştir. Bu görüntüleri incelediğimizde daha alt seviyedeki katmanlardaki görüntülerin modele sunulan görüntüye daha çok benzediği, orta katmanlarda bu görüntünün silüet olarak korunurken belli bölgelerinin vurgulanmaya başladığı, son katmanlarda ise görüntüyü sınıflandırmaya yarayacak piksel kodlarının oluştuğu gözlenmektedir. ESA ağlarının girişe yakın kısımlarında alt seviye özellikleri yani beyin bölümlerini veya tümör şekillerini, çıktıya yakın kısımlarında ise üst seviyeli özellikleri yani sınıf etiketlerini öğrendiği göz önüne alındığında, ara katmanlarda elde edilen görseller bunu desteklemekte, çıktıya yakın 12. katmanda sınıf etiketlerini kodlayacak piksel dağılımları oluşurken girişe yakın katmanlarda beyin bölgesinin vurgulanmaya başladığı anlaşılmaktadır.

Deney#12

Bu çalışmada önerilen ESA-Kapsül modeli veri setinin rastgele bölünmesi ile oluşan eğitim ve doğrulama setleri kullanılarak eğitilmiştir. Doğrulama seti oranı %10 olarak belirlenmiştir. Elde edilen karışıklık matrisi Şekil 4.20'de verilmiştir.




Şekil 4.20. Karışıklık matrisi (deney#12)

Karışıklık matrisine göre elde edilen performans değerleri ise Çizelge 4.17’de yer almaktadır.

Çizelge 4.17. Deney#12 sonuçları

Meningioma		Glioma		Pituitary		Genel Kesinlik (%)
P (%)	R (%)	P (%)	R (%)	P (%)	R (%)	
97,5	97,5	98,6	98,6	100	100	98,7


Deneysel çalışmada elde edilen kesinlik ve kayıp eğrileri grafikleri Şekil 4.21’de verilmiştir.



Şekil 4.21. Deney#12 kesinlik ve kayıp eğrileri a) kesinlik eğrisi b) kayıp eğrisi

Deney#13

Bu çalışmada önerilen ESA-Kapsül modeli, veri setinin sadece axial görüntülerinden oluşan alt kümesi üzerinde yine veri setinde paylaşılan 5-kat çapraz doğrulama indeksleri kullanılarak eğitilmiştir. Elde edilen karışıklık matrisi Şekil 4.22’de verilmiştir.



Şekil 4.22. Karışıklık matrisi (deney#13)

Bu karışıklık matrisine göre elde edilen performans metrikleri ise Çizelge 4.18’de verilmektedir. CE-MRI veri seti üzerinde verilerin tamamını kullanan modeller ile sadece axial alt kümesini kullanan modellerin karşılaştırılması Çizelge 4.19’da verilmiştir.

Çizelge 4.18. Deney#13 sonuçları

Meningioma		Glioma		Pituitary		Genel Kesinlik (%)
P (%)	R (%)	P (%)	R (%)	P (%)	R (%)	
85,9	82,2	94,9	94,3	94,3	96,9	92,5

Çizelge 4.19. Axial veri seti sonuçlarının karşılaştırılması

Model	Meningioma		Glioma		Pituitary		Genel Kesinlik (%)
	P (%)	R (%)	P (%)	R (%)	P (%)	R (%)	
ESA modeli	83,4	76,7	90,8	92,4	92,4	95,7	89,71
ESA (axial)	80,9	75,5	92,4	93,9	92,9	94,8	90,33
ESA-Kapsül	81,7	78,8	92	91,4	93,3	96,7	90,07
ESA-Kapsül (axial)	85,9	82,2	94,9	94,3	94,3	96,9	92,5


Deneysel çalışmada 5-kat çapraz doğrulamada elde edilen kesinlik ve kayıp grafikleri ise EK-1’de yer almaktadır. Çizelge 4.19’den görüldüğü üzere axial veri setinde elde edilen her iki sonuç da, tüm veri setinde elde edilen sonuçlardan daha başarılıdır. Model bazında değerlendirme yapıldığında da, her bir model için axial veri setinde elde edilen performans tüm veri setinde elde edilene göre daha yüksek gerçekleşmiştir.

4.1.4. Xception modeli

Bu bölümde literatürde mevcut olan Bölüm 3.2.2’de detayları anlatılan Xception modeli kullanılmaktadır. Xception modeliyle hem CE-MRI veri seti üzerinde hem de LOKAL veri seti üzerinde deneysel çalışmalar yapılmıştır. LOKAL veri seti üzerinde iki farklı deneysel çalışma yapılmış olup detayları aşağıda verilmektedir.

Deney#14

Bu çalışmada literatürde mevcut Xception [5] modeli ve veri setinin rastgele bölünmesi ile oluşan eğitim ve doğrulama setleri kullanılarak eğitilmiştir. Doğrulama seti oranı %30 olarak belirlenmiştir. Elde edilen karışıklık matrisi Şekil 4.23’de verilmiştir:



Şekil 4.23. Karışıklık matrisi (deney#14)


Şekil 4.23’de verilen karışıklık matrisine göre hesaplanan performans değerleri ise Çizelge 4.20’de yer almaktadır. Çizelge 4.20’den de görüldüğü üzere genel sınıflandırma kesinliği olarak %96,3 elde edilirken Glioma hassasiyet değeri açısından ise %97 performans başarısı Xception modelinin probleme uygulanmasıyla elde edilebilmiştir. En başarılı sonuç ise Pituitary hassasiyet metriği açısından %99 olarak elde edilmiştir.

Çizelge 4.20. Deney#14 sonuçları

Meningioma		Glioma		Pituitary		Genel Kesinlik (%)
P (%)	R (%)	P (%)	R (%)	P (%)	R (%)	
95	91,3	96,3	97,1	97,4	99,3	96,3

Deney#15

Bu çalışmada T2 ağırlıklı bir MR görüntüsünde GBM tümörü olup olmadığı Xception modeli kullanılarak 5-kat çapraz doğrulama ile tespit edilmiştir. Sınıflandırma işleminde ise normal vakaya ait 2280 görüntü ile birlikte 65 GBM vakasına ait 649 tümörlü görüntü olmak üzere toplam 2929 görüntü kullanılmıştır. Elde edilen karışıklık matrisi Şekil 4.24’de verilmiştir.



Şekil 4.24. Karışıklık matrisi (deney#15)

Bu karışıklık matrisine göre elde edilen performans değerleri ise Çizelge 4.21’de yer almaktadır.

Çizelge 4.21’den de görüldüğü üzere genel sınıflandırma kesinliği olarak %98 performans değeri yakalanabilmiştir. GBM tümörü hassasiyet değeri açısından ise %94 performans başarısı elde edilebilmiştir. En başarılı sonuç ise tümörsüz MR görüntüsü hassasiyet metriği açısından %99,5 olarak elde edilmiştir. Bu sonuçlar Xception modeliyle ESA modeline göre daha iyi performans elde edilebildiğini göstermektedir. Ancak Xception modelinde eğitilmesi gereken parametre sayısı çok daha fazladır.


Çizelge 4.21. Deney#15 sonuçları

GBM Vakası		Normal Vaka		Genel Kesinlik (%)
P (%)	R(%)	P(%)	R(%)	
98,2	93,5	98,2	99,5	98,2

Deneyisel çalışmada 5-kat çapraz doğrulamaya ilişkin kesinlik ve kayıp eğrileri ise EK-1'de yer almaktadır.

Deney#16

Bu çalışmada T2 ağırlıklı bir MR görüntüsünün tümör içerip içermediğine bakılmaksızın GBM vakasına mı yoksa normal vakaya mı ait olup olmadığı Xception modeli kullanılarak 5-kat çapraz doğrulama ile tespit edilmiştir. Elde edilen karışıklık matrisi Şekil 4.25'de yer almaktadır:



Şekil 4.25. Karışıklık matrisi (deney#16)

Bunun için LOKAL veri setindeki 3580 MR görüntüsünün tamamı kullanılmıştır. Bu karışıklık matrisine göre elde edilen performans değerler ise Çizelge 4.22'de yer almaktadır.


Çizelge 4.22. Deney#16 sonuçları

GBM Vakası		Normal Vaka		Genel Kesinlik (%)
P (%)	R(%)	P(%)	R(%)	
97,4	93,9	96,6	98,6	96,9

Deneyisel çalışmada 5-kat çapraz doğrulamaya ilişkin kesinlik ve kayıp eğrileri ise EK-1’de sunulmuştur.

4.1.5. Capsnet modeli

Bu modelde orijinal kapsül ağırları makalesindeki mimariye benzer bir kapsül mimarisi kullanılmış olup Şekil 4.26’da sunulmaktadır:



Şekil 4.26. Uygulanan capsnet mimarisi

Şekil 4.26’da sunulan mimarinin orijinal mimariden farkı Conv1 katmanında ve Primary Caps bloklarında 256 yerine 64 filtre kullanılmış olmasıdır. Bu değişikliğin nedeni ortam kısıtları ve kullanılan görüntü boyutunun göreceli olarak daha büyük olması nedeniyle ağı eğitilememesidir.

Deney#17

Orijinal Kapsül ağı mimarisinin [11], [74] ve [75] nolu kaynaklardaki kodlardan faydalanılarak bizim problemimize uyarlanmış haliyle yapılan 5-kat çapraz doğrulama sonucunda elde edilen karışıklık matrisi Çizelge 4.23’de verilmiş olup, bu matrizen oluşturulan performans metrikleri ise Çizelge 4.24’de yer almaktadır.

Çizelge 4.23. Karışıklık matrisi (deney#17)

	Tahmin Edilen		
	Pituitary	Glioma	Meningioma
Pituitary	911	12	7
Glioma	11	1316	99
Meningioma	42	108	558

Çizelge 4.24. Deney#17 sonuçları

Meningioma		Glioma		Pituitary		Genel Kesinlik (%)
P (%)	R (%)	P (%)	R (%)	P (%)	R (%)	
84	78,8	91,6	92,3	94,5	98	90,9

Çizelge 4.24'den görüldüğü üzere, CapsNet mimarisinin problemimize göre uyarlanıp deneysel çalışmalarda uygulanmasıyla genel sınıflandırma kesinliği olarak %90,9 performans değeri yakalanabilmiştir. Glioma tümörü hassasiyet değeri açısından ise %92 performans başarısı elde edilebilmiştir. En başarılı sonuç ise yine Pituitary hassasiyet metriği açısından %98 olarak elde edilmiştir.

5. GELİŞTİRİLEN ALGORİTMA VE MODELLER

Tez çalışması kapsamında Giriş bölümünde tanımlanan problem uzayına çözüm olarak literatürde mevcut yöntemlerin farklı parametre ve mimarilerle uygulanmasının yanı sıra 4 yeni algoritma ve model de tarafımızca önerilmiştir. Bunlardan ilk ikisi geleneksel makine öğrenmesi kapsamında geliştirilen algoritmalar. Diğer ikisi ise kapsül ağları dinamik yönlendirme algoritmasında ağırlık güncelleme işleminin değiştirilmesi ve bunun ESA-Kapsül mimarisinde kullanılmasıyla elde edilen model ve literatürde mevcut Xception modeliyle Kapsül ağları dinamik yönlendirme katmanının birleştirilmesiyle elde ettiğimiz XCaps modelidir. Önerilen algoritma ve modellerin detayları takip eden alt bölümlerde verilmektedir.

5.1. Önerilen Piksel Histogram Tabanlı Algoritma


MR görüntüsünden geleneksel makine öğrenmesi algoritmalarıyla beyin tümörü çeşidinin tespitine yönelik varsayılan yöntem haricinde, tez çalışması kapsamında 2 farklı algoritma önerilmektedir. Önerilen bu algoritmanın aşamaları Çizelge 5.1’de verilmiştir.

Çizelge 5.1. Piksel histogram dağılımı temelli sınıflandırma algoritması sözde kodu

Algoritma: Piksel Histogram Dağılımı temelli sınıflandırma algoritması
Girdi: I_{jpeg} : JPEG formatında MR görüntüsü Çıktı: $I_{prediction}$: sınıflandırma etiketi Adım1: $I_{scaled} \leftarrow I_{jpeg}$ MR görüntüsü 128x128x3 boyutuna ölçeklendirilir Adım2: $I_{gray} \leftarrow I_{scaled}$ Görüntü gri seviyeli dosyaya dönüştürülür Adım3: $I_{blurred} \leftarrow \text{GaussianBlur}(I_{gray})$ Adım4: $I_{hist-blurred} \leftarrow \text{Histogram}(I_{blurred})$ Adım5: $I_{inputVector} \leftarrow \text{Normalize}(I_{hist-blurred})$ Adım6: $I_{prediction} \leftarrow \text{Sınıflandırma Algoritması}(I_{inputVector})$ Sonuç: $I_{prediction}$

Bunlardan ilki piksel histogram dağılımının esas almaktadır. Bunun nedeni tümör bölgelerinin belirgin bir renk farkı olmakta olup bu durum piksel değerlerinin dağılımında bir farklılık dolayısıyla sınıflandırmada ayırt edici bir özellik sağlayabilir. Önerilen algoritmanın iş akış diyagramı ise Şekil 5.1’de yer almaktadır. Buna göre öncelikle beyin

MR görüntüsü 128x128x3 boyutuna ölçeklendirilir ve sonrasında gri seviyeli görüntüye dönüştürülür.




Şekil 5.1. Piksel histogram dağılımı temelli algoritma akışı

Daha sonra gri seviyeli JPEG dosyası Gaussian Bulanıklaştırma işlemi uygulanarak yumuşatılır ve görüntüdeki parlak bölgelerin vurgulanması sağlanır. Bulanıklaştırma operasyonu Eş. 5.1' de verilen formülle gerçekleştirilir.

$$G(x, y) = \frac{1}{2\pi\sigma^2} e^{-\frac{x^2+y^2}{2\sigma^2}} \quad (5.1)$$

Bulanıklaştırılan görüntüden histogram değerleri elde edilerek sınıflandırma algoritması için girdi vektörü oluşturulmaktadır. Histogram grafikleri her bir değer ile bu değere sahip örnek sayısının ilişkisini göstermektedir. Şekil 5.2'de bir MR görüntüsüne sahip örnek bir histogram grafiği verilmektedir. Gri seviyeli görüntülerde piksel değerleri 0-255 arasında değerler aldığından Şekil 5.2'de verilen örnekte de 0-255 arasındaki her bir değere sahip piksel sayıları gösterilmektedir. Bu örnekte 50-100 değerine sahip piksellerin sayısındaki farklılık göze çarpmaktadır. Beyin MR görüntülerinde tümörlü bölgelerin varlığından

kaynaklı renk deęişimleri de buna benzer farklılıklar ortaya koyarak normal görüntülerden ayırt edilmesini sağlayabilirler.



Şekil 5.2. Örnek histogram

5.1.1. Deney#18

Bu deneysel çalışmada önerdiğimiz piksel histogramı tabanlı yöntem ile sınıflandırma yapılmıştır. Yöntemin son adımında farklı makine öğrenmesi algoritmaları kullanılmış ve veri setinde sağlanan çapraz doğrulama indeksleri kullanılarak 5-kat çapraz doğrulama ile eğitim gerçekleştirilmiştir. Kullanılan algoritmalar ve elde edilen performans değerleri Çizelge’de sunulmuştur. Kullanılan algoritmalar ve elde edilen performans değerleri Çizelge 5.2’de sunulmuştur.

Çizelge 5.2. Deney#18 sonuçları

Algoritma	Meningioma		Glioma		Pituitary		Genel Kesinlik (%)
	P (%)	R (%)	P (%)	R (%)	P (%)	R (%)	
K-EYK	49	52	81	78	80	82	73
LR	41	11	67	86	67	75	66
Karar ağaçları	41	44	76	74	74	72	67
XGBoost	52	48	81	83	81	82	75
DVM	53	1	64	94	70	71	66
LightGBM	52	50	82	83	82	82	75

Çizelge 5.2’de verilen sonuçları incelediğimizde önerilen yöntemde de 10 performans metriğinin 8’inde en iyi sonuçları yine LightGBM algoritmasının yakaladığı görülürken, önerilen yöntem genel sınıflandırma kesinliği açısından varsayılan yönteme göre bariz bir ilerleme sağlayamamıştır.

5.2. Önerilen Yerel İkili Desenler Tabanlı Algoritma


Bölüm 5.1’de anlatılan yöntemde sadece tümörlü görüntülerdeki piksel değerlerinin dağılımının farklılığından yararlanılmıştır.

