

T.C.
ERCIYES ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
BİYOMEDİKAL MÜHENDİSLİĞİ ANABİLİM DALI

ÇOCUKLUK ÇAĞI BEYİN TÜMÖRLERİNİN
GÖRÜNTÜ İŞLEME TEKNİKLERİYLE ÖZELLİK
ÇIKARARAK MAKİNE ÖĞRENMESİ
YÖNTEMLERİYLE SINIFLANDIRILMASI

Hazırlayan
Nuray DEMİRÖZ

Danışman
Prof.Dr. Semra İÇER

Yüksek Lisans Tezi

Temmuz 2023
KAYSERİ

T.C.
ERCIYES ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
BİYOMEDİKAL MÜHENDİSLİĞİ ANABİLİM DALI

ÇOCUKLUK ÇAĞI BEYİN TÜMÖRLERİNİN
GÖRÜNTÜ İŞLEME TEKNİKLERİYLE ÖZELLİK
ÇIKARARAK MAKİNE ÖĞRENMESİ
YÖNTEMLERİYLE SINIFLANDIRILMASI
(Yüksek Lisans Tezi)

Hazırlayan
Nuray DEMİRÖZ

Danışman
Prof.Dr. Semra İÇER

Temmuz 2023
KAYSERİ

BİLİMSEL ETİĞE UYGUNLUK

Bu çalışmadaki tüm bilgilerin, akademik ve etik kurallara uygun bir şekilde elde edildiğini beyan ederim. Aynı zamanda bu kural ve davranışların gerektirdiği gibi, bu çalışmanın özünde olmayan tüm materyal ve sonuçları tam olarak aktardığımı ve referans gösterdiğimi belirtirim.

Nuray DEMİRÖZ

“Çocukluk Çağı Beyin Tümörlerinin Görüntü İşleme Teknikleriyle Özellik Çıkararak Makine Öğrenmesi Yöntemleriyle Sınıflandırılması” adlı Yüksek Lisans tezi, Erciyes Üniversitesi Lisansüstü Tez Önerisi ve Tez Yazma Yönergesi’ne uygun olarak hazırlanmıştır.

Hazırlayan
Nuray DEMİRÖZ

Danışman
Prof.Dr. Semra İÇER

Biyomedikal Mühendisliği ABD Başkanı
Prof.Dr. Semra İÇER

TEŞEKKÜR

Yüksek lisans eğitim hayatımda bana yol gösteren, engin bilgi ve deneyimlerini benden esirgemeyen ve her anlamda bana destek olan tez danışmanlarım **Prof. Dr. Semra İÇER** ve **Dr. Öğr. Üyesi Zehra Filiz KARAMAN**'a ve bilgi birikimimde bana yol gösteren ve desteklerini esirgemeyen tüm hocalarıma teşekkür ederim.

Yüksek lisans öğrenim hayatımı beraber geçirdiğim ve bu süreç boyunca bana her anlamda destek olan çok kıymetli dostlarım **Vildan DİZDAROĞLU**, **Abdullah YILDIRIM** ve **Gamze ÇAKIR**'a varlıklarından dolayı teşekkür ederim.

Nuray DEMİRÖZ

Temmuz 2023, KAYSERİ

ÇOCUKLUK ÇAĞI BEYİN TÜMÖRLERİNİN GÖRÜNTÜ İŞLEME TEKNİKLERİYLE ÖZELLİK ÇIKARARAK MAKİNE ÖĞRENMESİ YÖNTEMLERİYLE SINIFLANDIRILMASI

Nuray DEMİRÖZ

Erciyes Üniversitesi, Fen Bilimleri Enstitüsü
Yüksek Lisans Tezi, Temmuz 2023
Danışman : Prof.Dr. Semra İÇER

ÖZET

Çocukluk çağında en çok ölüme sebep olan maligniteler arasında beyin tümörleri yer almaktadır ve bu tümörler lösemiden sonra en çok görülen maligniteleridir. Beyinde oluşan anormal yapılar insan beyninin nöral yapısını ayırt etmede en yaygın olarak kullanılan Manyetik Rezonans Görüntüleme (MRG) teknikleri ile görüntülenir ve teşhis, tedavi süreçleri belirlenir. Ancak bu anormal yapının tanımlanması ve teşhis edilmesi uzun zamanlar alabilmektedir. Bu çalışma Posterior Fossa tümörüne sahip hastaların MRG görüntüleri üzerinde görüntü işleme yöntemleri uygulanarak tümörlerin bölütlenmesi ve tümörlerden sayısal özellikler çıkarılarak makine öğrenmesi algoritmaları ile tümör tiplerinin sınıflandırılması amacıyla yapılmıştır. Posterior Fossa tümörünün en yaygın üç tipi olan Medulloblastoma, Ependymoma, Pilocytic Astrositoma'ya sahip hastaların T2, kontrastı arttırılmış T1 ve ADC sekansları üzerinde çalışma yapılmıştır. Segmente edilen tümörler üzerinden 40 farklı sayısal özellik çıkarılmıştır. Çıkarılan özelliklerden anlamlı olan nitelikler belirlenerek tümörler Destek Vektör Makineleri (SVM) algoritması kullanılarak sınıflandırılmıştır. Sonuç olarak Posterior Fossa tümörleri yüksek doğrulukta sınıflandırılarak birbirinden ayırt edilmiştir.

Anahtar Kelimeler: Posterior Fossa Tümörleri, Manyetik Rezonans Görüntüleme, SVM.

CLASSIFICATION OF CHILDHOOD BRAIN TUMORS BY MACHINE LEARNING METHODS BY EXTRACTING FEATURES WITH IMAGE PROCESSING TECHNIQUES

Nuray DEMİRÖZ

Erciyes University, Graduate School of Natural and Applied Sciences
Master Thesis, July 2023

Supervisor: Prof.Dr. Semra İÇER

ABSTRACT

Among the most common causes of death in childhood, brain tumors are included, and they are the second most common malignancies after leukemia. Abnormal structures formed in the brain are visualized using Magnetic Resonance Imaging (MRI) techniques, which are the most commonly used methods to distinguish the neural structure of the human brain, and diagnosis and treatment processes are determined. However, identifying and diagnosing these abnormal structures can take a long time. In this study, image processing methods were applied to MRI images of patients with Posterior Fossa tumors to segment the tumors, and numerical features were extracted from the tumors to classify tumor types using machine learning algorithms. Work was done on T2, contrast-enhanced T1, and ADC sequences of patients with the three most common types of Posterior Fossa tumors: Medulloblastoma, Ependymoma, and Pilocytic Astrocytoma. 40 different numerical features were extracted from the segmented tumors. Significant attributes were identified from the extracted features, and the tumors were classified using the Support Vector Machines (SVM) algorithm. As a result, Posterior Fossa tumors were classified with high accuracy and distinguished from each other.

Keywords: Posterior Fossa Tumors, Magnetic Resonance Imaging, SVM.

İÇİNDEKİLER

ÇOCUKLUK ÇAĞI BEYİN TÜMÖRLERİNİN GÖRÜNTÜ İŞLEME TEKNİKLERİYLE ÖZELLİK ÇIKARARAK MAKİNE ÖĞRENMESİ YÖNTEMLERİYLE SINIFLANDIRILMASI

BİLİMSEL ETİĞE UYGUNLUK SAYFASI	ii
YÖNERGEYE UYGUNLUK SAYFASI	iii
KABUL VE ONAY	iv
TEŞEKKÜR	v
ÖZET	vi
ABSTRACT	vii
İÇİNDEKİLER	viii
KISALTMALAR	xi
TABLolar LİSTESİ	xii
ŞEKİLLER LİSTESİ	xiii
GİRİŞ	1

1. BÖLÜM

GENEL BİLGİLER VE LİTERATÜR ÇALIŞMASI

1.1. Posterior Fossa Tümörleri	3
1.1.1. Medulloblastom	4
1.1.2. Ependimom	7
1.1.3. Astrositomlar	10
1.2. Literatür Taraması	13
1.3. Tezin Amacı ve Önemi	15

2. BÖLÜM

YÖNTEM ve MATERYAL

2.1. Hastalar ve veri setleri	18
2.2. Görüntü İşleme	19

2.2.1. Matlab ile Görüntü İşleme	19
2.2.2. Histogram Eşitleme	20
2.2.3. Beklenti Maksimizasyonu Algoritması Segmentasyonu	23
2.2.4. Bölge Bazlı Aktif Kontur Segmentasyonu	25
2.3. Sayısal Özellik Çıkarımı	27
2.3.1. Birincil İstatiksel Özellikler	29
2.3.2. İkinci Dereceden Gri Düzey Birlikte Oluşum Matrislerini Temel Alan Özellikler	30
2.3.3. Ayrık Dalgacık Dönüşümünü Temel Alan Özellikler	33
2.3.4. Yüzde Değer Özellikleri	34
2.4. Öznitelik Seçimi	35
2.5. Makine Öğrenmesi Algoritmaları ve Sınıflandırma	36
2.6. Destek Vektör Makineleri	38

3. BÖLÜM

BULGULAR

3.1. Görüntü Segmentasyonu ve Sonuçları	40
3.2. Özellik Çıkarımı ve Sonuçları	40
3.3. Makine Öğrenmesi Algoritması ve Sonuçları	45
3.3.1. T2 Sekansı için Posterior Fossa Tümörlerinin Sınıflandırma Sonuçları	45
3.3.2. Kontrastı Artırılmış T1 Sekansı için Posterior Fossa Tümörlerinin Sınıflandırma Sonuçları	48
3.3.3. ADC Sekansı için Posterior Fossa Tümörlerinin Sınıflandırma Sonuçları	51

4. BÖLÜM

TARTIŞMA-SONUÇ ve ÖNERİLER

4.1. Tartışma	54
4.2. Sonuç ve Öneriler	56
KAYNAKÇA	57

ÖZGEÇMİŞ	61
--------------------	----



KISALTMALAR

MRG	:	Manyetik Rezonans Görüntüleme
MR	:	Manyetik Rezonans
BT	:	Bilgisayarlı Tomografi
EM	:	Ependymoma
MB	:	Medulloblastoma
PA	:	Pilocytic Astrositoma
GLCM	:	Gri Düzeyde Birlikte Oluşum Matrisi
DWT	:	Ayrık Dalgacık Dönüşümü
SVM	:	Destek Vektör Makineleri
CLAHE	:	Kontrast Sınırlı Uyarlanabilir Histogram Eşitleme
WEKA	:	Bilgi Analizi için Waikato Ortamı



TABLOLAR LİSTESİ

Tablo 1.1.	Literatür taraması ile incelenen çalışmaların özet bilgileri.	17
Tablo 2.1.	Posterior Fossa tümörleri için çalışılan kişi sayısı.	18
Tablo 2.2.	Özellik çıkarımı için kullanılan yöntemler ve bu yöntemler ile hesaplanan sayısal özellikler.	28
Tablo 2.3.	İkinci Dereceden Gri Düzey Birlikte Oluşum Matrislerini temel alan özellikler ve formülleri.	32
Tablo 3.1.	Çekim sekansları için Posterior Fossa tümör tipleri arasında elde edilen anlamlı özellik sayısı.	41
Tablo 3.2.	T2 sekansı için Posterior Fossa tümör tipleri ile elde edilen anlamlı özellikler.	42
Tablo 3.3.	Kontrastı artırılmış T1 sekansı için Posterior Fossa tümör tipleri ile elde edilen anlamlı özellikler.	43
Tablo 3.4.	ADC sekansı için Posterior Fossa tümör tipleri ile elde edilen anlamlı özellikler.	44
Tablo 3.5.	Sınıflandırılan Posterior Fossa tümörlerine ait sonuçlar.	53

ŞEKİLLER LİSTESİ

Şekil 1.1.	Medulloblastom tümörüne sahip hastadan alınan T2 sekans kesit görüntüsü.	5
Şekil 1.2.	Medulloblastom tümörüne sahip hastadan alınan kontrastı artırılmış T1 sekans kesit görüntüsü.	6
Şekil 1.3.	Medulloblastom tümörüne sahip hastadan alınan ADC sekans kesit görüntüsü.	6
Şekil 1.4.	Ependimom tümörüne sahip hastadan alınan T2 sekans kesit görüntüsü.	8
Şekil 1.5.	Ependimom tümörüne sahip hastadan alınan kontrastı artırılmış T1 sekans kesit görüntüsü.	8
Şekil 1.6.	Ependimom tümörüne sahip hastadan alınan ADC sekans kesit görüntüsü.	9
Şekil 1.7.	Pilositik Astrositom tümörüne sahip hastadan alınan T2 sekans kesit görüntüsü.	11
Şekil 1.8.	Pilositik Astrositom tümörüne sahip hastadan alınan kontrastı artırılmış T1 sekans kesit görüntüsü.	11
Şekil 1.9.	Pilositik Astrositom tümörüne sahip hastadan alınan ADC sekans kesit görüntüsü.	12
Şekil 2.1.	Bir kesitten çıkarılan tümörün normal görüntüsü.	22
Şekil 2.2.	Histogram eşitleme yapıldıktan sonra bir kesitten çıkarılan tümör görüntüsü.	22
Şekil 2.3.	Ependymoma tümörüne sahip hastadan alınan bir kesit.	24
Şekil 2.4.	Ependymoma tümörüne sahip hastadan alınan bir kesitten beklenti maksimasyonu algoritması ile çıkarılmış tümör görüntüsü.	24
Şekil 2.5.	Medulloblastoma tümörüne sahip hastadan alınan bir kesit ve bölge bazlı aktif kontur yöntemi ile sınırları çizilmiş tümör görüntüsü.	26
Şekil 2.6.	Medulloblastoma tümörüne sahip hastadan alınan bir kesitten bölge bazlı aktif kontur algoritması ile çıkarılmış tümör görüntüsü.	26

