



T.C.  
KIRŞEHİR AHİ EVRAN ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ  
İLERİ TEKNOLOJİLER ANABİLİM DALI

**OTO KODLAYICILAR VE GÖRÜNTÜ İŞLEME  
TEKNİKLERİ İLE BEYİN TÜMÖRLERİNİN MR  
GÖRÜNTÜLERİNİN SINIFLANDIRILMASI**

**Ruaa Adil ABDULHUSSEIN**

**YÜKSEK LİSANS TEZİ**

**KIRŞEHİR / 2022**



T.C.  
KIRŞEHİR AHİ EVRAN ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ  
İLERİ TEKNOLOJİLER ANABİLİM DALI

**OTO KODLAYICILAR VE GÖRÜNTÜ İŞLEME  
TEKNİKLERİ İLE BEYİN TÜMÖRLERİNİN MR  
GÖRÜNTÜLERİNİN SINIFLANDIRILMASI**

**Ruaa Adil ABDULHUSSEIN**

**YÜKSEK LİSANS TEZİ**

**DANIŞMAN**

**Dr. Öğr. Üyesi Serkan KESER**

**KIRŞEHİR / 2022**

## **TEZ BİLDİRİMİ**

Tez içindeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edilerek sunulduğunu, ayrıca tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade bilginin kaynağına eksiksiz atıf yapıldığını bildiririm.

Ruaa Adil ABDULHUSSEIN



20.04.2016 tarihli Resmî Gazete’de yayımlanan Lisansüstü Eğitim ve Öğretim Yönetmeliğinin 9/2 ve 22/2 maddeleri gereğince; Bu Lisansüstü Teze, Kırşehir Ahi Evran Üniversitesi’nin aboneli olduğu intihal yazılım programı kullanılarak Fen Bilimleri Enstitüsü’nün belirlemiş olduğu ölçütlere uygun rapor alınmıştır.



## ÖNSÖZ

Yüksek lisansa başlamamda ve yüksek lisans ders ve tez yazım sürecinde kendisini tanıdığım günden bu yana gösterdiği sakin ve sabırlı hali ile her zaman bana örnek olmasının yanı sıra bir bilim adamının nasıl çalışması gerektiğini kendisinden öğrendiğim değerli danışmanım Dr. Öğr. Üyesi Serkan KESER'e teşekkür ederim. Çalışmalarım boyunca maddi manevi destekleriyle beni hiçbir zaman yalnız bırakmayan, beni bugünlere getiren aileme de sonsuz teşekkürler ederim.

Ocak, 2022

Ruaa Adil ABDULHUSSEIN

# İÇİNDEKİLER

Sayfa No

TEZ BİLDİRİMİ .....	ii
ÖNSÖZ .....	iv
İÇİNDEKİLER.....	v
ŞEKİL LİSTESİ .....	vii
TABLO LİSTESİ.....	viii
SİMGE VE KISALTMA LİSTESİ .....	ix
ÖZET .....	x
ABSTRACT .....	xi
1. GİRİŞ .....	1
1.1. KAYNAK ARAŞTIRMASI.....	1
1.2. Çalışmanın Amacı.....	5
2. YAPAY ZEKA .....	6
2.1. Bilgisayarlı görü .....	6
2.1.1. Makine Öğrenme.....	7
2.1.1.1. Eğitim ve Test Veri Seçimi .....	7
2.1.1.2. Eğitim Veri Kümesinde Çalıştırılacak Algoritma Seçimi .....	7
2.1.1.3. Modeli Oluşturmak İçin Algoritmayı Eğitimde Kullanma .....	8
2.1.1.4. Modeli kullanma ve geliştirme .....	8
2.1.2. Denetimli Öğrenme .....	8
2.1.2.1. Yapay Sinir Ağları (YSA).....	8
2.1.2.2. Karar Ağaçları.....	9
2.1.2.3. Destek Vektör Makinesi (DVM) .....	10
2.1.2.4. K-en Yakın Komşu.....	10
2.1.3. Denetimsiz Öğrenme .....	11
2.1.3.1. K-ortalama .....	11
2.1.3.2. Yoğunluğa Dayalı Kümeleme.....	11
2.1.4. Derin Öğrenme .....	11
3. MATERYAL VE YÖNTEM.....	13
3.1. Oto Kodlayıcılar .....	13
3.2. Evrişimli Sinir Ağı.....	15
3.2.1. Evrişim Katmanı .....	16

3.2.2. Birleştirme Katmanı .....	16
3.2.3. Tam Bağlı Katman .....	17
3.2.4. Transfer Öğrenme Yöntemleri .....	18
3.2.4.1. AlexNet .....	18
3.2.4.2. Densenet201 .....	19
3.3. Kullanılan Veri Tabanı.....	19
3.4. Önerilen Sınıflayıcı Algoritmaları.....	20
3.4.1. ESA-Oto Kodlayıcı Hibrit Algoritması.....	20
3.4.2. ESA-Karar Ağaçları Algoritması .....	23
3.4.3. ESA-Destek Vektör Makinesi Algoritması .....	23
3.4.4. ESA-K En Yakın Komşu Algoritması.....	24
4. SONUÇLAR .....	24
4.1. Doğrulama Tekniği (Validation Technique).....	24
4.2. Karışıklık matrisi (Confusion Matrix) .....	24
4.3 Kullanılan Hibrit Algoritmaların Sonuçları .....	26
4.3.1 ESA-Karar Ağaçları Sonuçları.....	26
4.3.2 ESA-Destek Vektör Makinaları (DVM) Sonuçları .....	26
4.3.3. ESA-K En Yakın Komşu (ESA-KNN) Sonuçları.....	27
4.3.4. ESA- Oto Kodlayıcı Algoritma Sonuçları.....	27
KAYNAKLAR .....	33
ÖZGEÇMİŞ .....	40

## ŞEKİL LİSTESİ

	Sayfa No
Şekil 2.1. YSA yapısı .....	9
Şekil 2.2. Karar ağaçları yapısı .....	10
Şekil 3.1. Basit bir oto kodlayıcı ağ yapısı.....	14
Şekil 3.2. Evrişimli Sinir Ağı .....	15
Şekil 3.3. Evrişim Katmanı Örneği .....	16
Şekil 3.4. Birleştirme katmanı örneği.....	17
Şekil 3.5. Tam bağlı katman yapısı .....	17
Şekil 3.6. AlexNet yapısı.....	18
Şekil 3.7. Densenet201 Yapısı .....	19
Şekil 3.8. Önerilen metot yapısı .....	20
Şekil 3.9. Kullanılan oto kodlayıcı sinir ağı yapısı .....	21
Şekil 4.1. Karmaşıklık Matrisi .....	25
Şekil 4.2. Birinci Oto Kodlayıcı.....	27
Şekil 4.3. İkinci Oto Kodlayıcı.....	27
Şekil 4.4. SoftMax Yapısı .....	28
Şekil 4.5. İki Oto Kodlayıcı ve SoftMax Birleştirilmiş Yapısı .....	28
Şekil 4.6. ESA-Oto kodlayıcı ile elde edilen doğruluk sonuçları .....	28
Şekil 4.7. Rastgele çapraz geçirme test sonuçları.....	29



## TABLO LİSTESİ

	<b>Sayfa No</b>
<b>Tablo 3.1.</b> Çalışmada kullanılan eğitim ve test kümeleri.....	19
<b>Tablo 4.1.</b> Karşılaştırma tablosu .....	28



## SİMGE VE KISALTMA LİSTESİ

<b>Kısaltmalar</b>	<b>Açıklama</b>
ESA	Evrişimli Sinir Ağı
YSA	Yapay Sinir Ağları
DVM	Destek Vektör Makinesi
KNN	K Nearest Neighbor
DÖ	Derin Öğrenme
TP	Gerçek Pozitif
FP	Gerçek Negatif
FP	Yanlış Pozitif
FN	Yanlış Negatif
ACC	Doğruluk
TPR	Duyarlılık
SPC	Özgüllük
YDK	Yoğunluğa Dayalı Kümeleme
TSA	Tekrarlayan Sinir Ağları
KUSBA	Kısa-Uzun Süreli Bellek Ağları
SBM	Sınırlı Bölmeli Makineler
DİA	Derin İnanç ağları
MRI	Magnetic Resonance Imaging

## ÖZET

### YÜKSEK LİSANS TEZİ

# OTO KODLAYICILAR VE GÖRÜNTÜ İŞLEME TEKNİKLERİ İLE BEYİN TÜMÖRLERİNİN MR GÖRÜNTÜLERİNİN SINIFLANDIRILMASI

**Ruaa Adil ABDULHUSSEIN**

**Kırşehir Ahi Evran Üniversitesi  
Fen Bilimleri Enstitüsü  
İleri Teknolojiler Anabilim Dalı**

**Danışman: Dr. Öğr. Üyesi Serkan KESER**

Kanserler oluştuğu yerden yayılabilir ve beyin tümörlerine neden olabilirler. Beyin tümörü hastalarının %40'ından fazlasında beyin metastazının geliştiği görülür. Manyetik Rezonans Görüntüleme (MRI), beyin tümörlerini teşhis etmek için en yaygın kullanılan tıbbi görüntüleme tekniklerinden biridir. Ancak tümör cinsinin tespiti genel olarak doktorların görme duyuları ile yapılır. Bu çalışmada ise beyin tümörü çeşidinin tespiti için Evrişimsel Sinir Ağı (ESA) -Karar Ağaçları, ESA-Destek Vektör Makineleri, ESA- K en Yakın Komşu ve ESA-Oto kodlayıcı hibrit algoritmalar kullanılmıştır. Geliştirilen hibrit algoritmalarda ilk önce MRI görüntülerine Evrişimsel Sinir Ağı (ESA) uygulanarak öz nitelik katsayıları çıkarılır. Sonra elde edilen öz nitelik katsayıları kullanılan hibrit algoritmalar ile sınıflandırılır. Geliştirilen ESA-Oto kodlayıcı hibrit algoritması ile en yüksek doğruluk oranı (%97,7) elde etmiştir. Ayrıca sırası ile %75,9, %77,2 ve %79,4 doğruluk değerleri ESA-Karar Ağaçları, ESA-Destek Vektör Makineleri (ESA-DVM), ESA-K en Yakın Komşu (ESA- KEK) algoritmaları kullanılarak elde edilmiştir.

**Anahtar Kelimeler:** ESA, AlexNet, Oto kodlayıcı, Beyin tümörü, DVM, KEK.

## **ABSTRACT**

### **MASTER THESIS**

# **CLASSIFICATION OF MR IMAGES OF BRAIN TUMORS BY USING AUTO ENCODERS AND IMAGE PROCESSING TECHNIQUES**

**Ruaa Adil ABDULHUSSEIN**

**Kirsehir Ahi Evran University  
Science and Engineering Institute  
Advanced Technologies Department**

**Supervisor: Asst. Prof. Dr. Serkan KESER**

Cancers can spread from where they originated and cause brain tumors. More than 40% of brain tumor patients develop brain metastases. Magnetic Resonance Imaging (MRI) is one of the most widely used medical imaging techniques to diagnose brain tumors. However, the detection of the tumor type is generally made by the eyesight of the doctors. In this study, Convolutional Neural Network (CNN)-Decision Trees, CNN-Support Vector Machines, CNN-K Nearest Neighbor and CNN-Autoencoder hybrid algorithms were used to detect brain tumor type. In the developed hybrid algorithms, firstly, the feature coefficients are extracted by applying the Convolutional Neural Network (CNN) to the MRI images. Then, the obtained feature coefficients are classified by the hybrid algorithms used. The developed ESA-Autoencoder hybrid algorithm achieved the highest accuracy rate (97.7%). In addition, 75.9%, 77.2% and 79.4% accuracy values were obtained using CNN-Decision Trees, CNN-Support Vector Machines (CNN-SVM), CNN-K Nearest Neighbor algorithms (CNN-KNN), respectively.

**Keywords:** CNN, AlexNet, Autoencoder, Brain tumor, SVM, KNN.

# 1. GİRİŞ

Teknolojik gelişmeler her alanda olduğu gibi tıp alanında da yaygın olarak kullanılmaktadır [1]. Günümüzde bu teknolojinin gelişmesiyle hastanelerde kullanılan cihazlar ve tedavi yöntemleri de geliştirilmektedir. Donanım ve yazılımda sürekli gelişim olması sayesinde önerilen görüntü işleme metotları ile teşhis ve tedavilerin daha profesyonel bir şekilde uygulaması mümkün olmaktadır [2]. Böylece, insan hayatının söz konusu olduğu önemli süreçlerde daha kısa sürede daha etkili kararlar alınabilir.

Tıp alanında insan sağlığı ile ilgili olduğu için Ar-Ge çalışmalarının olabildiğince kapsamlı ve desteklenmesi önemlidir. Çünkü insan hayatı, maddi varlıklar ile ölçülemeyecek kadar değerlidir [3]. Erken teşhis birçok tedavide büyük önem taşımaktadır. Tedavi ertelendiğinde hastalık daha da ilerleyebilir ve tedavisi daha zor olabilir. Bazı durumlarda, geri dönüşü olmayan kayıplara neden olabilir. Bu nedenlerle doktora tanı ve tedavide yardımcı olmak için kullanılan veri çıkarma yöntemlerine literatürde sıkça rastlanmaktadır. Pek çok çalışmada ümit verici sonuçlar elde edilmiştir [4,5].

## 1.1. KAYNAK ARAŞTIRMASI

Bu tezde yapılan çalışmaya benzer birçok çalışma incelenmiş ve detaylı bir şekilde aşağıda açıklanmıştır.

Mircea Gurbină ve arkadaşları, normal beyin ve tümörlü beyin (iyi huylu veya kötü huylu) arasında ayırım yapmayı amaçlamaktadır [6]. Metastatik bronkojenik karsinom tümörleri, glioblastoma ve sarkom gibi bazı beyin tümörü türlerinin incelenmesi, beyin manyetik rezonans görüntüleme kullanılarak gerçekleştirilmiştir. MRI beyin tümörlerinin tespiti ve sınıflandırılması, farklı dalgacık dönüşümleri ve destek vektör makineleri kullanılarak elde edilmiştir.