Çizelge 5.3. Yerel ikili desenler temelli algoritma sözde kodu

Algoritma: Yerel İkili Desenler Temelli Algoritma
Girdi: I_{jpeg} : JPEG formatındaki MR görüntüsü Çıktı: $I_{prediction}$: sınıflandırma etiketi Adım1: $I_{scaled} \leftarrow I_{jpeg}$ MR görüntüsü 128x128x3 boyutuna ölçeklendirilir. Adım2: $I_{gray} \leftarrow I_{scaled}$ Görüntü gri seviyeli dosyaya dönüştürülür Adım3: $I_{blurred} \leftarrow \text{GaussianBlur}(I_{gray})$ Adım4: $I_{lbp} \leftarrow \text{LocalBinaryPatterns}(I_{blurred})$ Adım5: $I_{hist-blurred} \leftarrow \text{Histogram}(I_{blurred})$ Adım6: $I_{hist-lbp} \leftarrow \text{Histogram}(I_{lbp})$ Adım7: $I_{inputVector} \leftarrow \text{Concatinate}(\text{Normalize}(I_{hist-blurred}), \text{Normalize}(I_{hist-lbp}))$ Adım8: $I_{prediction} \leftarrow \text{LightGBM}(I_{inputVector})$ Sonuç: $I_{prediction}$


Beyin tümörlerinin belirgin bir şekli olmasa da genelleyebilecek bir dokusu olduğundan bu özelliklerin de vurgulanması için önerilen algoritma Çizelge 5.3’deki gibi güncellenerek deneysel çalışma tekrarlanmıştır. Bu yöntemde önerilen önceki yöntemden farklı olarak MR görüntüsünün iki boyutlu LBP değerleri de hesaplanmaktadır. Lokal ikili desenler yöntemi daha çok dijital resimlerde desen ve doku tanımada kullanılır. LBP hesaplaması yapılırken bir pikselin etrafında komşu pikseller 0 veya 1 olarak değiştirilir. Eğer bir komşu pikselin değeri, hedef pikselden büyük veya eşitse 1 değerini, değilse 0 değerini alır. Bu işlemin devamında elde edilen 0-1 değerleri saat yönünde geçilerek 8 bit uzunluğunda bir ikili sayı elde edilir. Bu sayının onluk değeri nihai değer olarak 2 boyutlu LBP matrisinde hedef pikselin pozisyonuna kaydedilir. Bu işlem bütün pikseller için

tekrarlanarak gri seviyeli resim dosyası ile aynı boyuta sahip 2 boyutlu LBP matrisi elde edilir. Şekil 5.3’de lokal ikili desen hesaplaması gösterilmektedir:



Şekil 5.3. Lbp hesaplama örneği

Önerilen yöntemde piksel histogram değerlerinin normalleştirilmiş haliyle yerel ikili desenler histogram değerlerinin normalleştirilmiş hali ardışık olarak birleştirilerek sınıflandırma için girdi vektörü oluşturulmaktadır. Önerilen algoritmanın iş akış diyagramı ise Şekil 5.4’de yer almaktadır.



Şekil 5.4. Yerel ikili desenler temelli algoritma

5.2.1. Deney#19

Bu deneysel çalışmada Bölüm 5.2’de anlatılan Yerel İkili Desenler Tabanlı Algoritma kullanılmaktadır. Modellerin eğitilmesi için yine farklı makine öğrenmesi algoritmaları kullanılmış ve veri setinde sağlanan çapraz doğrulama indeksleri kullanılarak 5-kat çapraz doğrulama ile eğitim gerçekleştirilmiştir. Kullanılan algoritmalar ve elde edilen performans değerleri Çizelge 5.4’de sunulmuştur.

Çizelge 5.4. Deney#19 sonuçları

	Meningioma		Glioma		Pituitary		Genel Kesinlik (%)
Algoritma	P (%)	R (%)	P (%)	R (%)	P (%)	R (%)	
K-EYK	49	50	80	80	81	82	73
LR	40	11	68	86	68	77	66
Karar ağaçları	42	44	76	77	77	75	69
XGBoost	53	49	83	84	81	84	76
DVM	23	0	64	94	71	74	66
LightGBM	54	51	84	85	82	85	77

LightGBM algoritmasıyla elde edilen sonuçlar açısından kullanılan yöntemlerin karşılaştırılması Çizelge 5.5’de verilmiştir.

Çizelge 5.5. Deneysel çalışma sonuçları karşılaştırması

	Meningioma		Glioma		Pituitary		Genel Kesinlik (%)	Süre
Yöntem	P(%)	R(%)	P(%)	R(%)	P(%)	R(%)		
Varsayılan	63	67	81	76	76	79	75	2463 sn.
Piksel Histogram Dağılımı	52	50	82	83	82	82	75	48 sn.
Yerel İkili Desenler	54	51	84	85	82	85	77	54 sn.

Çizelge 5.4’de verilen sonuçları incelediğimizde en iyi sonuçları yine LightGBM algoritması elde etmiştir. Bu yöntem hem varsayılan yönteme hem de önerdiğimiz ilk yönteme göre daha başarılı sonuçlar elde ederek genel sınıflandırma kesinliğini %75’den %77’ye yükseltmiştir. Sınıflandırma kesinliğini gösteren değerler incelendiğinde en

yüksek 2 sonucu sırasıyla XgBoost ve LightGBM algoritmalarının yakaladığı görülmektedir. Geleneksel makine öğrenmesi algoritmalarıyla yapılan sınıflandırmada varsayılan yöntem haricinde 2 yeni yöntem önerilerek deneyse çalışmalar yapılmış ve en iyi sonuçları LightGBM algoritması elde etmiştir. Çizelge 5.5'i incelediğimizde LightGBM algoritmasının kullanılması durumunda en iyi sonuçları önerilen yerel ikili desenler temelli algoritma elde etmiştir. Eğitim süresi açısından ise önerilen yöntemler varsayılan yöntemle göre çok çok kısa sürede eğitilebilmiştir. Yerel ikili desenlerin kullanılması beyin tümör tiplerinin tespitinde performans değerlerini artırmıştır. Bunun muhtemel sebebi tümör bölgesine ilişkin kenarların belirgin hale getirilerek nitelik setinin temsil gücünün artırılmış olmasıdır.

5.2.2. Deney#20

CE-MRI veri seti LOKAL veri setinden farklı olarak sadece axial görüntüleri değil aynı zamanda coronal ve sagittal görüntüler de içermektedir. Fakat coronal ve sagittal görüntüler axial görüntülerden farklı olarak boğaz, yutak, boyun gibi beyin harici bölümler de içermektedir. Ayrıca axial görüntüler diğerine nazaran daha homojen bir arka plana sahiptir. Axial görüntüler önerilen yöntemler açısından daha az gürültüye maruz olup daha iyi performans vermesi beklenir. Bu nedenle Bölüm 5.2'de önerdiğimiz yerel ikili desenlerden faydalanan algoritmayı CE-MRI veri setinin sadece axial görüntüleri üzerinde eğiterek sonuçlar paylaşılmış ve literatürdeki benzer çalışmalarla karşılaştırılmıştır.

Çizelge 5.6'da her bir sınıflandırma algoritması için hem tüm veri seti hem de sadece axial veri seti kullanılması durumunda elde edilen sonuçlar paylaşılmıştır. Axial veri seti için sonuçlar bir alt satırda gösterilmiştir. Modelin eğitiminde rastgele 5-kat çapraz doğrulama gerçekleştirilmiştir.

Çizelge 5.6'da verilen sonuçlar incelendiğinde tüm algoritmalar için axial veri setinde elde edilen sınıflandırma kesinliği değerlerinin önemli oranda arttığı görülmektedir. Glioma tümörü hassasiyet değeri açısından da tüm algoritmalar axial görüntüler üzerinde daha iyi sonuç verirken Lojistik Regresyon algoritmasıyla %99'a varan performans değeri yakalanabilmiştir. Genel sınıflandırma kesinliği açısından en iyi sonuçlar yine LightGBM algoritmasıyla yakalanmış olup, bu algoritmayla glioma tümörü hassasiyet değeri açısından ise %95 performans değeri elde edilebilmiştir.

Çizelge 5.6. Axial veri setindeki sonuçların karşılaştırılması

	Meningioma		Glioma		Pituitary		Genel Kesinlik (%)
Algoritma	P (%)	R (%)	P (%)	R (%)	P (%)	R (%)	
K-EYK	75	77	89	87	95	96	87
	82	87	96	93	94	95	92
LR	50	17	66	83	76	83	68
	87	10	68	99	92	80	75
KA	61	61	83	83	89	88	80
	73	72	92	92	89	89	87
XGBoost	77	76	90	89	93	95	88
	82	81	95	94	92	96	92
DVM	50	1	64	93	79	83	69
	73	14	75	98	89	93	79
LightGBM	83	82	93	92	95	96	91
	85	84	96	95	93	96	93

5.2.3. Deney#21

Bu deneysel çalışmada Lokal veri seti üzerinde önerilen yerel ikili desenler tabanlı algoritma kullanılarak sınıflandırma işlemi gerçekleştirilmiştir. Sınıflandırma işleminde normal vakaya ait 2280 görüntü ile birlikte 65 GBM vakasına ait tümörlü 649 görüntü olmak üzere toplam 2929 görüntü kullanılmıştır. Bu sınıflandırma işleminde T2 ağırlıklı bir MR görüntüsünde GBM tümörü olup olmadığı, önerilen yerel ikili desenler tabanlı algoritma ile 5-kat çapraz doğrulama ile tespit edilmiştir. Deneysel çalışma sonuçları Çizelge 5.7’de verilmiştir:

Çizelge 5.7. Deney#21 sonuçları

	GBM Tümörü		Normal		Genel Kesinlik (%)
Algoritma	P(%)	R(%)	P(%)	R(%)	
K-EYK	94	85	96	99	96
LR	87	27	83	99	83
KA	83	83	95	95	92
XGBoost	94	86	96	98	96
DVM	86	39	85	98	85
LightGBM	94	89	97	98	96

Çizelge 5.7’den görüldüğü üzere 7 performans metriği açısından en iyi sonuçları LightGBM algoritması elde etmiştir.

5.2.4. Deney#22

Bu sınıflandırma işleminde T2 ağırlıklı bir MR görüntüsünün tümör içerip içermediğine bakılmaksızın GBM vakasına mı yoksa normal vakaya mı ait olduğu önerilen yerel ikili desenler tabanlı algoritma kullanılarak 5-kat çapraz doğrulama ile tespit edilmiştir. Modelin eğitilmesinde normal vakaya ait 2280 görüntü ile birlikte 65 GBM vakasına 1300 görüntü olmak üzere toplam 3580 görüntü kullanılmıştır. Deneysel çalışma sonuçları Çizelge 5.8’de verilmiştir.

Çizelge 5.8. Deney#22 sonuçları

Algoritma	GBM Vakası		Normal Vaka		Genel Kesinlik (%)
	P(%)	R(%)	P(%)	R(%)	
K-EYK	94	87	93	97	93
LR	93	59	81	98	83
KA	83	84	91	90	88
XGBoost	94	87	93	97	93
DVM	93	59	81	97	83
LightGBM	95	90	95	97	95

Çizelge 5.8’den görüldüğü üzere en iyi sonuçları bu çalışmada da LightGBM algoritması elde etmiştir.

Geleneksel makine öğrenmesi algoritmasının yanı sıra, çalışılan problem dijital görüntüler üzerine kurulu olduğundan derin öğrenmeye dayalı modeller de önerilerek deneysel çalışmalar yapılmıştır.

5.3. Önerilen Geliştirilmiş Esa-Kapsül Modeli

Bu yöntemde ESA ağlarındaki tam bağlantılı katman yerine Kapsül ağlarının dinamik yönlendirme algoritmasının çalıştığı katman kullanılmıştır. Orijinal algoritma Şekil 5.5’de yer almaktadır.

Procedure 1 Routing algorithm.

```

1: procedure ROUTING( $\hat{u}_{j|i}$ ,  $r$ ,  $l$ )
2:   for all capsule  $i$  in layer  $l$  and capsule  $j$  in layer  $(l + 1)$ :  $b_{ij} \leftarrow 0$ .
3:   for  $r$  iterations do
4:     for all capsule  $i$  in layer  $l$ :  $c_i \leftarrow \text{softmax}(b_i)$ 
5:     for all capsule  $j$  in layer  $(l + 1)$ :  $s_j \leftarrow \sum_i c_{ij} \hat{u}_{j|i}$ 
6:     for all capsule  $j$  in layer  $(l + 1)$ :  $v_j \leftarrow \text{squash}(s_j)$ 
7:     for all capsule  $i$  in layer  $l$  and capsule  $j$  in layer  $(l + 1)$ :  $b_{ij} \leftarrow b_{ij} + \hat{u}_{j|i} \cdot v_j$ 
   return  $v_j$ 

```

Şekil 5.5. Dinamik yönlendirme algoritması

Ancak tez çalışması kapsamında daha önce anlatılan Kapsül mimarisi dinamik yönlendirme algoritmasının ağırlık güncelleme işleminde değişikliğe gidilmektedir. Bu algortmada 7.satırda ağırlıklar için güncelleme yapılırken b_{ij} mevcut değerine j kapsülünün çıktı vektörü ile i kapsülünün j kapsülüne gönderdiği girdi vektörünün nokta çarpımı eklenir. İki vektör arasında nokta çarpımı işlemi aralarındaki “benzerliği” ifade eder. Yani b_{ij} değeri l ve $l+1$ seviyesindeki i ve j iki kapsüllerinin benzerliğiyle güncellenir. $\text{Sim}_r(i,j)$ r döngüsündeki i ve j kapsüllerinin benzerliğini ifade edecek olursa her bir döngüde kullanılacak b_{ij} değerleri Çizelge 5.9’daki gibi olacaktır:

Çizelge 5.9. Ağırlık güncelleme formülasyonu

Döngü Sayısı	b_{ij} değeri
$r=1$	0
$r=2$	$\text{Sim}_1(i,j)$
$r=3$	$\text{Sim}_1(i,j) + \text{Sim}_2(i,j)$
$r=k$	$\sum_{r=1}^{k-1} \text{Sim}_r(i,j)$


Çizelge 5.9’dan da görüldüğü üzere b_{ij} değerleri her bir döngüde, önceki döngülerdeki değerlerinin toplamına eşit olmaktadır. İlk döngü sonucu oluşan benzerlik rastgele dağılımla belirlendiğinden b_{ij} değerleri önceki döngülerdeki benzerliklere ve özellikle de ilk döngüde eğitim olmaksızın elde edilen başlangıç benzerliğine karşı ön yargılı (biased) olmaktadır. Dolayısıyla önceki b_{ij} değerlerinin yeni hesaplamaya katılma oranının azaltılması, l seviyesindeki kapsüllerin her bir döngüde öğrendiği özelliği daha etkin vurgulamasını sağlayabilir. Bu hipotezden yola çıkarak Kapsül ağlarının dinamik yönlendirme algoritmasında ağırlık güncelleme satırı değiştirilerek önceki b_{ij} değerlerinin farklı seviyelerinde katkılarına göre farklı modeller de eğitilmiştir. Tarafımızca önerilen

değişiklikte bu algoritmanın 7. Satırında yer alan ağırlık güncelleme işlemi Eş. 4.5'deki gibi yapılmaktadır:

$$b_{ij} \leftarrow k \cdot b_{ij} + \mu_{j|i} \cdot v_j \quad (4.5)$$


Bu sayede önceki ağırlık değerinin yeni ağırlık değerine etkisi bir k parametresiyle kontrol edilerek algorithmada niteliklerin temsil gücünün optimizasyonu sağlanabilecektir. Bu eşitlikte $k=1$ için algoritma orijinal haliyle çalışmaktadır. Kapsül ağlarının bazı uygulamalarında [74], önceki ağırlık değeri kullanılmadan niteliklerin temsil gücünün artırılması hedeflenmiştir. Önerdiğimiz bu değişiklikle ise farklı olarak, önceki ağırlık değerlerinin etkisini tamamen ortadan kaldırmak yerine optimize edilebilir hale getirilerek en uygun k değeri bulunmaya çalışılmaktadır.

Dinamik yönlendirme algoritmasının ağırlık güncelleme işlemi değiştirilerek önerilen modelin mimarisi Şekil 5.6'da verilmiştir:




Şekil 5.6. Geliştirilmiş esa-kapsül mimarisi

Şekil 5.6'da verilen ESA-Kapsül mimarisinin ilk üç bloğunun yapısı Şekil 5.7'de yer almaktadır:



Şekil 5.7. Esa-kapsül mimarisi blok yapısı


Bu bloklardaki katman sayıları sırasıyla 32, 64, 96 olarak belirlemiştir. Bu katmanlarda 3x3 filtreler kullanılırken, havuz katmanında 2x2 filtreler kullanılmıştır. ESA-Kapsül mimarisinin dördüncü blok önceki bloklardan farklı bir yapıda olup bu bloğunun yapısı ise Şekil 5.8’de verilmiştir:



Şekil 5.8. Esa-kapsül mimarisi 4.blok yapısı

5.3.1. Deney#23

Bu deneysel çalışmada önerdiğimiz Geliştirilmiş ESA-Kapsül modeli veri setinde sağlanan 5-kat çapraz doğrulama indekslerine göre eğitilmiştir.