Şekil 2.7.	Ayrık Dalgacık Dönüşümü ayrıştırma işlemi için akış şeması. Görselde; A = Satırlarda Düşük Geçiş Filtresi , B = Sütunlarda Yüksek Geçiş Filtresi ve C = Sütunlarda Düşük Geçiş Filtresidir.	34
Şekil 2.8.	Makine öğrenmesi algoritmaları.	37
Şekil 2.9.	Destek Vektör Makineleri(SVM)'nin çalışma prensibi. İkinci derece denklemlerde hiperdüzlem bir çizgi iken üçüncü derece denklemlerde yüzey şeklindedir.	39
Şekil 3.1.	T2 sekansı için pilositik astrositom ve medulloblastom tümörlerinin ayrık dalgacık dönüşümü ile elde edilen basıklık ve varyans özelliklerine göre sınıflandırma sonucu grafik görüntüsü. Görüntüde sarı olanlar pilositik astrositom, mavi olanlar ise medulloblastom tümörüne sahip kişileri ifade etmektedir.	46
Şekil 3.2.	T2 sekansı için pilositik astrositom ve ependimom tümörlerinin ayrık dalgacık dönüşümü ile elde edilen maksimum ve ortalama değer özelliklerine göre sınıflandırma sonucu grafik görüntüsü. Görüntüde sarı olanlar pilositik astrositom, mavi olanlar ise ependimom tümörüne sahip kişileri ifade etmektedir.	47
Şekil 3.3.	T1 sekansı için pilositik astrositom ve medulloblastom tümörlerinin ayrık dalgacık dönüşümü ile elde edilen basıklık ve çarpıklık özelliği üzerinden sınıflandırma sonucu grafik görüntüsü. Görüntüde sarı olanlar pilositik astrositom, mavi olanlar ise medulloblastom tümörüne sahip kişileri ifade etmektedir.	48
Şekil 3.4.	T1 sekansı için pilositik astrositom ve ependimom tümörlerinin ayrık dalgacık dönüşümü ile elde edilen basıklık ve birinci dereceden elde edilen basıklık özelliği üzerinden sınıflandırma sonucu grafik görüntüsü. Görüntüde sarı olanlar pilositik astrositom, mavi olanlar ise medulloblastom tümörüne sahip kişileri ifade etmektedir.	49
Şekil 3.5.	T1 sekansı için medulloblastom ve ependimom tümörlerinin yüzde 10 ve yüzde 90 değer özelliği üzerinden sınıflandırma sonucu grafik görüntüsü. Görüntüde mavi olanlar ependimom, sarı olanlar ise medulloblastom tümörüne sahip kişileri ifade etmektedir.	50

Şekil 3.6. ADC sekansı için pilositik astrositom ve medulloblastom tümörlerinin ortalama değer ve standar sapma özellikleri üzerinden sınıflandırma sonucu grafik görüntüsü. Görüntüde sarı olanlar pilositik astrositom, mavi olanlar ise medulloblastom tümörüne sahip kişileri ifade etmektedir. 51

Şekil 3.7. ADC sekansı için medulloblastom ve ependimom tümörlerinin birinci dereceden basıklık ve entropi özellikleri üzerinden sınıflandırma sonucu grafik görüntüsü. Görüntüde mavi olanlar ependimom, sarı olanlar ise medulloblastom tümörüne sahip kişileri ifade etmektedir. 52



GİRİŞ

Bu tez çalışması kapsamında, çocukluk çağında en fazla görülen Posterior Fossa tümörlerinin üç farklı alt tipi olan Ependymoma, Medulloblastoma ve Pilocytic Astrositoma tümörlerinin anlamlı sayısal özelliklerinden sınıflandırılmasının yapılması hedeflenmektedir. Posterior Fossa tümörleri, beyindeki arka tarafın altında bulunan bölgede oluşan malignitelerdir. Bu tümörler beyin lezyonları içerisinde en kritik olanlarından biri olarak kabul edilir. Posterior Fossa tümörleri çocukluk çağında görülen tümörlerin %50-74'ünü oluşturmaktadır ve bunların çoğunluğunu da pilocytic astrositomalar, medulloblastomalar, ependymomalar ve beyin sapı gliomları oluşturmaktadır [1] [2]. Bu tümörler kişilerde görülme yaşı ve klinik olarak oluşan semptomlar bakımından benzer özellik göstermektedirler ve Posterior Fossa tümörlerinin doğru şekilde ayırt edilerek tanımlanması, gerekli ve etkili tedavi sürecinin planlanarak hastalarda sağkalım oranını arttırmak sağlık profesyonelleri için bir zorluk olup kritik öneme sahiptir. Bu süreçler ele alındığında, teşhisin ve tedavinin doğruluğu radyoloğun eğitime, uzmanlığına ve vermiş olacağı karara bağlı olmaktadır. Pediatrik beyin tümörleri için Manyetik Rezonans Görüntüleme(MRG)'nin geleneksel radyolojik raporlanması ile tanının doğruluğu %63 olarak belirlenmiş olup görüntülerin uzman retrospektif yaklaşım ile incelenmesi tanı doğruluğu %71'e kadar çıkarılmıştır [3]. Kesin ve doğru tanı, farklı tümörlere sahip hastalar için ameliyat öncesi değerlendirmeye yardımcı olabileceği gibi cerrahi adımlar planlanırken de yol gösterici olmaktadır. Posterior Fossa tümörlerinin erken ve doğru teşhis edilerek kişilerde sağkalım oranını artırmak için geleneksel yöntemler dışında görüntü işleme yöntemleri kullanılarak sayısal özellikler çıkarılıp makine öğrenmesi algoritmalarını kullanarak tümörleri ayırt etmek tanıda büyük kolaylıklar sağlayabilecek potansiyel bir yöntemdir.

Görüntü işleme yöntemleri sağlık alanında birçok farklı alanlarda kullanılmaktadır ve bu yöntemler ile tıbbi görüntüler üzerinden anlamlı sayısal özellikler çıkarılarak analiz edilebilir. Çıkarılan bu sayısal özellikler bize bir görüntünün içerdiği bilgiyi aktarır ve görüntülerin sahip olduğu spesifik anlamlı niteliklerin elde edilmesini sağlar. Görüntüden çıkarılan bu nitelikler daha sonra görüntüyü analiz etmek ve diğer görüntülerden farklılıklarının ayırt edilmesinde önemli bir rol alabilmektedir.

Makine öğrenmesi algoritmaları çözümlemeli model oluşturmayı otomatik hale getiren bir veri analizi yöntemi olup sistemlerin verilerden öğrenmek ve tanımlamak amacıyla tasarlanan bir yapay zeka dalıdır. Bilgiyi düzenleyerek minimum insan müdahalesi olacak şekilde karar verebilirler. Makine öğrenmesi algoritmaları veriler arasındaki ilişkinin bulunmasında kullanılan yaygın bir yöntemdir ve bu sebeplede çalışmamızda tümörlerin sınıflandırılması aşamasında kullanılmaktadır.

Görüntü işleme ve makine öğrenmesi algoritmalarının birlikte kullanılarak tümörlerin sınıflandırılması radyoloji uzmanlarına destek sağlayarak doğru ve erken teşhise yardımcı olarak klinik iş akışını kolaylaştırabilir. Posterior Fossa tümör tiplerini sınıflandırmak için benzer birçok çalışma bulunmaktadır fakat bu çalışmada diğer çalışmalardan ayrı olarak farklı görüntü işleme algoritmaları kullanılarak tümörleri segmente ettikten sonra farklı ve birçok sayısal özelliklerin çıkarılması ve daha sonra çıkarılan bu özelliklerden anlamlı olan özelliklerin belirlenerek bu özellikler üzerinden makine öğrenmesi algoritmaları ile çalışılan tümörlerin yüksek doğrulukta sınıflandırılması hedeflenmektedir.

Bu çalışmanın düzenlemesi şu şekildedir; 1. bölümde, yapılan çalışmayı daha iyi anlayabilmek için Posterior Fossa tümörleri hakkındaki genel bilgilere ve literatürde bu konu hakkında yapılan benzer birçok çalışmaya yer verilmiştir. 2. bölümde, çalışmanın yöntem ve materyal kısmı yer almaktadır. Bu kısımda görüntülerin temin edilme sürecine, tümörün iyileştirilmesi ve bölütlenmesine, sayısal özellik çıkarımında hangi yöntemlerin kullanıldığına ve anlamlı ayırt edici özelliklerin seçimine son olarakta hangi makine öğrenmesi algoritması ile nasıl sınıflandırma işlemi yapıldığına dair bilgiler bulunmaktadır. 3. bölümde çalışma sonucunda ulaşılan bulgulardan bahsedilmiştir. 4. bölümde ise elde edilen genel sonuçlar ve daha sonraki çalışmalar üzerine öneriler paylaşılıp yapılan çalışmanın eksiklikleri üzerinde tartışılmıştır.

1. BÖLÜM

GENEL BİLGİLER VE LİTERATÜR ÇALIŞMASI

1.1. Posterior Fossa Tümörleri


Posterior Fossa tümörleri, "posterior Fossa" olarak isimlendirilen ve kafatasının arka tarafında alt kısımda yer alan bölgede oluşan ve çocuklarda en sık ölüme sebebiyet veren maligniteler arasında bulunan beyin tümörleridir. Posterior Fossa, beyin sapı ve serebellumun bulunduğu alanı kapsamakla birlikte ön tarafta klivus, yanlarda temporal kemiğin petroz apeksi, arka kısımda oksipital kemik, üst bölgede tentoryum, aşağı kısımda ise foramen magnum ile çevrelenmiş içerisinde medulla oblongata, pons, 4.ventrikül, serebellum dural sinüsler ve çok önemli arter ve venlerin bulunduğu küçük bir anatomik yapıdır [4]. Arka çukur tümörleri olarakta bilinen bu tümörler işitme ve denge sinirinin iyi huylu tümörüdürler ancak bazı durumlarda kötü huylu olabilmektedirler. Bu tümörlerin çoğu beynin birincil tümörleridir fakat vücudun başka bölgelerinden beyine sıçraması(metastaz) olarak nadir görülürler. Tümörün türü, beyinde yerleşim yeri ve büyüklüğü, oluşan semptomlar ve uygulanacak tedavi seçenekleri üzerinde etkili olmaktadır. Posterior Fossa tümörlerinde oluşan semptomlar tümörün bulunduğu yere göre beyin sapı ve serebellum kompresyonu sonucu ve BOS dolaşımının bozulmasına bağlı olarak kafa içi basınç artışından dolayı oluşmaktadır. Bu tümörlerin büyüme hızları değişken olabilmektedir ve patolojik histoloji özelliklerine bağlı olarak değişim gösterebilmektedir. Etraftaki yapılara bası olması sebebiyle semptom oluşturmaları. Bu tümörlerinin hasta bireylerde oluşturduğu şikayetler, tümörlerin türü, yerleşim gösterdiği yer ve tümörün boyutuna bağlı olarak değişim göstermektedir. Çocukluk çağı posterior Fossa tümörlerinde en yaygın olarak mide bulantısı ve kusma %75, baş ağrısı %67, yürüyüş bozukluğu %60 ve papil ödem %34 oranında görülmekte olup, 4 yaşından küçük çocuklarda ise makrosefali ve kusma en sık görülen belirtiler arasındadır [5].