[7]'de T. A. Jemimma ve arkadaşları Watershed Dynamic Angle Projection - Convolution Neural Network (WDAPP-CNN) kullanarak tümör tespit tekniklerini önermiştir. Su havzası algoritması, tümör bölgesini segmentlere ayırır. Dinamik açı projeksiyon modeli, beynin dokulu özelliklerini çıkarır ve evrimsel sinir ağı, MRI beyin görüntüsünün tümörlü ve tümörsüz bölgelerini sınıflandırır. Beyin görüntüsündeki anormallik tespit edilir ve BRATS veri seti

aracılığıyla verimli bir şekilde test gerçekleştirilir. Bu yöntem %91,03 sınıflama başarımına sahiptir.

[8]'de Hein Tun Zaw, yayılan tüm kanserli dokuları içeren bir tümör bölgesini doğru bir şekilde tanımak için Naïve Bayes sınıflandırmasını kullanmıştır. Bu araştırmada beyin MRI veri tabanı, ön işleme, morfolojik işlemler, piksel çıkarma, maksimum entropi eşiği, istatistiksel özellik çıkarımı ve Naïve Bayes sınıflandırıcı tabanlı tahmin algoritması kullanmıştır. Bu yöntemin amacı, tümör bölgesini farklı beyin MRI görüntülerinden tespit etmek ve tespit edilen bölgede tümör olup olmadığını tahmin etmektir. Diğer yöntemlerle karşılaştırıldığında bu yöntem, beyin farklı bölgelerinde bulunan ve orta bölge de dahil olmak üzere (göz hizasına göre hizalı) tümörü doğru bir şekilde tespit edebilmektedir. Bu durum yöntemin önemli bir avantajıdır. 50 MRI görüntüsü üzerinde test edilen bu yöntem %94 genel doğruluğa, tümör görüntülerinde %81,25 doğruluğa ve tümör olmayan görüntülerde %100 doğruluğa sahiptir.

[9]'da Önerilen sistemin amacı, beyin tümörü görüntülerini Evrişimsel Sinir Ağı (ESA) ve Destek Vektör Makinesi (SVM) kullanarak üç alt türe sınıflandırmaktır. Bu beyin tümörü türleri Meningioma, Glioma ve Pituitary'dir. Hesaplamayı azaltmak için veri kümesindeki görüntülerin boyutu küçültülmüştür. Ayrıca modeli sağlam kılmak ve veri kümesini artırmak için biraz tuzlu gürültü eklenmiştir. Performans karşılaştırması Google Colab ve tensorflow platformunda python dilinde yapılmıştır.

[10]'da Arun Kumar ve arkadaşları, beyin tümörü içeren MRI görüntülerini çevrim içi veri tabanına alıp, ardından özellik seçimi için Parçacık Sürü Optimizasyonu (PSO) algoritması kullanılarak bir makine öğrenme modeli geliştirmişlerdir. Daha sonra mevcut beyindeki tümör türünü sınıflandırmak için Destek Vektör Makinesi (DVM) sınıflandırıcısı kullanılır.

Adel Kermi ve arkadaşları [26], üç boyutlu manyetik rezonans görüntüleme beyin ve standart grubun benzerlik analizlerini kullanarak otomatik beyin kanseri segmentasyon prosedürünü önermiştir. Gürültüyü gidermek için fotoğrafın ön işleme yapılmıştır. Simetri analizi tekniği etkili ve denetimsizdir. Bu teknik kullanılarak tümörlerin tespiti otomatik olarak yapılır. Tümörün şeklini ve hacmini her durumda sınırlarını tespit etmek için jeodezik seviye seti tabanlı 3 boyutlu deforme olabilir model uygulanır. Tümörleri tespit etmek ve segmentlere ayırmak için ortalama hesaplama süresi yaklaşık beş dakikadır. Elde edilen doğruluk ve duyarlılık sırasıyla %38,04 ve %89,01 bulunmuştur.

V. Anitha, S. Murugavalli [27] geliřtirdikleri bir algoritma ile açık ve sistematik inceleme tekniđini sunmuřtur. Önerilen algoritmada özellik çıkarımı Ayrık Dalgacık Dönüřümü (ADD) uygulandıktan sonra elde edilir. Bu özellik vektörleri ve filtre faktörleri daha sonra KNN tarafından öğrenilir ve test prosedürü çift fazda yapılır. Bu yöntem geleneksel sınıflandırma yöntemlerinden daha iyi performansa sahiptir. Elde edilen sonuç DVM tabanlı sınıflandırma tekniđine göre üstünlük gösterir. Sonuçlar çalışmanın görüntü sınıflandırma için tıbbi görüntüleme uygulamasına ve ayrıca bilgisayar destekli tanıma dahil edilebileceđini gösterir. Bu çalışmada doğruluk oranı %85 ve hassasiyet ise %100 elde edilmiřtir.

Parveen ve Iitpalsingh [28], manyetik rezonans görüntüleme fotođraflarının sınıflandırılması için veri madenciliđi teknikleri önermiřtir. Sınıflandırma dört ařamada gerçekleřtirilir. Bunlar ön iřleme, bölümlendirme, nitelik çıkarımı ve sınıflandırmadır. İlk ařamada, hız ve doğruluđu artırmak için iyileřtirme ve kafatası segmentasyonu yapılır. Segmentasyon ařamasında bulanık küme tekniđi uygulanır. Manyetik rezonans görüntüleme fotođraf özelliklerinin çıkarılması, gri seviyeli bir matris kullanılarak gerçekleřtirilir. Son ařama, görüntüleri sınıflandırmak için DVM uygulanır. Bu çalışmanın nihai sonuçları, MRI görüntü sınıflandırmaya göre yüksek derecede doğruluk ve verimlilik sergilemiřtir. Doğruluk %91,24 olarak belirlenmiřtir.

Daniele Ravi ve arkadaşları, operatif marj tanımının ayrıntılı bir yapısal haritasını elde etmek için yeni bir boyut azaltma ve iřleme yöntemi önermektedir [29]. Bu yöntem iki ařamada yapılır. İlk olarak Semantik Texton Forest kullanılarak semantik bölümlendirme yöntemi ile akan T dađırlımlı stokastik komřu iřlemi yapılır. Son olarak ise doku sınıflandırması yapılır. Çalışmada elde edilen doğruluk ve hassasiyet sırasıyla %81,90 ve %80,91 olmuřtur.

Lamia Salemi ve arkadaşları Glioblastoma modellemesi için yeni bir algoritma sunmuřtur [30]. Çıkarılan tümör bölgesi, global piksel bilgisine dayalı hızlı yayılma eřleřtirmesi ile uygulanarak yapılır. Yeni algoritma, zaman içinde kanser gelişimini deđerlendirmek için hızlı bir teknik kullanmaktadır. Bu yöntem, her görüntü için 0,5 saniyeden daha az optimize edilmiř bir çalışma süresine sahiptir ve uzun eğitim gerektirmez. Glioblastoma, sađlıklı hücrelere kıyasla farklı bir gri seviye sunar. Bu bilgi, beyin görüntüsünü iki bölgeye bölmek için kullanılır. Glioblastomlu bölgeler daha sonra yoğunluk seviyelerine dayalı olarak tahmin edilen modelle eřleřtirilir. Önerilen sistem, tümörleri gerçe zamanlı olarak çıkarır ve daha sonra büyüme tahminide gerçekleřtirilir. Bu çalışmada %89,74 doğruluk deđerini elde edilmiřtir.

Mukambika ve Uma, MRI Görüntüsünün 4 aşamada işlendiği aşamaları önermiştir [31]. Bunlar ön işleme, segmentasyon, örüntü çıkarma ve örüntü tanıma aşamalarıdır. Ön işleme aşamasında çift eşikleme prosedürü uygulanarak kafatası MRI görüntüsünden çıkarılır. İlk yöntem, manyetik rezonans görüntüleme beyin resimlerinden beyin kanserini kesmek için aktif bir konturlu parametrik olmayan deforme olabilen modeller kullanılarak oluşturulmuştur. İkinci yöntem, K-ortalama kümeleme tekniğidir. Segmentasyonun yanında iki aşamalı bir karar verme sağlanır. İlk aşamada özellik çıkarımı için uygulanan ayırık dalgacık dönüşümü ve "Gri Düzey Birlikte Oluşum Matrisi ve son olarakta, sınıflandırma aşamasında kullanılan Destek Vektör Makinesi (DVM) kullanılır. MRI beyin tümörü görüntülerinin veri seti, farklı hastaların T2 ağırlıklı 17 iyi huylu ve 24 kötü huylu tümör görüntüsünü içerir. Düzey seti ve K ortalama segmentasyonuna sahip DVM, normal beyin, iyi huylu veya kötü huylu tümör olarak görüntüyü sırasıyla %94,12 ve %82,35 doğrulukla sınıflandırır.

K. Sudharani ve arkadaşlarının önerdiği metot Histogram, Yeniden Örnekleme, K-NN Algoritması, Mesafe Matrisi gibi yöntemler kullanır [32]. İlk olarak histogram belirli bir görüntüdeki piksel dağılım miktarını sağlar. Uygun geometrik gösterim için resim 629×839'a yeniden boyutlandırılır. K parametresi ayarlandıktan sonra uygulanan KNN algoritması ile beyin tümörü sınıflandırılır. Sınıflandırmak için Manhattan mesafe ölçütü uygulanmıştır. Algoritmayı test etmek için kullanılan veri seti 48 görüntü içermektedir. Test edilen tüm görüntüler için sınıflandırma oranı %95'tir.

Rasel Ahmed ve arkadaşları, Yapay Sinir Ağı (YSA) kullanarak görüntü ön işleme, bölütleme, öz nitelik çıkarma, DVM sınıflaması ve tümör evresi sınıflandırması gibi aşamaları içeren bir yöntem önermiştir [33]. Bu çalışmada segmentasyon, K-ortalamlar ve Bulanık c-ortalamların hibrit algoritması olan bir algoritma uygulanmıştır. Özellik çıkarımı için birinci mertebeden istatistik özellikler ve İkinci mertebeye bölge özelliğine dayalı istatistik özellikler türetilir. Daha sonra DVM, beyin MRI resimlerini sağlıklı veya kanserli olarak sınıflandırır. Beyin tümörü evresi, ANN sınıflandırıcısı tarafından sınıflandırılır. Önerilen yöntem %97,7 sınıflama başarımına ulaşmıştır.



## 1.2. Çalışmanın Amacı

Günümüzde doğal olmayan gıdalar ve yanlış beslenme yüzünden pek çok kanser türü oluşmakta ve insan hayatını tehdit etmektedir. Bu kanser türlerinin bazıları aşı ya da ilaçlar ile erken evrelerde tedavi edilebilmektedir. Beyin tümörleri de beyin içinde oluşan ve insan hayatını zora sokan önemli bir hastalıktır. Bu hastalık her yıl yüzbinlerce insanın ölümüne sebep olmaktadır. Bu hastalığın erken evrede tespit edilmesi hastalığın tedavisi için en önemli etkenlerden biridir. Bir diğer etken ise beyin tümörünün tespitinden başka tümör cinsinin doğru tespit edilmesidir. Yanlış tespit yanlış tedavi yöntemlerine ve hastanın sağlığının daha da kötüleşmesine sebep olabilir. Görüntü işleme içeren MR görüntülerinden tümör tespiti çalışmaları son yıllarda büyük ilerlemeler sağlamıştır. Bu sayede yüksek doğruluklu tümör tespiti ile hem doktor hem de hasta için pek çok avantaj oluşmaktadır.

Bu çalışmada 3 çeşit tümörün ve tümör olmaması durumunun tespitini yapan Evrişimsel Sinir Ağı ile K-en Yakın Komşu, Karar Ağaçları, Destek Vektör Makineleri ve Oto Kodlayıcıları temel alan hibrit sınıflayıcılar gerçekleştirilmiştir. Sonuçlar incelendiğinde ve kullanılan görüntü veri tabanı büyüklüğü de dikkate alındığında Evrişimsel Sinir Ağı ve Oto Kodlayıcıları kullanarak elde edilen sınıflama başarımının çok yüksek olduğu görülmüştür. Bu sonuçlar Evrişimsel Sinir Ağı-Oto Kodlayıcı algoritmasının gerçek hayatta da tümör sınıflandırmada kullanılabileceğini göstermiştir.

## 2. YAPAY ZEKA

"Yapay zeka" terimi ilk kez 1956'da ortaya çıktı. Yapay zeka, artan miktarda veri, gelişmiş algoritmalar, bilgi işleme ve depolama kapasitesindeki gelişmeler nedeniyle günümüzde daha popüler hale gelmiştir. 1950'lerde ilk yapay zeka çalışması problem çözme ve sembolik yöntemler gibi konulara odaklandı. 1960'larda ABD Savunma Bakanlığı bu tür yapay zeka süreçleri ile ilgilenmeye başladı ve bilgisayarlara temel insan mantığını taklit etmeyi öğretmeye başladı. Örneğin, ABD Savunma Bakanlığı İleri Araştırma Projeleri Ajansı (DARPA) 1970'lerde sokak haritası projelerini tamamladı. Bu çalışmalar, insan yeteneklerini tamamlamak ve geliştirmek için tasarlanabilen karar destek sistemleri ve akıllı arama sistemleri dahil olmak üzere, bugün bilgisayarlarda gördüğümüz otomasyon ve biçimsel muhakemenin yolunu açmıştır. Günümüzde de yapay zeka sağlık, ekonomi, askeri pek çok alanda birçok özel fayda sağlayacak şekilde gelişmektedir [11].