Şekil 5.9. Karışıklık matrisi (deney#23)

Model, kapsül katmanının dinamik yönlendirme algoritmasında yapılan değişikliklerle eklenen k değeri için Bayes Optimizasyonu [76] yöntemiyle en iyi k değeri bulunmaya


çalışılmıştır. Optimizasyon sonucunda en iyi sonucu veren k değeri 0,2045 olup elde edilen karışıklık matrisi sonuçları Şekil 5.9’da yer almaktadır.

Karışıklık matrisine göre elde edilen performans değerleri ise Çizelge 5.10’da verilmiştir.

Çizelge 5.10. Deney#23 sonuçları

Meningioma		Glioma		Pituitary		Genel Kesinlik (%)
P (%)	R (%)	P (%)	R (%)	P (%)	R (%)	
84,6	80	93	93,3	93,9	97,2	91,42

Deneysel çalışmada 5-kat çapraz doğrulamada elde edilen kesinlik ve kayıp eğrileri ise sırasıyla EK-1’de verilmiştir. Bayes optimizasyon işleminde farklı k değerleri için elde edilen genel sınıflandırma kesinliği değerlerinin dağılımı Şekil 5.10’da yer almaktadır:



Şekil 5.10. Kapsül optimizasyonu performans dağılımı

Şekil 5.10 incelendiğinde k değeri ile sınıflandırma performansı arasında bariz bir doğrusal ilişki gözlenmese de, 0,9 sınıflandırma kesinliği üzerindeki değerler dikkate alındığında bu değerleri sağlayan k değerlerinin 0,1 ile 0,6 arasında değiştiği görülmekte olup bu durum bu konudaki hipotezimizi belli ölçüde desteklemektedir. CE-MRI veri seti üzerinde önerilen ve veri setinin 5-kat çapraz doğrulama indekslerine göre doğrulama yapılan derin öğrenme modellerinin karşılaştırılması Çizelge 5.11’de verilmiştir. Çizelge 5.11’den


görüldüğü üzere tüm performans metrikleri açısından en iyi sonuçları geliştirilmiş ESA-Kapsül modeli elde etmiştir.

Çizelge 5.11. Deneysel çalışma sonuçları karşılaştırması

	Meningioma		Glioma		Pituitary		
Deney Kodu	P (%)	R (%)	P (%)	R (%)	P (%)	R (%)	Genel kesinlik (%)
ESA modeli	79,6	75	90,2	90,5	92,2	95,8	88,54
ESA modeli	83,4	76,7	90,8	92,4	92,4	95,7	89,71
ESA-Kapsül	81,7	78,8	92	91,4	93,3	96,7	90,07
Geliştirilmiş ESA-Kapsül	84,6	80	93	93,3	93,9	97,2	91,42


5.4. Önerilen Xcaps Modeli

Literatürdeki derin öğrenme modellerinin gelişimini incelediğimizde son katmanda yapılan değişiklikler dikkat çekmektedir. Örneğin VGG ile son katmanda tam bağlantılı ağ önerilirken, daha sonra önerilen ResNet modelinde ise global ortalama havuzu kullanılmıştır. Buradan yola çıkarak, literatürde daha önce önerilen Xception modelinde [5] son katmanda tam bağlantılı ağ kullanmak yerine yeni bir teknoloji olan kapsül ağları dinamik yönlendirme katmanı kullanılmasının performansı artıracağı düşünülerek, Xception modelinde global ortalama havuzu öncesindeki katmanlar ile CapsNet [11] mimarisinin dinamik yönlendirme algoritmasının çalıştığı katman birleştirilerek yeni bir model oluşturulmuş olup tarafımızca XCaps modeli olarak adlandırılmıştır. XCaps modelinin mimarisi Şekil 5.11’de verilmiştir:



Şekil 5.11. Önerilen xcaps mimarisi

Orijinal Xception mimarisinde global ortalama havuzundan sonra 2048 boyutundaki vektörler ve tam bağlantılı katman yerine önerilen mimaride kapsül mimarisinin dinamik yönlendirme katmanı kullanılmaktadır. Yani orijinal Xception modelinin mimarisinde son katmanda yer alan çıkış akışı değiştirilmiş olup yeni çıkış akışı Şekil 5.12’de sunulmaktadır:




Şekil 5.12. Önerilen xcaps mimarisi çıkış akışı

Literatürde Xception ve kapsül mimarisinin birlikte kullanıldığı –bildiğimiz kadarıyla- bir yayın [77] bulunmakta olup bu çalışmada Xception çıktısı CapsNet modelinin birincil kapsüller katmanına bağlanmaktadır. Önerdiğimiz modelde ise farklı olarak Xception modelinin çıkış akışında yer alana global ortalama havuzu katmanının çıktısı yeniden şekillendirilerek CapsNet mimarisinin birincil kapsüller katmanı yerine doğrudan dinamik yönlendirme kapsüllerine bağlanmaktadır. XCaps modeli tam bağlantılı katman yerine dinamik yönlendirme katmanını kullanması sayesinde, Xception modelinin eğitilmesi gereken parametre sayısını 23 milyondan 21 milyona yaklaşık %10 civarında azaltmış olup CE-MRI veri setinde de sınıflandırma performansını %96,3’den %96,74’e yükseltmiştir.

5.4.1. Deney#24

Bu deneysel çalışmada önerdiğimiz XCaps modeli, veri setinin rastgele bölünmesi ile oluşan eğitim ve doğrulama setleri kullanılarak eğitilmiştir. Doğrulama seti oranı %30 olarak belirlenmiştir. Elde edilen karışıklık matrisi Şekil 5.13’de verilmiştir:




Şekil 5.13. Karışıklık matrisi (deney#24)

Karışıklık matrisine göre elde edilen performans değerleri ise Çizelge 5.12’de yer almaktadır. Çizelge 5.12’de verilen sonuçları incelediğimizde önerdiğimiz XCaps modeli genel sınıflandırma kesinliği açısından %96,74 performans değeri yakalayarak Xception modelinden daha iyi sonuç elde ettiği görülmektedir.

Çizelge 5.12. Deney#24 sonuçları

Meningioma		Glioma		Pituitary		Genel Kesinlik (%)
P (%)	R (%)	P (%)	R (%)	P (%)	R (%)	
95	92,2	96,7	97,4	98,2	99,6	96,74

Deneyssel çalışmada elde edilen kesinlik ve kayıp eğrileri grafikleri Şekil 5.14’de verilmiştir.



Şekil 5.14. Deney#24 kesinlik ve kayıp eğrileri a) kesinlik eğrisi b) kayıp eğrisi


Çizelge 5.13. Deneysel çalışma sonuçları karşılaştırması

Meningioma		Glioma		Pituitary		Genel Kesinlik (%)	Model	Eğitim verisi oranı (%)
P (%)	R (%)	P (%)	R (%)	P (%)	R (%)			
91,4	87,6	95	95,9	97	98,9	94,88	ESA-Kapsül	50
95	91,3	96,3	97,1	97,4	99,3	96,3	Xception	70
97,2	89,1	95	98,6	98,5	99,6	96,52	ESA-Kapsül	70
95	92,2	96,7	97,4	98,2	99,6	96,74	XCaps	70

CE-MRI veri seti üzerinde rastgele veri bölme ile yapılan eğitimlerde elde edilen performans sonuçları Çizelge 5.13’de karşılaştırılmaktadır. Çizelge 5.13’de yer alan sonuçlar dikkate alındığında eğitim verisinin miktarı arttıkça genel sınıflandırma kesinliği de artmaktadır. Bu sonuç beklenen bir sonuçtur çünkü eğitilen bir modele sunulan farklı veri miktarı arttıkça modelin genelleme başarısı da artmaktadır. Aşırı öğrenmeyi, yani eğitim esnasında yüksek performans alınırken doğrulama verisinde düşük performans çıkmasını engelleme yöntemlerinden birisi olan veri artırma mantığı da bunu desteklemektedir. Çizelgede dikkate alınması gereken diğer bir nokta ise %70 eğitim verisi kullanan modellerden Xception modeline göre önerilen XCaps modelinin biraz daha iyi sonuç alabilmesidir. Kapsül dinamik yönlendirme katmanı tam bağlantılı katmanlara göre modellerin performansını artırmaktadır.

5.5. MR Görüntülerinin Sekans Bazlı Analizi

Bu çalışma kapsamında LOKAL veri üzerinde, T2 ağırlıklı MR serisindeki bir görüntünün normal veya GBM vakası olup olmadığının otomatik tespiti gerçekleştirilmiştir. İş akış şeması Şekil 5.15’de verilmektedir. Burada kullanılan model önerilmiş yeni bir model değildir ancak bir MR görüntüsünün GBM vakasına mı yoksa normal vakaya mı ait olup olmadığını tespiti yönelik bir çalışmanın bildiğimiz kadarıyla henüz literatürde bulunmaması özgün yönünü oluşturmaktadır. Şekil 5.15’de verilen akış şemasının detaylarına geçmeden DICOM dosya formatını açıklamak gerekecektir. T2 ağırlıklı MR görüntü cihazı, yapılan çekime ilişkin hasta bilgileri, doktor bilgileri, işleme ait bazı veriler, cihaza ilişkin bir takım veriler ve görüntüye ilişkin piksel verilerini DICOM dosya formatında üretmektedir.



Şekil 5.15. İş akış şeması

Bu dosya formatının ilk bölümleri meta verilerden oluşmakta ardından ise piksel verileri gelmektedir. Deneysel çalışmalarda sadece piksel verisi gerekli olduğundan öncelikle DICOM formatı okunarak bu piksel verisi yeni bir Jpeg dosyası halinde kaydedilmektedir. Kişisel verilerin görüntüden ayrıştırılması, kişisel veri koruma kanunu açısından da zorunlu hale gelmiştir.

T2 ağırlıklı MR görüntü serisindeki her bir görüntü aynı boyuta sahip olmayabilir. Bu nedenle MR pikselleri Jpeg olarak kaydedildikten sonra bir takım resim ön-işlemeye tabi tutulmuştur. Bu kapsamda öncelikle genişliği ve/veya yüksekliği en fazla 320 olacak şekilde yeniden ölçeklendirilmiş, sonrasında ise görüntünün 320x320 ebatlarına tamamlanması için simetrik olarak 0 ile doldurma (padding) uygulanmıştır.

Sınıflandırma modeli olarak derin öğrenme yöntemlerinden biri olan ESA kullanılmıştır. Derin öğrenme algoritmaları veri boyutu yeterli büyüklükte olduğunda etkin sonuçlar vermektedir. Bu nedenle önerilen yaklaşımda sınıflandırma kesinliğinin artırılması için veri artırma, dropout teknikleri uygulanmıştır. Veri artırma kapsamında resimler için ölçeklendirme, rastgele döndürme, rastgele kaydırma, dikey çevirme gibi

yöntemler kullanılabilir. Bunlardan sadece rastgele döndürme, rastgele kaydırma ve dikey çevirme yöntemleri kullanılmıştır. Beyin MR görüntüleri dikey olarak neredeyse simetrik olduğundan dikey çevirme işlemi veri sayısını artırmada etkili bir yöntemdir. Ölçeklendirme yöntemi önerilen yaklaşımda etkisiz kalmaktadır. Ölçeklendirme kullanılmamasının nedeni resmin algoritmaya girdi olarak verilirken zaten sabit bir değere ölçeklendirilmesidir.

Dropout [78] tekniği yoğun katmanlar arasında ağırlık öğrenmek yerine ezberlemeye yönelmesini azaltmak için kullanılmaktadır. Bu teknikte bazı düğümler rastgele kapatılmakta, o döngü için hata hesaplamasında ve ağırlıkların güncellenmesinde kullanılmamaktadır. Tam bağlantılı katmanda Relu ve Sigmoid aktivasyon fonksiyonları kullanılmıştır. Sigmoid fonksiyonu 0 ile 1 arasında değerler üretmekte iken ReLU fonksiyonu, negatif girdiler için 0, pozitif girdiler için kendisini dönmektedir. Önerilen ESA modelinin tasarlanıp eğitilmesi için Keras [79] derin öğrenme kütüphanesi kullanıldı. Modelin eğitilmesi 5-Katlı Çapraz Doğrulama yöntemiyle gerçekleştirilmiştir. Buna göre her aşamada 179 resmin 35-36'sı test, geri kalanı eğitim verisi olarak ayrılmıştır. Veri artırma yöntemleri sonucu her bir eğitimde eğitim verisinin boyutu 50 katına çıkarıldı. Buna göre elde edilen sonuçlar Çizelge 5.14'de verilmiştir. Çizelge 5.14'de verilen değerler önerilen ESA modelinin kesinlik açısından %85,4 ve %94,4 arasında, hassasiyet açısından %81,2 ve %98 arasında, özgüllük açısından ise %73,8 ve %90,7 arasında değişen performans elde edebildiğini göstermektedir. Literatür çalışmalarında T2 ağırlıklı MR görüntüsünde tümör olup olmadığını tespiti yönelik çalışmalar mevcut iken, bir MR görüntüsünün GBM vakasına mı yoksa normal vakaya mı ait olup olmadığını tespiti yönelik bir çalışma bildiğimiz kadarıyla henüz bulunmamaktadır. Bu tespitin zorluğu, bazı MR görüntüleri normal vakadaki görünüme sahip olduğu halde, yani belirgin bir şekilde beyaz lezyon içermediği halde GBM vakasına ait olabilmektedir. Ancak deneysel çalışmalar ESA modelinin gözle bariz görülebilen farklılıklar içermese de GBM vakalarına ait MR görüntülerindeki görünmeyen bazı desenleri öğrenebildiğini göstermektedir.

5.6. Beyin Tümörü Erken Uyarı Sistemi ve Yöntemi

Bu bölümde, önceki bölümlerde detaylı olarak anlatılan ve beyin tümörünün otomatik tespitini sağlayan makine öğrenmesi modellerinden faydalanarak, radyoloji incelemesinde yoğunluktan kaynaklı geçen süreyi kısaltmak amacıyla özellikle GBM gibi ölümcül

tümörlerin tespiti halinde ilgili hekime anlık bilgilendirme yapılmasını sağlayacak bir erken uyarı sistemi önerilmektedir.

Çizelge 5.14. Deneysel çalışma sonuçları

	TN	FN	TP	FP	Genel Kesinlik (%)	Kesinlik (%)	Hassasiyet (%)
S0	110	10	55	4	92,1	93,2	84,6
S1	109	10	55	5	91,6	91,6	84,6
S2	105	17	48	9	85,4	84,2	73,8
S3	113	15	50	1	91	98	76,9
S4	108	13	54	6	90,5	90	83
S5	111	15	50	4	89,9	92,5	76,9
S6	111	9	56	3	93,2	94,9	86,1
S7	111	7	58	3	94,4	95	89,2
S8	110	10	55	4	92,1	93,2	84,6
S9	112	9	56	2	93,8	96,5	86,1
S10	110	9	56	4	92,7	93,3	86,1
S11	110	10	55	4	92,1	93,2	84,6
S12	106	15	50	8	87,1	86,2	76,9
S13	104	7	58	10	90,5	85,2	89,2
S14	113	16	49	1	90,5	98	75,3
S15	108	9	56	6	91,6	90,3	86,1
S16	105	10	55	9	89,3	85,9	84,6
S17	107	10	55	7	90,5	88,7	84,6
S18	102	13	52	12	91,6	81,2	80
S19	106	6	59	8	92,1	88	90,7


Erken uyarı sistemi temel olarak;

- bir veri şebekesi üzerinden veri alışverişi gerçekleştirmek üzere yapılandırılan en az bir iletişim cihazı,
- belirli anatomik yapıları görüntülemek üzere yapılandırılan en az bir MR cihazı,
- MR cihazı tarafından üretilmiş dosyaları saklamak ve bunlara bir şekilde erişim sağlamak üzere yapılandırılmış bir veri servisi,
- MR cihazı tarafından üretilmiş görüntü dosyalarını saklamak üzere yapılandırılan en az bir veri deposu,
- MR cihazı tarafından üretilmiş DICOM dosyalarını saklamak üzere yapılandırılan en az bir veri deposu,

- Veri servisi veya MR cihazı üzerinden elde edilen dosyalardan tümör tespiti yapılmasını sağlamak üzere yapılandırılan en az bir tespit modülü,
- Veri servisi veya MR cihazı üzerinden girdi olarak aldığı bir DICOM dosyasını, MR işlemcisine, tümör bölgesi tespit modeline ve tümör tespit modeline uygun bir çıktıya dönüştürerek gönderilmesini sağlayan DICOM işlemcisi,
- Veri servisi veya MR cihazı üzerinden girdi olarak aldığı bir MR görüntüsünü, tümör bölgesi tespit modeline ve/veya tespit modeline uygun bir çıktıya dönüştürerek gönderilmesini sağlayan MR işlemcisi,
- DICOM işlemcisi ve MR işlemcisinden aldığı veriyi tespit modeline uygun bir çıktıya dönüştürerek gönderilmesini sağlayan Tümör bölgesi tespit modeli,
- DICOM işlemcisi, MR işlemcisi ve Tümör bölgesi tespit modelinden aldığı veri ile beyin tümörü olup olmadığını ve olması durumunda tümör tipini veya vakanın normal mi GBM mi olduğunu veya GBM olması durumunda alt türlerini tespit eden tümör tespit modeli
- Tümör tespit modeli ve veri servisinden aldığı bilgilerle ilgili hekime bir internet veya intranet ağı üzerinden uyarı gönderilmesini sağlayan uyarı servisinden oluşmaktadır.