Aynı zamanda tek taraflı işitme kaybı, yüzde his kaybı, çınlama, denge bozukluğu ataksisi, diplopi, kuvvet kaybı, koordinasyon eksikliği, çift görme nörolojik bozukluklar ve nöbetlerde yaygın belirtiler arasında bulunmaktadır ve bunlar arasında tek taraflı işitme kaybı en fazla alınan şikayettir. Bu tümörlerin çocuklarda sık tanı konulan tipleri medulloblastom, astrositom ve ependimom'dur. Yetişkinlerde ise metastaz en sık tanı almaktadır. Posterior Fossa tümörleriyle ilgili yapılan radyolojik tetkikler, beyin manyetik rezonans görüntüleme (MRG) ve bazen de bilgisayarlı tomografi (BT) gibi görüntüleme tekniklerini içermektedir. Kontrastlı MRG teşhis aşamasında kullanılan hassas bir yöntemdir. Bu görüntüler ile tümör hakkında bazı bilgiler yani tümörün yeri, boyutu, sınırları, iç yapısı ve etkilediği diğer yapıları belirlemek için kullanılmaktadır. Radyologlar bu görüntülerden üzerinden sağladıkları bilgilere dayanarak tümör türünü ve tedavi planını oluşturmaya çalışırlar. Görüntüleme dışında aynı zamanda işitme testi (ses ve konuşma odyometrisi) ve vestibüler testlerden de teşhis aşamasında yararlanılmaktadır. Bazı durumlarda ise radyografiler ve diğer tetkikler de kişilerden istenilebilir. Tedavi aşamasında cerrahi müdahale çok önemli olup mümkün mertebe tümörün tamamının çıkarılmasını amaçlamaktadır. Radyoterapi ve Kemoterapi de tedavi aşamasında kullanılan diğer tedavi yöntemleridir.


1.1.1. Medulloblastom

Genellikle beyinin arka çukurunda konumlanmaktadırlar. Omurilik veya beyinin diğer kısımlarına beyin-omurilik sıvısı ile yayılım gösterebilirler. Kötü huylu tümörler olarak bilinmektedirler. Posterior Fossa tümörleri arasında görülme sıklığı astrositomlardan sonra gelir. Erişkinlerde oldukça nadir olup çocukluk çağıının en sık görülen tümörleridir. Daha çok 10 yaş altında görülürler. Erkek bireylerde iki kat daha sık görülmektedir. Bu tümörler biyolojik davranış olarak önemli farklılıklar gösterebilirler ve birçok alt tipe (klinik, histolojik, moloküler) ayrılmışlardır [4]. Beyin-omurilik sıvısı yollarını tıkadığı için beyinde sıvı toplanmasına yani hidrosefaliye neden olmaktadır. Bunun sonucunda da semptomlar baş ağrısı ve çok sık arka arkaya kusma gibi sonuçlar oluşabilmektedir. Bu etkilerin dışında kişiler gözlerde kayma, denge bozukluğu gibi şikayetler ile hastaneye başvurabilir. Tanı aşamasında kontrastsız BT'de hiperdens görünürler ve ADC değerleri ayırıcı tanıda çok önemli bilgiler vermektedir.


Tedavi aşamasında posterior Fossa tümörlerinde genel olarak kullanılan ve ilk seçenek olan cerrahi tedavi, ameliyat sırasında eğer mümkünse tümörün tamamen çıkarılması hedeflemektedir. Diğer tedavi seçenekleri(radyoterapi, kemoterapi) cerrahi tedavi alamayan hastalarda kullanılmaktadır. Ameliyat sonrasında tümörün yayılmasını ve büyümesini engellemek ve ameliyat sonrasında hastalığın tekrarlamaması için Radyoterapi tedavisi kullanılmaktadır ve bu iki tedaviye ek tedavi olarak bazı durumlar hariç tek başına tedavi olarak kullanılamayan Kemoterapi tedavisi kullanılmaktadır. Şekil 1.1, Şekil 1.2, Şekil 1.3’da meduloblastom tümör tipine ait T2, kontrastı artırılmış T1 ve ADC sekansları ile çekilmiş örnek görüntüler yer almaktadır.



Şekil 1.1. Medulloblastom tümörüne sahip hastadan alınan T2 sekans kesit görüntüsü.




Şekil 1.2. Medulloblastom tümörüne sahip hastadan alınan kontrastı artırılmış T1 sekans kesit görüntüsü.




Şekil 1.3. Medulloblastom tümörüne sahip hastadan alınan ADC sekans kesit görüntüsü.

1.1.2. Ependimom


Ependimom tümörleri, merkezi sinir sisteminde ependimal hücrelerinden kaynaklanan ve beyin omurilik sıvısı üreten ve dolaşımını sağlayan yapılarla bağlantılı olan bir tür beyin tümörü tipidir. Bu tümörlere çoğunlukla ventrikül içerisinde ya da ventrikülle bağlantılı olan alanlarda rastlanır. Çocukluk çağı posterior Fossa tümörleri içinde medulloblastom ve arstrositomlardan sonra yer alırlar. Üç yaş altındaki çocuklarda tüm beyin tümörlerinin %30'unu oluştururlar ve çoğunlukla 1 ila 5 yaş arasında görülürler. İkinci oluşan çok daha küçük pikler 20 ila 30 yaş aralığında gözlemlenir [4]. Erkeklerde biraz daha sık görülmektedir. Erişkinlerde ise oldukça nadir görülen tümörlerdir. Hem iyi hem de kötü huylu olabilmektedirler. Beynin veya omuriliğin farklı bölgelerine gidip orada büyüyebilirler. Beyin omurilik sıvısı ile de yayılabilirler. Beyin omurilik sıvısı ile yayılım hastalığının seyri hakkında kilit rol oynamaktadır ve nöral aksın dikkatle incelenmesini gerektirir. Manyetik rezonans görüntüleme radyolojik tanılarda tümörün cinsi ve huyu hakkında bilgi verebilir ancak kesin tanı ve karar tümör dokusunun mikroskop altında patolojik olarak incelemesi ile konulur. Oluşan semptomlar genellikle yerleşim yerlerine bağlı olup 4.Ventrikül yerleşiminde oluşanlar çoğunlukla hidrosefaliye neden olurlar ve bunun belirtileri ise baş ağrısı, kusma, dilde ödem oluşması olabilir. Serebellum yerleşimli olanlar ise nöbet geçirme, uyku hali, kollarda ve bacaklarda güçsüzlük, konuşma bozukluğu ve diğer türlü felçler olarak belirti gösterebilir. Medulloblastom ile benzer belirtilere sahiptir. Ependimomların teşhisi aşamasında nörolojik muayene, görüntüleme alanları (Manyetik Rezonans Görüntüleme ve Bilgisayarlı Tomografi (BT)) ve tümörlerin incelenmesi için bir biyopsi gerekebilir. T1A görüntülerinde heterojen hipointens olup, T2A/FLAIR 'de hiperintensirler. T2 görüntülemelerde eski kanama odakları görülmektedir [4]. Şekil 1.4, Şekil 1.5, Şekil 1.6'de ependimom tümör tipine ait T2, kontrastı artırılmış T1 ve ADC sekansları ile çekilmiş örnek görüntüler yer almaktadır.



Şekil 1.4. Ependimom tümörüne sahip hastadan alınan T2 sekans kesit görüntüsü.



Şekil 1.5. Ependimom tümörüne sahip hastadan alınan kontrastı artırılmış T1 sekans kesit görüntüsü.




Şekil 1.6. Ependimom tümörüne sahip hastadan alınan ADC sekans kesit görüntüsü.

1.1.3. Astrositomlar


Astrositomlar, astrosit adı verilen destek hücrelerinden kaynaklanan merkezi sinir sisteminde oluşan beyin tümörleridir. Bu hücreler beyindeki sinir hücrelerine destek sağlar ve aynı zamanda sinir dokusunun işlevini düzenlemeye yardımcı olurlar. Bu tümörler astrosit hücrelerinin anormal ve kontrol dışı bir şekilde çoğalması sonucunda oluşurlar. Beyin ve beyincik yerleşimli olabilirler. Genellikle iyi huylu tümörlerdir ve yavaş büyüme gösterirler. Tümör tamamen çıkarıldığında tam tedavi sağlanır. Jüvenil pilositik astrositomlar, astrositomların büyük bir çoğunluğunu (%85) oluştururlar. Bu tümörler daha çok 20 yaş altında görülmektedirler. Cinsiyet farkları bulunmamaktadır. Belirtileri arasında baş ağrısı, nöbetler, hafıza sorunları, dengesizlik, koordinasyon eksikliği, kollar ve bacaklarda kas güçsüzlüğü, konuşma bozuklukları, duyu kaybı ve nörolojik bozukluklar yer almaktadır ve bu belirtiler kişiden kişiye değişebilmektedir. Bilgisayarlı Tomografi ve Manyetik Rezonans Görüntüleme ile tanı konulabilir. Kontrastlı Bilgisayarlı Tomografide kontrastlanmayan kist ile güçlü kontrast tutan mural nodül şeklinde görülmektedir ve kanama nadir olarak görülmektedir. Manyetik Rezonans Görüntülemeye kistik bölüm T1A ve T2A görüntülerinde beyin omurilik sıvısına göre daha hafif hiperintens görülmektedirler. Posterior Fossa tümörleri içerisinde yer alan hemanjioblastomdan ayırımında Perfüzyon MRG önemlidir [4]. Şekil 1.7, Şekil 1.8, Şekil 1.9'da pilositik astrositom tümör tipine ait T2, kontrastı artırılmış T1 ve ADC sekansları ile çekilmiş örnek görüntüler yer almaktadır.



Şekil 1.7. Piloitik Astrositom tümörüne sahip hastadan alınan T2 sekans kesit görüntüsü.



Şekil 1.8. Piloitik Astrositom tümörüne sahip hastadan alınan kontrastı artırılmış T1 sekans kesit görüntüsü.



Şekil 1.9. Piloitik Astrositom tümörüne sahip hastadan alınan ADC sekans kesit görüntüsü.

1.2. Literatür Taraması

Literatürde posterior Fossa tümörleri üzerine radyolojik, görüntüleme özellikleri, patolojik ve histolojik olarak incelendiği, tümör alt tiplerine ait özellik ve tümörlerin ayırt edilerek sınıflandırılması gibi bir çok çalışma bulunmaktadır. Bu kısımda çalışmamıza benzer nitelikte olan ve literatür taraması sonucunda posterior Fossa tümörlerinin sınıflandırılması üzerine yapılan çalışmalardan birkaçına yer verilmiştir.

İlk olarak incelenen çalışmalardan Arle vd. [6] bilgisayar tabanlı bir sinir ağı geliştirerek 33 kişi üzerinde manyetik rezonans spektroskopisi görüntüleri kullanarak beyin tümörüne ait 10 özellik çıkarmışlardır. Bu çalışmada posterior Fossa tümörlerinden ilkel nöroektodermal tümör, ependimom ve astrositom tümörleri çalışmıştır. Tümörleri %95 doğrulukta sınıflayarak kullanılan sinir ağının önemli ölçüde doğrulukla tahmin edebileceği sonucuna varmışlardır.

Bidiwala ve Pitmann [7] tarafından yapılan çalışmada Bilgisayarlı Tomografi(BT) ve MRG görüntüleri kullanılmıştır. Klinik ve görüntüleme verilerini kullanarak sinir ağı geliştirerek 33 kişi üzerinde çalışmaları denemişlerdir. Posterior Fossa tümörlerinden EM, MB, PA tümörlerine sahip hastalar üzerinde çalışılmıştır. Çalışmanın sonucunda %85.7 doğrulukta sınıflandırma gerçekleştirmişlerdir.

Gutierrez vd. [8] 40 çocuk üzerinde çalışma yapmışlardır. EM, PA, MB tümör çeşitleri üzerinde çalışma yapmışlardır. T2 ve T1 ve difüzyon(ADC) sekanslarından şekil, histogram ve doku özellikleri hesaplanmıştır. Medulloblastomlar gri seviye Ko-oluşum matrisinden ADC sekansında doku özelliklerine bakılarak yüksek doğrulukta sınıflandırma işlemi gerçekleştirilmiştir. Destek vektör makineleri kullanılarak sınıflandırma işlemi yapılmış ve Posterior Fossa tümörlerini %91.4'ünü ADC histogram özelliklerini kullanarak doğru bir şekilde sınıflandırmışlardır.

Fetit vd. [9] konvansiyonel MRG üzerinden elde edilen üç boyutlu dokusal niteliklerle SVM algoritmasını eğiterek EM, MB ve PA tümörlerini sınıflandırmışlardır. 134 kişi üzerinde çalışma gerçekleştirilmiştir. Temel amaçları pediatrik beyin tümörlerinin sınıflandırılmasında MRG doku analizinin uygulanmasını gözlemlemektir. Çalışmada histogram istatistikleri, mutlak gradyan istatistikleri, gri düzeyde birlikte oluşum matrisi

ve gri düzey çalışma uzunluğu matrisi ile sayısal özellikler hesaplanmıştır. Tümörler %72 doğrulukla sınıflandırılmıştır.

Zarinabad vd. [10] yaptıkları çalışma ile 3T tarayıcılardan elde edilen metabolitlerin EM, PA, MB için ayırt edici potansiyeli araştırılmıştır. 41 pediatrik hasta(17 MB, 20 PA, 4 EM) üzerinde çalışma gerçekleştirilmiştir. Destek vektör makineleri, rastgele orman teknikleri ve doğrusal ayırmacı analiz sınıflandırma işlemi için kullanılmıştır. 3 farklı tümör tipini ayırt etmede en yüksek doğruluğa sahip olan destek vektör makineleri olmuştur. %86 doğrulukla tümörler SVM ile sınıflandırılmıştır.

Li vd. [11] 174 hastadan oluşan iki farklı pediatrik posterior Fossa tümörü(EM, MB) için makine öğrenmesi tabanlı manyetik rezonans biyobelirteçleri analizi yapılmıştır. 300 farklı biyobelirteç için üç farklı özellik çıkarımı yöntemi kullanılmıştır. 10 özellik seçim için ve k-en yakın komşular, SVM, rastgele ormanlar, regresyon ağaçları, sinir ağları gibi 11 farklı sınıflandırıcı analiz edilmiştir. SVM sınıflandırıcısı diğer sınıflandırıcılara nispeten daha iyi performans göstermiş olup %85.38 doğrulukta sınıflandırma işlemi gerçekleştirmişlerdir.

Quon vd. [12] tümör tespiti ve tümör patolojisi sınıflandırılması amacıyla derin öğrenme modeli geliştirmişlerdir. Toplam 92 çocuktan oluşan 4 farklı posterior Fossa tümörüne(gliom,MB,PA,EM) sahip hastalar üzerinde çalışma gerçekleştirilmiştir. Modifiye edilmiş bir ResNeXt-50-32x4d mimarisi kullanmışlardır ve model tümör sınıflandırma doğruluğu F ile %92 olarak bulunmuştur.

Zhou vd. [13] yaptıkları retrospektif çalışmada 107 hastanın preopatif MR görüntülerini kullanarak MB, EM, PA tümörlerinin yüksek doğrulukla sınıflandırılmasını amaçlamışlardır. T2, kontrastı artırılmış T1 ve ADC sekanslarını kullanarak radyomik özellikler çıkartmışlardır. Ağaç tabanlı boru hattı optimizasyon aracı ile tümörler sınıflandırılmıştır. Medulloblastomlar %94, ependimomlar %84 ve pilositik astrositomlar %94 doğrulukla sınıflandırılmışlardır. Uzman boru hattı optimizasyonu ile pediatrik posterior Fossa tümörlerinin yüksek doğrulukta sınıflandırıldığı sonucuna varmışlardır.

Li vd. [14] makine öğrenmesi algoritmalarına dayalı radyomik analiz yöntemi ile EM ve PA arasında preopatif sınıflandırma yapılmıştır. 45 posterior Fossa tanıli hasta üzerinde çalışılıp 300 farklı multimodal özellik çıkarımı yapılmıştır. Özellik çıkarımı için gabor dönüşümü, doku ve dalgacık dönüşümü tabanlı özellikler kullanılmıştır. Özellik seçimi

için Kruskal - Wallis test skoru kullanılmıştır. Tümörlerin sınıflandırılmasında SVM kullanılmış olup %87.75 doğrulukta sınıflandırma yapılmıştır.

Wang vd. [15] çalışmada MB, PA ve EM tümörleri sınıflandırarak bu tümörlerin non-invaziv MRG tabanlı analizini radyomik olarak incelenmiştir. 27 hastanın 3 farklı sekans MRG kullanılarak çalışma yapılmıştır. Segmente edilen tümörlerden yüksek verim özellikleri çıkarılarak orman tabanlı özellik seçim algoritması benimsemişlerdir. Özellikler çıkarılırken histogram, GLCM, Wavelet transform yöntemleri ile toplam 315 özellik çıkarılmıştır. Rastgele orman sınıflandırıcı kullanılarak yapılan sınıflandırmada ADC sekansı ile yapılan sınıflandırma T2 ve T1 sekanslarına göre daha iyi nicel sonuçlar verdiği gözlemlenmiştir. Bu çalışmanın sonucunda tümörler %93.81 doğrulukla sınıflandırılmıştır.

Sotoudeh vd. [16] yaptıkları çalışmada PA ve Hemanjiyoblastoma(HB) tümörlerini sınıflandırmışlardır. 34 PA ve 18 HB hasta üzerinde çalışmışlardır. Kontrast sonrası T1 sekansı ile özellikler çıkartmışlardır. Toplam 115 özellik üzerinde çalışma yapmışlardır. Histopatolojik tanıda daha fazla belirleyici olarak on iki özellik saptamışlardır. Birçok makine öğrenmesi(kNN, SVM, Sinir ağı vb.) ile sınıflandırma işlemi yapmışlardır. Yapılan çalışma sonucunda sinir ağının en iyi iki koşulu 0.9'luk bir AUC ve % 82'lik bir doğrulukla ayırt etmede en iyi performansa sahip olduğu sonucuna varmışlardır.

Tablo 1.1'de incelenen çalışmaların özeti yer almaktadır. Tablo1.1'de de görüldüğü gibi posterior Fossa tümörlerinin sınıflandırılmasına dair bir çok benzer çalışma bulunmaktadır.

1.3. Tezin Amacı ve Önemi

Bu tez çalışması kapsamında en yaygın olarak görülen üç farklı Posterior Fossa tümör çeşidi olan ependymoma, medulloblastoma ve pilocytic asrtositoma tümörlerinin sınıflandırılması amaçlanmıştır. Tablo 1.1'de görüldüğü gibi bir çok benzer çalışma bulunmaktadır. Diğer çalışmalara ek tüm tümör çeşitleri T2, kontrastı artırılmış T1 ve ADC sekansları için yüksek doğrulukta sınıflandırma yapılması hedeflenmektedir. Bu amaçlar doğrultusunda Posterior Fossa tümörleri ilk adımda segmente edildikten sonra bu tümörler üzerinden birinci dereceden istatistiksel özellikler, gri düzeyde birlikte oluşum

matrisini temel alan doku özellikleri, ayrık dalgacık dönüşümünü temel alan özellikler ve yüzde değerleri ile sayısal özellikler çıkarılmıştır. Çıkarılan sayısal özelliklerden görüntü için anlamlı olan sayısal özellikler Student-Test ile belirlenmiştir. Son olarak belirlenen anlamlı özellikler farklı çekim sekansları için denetimli makine öğrenmesi algoritması olan destek vektör makineleri ile yüksek doğrulukta sınıflandırılmıştır.

Yapılan bu çalışmada klinik olarak bakılan ve tanı aşamasında kullanılan T2, kontrastı artırılmış T1 ve ADC sekanslarında tümünde çalışma yapılmıştır. Tüm sekanslarda görüntü kesitlere parçalandıktan sonra tümörün belirgin olduğu yani tümörün doğuşundan bitişine tüm kesitler belirlenerek bu kesitlerde özellik çıkarımı işlemi yapılmıştır. Tüm kesitlerde çalışılması çalışmanın doğruluğunu arttırmaktadır ve diğer çalışmalara üstünlük sağlamaktadır. Ayrıca yapılan çalışmada tüm sekansların kullanılması tümör tipleri için ayırt etmede hangi sekansın daha iyi sonuçlar verebileceği konusunda da çalışmayı ileriye taşımaktadır.

Bu çalışma ile yapılan bir çok çalışmadan farklı olarak tek yerine bir çok kesit üzerinde çalışılarak doğruluk arttırılmıştır ve aynı zamanda tüm çekim sekansları kullanılarak ta tüm tümör tipleri en iyi hangi sekanla ayırt edilebileceğinin belirlenmesi amacıyla yapılarak diğer çalışmalardan üstünlükleriyle daha yüksek doğrulukta sınıflandırma işleminin yapılması hedeflenmiştir.

Bu çalışma radyoloji uzmanlarına klinik açıdan tanıda büyük kolaylıklar ve destek sağlayacak nitelikte olup yapılacak yeni çalışmalar için önemli bir kılavuz niteliği taşımaktadır.

Tablo 1.1. Literatür taraması ile incelenen çalışmaların özet bilgileri.

Yazarlar ve Yılı	Çalışılan Tümör Tipi	Çalışılan Kişi Sayısı	Doğruluk
Arle vd.(1997)	ilkel nöroektodermal tümör, EM, MB, PA	33	0.95
Bidiwala ve Pitmann(2004)	EM, MB, PA	33	0.857
Gutierrez vd.(2014)	EM, MB, PA	40	0.914
Fetit vd.(2018)	EM, MB, PA	134	0.72
Zarinabad vd.(2018)	EM, MB, PA	41	0.86
Li vd. (2019)	EM, MB	174	0.8538
Quon vd.(2020)	Glioma, MB, PA, EM	92	0.92
Zhou vd.(2020)	EM, MB, PA	107	MB(0.94), EM(0.84), PA(0.94)
Li vd. (2020)	EM, PA	45	0.8775
Wang vd.(2022)	EM, MB, PA	27	0.93.81
Sotoudeh vd(2023)	PA, HB	52	0.82

2. BÖLÜM

YÖNTEM ve MATERYAL

2.1. Hastalar ve veri setleri

Bu çalışma, Erciyes Üniversitesi Çocuk Radyolojisi bölümünde Posterior Fossa tümörü tanısı olan 0-18 yaş aralığındaki kişilerin beyin MR görüntüleri alınarak yapılmıştır. Alınan görüntüler Erciyes Üniversitesi Klinik Araştırmalar Etik Kurulundan izin alınarak kullanılmıştır. Etik Kurul karar numarası 2022/428'dir. Posterior Fossa tümörünün en yaygın görüldüğü üç tipi olan medulloblastoma (MB), pilocytic astrositoma (PA) ve ependymoma (EM)'ya ait görüntüler üzerinde çalışılmıştır. Bu tümör tiplerinin T2, kontrastı artırılmış T1 ve ADC sekanslarında çalışma yapılmıştır. Görüntüler 1.5T MR sisteminde Siemens Magnetom Aera cihazı ile aynı toplama protokolü kullanılarak çekilen hasta görüntülerinden oluşmaktadır. Alınan görüntülerde kesitler 5mm veya 1mm kalınlıkta olup dilim boşluğu 1mm'dir. Tablo 2.1 de 3 farklı sekans için çalışılan hasta sayısına yer verilmektedir.

Tablo 2.1. Posterior Fossa tümörleri için çalışılan kişi sayısı.

Tümör Tipi	T2 Sekansı	T1 Sekansı	ADC Sekansı
MEDULLOBLASTOM	11	10	9
EPENDİMOM	12	7	10
PILOCYTIC ASTROSITOM	5	5	5
TOPLAM	28	22	24

2.2. Görüntü İşleme

Görüntü işleme bilgisayar alanında günümüzde önemli bir yere sahiptir. İlerleyen teknoloji ile birlikte görüntü alanında yapılan çalışmalara olan ilgi giderek artmaktadır. Farklı alanlarda sağladığı kolaylık sebebiyle ilgi duyulan bir alan olup sağlık, tarım, astronomi, fizik, kimya, imalat, güvenlik, savunma, eğlence ve birçok bilim alanında kullanılan bir yöntem haline gelmiştir. Görüntü işlemenin bir çok farklı alanda kullanılabilirliği, üzerinde yapılan çalışmaların artmasına vesile olmuştur. Görüntü işleme, görüntülerin alınarak işlenmesi daha sonra analizi ve yorumlanmasıyla ilgilenen resimsel bilgilerin analizine yönelik bir yöntemdir [17].

Görüntü işleme genel olarak bazı süreçlerden oluşmaktadır. Süreç olarak görüntü bulma süreci ilk adımdır ve bu süreçte kamera, tarayıcı gibi kaynaklardan veya sağlık alanında farklı medikal görüntüleme cihazları üzerinden görüntüler edinilebilir. Bir sonraki adımda görüntü iyileştirme adımı bulunur. Bu adımda görüntü üzerinde ön işleme yapılır yani görüntüde gürültü azaltma, kontrast ayarlama gibi görüntünün kalitesini arttırmaya yönelik işlemler yapılır. Bu yapılan işlem ile görüntü üzerinden daha doğru bilgiler edinilir. Ön işleme yapılan görüntüden içerdiği bilgilerin çıkarılması bir sonraki adımdır. Bu aşamada görüntü üzerinden histogram, şekil, doku gibi spesifik yani görüntüyü anlamlı kılacak özellikler çıkarılmaktadır. Son olarak elde edilen bilgiler ile görüntü üzerinde yorumlar ve analizler yapılabilir. Sınıflandırma, nesne tanıma gibi birçok alanda farklı amaçlar için kullanılabilir. Sağlık alanında teşhis aşamasında ve tedavi sürecinin planlanması gibi bir süreçte büyük kolaylıklar sağlayan bir potansiyele sahiptir.

Görüntü işlemenin sağlık ve mühendislik alanlarında kullanım kolaylığı ve sağladığı faydalar sebebiyle bu çalışmada büyük bir öneme sahiptir. Yapılan çalışmada görüntü işleme adımı Matlab programı üzerinden hazır görüntü işleme algoritmaları kullanılarak tümörlerin segmentasyon işlemleri yapılmıştır. Kullanılan görüntü işleme yöntemlerine sonraki sayfalarda yer verilmiştir.

2.2.1. Matlab ile Görüntü İşleme

Görüntü işleme yapılabilen bir çok program ve programlama dili bulunmaktadır. Matlab programlama dilinin yüksek matematiksel işlem yeteneğinin olması ve görüntü işleme

alanına yönelik bir çok kütüphanesinin mevcut olması bu programı seçmemizde büyük bir öneme sahiptir. Matlab programına ait görüntü işleme araç kutusu(Image Processing Toolbox) ile hazır algoritmalar kullanılarak kolaylıkla görüntü işleme uygulamaları gerçekleştirilebilmektedir. Sağlık alanında, Matlab ile görüntü işleme araç kutusu kullanılarak tıbbi görüntülerde nesne ölçme ve ayırt etmede ve görüntülerden sayısal bilgi edinimi gibi alanlarda kullanılmaktadır [17]. Görüntülerde bulunan lezyonlar için bölütleme işlemlerini desteklemektedir. Bu bölgeleri tanımlamak ve çıkartmak için bir çok yöntem (bölgesel büyütme, eşikleme gibi) bulunmaktadır. Tıbbi görüntüler üzerinde bir çok hesaplamalar (alan,hacim vb.) kolaylıkla yapılabilmektedir. Görüntü kalitesi çeşitli filtreler ve algoritmalar ile netleştirilebilmektedir. Matlab'in yukarıda anlatılan ve daha bir çok sağladığı kolaylıklar nedeniyle bu çalışmada tümörlerin segmentasyonu ve sayısal özellik çıkarımı adımlarında tercih edilmiştir.


Bu çalışmada Erciyes Üniversitesi Tıp Fakültesi Çocuk Radyolojisi bölümünden alınan Posterior Fossa tanılı hastaların görüntüleri Matlab programı üzerinden hazır görüntü işleme algoritmaları kullanılarak bölütlenmiştir. İlk olarak alınan MR görüntüleri kesit kalınlıklarına göre parçalanmıştır. Parçalanmış görüntülerde renk bozukluklarını gidermek ve görüntü kalitesini iyileştirmek için ilk önce görüntülere kontrast sınırlı uyarlanabilir histogram eşitleme işlemi uygulanmıştır. Daha sonra parçalanmış kesitlerde tümörün görüldüğü kesitler belirlenip belirlenen tüm kesitlerde segmentasyon işlemi görüntü işleme algoritmaları ile yapılarak tümörler çıkarılmıştır. Bir kişi için ortalama 5-6 kesit üzerinde segmentasyon işlemi yapılmıştır. İki farklı görüntü işleme algoritması ile görüntülerden tümörler çıkarılmıştır. Bu algoritmalar Beklenti Maksimizasyonu algoritması ve Bölge Bazlı Aktif Kontur Segmentasyon algoritmasıdır. İlerleyen sayfalarda bu algoritmalara ayrıntılı bir şekilde yer verilmiştir.

2.2.2. Histogram Eşitleme


Bir görüntüde her bir gri ton seviyesinin bulunma frekansına(sıklığına) histogram denilir. Bir görüntünün histogramı, görüntü üzerinde her bir noktada bulunan piksellerin tespiti ve görüntüde bulunan piksellerin sayısının ne olduğunu gösterir. Bu bilgiler ile görüntü üzerinden birçok farklı bilgiler elde edilebilir. Histogram eşitleme ise bir görüntüde en çok parlaklık olan alana daha fazla kontrast zenginleştirme yöntemidir. Bu yöntem kontrast zenginleştirme yöntemleri içerisinde bulunmaktadır

[18]. Görüntüde düzgün olmayan renk değerleri içeren görüntüler için görüntü kalitesini iyileştirmek için uygun bir yöntemdir. Görüntü kalitesinin iyileşmesini kontrast artırarak gerçekleştirmektedir. Bu yöntem daha çok görüntü kontrastı düşük olan görüntülerde daha iyi sonuçlar vermektedir. Görüntüde belirgin olmayan bölgeler belirgin hale getirilip görüntünün kalitesinde iyileştirme yapılmaktadır. Bu sebeplerle görüntü üzerinde yapılan çalışmalarda ilk adım olarak genellikle histogram eşitleme kullanılmaktadır.

Yapılan çalışmada da görüntüler segmente edilmeden önce görüntü kalitesini artırmak ve tümörü belirginleştirmek amacıyla ilk adımda görüntülere histogram eşitleme uygulanmıştır. Bu çalışmada kontrast sınırlı uyarlanabilir histogram eşitleme(CLAHE) uygulanmıştır. Bu yöntem histogram eşitlemeden farklı olarak görüntünün bütününde değil çalışmayıp küçük veri alanlarında çalışmaktadır. Bu küçük veri bölgelerinde her bir bölge için ayrı ayrı histogram eşitleme kullanmaktadır ve piksel değerlerini sınırlayarak kontrast artışındaki aşırılıkları engellemektedir. Kullanılan histogram eşitleme yöntemi ile ayrıca ince detaylar da vurgulanabilmektedir. Sonuç olarak bu yöntem ile daha kararlı sonuçlar elde edilerek çok daha kaliteli görüntüler elde edilmiş olmaktadır. Bu sebeplerden ötürü yapılan çalışmada ilk adım olarak görüntülere kontrast sınırlı uyarlanabilir histogram eşitleme uygulanmıştır. Şekil 2.1, Şekil 2.2’de kullanılan görüntülerden bir kesitin orjinal hali ve kontrast sınırlı uyarlanabilir histogram eşitleme uygulandıktan sonra oluşan görüntüye yer verilmektedir.



Şekil 2.1. Bir kesitten çıkarılan tümörün normal görüntüsü.




Şekil 2.2. Histogram eşitleme yapıldıktan sonra bir kesitten çıkarılan tümör görüntüsü.

2.2.3. Beklenti Maksimizasyonu Algoritması Segmentasyonu

Beklenti Maksimizasyonu algoritması, eksik yada saklı verilerin bulunduğu durumlarda maksimum olasılığı hesaplamak için kullanılan etkili bir yinelemeli süreçten oluşmaktadır. Maksimum olasılık tahmininde, gözlemlenen verilerin olması en muhtemel olan model parametrelerinin tahmin edilmesi istenmektedir. Beklenti maksimizasyonu algoritmasının her bir tekrarlanması iki süreçten oluşmaktadır. Bu süreci E-adımı ve M-adımı oluşturmaktadır. E-adımında yani beklenti adımında gözlemlenen veriler ve varolan model parametrelerinin tahmini verildiğinde eksik veriler tahmin edilmektedir. Bu işlemi şartlı beklenti kullanılarak gerçekleştirildiği için beklenti terimin seçildiği açıklanmaktadır. Diğer bir adım olan M-adımında, eksik verilerin bilindiği varsayılarak olabilirlik fonksiyonu maksimize edilmektedir. E-adımından bulunan eksik veri tahminleri, gerçek eksik verilerin yerine kullanılmaktadır. Bu süreçte, her yinelemede olabilirlik artacağı için yakınsama sağlanmaktadır [19].

Bu tekrarlanan süreçte, sağlam parametre tahminleri elde edilene kadar işlem yinelenir. Eksik değişkenlerin bulunduğu yada diğer benzer olumsuz koşulların bulunduğu durumlarda, beklenti maksimizasyonu algoritması artan bir olasılık dizisini ve güvenli tekdüze yakınsamayı garanti eden güvenli bir algoritmadır [20].

Beklenti maksimizasyonu algoritmasının kullandığı alanlardan biride kümelemedir. Veri noktaları, sadece tek bir kümeye dahil edilmek yerine kısmen farklı kümelere dahil edilmektedir. Bir veri noktası belirli bir olasılığa sahip bir küme ile bağdaştırılır ve k-ortalamarı kümelemesinden farklı olarak son atamada en yüksek olasılığa sahip kümeye atanmaktadır. K-ortalamarı algoritmasında veriler merkezi en yakın olan bir kümeye atanmaktadır. K-ortalamar kümeleme beklenti maksimizasyonuna göre daha basit bir algoritma olup yerel minimumda sıkışıp kalabilirken, beklenti maksimizasyonu algoritması daha az sıkışma göstermektedir. Beklenti maksimizasyonu algoritması, tıbbi görüntü işleme ve görüntüde eksik verilerin hesaplanabilmesi gibi birçok geniş alanda kullanılabilmektedir [21]. Şekil 2.3, Şekil 2.4’de Ependymoma tümörü tipine ait bir kesit ve bu kesitten beklenti maksimizasyonu algoritması ile çıkarılmış tümör görüntüsü bulunmaktadır.



Şekil 2.3. Ependymoma tümörüne sahip hastadan alınan bir kesit.



Şekil 2.4. Ependymoma tümörüne sahip hastadan alınan bir kesitten beklenti maksimasyonu algoritması ile çıkarılmış tümör görüntüsü.

2.2.4. Bölge Bazlı Aktif Kontur Segmentasyonu


Aktif kontur yöntemleri son yıllarda çok tercih edilen bir yöntem haline gelmiştir. Görsel izleme ve görüntü segmentasyonu gibi çeşitli alanlarda ve uygulamalarda kullanılmaktadır. Bu yöntemde temel alınan düşünce, istenilen segmentasyonu üretmek için belirli bir enerji fonksiyonunu en aza indirmek amacıyla bir konturun bozulmasına izin vermektir. Aktif konturlar iki temel sınıftan oluşmaktadır. Bu sınıflar kenar tabanlı ve bölge tabanlı aktif kontur modelleridir [22]. Bu çalışmada bölge bazlı aktif kontur modeli kullanılmıştır.

Bölge tabanlı aktif kontur modeli görüntü gradyanını kullanmadan aktif kontur hareketini kanallı etmek amacıyla her ilgili olan bölgeyi tanımlamayı amaçlar. Bu aktif kontur modeli nesne sınırları zayıf olan görüntülerde çok daha iyi sonuçlar vermektedir [23].


Bölge bazlı aktif kontur segmentasyonu görüntü işlemede bir çok alanda kullanılan ve bir görüntüde belirlenmek istenilen nesnenin dış sınırlarını bularak nesnenin bölgesinin tahmin edilmesi sağlamaktadır. Daha önceden belirlenmiş bir başlangıç yerinden başlayıp görüntü üzerindeki sınırları kendiliğinden bulmayı içeren bir süreci kapsamaktadır. Nesnenin sınırları belirlenerek kolaylıkla segmentasyon işlemi yapılmış olur. Bu yöntem gürültü bulunan görüntülerde veya tonları karışık olan görüntülerde sınır belirlemede büyük kolaylıklar sağlamaktadır.

Bölge bazlı aktif kontur segmentasyonunda Chan-Vese [24]'nin kenarsız aktif konturlar yöntemi kullanılmıştır. Bu yöntem, homojen olan görüntülerde segmentasyon için tercih edilen güzel bir yoldur. Kullanılan aktif kontur modeli medikal görüntü işlemede, görüntülerde nesne tanıma ve izleme gibi bir çok alanda tercih edilen bir yöntemdir. Yapılan çalışmada da ise posterior Fossa tümörlerinin segmentasyonu aşamasında çalışmamıza büyük kolaylıklar sağlamıştır.

Şekil 2.5, Şekil 2.6'da Medulloblastoma tümör tipine ait bir kesit görüntüsü ve bölge bazlı aktif kontur algoritması ile sınırları belirlenerek çıkarılmış tümör görüntüsü bulunmaktadır.



Şekil 2.5. Medulloblastoma tümörüne sahip hastadan alınan bir kesit ve bölge bazlı aktif kontur yöntemi ile sınırları çizilmiş tümör görüntüsü.



Şekil 2.6. Medulloblastoma tümörüne sahip hastadan alınan bir kesitten bölge bazlı aktif kontur algoritması ile çıkarılmış tümör görüntüsü.

2.3. Sayısal Özellik Çıkarımı

Sayısal özellik çıkarımı ile bir görüntü üzerinden o görüntüyü diğer görüntülerden benzersiz bir şekilde ayıran farklı özellikleri seçmek için kullanılmaktadır. Görüntüler bir çok bilgi içermektedir ve bu bilgilerin hepsi görüntü için anlamlı olmayıp kullanılmamaktadır. Bu yüzden görüntü üzerinden bazı ayırt edici özellikler seçilerek görüntüyü daha net tanımlayabilecek özellikler elde etmiş olunur. Sayısal özellikler çıkarılırken Matlab'ın vektör ve matris işlemlerini kullanmak özellik hesaplanmasında büyük kolaylıklar sağlamaktadır bu sebeple bütün özellikler Matlab ile çıkarılmıştır.

Bu çalışmada 4 farklı yöntem ile sayısal özellikler belirlenmiştir. İlk olarak birincil istatistik (minimum değeri, max değeri, entropi vb.) özelliklerden 8 özellik, gri düzey birlikte oluşum matrisi (GLCM) üzerinden 22 özellik, Ayırık dalgacık dönüşümünü (DWT) temel alan 8 özellik ve son olarak yüzde değer özelliklerinden 2 özellik olacak şekilde toplam 40 özellik tüm tümör tipleri ve çekim sekanları için çıkarılarak tablolanmıştır.

Çıkarılan tüm sayısal özellikler tümörleri sınıflandırmak için uygun değildir. Çalışılan tümörler üzerinde tüm tümör tipleri için farklı anlamlı sayısal özellikler ayırt edici olarak belirlenmiştir. Ayırt edici olan sayısal özellikler Student t-Test yöntemi ile belirlenmiştir ve bu özellikler sınıflandırma için hazır hale getirilmiştir. Özellik çıkarımı için kullanılan yöntemler ve özellik seçimi için kullanılan Student t-Test yöntemini ilerleyen kısımlarda ayrıntılı olarak yer verilmiştir. Tablo2.2'de özellik çıkarımı için kullanılan yöntemler ve hesaplanan sayısal özelliklere yer verilmiştir.

Tablo 2.2. Özellik çıkarımı için kullanılan yöntemler ve bu yöntemler ile hesaplanan sayısal özellikler.

Özellik Çıkarım Yöntemi	Hesaplanan Sayısal Özellikler
Birincil İstatik	Minimum değer, Maksimum değer, Ortalama değer, Standart sapma, Varyans, Basıklık, Çarpıklık, Entropi
GLCM	Otokorelasyon, Kontrast, Korelasyon 1, Korelasyon 2, Küme Önem, Küme Gölgesi, Farklılık, Enerji, Entropi, Homojenlik 1, Homojenlik 2, Maximum Olasılık, Kareler Toplamı, Toplam Ortalama, Toplam Varyans, Toplam Entropi, Fark Varyansı, Fark Entropisi, Korelasyon Bilgi Ölçümü 1, Korelasyon Bilgi Ölçümü 2, Normalleştirilmiş Ters Fark, Ters Fark Momenti
DWT	Ayrık Dalgacık Dönüşümü üzerinden elde edilen Minimum değer, Maksimum değer, Ortama değer, Standart sapma, Varyans, Basıklık, Çarpıklık, Entropi
Yüzde Değerleri	Yüzde 10 değeri, Yüzde 90 değeri

2.3.1. Birincil İstatiksel Özellikler

Birinci derece dokusal özellikler, doğrudan MRG 'den alınan görüntülerden hesaplanan, görüntünün gri seviye histogramının temel istatistiksel özelliklerinden elde edilmektedir. Bu çalışmada 8 birincil istatistiksel özellik çıkarılmıştır. Bu özellikler minimum değer, maksimum değer, ortalama değer, standart sapma, varyans, basıklık çarpıklık ve entropidir. Bu istatistiksel özelliklerin açıklamaları şu şekildedir;

- **Minimum Değer:** Bu değer görüntüde en koyu yada en düşük yoğunluğa sahip pikselinin değerini ifade etmektedir. Görüntü üzerinde bu değer genel olarak siyah veya koyu renkli bölgelerde yer almaktadır.
- **Maksimum Değer:** Bu değer görüntüde en parlak yada en yüksek yoğunluğa sahip pikselinin değerini ifade etmektedir. Bu değer görüntü üzerinde genellikle beyaz veya parlak renkli bölgelerde yer almaktadır.
- **Ortalama Değer:** Bir görüntüdeki tüm piksel değerlerinin toplamının piksel sayısına bölünmesiyle elde edilen bir değerdir.

$$Ortalama = \left(\frac{1}{m \times n} \right) \sum_{x=0}^{m-1} \sum_{y=0}^{n-1} f(x, y) \quad (2.1)$$

- **Standart Sapma:** Bir görüntüde standart sapma, piksel değerlerinin ortalama etrafında ne kadar yayılım gösterdiğini ölçmektedir. Hesaplanan standart sapma değeri görüntüde yoğunluk dağılım ölçüsü bilgisinin yanı sıra görüntüden kontrast yada homojenlik bilgisi elde edilebilecek özellikler çıkarılabilmektedir.

$$StandartSapma(\sigma) = \sqrt{\left(\frac{1}{m \times n} \right) \sum_{x=0}^{m-1} \sum_{y=0}^{n-1} (f(x, y) - M^2)} \quad (2.2)$$

- **Varyans:** Görüntüde pikseller arasında bulunan yoğunluk değişkenliğinin ölçüsünün bilgisini vermektedir. Sayısal olarak hesaplanırken standart sapma değerinin karesine eşittir.

$$Varyans(\sigma) = \left(\frac{1}{m \times n} \right) \sum_{x=0}^{m-1} \sum_{y=0}^{n-1} (f(x, y) - M^2) \quad (2.3)$$

- **Basıklık:** Bu değer görüntüye ait histogramın simetrikliğini ya da asimetrikliğini ölçmektedir. Bir görüntüde histogram sağa doğru çekilerek pozitif basıklık sola doğru çekilerek negatif basıklık göstermektedir. Bu değerın sıfıra yaklaşması daha simetrik histogram oluşturmaktadır.

$$K_{urt}(X) = \left(\frac{1}{m \times n} \right) \frac{\sum (f(x, y) - M)^4}{SD^4} \quad (2.4)$$

- **Çarpıklık:** Bir görüntünün çarpıklık değeri histogramın asimetrikliğini ölçmektedir. Bir görüntüde histogramın sola doğru uzaması pozitif çarpıklığı sağa doğru uzaması ise negatif çarpıklığı ifade etmektedir. Bu değer sıfıra yakınlattıkça daha simetrik histogram oluşmaktadır.

$$S_k(X) = \left(\frac{1}{m \times n} \right) \frac{\sum (f(x, y) - M)^3}{SD^3} \quad (2.5)$$

- **Entropi:** Bu değer görüntünün istatistiksel düzensizliği yada bilgi içeriği hakkında ölçümler yapar. Entropi değeri yüksek olması görüntünün çok daha karmaşık ve düzensiz olduğunu ifade ederken düşük entropi değeri görüntünün düzenli yada homojen olduğunu ifade eder [25].

$$E = - \sum_{x=0}^{m-1} \sum_{y=0}^{n-1} f(x, y) \log 2f(x, y) \quad (2.6)$$

Yukarıdaki açıklanan formüllerde m ve n değerleri sırasıyla yükseklik ve genişlik boyutlarını ifade etmektedir. f(x,y) görüntülerin piksel değerini ve M ise ortalama değerini ifade etmektedir.

2.3.2. İkinci Dereceden Gri Düzey Birlikte Oluşum Matrislerini Temel Alan Özellikler

Gri düzey birlikte oluşum matrisi(GLCM), dokuları inceleyen ve piksellerin mekansal ilişkilerini gözden geçiren istatistiksel bir yöntemdir. Görüntüde belirli çevresel ilişkiye sahip ve belirli bir değeri olan piksel ikililerinin ne kadar sıklıkla ortaya çıktığını hesaplar ve sonuç olarak görüntünün dokusunu karakterize etmiş olur. Bu matris ile bir çok istatistiksel değerler hesaplanmaktadır [26].

Tıbbi görüntü işlemede şekil, boyut gibi özelliklerin yanında doku özellikleride büyük bir öneme sahiptir. İkinci dereceden istatistiksel özellikler formülize edilerek bir çok dokuyu tanımlayan özellikler çıkarılabilir. GLCM matrisi bize görüntülerde gri seviyelerinin farklı birleştirmelerinin hangi sıklıkla bir arada oluştuğunun göstergesidir [27].

MRG vasıtasıyla beyindeki dokuların karmaşık yapısı görüntülenirken ayırt edici özelliklerin çıkarılması önemli bir adımdır. Bu çalışmada gri düzey birlikte oluşum matrisi kullanılarak toplam 22 tane ikinci dereceden dokusal özellikler hesaplanmıştır. Çalışma kapsamında çıkarılan bir kaç özellik şu şekildedir;

- **Kontrast:** Piksellerin yoğunluğunu ve komşusunun bitişiğindeki pikselleri tanımlar.
- **Enerji:** Enerji, bir MRG görüntüsündeki pikseller arasındaki benzerliği sunar ve aynı değerlere sahip piksellerin tekrarlarını tanımlar.
- **Homojenlik:** Homojenlik değeri görüntüde dokulanma olması gereken bölgeleri ifade etmektedir.
- **Korelasyon:** Bir görüntüde piksellerin bilgileri arasındaki ilişkiyi ifade etmektedir [28].
- **Otokorelasyon:** Bu özellik ile görüntüde yer alan dokunun inceliği ve ne kadar pürüzsüz olduğunu tahmin etmek için kullanılmaktadır. Dokuda pürüzlerin bulunması ile otokorelasyon fonksiyonu yavaş bir şekilde aşağıya yönelim gösterir.
- **Küme Belirginliği:** bir görüntüde asimetrikliğin bir ölçüsü olarak tanımlanır. Görüntü küme belirginliği değeri yüksek ise görüntü daha az simetrik durumundadır.
- **Entropi:** Entropi değeri görüntüde rastgelelik ölçüsü olup görüntünün dokunu tanımlamada kullanılır [27].

Yukarıda bazı ikinci derecen gri düzey birlikte oluşum matrisi ile çıkarılan bazı istatistiksel özelliklere yer verilmiştir. Bu özellikler Matlab'te görüntülere gri düzeyde birlikte oluşum matrisi oluşturularak elde edilmiştir. Tablo2.3'de ise çıkarılan bir çok özellik ve formülleri yer almaktadır.

Tablo 2.3. İkinci Dereceden Gri Düzey Birlikte Oluşum Matrislerini temel alan özellikler ve formülleri.

GLCM Özellikleri	Formüller
Otokorelasyon	$\text{Autocorrelation} = \sum_i \sum_j \frac{(p_x - \mu_x)(y_x - \mu_x)}{\sigma_x \sigma_y}$
Kontrast	$\text{Contrast} = \sum_{x,y=0}^{K-1} P_{xy} (x - y)^2$
Korelasyon	$\text{Correlation} = \sum_{x,y=0}^{K-1} P_{xy} \frac{(x - \mu)(y - \mu)}{\sigma^2}$
Homojenlik	$\text{Homogeneity} = \sum_{x,y=0}^{K-1} -\ln(P_{xy}) P_{xy}$
Enerji	$\text{Energy} = \sum_{x,y=0}^{K-1} (P_{xy})^2$
Ters Fark Momenti	$\text{IDM} = \sum_{x=0}^{m-1} \sum_{y=0}^{n-1} \frac{1}{1+(x-y)^2} f(x, y)$
Entropi	$E = - \sum_{x=0}^{m-1} \sum_{y=0}^{n-1} f(x, y) \log 2f(x, y)$
Farklılık	$\text{Dissimilarity} = \sum_{i,j=0}^{N-1} P i, j $
Toplam Ortalama	$\text{Aver} = \sum_{i=0}^{2G-2} i P_{x+y}(i)$
Toplam Entropi	$\text{Sent} = - \sum_{i=0}^{2G-2} P_{x+y}(i) \log(P_{x+y}(i))$
Fark Entropisi	$\text{Dent} = - \sum_{i=0}^{G-1} P_{x+y}(i) \log(P_{x+y}(i))$
Küme Gölgesi	$\text{Shade} = \sum_{i=0}^{G-1} \sum_{j=0}^{G-1} (i + j - \mu_x - \mu_y)^3 * P(i, j)$
Küme Önem	$\text{Prom} = \sum_{i=0}^{G-1} \sum_{j=0}^{G-1} (i + j - \mu_x - \mu_y)^4 * P(i, j)$
Korelasyon Bilgi Ölçümü	$\text{IMC} = - \sum_{i,j=0}^{G-1} P(i, j) \log \{P_x(i) P_y(j)\} \quad (2.1)$


2.3.3. Ayırık Dalgacık Dönüşümünü Temel Alan Özellikler

Bu çalışmada kullanılan bir diğer özellik çıkarımı yöntemide ayırık dalgacık dönüşümü(DWT) ile elde edilen özelliklerdir. Ayırık dalgacık dönüşümü yöntemi dalgacık dönüştürme yöntemi olup zaman ve frekans bilgisi hakkında içerikler veren yöntemdir. Bu yöntem alçak ve yüksek geçirgen filtrelerin filtrelenmesi konusunda çalışmaktadır. Alçak ve yüksek geçişli filtrelerde düşük geçişli olan filtreler görüntüde her zaman yakınsamayı verirken yüksek geçişli olan filtreler görüntüde kenar bilgisi vermektedir [29].

DWT, frekansları farklı bant çözünürlüklerine ayırmaktadır. Görüntü üzerinde yatay yönde düşük frekanslara karşılık gelen dikeyde ise yüksek frekanslara karşılık gelen bant çözünürlüğüne ayırmaktadır. Yatay yönde olan yüksek frekanslar LH yani dikey ayrıntıları ifade eder. Dikey yönde olan düşük frekanslar HL yani yatay ayrıntıları ifade eder. Görüntüde yatay ve dikey yönde de düşük olan frekanslar LL yani yaklaşım görüntüsünü ifade eder. Yatay ve dikey yöndeki yüksek frekanslar ise HH yani çapraz ayrıntılar olarak ifade edilmektedir [30]. Şekil 2.7’de dalgacık dönüştürme işlemine yer verilmektedir.

Dalgacık dönüşümü, bir çok çözünürlük seviyelerine sahip görüntülerde inceleme analiz imkanı sağlar. Bu işlemleri çoklu çözünürlüklü analitik olmasıyla sağlamaktadır [30]. Bu yetileri sebebiyle MRG görüntülerinde ayırıcı özelliklerin çıkarılmasında kullanılan etkili bir yöntemdir. Yapılan bu çalışmada ayırık dalgacık dönüşümü yöntemi kullanılarak 8 özellik çıkarılmıştır. Bu özellikler minimum değeri, maksimum değeri, ortalama değeri, standart sapma, varyans, basıklık, çarpıklık ve entropi değerleridir. Görüntülerde ayırt edici yapılar olarak belirlenmiştir. Sonuç kısmında daha detaylı yer verilmiştir.

Matlab’te bulunan ayırık dalgacık ayrıştırılması gerçekleştirilmiştir ve katsayılar ayrıntılı olarak ayıklanmıştır. Ayıklanan katsayılardan 8 adet özellik bütün görüntülerdeki çalışılan tüm kesitler için hesaplanmıştır.



Şekil 2.7. Ayrık Dalgacık Dönüşümü ayrıştırma işlemi için akış şeması. Görselde; A = Satırlarda Düşük Geçiş Filtresi , B = Sütunlarda Yüksek Geçiş Filtresi ve C = Sütunlarda Düşük Geçiş Filtresidir.

2.3.4. Yüzde Değer Özellikleri

Yüzde değer özellikleri özellik çıkarımında bir çok alanda kullanılmaktadır. Yüzde değerleri bize görüntünün pikselleri ve yapılan hesaplamalar ile görüntüye ait istatistiksel bilgiler vermektedir. Özellik çıkarımında yüzde değerleri kullanılarak görüntüye ait veriler için her bir özelliği üzerinden yüzde değerleri hesaplanarak veriler analiz edilebilmektedir.

Bu çalışmada yüzde değerleri görüntülerdeki piksel yoğunluğu üzerinden hesaplanmıştır. Piksel yoğunluklarının % 10 değeri ve % 90 değeri olacak şekilde 2 özellik çıkarılmıştır.

Matlab'te gradyanların büyüklüğü ve yönü hesaplanmıştır. Gradyan büyüklüğü bize görüntüde piksellerin yoğunluk değişimlerinin değerini temsil ederken yönü, bu değişimlerin yönünü ifade etmektedir. Bu veriler üzerinden yüzde değer özellikleri çıkarılmıştır. Bu özellikler tümörlerin sınıflandırılmasında ayırt edicilik sağlamıştır.

2.4. Öznitelik Seçimi

Bu çalışmada toplam 40 özellik çıkarılmıştır. Çıkarılan bütün özellikler tüm tümörler için anlamlı değildir. Tümörleri spesifik olarak anlamlandıran ve sınıflandırılmasında kolaylık sağlayan özellikleri ayıklamak gerekmektedir. Anlamlı ve spesifik özellikler bu çalışmada Matlab üzerinden Student t-Test yapılarak ayıklanmıştır.

Student t-Test, istatistiksel bir test yöntemi olup iki veri kümesi arasında kayda değer ölçüde farklılık olup olmadığını görmek için kullanılmaktadır. Sonuçların normal dağılım göstermesi yöntemin sıfır hipotezinin doğru olduğunu göstermektedir. İki birbirinden bağımsız grup arasında farklılıklar olup olmadığını belirlemek için uygun bir yöntem olarak kullanılmaktadır. Bu testin verilerde uygulanabilir olabilmesi için teste tabi tutulacak grupların tamamen birbirinden bağımsız olması gerekmektedir. Kullanılan verilerin boyutu küçük olduğunda daha iyi şekilde kullanılmaktadır. Bu test tercih edilmeden önce kullanılan veri grupları uygun olacak şekilde normal bir dağılıma sahip olması önemli bir ayrıntıdır. Normal bir dağılım sergilememeleri durumunda Student t-Test kullanılması uygun bir tercih olmamaktadır.

Bu test ile sonuç olarak iki çıktı elde edilir. Bu çıktıları p değeri ve t değeri oluşturmaktadır. Yapılan test sonucunda daha düşük çıkan p değeri çalışılan 2 grup arasında olan farkın daha anlamlı olduğunu ifade etmektedir. Elde edilen t değeri çalışılan iki veri seti arasındaki farklılığın büyüklüğünü ve yönünü ifade etmektedir. İki veri seti arasındaki farkın tesadüfi olup olmaması ise p değerini ifade etmektedir.

Yukarıda anlatılan dört farklı özellik çıkarımı yöntemleri ile 40 farklı özellik tümörlerden çıkarılmıştır. Tümörlerden çıkarılan özellikler excel tablosu yapılarak kaydedilmiştir. Tüm tümör grupları ve farklı sekanslar için Student t-Test uygulanmıştır. Öznitelik seçimi Matlab'te Student t-Test ile kolayca gerçekleştirilerek tümör grupları arasında anlamlı sayısal özellikler belirlenmiştir. Çıkarılan anlamlı sayısal özelliklere bulgular kısmında ayrıntılı bir şekilde yer verilmiştir. Belirlenen anlamlı sayısal özellikler makine öğrenmesi algoritmaları ile sınıflandırılmak üzere hazır hale getirilmiştir.


2.5. Makine Öğrenmesi Algoritmaları ve Sınıflandırma

Bu çalışmada özellik çıkarımı ile elde edilen özniteklerden anlamlı olan sayısal özellikler üzerinden tümörler makine öğrenmesi algoritması yöntemleri kullanılarak sınıflandırılmıştır.

İlerleyen teknoloji ile birlikte insanlar bazı işlemleri daha basit bir şekilde yapabilmenin yöntemlerini bulmaya çalışmışlardır. Bu ihtiyaçlardan insan beyninin yaratıcılığı ile farklı makineler icat edilmiştir. Bu makineler hesaplama yapmak gibi birçok ihtiyaç konusunda insan yaşamını kolaylaştırmıştır. Makine öğrenimi de bu kolaylıklardan biridir. Makinelere yüklenen verileri daha iyi verimli bir şekilde işlenmesini öğretmek için kullanılan bir yöntemdir. Makine öğrenmesinin amacı verilerden öğrenmektir. Bizler için sadece verilere bakılarak bu verilerden elde edilen bilgileri yorumlayamayabiliriz. Kullanılan verilerin çokluğunda büyük bir zorluktur. Bu gibi ihtiyaçlar doğrultusunda makine öğrenimi ortaya çıkmıştır [31].

Makine öğrenmesi ile yerine getirmesi beklenen işlem için makineye programlar atılır ve makineden işlem sırasında deneyim kazanması ve bu deneyimlerden öğrenerek daha yüksek performansta işlem yapması beklenmektedir. Makine öğrenmesi ile verilere dayalı tahminler yapılarak makine karar verebilmektedir. Makine öğrenmesi bir çok farklı alanda kullanılmaktadır. Bu alanlara google gibi kişisel asistanlar, veri madenciliği, tıbbi teşhis, çevrim içi ulaşım ağları, sosyal medya hizmetleri gibi bir çok örnek verilebilmektedir [32]. Bu uygulamalar sınıflandırma regresyon ve kümeleme gibi işlemleri kapsamaktadır. Veriler farklı gruplara ayrılarak sınıflandırılabilir veya ev fiyatlarını tahmin etmek için regresyon yapılarak bir veri noktasının değeri sayısal olarak tahmin edilebilir. Son olarak verileri benzerliklerine göre kategorize edip kümeleme işlemleri yapılabilir.

Bir çok makine öğrenmesi algoritması bulunmaktadır ve kullanılan eğitim veri türlerine bağlı olarak denetimli öğrenme, denetimsiz öğrenme, yarı denetimli öğrenme ve pekiştirmeli öğrenme çeşitlerinden biri kullanılarak sınıflandırma, kümeleme veya regresyon işlemleri yapılabilmektedir. Şekil 2.8 'de makine öğrenmesi algoritmaları yer almaktadır.



Şekil 2.8. Makine öğrenmesi algoritmaları.

Denetimli veya gözetimli öğrenme algoritmalarında girdiler ile hedef çıktıları eşleyen bir fonksiyon oluşturulmaktadır. Bu öğrenmenin asıl görevi sınıflandırmadır ve bir çok sınıf arasından birkaç giriş çıkış örneğine bakarak bir vektörü yakın davranışlar gösteren fonksiyonu belirleyerek bir sınıfa atamaktadır. Denetimsiz veya gözetimsiz öğrenmede ise giriş kümesi modellenmektedir. Yarı denetimli öğrenmede ise uygun sınıflandırıcı oluşturmak için hem etiketli hem de etiketsiz örnekler kullanılmaktadır [33]. Denetimli öğrenme algoritmaları sınıflandırma ve regresyon uygulamalarında daha uygun olurken kümeleme uygulamaları denetimsiz öğrenme algoritmaları ile yapılmaktadır. Denetimli öğrenmede regresyonun kullanım alanı olarak ev fiyatı tahmini, sınıflandırma uygulamalarına örnek olarak spam filtresi tasarımı verilebilir. Denetimsiz öğrenmede kümeleme uygulamalarına müşteri ürün segmentasyonu örnek verilebilir. Yarı denetimli öğrenmede kümeleme ve sınıflandırma uygulamalarına dil analizi örnek verilebilir.

Sınıflandırma, regresyon ve kümeleme işlemleri için bir çok farklı makine öğrenmesi algoritması bulunmaktadır. Makine öğrenmesi algoritmalarının tıbbi teşhis gibi bir çok sağlık alanında sağladığı kolaylıklar çalışmamızda yer vermemizde büyük bir öneme sahiptir. Bu çalışmada denetimli öğrenme algoritmalarından biri olan destek vektör makineleri kullanılarak tümörler sınıflandırılmıştır.

2.6. Destek Vektör Makineleri

Denetimli öğrenme grubunda olan destek vektör makineleri(SVM), yüksek doğruluk sağlayabilen karmaşık bir algoritmadır. Yüksek boyutlu verilerde iyi bir genelleme yeteneğine sahiptir ve bu verilere karşı dayanıklıdır. Parametrelerin seçimi performansında büyük öneme sahiptir. Eğitim hızı diğer algoritmalara göre azdır [34].


SVM, hem sınıflandırma hem de regresyon uygulamalarında tercih edilen fakat daha çok sınıflandırma uygulamalarında kullanılan bir algoritmadır. Sınıflandırma uygulamalarında eğitim veri setinde bulunan örnek veriler üzerinden nesneleri doğru olarak sınıflandırmayı amaçlamaktadır. Farklı sınıfları ait verileri ayırt etmek için karar düzlemine gereksinim duymaktadır. Nesnelerin sınıflandırılmasında karmaşık matematiksel fonksiyonlar kullanılmaktadır. Bu karmaşık matematiksel fonksiyonlara çekirdek adı verilmektedir [32].

Destek vektör makineleri ile sınıflandırma fonksiyonuna ait denklem (2.7) gibi ifade edilmektedir.

$$f(z) = \text{sign}\left[\sum_{i=1}^n a_j y_j x_j z + b\right] \quad (2.7)$$

Bu denklemde x_j parametresi destek vektörlerini, a_j parametresi optimum Lagrange çarpanlarını, y_j parametreleri sınıf etiketlerini ifade etmektedir. Formülde yer alan b değişkeni ise bias parametresi yani fonksiyonun eğilim parametresi olarak ifade edilmektedir [35].

SVM algoritması çalışırken veri gruplarını ayırmak için hiperdüzlem tanımlanmalıdır. Sınıflandırma işleminin yapılabilmesi için verileri maksimum marjla ayırabilen hiperdüzlemin bulunması gerekmektedir. Bu hiperdüzlem sınıflandırma hatalarını en aza indirmek için her iki veri grubu için marjinal mesafeyi en üst düzeye çıkarmaktadır. Veriler içerisinde her bir veri öncelikli olarak n boyutlu bir uzayda bir nokta olarak çizilir ve her bir niteliğin değeri belirli bir koordinatın değerini ifade etmektedir [36]. Şekil 2.9'de SVM'nin çalışma prensibi görselleştirilmiştir.



Şekil 2.9. Destek Vektör Makineleri(SVM)'nin çalışma prensibi. İkinci derece denklemlerde hiperdüzlem bir çizgi iken üçüncü derece denklemlerde yüzey şeklindedir.

SVM algoritması bir çok uygulamada kullanılmaktadır. Bunlara örnek olarak el yazısı tanıma, yüz algılama, metin sınıflandırma, biyoinformatik ve sağlık alanında kanser teşhisi gibi bir çok alanda yer almaktadır.

SVM'nin uygulamalarda bir çok avantajı bulunmaktadır. Bu avantajlar arasında verilerde yüksek doğrulukta sınıflandırma, karmaşık yapıda olan karar sınırlarını modelleyebilme ve çok sayıda bağımsız değişken içeren verilerde çalışabilme bulunmaktadır. Bu avantajların yanı sıra bazı dezavantajları da bulunmaktadır. Eğitim süresinin uzun olması dezavantaj olarak SVM 'de büyük veri setlerinde performansının düşmesine sebep olmaktadır. Bir diğer dezavantajı ise kullanılan veri setinde gürültülerin bulunması SVM'nin çalışmasını olumsuz etkiler ve iyi çalışmaz [32]. Bu çalışmada sınıflandırma işlemi WEKA programı üzerinden destek vektör makineleri kullanılarak gerçekleştirilmiştir.

Bu bölümde çalışmamız kapsamında kullanılan yöntemlere ayrıntılı bir şekilde yer verilmiştir. Bir sonraki bulgular bölümünde kullanılan yöntemler ile elde edilen sonuçlara yer verilecektir.

3. BÖLÜM

BULGULAR

3.1. Görüntü Segmentasyonu ve Sonuçları

Bu çalışmada görüntü segmentasyonu adımımda iki farklı yöntem kullanılarak görüntüler bölütlenmiştir. Erciyes Üniversitesi Çocuk Radyolojisi bölümünden alınan Posterior Fossa tanılı hastaların görüntüleri kullanılmıştır. Alınan manyetik rezonans görüntüleri Matlab programı ile kesitlere parçalanmıştır. Alınan kesitlerde tümörün belirgin olduğu kesitler seçilerek segmentasyon işlemi bu kesitler üzerinde gerçekleştirilmiştir. Bir kişi için ortalama 5-6 kesit üzerinde segmentasyon işlemi yapılmıştır.

Tümörler üzerinde segmentasyon işlemine başlamadan önce görüntü kalitesini iyileştirmek için görüntülere histogram eşitleme yani kontrast artırma uygulanmıştır. Çalışılan kesitlerde tümör segmentasyonu için beklenti maksimasyonu algoritması ve bölge bazlı aktif kontur segmentasyonu kullanılmıştır. Bu iki yönteminde sağlık alanında bir çok uygulamada kullanılması çalışmamızda da yer vermemizde büyük bir öneme sahiptir. Bölge bazlı aktif kontur segmentasyonunun gürültü bulunan görüntülerde ve renk tonları karışık olan tümör görüntülerinde sınırları belirlemede çalışmamızda kolaylıklar sağlamıştır. Bu iki segmentasyon algoritması hazır kodlar üzerinden çalışılan görüntülere uyarlanarak uygulanmıştır. Kullanılan iki farklı görüntü segmentasyonu yöntemi ile tüm tümörler başarılı bir şekilde bölütlenmiştir.

3.2. Özellik Çıkarımı ve Sonuçları

Yapılan çalışmada özellik çıkarımı adımımda dört farklı yöntem kullanılarak sayısal özellikler çıkarılmıştır. Kullanılan yöntemler ile birincil istatistiksel özellikler, ikinci dereceden gri düzey birlikte oluşum matrislerini temel alan özellikler, ayrık dalgacık dönüşümünü temel alan özellikler ve yüzde değer özellikleri olacak şekilde toplam 40

özellik çıkarılmıştır.

Bu özelliklerin 8 tanesi birincil istatistiksel özelliklerdir. Bu özellikler minimum değer, maksimum değer, ortalama değer, standart sapma, varyans, basıklık, çarpıklık, entropi'dir. GLCM kullanılarak toplam 22 özellik çıkarılmıştır. Bu özellikler Otokorelasyon, Kontrast, Korelasyon 1, Korelasyon 2, Küme önem, Küme gölgesi, Farklılık, Enerji, Entropi, Homojenlik 1, Homojenlik 2, Maksimum olasılık, Kareler toplamı, Toplam ortalama, Toplam varyans, Toplam Entropi, Fark varyansı, Fark entropisi, Korelasyon bilgi ölçümü 1, Korelasyon bilgi ölçümü 2, Normalleştirilmiş ters fark, Ters fark momenti' dir.

DWT'yi temel alan toplam 8 özellik çıkarılmıştır. Bu özellikler minimum değer, maksimum değer, ortalama değer, standart sapma, varyans, basıklık, çarpıklık, entropi'dir. Son olarak görüntünün piksel yoğunluğu üzerinden %10 değeri ve %90 değeri olacak şekilde 2 özellik çıkarılmıştır.

Bu çıkarılan özelliklerin hepsi çalışılan Posterior Fossa tümör çeşitleri için anlamlı olmamaktadır. Tümörler için spesifik olan anlamlı sayısal özelliklerin belirlenmesi gerekmektedir. Bu çalışmada anlamlı olan özellikler Matlab üzerinden Student t-Test kullanılarak belirlenmiştir. Çalışılan tüm tümör tipleri ve çekim sekansları için Student t-Test uygulanarak tümörlerin sınıflandırılması için gereken anlamlı sayısal özellikler belirlenmiştir. Bazı tümör grupları arasında 40 özellik içerisinde anlamlı bir sayısal özellik bulunamamıştır. Tablo 3.1 'de üç farklı posterior Fossa tümörü tipi ve T2, kontrastı arttırılmış T1 ve ADC sekansları için ayırt edici özellik sayısına yer verilmiştir. T2 sekansı için belirlenen anlamlı sayısal özellikler ise Tablo 3.2' de gösterilmiştir.

Tablo 3.1. Çekim sekansları için Posterior Fossa tümör tipleri arasında elde edilen anlamlı özellik sayısı.

Tümör Tipi	T2 SEKANSI	T1 SEKANSI	ADC SEKANSI
EM-MB	—	2	18
EM-PA	15	2	—
MB-PA	11	6	22

Tablo 3.2. T2 sekansı için Posterior Fossa tümör tipleri ile elde edilen anlamlı özellikler.

Anlamlı Özellikler MB - PA		EM -PA
GLCM	Otokorelesyon, Küme Önem,	Otokorelesyon, Küme Önem,
	Kareler Toplamı, Toplam Varyans	Kareler Toplamı, Toplam Varyans,
DWT		Toplam Ortalama,
		Korelasyon Bilgi ölçümü 1,
		Korelasyon Bilgi ölçümü 2
	Standart Sapma ,Varyans,	Maksimum Değer, Ortalama Değer
	Çarpıklık, Entropi	Standart Sapma, Varyans
Birincil İstatiksel		Basıklık ,Entropi
	Standart Sapma,Varyans,	Standart Sapma, Varyans
	Basıklık	

Tablo 3.2’de T2 sekansı için Posterior Fossa tümör tiplerinden elde edilen anlamlı sayısal özellikler gösterilmiştir. MB-PA arasında 11 anlamlı, EM-PA arasında 15 anlamlı özellik bulunurken MB-EM arasında ise anlamlı özellik bulunamamıştır. T2 sekansı ile yapılan özellik çıkarımında bazı özellikler ortak olarak anlam ifade etmiştir. Yüzde değer özellikleri T2 sekansı görüntülerinde anlamlı özellik çıkarımında başarılı olmamıştır. Aşağıdaki Tablo 3.3’ de kontrastı artırılmış T1 sekansı için belirlenen anlamlı sayısal özellikler gösterilmiştir.

Tablo 3.3. Kontrastı artırılmış T1 sekansı için Posterior Fossa tümör tipleri ile elde edilen anlamlı özellikler.

Anlamlı Özellikler	EM - PA	MB -PA	EM-MB
GLCM	————	————	————
DWT	Basıklık, Çarpıklık	Basıklık, Çarpıklık	————
Birincil İstatiksel	————	Basıklık, Çarpıklık	————
Yüzde değer	————	Yüzde 10, Yüzde 90	Yüzde 10, Yüzde 90

Tablo 3.3’ de kontrastı artırılmış T1 sekansı için Posterior Fossa tümör tiplerinden elde edilen anlamlı sayısal özellikler gösterilmiştir. T1 sekansı için çalışılan özelliklerden çok azı anlam ifade etmiştir. T2 sekansında yüzde değer özellikleri anlam ifade etmezken T1 sekansında MB - PA ve EM - MB tümörlerinin arasında anlamlı sayısal özellik olarak belirlenmiştir. Wavelet dönüşümü ile elde edilen basıklık ve çarpıklık özellikleri gruplar arasında anlamlı olarak belirlenmiştir. Kontrastı artırılmış T1 sekansı için EM- MB arasında 6, PA-EM arasında 2, EM-MB arasında ise 2 anlamlı özellik çıkarılmıştır.

Tablo 3.4’de ADC sekansı için Posterior Fossa tümör tiplerinden elde edilen anlamlı sayısal özellikler gösterilmiştir. ADC sekansı için PA - MB arasında 22, MB - EM arasında 18 anlamlı fark bulunurken, PA - EM tümörleri arasında anlamlı fark bulunamamıştır. ADC sekansı ile diğer sekanslara göre çalışılan sayısal özelliklerden daha fazla anlamlı özellik çıkarılmıştır. T2 sekansında olduğu gibi yüzde değer özellikleri ADC sekansında da anlamlı özellik çıkarımında başarılı olamamıştır. Bu çıkarılan sayısal özellikler tümörlerin sınıflandırılmasında büyük önem taşımaktadır. Bir sonraki adımda yapılan sınıflandırma işlemi belirlenen anlamlı özellikler üzerinden gerçekleştirilmiştir.

Tümör tiplerinden elde ettiğimiz anlamlı sayısal özelliklere göre bulduğumuz sonuçlar International Izmir Congress on Life, Engineering and Applied Sciences Proceedings Book kitabında bildiri olarak yayınlanmış olup kongrede sunulmuştur.

Tablo 3.4. ADC sekansı için Posterior Fossa tümör tipleri ile elde edilen anlamlı özellikler.

Anlamlı Özellikler MB - PA		MB - EM
GLCM	Otokorelesyon, Korelasyon 1,	Otokorelesyon, Korelasyon 2,
	Korelasyon 2, Küme Önem,	Kareler Toplamı, Küme Gölgesi,
	Küme Gölgesi, Enerji,	Toplam Ortalama,
	Entropi, Homojenlik 1,	Toplam Varyans
	Homojenlik 2, Maksimum Olasılık,	
	Kareler Toplamı, Toplam Ortalama,	
	Toplam Varyans, Fark Entropisi	
DWT	Ortamala Değer, Standart Sapma,	Minimum Değer, Maksimum Değer,
	Basıklık, Varyans	Standart Sapma, Varyans,
		Basıklık, Çarpıklık
Birincil İstatiksel	Ortamala Değer, Standart Sapma,	Minimum Değer, Maksimum Değer,
	Basıklık, Varyans	Standart Sapma, Varyans,
		Basıklık, Çarpıklık

3.3. Makine Öğrenmesi Algoritması ve Sonuçları

Bu tez çalışmasında Posterior Fossa tümörleri Destek Vektör Makinaları kullanılarak sınıflandırılmıştır. Sırasıyla T2, kontrastı artırılmış T1 ve ADC sekanları için tümörlerin sınıflandırılma sonuçları açıklanmıştır. Sınıflandırma işlemleri WEKA programı üzerinden yapılmıştır.

3.3.1. T2 Sekansı için Posterior Fossa Tümörlerinin Sınıflandırma Sonuçları

T2 sekansı için Posterior Fossa tümörlerinden 5 kişi pilositik astoristom, 12 kişi ependimom, 11 kişi medulloblastom olmak üzere toplam 28 kişi üzerinde sınıflandırma işlemi yapılmıştır.

T2 sekansında medulloblastom ve ependimom tümörleri aralarında anlamlı sayısal özellik çıkarılamadığı için sınıflandırılmamıştır.

Pilositik astrositom ve medulloblastom tümörleri arasında yapılan sınıflandırma SVM algoritmasında çapraz doğrulama(Cross- validation) yapılarak sonuçlar elde edilmiştir.

Yapılan sınıflandırma sonucunda;

TP Oranı: 1,


FP Oranı: 0,

F-Ölçümü: 1,

ROC Alanı: 0.757 sonuçları elde edilmiştir.

$$Dogruluk = \frac{TP + TN}{TP + FP + TN + FN} \quad (3.1)$$

Denklem 3.1'de TP, gerçek pozitif; TN, gerçek negatif; FP yanlış pozitif; FN, yanlış negatifi ifade etmektedir. Bu değerler doğrultusunda pilositik astrositom ve medulloblastom tümörleri % 100 doğrulukla sınıflandırılmıştır. