

**KOCAELİ ÜNİVERSİTESİ**  
**FEN BİLİMLERİ ENSTİTÜSÜ**

**BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI**

**YÜKSEK LİSANS TEZİ**

**BEYİN MR GÖRÜNTÜLERİNİN AKILLI YÖNTEMLER İLE  
SINIFLANDIRILMASI, KÜMELENMESİ VE BÖLÜTLENMESİ**

**FARUK ALTUNTAŞ**

**KOCAELİ 2021**

**KOCAELİ ÜNİVERSİTESİ**  
**FEN BİLİMLERİ ENSTİTÜSÜ**

**BİLGİSAYAR MÜHENDİSLİĞİ**  
**ANABİLİM DALI**

**YÜKSEK LİSANS TEZİ**

**BEYİN MR GÖRÜNTÜLERİNİN AKILLI YÖNTEMLER İLE**  
**SINIFLANDIRILMASI, KÜMELENMESİ VE BÖLÜTLENMESİ**

**FARUK ALTUNTAŞ**

**Prof. Dr. Yaşar BECERİKLİ**

**Danışman, Kocaeli Üniv.**

.....

**Dr. Öğr. Üyesi Orhan AKBULUT**

**Jüri Üyesi, Kocaeli Üniv.**

.....

**Dr. Öğr. Üyesi Osman Hilmi KOÇAL**

**Jüri Üyesi, Yalova Üniv.**

.....

**Tezin Savunulduğu Tarih: 24.06.2021**

## ÖNSÖZ VE TEŞEKKÜR

Bu çalışmada beyin MR görüntülerinin sınıflandırılması, kümelenmesi ve bölütlenmesi için kullanılan akıllı algoritmalar incelenerek bu algoritmalarından biri olan derin öğrenme yöntemi ile sınıflandırma ve bölütleme uygulaması geliştirilmeye çalışılmıştır. Geliştirilen uygulama ile beyin MR görüntülerinin daha hızlı ve etkin bir şekilde analiz edilmesi amaçlanmıştır.

Benim için uzun bir süreç olan yüksek lisans eğitimim süresince benden umudunu hiç kesmeyen ve bana her alanda destek olan saygıdeğer hocam Prof. Dr. Yaşar BECERİKLİ'ye,

Bu günlere gelmemde en büyük emek sahibi olan kıymetli annem, babam ve ağabeyime,

Tez çalışmam süresince bana destek olan kıymetli arkadaşlarım Öğr. Gör. Samet DİRİ, Müh. Ayhan GÜLTEKİN, Ergül MADEN ve Kocaeli Üniversitesi Yazılım Ekibine,

Bu süreçte en yoğun zamanlarında bile beni kırmayarak bütün sorularıma cevap veren değerli hocam Doç. Dr. Dilek AVŞAROĞLU'na,

Çalışmalarım süresince ve hayatımın her alanında bana destek olan hayat arkadaşım, sevgili eşim Zehra ALTUNTAŞ'a,

Ve en önemlisi bu tezin tamamlanmasındaki en büyük motivasyon kaynağım olan oğullarım Mete ve Deniz'e sonsuz teşekkürlerimi sunarım.

Haziran – 2021

Faruk ALTUNTAŞ

## İÇİNDEKİLER

ÖNSÖZ VE TEŞEKKÜR .....	i
İÇİNDEKİLER .....	ii
ŞEKİLLER DİZİNİ.....	iv
SİMGELER VE KISALTMALAR DİZİNİ.....	v
ÖZET .....	vi
ABSTRACT.....	vii
GİRİŞ .....	1
1. GENEL BİLGİLER.....	5
1.1. Beyin MR'ı (Manyetik Rezonans) Nedir? .....	5
1.2. Görüntü Sınıflandırma, Kümeleme ve Bölütleme Nedir?.....	6
2. BEYİN MR GÖRÜNTÜLERİNİN SINIFLANDIRMA, KÜMELEME VE BÖLÜTLEME ALGORİTMALARI .....	9
2.1. K-En Yakın Komşuluk Algoritması (K-NN).....	9
2.1.1. Öklid Uzaklığı.....	10
2.1.2. Manhattan (Cityblok) Uzaklığı .....	10
2.1.3. Minkowski Uzaklığı.....	10
2.1.4. Chebychev Uzaklığı .....	10
2.2. Destek Vektör Makinesi Algoritması (SVM) .....	10
2.2.1. Doğrusal (linear) SVM.....	11
2.2.2. Doğrusal olmayan (non-linear) SVM.....	11
2.3. K-Ortalama Kümeleme Algoritması (K-Means).....	12
2.4. Bulanık C-Ortalama Algoritması (FCM) .....	13
2.5. Yapay Sinir Ağları.....	14
2.5.1. Aktivasyon fonksiyonları .....	16
2.5.1.1. Sigmoid aktivasyon fonksiyonu.....	16
2.5.1.2. Tanh aktivasyon fonksiyonu .....	16
2.5.1.3. Relu (Rectified Linear Unit) aktivasyon fonksiyonu.....	16
2.5.1.4. Softmax aktivasyon fonksiyonu.....	16
2.5.2. Hata fonksiyonları .....	17
2.5.2.1. Ortalama hata (Mean Error) fonksiyonu.....	17
2.5.2.2. Çapraz entropi fonksiyonu.....	17
2.6. Derin Öğrenme .....	17
2.6.1. Evrişimsel sinir ağı.....	19
2.6.1.1. Giriş katmanı.....	19
2.6.1.2. Evrişim katmanı .....	20
2.6.1.3. Havuzlama katmanı .....	21
2.6.1.4. Tam bağlı katman .....	22
2.6.1.5. Çıkış katmanı .....	22
3. DERİN ÖĞRENME YÖNTEMİ İLE BEYİN MR GÖRÜNTÜLERİNİN SINIFLANDIRMA VE BÖLÜTLEME UYGULAMASI .....	23
3.1. Geliştirilen Uygulamalar .....	23
3.2. Kullanılan Veri Seti.....	23
3.3. Uygulama Geliştirme Ortamı .....	24

3.4. Uygulama 1: Beyin MR Görüntülerinin Normal veya Anormal Olarak Sınıflandırılması .....	24
3.5. Uygulama 2: Beyin MR Görüntülerinin Tümör Türlerine Göre Sınıflandırılması .....	27
3.6. Uygulama 3: Beyin MR Görüntülerinin Bölütlenmesi ile Tümör Tespiti .....	32
4. SONUÇLAR VE ÖNERİLER .....	37
KAYNAKLAR .....	40
KİŞİSEL YAYIN VE ESERLER .....	45
ÖZGEÇMİŞ .....	46



## ŞEKİLLER DİZİNİ

Şekil 1.1. MR görüntüleme düzlemleri .....	5
Şekil 1.2. Farklı ağırlıklardaki beyin MR görüntüleri.....	6
Şekil 1.3. Hiyerarşik ve bölümlü kümeleme .....	7
Şekil 2.1. K-En Yakın Komşuluk Algoritması yeni nokta eklenmesi .....	9
Şekil 2.2. Doğrusal SVM Algoritması ile sınıflandırma işlemi .....	11
Şekil 2.3. SVM Algoritması ile sınıflandırma işlemi.....	12
Şekil 2.4. Yapay sinir hücresinin modellenmesi .....	15
Şekil 2.5. Derin sinir ağı modeli .....	18
Şekil 2.6. Evrişimsel sinir ağı modeli .....	19
Şekil 2.7. Özellik Haritası .....	20
Şekil 2.8. Evrişim işleminin uygulanması.....	21
Şekil 2.9. Havuzlama işleminin uygulanması .....	21
Şekil 2.10. Tam bağlı katman .....	22
Şekil 3.1. Tanımlanan ESA modeli.....	25
Şekil 3.2. Uygulama 1 ESA modeli eğitim sonucu doğruluk grafiği.....	26
Şekil 3.3. Uygulama 1 ESA modeli eğitim sonucu kayıp grafiği .....	26
Şekil 3.4. Durum 1 eğitim sonucu doğruluk grafiği.....	28
Şekil 3.5. Durum 1 eğitim sonucu kayıp grafiği .....	28
Şekil 3.6. Durum 2 eğitim sonucu doğruluk grafiği.....	29
Şekil 3.7. Durum 2 eğitim sonucu kayıp grafiği .....	29
Şekil 3.8. Durum 3 eğitim sonucu doğruluk grafiği.....	30
Şekil 3.9. Durum 3 eğitim sonucu kayıp grafiği .....	30
Şekil 3.10. Durum 4 eğitim sonucu doğruluk grafiği.....	31
Şekil 3.11. Durum 4 eğitim sonucu kayıp grafiği .....	31
Şekil 3.12. U-Net mimarisi (Ronneberger ve diğ., 2015) .....	32
Şekil 3.13. U-Net modeli eğitim sonucu doğruluk grafiği.....	34
Şekil 3.14. U-Net modeli eğitim sonucu kayıp grafiği .....	34
Şekil 3.15. Birinci veri seti bölütleme sonucu (a: Orijinal MR görüntüsü, b: Beklenen ESA sonucu, c: Tanımlanan ESA tahmin sonucu) .....	35
Şekil 3.16. İkinci veri seti bölütleme sonucu (a: Orijinal MR görüntüsü, b: Beklenen ESA sonucu, c: Tanımlanan ESA tahmin sonucu) .....	36

## SİMGELER VE KISALTMALAR DİZİNİ

C	: Küme Vektörü
H	: Entropi
N	: Veri Noktası Sayısı
U	: Üyelik Matrisi
W	: Ağırlık Matrisi
b	: Bias Değeri
d	: Uzaklık
x	: Veri Noktası
$\epsilon$	: Eşik Değer

### Kısaltmalar

BCO	: Bulanık C-Ortalama
DNN	: Derin Sinir Ağı
ESA	: Evrişimsel Sinir Ağı
FCM	: Fuzzy C-Means (Bulanık C-Ortalama)
K-NN	: K-Nearest Neighbors (K-En Yakın Komşuluk)
KO	: K-Ortalama
MAE	: Mean Average Error (Ortalama Mutlak Hata)
ME	: Mean Error (Ortalama Hata)
MR	: Manyetik Rezonans
MSE	: Mean Squared Error (Ortalama Kare Hata)
RF	: Radio Frequency (Radyo Frekansı)
RMSE	: Root Mean Squared Error (Karekök Ortalama Kare Hata)
SVM	: Support Vector Machine (Destek Vektör Makinesi)
TE	: Time to Echo (Yankı Süresi)
TR	: Time to Repeat (Tekrar Etme Süresi)
YSA	: Yapay Sinir Ağı

# BEYİN MR GÖRÜNTÜLERİNİN AKILLI YÖNTEMLER İLE SINIFLANDIRILMASI, KÜMELENMESİ VE BÖLÜTLENMESİ

## ÖZET

Beyin MR görüntülerinin analizi tıp alanında büyük bir öneme sahiptir. Bu nedenle, görüntü işleme ve analiz performansını iyileştirmek için çok sayıda akıllı yöntem geliştirilmiştir. Tez çalışması kapsamında beyin MR görüntülerinin sınıflandırma, kümeleme ve bölütleme işlemleri için K-En Yakın Komşuluk, Destek Vektör Makinesi, Yapay Sinir Ağı, K-Ortalama, Bulanık C-Ortalama ve Derin Öğrenme algoritmaları detaylı olarak incelenerek birleri arasındaki performans karşılaştırmaları yapılmıştır. Daha sonra derin öğrenme algoritması olan Evrişimsel Sinir Ağı (ESA) ile geliştirilen uygulamayla beyin MR görüntüleri sınıflandırılmaya ve bölütlenmeye çalışılmıştır. Yapılan uygulama ile ESA algoritmasından diğer algoritmalara göre daha iyi sonuçlar alındığı görülmüştür. Sınıflandırma uygulamalarında öncelikle beyin MR görüntüleri normal ve anormal olarak iki sınıfa daha sonra anormal görüntülerdeki tümör türleri sınıflandırılmaya çalışılmıştır. Yapılan testler sonucunda görüntülerin sınıflandırılmasında önceki çalışmalarda kullanılan ESA mimarilerinden daha az sayıda evrişim katmanı kullanılarak %96 ve üzerinde başarımla elde edilmiştir. Son olarak sınıflandırılan tümörlerin yerlerinin tespit edilmesi amacı ile bir ESA modeli olan U-Net mimarisi ile görüntüler bölütlenmeye çalışılmıştır. Yapılan testlerle tümörlerin yerleri büyük oranda tespit edilmiştir.

**Anahtar Kelimeler:** Akıllı Yöntemler, Derin Öğrenme, Evrişimsel Sinir Ağı, Yapay Sinir Ağları.



# **CLASSIFICATION, CLUSTERING AND SEGMENTATION OF BRAIN MR IMAGES BY INTELLIGENT METHODS**

## **ABSTRACT**

Analysis of brain MRI images is of great importance in the medical field. For this reason, many intelligence methods have been developed to improve image processing and analysis performance. Within the scope of this thesis study, K-Nearest Neighborhood, Support Vector Machine, Artificial Neural Network, K-Mean, Fuzzy C-Mean and Deep Learning algorithms for classification, clustering and segmentation of brain MR images were examined, and their performances were compared with each other in detail. Later, with the application developed using the Convolutional Neural Network (ConNN) method, a Deep Learning algorithm, brain MR images were classified and segmented. With the application, it was seen that better results were obtained from the ConNN algorithm compared to other algorithms. In classification practices, brain MR images were first classified into two classes as normal and abnormal, and then tumor types in abnormal images. As a result of the tests, a performance 96% and above was achieved by using fewer convolution layers than the ConNN architectures used in previous studies in the classification of images. Finally, in order to locate the classified tumors, the images were divided with the U-Net architecture, a ConNN model. With the tests performed, the locations of the tumors were determined to a great extent.