Sistemde yer alan manyetik rezonans görüntüleme cihazı, beyin görüntülerini T1, T1C, T2W ve flair tipinde ve eksenel, koronal ve sagittal düzlemde çekmek ve çekilen görüntüleri iki veya üç boyutlu bilimsel verilerin depolanması, görüntülenmesi ve analizinde kullanılmak amacıyla geliştirilmiş olan dijital veri formatına (DICOM) üretmek ve dönüştürmek üzere yapılandırılmaktadır.


Veri servisi, içerisinde MR görüntüleme cihazı tarafından üretilmiş görüntülerin, sıklıkla kullanılan bir resim formatında tutulmasını ve erişimini sağlamak, DICOM ve benzer formattaki dosyaları saklamak ve erişimini sağlamak, MR görüntülerinin ait olduğu hasta bilgilerini tutmak ve erişimini sağlamak, hasta ve hekim eşleştirmelerini tutmak ve bu bilgiye erişimi sağlamak üzere yapılandırılmış olup MR cihazına dahili, entegre veya ayrı bir şekilde çalışabilmektedir. Önerilen erken uyarı sisteminin mimarisi Şekil 5.16'da verilmiştir. Tespit Modülü tez çalışması kapsamında gerçekleştirilen özgün çalışmaların kullanılacağı modüldür. Tespit modülü, MR cihazı, veri servisi ve uyarı servisi ile iletişim halinde olmak üzere yapılandırılmaktadır.



Şekil 5.16. Erken uyarı sistemi mimarisi

Modül temel olarak 4 bileşenden oluşmaktadır. Bunlar:

- Veri servisi veya MR cihazı üzerinden girdi olarak aldığı bir DICOM dosyasını, MR işlemcisine, tümör bölgesi tespit modeline ve tespit modeline uygun bir çıktıya dönüştürerek gönderilmesini sağlayan DICOM işlemcisi ,
- Veri servisi veya MR cihazı üzerinden girdi olarak aldığı bir MR görüntüsünü, tümör bölgesi tespit modeline ve/veya tespit modeline uygun bir çıktıya dönüştürerek gönderilmesini sağlayan MR işlemcisi,
- DICOM işlemcisi ve MR işlemcisinden aldığı veriyi tespit modeline uygun bir çıktıya dönüştürerek gönderilmesini sağlayan Tümör bölgesi tespit modeli,
- DICOM işlemcisi ve MR işlemcisi ve Tümör bölgesi tespit modelinden aldığı veri ile beyin tümörü olup olmadığını ve olması durumunda tümör tipini veya vakanın normal mi GBM mi olduğunu veya GBM olması durumunda alt türlerini tespit eden tümör tespit modelidir. Tespit modülü mimarisi Şekil 5.17’de verilmektedir



Şekil 5.17. Tespit modülü mimarisi

DICOM işlemcisinde;

- alınan bir DICOM dosyasından piksel verisinin okunması,
- okunan piksel verisinde piksel değerlerinin 8 bit uzunluğundan daha uzun veri alanlarında tutulması durumunda 8 bitlik değerlere dönüştürülmesi,
- dönüştürülen piksel verisinin MR görüntüsü olarak kaydedilmesi,
- okunan piksel verisinin veya dönüştürülen piksel verisinin çoğunlukla orjinalden daha küçük bir boyuta ölçeklendirilmesi,

- yeniden boyutlandırılan verinin tümör bölgesi tespit modeline veya doğrudan tespit modeline iletilmesi gerçekleştirilmektedir.

MR işlemcisinde ise;

- alınan bir MR görüntüsünün gri seviyeli görüntüye dönüştürülmesi,
- görüntünün normalleştirilmesi ve çoğunlukla orjinalden daha küçük bir boyuta ölçeklendirilmesi,
- elde edilen çıktının tümör bölgesi tespit modeline veya tespit modeline gönderilmesi gerçekleştirilmektedir.

Tümör bölgesi tespit modeli ve tümör tespit modeli ise tez çalışması kapsamında uygulanan veya geliştirilen makine öğrenmesi modellerini ifade etmekte olup tümör tespit modeli tarafından oluşturulan tahmin sonucu uyarı servisine iletilmektedir.

Uyarı servisi tümör tespit modülünden gelen sonuca göre olumsuz bir durum varsa veri servisi ile iletişim kurarak hasta-hekim bilgilerini okumakta ve ilgili hekime kısa mesaj servisi ve/veya mobil bir uygulama aracılığıyla anlık bilgilendirme yapılmasını sağlamaktadır.

Önerilen bu erken uyarı sistemi sayesinde MR görüntüleri çekimden kısa bir süre sonra otomatik olarak analiz edilebilecek, daha önceden eğitilmiş makine öğrenmesi modelleriyle beyin tümörü olup olmadığı tespit edilebilecek ve özellikle GBM tümörü gibi ölümcül sonuçlara yol açabilen bir olumsuzluk tespit edildiğinde ise radyolog incelemesinde geçen süre kaybedilmeden ilgili hekime anlık olarak bilgilendirme yapılarak vakaya acil müdahale edilmesi sağlanabilecektir. Tasarlanan bu sistem için gerekli dokümanlar hazırlanarak patent başvuru süreci de başlatılmıştır.

6. SONUÇLARIN LİTERATÜR İLE KIYASLANMASI

Bu bölümde, Bölüm 4’de uyguladığımız mevcut yöntemlerle Bölüm 5’de geliştirdiğimiz yeni yöntemlerin elde ettiği performans değerlerinin literatür çalışmalarıyla karşılaştırılması yapılmaktadır. CE-MRI veri setinde aynı zamanda orijinal makalenin kullandığı 5-kat çapraz doğrulama indisleri de yer almaktadır. Ancak bazı çalışmalar bu indisleri kullanmak yerine rastgele 5-kat çapraz doğrulama veya rastgele veri bölme yöntemleri kullanmışlardır. Bu nedenle karşılaştırmalar doğrulama yöntemlerine göre ayrı alt başlıklar halinde aşağıdaki bölümlerde gerçekleştirilmiştir.

6.1. Sonuçların Orijinal Makale ile Karşılaştırılması

Bu bölümde CE-MRI veri seti üzerinde yapılan deneysel çalışma sonuçları, veri setini paylaşan makale [17] sonuçları karşılaştırılmaktadır. CE-MRI veri seti ile birlikte 5-kat çapraz doğrulamada kullanılacak indeksler de sağlanmıştır. Bu indeksler belirlenirken *hasta bazlı* belirlenmiş, yani aynı hastaya ait görüntüler eğitim ve doğrulama setinde aynı anda kullanılmamıştır.

Çizelge 6.1. Deneysel çalışma sonuçları literatür karşılaştırması

	Meningioma		Glioma		Pituitary		Genel Kesinlik (%)
Ref.	P (%)	R (%)	P (%)	R (%)	P (%)	R (%)	
[17]	85	86	95,7	96,4	88,9	87,3	91,14
Geliştirilmiş ESA-Kapsül	84,6	80	93	93,3	93,9	97,2	91,42

Çizelge 6.1’den görüldüğü üzere genel sınıflandırma kesinliği ve Pituitary metrikleri açısından en iyi sonuçları geliştirilmiş ESA-Kapsül modeli elde etmiştir.

Önerdiğimiz model herhangi bir nitelik mühendisliğine gerek duymaksızın doğrudan MR görüntü dosyasını girdi alarak analiz yaparken orijinal makalede öncelikle tümör bölgesinin tespit edilmesi, bu bölgeden nitelik seti oluşturulması ve performansın artırılması için tümör bölgesinin görüntü işleme teknikleriyle artırılmasına ihtiyaç

duymaktadır. Önerilen model bu tür işlem maliyetlerine maruz kalmadan daha iyi genel sınıflandırma kesinliği yakalayabilmiştir.

6.2. 5-Kat Çapraz Doğrulama Yapan Çalışmalarla Karşılaştırma

Önerilen modellerin orijinal makale sonuçlarıyla karşılaştırılması Bölüm 6.1’de anlatılmıştı. CE-MRI veri setini kullanan literatür çalışmalarının bir kısmı 5-kat çapraz doğrulama yaparken büyük çoğunluğu sabit bir eğitim verisi oranı belirleyerek deneysel çalışmaları gerçekleştirmiştir. 5-kat çapraz doğrulama yapan yayınlarla önerilen geliştirilmiş ESA-Kapsül modelinin performans karşılaştırılması ise Çizelge 6.2’de verilmiştir.

Çizelge 6.2. Deneysel çalışma sonuçları literatür karşılaştırması

	Meningioma		Glioma		Pituitary		Genel Kesinlik (%)
Ref.	P (%)	R (%)	P (%)	R (%)	P (%)	R (%)	
[22]GoogleNet+DVM	94,6	96,6	99,2	97,8	98,4	99	97,9
[27] VGG19	88	89,9	93,2	96	87,3	96,8	94,8
[37]							92,6
ESA-Kapsül	84,6	80	93	93,3	93,9	97,2	91,42
ESA-Kapsül (Rastgele 5-Kat)	93,3	92,2	96,7	96,5	98	99,1	96,3

Çizelge 6.2’de verilen diğer çalışmaların orijinal makale ile aynı doğrulama indekslerini kullanıp kullanmadığı net değildir. Aynı indeksler kullanılmamışsa, önerilen ESA-Kapsül modeli, VGG19 ile transfer öğrenme kullanan çalışmadan her metrik açısından daha iyi sonuç alabilmiştir. Aynı indeksleri kullanmışsa, VGG19 transfer öğrenme ile yapılan çalışmaya göre ise Pituitary kesinlik ve hassasiyet metrikleri açısından önerilen yöntem daha iyi sonuç almıştır. Buna karşın önerilen model VGG19 modelini esas alan çalışmaya göre Pituitary kesinlik ve hassasiyet metrikleri açısından daha iyi sonuç alabilmiştir. Bunun bir açıklaması Pituitary tümörünün yeri her görüntüde aynı bölgede olup diğer tümörler gibi değişkenlik göstermemektedir. Buna karşın veri setinde 3 farklı düzleme ait görüntüler olması Kapsül ağlarının bu konuda avantaj sağlamasına ve önerilen modelin bu metrikler açısından daha iyi sonuçlar elde edebilmesine imkan sağlamış olabilir. GoogLeNet + DVM ile yapılan çalışma tüm metrikler açısından en iyi sonucu

yakalamıştır. Bizim çalışmamızda ortam bellek kısıtları nedeniyle literatürde mevcut karmaşık modeller 5-kat çapraz doğrulamada kullanılamamıştır. Buna karşın, GoogLeNet ve DVM ile yapılan çalışmanın gerisinde kalsa da, VGG19 ile transfer öğrenme uygulayan çalışmaya göre daha iyi sonuçlar alınabilmektedir.

6.3. Rastgele Veri Bölme ile Doğrulama Yapan Çalışmalarla Karşılaştırma

Literatürde bazı çalışmalar rastgele oranlarda eğitim verisi belirleyerek önerdikleri modellerin sınıflandırma performansını değerlendirmişlerdir. Çizelge 6.3’de bu çalışmalardan %70 civarında eğitim verisi kullananlar ile bizim önerdiğimiz modeller kıyaslanmaktadır:

Çizelge 6.3. Deneysel çalışma sonuçları literatür karşılaştırması

Ref.	Yöntem	Veriseti kullanım şekli	Kesinlik (%)
[20]	ESA çıktılarını alan KELM	%70 eğitim	93,7
[19]	BPNN	%70 ile eğitim	91,9
[26]	ESA	%68 ile eğitim	96,1
[24]	VGG16	%70 ile eğitim	98,7
[36]	ESA	%67 ile eğitim	94,4
[37]	PCA-NGIST RELM	%70 ile eğitim	94,2
Önerilen	XCaps	%70 ile eğitim	96,7

Çizelge 6.3’den görüldüğü üzere önerilen ESA-Kapsül modeli, [24] nolu çalışma haricindeki çalışmalardan daha iyi sınıflandırma kesinliği yakalayabilmektedir. VGG16 modelinde yaklaşık 138 milyon parametere eğilirken önerilen ESA-Kapsül modelinde sadece 300 000 parametre eğilmektedir. Yani önerilen model, VGG16 tabanlı modellerden 460 kat daha küçük olup eğitim ve doğrulama hızı da bununla ters orantılı olarak artacaktır.

Çizelge 6.4’de ise %50 civarında eğitim verisi kullanan çalışmalarla önerilen model kıyaslanmıştır. Çizelge 6.4’e göre önerdiğimiz ESA-Kapsül modeli az farkla da olsa [25] nolu çalışmadan daha iyi sonuç alabilmektedir. Bununla birlikte eğitilen parametre sayısı açısından ise VGG19 tabanlı modellerde yaklaşık 144 milyon parametre eğitildiğinden önerdiğimiz modelden yaklaşık 480 kat daha karmaşıktır. Çizelge 6.4’deki sonuçlar çok

daha basit ve hızlı modellerle karmaşık modellerden daha iyi sonuç alabildiğimizi göstermektedir.

Çizelge 6.4. Deneysel çalışma sonuçları literatür karşılaştırması

Ref.	Yöntem	Veriseti kullanım şekli	Kesinlik (%)
[25]	VGG-19	%50 ile eğitim	94,6
Uyarlanan	ESA-kapsül	%50 ile eğitim (2-fold ortalama)	94,9

Literatürde bazı çalışmalarda %98 üzerinde sınıflandırma kesinliği yakalanabilmiştir.

Çizelge 6.5. Deneysel çalışma sonuçları literatür karşılaştırması

Ref.	Yöntem	Veriseti kullanım şekli	Kesinlik (%)
[23]	ESA+DWT+ LSTM	Her bir tümör tipinden 100'er tane olmak üzere seçilen 300 görüntü üzerinde eğitim	98,7
Uyarlanan	ESA-Capsule	%90 ile eğitim	98,7

Çizelge 6.5'de yer alan sonuçlara bakıldığında [23] nolu çalışmada elde edilen sınıflandırma kesinliği veri setinin %90' eğitimi kullanılması durumunda önerdiğimiz ESA-Kapsül modeliyle de yakalanabilmiştir. Çizelge 6.6'da ise CapsNet mimarisini kullanan çalışma ile önerdiğimiz CapsNet modelinin kıyaslanması yapılmıştır. Çizelge 6.6'dan görüleceği üzere CE-MRI veri seti üzerinde CapsNet mimarisine [21] nolu çalışmaya göre genel sınıflandırma kesinliği önemli miktarda artmıştır. Çizelge 6.7'de ise Xception modeli kullanılarak yapılan çalışmalar kıyaslanmıştır.

Çizelge 6.6. Deneysel çalışma sonuçları literatür karşılaştırması

Ref.	Yöntem	Veriseti kullanım şekli	Kesinlik (%)
[21]	CapsNet	Net bilgi verilmemiş	86,7
Uygulanan	CapsNet	5-kat çapraz doğrulama	90,9

Çizelge 6.7. Deneysel çalışma sonuçları literatür karşılaştırması

Ref.	Yöntem	Veriseti kullanım şekli	Kesinlik (%)
[35]	Xception	%60 ile eğitim	68,6
Uygulanan	Xception	%70 ile eğitim	96,3

Uyguladığımız Xception tabanlı modelde [35] nolu çalışmaya göre çok yüksek sınıflandırma kesinliği yakalanabilmiştir.

Çizelge 6.8’de literatürdeki mevcut bazı modellerle önerilen modellerin eğitilen parametre sayıları açısından karmaşıklıkları kıyaslanmaktadır.