Son zamanlarda yapay zeka teknikleri, sağlık hizmetlerinde büyük ilerlemeler sağlanmasına katkılar sağladı. Gelecekte yapay zekanın hekimlerin daha iyi klinik kararlar vermelerine ve hatta sağlık hizmetinin belirli işlevsel alanlarında (örneğin radyoloji) insan yargısının yerini almalarına yardımcı olabileceği düşünülüyor. Sağlık hizmeti verilerinin artan kullanılabilirliği ve büyük veri analiz yöntemlerinin hızlı gelişimi, sağlık hizmetlerinde yapay zekanın son zamanlardaki başarılı uygulamalarını mümkün kılmıştır [12].

### 2.1. Bilgisayarlı görü

Bilgisayarlı görü, dış dünyada görülebilen nesnelerin yorumlandığı ve anlaşıldığı yapay zeka dalıdır. Uzun zamandır yapay zeka ile ilişkilendirilmesine ve bir alt dal olarak görülmesine rağmen, bazı alanlarda giderek önemli hale gelmektedir.

Bilgisayarlı görü için ilk olarak 1966 yılında Seymour Papert ve Marvin Minsky tarafından yazılan Yaz Vizyonu Projesi ile nesnelere tanımlayan bir sistem olarak oluşturulmuştur [51]. Bir sonraki çalışma, Kunihiro Fukushima'nın 1979'da önemli bir yer tutan bilgisayarlı görme sistemi önerisiyle gerçekleştirilmiştir [52]. Son zamanlarda başarıyla uygulanan Evrimsel Sinir Ağları (ESA), Neocognitron'dan esinlenerek geliştirilmiştir [53]. Derin öğrenmede başarılı sonuçlar, özellikle de ESA'nın Imagenet görüntü tanıma yarışmasının bir parçası olarak geliştirdiği AlexNet'in parlak zaferi ile gözleri bilgisayarlı görüye çevirmiştir [13].

Bilgisayarla görü için, üç temel süreç vardır. Bunlar görüntüyü elde etme, görüntüyü işleme ve görüntüyü anlamadır. Bilgisayarlı görü türleri ise görüntü bölütleme, nesne tanıma, yüz tanıma, kenar tanıma, örüntü tanıma, görüntü sınıflandırma ve özellik işlemedir. Gerçek dünyada bilgisayarlı görü uygulamaları birçok yerde kullanılır. Facebook'ta yüz tanıma, askeri alanda hedef tanıma, ulaşım, Tesla-google gibi şirketlerde kullanılan sürücüsüz araçlar, güvenlik uygulamalarında yüz tanıma teknolojisi ve modern perakende mağazalarında otomatik ödeme işlemleri bunlara örnek gösterilebilir. Bilgisayarlı görü için önceki çalışmalarda birden fazla yapay zeka teknikleri kullanılmıştır. Bu teknikler genel olarak üçe ayrılır. Bunlar denetimli öğrenme, denetimsiz öğrenme ve derin öğrenmedir.

### **2.1.1. Makine Öğrenme**

Makine öğrenimi, verilerden öğrenen ve kodlama olmadan zaman içinde doğruluğu artıran uygulamalar oluşturmaya odaklanan bir yapay zeka dalıdır. Veri biliminde bir algoritma, istatistiksel işlem adımlarının bir dizisidir. Makine öğreniminde algoritmalar, yeni verilere dayalı kararlar ve tahminler yapmak için büyük miktardaki verileri kullanarak eğitim gerçekleştirirler. Algoritma ne kadar iyi olursa, daha fazla veri işledikçe kararlar ve tahminler o kadar doğru olur. Bir makine öğrenimi uygulaması (veya modeli) oluşturmanın dört temel adımı vardır. Bunlar tipik olarak, modelin geliştirilmekte olduğu iş profesyonelleri ile yakın çalışan veri bilimcileri tarafından gerçekleştirilir [14]

#### ***2.1.1.1. Eğitim ve Test Veri Seçimi***

Eğitim verileri, makine öğrenimi modelinin problemi çözmek için kullanacağı verileri temsil eden bir veri kümesidir. Bazı durumlarda eğitim verileri modelin tanımlaması gereken özellikleri ve sınıflandırmaları belirtmek için "etiketlenir". Diğer veriler etiketlenmemiştir ve modelin bu özellikleri çıkarması ve kendi başına sınıflandırması gerekir.

#### ***2.1.1.2. Eğitim Veri Kümesinde Çalıştırılacak Algoritma Seçimi***

Kullanılacak algoritma bir dizi istatistiksel işlem adıımıdır. Algoritma türü, eğitim veri setindeki veri türüne (etiketli veya etiketsiz), miktarına ve çözülecek problemin türüne bağlıdır.

### **2.1.1.3. Modeli Oluşturmak İçin Algoritmayı Eğitimde Kullanma**

Algoritmayı eğitmek yinelemeli bir süreçtir. Bu süreç algoritma aracılığıyla değişkenleri çalıştırmayı, üretilen sonuçlarla karşılaştırmayı, algoritma içindeki ağırlıkları, etiketleri ayarlamayı ve daha doğru bir sonuç verebilecek değişkenleri algoritmada tekrar çalıştırmayı içerir.

### **2.1.1.4. Modeli kullanma ve geliştirme**

Son adım modeli yeni verilerle zaman içinde doğruluğu ve etkinliği iyileştirmek için kullanmaktır. Yeni veriler çözülecek probleme göre seçilmelidir


## **2.1.2. Denetimli Öğrenme**

Denetimli makine öğrenmede bir sistem etiketlenmiş verilerle eğitilir. Etiketler her veri noktasını "X" veya "Y" gibi bir veya daha fazla grup halinde sınıflandırır. Sistem eğitim verileri adı verilen bu verilerin nasıl yapılandırıldığını öğrenir. Yeni veri kategorilerini veya "test" verilerini tahmin etmek için eğitim sonucunda elde edilen bilgiler kullanılır [15].

### **2.1.2.1. Yapay Sinir Ağları (YSA)**

Yapay Sinir Ağları (YSA), yapay zeka tekniklerinden biridir. YSA insan beyninin yeteneklerini yardım almadan gerçekleştirmeyi amaçlayan bilgisayar sistemleridir. Bu sistemleri programlarken geleneksel yöntemler genellikle yeterli olmaz.

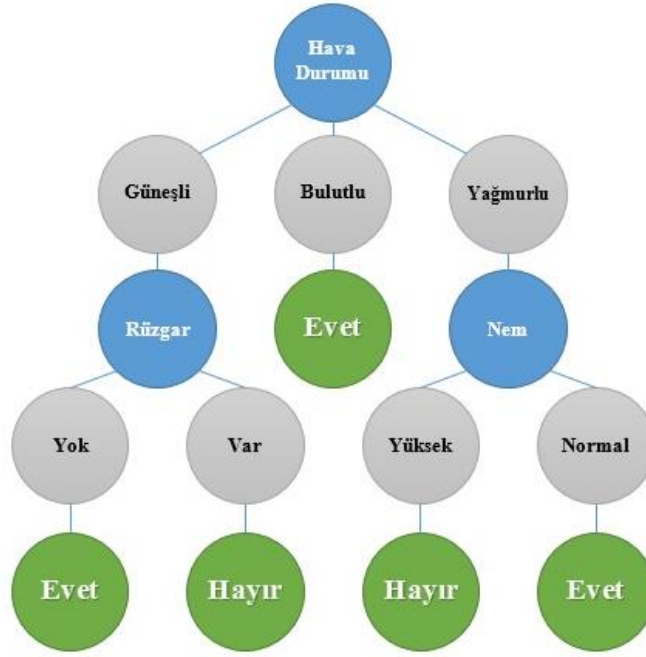
Aslında yapay sinir ağları tasarlanırken insanlarda ve hayvanlardaki biyolojik sinir ağından esinlenilmiştir. İnsan beynindeki nöronların bilgiyi iletmesi için elektriksel sinyaller bir nörondan diğerine iletilir. İletilen sinyaller beyinde (hafızada) depolanabilir. Başka bir deyişle, bilgisayarın depolama için kullandığı bellek, biyolojik sistemdeki beyni taklit eder. Hedefler aynıdır, ancak kullanılan mekanizma farklıdır. Kısaca YSA, zamanlaması zor olaylar için geliştirilmiş, veri işlemeyle ilgilenen bir bilgisayar bilimi algoritması olarak kabul edilir [16].



Şekil 2.1. YSA yapısı

### 2.1.2.2. Karar Ağaçları

Karar ağaçları sınıflandırma veya regresyon analizi amacıyla verileri tutarlı kümelerle bölmeyi amaçlayan denetimli öğrenme modelleridir. Karar ağacı varsayılan olarak döngüseldir ve bir kök düğüm, yaprak düğümler, dahili düğümler ve kenarlardan oluşur. Kök düğüm, ağacın başlangıcını, yaprak düğümleri sonucu veya sınıf etiketini temsil eden ağacın sonunu belirtir. Dahili düğüm, her düğümdeki verileri bölmek için kullanılan değişkenle ilgili ayrıntıları depolar. Kenarlar, düğümler arasındaki bağlantılardır ve bölümlerle ilgili ayrıntıları içerir. Bir kaydın sonucu, ağaç boyunca kök düğümden yaprak düğüme bilgi işlenerek elde edilir [50]. Eksik verileri tahmin etme görevini gerçekleştirmek için karar ağaçlarının kullanılması, eksik veri girişleri olan her değişken için bir ağaç oluşturmayı gerektirir. Bu değişken, giriş değişkeni kümesinin parçası olan gerçek sınıf etiketi olarak kabul edilir. Ağaç oluşturma, bilinen sınıf etiketlerine sahip kayıtlar kullanılarak yapılır ve eksik veri girişlerine göre karşılık gelen bir ağaç oluşturulur [17].



Şekil 2.2. Karar ağaçları yapısı

### 2.1.2.3. Destek Vektör Makinesi (DVM)

DVM günümüzde en yaygın olarak kullanılan makine öğrenimi tekniğine dayalı sınıflandırma tekniğidir. İstatistiksel öğrenme teorisine dayanmaktadır ve 1995 yılında Vapnik tarafından geliştirilmiştir [47]. Bu tekniğin temel amacı, doğrusal olmayan ayrılabilir örnekleri farklı türlerde çekirdek fonksiyonları kullanarak başka bir yüksek boyutlu alana yansıtmaktır. Son yıllarda, özellikle DVM 'nin artan popülaritesi nedeniyle çekirdek yöntemler büyük ilgi görmektedir. DVM 'de genel olarak doğrusal, polinom ve radyal tabanlı çekirdek işlevleri genel olarak kullanılır [20].

### 2.1.2.4. K-en Yakın Komşu

K en yakın komşu mevcut tüm durumları saklayan ve yeni durumları bir benzerlik ölçütüne, örneğin mesafe ölçütlerine göre sınıflandıran basit bir algoritmadır [48]. KNN, 1970'lerin başında parametrik olmayan bir teknik olarak istatistiksel tahmin ve örüntü tanımda kullanılmıştır. KNN algoritması hem sınıflandırma hem de regresyon problemlerini çözmek için kullanılabilen basit, uygulaması kolay denetimli bir makine öğrenme algoritmasıdır [21].

### **2.1.3. Denetimsiz Öğrenme**

Denetimsiz öğrenme etiketsiz öğrenmedir. Bu yöntemde, gruplar oluşturularak ve bu gruplara veri atayarak birbirine çok az benzeyen veri noktalarının özelliklerini belirlemeyi hedeflemektedir [18].

#### **2.1.3.1. K-ortalama**

K-ortalama ile kümeleme, en basit ve popüler denetimsiz makine öğrenimi algoritmalarından biridir. Tipik olarak denetimsiz algoritmalar bilinen veya etiketli sonuçlara atıfta bulunmadan yalnızca girdi vektörlerini kullanarak veri kümelerinden çıkarımlar yapar. Öğrenme verilerini işlemek için, veri madenciliğindeki K-ortalama algoritma her küme için başlangıç noktaları olarak rastgele seçilmiş merkezlerle işleme başlar ve ardından merkezlerin konumlarını optimize etmek için yinelemeli hesaplamalar yapar. Ana fikir, her küme için bir tane olmak üzere k merkezi tanımlamaktır. Bu merkezler akıllı bir şekilde yerleştirilmelidir, çünkü farklı konumlar farklı sonuçlara neden olur. Bu nedenle, daha iyi bir seçim, onları birbirinden mümkün olduğunca uzağa yerleştirmektir [19].

#### **2.1.3.2. Yoğunluğa Dayalı Kümeleme**

Yoğunluğa Dayalı Kümeleme (YDK), bir veri alanındaki kümenin yüksek nokta yoğunluğuna sahip bitişik bir bölge olduğu fikrine dayanarak verilerdeki farklı kümeleri tanımlayan denetimsiz öğrenme yöntemlerini ifade eder. Düşük nokta yoğunluğuna sahip ayırma bölgelerindeki veri noktaları tipik olarak gürültü değerleri olarak kabul edilir [49].

### **2.1.4. Derin Öğrenme**

Makine öğreniminin bir alt alanı olan derin öğrenme, bilgi işlem gücünün önemli ölçüde artması ve yeni büyük veri setlerinin her geçen gün artması nedeniyle son yıllarda popülerlik kazanmıştır. Derin öğrenme alanı, görüntü sınıflandırma, nesne algılama, konuşma tanıma, dil çevirisi, doğal dil işleme ve oyun gibi çeşitli karmaşık görevlerde devrim niteliğinde performans sergilemeye devam etmektedir [54]. Derin öğrenme modellerinin grafik işleme birimi üzerinde çalışabilme yeteneği, büyük veri setlerini modelleme açısından birçok geleneksel makine öğrenimi yaklaşımından daha iyi performans göstermelerine izin vermiştir. Derin öğrenme sistemleri, girdi olarak birden çok veri türünü kabul edebilmektedir. Bu durum aynı tür veriler için özellikle önemlidir [22]. Mevcut derin öğrenme algoritmalarının çoğu, bir kayıp işlevini en aza indirirken eğitim verilerinden ağırlıkların ve sapma (bias) değerinin

öğrenildiği denetimli öğrenme gerçekleştiren bir yapay sinir ağı kullanır (örneğin, kök ortalama kare hatası, çapraz entropi vb.).

Eğitim sırasında her ağırlığın ve sapma değerinin bir fonksiyonu olarak kayıp fonksiyonunun gradyenlerini hesaplamak için geri yayılma algoritması kullanılır. Bu gradyenler daha sonra ağırlıkları ve eğilimleri gradyenin ters yönünde güncellemek için optimizasyon algoritmalarında kullanılır. Farklı eğitim örneklerinde ağırlıkları ve sapma değerinin birden çok kez güncellemek, sonunda uygun şekilde eğitilmiş bir sinir ağı oluşturacaktır [23]. Derin sinir ağlarının türleri arasında ESA, Tekrarlayan Sinir Ağları (TSA), Kısa-Uzun Süreli Bellek Ağları (KUSBA), Sınırlı Bölmeli Makineler (SBM) ve Derin İnanç ağları (DİA) bulunur.

Evrışimli Sinir Ağları (ESA) derin öğrenme mimarisi, tıbbi görüntülerin ve video verilerinin işlenmesinde sıklıkla kullanılır. ESA'ların önemli bileşenleri, evrışimli katmanlar, maksimum toplama katmanları ve tam bağlantı katmanlarıdır. Giriş katmanının formatı, giriş verileriyle aynı olmalıdır. Çıktı katmanının biçimi, eğitim verileriyle aynı olmalıdır [24]. Son zamanlarda ESA, birçok tıbbi görüntü işleme ve tanıma uygulamalarında kullanılmıştır. Bu çalışmaların çoğunda verimli ve iyi sonuçlar bulunmuştur.



### 3. MATERYAL VE YÖNTEM

#### 3.1. Oto Kodlayıcılar

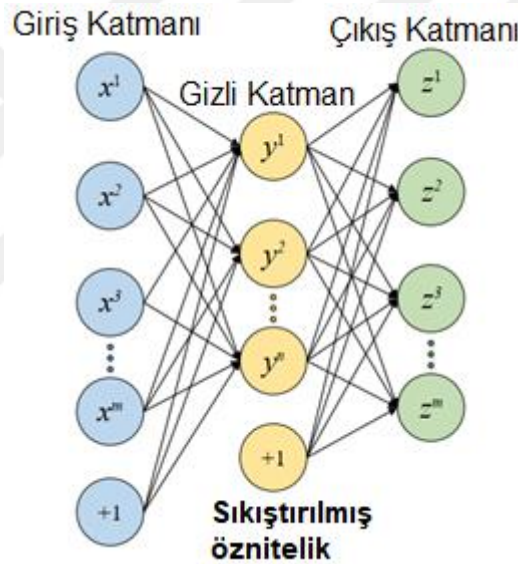
Oto kodlayıcılar, denetimsiz öğrenme metodu olan yapay sinir ağlarının bir çeşididir. Oto kodlayıcılar uzun bir süredir bilinmesine karşın uygulamalarının hayata geçmesi 1980'li yılları bulmuştur [39]. Bu sinir ağını diğer sinir ağı çeşitlerinden ayıran kısım verilerin öncelikle gizli katmanlarda sıkıştırılıp ardından sıkıştırılan veriler kullanılarak, giriş verisinin elde edilmeye çalışılmasıdır [40]. Bunun en temel amacı, veriler içerisinde bulunan özniteliklerin ortaya çıkartılarak verinin yeniden elde edilebileceğinin gösterilmesidir. Özniteliklerin ortaya çıkarılması aşaması gizli katmanlarda en düşük boyuttaki veri içeren katmanda gerçekleştirilir. Bu özellik kullanılarak oto kodlayıcıların veriler içerisinde bulunan öznitelik vektörlerini bulmalarına dair çalışmalar mevcuttur [41,42].

Bir verinin öz niteliklerin bulunmasının sinir ağlarının eğitilmesi konusunda oldukça önemli bir durum olduğu kaçınılmaz bir gerçektir. Bir ağı eğitmek için kullanılacak olan verinin bir başka ağ tarafından üretilmesi bu konsept kullanılarak gerçekleştirilebilir. Oto kodlayıcıların verileri tekrar oluştururken giriş verisinin içerisinde bulunan herhangi bir düzeni olmayan gürültü sinyallerini tekrar oluşturmaması beklenmektedir [43]. Bu özellikten ötürü farklı bir kullanım alanı olarak verilerin gürültüden ayrıştırılması konusunda da kullanılması düşünülebilir.

En basit oto kodlayıcı yapısı çok katmanlı perceptron mimarisine benzemektedir. Bir oto kodlayıcının içerisinde bir giriş katmanı, bir veya birden fazla gizli katman ve bir çıkış katmanı bulunmaktadır. Giriş ve çıkış katmanlarının boyutları eşit olmak zorundadır. Eğitim yapılırken verilen giriş verilerine karşılık herhangi bir çıkış işareti verilmediğinden ötürü denetimsiz öğrenme metodu olarak değerlendirilmektedir.

Oto kodlayıcılar kendi yapay sinir ağlarının içerisinde iki farklı yapı bulundururlar. Bu yapılar kodlayıcı (encoder) ve çözücü (decoder) isimlerini almaktadırlar. Bu yapıların görevlerini açıklamak gerekirse kodlayıcı kısmında bulunan sinir ağı, giriş verisini çözücünün tekrar oluşturmaya yetecek kadar öğrenmeye izin verecek şekilde boyutunu düşürerek bir öznitelik çıkartılmasını sağlamakla görevlidir. Çözücü kısımda bulunan sinir ağı ise kodlayıcı tarafından çıkartılan özniteliklerin boyutlarının büyütülerek giriş verisini tekrar oluşturmak ile görevlidir. Bu iki yapı arasında kalan öznitelikler birçok farklı uygulamada kullanılmaktadır [44,45,46].

Oto kodlayıcıların birçok çeşidi mevcuttur. Bunlar düzenlenmiş oto kodlayıcılar (regularized autoencoders) ve varyasyonel oto kodlayıcılar (variational autoencoders) olarak iki ana başlıkta incelenebilir [36]. Oto kodlayıcılar, çıktı olarak giriş verisini elde etmeye çalıştıklarından ötürü, her zaman veriyi girişten çıkışa taşımaya çalışan bir kopya düzeneği oluşturmaya çalışırlar. Oto kodlayıcıların kopya çekmesini önlemek adına yapılmış çalışmalar düzenlenmiş oto kodlayıcılar olarak adlandırılmıştır. Bu düzenlenmiş oto kodlayıcılara örnek olarak gürültü azaltıcı oto kodlayıcılar (Denoising autoencoders/DAE) ve kopyasız oto kodlayıcılar (No peaking autoencoders) verilebilirler. Bu modellerde kopya çekilmenin engellenmesi adına farklı yaklaşımlar denenmiş ve başarılı sonuçlara ulaşılmıştır. Düzenlenmiş oto kodlayıcılara son bir örnek olarak seyrek oto kodlayıcılar (sparse autoencoders) verilebilir [25]. Aşağıdaki Şekil 3.1’de basit bir oto kodlayıcı ağ yapısı verilmiştir [59].



Şekil 3.1. Basit bir oto kodlayıcı ağ yapısı

Denetimsiz bir öğrenme algoritması olarak, bir oto kodlayıcı ağ üç katmandan oluşur. Bunlar giriş katmanı, gizli katman ve çıkış katmanıdır [59]. Bir oto kodlayıcı, gizli katmanın en iyi ifadesini çıkarmak için yeniden yapılandırma hatasını en aza indirerek çıkış katmanının değerlerini giriş katmanı değerlerine eşit yapar. Oto kodlayıcı ağ tabanlı veri işleme, kodlama ve kod çözme olarak iki adımdan oluşur.

İlk adımda giriş verisi  $x = [x^{(1)} x^{(2)} \dots x^{(m)}]$  giriş katmanından gizli (ara) katmana ‘kodlanır’ ve  $y$  özellik vektörü elde edilir. Bu işlem denklem 3.1’de verilmiştir.

$$y = f(x) = S(Wx + b) \quad (3.1)$$

Burada  $y = [y^{(1)}y^{(2)} \dots y^{(m)}]^T$  gizli katmanda oluşan kodlanmış özellik değerini temsil etmektedir. Sırası ile  $m$  ve  $n$  giriş ve gizli katmanların düğümlerinin sayısıdır.  $W$  bir ağırlık matrisi ve  $b$  bias vektörüdür.  $S(x)$  ise sigmoid fonksiyonudur ve  $S(x) = 1/(1 + e^{-x})$  değerine sahiptir.

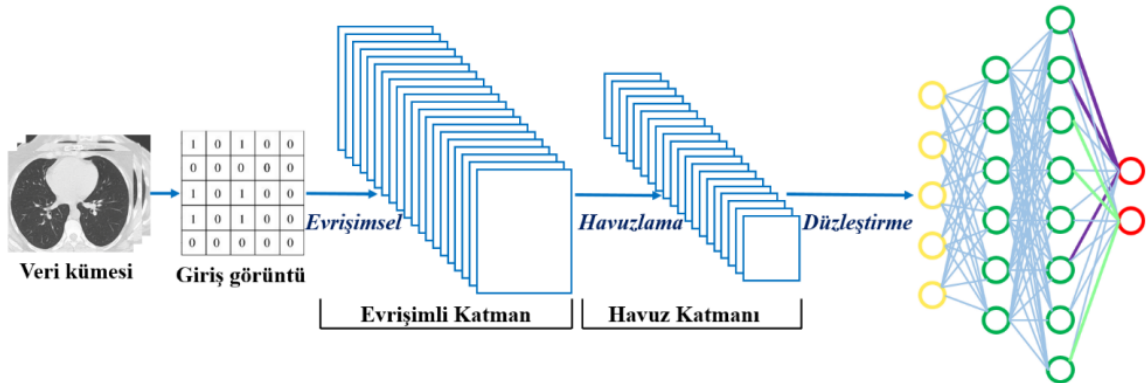
İkinci adım olarak kodlama sonucu gizli katmanda elde edilen  $y$  vektörleri için ‘kod çözme’ işlemi yapılarak çıkış katmanında  $z$  özellik vektörü elde edilir.

$$z = g(x) = S(W^T y + b') \quad (3.2)$$

Burada  $z = [z^{(1)}z^{(2)} \dots z^{(m)}]^T$  kod çözme ile yeniden elde edilen vektördür ve  $b'$  sapma (bias) vektörüdür.

### 3.2. Evrişimli Sinir Ağı


Evrişimli sinir ağı (ESA), görüntüler ve videolar gibi matristen (çok boyutlu dizilerden) oluşan verilerle kullanılmak için ilk olarak 1980'lerin sonunda tanıtılmıştır. Ardından ESA, nesne algılama, tanıma ve sınıflandırma gibi bilgisayarla görme ile ilgili sorunlarda büyük başarı göstermiştir. ESA, özellikleri çıkarmak için çoklu evrişimli katmanların ve havuzlamanın kullanıldığı ve her katmanın çıktısının bir sonraki katmana bağlandığı, yüksek özelliklerin çıkarılması için kullanılan iki ana işlev olan evrişimli katman ve havuzlamadan oluşmaktadır [16]. Çıkarılan üst düzey özellikler DVM ve SoftMax gibi tam bağlantılı katmanlar kullanılarak sınıflandırılır. Evrişimli sinir ağı yapısı Şekil 3.2’de verilmiştir [35].



Şekil 3.2. Evrişimli Sinir Ağı

### 3.2.1. Evrişim Katmanı

Evrişimli sinir ağlarına adını veren evrişim katmanı, sinir bağlantılarının evrişim ile kurulduğu özel bir ileri beslemeli ağ katmanıdır [35]. Bağlantı ağırlıkları evrişim çekirdeği olarak da bilinen bir dizi eğitilebilir filtre ile temsil edilir. Bir evrişim katmanının temel amacı, veri kümesinde ortak olan girdi kümesinin yerel bölgelerindeki öz nitelikleri belirlemek ve bunların görünümünü bir öz niteliğe eşlemektir. Evrişim işlemi sırasında, kayan bir pencere kullanılarak tüm görüntüye uygulanan düzlemdeki her filtre için bir öznitelik haritası elde edilir. Şekil 3.3'te evrişim katmanı için bir örnek verilmiştir.




Şekil 3.3. Evrişim Katmanı Örneği

### 3.2.2. Birleştirme Katmanı

Bir ESA mimarisindeki her evrişim katmanında, önceki katmandan alınan öz nitelik haritaları üzerinde bir evrişim işlemi gerçekleştirilir. Ardı ardına gerçekleştirilen evrişim işlemleri ile ilk katmanlarda nesnelerin küçük bölümlerinden elde edilen öz nitelikler sonraki katmanlarda belirleyici hale gelmektedir. Birleştirme katmanları evrişim katmanı çıktısının boyutlarını azaltmak amacıyla kullanılmaktadır [37]. Birleştirme katmanı kullanılmadan oluşturulan bir evrişimli sinir ağında elde edilen öznitelik sayısı istenmeyen bir şekilde yüksek olabilmektedir. Bu kadar çok sayıda öz nitelik ile yapılacak eğitim, çok yüksek bir hesaplama gücü gerektirdiği gibi eğitimde aşırı uyum sorununa da neden olabilmektedir. Birleştirme katmanının uygulama amacı, uzamsal boyutu ve parametre sayısını azaltmak suretiyle giriş olarak verilen öz nitelik haritasını aşağı örnekmektir. Ayrıca evrişimli sinir ağı mimarisinde birbiri ardına gelen evrişim katmanlarından sonra kullanılan birleştirme katmanı ile öz niteliklerin uzamsal değişmezliği bir dereceye kadar sağlanmaktadır. Birleştirme katmanında ortalama birleştirme, maksimum birleştirme, L2-norm birleştirme gibi birkaç yöntem bulunmakla birlikte, yerel bölgenin baskın olan öz niteliğini ortaya çıkaran maksimum birleştirme uygulamalarda sıklıkla kullanılmaktadır [38]. Bu yöntem hatayı en yüksek yanıtlarla yaymayı sağladığı için özellikle


önemlidir. Çünkü ortalama alma işleminde sıklıkla karşılaşılan gradyenlerin kaybolması riskini önemli ölçüde azaltır.