**Keywords:** Intelligent Methods, Deep Learning, Convolutional Neural Network, Artificial Neural Networks.

## GİRİŞ

Teknolojinin hızlı gelişimi, işlemcilerin ve grafik işlemcilerin işlem güçlerinin artması insan hayatında birçok değişikliğe sebep olmaktadır.

Bu değişiklikler bütün alanlarda olduğu gibi tıp elektroniğinde hem görüntüleme hem de bu görüntülerin işlenmesinde kendini göstermektedir. Tıbbi görüntülerde bilgisayar destekli görüntü analizi hastalık belirtilerinin tespitini kolaylaştırmaktadır. Böylece hastalıkların tedavisinde en önemli unsulardan biri olan erken teşhis için olanak sağlamaktadır. Bilgisayar destekli sistemler hem daha hızlı tanılama hem de belirlenmesi uzmanlık gerektirecek tanılar için kolaylık sağlamaktadır.

Tıp alanında beyin anormalliklerinin gözlemlenmesinde ve tanımlanmasında kullanılan birçok görüntüleme yöntemi bulunmaktadır. Beynin görüntülenmesinde Manyetik Rezonans (MR) görüntüleme en sık kullanılan yöntemlerden biridir. MR, insan vücudunda, özellikle beyinin anatomik yapılarının görüntülerini çok iyi sunan, klinik ve biyomedikal araştırmalar için detaylı veri sağlayan bir görüntüleme yöntemidir (Kumar ve diğ., 2017). MR beyin yapısını üç boyutlu ve çok yönlü olarak görüntülemektedir.

Beyin yapısının karmaşıklığı ve MR görüntülerinin büyüklüğü düşünüldüğünde beyindeki anormalliklerin bir uzman tarafından tespit edilmesi zor ve zaman alıcı olmaktadır. Bu problemlerin üstesinden gelmek ve beyin MR görüntülerinin işlenmesi için otomatik, hızlı ve doğru çalışan sistemlere gereksinim duyulmaktadır. Bu amaçla görüntülerin analizi için geliştirilmiş birçok yöntem bulunmaktadır. Özellikle son zamanlarda teknolojik gelişmelerinde etkisiyle bu yöntemler insan faktörünü ortadan kaldırmaya yönelik yöntemlere doğru yönelmiştir.

Bu tez çalışmasında beyin MR görüntülerinin sınıflandırılması, kümelenmesi ve bölütlenmesi için en çok kullanılan akıllı algoritmalar anlatılmış ve literatür araştırması sonrasında bir derin öğrenme modeli olan Evrimsel Sinir Ağı yöntemi ile beyin MR görüntülerinin sınıflandırılması ve bölütlenmesi amaçlanmıştır. Belirlenen

algoritmaların beyin MR görüntülerindeki başarımları değerlendirilmiştir. Gerçekleştirilen sınıflandırma ve bölütleme uygulaması ile beyin MR görüntülerinin yorumlanmasına olumlu katkı sağlaması amaçlanmıştır.

Beyin MR görüntülerinin sınıflandırılması, kümelenmesi ve bölütlenmesi üzerine gerçekleştirilmiş olan çok sayıda makale ve tez incelenmiş ve aşağıdaki sonuçlara ulaşılmıştır.

(Rajini ve Bhavani, 2011) makalede beyin MR görüntüleri sınıflandırılarak otomatik tanı için bir yaklaşım önerilmektedir. Sınıflandırma işlemi öncesinde özellik çıkarma işlemi uygulanmaktadır. Sınıflandırma için ileri beslemeli yapay sinir ağı ve k-en yakın komşu algoritmaları kullanılmaktadır. Yapılan sınıflandırma sonucunda ileri beslemeli yapay sinir ağı tabanlı sınıflandırıcıdan %90 ve k-en yakın komşu tabanlı sınıflandırıcıdan %99 başarımlar elde edilmiştir.

(Wasule ve Sonar, 2017) makalede beyin MR görüntülerindeki tümörlerin iyi veya kötü huylu ve yüksek veya düşük dereceli olarak otomatik sınıflandırılmasına yönelik bir yaklaşım önerilmektedir. Sınıflandırma işlemi öncesinde özellik çıkarma işlemi uygulanmaktadır. Sınıflandırma için Destek Vektör Makinesi (SVM) ve k-en yakın komşuluk (K-NN) algoritmaları kullanılmaktadır. Sınıflandırma iki farklı veri seti üzerinde uygulanmaktadır. Sınıflandırma sonucu SVM tabanlı ve K-NN tabanlı sınıflandırıcılardan birinci veri setinde %96, %86 ikinci veri setinde %85, %72,50 başarımlar elde edilmiştir.

(Mohsen ve diğ., 2018) makalede beyin MR görüntülerindeki tümörlerin dört sınıfa ayrılmasına yönelik bir yaklaşım sunulmaktadır. Sınıflandırma algoritması olarak Derin Öğrenme mimarilerinden biri olan Derin Sinir Ağı (DNN) kullanılmaktadır. Sınıflandırma sonucu farklı algoritmalar ile karşılaştırılmakta ve %96 başarımla diğer yöntemlerden daha iyi sonuç alındığı belirtilmiştir.

(Banchpalliwar ve Salankar, 2016) makalede beyin MR görüntülerinin bölütlenmesi için kümeleme algoritmaları karşılaştırılmaktadır. K-Ortalama (KO) ve Bulanık C-Ortalama (BCO) kümeleme algoritmaları karşılaştırılmıştır. Bölütleme sonucu BCO algoritmasının KO algoritmasına göre daha uzun süre aldığı fakat %92'ye karşı %82 daha iyi başarımlar gösterdiği belirtilmiştir.

(Liu ve diğ., 2018) makalede derin öğrenme algoritması ile MR görüntülerinin işlenmesi ve analizi kapsamlı olarak anlatılmaktadır. Öncelikle MR görüntüleme ve derin öğrenmenin tanımlamaları yapılmış arkasından görüntü bölütleme, sınıflandırma uygulamaları anlatılmıştır. Daha sonra geliştirilmiş bazı derin öğrenme mimarileri sunulmuştur. Son olarak derin öğrenmenin MR görüntülerine uygulanmasının değerlendirilmesi yapılmıştır.

(Arı, 2019) doktora tezinde beyin MR görüntülerinden tümör tespiti yapabilen Bilgisayar Destekli Otomatik Tespit Sistemi (BDOTS) tasarımı önerilmektedir. Önerilen iki BDOTS sistemi öznelik çıkarımı ile sınıflandırma yapmaktadır. Diğerleri ise derin öğrenmenin bir modeli olan Evrişimsel Sinir Ağı (ESA) ve geliştirilmiş ESA mimarileri ile sınıflandırma yapmaktadır. Geliştirilen yöntemlerin performansları ve başarımları detaylıca karşılaştırılmıştır. Sonuç olarak geliştirilen yöntemlerden %95 üzerinde başarımlar alındığı belirtilmiştir.

(Kılıç, 2019) yüksek lisans tezinde beyin MR görüntülerinin derin öğrenme mimarilerinden biri olan U-Net tabanlı bir ESA ile bölütlenmesi önerilmiştir. Çalışmada derin öğrenme mimarisi detaylı olarak anlatılmış ve yapılan dokuz farklı test sonucu paylaşılmıştır. Sonuç olarak yüksek derecede başarımlar elde edildiği belirtilmiştir.

(Güngen, 2020) yüksek lisans tezinde beyin MR görüntülerindeki tümörlerin sınıflandırılması amaçlanmıştır. Sınıflandırma algoritması olarak VGG16, VGG19, Resnet50 ve Densenet121 Derin öğrenme algoritmaları kullanılmıştır. Yapılan sınıflandırma sonuçlarında yüksek derecede başarımlar elde edildiği belirtilmiştir.

(Alan, 2010) yüksek lisans tezinde beyin MR görüntülerinden bulanık sınıflandırma ile tümör tespiti yapılmıştır. Öncelik olarak kümeleme algoritmaları kullanılarak MR görüntülerinin bölütlenmesi sağlanmış. Sınıflandırma sürecinde ise kural tabanlı bulanık sistem uygulanmıştır. Kural çıkarımında kullanılan kümeleme algoritmalarında birbirlerine karşı kesin bir üstünlükleri olmadığı belirtilmiştir. Sonuç olarak uygulanan kural tabanlı bulanık sistem ile sınıflandırmada yüksek derecede başarımlar elde edildiği belirtilmiştir.

(Kumar ve diğ., 2017) makalede beyin MR görüntülerinin sınıflandırılması için hibrit bir algoritma önerilmiştir. Önerilen algoritmada özellik çıkarımı için ayrık dalgacık dönüşümü, özellik sayısının azaltılması için genetik algoritma kullanılmaktadır. Sınıflandırma için Destek Vektör Makinesi (SVM) algoritması uygulanmaktadır. Hibrit yaklaşımın diğer algoritmalara göre doğruluk oranının daha fazla olduğu belirtilmektedir. Yapılan uygulama sonucunda %90 oranında doğruluğa ulaşıldığı belirtilmiştir.

Tez çalışması dört bölümden oluşmaktadır.

Birinci bölümde; genel bilgiler başlığı altında beyin MR'ı açıklanmıştır. Daha sonra görüntü sınıflandırma, kümeleme ve bölütleme yöntemleri tanımlanmıştır. Son olarak belirlenen akıllı algoritmalar verilmiştir.

İkinci bölümde; belirlenen sınıflandırma, kümeleme ve bölütleme algoritmalarının tanımlamaları yapılarak çalışma yöntemleri detaylı olarak anlatılmıştır.


Üçüncü bölümde; gerçekleştirilen sınıflandırma ve bölütleme uygulamaları ayrıntılı olarak anlatılmıştır. Uygulama geliştirme ortamı, kullanılan veri setleri tanıtılmıştır. Oluşturulan evrimsel sinir ağı modelleri ayrıntılı olarak verilerek, eğitim aşamaları ve alınan sonuçlar paylaşılmıştır.

Dördüncü bölümde; tez içerisinde anlatılan algoritmaların bir karşılaştırması yapılmıştır. Gerçekleştirilen uygulamanın sonuçları tartışılmıştır. Bu alanda yapılabilecek uygulamalarla ilgili önerilerden bahsedilmiştir.

## 1. GENEL BİLGİLER

### 1.1. Beyin MR'ı (Manyetik Rezonans) Nedir?


MR, güçlü mıknatıslar ile oluşturulan manyetik alan ve radyo dalgaları (RF) kullanılarak radyasyon içermeden organların detaylı olarak görüntülenmesidir (Herek ve Karabulut, 2010). Beyin MR'ı ise beyin yapılarının MR görüntüleme yöntemi ile görüntülenmesidir. Beyin MR'ı ile hipofiz bezi, beyin sapı gibi küçük yapılar da dahil olmak üzere beyindeki çeşitli anormallikler tespit edilebilir (URL-7). Beyin MR görüntüleri Şekil 1.1'deki gibi üst (axial), yan (sagittal) ve arka (coronal) olmak üzere farklı düzlemlerde görüntülenmektedir.



Şekil 1.1. MR görüntüleme düzlemleri

Tanımında da belirtildiği gibi MR görüntüsü güçlü manyetik alan ve RF'ler ile oluşturulur. Veri kaynağı olarak hücreler içerisindeki hidrojen çekirdeğini (protonları) kullanır. Manyetik alan içerisinde uyarılan protonlar uygulanan manyetik alana göre dizili hale gelirler. Sonrasında görüntü alınacak bölgeye RF sinyali gönderilir. Bu sinyali alan protonlar aldıkları enerjiye göre hareket etmeye başlarlar. Protonlar eski konumlarına geri dönerken RF sinyalinden aldıkları enerjiyi geri yayarlar. MR görüntüleri bu enerji sinyallerinden oluşturulur. Protonların ilk konumlarına geri dönüş süresi T1, geri yaydıkları enerji sinyalinin bittiği süre ise T2 süresi olarak adlandırılır. Görüntüleme sürecinde görüntülenecek bölgeye ardışık RF sinyalleri

gönderilir. İki RF sinyali arasındaki süre TR (Time to Repetition), geri dönen sinyalin dinlendiği süre ise TE (Time to Echo) olarak adlandırılır. TR, TE, T1 ve T2 süreleri değiştirilerek yapılan görüntülemeler ile Şekil 1.2’de görüldüğü gibi farklı ağırlıklarda görüntüleme sağlanır. Bu sayede beyinin daha detaylı olarak görüntülenmesi sağlanmış olur (Cantemir, 2019; URL-9)



Şekil 1.2. Farklı ağırlıklardaki beyin MR görüntüleri

## 1.2. Görüntü Sınıflandırma, Kümeleme ve Bölütleme Nedir?

Birçok alanda önemli bir yer tutan görüntü analizi, görüntülerin çeşitli yöntemlerle işlenerek anlamlı hale getirilmesidir. Görüntüler sınıflandırma, kümeleme ve bölütleme yöntemleri ile işlenerek görüntü içerisindeki nesnelerin tanınması, yerinin tespit edilmesi, boyutlandırılması, şekillerinin belirlenmesi, izlenmesi sağlanabilir.

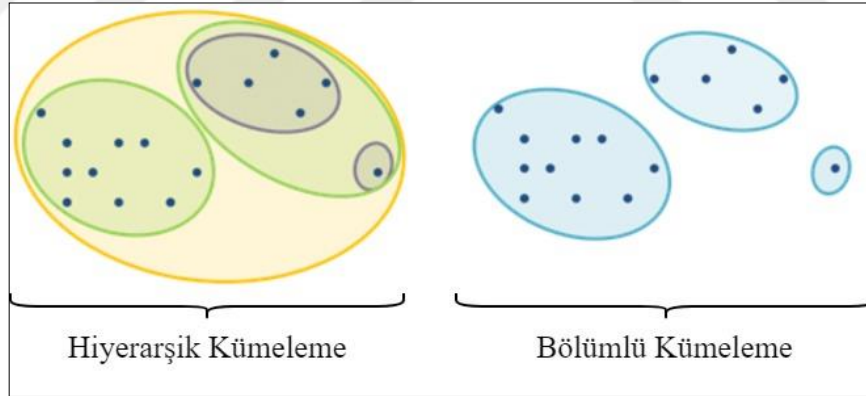
Yapılan literatür taramasında da görüldüğü üzere görüntü sınıflandırma, kümeleme ve bölütleme çok sayıda akademik çalışmaya konu olmaktadır. Yapılan çalışmalarda birçok farklı tanımlaması yapılan görüntü sınıflandırma, kümeleme ve bölütleme kavramları aşağıdaki gibi tanımlanabilir.