Çizelge 6.8. Model karmaşıklık karşılaştırması

Model İsmi	Yaklaşık Parametre Sayısı
Xception	23 000 000
GoogLeNet	7 000 000
VGG16	138 000 000
VGG19	144 000 000
Önerilen ESA	600 000
Önerilen ESA-Kapsül	300 000
Önerilen XCaps	21 000 000
CapsNet	9 000 000

Çizelge 6.8’den görüldüğü üzere önerilen ESA ve ESA-Kapsül modelleri diğer modellere göre 7 ila 480 kat daha küçük olmasına karşın yukarıdaki çizelgelerde de verildiği üzere bu modellerle hemen hemen aynı sınıflandırma kesinliğini yakalayabilmiştir.

6.4. Axial Veri Seti Kullanan Çalışmalarla Karşılaştırma


CE-MRI veri setinin axial görüntü alt kümesini kullanan literatür çalışmalarıyla yapılan kıyaslama Çizelge 6.9’da yer almaktadır.

Çizelge 6.9. Axial veri seti sonuçlarının literatür karşılaştırması

	Meningioma		Glioma		Pituitary		Genel Kesinlik (%)
Model	P (%)	R (%)	P (%)	R (%)	P (%)	R (%)	
[18] ESA	84	74	93	93	94	96	91
ESA (axial)	80,9	75,5	92,4	93,9	92,9	94,8	90,33
ESA-Kapsül (axial)	85,9	82,2	94,9	94,3	94,3	96,9	92,5

Çizelge 6.9’da CE-MRI veri setinin axial görüntü alt kümesinde 5-kat çapraz doğrulamayla elde edilen performans değerleri benzer [18] nolu çalışmayla kıyaslanmaktadır. Tablodan açıkça görüleceği üzere önerilen ESA-Kapsül modeli tüm metrikler açısından daha iyi sonuç elde edebilmiştir. Çizelgelerde verilen sonuçlar dikkate alındığında önerilen yöntem axial görüntülerde daha başarılı sonuçlar yakalamıştır. Bu

durum axial görüntülerin sahip olduğu özelliklere dayanarak sunduğumuz hipotezle uyumlu olduğu gibi, 2 boyutlu düzlemde Linear Discriminant Analysis ile indirgenmiş boyutta veri set örneklerinin dağılımı izlendiğinde de beklenen bir sonuçtur. Şekil 6.1 (a)'da tüm görüntü tiplerinin, Şekil 6.1 (b)'de ise axial görüntü tiplerinin dikkate alınması durumundaki veri setlerinin örneklerinin dağılımını göstermektedir.



Şekil 6.1. Ce-mri örnek dağılımı a) tüm veri seti b) sadece axial

Şekil 6.1 (b)'de yani sadece axial görüntüler kullanıldığında tüm görüntü tiplerinin kullanılmasına kıyasla, farklı renklerin yanı tümör sınıflarının birbirinden daha net ayrıştığı görülmektedir.

6.5. Lokal Veri Setinde Yapılan Çalışmaların Karşılaştırılması

T2 ağırlıklı bir MR görüntüsünde tümör olup olmadığının tespitine yönelik LOKAL veri seti üzerinde yapılan deneysel çalışmalarda elde edilen sonuçlar Çizelge 6.10'da özetlenmiştir. Bu sonuçlara göre derin öğrenme modelleri LightGBM algoritmasına göre daha iyi sonuçlar almış, özellikle GBM hassasiyet metriğini önemli ölçüde artırmıştır. Bununla birlikte en iyi sonucu Xception modeli yakalayabilmiştir.

Çizelge 6.10. Deney sonuçlarının karşılaştırılması

	GBM tümörlü		Normal		Genel kesinlik (%)
Algoritma	P (%)	R(%)	P(%)	R(%)	
LightGBM	94	89	97	98	96
ESA	97,2	91,7	97,7	99,3	97,6
Xception	98,2	93,5	98,2	99,5	98,2

T2 ağırlıklı bir MR görüntüsünün GBM vakasına mı yoksa normal vakaya mı ait olup olmadığının tespit edildiği deneysel çalışmalarda elde edilen sonuçlar da Çizelge 6.11’de özetlenmiştir.

Çizelge 6.11. Deney sonuçlarının karşılaştırılması

	GBM vakası		Normal		Genel kesinlik (%)
Algoritma	P (%)	R(%)	P(%)	R(%)	
LightGBM	95	90	95	97	95
ESA	96	93	96	97,8	96
Xception	97,4	93,9	96,6	98,6	96,9

Çizelge 6.11’de verilen sonuçlara göre derin öğrenme modelleri LightGBM algoritmasına göre yine daha iyi sonuçlar elde ederken derin öğrenme modelleri içerisinde de Xception modeli yine en iyi sonuçları yakalayabilmiştir.

Çizelge 6.10 ve 6.11’i incelediğimizde Lokal veri seti üzerindeki tüm deneysel çalışmalarda %99’a varan yüksek performans değerleri elde edilmiştir. Bunun yanı sıra genel sınıflandırma kesinliği açısından benzer sonuçlar olsa da tümörsüz görüntülerin sınıflandırmasında GBM tümörsüz için hassasiyet metriği diğer deneylerdekine göre kısmen düşük kalmıştır. Bunun sebebi tümör içermeyen GBM MR görüntülerinin tümörden uzaklaştıkça normal görüntülerle aynı desenlere sahip olması ve bu nedenle modelin bu görüntüleri ayırt edememesi olabilir.

LightGBM temelli algoritmalar derin öğrenme modelinin gerisinde kalsa da bazı avantajlara sahiptir. Örneğin LightGBM hem işlem hızı açısından hem de yeni elde edilecek verilerle modelin yeniden eğitilmesi aşamasında derin öğrenmenin gerektirdiği yoğun işlem ve işlemci gücünden tasarruf açısından daha avantajlı olacaktır. Ayrıca önerilen algoritmalarda görüntünün yeniden boyutlandırılmasına gereksinim duyulmamaktadır. Yani DICOM dosyasındaki piksel verisi doğrudan kullanılabilir. Derin öğrenme ise hem sağladığı daha yüksek performans değerleriyle hem de nitelik seti mühendisliği veya uzman bilgisi gerektirmemesi nedeniyle tercih sebebi olmaktadır.

7. TARTIŞMA VE SONUÇ

Beyin tümörlerinin ve özellikle GBM tümörünün hızlı, etkin ve bütüncül bir yaklaşımla otomatik tespitine yönelik çalışmalarımız önceki bölümlerde detaylı bir şekilde anlatılarak sonuçlar literatürle kıyaslanmıştır. Elde edilen bulgu ve sonuçların mevcut literatür çalışmalarıyla uyumlu olduğu, MR görüntülerinden beyin tümörlerinin tespitinde derin öğrenme modellerinin yüksek performans sağlayabildiği görülmüş olup çalışma sonuçlarına ilişkin detaylı değerlendirme ve öneriler takip eden bölümlerde verilmiştir.

7.1. Tartışma

Tez çalışması kapsamında beyin MR görüntüleri üzerinde tümör olup olmadığının tespiti ve tümör olması durumunda hangi beyin tümörü tipinin olduğunun tespiti için hem geleneksel makine öğrenmesi kapsamında hem de derin öğrenme kapsamında farklı algoritma ve modeller önerilmiştir. Önerilen piksel histogramları tabanlı algoritma varsayılan yönteme göre eğitim süresini 50 kat azaltmış ancak benzer sınıflandırma performansı yakalayabilmiştir. Bunun üzerine piksel histogramlarıyla birlikte yerel ikili desenler histogramının da kullanıldığı yeni bir algoritma daha önerilmiştir. Önerilen bu algoritma sınıflandırma performansını %75'den %77'ye yükseltirken eğitim süresi varsayılan yönteme göre yine yaklaşık 50 kat daha kısa olmuştur. Yerel ikili desenler histogramı kullanılınca performansın artması sebebi olarak tümör bölgesindeki desenlerin daha fazla belirgin hale getirilerek sınıflandırma için daha fazla ayrıştırıcı bilgi sağlanması olduğu değerlendirilmektedir. Önerilen bu iki algoritma son işlem aşamasında herhangi bir danışmanlı sınıflandırma algoritması kullanabilmektedir. Bu kapsamda farklı algoritmalar kullanılmış ve genelde en iyi sonuçları XgBoost ve LightGBM algoritmaları yakalayabilmiştir. Tümör tespiti ve sınıflandırmasında XgBoost algoritması daha önce literatürde kullanılmış olsa da [80] LightGBM algoritması – bildiğimiz kadarıyla- ilk defa kullanılmaktadır.

Geleneksel makine öğrenmesi yaklaşımları kapsamında önerdiğimiz her iki algoritma da varsayılan yönteme göre daha etkin sonuçlar verse de CE-MRI veri setini paylaşan makale [17] ile kıyaslandığında sınıflandırma performansı yetersiz kalmıştır. Bunun üzerine derin öğrenme yaklaşımları kapsamında farklı modeller önerilmiştir. ESA modeliyle %89,71,

ESA-Kapsül modeliyle ise %90,07 sınıflandırma performansı yakalanmıştır. Bu sonuçlar da orijinal makalenin %91,12 olan sınıflandırma kesinliğini yakalayamamıştır. Son olarak ESA-Kapsül mimarisinde dinamik yönlendirme katmanının ağırlık güncelleme işlemi optimize edilebilir hale getirilerek geliştirilmiş ESA-Kapsül mimarisi önerilmiş ve %91,42 sınıflandırma kesinliği yakalanarak orijinal makalenin sonucuna göre bir iyileşme sağlanmıştır.

Kapsül mimarisinin orijinal dinamik yönlendirme algoritmasında ağırlık değeri bir önceki döngülerdeki ağırlık değerlerine göre belirlenmektedir. İlk döngü sonucu oluşan benzerlik rastgele dağılımla belirlendiğinden ilk döngüde eğitim olmaksızın elde edilen başlangıç benzerliğine karşı ön yargılı (biased) olmaktadır. Dolayısıyla önceki değerlerin yeni hesaplamaya katılma oranının azaltılmasının, kapsüllerin her bir döngüde öğrendiği özelliği daha etkin vurgulamasını artırdığı değerlendirilmektedir.

Önerilen ESA-Kapsül modeli daha iyi sonuç alsa da ESA modeline göre performansı beklendiği ölçüde artıramamıştır. CapsNet modeli ise hem literatürde hem de bizim çalışmamızda daha da düşük sonuçlar elde etmiştir. Aslında veri setinin farklı açılardan farklı düzlemlerde beyin MR görüntüleri içeriyor olması nedeniyle kapsül modelinin daha iyi performans göstermesi beklenirdi. Çünkü kapsül yapıları görüntüleme açısından bağımsız şekilde yüksek seviyeli özelliklerin öğrenilmesi için tasarlanmıştır. Ancak beyin tümörleri sabit bir pozisyonda değil MR görüntüsünün farklı yerlerinde olabilmektedir. Bu durum Şekil 3.13’de yüz örneğinde olduğu gibi ESA ağlarına avantaj sağlamaktadır. Her iki modelin kendine göre farklı avantajları olmasının kapsülden beklenen performans artışının yeterince yansımamasına sebep olduğu değerlendirilmektedir. Ayrıca CapsNet modelinde orijinal görüntü boyutlarının bellek yetersizliği nedeniyle küçültülmüş olmasının da performansı olumsuz etkilediği düşünülmektedir. Bunlarla birlikte önerilen ESA-Kapsül modeli ESA modeline göre Pituitary hassasiyet değerini %95,7’den %97,2’ye, axial veri seti üzerinde %94,8’den %96,9’a, önerilen XCaps modeliye Xception modeline göre %99,3’den %99,6’ya yükseltebilmiştir. Bu durum Pituitary tümöründe olduğu gibi tümör bölgesinin yerinin sabit olması durumunda kapsül katmanının performansa katkısının daha belirgin ortaya çıktığını göstermektedir.

Çalışma kapsamında literatürde mevcut Xception [5] modeliyle Kapsül [11] mimarisinin dinamik yönlendirme katmanını birleştirilmesi XCaps isminde yeni bir model de

önerilmiştir. Önerilen XCaps modeli, eğitim verisinin %70'i kullanılması durumunda, orijinal Xception modeline göre sınıflandırma performansını %96,3'den %96,74'e yükseltebilmiştir. Bununla birlikte XCaps modelinde Xception modeline göre yaklaşık 2 milyon daha az parametre eğitilmektedir.

Literatür çalışmalarında veri setindeki indeksleri kullanan orijinal makale [17] sonuçlarıyla birebir kıyaslama yapılabilmiş, elmalarla elmaların kıyaslanabildiği bu durumda önerdiğimiz geliştirilmiş ESA-Kapsül modeli genel sınıflandırma performansının yanı sıra Pituitary kesinlik ve hassasiyet metrikleri açısından orijinal veri seti makalesinden daha iyi sonuçlar almıştır. Bununla birlikte Çizelge 6.2'de 5-kat çapraz doğrulama yapan diğer çalışmalar da özetlenmiştir ancak bu çalışmaların ancak orijinal makale ile aynı doğrulama indekslerini kullanıp kullanmadığı net anlaşılamamaktadır. Aynı indeksleri kullanmışsa, VGG19 transfer öğrenme ile yapılan çalışmaya göre ise Pituitary kesinlik ve hassasiyet metrikleri açısından önerilen yöntem daha iyi sonuç almış olup bunun sebebinin Pituitary tümörünün yeri her görüntüde aynı bölgede olup diğer tümörler gibi değişkenlik göstermemesi ve önerilen modeldeki Kapsül katmanının bu konuda avantaj sağlaması olduğu değerlendirilmektedir.


Literatürde bazı çalışmalar rastgele oranlarda eğitim verisi belirleyerek önerdikleri modellerin sınıflandırma performansını değerlendirmişlerdir. Çizelge 6.3'de bu çalışmalardan %70 civarında eğitim verisi kullananlar ile bizim önerdiğimiz modeller özetlenmiş olup önerilen XCaps modeli, [24] nolu çalışma haricindeki çalışmalardan daha iyi sınıflandırma kesinliği yakalayabilmiştir. VGG16 modelinde yaklaşık 138 milyon parametere eğitilirken önerilen XCaps modelinde sadece 21 milyon parametre eğitilmektedir. Yani önerilen XCaps modeli, VGG16 tabanlı modelden yaklaşık 7 kat küçük olup eğitim ve doğrulama hızı da bununla ters orantılı olarak artmaktadır.

Çizelge 6.8'de hem literatürdeki mevcut modeller hem de önerilen modellerin parametre sayıları özetlenmiştir. Buna göre önerilen ESA, ESA-Kapsül ve XCaps modelleri diğer modellere göre 7 ila 480 kat daha küçük olmasına karşın bu modellerle hemen hemen aynı sınıflandırma kesinliğini yakalayabilmiştir.

Kıyaslama veri seti için önerdiğimiz derin öğrenme tabanlı yöntemler, görüntü boyutunun küçültülerek gri-seviyeli görüntüye dönüştürülmesi haricinde, literatürdeki bazı

alışmalardan [36] farklı olarak n-işleme gerektirmemektedir. Bu şekilde n işleme gerektirmeyen alışmalara [81] gre de daha başarılı sonuç alınmıştır.

nerilen derin ğrenme modellerinin birden fazlasında yanlış etiketlenen bazı rnek MR grntleri Resim 7.1’de verilmiştir.



Resim 7.1. Tahmin rnekleri a) meningioma yanlış tahmin b) glioma yanlış tahmin c) pituitary yanlış tahmin

Resim 7.1 (a), (b) ve (c) ‘de sırasıyla gerekte Meningioma, Glioma ve Pituitary olup nerilen modellerce yanlış etiketlenen MR grntleri yer almaktadır. Meningioma olan grnt Pituitary olarak tespit edilirken, Glioma ve Pituitary olan rnekler ise Meningioma olarak tahmin edilmiştir. Gazi niversitesi Tıp Fakltesi Beyin Cerrahisi Anabilim Dalı uzmanı tarafından manuel olarak incelenen bu rneklerden gerekte Pituitary olan Resim 7.1 (c)’deki rnek doėru tespit edilirken, gerekte Meningioma olan Resim 7.1 (a)’daki rnek ise nerilen modellerin yaptığı gibi Pituitary olarak tespit edilmiştir. Resim 7.1 (b) ‘deki Glioma olan grnt iinse kesin bir tanı konulamamıştır. Sonuç olarak bu  MR grntsnn nerilen modellerden farklı olarak sadece 1 tanesi doėru tespit edilmiştir. Bu durum nerilen modellerin uygulamada daha da iyi sonuçlar verebileceėini gstermektedir.

nerdiğimiz modellerin test edildiėi kıyaslama veri seti axial haricinde coronal ve sagittal dzlemde MR grntleri de iermektedir. Coronal ve sagittal grntler boėaz, yutak, boyun gibi beyin harici blmler de iermekte olup axial grntlere gre daha heterojen bir arka plana sahiptir. Bu durumda axial grntlerde nerilen yntemlerin daha iyi performans verebileceėi şeklinde bir hipotez de nerilmiş olup buna doėrulayan sonuçlar elde edilmiştir. Yerel ikili desenler tabanlı algoritma ile sadece axial grntler zerinde

rastgele 5-kat çapraz doğrulama ile gerçekleştirilen testlerde bütün danışmanlı sınıflandırma algoritmaları için tüm veri setine göre daha yüksek sonuçlar alınmıştır. Benzer şekilde önerilen derin öğrenme modelleri de axial görüntülerde daha iyi sonuç elde edebilmiştir. Zaten tüm veri setindeki bazı testlerde yanlış tahmin edilen görüntülerde axial olanların oranı %19-22 arasında değişmekte olup, axial görüntülerin tüm veri seti içindeki oranının %32 olduğu dikkate alındığında axial görüntülerde daha isabetli sonuçlar alınabildiği anlaşılmaktadır.

Kıyaslama veri seti haricinde LOKAL veri seti üzerinde de önerilen modellerle deneysel çalışmalar gerçekleştirilmiştir. Benzer şekilde önerilen derin öğrenme modelleriyle geleneksel yöntemlere göre daha iyi sonuçlar alınabilmektedir. Literatürde bazı çalışmalar [17] tümör tipinin tespiti için tümör bölgesinden nitelik çıkarımında bulunmaktadır. Bu durumda bu çalışmalarda kullanılan yöntemler tümör olup olmadığının tespitinde kullanılamamaktadır. Çünkü yöntemler tümörün zaten var olmasını ve yerinin belli olmasını gerektirmektedir. Önerdiğimiz geleneksel yöntemler ise hem tümörlü görüntülerdeki tümör tipinin sınıflandırılmasında hem de bir beyin MR görüntüsünde anomali olup olmadığının tespitinde kullanılabilmektedir. Tümör tipinin sınıflandırılmasında ise tümör bölgesinin tespitini gerektirmemektedir. MR görüntüsünün GBM tümörü içerip içermediğinin tespitinde %98,2 gibi yüksek bir sınıflandırma kesinliği performansı elde edilmiştir.

LOKAL veri setinde ayrıca literatürde ilk defa –bildiğimiz kadarıyla- belirgin bir tümör içermese de görüntünün normal vakaya ait olup olmadığı da tespit edilmiş olup GBM açısından %94’e varan yüksek hassasiyet performansı elde edilmiştir.

7.2. Sonuç ve Öneriler

Bu tez çalışmasında gerçek bir ihtiyaçtan yola çıkılmış ve radyoloji incelemesindeki gecikmenin önlenip beyin tümörlerinin erken teşhis ve tedavisine başlanabilmesi için derin öğrenme temelli özgün yöntemler geliştirilerek bir erken uyarı sistemi tasarlanmıştır. Deneysel çalışmalarda sadece literatürde kullanılan kıyaslama veri setleri değil aynı zamanda Gazi Üniversitesi Tıp Fakültesi Beyin Ve Sinir Cerrahisi Ana Bilim Dalı tarafından sağlanan yerel bir veri seti de kullanılmıştır. Giriş bölümünde detayları verilen problem uzayındaki hususlara çözüm kapsamında hem geleneksel makine öğrenmesi

yöntemlerini hem de derin öğrenme yöntemlerini ve özellikle yeni bir teknoloji olan Kapsül ağlarını esas alan yeni modeller önerilmiş ve literatürdeki mevcut bazı modeller ise problemimize uyarlanarak deneysel çalışmalar yapılarak literatürle uyumlu yüksek performans değerleri elde edilmiştir. Önerilen ve uygulanan modeller hem Gazi Üniversitesi Tıp Fakültesi Beyin Cerrahisi Anabilim dalı tarafından sağlanan LOKAL veri seti üzerinde hem de açık kaynak kıyaslama veri seti üzerinde test edilerek mevcut çalışmalarla kıyaslanmıştır. Buna göre kıyaslama veri setini yayımlayan orijinal makalenin [17] %91,12 olan sınıflandırma kesinliği, tarafımızca önerilen ve ESA-Kapsül mimarisinde dinamik yönlendirme katmanının ağırlık güncelleme işlemi optimize edilebilir hale getiren, geliştirilmiş ESA-Kapsül mimarisi ile %91,42'ye yükseltilmiştir. Orijinal makaleden farklı olarak önerdiğimiz ve uyguladığımız Kapsül ağlarını esas alan tüm modellerimiz tümör bölgesinin tespit edilerek bu bölge üzerinde nitelik mühendisliği yapılmasına gerek duymamakta, doğrudan beyin MR görüntüsü üzerinde analiz yapmaktadır. Bu durum yeni bir tümör tipi ortaya çıkması ve benzeri durumlarda modelin kolayca yeni duruma uyarlanabilmesi gibi esneklikler sağlamaktadır. Yine tarafımızca önerilen XCaps modeliyle de kıyaslama veri setinin %70'inin eğitimde kullanılması durumunda %96,7 sınıflandırma kesinliği elde edilmiş olup bu sonuç, VGG16 kullanan başka bir çalışmadan sonra ikinci en iyi sonuç olmuştur. Buna karşın VGG16 modeline göre eğitilmesi gereken parametre sayısı açısından XCaps modeli yaklaşık 7 kat daha küçük bir modeldir. Ayrıca önerdiğimiz XCaps modeli, Xception modeline göre sınıflandırma performansını %96,3'den %96,74'e yükseltirken eğitilmesi gereken parametre sayısını da yaklaşık %10 azaltarak 23 milyondan 21 milyona indirmeyi başarmıştır. Özetlemek gerekirse problem uzayındaki ilk probleme çözüm olarak özellikle güncel bir teknoloji olan Kapsül ağlarından faydalanılarak, hem %96,74'e varan yüksek performans değerleri elde edebilen hem de eğitilmesi gereken parametre sayısını azaltarak ihtiyaç duyulacak işlem gücü ihtiyacını azaltabilen, nitelik mühendisliği gerektirmeden doğrudan MR görüntüsü üzerinde analiz yapabilecek esneklikte yeni modeller tarafımızca önerilmiştir.

Önerilen veya uyarlanarak uygulanan yöntemlerin yanı sıra düzlem açısından MR görüntü farklılıkları da analiz edilmiş, coronal ve sagittal görüntüler boyun, boğaz ve yutak gibi beyin harici organları da içermektedirken axial görüntüler ise sadece beyin bölgesini içermekte ve daha homojen bir desene sahip olmasından yola çıkılarak axial görüntülerin modellerin eğitilmesinde kullanılmasının sınıflandırma kesinliğini artıracığı

değerlendirilmiştir. Zaten tüm veri setindeki bazı testlerde yanlış tahmin edilen görüntülerde axial olanların oranı %19-22 arasında değişmekteyken, axial görüntülerin tüm veri setindeki oranının %32 olması bunu desteklemiştir. Sonuç olarak sadece axial görüntüler üzerinde ESA-Kapsül modeliyle %91,42 olan sınıflandırma kesinliği %92,5'e yükseltilmiştir. Sadece axial görüntü kullanılması durumunda sınıflandırma kesinliğinin artıyor olması diğer düzlemlerde görüntü çekimine ihtiyaç bırakmayacak, bu ise vakanın cihaz içinde tabi tutulacağı işlem süresini ve işlem maliyeti azaltabilecektir.

Tez çalışmaları kapsamında literatürde olmayan yeni bir çalışma da gerçekleştirilmiştir. Literatür çalışmalarında T2 ağırlıklı MR görüntüsünde tümör olup olmadığını tespiti yönelik çalışmalar mevcut iken, bir MR görüntüsünün GBM vakasına mı yoksa normal vakaya mı ait olup olmadığını tespiti yönelik bir çalışma bildiğimiz kadarıyla henüz bulunmamaktadır. Bu tespitin zorluğu, bazı MR görüntüleri normal vakadaki görünüme sahip olduğu halde, yani belirgin bir şekilde beyaz lezyon içermediği halde GBM vakasına ait olabilmektedir. Ancak deneysel çalışmalar ESA modelinin gözle bariz görülebilen farklılıklar içermese de GBM vakalarına ait MR görüntülerindeki görünmeyen bazı desenleri öğrenebildiğini göstermektedir. T2 ağırlıklı bir MR görüntüsünün tümör içerip içermediğine bakılmaksızın GBM vakasına mı yoksa normal vakaya mı ait olup olmadığı Xception modeli kullanılarak analiz edilmiş ve GBM vakası hassasiyet değeri açısından %94'e, genel sınıflandırma kesinliği açısından ise %97'ye varan performans değerleri elde edilmiştir. GBM tümörü tespitinde MR görüntüsünde bariz tümör olmasa da vakanın tespit edilebiliyor olması, tümör bölgesinin yakalanabilmesi için MR çekimi sırasında daha kısa aralıklarla daha çok kesit taranması ihtiyacını dolayısıyla teşhis için gereken görüntü sayısını azaltacaktır. Ancak bu bulgu GBM tümörü için geçerli görünürken diğer tümör tiplerine genellenebilmesi için ilave çalışmalar yapılması gerekecektir. Bununla birlikte Gazi Üniversitesi Tıp Fakültesi Beyin Cerrahisi Anabilim Dalı tarafından oluşturulan T2 ağırlıklı MR görüntüleri veri seti sayesinde, Xception modeli kullanılarak tespit modelleri eğitilmiş olup GBM tümörü hassasiyet değeri açısından %94'e, genel sınıflandırma kesinliği açısından ise %98'e varan performans değerleri elde edilmiştir. T2 ağırlık MR görüntüleri hem GBM tümörünü en belirgin şekilde ortaya çıkarabilmesi hem de damardan ilaç verme gibi riskli ve maliyetli işlemler gerektirmemesi açısından manuel teşhiste tercih edilen bir görüntü çeşididir. T2 ağırlıklı MR görüntüsü üzerinde %98'e varan sınıflandırma kesinliği elde edilmesi, işlem riski ve maliyetini azaltarak yüksek performans ile GBM tümörlerinin otomatik ve hızlı tespitinin mümkün olacağını göstermektedir.

Tez çalışmalarının son aşamasında ise uygulanan ve geliştirilen makine öğrenmesi modellerinin kullanılmasını esas alan bir erken uyarı sistemi önerilmiştir. Bu sistem sayesinde radyolog incelemesindeki yoğunuktan kaynaklı zaman kaybının önlenerek özellikle GBM gibi ölümcül tümörlerin otomatik tespiti halinde ilgili hekime anlık olarak uyarı gönderilmesi ve hastaya acilen müdahale imkanının oluşturulması amaçlanmıştır. Önerilen erken uyarı sistemine yönelik gerekli dokümantasyon yapılarak patent başvuru süreci de (2020/13244) başlatılmıştır.

Tez çalışmasının sahip olduğu diğer özgün yönlerine değinecek olursak, CE-MRI kıyaslama veri seti üzerinde rastgele veri seçimi yapılan çalışmalara göre en iyi sonucu % 98,7 sınıflandırma kesinliği ile önerdiğimiz geliştirilmiş ESA-Kapsül modeli elde etmiştir. Kapsül dinamik yönlendirme algoritmasında önerdiğimiz değişikliklerle ağırlık güncelleme işlemi optimize edilebilir hale getirilmiş ve ESA-Kapsül ağının CE-MRI veri seti üzerindeki sınıflandırma performansı %90'dan %91,42'ye yükseltilmiştir. Beyin MR görüntüleri üzerindeki çalışmalarda MAM tabanlı algoritmalarla daha iyi sonuçlar alınabildiği görülmüş olup, LightGBM algoritması bu alanda –bildiğimiz kadarıyla- ilk defa kullanılmıştır. Çalışma kapsamında, GİÜ kullanılamayacak durumlarda kullanılabilmek üzere geleneksel makine öğrenmesi kapsamında iki yeni algoritma önerilmiş olup önerilen algoritmalar hem tümör olup olmadığının tespitinde hem de tümör tipinin tespitinde kullanılabilir. Önerilen algoritmalar varsayılan yöntemle göre sınıflandırma kesinliğini %75'den %77'ye artırırken eğitim süresini 50 kat kadar azaltabilmiştir.

Tez deneysel çalışmaları Google Colab Research ortamında, sadece 1 Grafiksel İşlem Ünitesi tahsisi ve her 12 saatte bir sistemin sıfırlanması kısıtlarıyla tamamlanmıştır. Ayrıca lokal veri seti oluşturma çalışmaları başlangıç aşamasında olup vaka sayısı ve görüntü çeşitliliği açısından henüz yeterli miktarda veri bulunmamaktadır. Hem ortam kısıtlaması hem de veri seti boyutundaki yetersizlik nedeniyle literatürde sunulan, önceden eğitilmiş GoogleNet, VGG19 vb. gibi karmaşık derin öğrenme mimarileri çalışmamızda kullanılamamıştır.

Gazi Üniversitesi Tıp Fakültesi Beyin Ve Sinir Cerrahisi Ana Bilim Dalı tarafından sağlanan bu tez çalışmasında da kullanılan yerel veri seti aynı zamanda Türkiye'de herkese

açık paylaşılan ilk veri seti olma özelliği olan Gazi Brains Dataset 2020 veri setinin de temellerini oluşturmuştur.

Akademik araştırmaların yerli ürünlere dönüşmesi için yerli veri setleri üzerinde çalışılması bir zorunluluktur. Bu tez çalışmasında uygulanan modellerin yerli bir veri seti üzerinde de yüksek performans değerleri elde edebilmesi ve Türkiye’de herkese açık paylaşılan ilk veri setinin oluşmasına katkı sağlaması da bu alanda bundan sonra yapılacak çalışmalar için de ayrı bir motivasyon sağlayacaktır. Tez çalışmasının, Türkiye’deki beyin cerrahisi uzmanlarının işlerini hızlandırma ve kolaylaştırmaya yönelik yerli bir ürüne dönüşmesi yolunda ilk adım olarak patent başvurusu da başlatılmış olup değerlendirme süreci devam etmektedir.

KAYNAKLAR

1. Krizhevsky A., Sutskever, I. and Hinton, G.E. (2012). ImageNet classification with deep convolutional neural networks. *Proceedings of the 25th International Conference on Neural Information Processing Systems*, 1097-1105.
2. İnternet: Simonyan, K. and Zisserman, A. (2015). Very Deep Convolutional Networks for Large-Scale Image Recognition. *International Conference on Learning Representations*. URL: <https://arxiv.org/abs/1409.1556>. Son Erişim Tarihi: 22.05.2020
3. Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S. and Anguelov, D. (2015). Going deeper with convolutions. *IEEE Conference on Computer Vision and Pattern Recognition*, 1-9.
4. He, K., Zhang, X., Ren, S. and Sun, J. (2016). Deep residual learning for image recognition. *IEEE Conference on Computer Vision and Pattern Recognition*, 770-778.
5. Chollet, F. (2017). Xception: Deep learning with depthwise separable convolutions. *IEEE Conference on Computer Vision and Pattern Recognition*, 1800-1807.
6. Wei, F. and Menzies, T. (2017). Easy over hard: a case study on deep learning. *Proceedings of the 11th Joint Meeting on Foundations of Software Engineering*, 49–60.
7. Atici, M.A., Sagirolu, S. and Dogru, İ.A. (2016). Android malware analysis approach based on control flow graphs and machine learning algorithms. *4th International Symposium on Digital Forensic and Security (ISDFS)*, 26-31.
8. Ke, G., Meng, Q., Finley, T., Wang, T., Chen, W. and Ma, W. (2017). LightGBM: a highly efficient gradient boosting decision tree. *Proceedings of the 31st International Conference on Neural Information Processing Systems*, 3149-3157.
9. Chen, T. and Guestrin, C. (2016). XGBoost: A Scalable Tree Boosting System. *Proceedings of the 22nd International Conference on Knowledge Discovery and Data*, 785-794.
10. LeCun, Y., Haffner, P., Bottou, L. and Bengio, Y. (1999). Object Recognition with Gradient-Based Learning. *Shape, Contour and Grouping in Computer Vision*, 1681, 319-345.
11. Sabour, S., Frosst, N. and Hinton, G.E. (2017). Dynamic routing between capsules. *Proceedings of the 31st International Conference on Neural Information Processing Systems*, 3859-3869.
12. Anaraki, A.K., Ayati, M. and Kazemi, F. (2019). Magnetic resonance imaging-based brain tumor grades classification and grading via convolutional neural networks and genetic algorithms. *Biocybernetics and Biomedical Engineering*, 39(1), 63-74.
13. Zhang, Y., Hu, Q., Guo, Z., Xu, J. and Xiong, K. (2018). Multi-Class Brain Images Classification Based on Reality-Preserving Fractional Fourier Transform and Adaboost. *3rd IEEE International Conference on Image, Vision and Computing*, 444-447.

14. Koley, S., Sadhu, A.K., Mitra, P., Chakraborty, B. and Chakraborty, C. (2016). Delineation and diagnosis of brain tumors from post contrast T1-weighted MR images using rough granular computing and random forest. *Applied Soft Computing*, 41, 453-465.
15. Narayana, A.P., Coronado, I., Robinson, M., Sujit, S.J., Datta, S. and Sun, X. (2018). Multimodal MRI Segmentation of Brain Tissue and T2-Hyperintense White Matter Lesions in Multiple Sclerosis using Deep Convolutional Neural Networks and a Large Multi-center Image Database. *9th Cairo International Biomedical Engineering Conference (CIBEC)*, 13-16.
16. Atici, M.A., Sagiroglu, S., Celtikci, P., Uçar, M., Börcek, A.Ö. and Emmez, H. (2020). A novel deep learning algorithm for the automatic detection of high-grade gliomas on t2-weighted magnetic resonance images. a preliminary machine learning study. *Turkish Neurosurgery*, 30(2), 194-198.
17. Jun, C., Wei, H., Shuangliang, C., Ru, Y., Wei, Y. and Zhaoqiang, Y. (2015). Enhanced Performance of Brain Tumor Classification via Tumor Region Augmentation and Partition. *PLoS ONE*, 10(10).
18. Paul, J.S., Plassard, A.J., Landman, B.A. and Fabbri, D. (2017). Deep learning for brain tumor classification. *Proceedings of Society of Photographic Instrumentation Engineers Medical Imaging*, 1013710–1.
19. Ismael, M.R. and Abdel-Qader, I. (2018) Brain tumor classification via statistical features and back-propagation neural network. *IEEE International Conference on Electro/Information Technology*, 252–257.
20. Pashaei, A., Sajedi, H. and Jazayeri, N. (2018). Brain tumor classification via convolutional neural network and extreme learning machines. *IEEE 8th International Conference on Computer and Knowledge Engineering*, 314–319.
21. Afshar, P., Mohammadi, A. and Plataniotis, K.N. (2018). Brain tumor type classification via capsule networks. *25th IEEE International Conference on Image Processing (ICIP)*, 3129-3133.
22. Deepak, S. and Ameer, P.M. (2019). Brain tumor classification using deep CNN features via transfer learning. *Computers in Biology and Medicine*, 111, 103345.
23. Kutlu, H. and Avcı, E. (2019). A Novel Method for Classifying Liver and Brain Tumors Using Convolutional Neural Networks, Discrete Wavelet Transform and Long Short-Term Memory Networks. *Sensors*, 19(9), 1992.
24. Arshia, R., Saeeda, N., Muhammad, R., Faiza, A. and Muhammad, I. (2020). A Deep Learning-Based Framework for Automatic Brain Tumors Classification Using Transfer Learning. *Circuits, Systems, and Signal Processing*, 39(8), 757-775.
25. Muhammad, S., Salman, K., Khan, M., Wanqing, W., Amin, U. and Sung, B. (2019). Multi-Grade Brain Tumor Classification using Deep CNN with Extensive Data Augmentation. *Journal of Computational Science*, 30, 174-182.

26. Sultan, H.H., Salem, N.M. and Al-Atabany, W. (2019). Multi-classification of Brain Tumor Images using Deep Neural Network. *IEEE Access*, 7, 69215 - 69225.
27. Swati, Z.N.K., Zhao, Q., Kabir, M., Ali, F., Ali, Z., Ahmed, S. and Lu, J. (2019). Brain tumor classification for MR images using transfer learning and fine-tuning. *Computerized Medical Imaging and Graphics*, 75, 34-46.
28. Hussaina, S., Anwar, S.M. and Majid, M. (2018). Segmentation of glioma tumors in brain using deep convolutional neural network. *Neurocomputing*, 282, 248-261.
29. Lu, S., Lei, L., Haung, H. and Xiao, L. (2016). A Hybrid Extraction-Classification Method For Brain Segmentation In MR image. *9th International Congress on Image and Signal Processing, BioMedical Engineering and Informatics*, 1381-1385.
30. Amin, J., Sharif, M., Yasmin, M. and Fernandes, S.L. (in press). A distinctive approach in brain tumor detection and classification using MRI. *Pattern Recognition Letters*.
31. Raju, A.R., Suresh, P. and Rao, R.R. (2018). Bayesian HCS-based multi-SVNN: A classification approach for brain tumor segmentation and classification using Bayesian fuzzy clustering. *Biocybernetics and Biomedical Engineering*, 38(3), 646-660.
32. Li, Y., Jia, F. and Qin, J. (2016). Brain tumor segmentation from multimodal magnetic resonance images via sparse representation. *Artificial Intelligence in Medicine*, 73, 1-13.
33. Sachdeva, J., Kumar, V., Gupta, I., Khandelwal, N. and Ahuja, C.K. (2016). A package-SFERCB-Segmentation, feature extraction, reduction and classification analysis by both SVM and ANN for brain tumors. *Applied Soft Computing*, 47, 151-167.
34. İnternet: Banerjee, S., Mitra, S., Sharma, A. and Shankar, B.U. (2018). A CADe System for Gliomas in Brain MRI using Convolutional Neural Networks. URL: <https://arxiv.org/abs/1806.07589>. Son Erişim Tarihi: 22.05.2020
35. Kumar, D. and Mittal, A. (2019). Artificially-integrated Convolutional Neural Networks for Brain Tumor Prediction. *EAI Endorsed Transactions on Pervasive Health and Technology*, 5(17).
36. Das, S., Aranya, O.F.M.R.R and Labiba, N.N. (2019). Brain Tumor Classification Using Convolutional Neural Network. *1st International Conference on Advances in Science, Engineering and Robotics Technology*, 1-5.
37. Gumaei, A., Hassan, M.M., Hassan, M.R., Alelaiwi, A. and Fortino, G. (2019). A Hybrid Feature Extraction Method With Regularized Extreme Learning Machine for Brain Tumor Classification. *IEEE Access*, 7, 36266-26273.
38. Çinar, A. and Yildirim, M. (2020). Detection of tumors on brain MRI images using the hybrid convolutional neural network architecture. *Medical Hypotheses*, 139, 109684.

39. Toğaçar, M., Ergen, B. and Cömert, Z. (2020). BrainMRNet: Brain tumor detection using magnetic resonance images with anovel convolutional neural network model. *Medical Hypotheses*, 134, 109531.
40. Yang, Y., Yan, L., Zhang, X., Han, Y., Nan, H., Hu, Y., Hu, B., Yan, S., Zhang, J., Cheng, D., Ge, X., Huang, X., Zhao, D. and Wang, W. (2018). Glioma Grading on Conventional MR Images: A Deep Learning Study With Transfer Learning, *Frontiers in Neuroscience*, 12, 804.
41. Swati, Z.N.K, Zhao, Q., Kabir, M., Ali. F., Ali, Z. and Ahmed. S. (2019). Content-Based Brain Tumor Retrieval for MR Images Using Transfer Learning, *IEEE Access*, 7, 17809-17822.
42. Jun, C., Wei, H., Huang, M., Huang, W., Jiang, J., Zhou,Y., Yang, R., Zhao, J., Feng, Y., Feng, Q. and Chen, W. (2016). Retrieval of Brain Tumors by Adaptive Spatial Pooling and Fisher Vector Representation. *PLoS ONE*, 11(6).
43. Lao, J., Chen, Y., Li, Z., Li, Q., Zhang, J., Liu, J. and Zhai, G. (2017). A Deep Learning-Based Radiomics Model for Prediction of Survival in Glioblastoma Multiforme, *Scientific Reports*, 7(1), 10353.
44. El-Kareh, R., Hasan, O. and Schiff, G.D. (2013). Use of health information technology to reduce diagnostic errors. *BMJ Quality & Safety*, 22(2), 40-51.
45. Thijs, K., Litjens, G., Ginneken, B., Gubern-Mérida, A., Sánchez, C. and Mann, R. (2016). Large Scale Deep Learning for Computer Aided Detection of Mammographic Lesions. *Medical Image Analysis*, 35, 303-312.
46. Buda, M., Saha, A. and Mazurowski, M. (2019). Association of genomic subtypes of lower-grade gliomas with shape features automatically extracted by a deep learning algorithm. *Computers in Biology and Medicine*, 109, 218-225.
47. Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B. and Grisel. O. (2011). Scikit-learn: Machine Learning in Python. *Journal of Machine Learning Research*, 12, 2825-2830.
48. McKinney, W. (2010). Data Structures for Statistical Computing in Python. *Proceedings of the 9th Python in Science Conference*, 56-61.
49. Hunter, J.D. (2007). Matplotlib: A 2D Graphics Environment. *Computing in Science & Engineering*, 9(3), 90-95.
50. İnternet: Chen, T. (2014). eXtreme Gradient Boosting. URL: <https://github.com/dmlc/xgboost>. Son Erişim Tarihi: 22.05.2020
51. İnternet: Ke, G. (2017). LightGBM, Light Gradient Boosting Machine. URL: <https://github.com/microsoft/LightGBM>. Son Erişim Tarihi: 22.05.2020
52. Rutkowski, L., Jaworski, M., Pietruczuk, L. and Duda, P. (2014). The CART decision tree for mining data streams. *Information Sciences*, 266, 1-15.


53. Liu, H. and Cocea, M. (2018). Induction of classification rules by Gini-index based rule generation. *Information Sciences*, 436-437, 227-246.
54. Friedman, J.H. (2001). Greedy function approximation: A gradient boosting machine. *Annals of Statistics*, 29(5), 1189-1232.
55. Shichao, Zhang. (2019). Cost-sensitive KNN classification. *Neurocomputing*, 391, 234-242.
56. Talha, K.A, Dođru, İ.A. and Aydın, Ç. (2015). APK Auditor: Permission-based Android malware detection system. *Digital Investigation*, 13, 183-189.
57. Atici, M.A. (2017). An analysis of automatic gender detection by first-order configural relations. *International Conference on Computer Science and Engineering (UBMK)*, 18-21.
58. Dedetürk, B.K. and Akay, B. (2020). Spam filtering using a logistic regression model trained by an artificial bee colony algorithm. *Applied Soft Computing*, 91, 106229.
59. Okwuashi, O. and Ndehedehe, C.E. (2020). Deep support vector machine for hyperspectral image classification. *Pattern Recognition*, 103, 107298.
60. Nie, F. and Li, W.Z.X. (2019). Decision Tree SVM: An extension of linear SVM for non-linear classification. *Neurocomputing*, 401, 153-159.
61. Wang, X., Qin, Y., Wang, Y., Xiang, S. and Chen, H. (2019). ReLTanh: An activation function with vanishing gradient resistance for SAE-based DNNs and its application to rotating machinery fault diagnosis. *Neurocomputing*, 363, 88-98.
62. İnternet: Nielsen, M. (2019). Deep learning. URL: neuralnetworksanddeeplearning.com. Son Erişim Tarihi: 22.05.2020
63. Huang, G., Liu, Z., Maaten, L.V.D. and Weinberger, K.Q. (2017). Densely Connected Convolutional Networks. *IEEE Conference on Computer Vision and Pattern Recognition*, 2261-2269.
64. İnternet: Howard, A.G., Zhu, M., Chen, B., Kalenichenko, D., Wang, W., Weyand, T., Andreetto, M. and Adam, H. (2017). MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications. URL: <https://arxiv.org/abs/1704.04861>. Son Erişim Tarihi: 22.05.2020
65. Zoph, B., Vasudevan, V., Shlens, J. and Le, Q.V. (2018). Learning Transferable Architectures for Scalable Image Recognition. *IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 8697-8710.
66. Zhong, X., Gong, O., Huang, W., Li, L. and Xia, H. (2019). Squeeze-and-Excitation Wide Residual Networks in Image Classification. *IEEE International Conference on Image Processing (ICIP)*, 395-399.
67. Sandler, M., Howard, A., Zhu, M., Zhmoginov, A. and Chen, L.C. (2018). MobileNetV2: Inverted Residuals and Linear Bottlenecks. *IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 4510-4520.

68. Tan, M. and Le, Q.V. (2019). EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks. *Proceedings of the 36th International Conference on Machine Learning*, 6105-6114.
69. İnternet: Pechyonkin, M. (2017). Understanding Hinton's Capsule Networks. Part 2. How Capsules Work. URL: <https://pechyonkin.me/capsules-2>. Son Erişim Tarihi: 22.05.2020
70. Hinton, G.E., Krizhevsky, A. and Wang, S.D. (2011). Transforming auto-encoders. *Proceedings of the 21th International Conference on Artificial Neural Networks*, 44-51.
71. Fawcett, T. (2006). An introduction to ROC analysis. *Pattern Recognition Letters*, 27(8), 861–874.
72. İnternet: Shorten, C. (2018). KaggleDogBreedChallenge. URL: <https://github.com/CShorten/KaggleDogBreedChallenge/>. Son Erişim Tarihi: 22.05.2020
73. Ioffe, S. and Szegedy, C. (2015). Batch normalization: accelerating deep network training by reducing internal covariate shift. *Proceedings of the 32nd International Conference on International Conference on Machine Learning*, 448-456.
74. İnternet: Su, J. (2018). A Capsule Implement with Pure Keras. URL: <https://github.com/bojone/Capsule>. Son Erişim Tarihi: 22.05.2020
75. İnternet: Singh, A.K. (2019). Implementing Capsule Network in Keras. URL: <https://theailearner.com/2019/01/21/implementing-capsule-network-in-keras/>. Son Erişim Tarihi: 22.05.2020
76. Garrido-Merchán, E.C. and Hernández-Lobato, D. (2020). Dealing with categorical and integer-valued variables in Bayesian Optimization with Gaussian processes. *Neurocomputing*, 380, 20-35.
77. Pan, D., Lu, Y. and Kang, P. (2019). A Deep Learning Model for Multi-label Classification Using Capsule Networks. *15th International Conference on Intelligent Computing*, 144-155.
78. Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I. and Salakhutdinov, R. (2014). Dropout: A Simple Way to Prevent Neural Networks from Overfitting, *Journal of Machine Learning Research*, 15(1), 1929-1958.
79. İnternet: Chollet, F. (2015). Keras. URL: <https://keras.io> Son Erişim Tarihi: 22.05.2020
80. Nakagawa, M., Nakaura, T., Namimoto, T., Kitajima, M., Uetani, H., Tateishi, M., Oda, S., Utsunomiya, D., Makino, K. and Nakamura, H. (2018). Machine learning based on multi-parametric magnetic resonance imaging to differentiate glioblastoma multiforme from primary cerebral nervous system lymphoma. *European Journal of Radiology*, 108, 147-154.


81. Abiwinanda, N., Muhammad, H., Hesaputra, S., Handayani, A. and Mengko, T. (2018). Brain Tumor Classification Using Convolutional Neural Network. *World Congress on Medical Physics and Biomedical Engineering*, 183-189.

EKLER


EK-1. Kesinlik ve kayıp eğrileri




(a)




(b)




(c)



(ç)




(d)




(e)

Şekil 1.1. Deney#2 kesinlik-Kayıp eğrileri a) kat-1 kesinlik eğrisi b) kat-2 kesinlik eğrisi c) kat-3 kesinlik eğrisi ç) kat-4 kesinlik eğrisi d) kat-5 kesinlik eğrisi e) kat-1 kayıp eğrisi f) kat-2 kayıp eğrisi g) kat-3 kayıp eğrisi ğ) kat-4 kayıp eğrisi h) kat-5 kayıp eğrisi


EK-1. (devam) Kesinlik ve kayıp eğrileri




(f)



(g)




(ğ)




(h)

Şekil 1.1. (devam) Deney#2 kesinlik-Kayıp eğrileri a) kat-1 kesinlik eğrisi b) kat-2 kesinlik eğrisi c) kat-3 kesinlik eğrisi ç) kat-4 kesinlik eğrisi d) kat-5 kesinlik eğrisi e) kat-1 kayıp eğrisi f) kat-2 kayıp eğrisi g) kat-3 kayıp eğrisi ğ) kat-4 kayıp eğrisi h) kat-5 kayıp eğrisi


EK-1. (devam) Kesinlik ve kayıp eğrileri




(a)




(b)




(c)



(ç)




(d)




(e)

Şekil 1.2. Deney#3 kesinlik ve kayıp eğrileri a) kat-1 kesinlik eğrisi b) kat-2 kesinlik eğrisi c) kat-3 kesinlik eğrisi ç) kat-4 kesinlik eğrisi d) kat-5 kesinlik eğrisi e) kat-1 kayıp eğrisi f) kat-2 kayıp eğrisi g) kat-3 kayıp eğrisi ğ) kat-4 kayıp eğrisi h) kat-5 kayıp eğrisi


EK-1. (devam) Kesinlik ve kayıp eğrileri




(f)



(g)




(ğ)




(h)

Şekil 1.2. (devam) Deney#3 kesinlik ve kayıp eğrileri a) kat-1 kesinlik eğrisi b) kat-2 kesinlik eğrisi c) kat-3 kesinlik eğrisi ç) kat-4 kesinlik eğrisi d) kat-5 kesinlik eğrisi e) kat-1 kayıp eğrisi f) kat-2 kayıp eğrisi g) kat-3 kayıp eğrisi ğ) kat-4 kayıp eğrisi h) kat-5 kayıp eğrisi


EK-1. (devam) Kesinlik ve kayıp eğrileri




(a)




(b)




(c)



(ç)




(d)




(e)

Şekil 1.3. Deney#4 kesinlik ve kayıp eğrileri a) kat-1 kesinlik eğrisi b) kat-2 kesinlik eğrisi c) kat-3 kesinlik eğrisi ç) kat-4 kesinlik eğrisi d) kat-5 kesinlik eğrisi e) kat-1 kayıp eğrisi f) kat-2 kayıp eğrisi g) kat-3 kayıp eğrisi ğ) kat-4 kayıp eğrisi h) kat-5 kayıp eğrisi


EK-1. (devam) Kesinlik ve kayıp eğrileri




(f)



(g)



(ğ)




(h)


Şekil 1.3. (devam) Deney#4 kesinlik ve kayıp eğrileri a) kat-1 kesinlik eğrisi b) kat-2 kesinlik eğrisi c) kat-3 kesinlik eğrisi ç) kat-4 kesinlik eğrisi d) kat-5 kesinlik eğrisi e) kat-1 kayıp eğrisi f) kat-2 kayıp eğrisi g) kat-3 kayıp eğrisi ğ) kat-4 kayıp eğrisi h) kat-5 kayıp eğrisi

,


EK-1. (devam) Kesinlik ve kayıp eğrileri




(a)




(b)




(c)



(ç)




(d)




(e)

Şekil 1.4. Deney#5 kesinlik ve kayıp eğrileri a) kat-1 kesinlik eğrisi b) kat-2 kesinlik eğrisi c) kat-3 kesinlik eğrisi ç) kat-4 kesinlik eğrisi d) kat-5 kesinlik eğrisi e) kat-1 kayıp eğrisi f) kat-2 kayıp eğrisi g) kat-3 kayıp eğrisi ğ) kat-4 kayıp eğrisi h) kat-5 kayıp eğrisi


EK-1. (devam) Kesinlik ve kayıp eğrileri




(f)



(g)




(ğ)




(h)

Şekil 1.4. (devam) Deney#5 kesinlik ve kayıp eğrileri a) kat-1 kesinlik eğrisi b) kat-2 kesinlik eğrisi c) kat-3 kesinlik eğrisi ç) kat-4 kesinlik eğrisi d) kat-5 kesinlik eğrisi e) kat-1 kayıp eğrisi f) kat-2 kayıp eğrisi g) kat-3 kayıp eğrisi ğ) kat-4 kayıp eğrisi h) kat-5 kayıp eğrisi


EK-1. (devam) Kesinlik ve kayıp eğrileri




(a)




(b)




(c)



(ç)




(d)




(e)

Şekil 1.5. Deney#6 kesinlik ve kayıp eğrileri a) kat-1 kesinlik eğrisi b) kat-2 kesinlik eğrisi c) kat-3 kesinlik eğrisi ç) kat-4 kesinlik eğrisi d) kat-5 kesinlik eğrisi e) kat-1 kayıp eğrisi f) kat-2 kayıp eğrisi g) kat-3 kayıp eğrisi ğ) kat-4 kayıp eğrisi h) kat-5 kayıp eğrisi


EK-1. (devam) Kesinlik ve kayıp eğrileri




(f)



(g)




(ğ)




(h)

Şekil 1.5. (devam) Deney#6 kesinlik ve kayıp eğrileri a) kat-1 kesinlik eğrisi b) kat-2 kesinlik eğrisi c) kat-3 kesinlik eğrisi ç) kat-4 kesinlik eğrisi d) kat-5 kesinlik eğrisi e) kat-1 kayıp eğrisi f) kat-2 kayıp eğrisi g) kat-3 kayıp eğrisi ğ) kat-4 kayıp eğrisi h) kat-5 kayıp eğrisi


EK-1. (devam) Kesinlik ve kayıp eğrileri




(a)




(b)




(c)



(ç)




(d)




(e)

Şekil 1.6. Deney#7 kesinlik ve kayıp eğrileri a) kat-1 kesinlik eğrisi b) kat-2 kesinlik eğrisi c) kat-3 kesinlik eğrisi ç) kat-4 kesinlik eğrisi d) kat-5 kesinlik eğrisi e) kat-1 kayıp eğrisi f) kat-2 kayıp eğrisi g) kat-3 kayıp eğrisi ğ) kat-4 kayıp eğrisi h) kat-5 kayıp eğrisi


EK-1. (devam) Kesinlik ve kayıp eğrileri




(f)



(g)




(ğ)




(h)

Şekil 1.6. (devam) Deney#7 kesinlik ve kayıp eğrileri a) kat-1 kesinlik eğrisi b) kat-2 kesinlik eğrisi c) kat-3 kesinlik eğrisi ç) kat-4 kesinlik eğrisi d) kat-5 kesinlik eğrisi e) kat-1 kayıp eğrisi f) kat-2 kayıp eğrisi g) kat-3 kayıp eğrisi ğ) kat-4 kayıp eğrisi h) kat-5 kayıp eğrisi


EK-1. (devam) Kesinlik ve kayıp eğrileri




(a)




(b)




(c)



(ç)




(d)




(e)

Şekil 1.7. Deney#8 kesinlik ve kayıp eğrileri a) kat-1 kesinlik eğrisi b) kat-2 kesinlik eğrisi c) kat-3 kesinlik eğrisi ç) kat-4 kesinlik eğrisi d) kat-5 kesinlik eğrisi e) kat-1 kayıp eğrisi f) kat-2 kayıp eğrisi g) kat-3 kayıp eğrisi ğ) kat-4 kayıp eğrisi h) kat-5 kayıp eğrisi


EK-1. (devam) Kesinlik ve kayıp eğrileri




(f)



(g)




(ğ)




(h)

Şekil 1.7. (devam) Deney#8 kesinlik ve kayıp eğrileri a) kat-1 kesinlik eğrisi b) kat-2 kesinlik eğrisi c) kat-3 kesinlik eğrisi ç) kat-4 kesinlik eğrisi d) kat-5 kesinlik eğrisi e) kat-1 kayıp eğrisi f) kat-2 kayıp eğrisi g) kat-3 kayıp eğrisi ğ) kat-4 kayıp eğrisi h) kat-5 kayıp eğrisi




(a)




(b)

Şekil 1.8. Deney#9 kesinlik ve kayıp eğrileri a) kat-1 kesinlik eğrisi b) kat-2 kesinlik eğrisi c) kat-3 kesinlik eğrisi ç) kat-4 kesinlik eğrisi d) kat-5 kesinlik eğrisi e) kat-1 kayıp eğrisi f) kat-2 kayıp eğrisi g) kat-3 kayıp eğrisi ğ) kat-4 kayıp eğrisi h) kat-5 kayıp eğrisi


EK-1. (devam) Kesinlik ve kayıp eğrileri




(c)




(ç)




(d)



(e)




(f)




(g)

Şekil 1.8. (devam) Deney#9 kesinlik ve kayıp eğrileri a) kat-1 kesinlik eğrisi b) kat-2 kesinlik eğrisi c) kat-3 kesinlik eğrisi ç) kat-4 kesinlik eğrisi d) kat-5 kesinlik eğrisi e) kat-1 kayıp eğrisi f) kat-2 kayıp eğrisi g) kat-3 kayıp eğrisi ğ) kat-4 kayıp eğrisi h) kat-5 kayıp eğrisi

EK-1. (devam) Kesinlik ve kayıp eğrileri




(ğ)




(h)


Şekil 1.8. (devam) Deney#9 kesinlik ve kayıp eğrileri a) kat-1 kesinlik eğrisi b) kat-2 kesinlik eğrisi c) kat-3 kesinlik eğrisi ç) kat-4 kesinlik eğrisi d) kat-5 kesinlik eğrisi e) kat-1 kayıp eğrisi f) kat-2 kayıp eğrisi g) kat-3 kayıp eğrisi ğ) kat-4 kayıp eğrisi h) kat-5 kayıp eğrisi




(a)



(b)




(c)




(ç)

Şekil 1.9. Deney#10 kesinlik ve kayıp eğrileri a) kat-1 kesinlik eğrisi b) kat-2 kesinlik eğrisi c) kat-1 kayıp eğrisi ç) kat-2 kayıp eğrisi


EK-1. (devam) Kesinlik ve kayıp eğrileri




(a)




(b)




(c)



(ç)




(d)




(e)

Şekil 1.10. Deney#13 kesinlik ve kayıp eğrileri a) kat-1 kesinlik eğrisi b) kat-2 kesinlik eğrisi c) kat-3 kesinlik eğrisi ç) kat-4 kesinlik eğrisi d) kat-5 kesinlik eğrisi e) kat-1 kayıp eğrisi f) kat-2 kayıp eğrisi g) kat-3 kayıp eğrisi ğ) kat-4 kayıp eğrisi h) kat-5 kayıp eğrisi


EK-1. (devam) Kesinlik ve kayıp eğrileri




(f)



(g)




(ğ)




(h)

Şekil 1.10. (devam) Deney#13 kesinlik ve kayıp eğrileri a) kat-1 kesinlik eğrisi b) kat-2 kesinlik eğrisi c) kat-3 kesinlik eğrisi ç) kat-4 kesinlik eğrisi d) kat-5 kesinlik eğrisi e) kat-1 kayıp eğrisi f) kat-2 kayıp eğrisi g) kat-3 kayıp eğrisi ğ) kat-4 kayıp eğrisi h) kat-5 kayıp eğrisi


EK-1. (devam) Kesinlik ve kayıp eğrileri




(a)




(b)




(c)



(ç)




(d)




(e)

Şekil 1.11. Deney#15 kesinlik ve kayıp eğrileri a) kat-1 kesinlik eğrisi b) kat-2 kesinlik eğrisi c) kat-3 kesinlik eğrisi ç) kat-4 kesinlik eğrisi d) kat-5 kesinlik eğrisi e) kat-1 kayıp eğrisi f) kat-2 kayıp eğrisi g) kat-3 kayıp eğrisi ğ) kat-4 kayıp eğrisi h) kat-5 kayıp eğrisi


EK-1. (devam) Kesinlik ve kayıp eğrileri




(f)



(g)




(ğ)




(h)

Şekil 1.11. (devam) Deney#15 kesinlik ve kayıp eğrileri a) kat-1 kesinlik eğrisi b) kat-2 kesinlik eğrisi c) kat-3 kesinlik eğrisi ç) kat-4 kesinlik eğrisi d) kat-5 kesinlik eğrisi e) kat-1 kayıp eğrisi f) kat-2 kayıp eğrisi g) kat-3 kayıp eğrisi ğ) kat-4 kayıp eğrisi h) kat-5 kayıp eğrisi


EK-1. (devam) Kesinlik ve kayıp eğrileri




(a)




(b)




(c)



(ç)




(d)




(e)

Şekil 1.12. Deney#16 kesinlik ve kayıp eğrileri a) kat-1 kesinlik eğrisi b) kat-2 kesinlik eğrisi c) kat-3 kesinlik eğrisi ç) kat-4 kesinlik eğrisi d) kat-5 kesinlik eğrisi e) kat-1 kayıp eğrisi f) kat-2 kayıp eğrisi g) kat-3 kayıp eğrisi ğ) kat-4 kayıp eğrisi h) kat-5 kayıp eğrisi


EK-1. (devam) Kesinlik ve kayıp eğrileri




(f)



(g)




(ğ)




(h)

Şekil 1.12. (devam) Deney#16 kesinlik ve kayıp eğrileri a) kat-1 kesinlik eğrisi b) kat-2 kesinlik eğrisi c) kat-3 kesinlik eğrisi ç) kat-4 kesinlik eğrisi d) kat-5 kesinlik eğrisi e) kat-1 kayıp eğrisi f) kat-2 kayıp eğrisi g) kat-3 kayıp eğrisi ğ) kat-4 kayıp eğrisi h) kat-5 kayıp eğrisi


EK-1. (devam) Kesinlik ve kayıp eğrileri




(a)




(b)




(c)



(ç)




(d)




(e)

Şekil 1.13. Deney#23 kesinlik ve kayıp eğrileri a) kat-1 kesinlik eğrisi b) kat-2 kesinlik eğrisi c) kat-3 kesinlik eğrisi ç) kat-4 kesinlik eğrisi d) kat-5 kesinlik eğrisi e) kat-1 kayıp eğrisi f) kat-2 kayıp eğrisi g) kat-3 kayıp eğrisi ğ) kat-4 kayıp eğrisi h) kat-5 kayıp eğrisi


EK-1. (devam) Kesinlik ve kayıp eğrileri




(f)



(g)




(ğ)




(h)

Şekil 1.13. (devam) Deney#23 kesinlik ve kayıp eğrileri a) kat-1 kesinlik eğrisi b) kat-2 kesinlik eğrisi c) kat-3 kesinlik eğrisi ç) kat-4 kesinlik eğrisi d) kat-5 kesinlik eğrisi e) kat-1 kayıp eğrisi f) kat-2 kayıp eğrisi g) kat-3 kayıp eğrisi ğ) kat-4 kayıp eğrisi h) kat-5 kayıp eğrisi


EK-2. Ara katman görselleştirilmesi




(a)




(b)




(c)



(ç)




(d)



(e)

Şekil 2.1. Ara katman görselleştirilmesi a) katman-2 b) katman-3 c) katman-4 ç) katman-5 d) katman- 6 e) katman-7 f) katman-8 g) katman-9 ğ) katman-10 h) katman-11 ı) katman-12 i) katman-13.

EK-2. (devam) Ara katman görselleştirilmesi



Şekil 2.1. (devam) Ara katman görselleştirilmesi a) katman-2 b) katman-3 c) katman-4 ç) katman-5 d) katman- 6 e) katman-7 f) katman-8 g) katman-9 ğ) katman-10 h) katman-11 ı) katman-12 i) katman-13.

ÖZGEÇMİŞ

Kişisel Bilgiler

Soyadı, adı : ATICI, Mehmet Ali
 Uyuğu : T.C.
 Doğum tarihi ve yeri : 13.02.1980, Keşan
 Medeni hali : Evli
 Telefon : +905050855193
 e-mail : machinelearningdynamics@gmail.com



Eğitim

Derece	Eğitim Birimi	Mezuniyet Tarihi
Doktora	Gazi Üniversitesi / Bilgisayar Mühendisliği	Devam ediyor
Yüksek Lisans	Gazi Üniversitesi / Bilgisayar Mühendisliği	2007
Lisans	Bilkent Üniversitesi / Bilgisayar Mühendisliği	2002

İş Deneyimi

Yıl	Yer	Görev
2002-2002	İşlem A.Ş.	Yazılım Mühendisi
2004-2010	NVİ Genel Müdürlüğü	Mühendis
2010-2013	Gelir İdaresi Başkanlığı	Mühendis

Yabancı Dil

İngilizce

Yayınlar

- Atici, M.A., Sagioglu, S., Celtikci, P., Uçar, M., Börcek, A.Ö. and Emmez, H. (2020). A novel deep learning algorithm for the automatic detection of high-grade gliomas on t2-weighted magnetic resonance images. a preliminary machine learning study. *Turkish Neurosurgery*, 30(2), 194-198.
- Atici, M.A. (2017). An analysis of automatic gender detection by first-order configural relations. *International Conference on Computer Science and Engineering (UBMK)*, 18-21.

3. Atici, M.A., Sagioglu, S. and Dogru, I.A. (2016). Android malware analysis approach based on control flow graphs and machine learning algorithms. *4th International Symposium on Digital Forensic and Security (ISDFS)*, 26-31.
4. Atıcı, M.A. ve Sağıroğlu, Ş . (2016). Steganografi Tabanlı Yeni Bir Klasör Kitleme Yaklaşımı ve Yazılımı Geliştirilmesi. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 31(1), 129-144.
5. Atici, M.A., Doğru, İ.A. and Sağıroglu Ş. (2015). Detecting Remote to Local User Attacks with High Ratio. *3rd International Symposium on Digital Forensics and Security*, 14-19.

Hobiler

Yüzme, Masa tenisi



GAZİ GELECEKTİR..