Şekil 3.4. Birleştirme katmanı örneği

### 3.2.3. Tam Bağlı Katman

Evrişimli sinir ağları temelde öz nitelik çıkarma ve sınıflandırma olmak üzere iki aşamadan oluşmaktadır. Orijinal ve harmanlanmış seviyeler özellik çıkarma adımı olarak hizmet ederken, çıktı katmanı için sınıflandırma işleminde bir veya daha fazla tam bağlı katman bulunur [16]. Katlama ve birleştirme işlemi, yeterli bir öz nitelik seviyesi oluşturulana kadar devam edecektir. Bir sonraki adımda bu öz nitelikleri kullanarak bir sonuç değeri elde etmek için bir sınıflandırma yapılır. Sınıflandırma aşamasında elde edilen öz nitelikler kullanılarak her sınıf için bir olasılık değeri elde edilir. Sınıflandırma sonucunun elde edildiği bu son katmanda ikili sınıflandırma için sigmoid aktivasyon fonksiyonu kullanılırken, çok sınıflı çıkışlar için softmax aktivasyon fonksiyonu kullanılmaktadır. Şekil 3.5'te bir tam bağlı katman yapısındaki bağlantılar gösterilmektedir.




Şekil 3.5. Tam bağlı katman yapısı

### 3.2.4. Transfer Öğrenme Yöntemleri

Transfer öğrenme yöntemi bilgiyi önceden eğitilmiş olan model üzerinden yeni oluşturulan modele aktarma işlemi olarak tanımlanabilir. Transfer öğrenmenin amacı, çok çaba gerektiren modelleri yeniden oluşturmak yerine önceden edinilen bilgiler kullanılıp ve model geliştirme sürecini önemli ölçüde azaltarak model performansını iyileştirmektir. Araştırmacılar tarafından makine öğrenmesi ile çözülmek istenilen karmaşık problemlerin sayısı arttıkça transfer öğrenme yöntemi daha fazla talep edilebilir hale gelmektedir. Transfer öğrenme, ilk görevden edinilen bilgiler sayesinde ikinci görevde hızlı ilerleme ve gelişmiş bir performans sağlamaktadır [13].

#### 3.2.4.1. AlexNet


AlexNet, 2012 yılında yayınlanmıştır ve 2012 ILSVRC'yi kazanan ilk ESA mimarileri arasındadır. Bu mimari, yaklaşık 22.000 kategoride, 7 seviyede ve 60 milyon parametrede 224 x 224 x 3 boyutlarında yaklaşık 15 milyon RGB görüntü verisinden oluşur. Bu ağır mimarisi, LeNet'ten daha derin olması dışında çok benzer. 11x11, 5x5, 3x3 filtreler ve her biri 4096 sinir düğümü ve maksimum 3x3 grubu olan 2 tam bağlantılı katmandan oluşur. Optimizasyon amacıyla, hızı 6 kat artıran tanh aktivasyonu yerine ReLU aktivasyonu daha çok tercih edilir [14]. AlexNet yapısı Şekil 3.6'da gösterilmektedir.



Şekil 3.6. AlexNet yapısı

### 3.2.4.2. Densenet201

ESA'nin geleneksel tanıtımı [25]'te bulunabilir. Bununla birlikte geleneksel ESA'da tüm katmanlar kademeli olarak bağlanır. Bu durum ağı daha derine ve daha geniş bir alana inmesini zorlaştırır. Çünkü gradyen kaybolması sorunuyla karşılaşılabilir. Bu problem için ResNet en az iki katmanı atlayarak kısayol bağlantısını kullanma fikrini sunmuştur. Şekil 3.7'de Densenet yapısı gösterilmektedir [4].



Şekil 3.7. Densenet201 Yapısı

### 3.3. Kullanılan Veri Tabanı

Bu çalışmada Kaggle web sitesinden elde edilmiş ve son yıllarda çok kullanılan MR beyin görüntülerini içeren veri tabanı kullanılmıştır. Ayrıca bu veri tabanı en fazla hastalık türünü içeren veri tabanlarından biridir [34]. Bu veri tabanı Glioma, Meningioma, Pituitary ve tümör olmaması durumları için 4 çeşit sınıftan oluşmaktadır. Çalışmada kullanılan eğitim ve test kümeleri aşağıda verilen Tablo 3.1'deki gibi eğitim ve test kısımlarına ayrılmıştır.

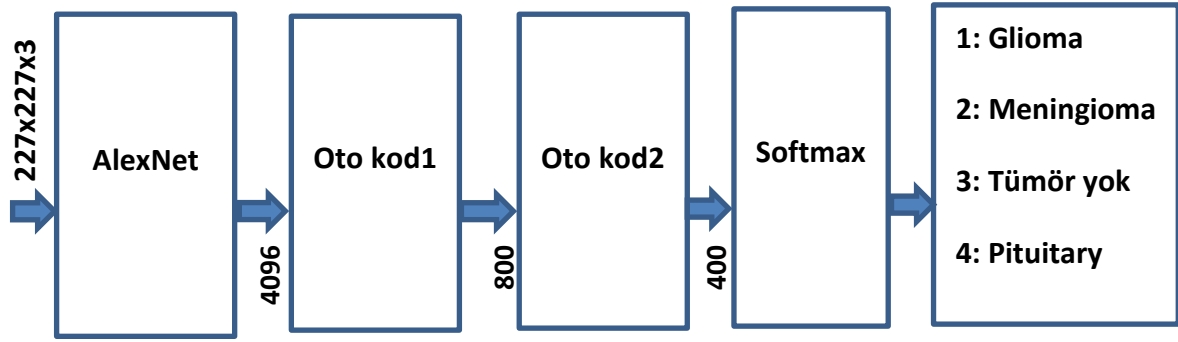
**Tablo 3.1.** Çalışmada kullanılan eğitim ve test kümeleri

Tümör Türü	Eğitim Sayısı	Test Sayısı
Glioma tümör	826	100
Meningioma tümör	822	115
Tümör olmaması	395	105
Pituitary tümör	827	74

### 3.4. Önerilen Sınıflayıcı Algoritmaları

#### 3.4.1. ESA-Oto Kodlayıcı Hibrit Algoritması

Bu çalışmada oto kodlayıcılar ve ESA Metoduna dayalı yeni bir hibrit metot önerilmiştir. Bunun için ilk önce MRI görüntüsü alınır ve ESA Metodu kullanarak MRI görüntüsü analiz edilir. Bu analiz sonucunda önemli olmayan detaylar silinir. Daha sonra derin oto kodlayıcılar kullanarak MRI görüntüsünden daha üst düzey özellikler çıkarılır. Oto kodlayıcı'nın son katmanı olan SoftMax çıkarılan özellikleri sınıflandırmak için kullanılır. Oto kodlayıcılar ve SoftMax birleştirilir ve sınıflandırma sonucuna göre denetimli öğrenme işlemi gerçekleştirilir. Çalışmada kullanılan yöntem aşamaları Şekil 3.8'de verilmiştir.



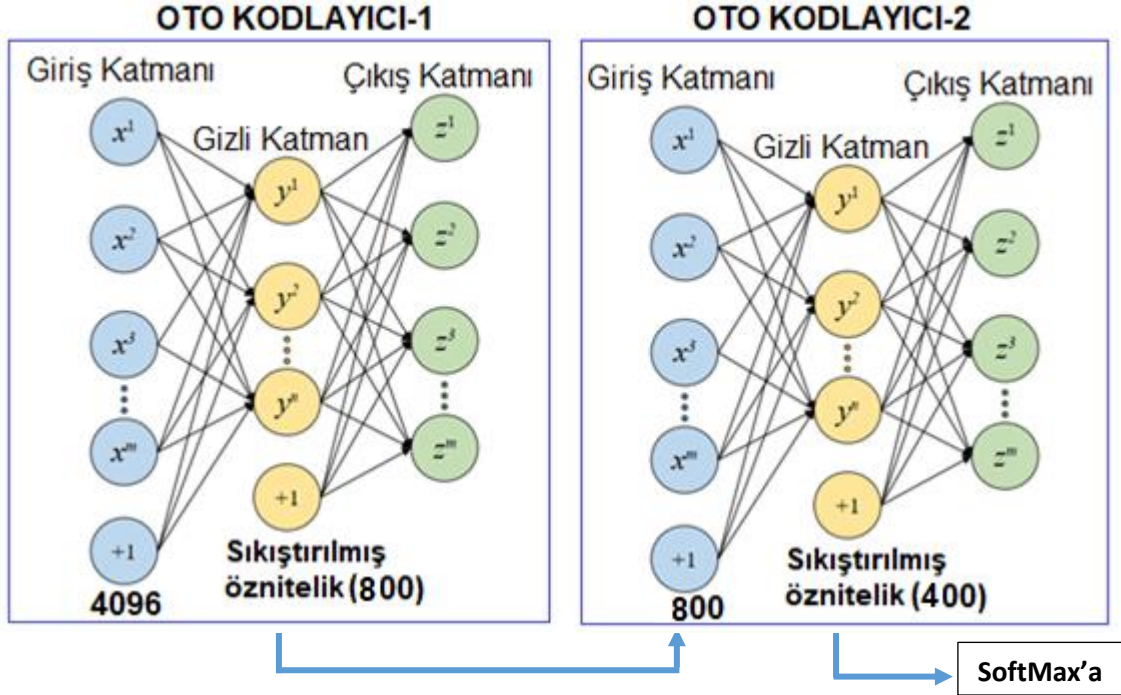
Şekil 3.8. Önerilen metot yapısı

Şekil 3.8'de sırası ile Alexnet, birinci ve ikinci oto kodlayıcılar ve sınıflayıcı katmanı Softmax bulunmaktadır. Şekil 3.8'deki önerilen yapı aşağıda açıklanmıştır.

- Herhangi bir boyuttaki görüntüler, bu çalışmada ön eğitim modeli olarak kullanılan AlexNet'in giriş boyutu olan  $227 \times 227$ 'ye otomatik olarak dönüştürülerek kullanılır.
- Alexnet kullanmanın amacı, iki boyutlu doğrusal olmayan görüntüleri sınıflandırıcılar kullanılarak kolayca sınıflandırılabilen tek adetlik doğrusal öz nitelik vektörüne dönüştürmektir. Sonuç olarak Alexnet çıkışında  $227 \times 227$  boyutlu giriş 4096 boyutlu çıkış vektörüne dönüştürülür. Alexnet'in çıktısı olan bu 4096 boyutlu öz nitelik vektörü, giriş görüntüsünün üst düzey özelliklerini temsil eder. Bu çalışmada, AlexNet'in  $4096 \times 1$  çıkış vektörü derin seyrek oto kodlayıcılara bağlanmıştır.



- Derin seyrek oto kodlayıcılar, özellik çıkarma için kullanılan iki oto kodlayıcıdan ve çıkarılan özellikleri sınıflandırmak için SoftMax'ten oluşur. Bu çalışmadaki asıl önemli konu, Alexnet'in çıkışının ilk oto kodlayıcıya nasıl bağlandığıdır. Bu bağlantı şekli aşağıdaki Şekil 3.9'da verilmiştir.



Şekil 3.9. Kullanılan oto kodlayıcı sinir ağı yapısı

Şekil 3.9'da da görüldüğü gibi oto kodlayıcılar öz nitelik vektörü boyutlarının sayısını kademeli olarak azaltır. İlk oto kodlayıcı Alexnet'ten giriş katmanına gelen 4096 boyutlu öz nitelik vektörü boyutunu 800'e ve ikinci oto kodlayıcı da 400'e düşürür. Öz nitelik vektörü boyutunun nasıl seçileceğine dair bir kural yoktur. Oto kodlayıcılar için boyut probleminden probleme farklı şekilde seçilebildiği için genel olarak özellik vektörü boyutu deneme yanılma teknikleri ile bulunmaktadır. Birden fazla oto kodlayıcı uygulamanın amacı, girdi özelliklerinin tüm bölümlerinin kaybolmadan ve veri kaybetmeden öğrenilmesine yol açan öz nitelik sayısını kademeli olarak azaltarak derin öğrenmenin avantajından yararlanmaktır. Aşağıdaki kodda gösterildiği gibi temsil edilen ilk oto kodlayıcı işlevi matlab koduyla verilmiştir.

```

SparseautoencoderSize1 = 800;
sparseautoencoder1 = trainAutoencoder (featuresTrain...
SparseautoencoderSize1, 'MaxEpochs', 10, ...
'L2WeightRegularization', 0.004, ...
'SparsityRegularization', 4, ...
'SparsityProportion', 0.15, 'ScaleData', false);

```

*sparseautoencoderfeat1 = encode (sparseautoencoder1, featuresTrain);*

- SparseautoencoderSize1'in seçtiğimiz ilk oto kodlayıcının gizli katmanını temsil ettiği değer 800'dir. Oto kodlayıcının eğitiminde kullanılan döngülerin sayısını ise *maxEpochs* temsil eder. *L2WeightRegularization*, ağırlıklar için bir L2 düzenleyicisinin değeridir, ancak sapma değerini (bias) kontrol etmez. *SparsityRegularization*, seyreklik düzenleyici etkisini kontrol eder. Ayrıca, Seyreklik Oranı (*SparsityProportion*), seyreklik düzenleyici bir parametre olarak seyreklik oranını kontrol eder. Oto kodlayıcıların etkin bir şekilde çalıştığı aralık olan [0,1] arasındaki verileri normalleştirmek için *ScaleData* kullanılır.
- Aşağıda ikinci oto kodlayıcı için matlab kodu verilmiştir.

```
SparseautoencoderSize2 = 400;  
sparseautoencoder2 = trainAutoencoder (sparseautoencoderfeat1,  
SparseautoencoderSize2, ... 'MaxEpochs',10,  
'L2WeightRegularization',0.002, ...  
'SparsityRegularization',4, 'SparsityProportion',0.1, 'ScaleData', false);  
sparseautoencoderfeat2 = encode (sparseautoencoder2, sparseautoencoderfeat1);
```

Çıkarılan özellikler SoftMax tarafından sınıflandırılır. SoftMax fonksiyonunun matematiksel modeli aşağıda sunulmuştur, burada SoftMax'e girdi olarak gelen  $800 \times 1$  boyutlu vektör  $x$  ile temsil edilir. Deklem 3.3'de  $y$  etiketi (label) temsil ederken, modüle giren  $x$  vektörünün indisi  $i$  ( $i = 1, 2, \dots, k$ ) ile temsil edilir. Ayrıca  $k$  örnek sayısını temsil eder.

$$\text{SoftMax}(y) = \frac{e^{x_i}}{\sum_{k=1}^k e^{x_k}} \quad (3.3)$$

SoftMax, giriş özelliklerini sırası ile beyin tümörü ve tümör olmayan durum olarak "0001", "0010", "0100" ve "1000" ile temsil ederek sınıflandırır. Beyin tümörlerinin 0 ve 1'e kodlanması, SoftMax'ın sadece 0 ve 1 ile kullanabilmesinden dolayıdır. Aşağıda Softmax'ın sınıflama için kullandığı kod verilmiştir.

```
softmaxnet = trainSoftmaxLayer (sparseautoencoderfeat2, YTrain, 'MaxEpochs',10)
```

Eğitim aşamasında doğrulama (validation) doğruluğunun en yüksek olduğu değerler için döngü sayısı belirlenmelidir.

### 3.4.2. ESA-Karar Ağaçları Algoritması

Karar ağaçları çok eski ve ünlü sınıflandırıcı tekniklerinden biridir. Ancak bazı dezavantajlara sahiptir. Bu dezavantajlar aşağıdaki gibidir.

- Verilerdeki küçük bir değişiklik, karar ağacının yapısında büyük bir değişikliğe neden olarak kararsızlığa neden olabilir.
- Bir Karar ağacı için bazen hesaplama, diğer algoritmalara kıyasla çok daha karmaşık olabilir.
- Karar ağacı genellikle modeli eğitmek için daha fazla zaman gerektirir.
- Karar ağacı eğitimi, karmaşıklığı ve aldığı zaman daha fazla olduğu için nispeten pahalıdır.

Bu çalışmada ESA ile çıkarılan 4096 öz nitelik vektörü karar ağaçları ile sınıflandırılmıştır. Böylece hibrit ESA-Karar Ağacı algoritması uygulanmıştır. Aşağıdaki kod, Karar Ağacının test işlemini yapmasını sağlamaktadır.

```
treeMd = fitctree(xTrain,YTrain);  
treePredicate = predict(treeMd,xTest);  
plotconfusion(YTest,treePredicate)
```

fitctree MATLAB'ta ESA-Karar Ağacı sınıflandırıcısını oluşturmak için kullanılan bir işlevdir. xTrain ESA ile çıkarılan özellikler ve YTrain özelliklerin etiketleridir.

### 3.4.3. ESA-Destek Vektör Makinesi Algoritması

DVM farklı alanlarda sınıflandırma ve regresyon problemlerinde kullanılan çok verimli bir denetimli öğrenme tekniğidir. Bu çalışmada ESA ile çıkarılan 4096 öz nitelik vektörleri ESA-Destek Vektör Makinesi ile kullanılarak sınıflandırılmıştır. Destek Vektör Makinesi için test aşamasındaki sınıflama işlemi aşağıdaki MATLAB fonksiyonu ile sağlanmaktadır.

```
svmMd = fitcecoc(xTrain,YTrain);  
svmPredicate = predict(svmMd,xTest);  
plotconfusion(YTest,svmPredicate)
```

fitcecoc fonksiyonu ile Destek Vektör Makinesi sınıflandırma fonksiyonu oluşturulmuştur.

### 3.4.4. ESA-K En Yakın Komşu Algoritması

Bu çalışmada ESA ile çıkarılan 4096 boyutlu öz nitelik vektörleri K-en yakın komşu algoritması ile sınıflandırılmıştır. Böylece hibrit ESA-KNN algoritması uygulanmış olmaktadır. Bu hibrit algoritmayı uygulamak için MATLAB ortamında aşağıdaki kodlar kullanılmıştır.

```
knnMd = fitcknn(xTrain,YTrain);  
knnPredicate = predict(knnMd,xTest);
```

fitcknn fonksiyonu K-en yakın komşu algoritmasının MATLAB ortamında uygulamasını sağlar.

## 4. SONUÇLAR

### 4.1. Doğrulama Tekniği (Validation Technique)

Veri, makine öğreniminin devam etmesini sağlayan destektir. Bir makine öğrenimi ve derin öğrenme modeli ne kadar güçlü olursa olsun kötü verilerle asla istenileni yapamaz. Rastgele gürültü bir modelin bozulmasına sebep olabilir. Doğrulama süreci neyin yanlış olduğunu doğrudan bulamasa da süreç bize bazen modelin kararlılığında bir sorun olduğunu gösterebilir.

Verileri doğrulamanın en temel yöntemi veriler üzerinde bir eğitim/doğrulama/test işlemlerinin gerçekleştirilmesiyle oluşur. Bunun için tipik bir oran 80/20 olabilir. Modeli eğitim seti ile eğittikten sonra, kullanıcı tatmin edici bir performans metriğine ulaşana kadar sonuçları doğrulamaya ve doğrulama kümesi ile parametreleri ayarlamaya geçmelidir. Bu aşama tamamlandığında, kullanıcı performansını tahmin etmek ve değerlendirmek için test seti ile modeli test eder.

Monte Carlo çapraz doğrulama olarak da bilinen rastgele alt örnekleme, verilerin rastgele alt kümelerle bölünmesine dayanır. Bu sayede alt kümelerin boyutu kullanıcı tarafından tanımlanır. Verilerin rastgele bölünmesi, keyfi olarak sık sık tekrarlanabilir. Son olarak yapılan test sayıları doğrulamaları toplanır ve toplam test sayısına bölünür. Bu sayede aşırı öğrenme (overfitting) sıkıntısını ortadan kaldırmış olur.

### 4.2. Karışıklık matrisi (Confusion Matrix)

Bir karışıklık matrisi, bir sınıflandırma modelinin performansını değerlendirmek için kullanılan bir  $N \times N$  boyutlu matristir. Burada  $N$  sınıf sayısıdır. Bu matris ile gerçek hedef değerleri ile makine öğrenimi modeli tarafından tahmin edilen değerler karşılaştırılır. Böylece sınıflandırma

modelinin ne kadar iyi çalıştığına ve hangi hataları yaptığına dair bütünsel bir genel bakış sunar. Karmaşıklık matrisinde birden fazla parametre bulunmaktadır. Açıklamaları aşağıda verilmiştir.

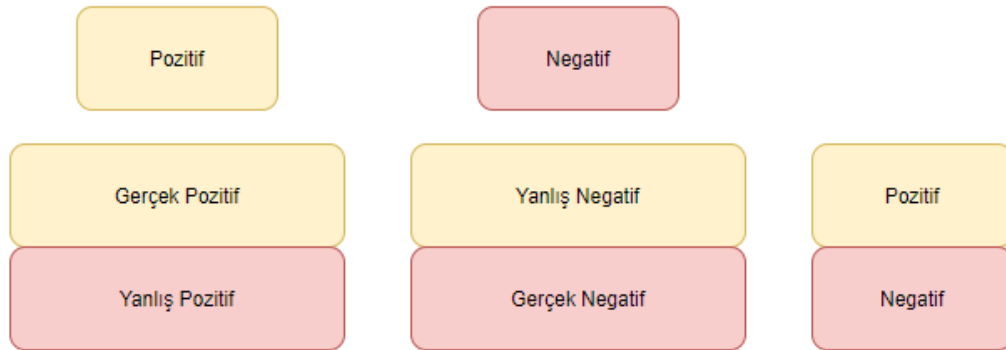
Gerçek Pozitif (TP): Tahmin edilen değer, gerçek değerle eşleşir. Gerçek değer pozitif ve model pozitif bir değer öngördü şeklinde yorumlanır.

Gerçek Negatif (TN): Tahmin edilen değer, gerçek değerle eşleşir. Gerçek değer negatif ve model negatif bir değer öngördü şeklinde yorumlanır.

Yanlış Pozitif (FP): Tahmin edilen değer yanlış tahmin edildi. Gerçek değer negatif ancak model pozitif bir değer öngördü şeklinde yorumlanır.

Yanlış Negatif (FN): Tahmin edilen değer yanlış tahmin edildi. Gerçek değer pozitif ancak model negatif bir değer öngördü şeklinde yorumlanır.

Yukarıdaki parametreleri kullanarak birden fazla kriter hesaplanır ve bu kriterler modelin performansını gösterir. Bunların başında doğruluk (accuracy) kriteri gelir, doğru sınıflandırılmış değerlerin sayısının toplanması ve toplam değer sayısına bölünmesiyle hesaplanır. Sınıflandırma problemlerinde doğruluk kullanılan en önemli kriterlerden biridir. Bu nedenle çalışmada karşılaştırma için doğruluk değeri kullanılmıştır.



**Şekil 4.1.** Karmaşıklık Matrisi

Doğruluk (ACC), Denklem 4.1'de verildiği gibi temsil edilir.

$$\text{Doğruluk (Acc)} = \frac{(TP + TN)}{(P + N)} = \frac{(TP + TN)}{(TP + TN + FP + FN)} \quad (4.1)$$

TP gerçek pozitif, TN gerçek negatif, P koşul pozitif, N koşul negatif, FP yanlış pozitif ve FN yanlış negatif gösterir. Ayrıca Duyarlılık (TPR), doğru olarak tanınan pozitiflerin yüzdesini hesaplar. Ölçülen Duyarlılık Denklem 4.2'de verildiği gibidir.

$$\text{Duyarlılık (TPR)} = \frac{TP}{(TP + FN)} \quad (4.2)$$

Ayrıca, Özgüllük (SPC), doğru olarak tanınan negatiflerin yüzdesini hesaplar. Ölçülen Özgüllük Denklem 4.3'te gösterildiği gibidir.

$$\text{Özgüllük (SPC)} = \frac{TN}{(FP + TN)} \quad (4.3)$$

Derin öğrenme teknikleri ile geliştirilen uygulama aşağıda belirtilen kısımlarda test edilmiştir. Bu çalışmada kullanılan tümör verileri 4 sınıfta toplanır. Bunlar Glioma, Meningioma, Pituitary tümörlerini ve Tümör olmaması durumlarını kapsamaktadır. Veri kümesi eğitim ve test gruplarına ayrılmıştır. Önce önerilen yöntem için eğitim gerçekleştirilmiştir ve sonra test işlemi yapılmıştır. Çalışmada sınıflama için ESA ile hibrit oluşturulan ESA-K en Yakın Komşu, ESA-Karar Ağaçları, ESA-Destek Vektör Makineleri ve ESA- Oto kodlayıcı kullanılır.

### 4.3 Kullanılan Hibrit Algoritmaların Sonuçları

Çalışmada kullanılan hibrit algoritmalar için yapılan çalışmaların ortalama doğruluk sonuçları aşağıdaki bölümlerde verilmiştir. Her hibrit algoritma için en yüksek doğrulukları veren sonuçlar, kullanılan parametreler ile bu bölümlerde verilmiştir.

#### 4.3.1 ESA-Karar Ağaçları Sonuçları

ESA-Karar Ağacı algoritması ile yapılan çalışmalarda Karar Ağaçları kullanılarak elde edilen sonuçlar şekil 4.2'de sunulmuştur. Çalışmada ESA-Karar Ağacı algoritması ile doğruluk değeri %75,9 elde edilmiştir. Elde edilen sonuçlar incelendiğinde düşük doğruluk değeri elde edilmiştir.

#### 4.3.2 ESA-Destek Vektör Makinaları (DVM) Sonuçları

ESA-Destek Vektör Makinesi algoritması ile yapılan çalışmalarda elde edilen sonuçlar şekil 4.3'te verilmiştir. DVM ile elde edilen Doğruluk değeri gauss çekirdek işlevi kullanılarak


%76,9 bulunmuştur ve polinom çekirdeği ile %77,2 elde edilmiştir. Bu doğruluk oranları da çok düşük değerlerdir. Yaklaşık her dört MR görüntüsünden birinde hata yapılması demektir.

#### 4.3.3. ESA-K En Yakın Komşu (ESA-KNN) Sonuçları

Bu bölümde K-en yakın komşu algoritması ile elde edilen sonuçlar üç farklı senaryoda test edilmiştir. Deneysel çalışmalarda en yüksek doğruluk %79,4 değeri K=3 komşuluk için bulunmuştur. ESA-KNN algoritmasının doğruluk sonucu, ESA-Karar ağaçları ve ESA-DVM algoritmalarına göre daha iyi sonuçlar vermiştir. Ayrıca, K=5 için doğruluk %78,7 ve K=7 için %78,1 bulunmuştur.


#### 4.3.4. ESA- Oto Kodlayıcı Algoritma Sonuçları

Oto kodlayıcı ile elde edilen sonuçlar detaylı olarak aşağıda verilmiştir. ESA kullanılarak elde edilen öz nitelikler ilk oto kodlayıcıya girdi olarak verilir. İlk oto kodlayıcı şekil 4.2’teki gibi verinin boyutunu 4096’ dan 800 indirir.



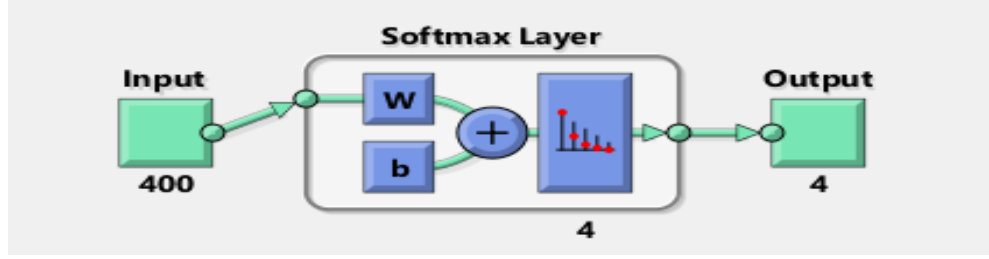
Şekil 4.2. Birinci Oto Kodlayıcı

Birinci oto kodlayıcı ile elde edilen özellikler gizli katmandan ikinci oto kodlayıcıya iletilir. İlk oto kodlayıcıdan 800 özellik elde edilmiştir. Bu özellikler ikinci oto kodlayıcı ile 400 özelliğe indirilir. İkinci oto kodlayıcının yapısı şekil 4.3 da gösterilmiştir.



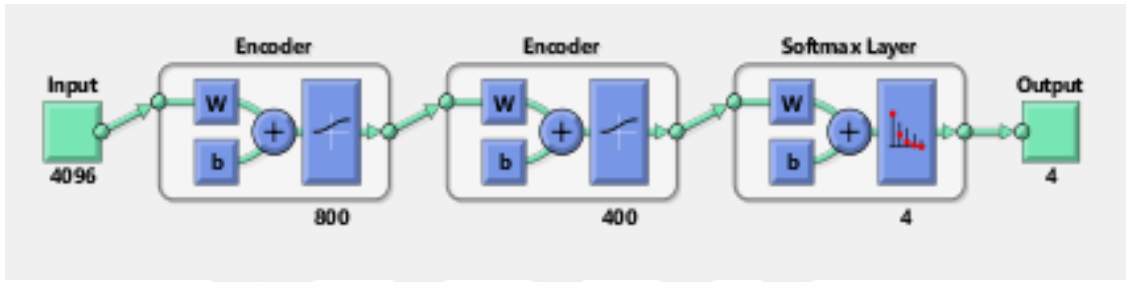
Şekil 4.3. İkinci Oto Kodlayıcı

Elde edilen 400 öz nitelik SoftMax kullanarak sınıflandırılır. Bu kısımda SoftMax denetimli öğrenme tekniği olarak çalışır ve daha önceki adımda oto kodlayıcı ile çıkarılan özellikleri sınıflandırır. SoftMax’ın yapısı Şekil 4.4’te sunulmuştur.



Şekil 4.4. SoftMax Yapısı

Son adımda iki oto kodlayıcı ve SoftMax birleştirilir ve eğitim gerçekleştirilir. Oluşturulan bu yapı şekil 4.5’te verilmiştir.



Şekil 4.5. İki Oto Kodlayıcı ve SoftMax Birleştirilmiş Yapısı

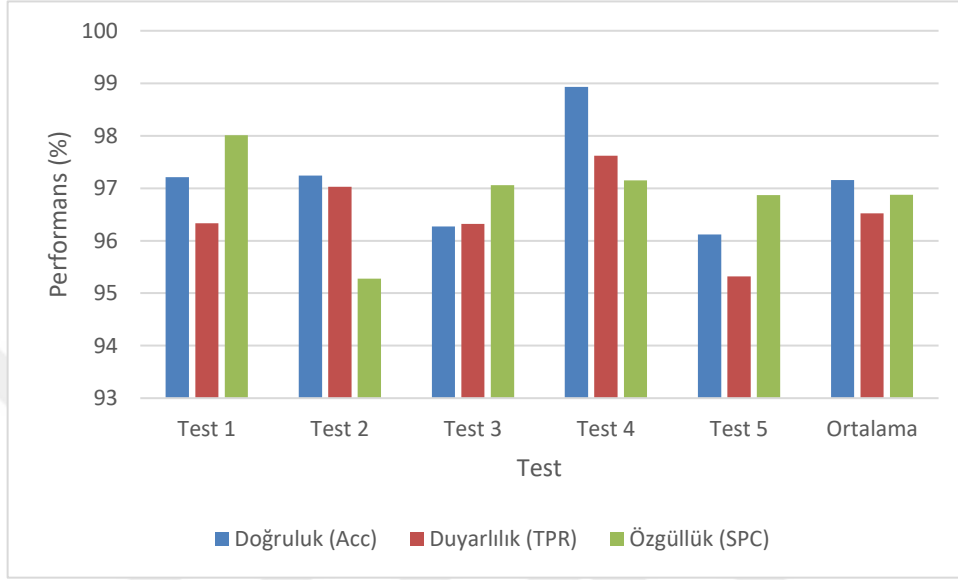
ESA- Oto Kodlayıcı algoritması kullanılarak bulunan doğruluk sonuçları aşağıdaki Şekil 4.6’da verilmiştir.

		Confusion Matrix					
Output Class		Glioma	Meningioma	Tümör yok	Pituitary		
		Glioma	74 18.8%	0 0.0%	0 0.0%	3 0.8%	96.1% 3.9%
Meningioma	0 0.0%	105 26.6%	0 0.0%	1 0.3%	99.1% 0.9%		
Tümör yok	0 0.0%	0 0.0%	115 29.2%	9 2.3%	92.7% 7.3%		
Pituitary	0 0.0%	0 0.0%	0 0.0%	87 22.1%	100% 0.0%		
		100% 0.0%	100% 0.0%	100% 0.0%	87.0% 13.0%	97.7% 3.3%	
		Glioma	Meningioma	Tümör yok	Pituitary		
		Target Class					

Şekil 4.6. ESA-Oto kodlayıcı ile elde edilen doğruluk sonuçları



Ayrıca rastgele çapraz geçirme ile 5 adet test ve eğitim kümesi oluşturulmuş ve 5 test işlemi yapılmıştır. Test ile üç farklı parametre hesaplanmıştır. Bunlar deneysel çalışmalarda ortalama Doğruluk (Acc), Duyarlılık (TPR), Özgüllük (SPC) değerleri olarak sırası ile 97.7 %, 96.524%, 96.874% elde edilmiştir.



Şekil 4.7. Rastgele çapraz geçirme test sonuçları

Ayrıca önerilen ESA- Oto Kodlayıcı algoritması doğruluk oranı önceden yapılmış çalışmalar ile karşılaştırılmıştır. Bu karşılaştırma Tablo 4.1’de beyin tümörü tespiti ile ilgili güncel olan çalışmaları içermektedir.

Tablo 4.1. Karşılaştırma Tablosu

Kaynak	Sene	Yöntem	Sınıflandırma Şekli	Veri Seti	Accuracy (%)
Ghassemi et al [26]	2020	GAN + ConvNet (rastgele bölme)	Glioma, meningioma and pituitary	Kaggle [34]	95.6%

Hashemzahi et al [27]	2019	hibrit ESA-NADE	Glioma, meningioma and pituitary	Kaggle [34]	95%
Singh et al [28]	2020	C-Ortalama +DVM	Glioma, meningioma and pituitary	Kaggle [34]	91.24%
Sultan et al [55]	2019	ESA	Glioma, meningioma and pituitary	Kaggle [34]	96.13%
Kabir Anaraki [56]	2019	ESA + Genetik algoritma	Glioma, meningioma and pituitary	Kaggle [34]	94.2%
Sajjad et al. [57]	2019	ESA	Glioma, meningioma and pituitary classification	Kaggle [34]	94.58 %
Cheng et al. [58]	2015	GLCM	Glioma, meningioma and pituitary classification	Kaggle [34]	91.43%
Önerilen yöntem	2021	ESA+Oto-kodlayıcılar	Glioma, meningioma, pituitary, ve Normal Classification	Kaggle [34]	97.7%

Tablo 4.1 de önceden yapılan çalışmalar ile bu çalışmanın arasında karşılaştırma yapılmıştır. [26]'da Önerilen yöntem, beyin simetri analiz yöntemine ve bölge tabanlı ve sınır tabanlı bölütleme yöntemlerini birleştiren bir hibrit yaklaşıma dayanmaktadır. Segmentasyon süreci üç ana aşamadan oluşmaktadır. İlkinde, herhangi bir gürültüyü gidermek ve beyni kafa görüntüsünden çıkarmak için görüntüye ön işleme uygulanır. Bu çalışmada kullanılan yöntem %95,6 doğruluk elde etmiştir.

[27]'de Önerilen sistemde, ilk önce kendi kendini organize eden harita sinir ağı (self-organising map neural network), ayırık dalgacık dönüşümü karışım dalgacıklarından çıkarılan öznelikleri analiz eder ve sonuçta ortaya çıkan özellikleri, K-en yakın komşu tarafından eğitilir ve test süreci de iki aşamada gerçekleştirilir. Önerilen yöntem %95 doğruluk elde etmiştir.

[28]'de önerilen yöntem, destek vektör makinesi (DVM) ve beyin tümörünün tahmini için hibrit bir teknik olan bulanık c-ortalamaların (fuzzy c-means) bir kombinasyonudur. Bulanık c-ortalamalar kümelemesi, beyin MRG görüntüsündeki şüpheli bölgeyi tespit etmek için görüntünün segmentasyonu için kullanılır. Sonra, DVM sınıflandırmak için kullanılır. Önerilen yöntem %91,24 doğruluk elde etmiştir.

[55]'de, herkesin kullanabileceği iki veri kümesi kullanılarak farklı beyin tümörü tiplerini sınıflandırmak için evrişimli bir sinir ağına dayalı tümörleri (meningiom, glioma ve hipofiz tümörü) olarak sınıflandıran bir model önerilmiştir. Önerilen ağ yapısı %96,13 doğrulukla değerine ulaşmıştır.

[56]'da önerilen yöntemde, CNN'nin mimarisi (yapısı), genellikle deneme yanılmaya dayalı veya önceden tanımlanmış ortak yapıları benimseyen mevcut bir derin sinir ağı mimarisi seçme yöntemlerinden farklı olarak GA kullanılarak geliştirilmiştir. Ayrıca tahmin hatasının varyansını azaltmak için GA tarafından geliştirilen en iyi model üzerinde bir kümeleme algoritması kullanılır. Sınıflandırmada %90,9 doğruluk elde edilmiştir.

[57]'de yeni bir ESA tabanlı çok dereceli beyin tümörü sınıflandırma sistemi önerilmiştir. İlk olarak bir MR görüntüsündeki tümör bölgeleri derin öğrenme tekniği kullanılarak bölümlere ayrılır. İkinci olarak önerilen sistemi etkili bir şekilde eğitmek için kapsamlı veri büyütme kullanılır ve beyin tümörü sınıflandırması için veri eksikliği probleminden kaçınılır. Son olarak, önceden eğitilmiş bir ESA modeli beyin tümörü sınıf sınıflandırması için artırılmış veriler kullanır. Önerilen yöntem ile 94.58 % doğruluk elde edilmiştir.

[58]'de sınıflandırma performansını artırmak için bir yöntem önerilmiştir. İlk olarak, orijinal tümör bölgesi yerine ROI ile görüntü genişletme gerçekleştirilip büyütülmüş tümör bölgesi kullanılmaktadır. Çünkü tümör çevresindeki dokular da tümör tipleri için önemli ipuçları sunabilir. İkincisi, artırılmış tümör bölgesi giderek daha ince halka şeklindeki alt bölgelere bölünür. Önerilen yöntem 97.15 % doğruluk oranı göstermiştir.

Bu çalışmada ise ESA temelli 4 adet hibrit sınıflandırıcı algoritması önerilmiştir. İlk aşamada ESA ile 4096 öz nitelik katsayıları çıkarılmıştır. Bu öz nitelikler genellikle birçok çalışmada yüksek doğruluk oranı sunar. Bu çalışmada, ESA tek başına yetersiz kalmıştır ve ESA ile çıkarılan özellikler sınıflandırma aşamasında 80% altında sonuçlar göstermiştir. Elde edilen sonuçlar ESA-karar ağaçları ile %75,9, ESA-DVM ile %76,9 ve ESA-K en yakın komşu ile %79,4 sonuçlar elde edilmiştir. Bu doğruluk oranlarına göre bu 3 hibrit algoritmayı sağlık alanında kullanmak için çok yetersizdir. Son olarak, ESA-oto kodlayıcı algoritması ile %97,7 doğruluk değerine ulaşılmıştır. Bu sonuç için ilk oto kodlayıcıdan 800 ve ikinci oto kodlayıcıdan 400 öz nitelik çıkarılmıştır. SoftMax ile bu çıkarılan yüksek seviyeli 400 özellik ile sınıflandırma işlemi yapılmıştır ve elde edilen doğruluk %97,7 olmuştur.

## KAYNAKLAR

- [1]. Ari, A., Hanbay, D., 2019, Tumor detection in MR images of regional convolutional neural networks, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 3, 1395-1408.
- [2]. Nabizadeh, N., & Kubat, M., 2015, Brain tumors detection and segmentation in MR images: Gabor wavelet vs statistical features, *Computers & Electrical Engineering*, 45, 286–301.
- [3]. Mousavi, S.M., Naghsh, A., Abu-Bakar, S.A.R., 2015, A heuristic automatic and robust ROI detection method for medical image watermarking, *Journal of Digital Imaging*, 28 (4), 417–427.
- [4]. Kurat, N., Ozkaya N., 2014, Automatically extracting brain tumor from MR image, *Signal Processing and Communications Applications Conference (SIU) on IEEE*, 22nd. IEEE, 1532-1535. DOI: 10.1109/SIU.2014.6830533.
- [5]. Gajanayake, G. M. N. R., Roshan Dharshana Yapa, B. Hewawithana., 2009, Comparison of standard image segmentation methods for segmentation of brain tumors from 2D MR images. *Industrial and Information Systems (ICIIS), 2009 International Conference on. IEEE*. DOI: 0.1109/ICIINFS.2009.5429848.
- [6]. Gurbină, M., Lascu, M., & Lascu, D., 2019, Tumor detection and classification of MRI brain image using different wavelet transforms and support vector machines. In *2019 42nd International Conference on Telecommunications and Signal Processing (TSP)* (pp. 505-508). IEEE.
- [7]. Jemimma, T. A., & Vetharaj, Y. J., 2018, Watershed algorithm based DAPP features for brain tumor segmentation and classification. In *2018 International Conference on Smart Systems and Inventive Technology (ICSSIT)* (pp. 155-158). IEEE.
- [8]. Zaw, H. T., Maneerat, N., & Win, K. Y., 2019, Brain tumor detection based on Naïve Bayes Classification. In *2019 5th International Conference on Engineering, Applied Sciences and Technology (ICEAST)* (pp. 1-4). IEEE.
- [9]. Baranwal, S. K., Jaiswal, K., Vaibhav, K., Kumar, A., & Srikantaswamy, R., 2020, Performance analysis of Brain Tumour Image Classification using CNN and SVM. In *2020*

Second International Conference on Inventive Research in Computing Applications (ICIRCA) (pp. 537-542). IEEE.

[10]. Kumar, A., Ashok, A., & Ansari, M. A., 2018, Brain tumor classification using hybrid model of PSO and SVM classifier. In 2018 International Conference on Advances in Computing, Communication Control and Networking (ICACCCN) (pp. 1022-1026). IEEE.

[11]. Li, Z., 2020, Analysis on the Influence of Artificial Intelligence Development on Accounting. In 2020 International Conference on Big Data, Artificial Intelligence and Internet of Things Engineering (ICBAIE) (pp. 260-262). IEEE.

[12]. Abhivardhan, 2020, The Perspective of Dimensional Perpetuity for Artificial Intelligence: A Model on Socio-Legal and Political Evolution as a Challenge to Entrepreneurial Ethics, 2nd World Symposium on Artificial Intelligence (WSAI), Guangzhou, China, pp. 69-72.

[13]. Zhang, B., 2010, Computer vision vs. human vision. In 9th IEEE International Conference on Cognitive Informatics (ICCI'10) (pp. 3-3). IEEE.

[14]. Álvarez-Valera, H. H., Bolivar-Vilca, E., Cervantes-Jilaja, C., Cuadros-Zegarra, E. E., Barrios-Aranibar, D., & Patiño-Escarcina, R., 2014, Automation of chestnuts selection process using computer vision in real time. In 2014 33rd International Conference of the Chilean Computer Science Society (SCCC) (pp. 87-91). IEEE.

[15]. Li, N., Zhao, L., Chen, A. X., Meng, Q. W., & Zhang, G. F., 2009, A new heuristic of the decision tree induction. In 2009 International Conference on Machine Learning and Cybernetics (Vol. 3, pp. 1659-1664). IEEE.

[16]. Tan, Y., & Zhang, G. J., 2005, The application of machine learning algorithm in underwriting process. In 2005 international conference on machine learning and cybernetics (Vol. 6, pp. 3523-3527). IEEE.

[17]. Yu, J., Gwak, J., Lee, S., & Jeon, M., 2015, An incremental learning approach for restricted boltzmann machines. In 2015 International Conference on Control, Automation and Information Sciences (ICCAIS) (pp. 113-117). IEEE.

[18]. Guo, H. S., Wang, W. J., & Men, C. Q., 2009, A novel learning model-kernel granular support vector machine. In 2009 International Conference on Machine Learning and Cybernetics (Vol. 2, pp. 930-935). IEEE.

- [19]. Pahwa, K., & Agarwal, N., 2019, Stock market analysis using supervised machine learning. In 2019 International Conference on Machine Learning, Big Data, Cloud and Parallel Computing (COMITCon) (pp. 197-200). IEEE.
- [20]. Zhan, Y., Chen, H., Zhang, S. F., & Zheng, M., 2009, Chinese text categorization study based on feature weight learning. In 2009 international conference on machine learning and cybernetics (Vol. 3, pp. 1723-1726). IEEE.
- [21]. Karatekin, T., Sancak, S., Celik, G., Topcuoglu, S., Karatekin, G., Kirci, P., & Okatan, A., 2019, Interpretable machine learning in healthcare through generalized additive model with pairwise interactions (GA2M): Predicting severe retinopathy of prematurity. In 2019 International Conference on Deep Learning and Machine Learning in Emerging Applications (Deep-ML) (pp. 61-66). IEEE.
- [22]. Huang, C. J., Liu, M. C., Chu, S. S., & Cheng, C. L., 2004, Application of machine learning techniques to Web-based intelligent learning diagnosis system. In Fourth International Conference on Hybrid Intelligent Systems (HIS'04) (pp. 242-247). IEEE.
- [23]. Meena, G., Sharma, D., & Mahrishi, M., 2020, Traffic Prediction for Intelligent Transportation System using Machine Learning. In 2020 3rd International Conference on Emerging Technologies in Computer Engineering: Machine Learning and Internet of Things (ICETCE) (pp. 145-148). IEEE.
- [24]. Cunhe, L., & Chenggang, W., 2010, A new semi-supervised support vector machine learning algorithm based on active learning. In 2010 2nd International Conference on Future Computer and Communication (Vol. 3, pp. V3-638). IEEE.
- [25]. Zhang, J., 2011, Deep transfer learning via restricted boltzmann machine for document classification. In 2011 10th International Conference on Machine Learning and Applications and Workshops (Vol. 1, pp. 323-326). IEEE.
- [26]. Kermi, A., Andjouh, K., & Zidane, F., 2018, Fully automated brain tumour segmentation system in 3D-MRI using symmetry analysis of brain and level sets. IET Image Processing, 12(11), 1964-1971.
- [27]. Anitha, V., & Murugavalli, S., 2016, Brain tumour classification using two-tier classifier with adaptive segmentation technique. IET computer vision, 10(1), 9-17.

- [28]. Singh, A., 2015, Detection of brain tumor in MRI images, using combination of fuzzy c-means and SVM. In 2015 2nd International Conference on Signal Processing and Integrated Networks (SPIN) (pp. 98-102). IEEE.
- [29]. Ravì, D., Fabelo, H., Callic, G. M., & Yang, G. Z., 2017, Manifold embedding and semantic segmentation for intraoperative guidance with hyperspectral brain imaging. *IEEE transactions on medical imaging*, 36(9), 1845-1857.
- [30]. Sallemi, L., Njeh, I., & Lehericy, S., 2015, Towards a computer aided prognosis for brain glioblastomas tumor growth estimation. *IEEE transactions on nanobioscience*, 14(7), 727-733.
- [12]. Mukambika, P. S., & Uma Rani, K., 2017, Segmentation and classification of MRI brain tumor. *Int. Res. J. Eng. Technol. (IRJET)*, 4(07), 683-688.
- [31]. Sudharani, K., Sarma, T. C., & Rasad, K. S., 2015, Intelligent Brain Tumor lesion classification and identification from MRI images using k-NN technique. In 2015 International Conference on Control, Instrumentation, Communication and Computational Technologies (ICCICCT) (pp. 777-780). IEEE.
- [32]. Ahmmed, R., Swakshar, A. S., Hossain, M. F., & Rafiq, M. A., 2017, Classification of tumors and it stages in brain MRI using support vector machine and artificial neural network. In 2017 International Conference on Electrical, Computer and Communication Engineering (ECCE) (pp. 229-234). IEEE.
- [33]. Machhale, K., Nandpuru, H. B., Kapur, V., & Kosta, L., 2015, MRI brain cancer classification using hybrid classifier (SVM-KNN). In 2015 International Conference on Industrial Instrumentation and Control (ICIC) (pp. 60-65). IEEE.
- [34]. Bhuvaji, S., Kadam, A., Bhumkar, P., Dedge, S., & Kanchan, S., 2020, Brain tumor classification (mri). Kaggle, doi, 10.
- [35]. Özbay, E., & Özbay, F. A., 2021, Derin Öğrenme ve Sınıflandırma Yaklaşımları ile BT görüntülerinden Covid-19 Tespiti. *Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi*, 12(2), 211-219.
- [36]. Karim, A. M., Güzel, M. S., Tolun, M. R., Kaya, H., & Celebi, F. V., 2019, A new framework using deep auto-encoder and energy spectral density for medical waveform data classification and processing. *Biocybernetics and Biomedical Engineering*, 39(1), 148-159.



- [37]. Vives-Boix, V., & Ruiz-Fernandez, D., 2021, Synaptic metaplasticity for image processing enhancement in convolutional neural networks. *Neurocomputing*, 462, 534-543.
- [38]. Chen, Y., Yi, H., Liao, C., Huang, P., & Chen, Q., 2021, Visual measurement of milling surface roughness based on Xception model with convolutional neural network. *Measurement*, 186, 110217.
- [39]. Huang, R., Liu, C., Li, G., & Zhou, J., 2016, Adaptive deep supervised autoencoder based image reconstruction for face recognition. *Mathematical Problems in Engineering*.
- [40]. Yan, Y., Tan, Z., Su, N., & Zhao, C., 2017, Building extraction based on an optimized stacked sparse autoencoder of structure and training samples using LIDAR DSM and optical images. *Sensors*, 17(9), 1957.
- [41]. Karim, A.M.; Güzel, M.S.; Tolun, M.R.; Kaya, H.; Çelebi, F.V., 2018, A new generalized deep learning framework combining sparse autoencoder and Taguchi method for novel data classification and processing. *Math. Probl. Eng.*
- [42]. Rao, K. N., Rao, K. V., & PVGD, P. R., 2021, A hybrid Intrusion Detection System based on Sparse autoencoder and Deep Neural Network. *Computer Communications*, 180, 77-88.
- [43]. Li, Y., Lei, Y., Wang, P., Jiang, M., & Liu, Y., 2021, Embedded stacked group sparse autoencoder ensemble with L1 regularization and manifold reduction. *Applied Soft Computing*, 101, 107003.
- [44]. Yang, Q., Jia, C., & Li, T., 2019, Prediction of aptamer–protein interacting pairs based on sparse autoencoder feature extraction and an ensemble classifier. *Mathematical biosciences*, 311, 103-108.
- [45]. Görgel, P., & Simsek, A., 2019, Face recognition via deep stacked denoising sparse autoencoders (DSDSA). *Applied Mathematics and Computation*, 355, 325-342.
- [46]. Han, Z., Hossain, M. M., Wang, Y., Li, J., & Xu, C., 2020, Combustion stability monitoring through flame imaging and stacked sparse autoencoder based deep neural network. *Applied Energy*, 259, 114159.
- [47]. Morid, M. A., Lau, M., & Del Fiol, G., 2021, Predictive analytics for step-up therapy: Supervised or semi-supervised learning?. *Journal of Biomedical Informatics*, 119, 103842.

- [48]. Lagani, G., Falchi, F., Gennaro, C., & Amato, G., 2021, Hebbian Semi-Supervised Learning in a Sample Efficiency Setting. arXiv preprint arXiv:2103.09002.
- [49]. Hu, L., Liu, H., Zhang, J., & Liu, A., 2021, KR-DBSCAN: A density-based clustering algorithm based on reverse nearest neighbor and influence space. *Expert Systems with Applications*, 186, 115763.
- [50]. Moros, J., Cabalín, L. M., & Laserna, J. J., 2021, Refractory residues classification strategy using emission spectroscopy of laser-induced plasmas in tandem with a decision tree-based algorithm. *Analytica Chimica Acta*, 339294.
- [51]. Haleem, N., Bustreo, M., & Del Bue, A., 2021, A computer vision based online quality control system for textile yarns. *Computers in Industry*, 133, 103550.
- [52]. Paneru, S., & Jeelani, I., 2021, Computer vision applications in construction: Current state, opportunities & challenges. *Automation in Construction*, 132, 103940.
- [53]. Minz, P. S., & Saini, C. S., 2021, Comparison of computer vision system and colour spectrophotometer for colour measurement of mozzarella cheese. *Applied Food Research*, 1(2), 100020.
- [54]. Bai, X., Wang, X., Liu, X., Liu, Q., Song, J., Sebe, N., & Kim, B., 2021, Explainable Deep Learning for Efficient and Robust Pattern Recognition: A Survey of Recent Developments. *Pattern Recognition*, 108102.
- [55]. Sultan HH, Salem NM, Al-Atabany W., 2019, Multi-classification of brain tumor images using deep neural network. *IEEE Access* 7:69215–69225. <https://doi.org/10.1109/ACCESS.2019.2919122>.
- [56]. Kabir Anaraki A, Ayati M, Kazemi F., 2019, Magnetic Resonance imaging-based brain tumor grades classification and grading via convolutional neural networks and genetic algorithms. *Biocybern Biomed Eng* 39(1):63–74. <https://doi.org/10.1016/j.bbe.2018.10.004>.
- [57]. Sajjad M, Khan S, Muhammad K, Wu W, Ullah A, Baik SW., 2019, Multi-grade brain tumor classification using deep CNN with extensive data augmentation. *J Comput Sci* 30:174–182. <https://doi.org/10.1016/j.jocs.2018.12.003>.

[58]. Cheng J, Huang W, Cao S, Yang R, Yang W, Yun Z, Wang Z, Feng Q., 2015, Enhanced performance of brain tumor classification via tumor region augmentation and partition. PLoS ONE 10(10):1–13. <https://doi.org/10.1371/journal.pone.0140381>.

[59]. Shin, H.C.; Orton, M.R.; Collins, D.J.; Doran, S.J.; Leach, M.O., 2013, Stacked Autoencoders for Unsupervised Feature Learning and Multiple Organ Detection in a Pilot Study Using 4D Patient Data. IEEE Trans. Pattern Anal. Mach. Intell. 35, 1930–1943.



## ÖZGEÇMİŞ

Kişisel Bilgiler	
Adı Soyadı	RUAA ADIL ABDUL HUSSEIN
Uyruğu	<input type="checkbox"/> T.C. <input checked="" type="checkbox"/> Diğer: Irak
E-Posta Adresi	
Web Adresi	

Eğitim Bilgileri	
Lisans	
Üniversite	Technology / kirkuk
Fakülte	Engineering
Bölümü	Software engineering techniques
Mezuniyet Yılı	2010

Yüksek Lisans	
Üniversite	Kırşehir Ahi Evran Üniversitesi
Enstitü Adı	Fen Bilimleri Enstitüsü
Anabilim Dalı	İleri Teknolojiler Ana Bilim Dalı
Programı	
Mezuniyet Tarihi	2022