Görüntü sınıflandırma genel olarak görüntülerin tanımlı bir dizi sınıf ile etiketlenmesi işlemidir (Cantemir, 2019; Cengil ve diğ., 2017; Lu ve Weng, 2007; Miranda ve diğ., 2016). Görüntü sınıflandırma tıp, endüstri, askeri vb. alanlarda teşhis, tanı, navigasyon, uzaktan algılama uygulamalarında önemli bir yer tutmaktadır. Sınıflandırma yöntemlerinde amaç etiketlenmemiş görüntüyü çeşitli yöntemlerle etiketlenmiş veri içerisindeki en yakın sınıf etiketi ile etiketlemektir.

Sınıflandırma denetimli ve denetimsiz sınıflandırma olarak iki grupta incelenebilir. Sınıflandırma işlemi etiketlenmiş bir veri seti kullanılarak yapılıyor ise denetimli sınıflandırma, önceden tanımlanmış sınıf etiketi olmayan veri seti ile yapılıyor ise denetimsiz sınıflandırma olarak adlandırılır (Cantemir, 2019).

Görüntü kümeleme, görüntü içerisindeki nesnelerin benzerliklerine göre farklı gruplara ayrılması olarak tanımlanabilir (Khalid ve diğ., 2014; Omran ve diğ., 2007). Kümeleme yöntemleri genel olarak eğitim verisi olmadan denetimsiz olarak çalışır (Banchpalliwar ve Salankar, 2016; Omran ve diğ., 2007; Xu ve diğ., 2017).

Kümeleme hiyerarşik ve bölümlü kümeleme olarak Şekil 1.3'te görüldüğü gibi iki grupta incelenebilir (Xu ve diğ., 2017). Hiyerarşik kümelemede başlangıçta her bir veri noktası bir küme olarak alınır. Daha sonra en yakın veri noktaları birbirine eklenerek kümeler oluşturulur. Bu tür kümelemede kümeler ağaç yapısının bir bölümünü oluşturur. Bölümlü kümelemede ise veri belirli sayıda kümeye ayrılır. Daha sonra belirlenen optimizasyon algoritmaları ile küme içi benzerlik yükseltilmeye çalışılır.



Şekil 1.3. Hiyerarşik ve bölümlü kümeleme (URL-10)

Görüntü bölütleme, görüntünün doku, yoğunluk, gri seviyesi gibi çeşitli özelliklerine göre anlamlı bölümlere ayrılmasıdır. Başka bir ifade ile görüntü içerisindeki nesnelerin anlamlı bir haritasının oluşturulmasıdır (Bali ve Singh, 2015; Dhanachandra ve diğ., 2015; Polat, 2007). Bölütleme yöntemi ile görüntünün tamamını yorumlamak yerine görüntüde ayrılan anlamlı bölümlere odaklanılır (Lee ve diğ., 2015). Böylece işlem sayısı azaltılmış ve uygulanan algoritmanın daha hızlı çalışması sağlanmış olur.



Bölütlenmiş bir görüntüde optimum durumda oluşan anlamlı bölümler karakteristik özellikleri bakımından çok benzer olmalıdır. Birbirine komşu bölümler ise tam tersi olarak farklı özelliklere sahip olmalıdır (Alan, 2010).

Tanımlamaları yapılan görüntü sınıflandırma, kümeleme ve bölütleme yöntemleri için birçok akıllı yöntem geliştirilmiştir. Literatür araştırması sırasında görülen ve beyin MR görüntülerinin işlenmesinde yaygın olarak kullanılan K-NN, SVM, K-Ortalama, Bulanık C-Ortalama, Yapay Sinir Ağları ve Derin Öğrenme algoritmaları bir sonraki bölümde açıklanmıştır.




## 2. BEYİN MR GÖRÜNTÜLERİNİN SINIFLANDIRMA, KÜMELEME VE BÖLÜTLEME ALGORİTMALARI

### 2.1. K-En Yakın Komşuluk Algoritması (K-NN)

K-En Yakın Komşuluk, çok sık olarak kullanılan uygulaması basit denetimli bir sınıflandırma algoritmasıdır. Bir özellik vektörünün sınıflandırılması uygun bir uzaklık ölçüsüne göre eğitim vektörlerinin belirlenmesi ile yapılır (Rajini ve Bhavani, 2011). Yeni bir nokta eklendiğinde Şekil 2.1’de de görüldüğü gibi eğitim verisinden k parametresi ile belirlenen sayıda en yakın komşuluklar bulunur. Eklenen nokta bulunan komşuluklar içerisinde sayısı en fazla olan sınıfa eklenerek sınıflandırma sağlanmış olur. K-NN algoritması akış adımları aşağıdaki gibi sıralanır.

K-NN algoritması akış adımları;

- Sınıflandırılacak veriyi ve K parametresini belirle,
- Belirlenen uzaklık fonksiyonu ile eğitim verisinde bulunan etiketli sınıflara olan uzaklığı hesapla,
- Hesaplanan uzaklıklara göre en yakın K sayıda komşuluğu belirle,
- Belirlenen en yakın komşuluklar arasında hangi sınıf sayısı daha çok ise veriyi bu sınıf ile etiketle (Altay, 2016).



Şekil 2.1. K-En Yakın Komşuluk Algoritması yeni nokta eklenmesi

K-NN algoritmasının performansını etkileyen en önemli unsulardan biri de uzaklık hesaplama fonksiyonunun belirlenmesidir. En çok kullanılan uzaklık hesaplama

fonksiyonları Öklid Uzaklığı, Manhattan (Cityblok) Uzaklığı, Minkowski Uzaklığı, Chebychev Uzaklığı olarak kullanılmaktadır (Wasule ve Sonar, 2017).

### 2.1.1. Öklid Uzaklığı

En sık kullanılan uzaklık hesaplama tekniğidir. İki nokta arasındaki doğrusal mesafeyi  $x_i$  ve  $y_i$  veri kümesindeki iki nokta olmak üzere Denklem (2.1)'deki gibi hesaplar.

$$d = \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad (2.1)$$

### 2.1.2. Manhattan (Cityblok) Uzaklığı

Manhattan uzaklığı iki nokta arasındaki mutlak uzaklıkların toplamı olarak Denklem (2.2)'deki gibi hesaplanır (Keziban, 2020).

$$d(i, j) = \sum_{k=1}^n (|x_{ik} - y_{jk}|) \quad (2.2)$$

### 2.1.3. Minkowski Uzaklığı

Öklit uzaklığı ve Manhattan uzaklığının genelleştirilmiş halidir.  $P=(x_1, x_2, x_3, \dots, x_n)$  ve  $Q=(y_1, y_2, y_3, \dots, y_n)$  olmak üzere herhangi iki nokta arasındaki uzaklık Denklem (2.3)'deki gibi hesaplanır.

$$d = \left( \sum_{i=1}^n (|x_i - y_i|^p) \right)^{\frac{1}{p}} \quad (2.3)$$

### 2.1.4. Chebychev Uzaklığı

Maksimum metrik veya satranç mesafesi olarak da bilinir. Herhangi iki nokta arasındaki mutlak uzaklıkların maksimumu olarak Denklem (2.4)'deki gibi hesaplanır.

$$d = \lim_{p \rightarrow \infty} \left( \sum_{i=1}^n (|x_i - y_i|^p) \right)^{\frac{1}{p}} = \max_i (|x_i - y_i|) \quad (2.4)$$

## 2.2. Destek Vektör Makinesi Algoritması (SVM)

Destek Vektör Makinesi, ikili sınıflandırma problemlerinin çözümü için geliştirilmiş denetimli sınıflandırma algoritmalarından biridir. SVM'ler veriyi sınıflandırabilmek


için karar sınırları başka bir deyişle hiper düzlemler kullanır (Ulgen, 2017). SVM algoritması doğrusal (lineer) ve doğrusal olmayan (non-linear) olarak iki başlıkta incelenebilir (Nandpuru ve diğ., 2014).

### 2.2.1. Doğrusal (lineer) SVM

Doğrusal SVM Şekil 2.2’de görüldüğü gibi belirlenen iki sınıf arasındaki maksimum boşluğu bulmaya çalışır. Doğrusal sınıflandırma fonksiyonu Denklem (2.5)’deki gibi tanımlanır.

$$f(x)=w^T x+b \quad (2.5)$$

Denklemden  $w$  ağırlık vektörü,  $b$  bias değeri ve  $x$  veri noktasını temsil etmektedir.  $f(x)=w^T x+b=0$  hiper düzlemi ile her bir  $x$  veri noktası için  $f(x) \geq 0$  ise  $y=+1$ ,  $f(x) \leq 0$  ise  $y=-1$  olarak etiketlenerek veri iki sınıfa ayrılmış olur.




Şekil 2.2. Doğrusal SVM Algoritması ile sınıflandırma işlemi

### 2.2.2. Doğrusal olmayan (non-linear) SVM

Doğrusal SVM’ler de veriler belirlenen en iyi bir hiper düzlem ile iki sınıfa ayrılmaktadır. Ancak her zaman veriler bir hiper düzlem ile sınıflara ayrılamayacak kadar karmaşık olabilir. Bu durumlarda Doğrusal olmayan SVM’ler sınıflandırma için kullanılmaktadır. Burada veriler doğrusal olmayan bir çekirdek fonksiyonu ile yüksek

boyutlu bir özellik uzayına etiketlenirler. Doğrusal olmayan SVM Denklem (2.6)'da ki gibi tanımlanabilir.

$$f(x)=w^T\phi(x)+b \quad (2.6)$$



Şekil 2.3. SVM Algoritması ile sınıflandırma işlemi

En sık kullanılan doğrusal olmayan çekirdek fonksiyonları Polynomial (2.7) ve Gauss RBF (Radial Basis Function) (2.8) çekirdek fonksiyonlarıdır.

$$= (x^T y + c)^d \quad (2.7)$$

$$= \exp\left(-\frac{\|x-x'\|^2}{2\sigma^2}\right) \quad (2.8)$$

### 2.3. K-Ortalama Kümeleme Algoritması (K-Means)

K-Ortalama Kümeleme Algoritması ilk olarak 1967 de James MacQueen tarafından kullanılmıştır. Popüler kümeleme algoritmalarından biridir. Temel olarak algoritma veri setini belirlenen K sayıda kümeye böler. İteratif olarak çalışan algoritma küme içi benzerliği yüksek kümeler arası benzerliği ise düşük tutmaya çalışır (Yıldız ve diğ., 2010).

Genel olarak algoritma iki kısımdan oluşur. İlk kısımda K küme merkezleri hesaplanır. İkinci kısımda ise her bir veri noktası belirlenen kümelerden en yakın küme etiketi ile etiketlenir. Küme merkezlerinin hesaplanmasında çeşitli yöntemler kullanılmaktadır. En sık kullanılan yöntem Denklem (2.9)'da ki gibi hesaplanan Öklid mesafesidir. Gruplama işlemleri tamamlandıktan sonra küme merkezleri tekrar hesaplanır. Hesaplanan yeni merkezlere göre bütün veri noktaları arasındaki uzaklık Denklem (2.10) ile tekrar hesaplanır. Veri noktaları en yakın oldukları küme ile tekrar etiketlenir (Dhanachandra ve diğ., 2015).

$$d = \|p(x,y) - c_k\| \quad (2.9)$$

$$c_k = \frac{1}{k} \sum_{y \in c_k} \sum_{x \in c_k} p(x,y) \quad (2.10)$$

Algoritmanın uygulanabilirliğinin kolay olması, işlem sayısının az olması, büyük veri setlerinde hızlı sonuçlar veriyor olması avantajlı yanlarındandır. Başlangıçta küme merkezlerinin rastgele belirlenmesi, en kötü durum da iterasyon sayısının çok fazla olabilmesi ve genel kümelemeyi garanti edememesi dezavantajları olarak gösterilebilir.

#### 2.4. Bulanık C-Ortalama Algoritması (FCM)

İlk olarak 1973'te J.C. Dunn tarafından geliştirilmiş ve 1981'de J.C. Bezdek tarafından iyileştirilmiştir. Bulanık C-Ortalama (FCM) algoritması üzerinde birçok çalışma yapılmıştır (Nilakant ve diğ., 2017). FCM belirsiz durumlarda güçlü özelliklere sahip olması ve diğer bölütleme algoritmalarından daha fazla istatistiksel bilgi saklayabildiğinden dolayı görüntü bölütleme alanında yaygın olarak kullanılmaktadır (Chouhan ve diğ., 2019).

Algoritma verinin ikiden fazla kümeye ayrılmasına olanak sağlar. Veriler belirlenen kümelere bulanık mantığa uygun olarak [0,1] arasında bir olasılık değeri ile bağlıdır. Bir verinin kümelere olan bağlılık olasılıkları toplamı 1'dir. Amaç fonksiyonu tamamlandığında veri hangi merkeze daha yakın olasılık değerine sahip ise o kümeye ait olarak etiketlenerek algoritma sonlandırılır (Işık ve Çamurcu, 2007; Yıldız ve diğ., 2010).

FCM algoritması en küçük kareler metodunun bir genellemesi olan Denklem (2.11)'de ki amaç fonksiyonunu minimize etmeye çalışır.

$$J_m = \sum_{i=1}^N \sum_{j=1}^C u_{ij}^m \|x_i - c_j\|^2, \quad 1 \leq m < \infty \quad (2.11)$$

Algoritma U üyelik matrisi, X veri noktası, C küme merkezi matrisi olmak üzere aşağıdaki adımları izler.

- Üyelik matrisi (U) rastgele belirlenir.
- Belirlenen üyelik matrisi için küme merkezleri (C) Denklem (2.12) ile hesaplanır.
- Küme merkezleri hesaplandıktan sonra U Denklem (2.13) ile tekrar hesaplanır.
- Algoritma  $\|U^{k+1} - U^k\| < \varepsilon$  olana kadar ikinci adımdan devam eder.

$$c_j = \frac{\sum_{i=1}^N u_{ij}^m x_i}{\sum_{i=1}^N u_{ij}^m} \quad (2.12)$$

$$u_{ij} = \frac{1}{\sum_{k=1}^C \left( \frac{\|x_i - c_j\|}{\|x_i - c_k\|} \right)^{\frac{2}{m-1}}} \quad (2.13)$$

Beyin MR görüntülerinin bölütlenmesinde hızlı ve yüksek bir başarımla elde edilmesi FCM'nin avantajlı yönünü oluşturmaktadır (Fasihi ve Mikhael, 2016).


## 2.5. Yapay Sinir Ağları

Yapay Sinir Ağları (YSA) insan sinir hücresi temel alınarak katmanlar halinde oluşturulmuş matematiksel bir modeldir. İlk olarak Warren McCulloch ve Walter Pitts tarafından 1943 yılında insan sinir hücresi matematiksel olarak modellenmiştir (URL-1, 2021). İlerleyen dönemlerde çeşitli alanlarda kullanılmak üzere gelişmeye devam etmiştir. Esin kaynağı insan sinir hücresi yapısına benzer olarak Şekil 2.4'te görüldüğü gibi dış taraftan gelen verilerin alındığı giriş katmanı, alınan verilerin toplandığı ve aktivasyon fonksiyonundan geçirildiği işlem merkezi (hücre gövdesi) katmanı ve sonuçların alınarak değerlendirildiği çıkış katmanı olarak tasarlanmıştır.

Dışarıdan alınan veriler (x) ağırlıklandırılarak (w) hücre merkezine veya başka bir ifade ile toplayıcıya iletilir. Toplayıcıya gelen ağırlıklandırılmış veri bias (b) değeri eklenerek doğrusal olmayan bir aktivasyon fonksiyonundan geçirilir. Son olarak

aktivasyon fonksiyonu sonucu çıkış katmanına (y) iletilir. YSA'lar Denklem (2.14)'te ki gibi ifade edilir.

$$y=f(\sum wx+b) \quad (2.14)$$



Şekil 2.4. Yapay sinir hücresinin modellenmesi (Cantemir, 2019)

YSA'nın kararlılığını ve performansını artıran önemli parametrelerden biride aktivasyon fonksiyonlarıdır. YSA'nın kullanım alanına göre değişkenlik gösteren aktivasyon fonksiyonlarının en sık kullanılanları Sigmoid, Tanh, Relu (Rectified Linear Unit), Softmax olarak gösterilebilir (Sharma ve diğ., 2020).

YSA'lar katmanlar arası hücrelerin bağlanma şekillerine göre İleri Beslemeli ve Geri Beslemeli ağlar olarak iki grupta incelenebilir. İleri beslemeli ağlarda bir katmandaki hücre çıkışları bir sonraki katmandaki hücre girişleri olarak alınır. Bu ağlar doğrusal olmayan sabit bir işlevi yerine getirmiş olur. Geri beslemeli ağlarda bir hücrenin çıkışı sadece bir sonraki katmana değil kendisine veya diğer hücelere giriş olarak verilir. Bu şekilde ağ dinamik bir yapı kazanmış olur.

YSA'larda sistemin önemli katmanlarından biri de çıkış katmanıdır. Bu katman sisteme verilen girişin sonucunun alındığı ve genel hatanın hesaplandığı kısımdır. Bu kısımda problemin tanımına ve ağın yapısına göre farklı hata fonksiyonları kullanılmaktadır. Ortalama Hata, Çapraz Entropi vb. hata fonksiyonları kullanılmaktadır (Mulla, 2020).

YSA'lar esnek olması, doğrusal olmaması, hata toleransı, paralellik ve kararlı yapısı sebebiyle sınıflandırmada başarılı sonuçlar vermektedir. Hızlı ve doğru sonuçlar üretmesi avantajları arasında gösterilebilir. Bunun yanında bazı dezavantajları da bulunmaktadır. Ağın eğitilmesinin zaman alması, yeterli miktarda ve doğru eğitim setinin bulunma zorluğu dezavantajları arasında sayılabilir.



## 2.5.1. Aktivasyon fonksiyonları

### 2.5.1.1. Sigmoid aktivasyon fonksiyonu

En sık kullanılan doğrusal olmayan aktivasyon fonksiyonudur. Fonksiyon almış olduğu giriş değerini 0 ile 1 arasına indirger. Aktivasyon fonksiyonu Denklem (2.15)'te ki gibi tanımlanır.

$$S(x) = \frac{1}{1+e^{-x}} \quad (2.15)$$

### 2.5.1.2. Tanh aktivasyon fonksiyonu

Hiperbolik Tanjant (Tanh) aktivasyon fonksiyonu Sigmoid fonksiyonuna benzer bir yapıdadır. Sigmoid fonksiyonundan farklı olarak aldığı giriş değeriniz -1 ile 1 aralığına indirger. Tanh fonksiyonu Denklem (2.16)'da ki gibi tanımlanır.

$$\tanh(x) = \frac{e^{2x}-1}{e^{2x}+1} \quad (2.16)$$

### 2.5.1.3. Relu (Rectified Linear Unit) aktivasyon fonksiyonu

Rectified Linear Unit (Relu) aktivasyon fonksiyonu çıkış değerini 0 ile aldığı giriş değeri arasına indirger. Relu aktivasyon fonksiyonu ağdaki bütün nöronların aktif olmasının önüne geçer. Bu sayede hesaplama yükü azaltılmış olur ve ağ daha hızlı çalışır. Relu aktivasyon fonksiyonu Denklem (2.17)'de ki gibi tanımlanır.

$$\text{Relu}(x) = \max(0, x) \quad (2.17)$$

### 2.5.1.4. Softmax aktivasyon fonksiyonu

Sınıflandırma problemlerinde ikiden fazla sınıflandırma gerekli durumlarda tercih edilmektedir. Aldığı girişin hangi sınıfa ait olduğunu olasılıksal olarak hesaplayan [0,1] aktivasyon fonksiyonudur. Çoğunlukla derin öğrenme modellerinde çıkış katmanı aktivasyon fonksiyonu olarak kullanılmaktadır. Softmax aktivasyon fonksiyonu Denklem (2.18)'de ki gibi tanımlanır.

$$\vartheta(\text{m. sınıf}) = \frac{e^{W_m A}}{\sum_{i=1}^N e^{W_i A}} \quad (2.18)$$

## 2.5.2. Hata fonksiyonları

### 2.5.2.1. Ortalama hata (Mean Error) fonksiyonu

Ortalama hata fonksiyonunun Ortalama Hata Denklem (2.19), Ortalama Kare Hata Denklem (2.20), Ortalama Mutlak Hata Denklem (2.21), Kök Ortalama Kare Hata Denklem (2.22) gibi çeşitli uygulama fonksiyonları bulunmaktadır. Ortalama Hata Fonksiyonu anlaşılması ve uygulaması kolay bir fonksiyondur. Genel olarak YSA'nın çıkış değerleri ile beklenen değerler arasındaki farkların kullanılan fonksiyon türüne göre ortalaması olarak ifade edilir.

$$ME = \frac{1}{n} \sum_{i=1}^n (y_i - y'_i) \quad (2.19)$$

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - y'_i)^2 \quad (2.20)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n (|y_i - y'_i|) \quad (2.21)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_i - y'_i)^2}{n}} \quad (2.22)$$

### 2.5.2.2. Çapraz entropi fonksiyonu


Sınıflandırma problemlerinde sıkça kullanılan Çapraz Entropi YSA'nın çıkış değerleri ile beklenen değerler arasında bir olasılık hesabı yapar (Koşan ve diğ., 2019). Beklenen olasılık değeri ile hesaplanan olasılık farkı arttıkça çapraz entropi kaybı yükselir. Optimum durum farkın 0 olmasıdır. Fonksiyon Denklem (2.23)'te ki gibi tanımlanır.

$$H(p,q) = - \sum_{i,j} p(i,j) \log q(i,j) \quad (2.23)$$

## 2.6. Derin Öğrenme

Derin Öğrenme, Yapay Sinir Ağlarının (YSA) bir uyarlaması olan makine öğrenmesi algoritmalarından biridir (Arı, 2019; Mohsen ve diğ., 2018). Nesne tanıma, ses tanıma, otomatik sistemler vb. birçok alanda kullanılmaktadır. Genel olarak kullanılan sınıflandırma, kümeleme ve bölütleme algoritmaları elde edilen verileri gürültü azaltma, normalleştirme, özellik çıkarma gibi ön işlemlerden geçirdikten sonra

kullanılmaktadırlar. Derin Öğrenme ise ham verileri herhangi bir ön işleme tabi tutmadan öğrenmeyi gerçekleştirir. Diğer algoritmalar ile derin öğrenme arasındaki en büyük fark olarak bu durum gösterilebilir.



Şekil 2.5. Derin sinir ağı modeli (Mohsen ve diğ., 2018)

Derin öğrenme YSA'nın bir modellemesi olması ve veri işleme yöntemi bakımından insan beyninin sınıflandırma, tanıma, öğrenme, karar verme, takip etme gibi becerilerini yerine getirebilen bir makine öğrenme algoritması olarak tanımlanabilir (Arı, 2019). Derin öğrenmede katman sayısının fazla olması katmanlar arasında öğrenmenin pekiştirilerek gerçekleştirilmesi sebebiyle daha iyi sonuçlar vermektedir. Diğer algoritmalara göre büyük veri setlerini işleyebilmesi ve karmaşık problemlerde yüksek başarı elde etmesi en büyük avantajı olarak gösterilebilir.

Derin öğrenmenin anlatılan avantajları yanı sıra her algoritmanın olduğu gibi dezavantajları da bulunmaktadır. Öncelikle eğitimin tam ve doğru bir şekilde gerçekleşmesi için büyük bir veri setine ihtiyaç duymaktadır. Veri seti ve derin öğrenme mimarisinin parametre sayısının fazla olması sebebiyle yüksek hesaplama gücüne sahip donanımlara ihtiyaç duymaktadır.

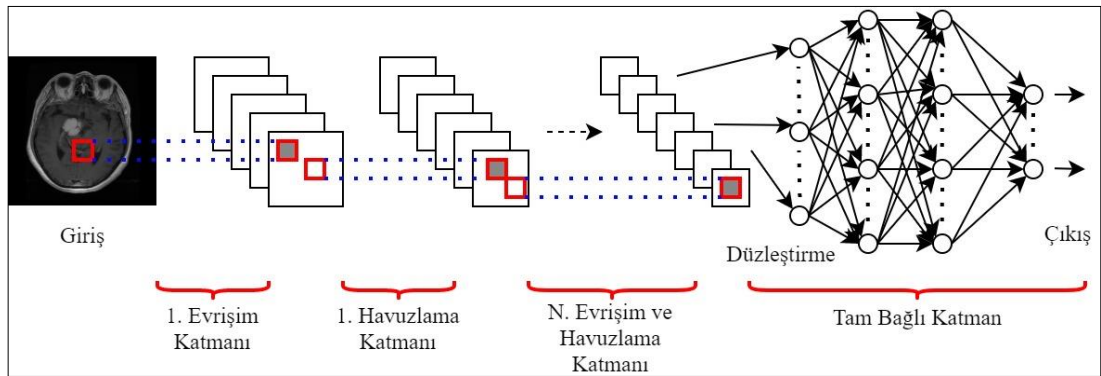
Derin öğrenmenin sınıflandırma, bölütleme, hastalık tespiti, nesne tanıma vb. kullanım alanına göre farklılık gösteren çeşitli yaklaşımları bulunmaktadır. En çok kullanılan derin öğrenme algoritmaları Evrişimsel Sinir Ağları (ESA), Derin Boltzman

Makineleri (DBM), Otomatik Kodlayıcılar, Derin İnanç Ağları (DİA) olarak gösterilebilir (Yamanakkanavar ve diğ., 2020).

### 2.6.1. Evrişimsel sinir ağı

Derin öğrenme mimarileri arasında ESA biyolojik görüntü sınıflandırma ve bölütleme alanındaki zorluklar karşısında gösterdiği performansından dolayı en çok kullanılan derin öğrenme algoritmasıdır (Işın ve diğ., 2016; Mohsen ve diğ., 2018). Derin öğrenme temeli 1950'ler öncesine dayanmakla birlikte ESA'nın gelişimi 1986 yılında Geoffrey Hinton (Rumelhart ve diğ., 1986) tarafından geri yayılım algoritmasının çok katmanlı ağlarda başarılı bir şekilde uygulanması ile başlamaktadır. Daha sonra 1998 yılında Yann LeCun ve arkadaşları tarafından el yazısı karakterlerinin ESA tarafından tanınabileceği ortaya konulmuştur (Lecun ve diğ., 1998). Sonraki yıllarda teknolojinin gelişmesi ve bilgisayar donanımlarının işlem kapasitelerinin artmasına bağlı olarak ESA alanındaki gelişmeler hızla devam etmiştir.

ESA mimarisi ileri beslemeli ağ yapısında birbirleri ile ilişkili farklı katmanlardan oluşmaktadır. ESA Şekil 2.5'teki gibi giriş katmanı, evrişim katmanı, havuzlama katmanı, tam bağlı katman ve çıkış katmanı olarak beş katmandan oluşmaktadır (Becerikli ve Altuntaş, 2021).



Şekil 2.6. Evrişimsel sinir ağı modeli (Bernal ve diğ., 2019)

ESA katmanları işlemleri ve aralarındaki ilişkiler aşağıda açıklanmıştır.

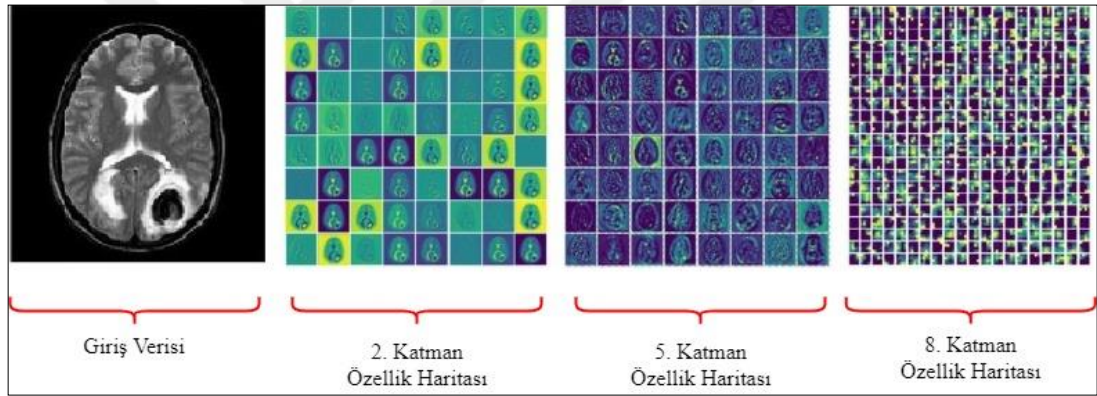
#### 2.6.1.1. Giriş katmanı

Mimarinin ilk katmanıdır. Veri bu katmana herhangi bir işleme tabi tutulmadan ham olarak verilir. Giriş yapılan verinin boyutu mimarinin başarımında ve hızında büyük

öneme sahiptir. Giriş verisinin çok büyük olması kullanılan bellek miktarının artmasına, eğitim ve test süresinin uzamasına sebep olabilir. Tam tersi olarak giriş verisinin küçük olması derinliğin azalmasına, çıkarılabilecek özellik sayısının azalmasına ve mimarinin başarımının düşmesine sebep olabilir. Bu sebeplerden dolayı giriş verisi hem sistem kaynakları hem de mimari göz önüne alınarak en uygun şekilde seçilmelidir.

### 2.6.1.2. Evrişim katmanı

Evrişim işlemi; giriş verisinin, ağırlıkları başlangıçta rastgele belirlenen, sayısı (32, 64, 128 vb.) ve boyutu (3x3, 5x5 vb.) ise önceden belirlenmiş filtreler ile evrişime (konvülyasyona) tabi tutulması işlemidir. Bu işlem ile giriş verisinden özellik haritası çıkarılmış olur. İşlem sonrasında verinin analizi kolaylaşmış olur (Güngen, 2020).

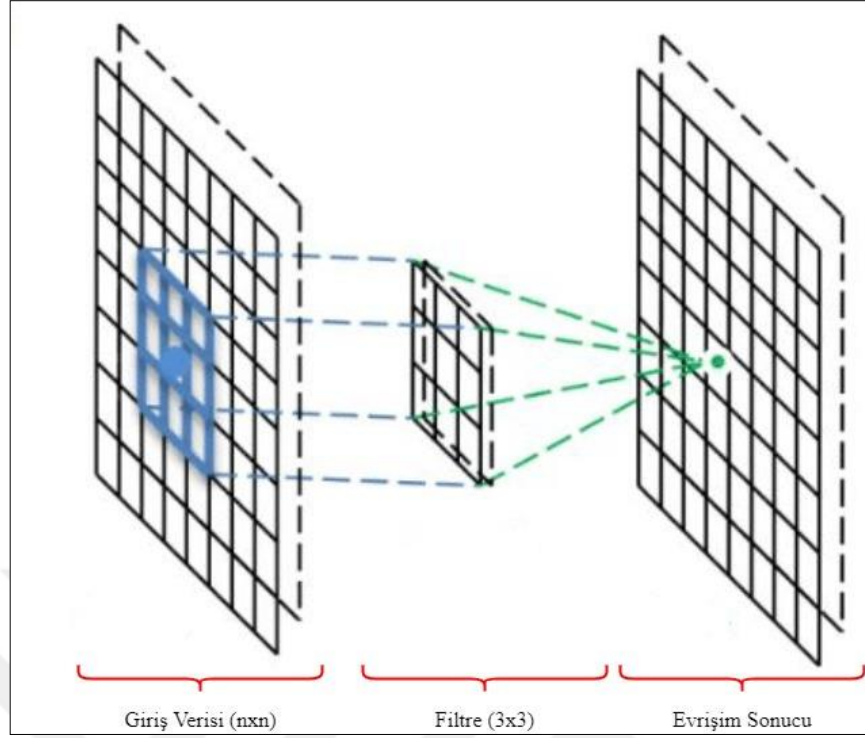


Şekil 2.7. Özellik Haritası (URL-6)

Evrişim işlemi,  $x$  giriş verisi ( $n \times n$  boyutunda),  $w$  filtre ( $3 \times 3$  boyutunda) olmak üzere Denklem (2.24)'te ki gibi tanımlanır.

$$x'_{i,j} = \sum_{k=1}^3 \sum_{l=1}^3 w_{(k,l)} x_{(i-k,j-l)} \quad (2.24)$$

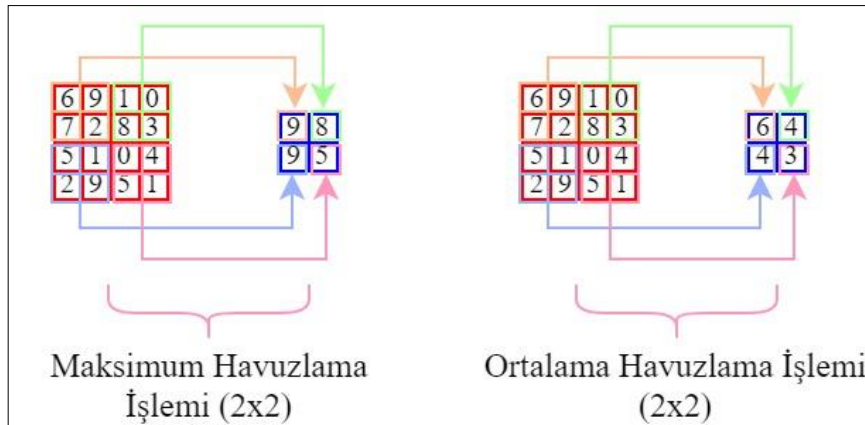
Evrişim işlemi sonucu mimarinin doğrusal olmasının önüne geçmek ve kararlılığını arttırmak için bir aktivasyon fonksiyonundan geçirilir. Bu aktivasyon fonksiyonları Yapay Sinir Ağları bölümünde anlatılan aktivasyon fonksiyonlarıdır. Aktivasyon fonksiyonu katmanlar arası sinir hücrelerinin bağımsızlığını arttırarak mimarinin istikrarlı bir şekilde çalışmasını sağlar (Arı, 2019). ESA mimarisinde sıklıkla Relu aktivasyon fonksiyonu kullanılmaktadır. Fonksiyonun işlem sayısını azaltması tercih sebebi olmasını sağlamıştır.



Şekil 2.8. Evrişim işleminin uygulanması (URL-5)

### 2.6.1.3. Havuzlama katmanı

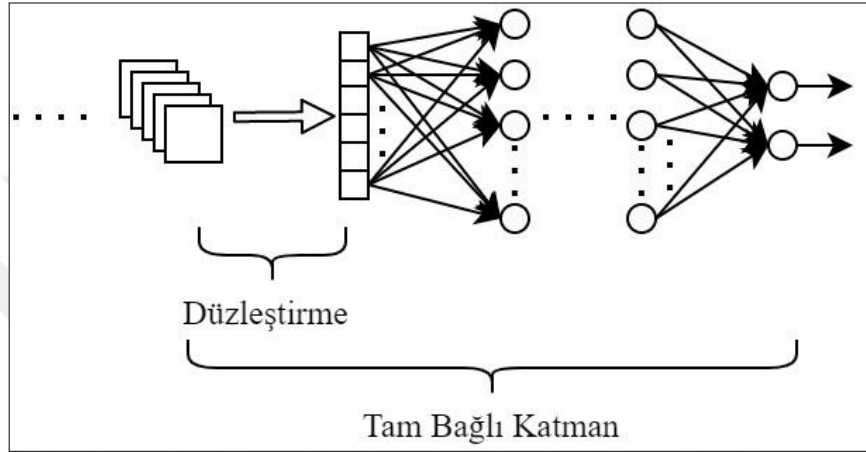
Havuzlama katmanı, özellik haritalarının boyutlarının azaltılmasını sağlar ve çıkarılan özellik haritasının sağlamlığını artırır. ESA içerisinde yaygın olarak evrişim katmanları arasında kullanılır. Bu katman sonucunda özellik haritasının boyutu belirlenen havuzlama adım sayısına göre oluşur. Havuzlama işlemi ortalama ve maksimum havuzlama olarak iki farklı şekilde uygulanır (Guo ve diğ., 2017). Havuzlama işleminde (2x2) adım sayısı ve maksimum havuzlama yöntemi en sık kullanılan yöntemdir.



Şekil 2.9. Havuzlama işleminin uygulanması (Jeong, 2019)

#### 2.6.1.4. Tam bağı katman

Tam bağı katman evrişimsel sinir ağı mimarisinin sınıflandırma kısmını oluşturan bir sinir ağıdır. Evrişim ve havuzlama katmanlarından sonra oluşan özellik haritası öncelikle bir düzleştirme işlemi ile sütun vektörü haline getirilir. Daha sonra elde edilen sütun vektörü bu kısımda oluşturulan sınıflandırıcı tam bağı sinir ağına giriş olarak verilir.



Şekil 2.10. Tam bağı katman (Jeong, 2019)

#### 2.6.1.5. Çıkış katmanı

ESA mimarisinin sonucunun alındığı katmandır. Genel hatanın hesaplandığı ve geri yayılımın başlatıldığı kısımdır. ESA çıkış katmanında genellikle Softmax aktivasyon fonksiyonu kullanılmaktadır. Kayıp fonksiyonu olarak ise Yapay Sinir Ağları bölümünde anlatılan kayıp fonksiyonları kullanılmaktadır.

### **3. DERİN ÖĞRENME YÖNTEMİ İLE BEYİN MR GÖRÜNTÜLERİNİN SINIFLANDIRMA VE BÖLÜTLEME UYGULAMASI**

#### **3.1. Geliştirilen Uygulamalar**

Yapılan bu tez çalışmasında beyin MR görüntülerinin sınıflandırılması, kümelenmesi ve bölütlenmesi için uygulanan bazı akıllı yöntemler araştırılmış, tanımlamaları yapılmış ve çalışma yöntemleri açıklanmaya çalışılmıştır. Bu yöntemlerden veri setinde ön işlem gerektirmemesi ve performansı göz önünde bulundurularak (Becerikli ve Altuntaş, 2021) bir derin öğrenme yöntemi olan Evrişimsel Sinir Ağı ile beyin MR görüntülerinin sınıflandırılması ve bölütlenmesi için üç farklı uygulama yapılmıştır.

İlk uygulama ile beyin MR görüntüleri tanımlanan bir ESA ile normal veya anormal olarak iki sınıfa ayrılmaya çalışılmıştır. İkinci uygulamada ise beyin MR görüntülerindeki tümörler türlerine göre sınıflandırılmaya çalışılmıştır. Üçüncü ve son uygulamada ise beyin MR görüntülerindeki tümörlerin tespiti için görüntüler bölütlenmeye çalışılmıştır.

#### **3.2. Kullanılan Veri Seti**

Tez kapsamında sınıflandırma uygulamalarında kullanılan veri setleri Kaggle arşivinde yer alan Beyin Tümörü Tespiti için Beyin MR Görüntüleri veri seti (URL-2) ve Beyin Tümörü Sınıflandırması (MR) veri setidir (URL-3). Veri setleri jpg formatında axial, sagittal, coronal görünümünde, T1, T2 ve Flair kontrast ağırlıklarında MR görüntüleri içermektedir. İlk veri seti görüntüleri normal ve anormal olmak üzere iki sınıf halinde ayrılmaktadır. İkinci veri setinde ise MR görüntüleri tümör olmayan ve üç farklı tümör türü olarak dört sınıfa ayrılmaktadır.

Kullanılan üçüncü veri seti ise Figshare arşivinde yer alan Beyin Tümör veri setidir (URL-4). Veri seti 512x512 çözünürlükte T1 kontrast ağırlığında MR görüntüleri içermektedir. Veri seti farklı tümör türlerine sahip 233 hastadan alınmış toplam 3064 MR görüntüsü içermektedir.



### 3.3. Uygulama Geliştirme Ortamı

Geliştirilen uygulamalar Python programlama dili ile geliştirilmiştir. Python, nesne yönelimli, modüler ve yüksek seviyeli bir programlama dilidir. 1990 yılında Guido van Rossum tarafından geliştirilmeye başlanmıştır. Kolay öğrenilebilir olması ve birçok alanda kütüphanelere sahip olması kullanımını artırmıştır. Hemen hemen bütün platformlarda çalıştırılabilen açık kaynak koduna sahiptir. Tensorflow, PyTorch, Keras, Numpy gibi yapay zekâ ve görüntü işleme alanında kullanılan kütüphanelere sahiptir (URL-8).

Tasarlanan ESA mimarilerinin eğitimi Google Colab üzerinde yapılmıştır. Colab, web sayfası üzerinden kod yazılmasına ve yazılan kodların yürütülmesine olanak sağlayan etkileşimli bir ortam olarak tanımlanmaktadır. Google Colab üzerinde Python kütüphaneleri çalıştırılabilmekte ve ücretsiz olarak GPU desteği sağlanmaktadır (URL-11). Keras, Tensorflow, PyTorch gibi kütüphanelerin kullanılabilmesi sayesinde derin öğrenme uygulamaları geliştirilebilmekte ve ESA mimarileri gibi derin öğrenme mimarilerinin eğitimleri kısa sürede tamamlanmaktadır.

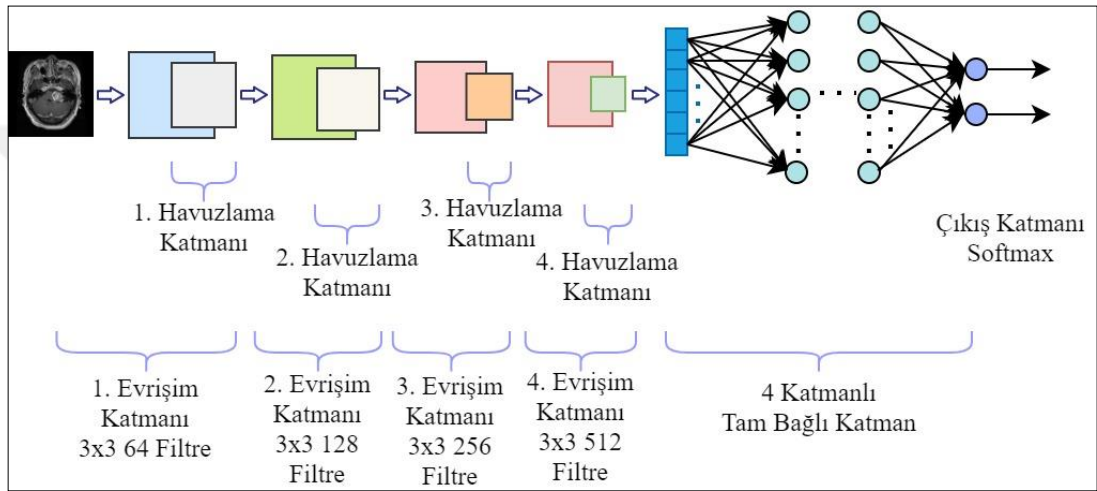
### 3.4. Uygulama 1: Beyin MR Görüntülerinin Normal veya Anormal Olarak Sınıflandırılması

Yapılan bu çalışmada VGG-16 (Kaur ve Gandhi, 2019) modeli baz alınarak bir ESA modeli tasarlanmıştır. Tasarlanan model ile beyin MR görüntüleri otomatik bir şekilde normal veya anormal olarak sınıflandırılmıştır. Model yapısı şekil Şekil 3.1’de gösterildiği gibi dört evrişim ve havuzlama katmanından ve dört katmanlı tam bağlı katmandan oluşmaktadır. Modelde evrişim katmanlarında aktivasyon fonksiyonu olarak Relu kullanılmaktadır. Havuzlama katmanında ise 2x2 adım ile maksimum havuzlama yapılmaktadır.

Birinci evrişim katmanında, giriş görüntüsü 224x224 çözünürlükte alınarak 3x3 boyutunda 64 adet filtre ile evrişime tabi tutulmaktadır. Evrişim işlemi sonrasında havuzlama yapılarak 112x112 boyutunda 64 adet ilk özellik haritası elde edilmektedir.

İkinci evrişim katmanında, birinci katmandan gelen 64 adet özellik haritası 3x3 boyutunda 128 adet filtre ile evrişim ve havuzlama işlemine tabi tutularak 56x56 boyutunda 128 adet ikinci özellik haritası oluşturulmaktadır.

Üçüncü ve dördüncü evrişim katmanlarında da bir önceki katmandan alınan özellik haritası 3x3 boyutunda sırası ile 256 adet ve 512 adet filtre ile evrişime tabi tutularak havuzlama yapılmaktadır. Dördüncü havuzlama sonrasında 14x14 boyutunda 512 adet özellik haritası çıkarılmaktadır.



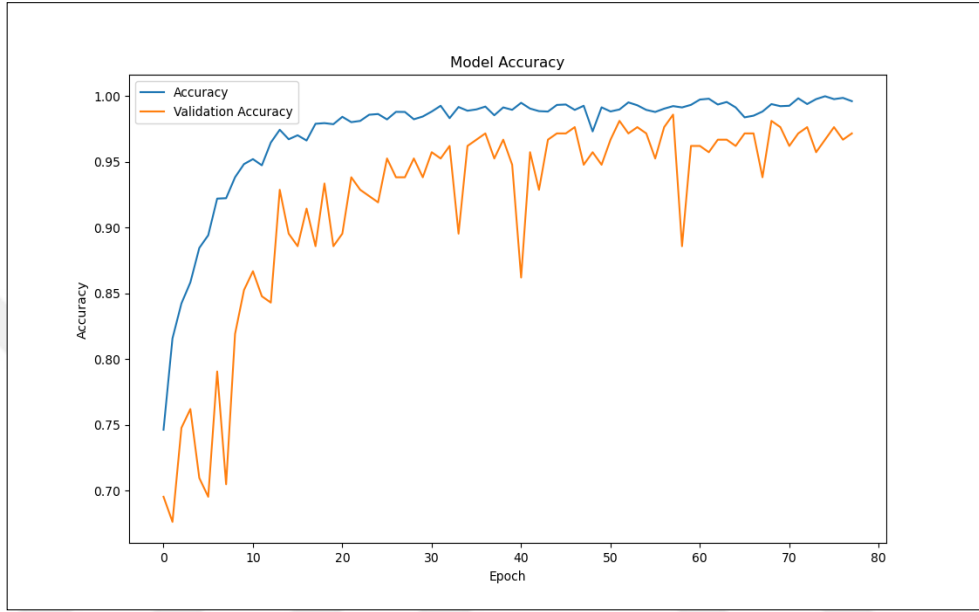
Şekil 3.1. Tanımlanan ESA modeli

Evrişim işlemi sonrası elde edilen özellik haritası düzleştirme işlemi ile sütun vektörüne dönüştürülerek modelin devamı olan 4 katmanlı tam bağlı sınıflandırıcı sinir ağına giriş olarak verilmektedir. Tam bağlı katmanın birinci katmanında 1024, ikinci ve üçüncü katmanında 2048, dördüncü katmanında 1024 adet sinir hücresi bulunmaktadır. Her katman arasında ezberlemenin engellenmesi için 0.3 katsayı ile Dışlama (Dropout) fonksiyonu kullanılmaktadır.


Çıkış katmanında iki çıkış bulunmakta ve aktivasyon fonksiyonu olarak Softmax kullanılmaktadır.

Modelin eğitiminde kayıp fonksiyonu olarak Çapraz Entropi fonksiyonu (categorical\_crossentropy) kullanılmaktadır. Geri yayılım algoritması olarak 0.0005 eğitim adımı ile Adam optimizasyon algoritması kullanılmaktadır.

Modelin eğitimi sonucunda %99 doğruluk oranına ulaşılmaktadır. Öğrenme Şekil 3.2 ve Şekil 3.3'teki doğruluk ve kayıp grafiklerinde de görüldüğü üzere hızlı bir şekilde gerçekleşmektedir. Eğitim ve test verisi dışında olması düşünülerek ikinci veri setinden alınan 200 MR görüntüsü ile yapılan doğrulama testi sonucunda %100 doğrulukla sınıflandırma yapılmaktadır.



Şekil 3.2. Uygulama 1 ESA modeli eğitim sonucu doğruluk grafiği



Şekil 3.3. Uygulama 1 ESA modeli eğitim sonucu kayıp grafiği

### 3.5. Uygulama 2: Beyin MR Görüntülerinin Tümör Türlerine Göre Sınıflandırılması


İkinci çalışmada Uygulama 1 geliştirilerek herhangi bir hastalığı olmayan normal MR görüntüleri ile glioma, meninglioma ve hipofiz tümörü olarak üç farklı tümör türünü içeren beyin MR görüntüleri arasında sınıflandırma yapılmıştır. Sınıflandırma yapılırken model üzerinde evrişim katmanı sayıları ve kullanılan filtre sayıları değiştirilerek dört farklı durumda eğitim gerçekleştirilmiş ve doğrulama yapılmıştır. Bu sayede evrişim ve filtre sayılarının sınıflandırma performansına katkısı görülmeye çalışılmıştır.

Model, içerisinde tümör olmayan, glioma, meninglioma ve hipofiz tümörü bulunan 500'er adet eğitim ve 200'er adet test MR görüntüsü içeren veri seti ile eğitilmiştir. Modelin eğitiminde çıkış aktivasyon fonksiyonu Softmax, kayıp fonksiyonu Çapraz entropi (categorical\_crossentropy) ve geri yayılım algoritması için Adam optimizasyon algoritması kullanılmıştır.


Doğrulama için iki farklı veri seti oluşturulmuştur. Birinci veri setinde her bir sınıftan 100 MR görüntüsü, ikinci veri setinde ise farklı sınıf sayılarında toplam 3064 MR görüntüsü bulunmaktadır.

Durum 1: Model, Uygulama 1'deki şekli ile kullanılmış sadece çıkış katmanı tümör türlerinin farklı sınıflarını temsil edebilmesi için dört çıkış olarak değiştirilmiştir. Modelin eğitimi 11 dakikada tamamlanmıştır. Eğitim sonucu %98 doğruluk oranına ulaşılmaktadır. Şekil 3.4'teki doğruluk ve Şekil 3.4'teki kayıp grafiklerinde öğrenmenin hızlı bir şekilde gerçekleştiği görülmektedir.

Doğrulama verileri ile yapılan doğrulama sonucu tahmin süresi bir MR görüntüsü için ortalama 0,875 saniyede tamamlanmaktadır. Tahmin sonucu birinci veri setinde %100 ikinci veri setinde %96 doğruluk elde edilmiştir.




Şekil 3.4. Durum 1 eğitim sonucu doğruluk grafiği




Şekil 3.5. Durum 1 eğitim sonucu kayıp grafiği

Durum 2: Modele bir evrişim katmanı daha eklenmiş evrişim sayısı dörtten beşe çıkarılmış ve beşinci evrişim katmanında filtre sayısı 1024 olarak kullanılmıştır. Eğitim süresi Durum 1'e göre biraz daha uzayarak 12 dakikada tamamlanmıştır. Eğitim sonucu %99 doğruluk oranına ulaşılmaktadır. Şekil 3.6'daki doğruluk ve Şekil 3.7'deki kayıp grafiklerinde öğrenmenin hızlı bir şekilde gerçekleştiği görülmektedir. Doğrulama verisi ile yapılan doğrulama sonucu tahmin süresi bir MR görüntüsü için ortalama 0,0775 saniye sürmektedir. Tahmin sonucu birinci veri setinde %100 ikinci veri setinde %96 doğruluk elde edilmiştir.




Şekil 3.6. Durum 2 eğitim sonucu doğruluk grafiği




Şekil 3.7. Durum 2 eğitim sonucu kayıp grafiği

Durum 3: Modelde evrişim sayısı Uygulama 1 ile aynı tutulmuş (dört evrişim) filtre sayısı ise birinci evrişim katmanından dördüncü evrişim katmanına kadar iki katına çıkarılmıştır. Bu sayede filtre sayısındaki değişimin modelin eğitim sırasındaki ve eğitim sonrası tahmin performansına etkisi görülmeye çalışılmıştır. Modelin eğitim süresi 12 dakikada tamamlanmıştır. Eğitim sonucu %99 doğruluk oranına ulaşılmaktadır. Şekil 3.8'deki doğruluk ve Şekil 3.9'daki kayıp grafiklerinde öğrenmenin gerçekleşme hızı görülmektedir.

Doğrulama verisi ile yapılan doğrulama sonucu tahmin süresi bir MR görüntüsü için ortalama 0,1875 saniye sürmüş sonuç olarak birinci veri setinde %100 ikinci veri setinde %97 doğruluk elde edilmiştir.



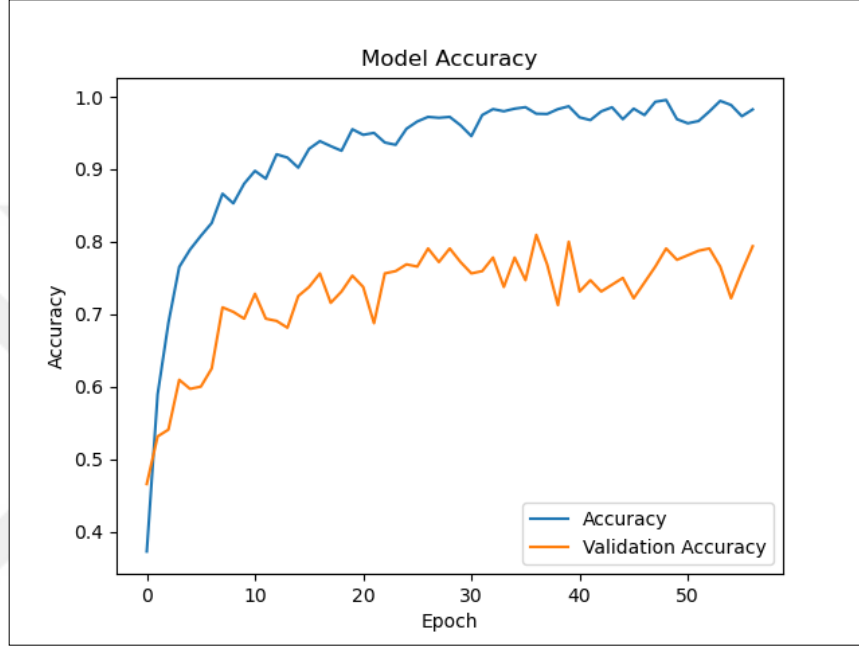
Şekil 3.8. Durum 3 eğitim sonucu doğruluk grafiği




Şekil 3.9. Durum 3 eğitim sonucu kayıp grafiği

Durum 4: Modele Durum 3'e ek olarak 1024 adet filtre ile bir evrişim katmanı daha eklenmiştir. Burada ise hem evrişim katmanındaki hem de filtre sayısındaki artışın

modelin performansına etkisi görülmeye çalışılmıştır. Eğitim sonucu %99 doğruluk oranına ulaşılmaktadır. Şekil 3.10'daki doğruluk ve Şekil 3.11'deki kayıp grafiklerinde öğrenmenin gerçekleşme hızı görülmektedir. Doğrulama verisi ile yapılan doğrulama sonucu tahmin süresi bir MR görüntüsü için ortalama 0,1325 saniye sürmüş sonuç olarak birinci veri setinde %100 ikinci veri setinde %96 doğruluk elde edilmiştir.



Şekil 3.10. Durum 4 eğitim sonucu doğruluk grafiği



Şekil 3.11. Durum 4 eğitim sonucu kayıp grafiği




Tanımlanan dört modelde de yüksek derecede başarımlık sağlandığı görülmüştür. Evrişim sayısının ve filtre sayısının artırılması doğruluk oranında gözle görülür bir değişiklik oluşturmazken eğitim süresi ve tahmin süresini uzattığı görülmektedir.

### 3.6.Uygulama 3: Beyin MR Görüntülerinin Bölütlenmesi ile Tümör Tespiti

İlk iki uygulamamızda beyin MR görüntüleri öncelikle normal veya anormal olarak arkasından anormal görüntülerdeki tümörler üç farklı tümör türüne göre sınıflandırıldı. Üçüncü uygulamada ise önceki uygulamalardan farklı olarak U-Net (Dong vd., 2017) ESA modeli ile beyin MR görüntülerinin bölütlenmesi sağlanarak MR görüntüsündeki tümörün yeri tespit edilmeye çalışılmıştır.

U-Net mimarisi Freiburg Üniversitesi Bilgisayar Bilimleri Bölümünde geliştirilmiştir. 2015 yılında U-Net: Biyomedikal Görüntü Bölütlemesi için Evrişimli Ağlar (Ronneberger ve diğ., 2015) makalesi ile Olaf Ronneberger, Philipp Fischer, Thomas Brox tarafından duyurulmuştur. Mimari Şekil 3.12’de görüldüğü gibi sıkıştırma ve genişletme olarak iki bölümden oluşur. Modelin yapısı gereği tam bağlı katmanları bulunmaz.



Şekil 3.12. U-Net mimarisi (Ronneberger ve diğ., 2015)


İlk bölümde giriş görüntüsü bir dizi evrişim ve havuzlama işlemine tabi tutulur. Böylece özellik haritaları çıkarılmış olur. İkinci bölümde ise havuzlama işlemi ile boyutu küçülen özellik haritaları boyut artırma işlemi uygulanarak giriş verisi ile aynı olacak şekilde büyütülür. Aynı zamanda birinci bölümdeki özellik haritaları da burada yeni oluşturulan özellik haritaları birleştirilir. Bu sayede birinci kısımdan gelen özelliklerin kaybolmasının önüne geçilmiş olur. Ardından evrişim işlemleri ile mimari tamamlanır.

Modelin eğitiminde farklı tümör türlerine sahip 3064 adet MR görüntüsü içeren veri seti kullanılmıştır. Uygulama için oluşturulan model de çıkış katmanında Softmax aktivasyon fonksiyonu, kayıp fonksiyonu olarak Çapraz entropi (sparse\_categorical\_crossentropy) fonksiyonu ve geri yayılım algoritması için Adam optimizasyon algoritması kullanılmıştır. Model aşağıda açıklanan durumda eğitilmiş ve doğrulaması sağlanmıştır.


Tanımlanan modelin birinci bölümünde diğer bir deyişle sıkıştırma bölümünde dört katman uygulanmış ve her katmanda bir evrişim katmanı ve bir havuzlama katmanı tanımlanmıştır. Giriş katmanından başlanarak filtre sayısı 64, 128, 256 ve 512 olarak uygulanmıştır. İkinci bölümde yani genişletme bölümünde yine dört katman uygulanmış ve her katmanda bir evrişim, bir boyut artırma arkasından ikinci evrişim katmanı uygulanmıştır. Filtre sayıları ilk katmanın tersi olarak 512, 256, 128 ve 64 adet olarak uygulanmıştır.

Modelin parametre sayısı diğer tanımlanan modellerden çok daha fazla olması sebebiyle eğitim süresi daha uzun sürmüştür. Modelin eğitimi yaklaşık 60 dakikada tamamlanmıştır. Eğitim sonucunda Şekil 3.13'teki doğruluk ve 3.14'teki kayıp grafiklerinde de görüldüğü gibi öğrenme hızlı bir şekilde gerçekleşmiş ve %98 doğruluk elde edilmiştir.


Model iki farklı veri seti ile doğrulanmış MR görüntüsündeki tümör bölgesi yüksek bir başarıyla tespit edilmiştir. İki farklı veri seti ile yapılan tahmin sonuçları Şekil 3.15'te ve 3.16'da görülmektedir. Şekillerde (a) kısmında orijinal MR görüntüsü, (b) kısmında önceden belirlenmiş ve işaretlenmiş tümör ve (c) kısmında ise modelimizin eğitimi sonrasında yapılan tahmin sonucu belirlediği tümör görülmektedir.




Şekil 3.13. U-Net modeli eğitim sonucu doğruluk grafiği



Şekil 3.14. U-Net modeli eğitim sonucu kayıp grafiği



Şekil 3.15. Birinci veri seti bölütleme sonucu (a: Orijinal MR görüntüsü, b: Beklenen ESA sonucu, c: Tanımlanan ESA tahmin sonucu)



Şekil 3.16. İkinci veri seti bölütleme sonucu (a: Orijinal MR görüntüsü, b: Beklenen ESA sonucu, c: Tanımlanan ESA tahmin sonucu)

#### 4. SONUÇLAR VE ÖNERİLER

Beyin MR görüntülerinin akıllı yöntemler ile sınıflandırma, kümeleme ve bölütlenmesi beyinde oluşan herhangi bir hastalık belirtisinin analizini kolaylaştırmaktadır. Bu yöntemlerle geliştirilmiş bilgisayar destekli otomatik bir sistem hem hastalığın tanı sürecini kısaltmakta hem de uzmanlık gerektirecek durumlarda kolaylık sağlamaktadır. Bu sebepler göz önüne alındığında zamanın ve insan kaynağının daha verimli kullanılması için beyin MR görüntülerinin analizi önemli bir araştırma alanı haline gelmiştir.

İncelenen algoritmalarından K-En Yakın Komşuluk (K-NN), Destek Vektör Makinesi (SVM) ve Yapay Sinir Ağı (YSA) algoritmaları birçok sınıflandırma çalışmasında kullanılmış ve başarılı sonuçlar elde edilmiştir. Algoritmaların hızlı çalışmaları, tutarlı ve yüksek doğruluk sağlamaları önemli avantajlarını oluşturmaktadır. Algoritmaların en önemli dezavantajı sınıflandırma işlemi öncesi veri hazırlama aşamasına ihtiyaç duyulmasıdır. Başarılı bir sınıflandırma işlemi için öncelikle bir öznitelik çıkarımı yapılması gerekmektedir. Çıkarılan öznitelik haritası ne kadar iyi olursa algoritmaların başarımı da buna bağlı olarak yükselmektedir.

K-Ortalama ve Bulanık C-Ortalama algoritmalarının kümeleme ve bölütleme çalışmalarında başarılı sonuçlar verdiği görülmektedir. Büyük veri setlerinde kullanılabilirliği ve hızlı sonuç vermeleri en önemli avantajları olarak öne çıkmaktadır. Bu sebeple beyin MR görüntülerinin analizinde sıklıkla kullanılmaktadırlar. Algoritmaların bir önceki bölümde bahsedilen öznitelik çıkarımına ihtiyaç duymaları, K ve C sayılarının optimum olarak belirlenmesi gerekliliği en önemli dezavantajlarını oluşturmaktadır.

Derin Öğrenme yöntemi ise sınıflandırma, kümeleme ve bölütleme alanlarının tamamında kullanılmaktadır. Görüntü analizinde veride herhangi bir ön işlem yapılmasına ihtiyaç duymaması yöntemin en önemli avantajını oluşturmaktadır. Diğer algoritmalara göre büyük veri setlerinde kullanılabilirliği, esnek yapıda olmaları ve

hata toleransları diğer avantajlarını oluşturmaktadır. Yöntemin en büyük dezavantajı eğitimlerinin uzun sürmesi ve eğitim için büyük veri setine ihtiyaç duymalarıdır.

Tez çalışması kapsamında yapılan literatür araştırmasında derin öğrenme yöntemi kullanılarak yapılan çalışmalarda diğer algoritmalarla yapılan çalışmalara göre daha başarılı sonuçlar alındığı gözlemlenmiştir. Bu sebeple yapılan sınıflandırma ve bölütleme uygulamalarında bir derin öğrenme yöntemi olan Evrişimsel Sinir Ağı (ESA) modeli kullanılmıştır. ESA çözümlenecek problemi bir bütün olarak görmekte ve uçtan uca bir çözüm sunmaktadır.

Tez çalışmasında beyin MR görüntülerinin sınıflandırılması ve bölütlenmesi amacı ile üç farklı uygulama geliştirilmiştir.

İlk uygulama da beyin MR görüntülerini normal veya anormal olarak iki sınıfa ayıran bir ESA modeli tanımlamıştır. Modelin eğitimi Kaggle arşivinden alınan bir veri seti ile yapılmıştır. Eğitim sonrasında yapılan doğrulamada %100 başarımla elde edilmiştir. Modelin başarımla literatürdeki diğer algoritmalar ile karşılaştırıldığında daha başarılı olduğu görülmüştür.

İkinci uygulama olarak beyin MR görüntülerindeki tümör türlerinin sınıflandırılması amaçlanmıştır. Problemin çözümü için farklı bir ESA modeli tanımlanmıştır. Tanımlanan model ile normal, glioma, meninglioma ve hipofiz tümör türleri içeren beyin MR görüntüleri sınıflandırılmıştır. Model içerisinde yapılan dört farklı değişiklik ile sınıflandırma başarımlarının değişimi izlenmiştir. Eğitim sonrası iki farklı veri seti ile doğrulama gerçekleştirilmiştir. Sonuç olarak iki veri setinde de %96 ve üzerinde başarımla elde edilmiştir. Model içerisinde yapılan değişikliklerin başarımlarının değişimine fazla etkisi olmadığı ancak artan parametre sayısı sebebi ile tahmin süresinde uzamaya neden olduğu görülmüştür. Modelin başarımlarının diğer algoritmalarla yapılan tümör türlerinin sınıflandırılması çalışmaları ile karşılaştırıldığında daha başarılı olduğu belirlenmiştir.

Üçüncü uygulamada ise ilk iki uygulamadan farklı olarak beyin MR görüntüsündeki tümörün yerinin tespit edilmesi amaçlanmıştır. Burada çözüm için bir ESA modeli olan U-Net modeli kullanılmıştır. Eğitim sonucunda %98 doğruluğa ulaşılmıştır. Yapılan testler sonucunda tümörün yerinin belirlenmesinde yüksek derecede başarımla

elde edilmiştir. Görüntülerin bölütlenmesinde ESA modeli veride ön işlem yapılmasına gerek duymaması, kolay uygulanabilmesi, hızlı sonuçlar vermesi ve yüksek başarıma ulaşması ile ön plana çıkmaktadır.

Tez kapsamında yapılan araştırmalar ve uygulamalar sonucunda ESA modelinin diğer algoritmalara göre daha başarılı olduğu görülmüştür. Birinci ve ikinci uygulama olan sınıflandırma uygulamalarında, kullanılan veri setleri ile yapılan testlerde literatürdeki diğer algoritmalara göre ESA modelinin başarımının daha yüksek olduğu tespit edilmiştir. Uygulamalarda baz alınan VGG16 mimarisine göre daha az evrişim katmanı ile yaklaşık aynı başarıma ulaşılmıştır. Üçüncü uygulama olan bölütleme uygulamasında U-Net mimarisi uygulanmış ve yüksek derecede başarımlar elde edilmiştir.

Kullanılan veri setleri ile yapılan testler sonucunda tanımlanan ESA modelleri ile daha önce yapılan çalışmalara yaklaşık sonuçlar alınmıştır. Fakat farklı veri setleri ile eğitimlerin yapılması ve test edilmesi daha objektif sonuçlar almamızı sağlayacaktır. Ayrıca oluşturulan modellerin farklı varyasyonları kullanılarak daha iyi sonuçlar elde edilebilecektir. ESA mimarisinin eğitimi için gerekli olan teknolojik donanım geliştirilerek daha büyük veri setleri işlenebilir. Bu sayede elde edilecek sonuçlarda da iyileşme sağlanacağı düşünülmektedir.



## KAYNAKLAR

Alan A., Bulanık Sınıflandırma ile Beyin MR Görüntülerinde Tümör Tespiti, Yüksek Lisans Tezi, Kocaeli Üniversitesi, Fen Bilimleri Enstitüsü, Kocaeli, 2010, 283039.

Altay O., Genetik ve Genetik Olmayan Faktörlere Bağlı Olarak Türk Hastalarda Varfarin Dozajını Tahmin Eden Bir Uzman Sistem Geliştirilmesi, Yüksek Lisans Tezi, Fırat Üniversitesi, Fen Bilimleri Enstitüsü, Elâzığ, 2016, 424199.

Arı A., Derin Öğrenme Tabanlı Beyin MR Görüntülerinden Beyin Tümörlerinin Tespit Edilmesi ve Sınıflandırılması, Doktora Tezi, İnönü Üniversitesi, Fen Bilimleri Enstitüsü, Malatya, 2019, 572295.

Bali A., Singh S. N., A Review on the Strategies and Techniques of Image Segmentation, *2015 Fifth International Conference on Advanced Computing & Communication Technologies*, DOI: 10.1109/ACCT.2015.63.

Banchpalliwar R. A., Salankar S. S., A Review on Brain MRI Image Segmentation Clustering Algorithm, *IOSR Journal of Electronics and Communication Engineering*, 2016, **11**(1), 80-84.

Becerikli Y., Altuntaş F., Beyin MR Görüntülerinin Derin Öğrenme ile Sınıflandırılması, Kümelenmesi ve Bölütlenmesi, *Uluslararası Akademik Araştırmalar Kongresi*, Çevrimiçi, Türkiye, 19-21 Nisan 2021.

Bernal J., Kushibar K., Asfaw D. S., Valverde S., Oliver A., Martí R., Lladó X., Deep convolutional neural networks for brain image analysis on magnetic resonance imaging: A review. *Artificial Intelligence in Medicine*, 2019, 95, 64-81, DOI: 10.1016/j.artmed.2018.08.008.

Cantemir Z., Derin Öğrenme Yöntemleriyle Medikal Görüntü Sınıflandırma, Yüksek Lisans Tezi, Gazi Üniversitesi, Fen Bilimleri Enstitüsü, Ankara, 2019, 572384.

Cengil E., Çınar A., Özbay E., Image Classification With Caffe Deep Learning Framework, *2017 International Conference on Computer Science and Engineering (UBMK)*, DOI: 10.1109/UBMK.2017.8093433.

Chouhan S. S., Kaul A., Singh U. P., Image Segmentation Using Computational Intelligence Techniques: Review, *Archives of Computational Methods in Engineering*, DOI: 10.1007/s11831-018-9257-4.

Dhanachandra N., Manglem K., Chanu Y. J., Image Segmentation Using K -means Clustering Algorithm and Subtractive Clustering Algorithm, *Procedia Computer Science*, 2015, **54**, 764-771, DOI: 10.1016/j.procs.2015.06.090.

Dong H., Yang G., Liu F., Mo Y., Guo Y., Automatic Brain Tumor Detection and Segmentation Using U-Net Based Fully Convolutional Networks, Editors: Valdés Hernández M., González-Castro V., *Medical Image Understanding and Analysis*, 1nd ed., Springer International Publishing, 506-517, 2017.

Fasihi M. S., Mikhael W. B., Overview of Current Biomedical Image Segmentation Methods, *2016 International Conference on Computational Science and Computational Intelligence (CSCI)*, 2016, DOI: 10.1109/CSCI.2016.0156.

Guo T., Dong J., Li H., Gao Y., Simple Convolutional Neural Network on Image Classification. *2017 IEEE 2nd International Conference on Big Data Analysis (ICBDA)*, 2017, DOI: 10.1109/ICBDA.2017.8078730.

Güngen C., Beyin Tümörlerinin Derin Öğrenme ile Manyetik Rezonans Görüntülerinden Sınıflandırılması, Yüksek Lisans Tezi, Sivas Cumhuriyet Üniversitesi, Fen Bilimleri Enstitüsü, Sivas, 2020, 636979.

Herek D., Karabulut N., Manyetik Rezonans Görüntüleme, *TTD Toraks Cerrahisi Bülteni*, Eylül 2010, **1** (3).

Işık M., Çamurcu A. Y., K-Means, k-Medoids ve Bulanık C-Means Algoritmalarının Uygulamalı Olarak Performanslarının Tespiti, *İstanbul Ticaret Üniversitesi Fen Bilimleri Dergisi*, 2007, **6** (13), 31-45.

Işın A., Direkoğlu C., Şah M., Review of MRI-based Brain Tumor Image Segmentation Using Deep Learning Methods, *Procedia Computer Science*, 2016, DOI: 10.1016/j.procs.2016.09.407.

Jeong J., The Most Intuitive and Easiest Guide for CNN, Towards Data Science, <https://towardsdatascience.com/the-most-intuitive-and-easiest-guide-for-convolutional-neural-network-3607be47480>, (Ziyaret tarihi: 15 Nisan 2021).

Kaur T., Gandhi T. K., Automated Brain Image Classification Based on VGG-16 and Transfer Learning, *2019 International Conference on Information Technology (ICIT)*, 2019, DOI: 10.1109/ICIT48102.2019.00023.

Keziban M., Bazı Bitki Uçucu Yağlarının in Vitro Gerçek Sindirilebilirlik, Bakteri ve Protozoa Sayısına Etkileri Bakımından Hiyerarşik Kümeleme Yöntemleriyle Sınıflandırılması, Yüksek Lisans Tezi, Çukurova Üniversitesi, Fen Bilimleri Enstitüsü, Adana, 2010, 266158.

Khalid I. R., Pal N., Arora K., Clustering of Image Data Using K-Means and Fuzzy K-Means, *International Journal of Advanced Computer Science and Applications*, 2014, DOI: 10.14569/IJACSA.2014.050724.

Kılıç İ., Beyin Tümörü Tespiti için Derin Öğrenme ile MR Görüntülerinin Bölütlenmesi, Yüksek Lisans Tezi, Atatürk Üniversitesi, Fen Bilimleri Enstitüsü, Erzurum, 2019, 536887.

Koşan M. A., Coşkun A., Karacan H., Yapay Zekâ Yöntemlerinde Entropi, *Bilişim Sistemleri ve Yönetim Araştırmaları Dergisi*, 2019, **1** (1), 15-21.

Kumar S., Dabas C., Godara S., Classification of Brain MRI Tumor Images: A Hybrid Approach, *Procedia Computer Science*, 2017, **122**, 510-517.

Lecun Y., Bottou L., Bengio Y., Haffner P., Gradient-Based Learning Applied to Document Recognition, *Proceedings of the IEEE*, 1998, **86** (11), 2278-2324.

Lee L. K., Liew S. C., Thong W. J., A Review of Image Segmentation Methodologies in Medical Image, Editors: Sulaiman, H. A., Othman, M. A., Othman, M. F. I., Rahim, Y. A., Pee, N. C., *Advanced Computer and Communication Engineering Technology*, 1st ed., Springer International Publishing, 1069-1080, 2014.

Liu J., Pan Y., Li M., Chen Z., Tang L., Lu C., Wang J., Applications of Deep Learning to MRI Images: A Survey, *Big Data Mining and Analytics*, DOI: 10.26599/BDMA.2018.9020001.

Lu D., Weng Q., A Survey of Image Classification Methods and Techniques for Improving Classification Performance, *International Journal of Remote Sensing*, 2007, **28** (5), 823-870.

Miranda E., Aryuni M., Irwansyah E., A Survey of Medical Image Classification Techniques, *2016 International Conference on Information Management and Technology (ICIMTech)*, DOI: 10.1109/ICIMTech.2016.7930302.

Mohsen H., El-Dahshan E. A., El-Horbaty E. M., Salem A. M., Classification Using Deep Learning Neural Networks for Brain Tumors, *Future Computing and Informatics Journal*, 2018, **3**(1), 68-71.

Mulla M. Z., Cost, Activation, Loss Function|| Neural Network|| Deep Learning. What are these?, Medium, <https://medium.com/@zeeshanmulla/cost-activation-loss-function-neural-network-deep-learning-what-are-these-91167825a4de>, (Ziyaret tarihi: 10 Ocak 2021)

Nandpuru H. B., Salankar S. S., Bora V. R., MRI Brain Cancer Classification Using Support Vector Machine, *2014 IEEE Students' Conference on Electrical, Electronics and Computer Science*, DOI: 10.1109/SCEECS.2014.6804439.

Nilakant R., Menon H. P., Kumar V., A Survey on Advanced Segmentation Techniques for Brain MRI Image Segmentation, *International Journal on Advanced Science, Engineering and Information Technology*, 2017, **7** (4), 1448-1456.

Omran M. G. H., Engelbrecht A. P., Salman A., An Overview of Clustering Methods, *Intelligent Data Analysis*, 2007, **11** (6), 583-605.

Polat R., Biyomedikal Görüntü Bölütleme, Yüksek Lisans Tezi, Fırat Üniversitesi, Fen Bilimleri Enstitüsü, Elazığ, 2007, 212137.

Rajini N. H., Bhavani R., Classification of MRI Brain Images Using K-Nearest Neighbor and Artificial Neural Network, *2011 International Conference on Recent Trends in Information Technology (ICRTIT)*, DOI: 10.1109/ICRTIT.2011.5972341.

Ronneberger O., Fischer P., Brox T., U-Net: Convolutional Networks for Biomedical Image Segmentation, Editors: Navab, N., Hornegger, J., Wells, W. M., Frangi, A. F., *Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015*, 3rd Part, Springer, 234-241, 2015.

Rumelhart D. E., Hintont G. E., Williams R. J., Learning representations by back-propagating errors, *Nature*, 1986, **323**, 533–536.

Sharma S., Sharma S., Athaiya A., Activation Functions in Neural Networks, *International Journal of Engineering Applied Sciences and Technology*, 2020, **4** (12), 310-316.

Ulgen E. K., Makine Öğrenimi Bölüm-4 (Destek Vektör Makineleri), Medium, <https://medium.com/@k.ulgen90/makine-ogrenimi-bolum-4-destek-vektor-makineleri-2f8010824054>, (Ziyaret tarihi: 05 Mart 2021)

URL-1: [https://en.wikipedia.org/w/index.php?title=Artificial\\_neural\\_network&oldid=1022388240](https://en.wikipedia.org/w/index.php?title=Artificial_neural_network&oldid=1022388240), (Ziyaret tarihi: 25 Mart 2021).

URL-2: <https://kaggle.com/navoneel/brain-mri-images-for-brain-tumor-detection>, (Ziyaret tarihi: 13 Eylül 2020).

URL-3: <https://kaggle.com/sartajbhuvaji/brain-tumor-classification-mri>, (Ziyaret tarihi: 15 Kasım 2020).

URL-4: [https://figshare.com/articles/dataset/brain\\_tumor\\_dataset/1512427/5](https://figshare.com/articles/dataset/brain_tumor_dataset/1512427/5), (Ziyaret tarihi: 16 Kasım 2020).

URL-5: [https://www.researchgate.net/figure/a-Illustration-of-the-operation-principle-of-the-convolution-kernel-convolutional-layer\\_fig2\\_309487032](https://www.researchgate.net/figure/a-Illustration-of-the-operation-principle-of-the-convolution-kernel-convolutional-layer_fig2_309487032), (Ziyaret tarihi: 10 Mayıs 2021).

URL-6: [https://www.researchgate.net/figure/Typical-feature-maps-of-sample-brain-MR-images-in-different-layers-a-Layer2-output-b\\_fig5\\_329610130](https://www.researchgate.net/figure/Typical-feature-maps-of-sample-brain-MR-images-in-different-layers-a-Layer2-output-b_fig5_329610130), (Ziyaret tarihi: 16 Mayıs 2021).

URL-7: <https://www.healthline.com/health/head-mri>, (Ziyaret tarihi: 25 Mart 2021).

URL-8: [https://tr.wikipedia.org/w/index.php?title=Python\\_\(programlama\\_dili\)&oldid=25429511](https://tr.wikipedia.org/w/index.php?title=Python_(programlama_dili)&oldid=25429511), (Ziyaret tarihi: 13 Nisan 2021)

URL-9: <http://www.tumrad.net/?Syf=5&Id=20562>, (Ziyaret tarihi: 10 Mayıs 2021).

URL-10: <https://quantdare.com/hierarchical-clustering/>, (Ziyaret tarihi: 12 Şubat 2021).

URL-11: <https://colab.research.google.com/notebooks/welcome.ipynb?hl=tr>, (Ziyaret tarihi: 10 Ocak 2021)

Wasule V., Sonar P., Classification of Brain MRI Using SVM and KNN Classifier, *2017 Third International Conference on Sensing, Signal Processing and Security (ICSSS)*, DOI: 10.1109/SSPS.2017.8071594.

Xu Y., Jia Z., Wang L., Ai Y., Zhang F., Lai M., Chang E. I., Large Scale Tissue Histopathology Image Classification, Segmentation, and Visualization via Deep Convolutional Activation Features, *BMC Bioinformatics*, DOI: <https://doi.org/10.1186/s12859-017-1685-x>

Yamanakkanavar N., Choi J. Y., Lee B. MRI Segmentation and Classification of Human Brain Using Deep Learning for Diagnosis of Alzheimer's Disease: A Survey, *Sensors*, DOI: <https://doi.org/10.3390/s20113243>.

Yıldız K., Çamurcu Y., Doğan B., Veri Madenciliğinde Temel Bileşenler Analizi ve Negatifsiz Matris Çarpanlarına Ayırma Tekniklerinin Karşılaştırmalı Analizi, *Akademik Bilişim*, Muğla, Türkiye, 10-12 Şubat 2010.

## KİŞİSEL YAYIN VE ESERLER

Becerikli Y., **Altuntaş F.**, Beyin MR Görüntülerinin Derin Öğrenme ile Sınıflandırılması, Kümelenmesi ve Bölütlenmesi, *Uluslararası Akademik Araştırmalar Kongresi*, Çevrimiçi, Türkiye, 19-21 Nisan 2021.

Gültekin A., Diri S., **Altuntaş F.**, Yerlikaya Z., Rol Tabanlı Erişim Kontrolü Kullanılarak Öğrenci Bilgi Sistemi Modellenmesi, *Uluslararası Marmara Fen ve Sosyal Bilimler Kongresi*, Kocaeli, Türkiye, 23-25 Kasım 2018.



## ÖZGEÇMİŞ

Faruk ALTUNTAŞ; ilk, orta ve lise öğrenimini Şavşat'ta tamamladı. 2004 yılında girdiği Kocaeli Üniversitesi Elektrik Mühendisliği bölümünden yatay geçiş ile Bilgisayar Mühendisliği bölümüne geçerek 2009 yılında mezun oldu. 2010 yılında başladığı Kocaeli Üniversitesi Fen Bilimleri Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı'ndaki Yüksek Lisans eğitimine devam etmektedir. 2011-2018 yılları arasında Kocaeli Üniversitesi'nde yazılım geliştirici olarak çalıştı. 2018 yılında Sakarya Üniversitesi Karasu Meslek Yüksek Okulunda öğretim görevlisi olarak başladı daha sonra Yükseköğretim Kalite Kurulunda görevlendirildi. Halen Yükseköğretim Kalite Kurulunda yazılım geliştirici olarak görev yapmaktadır.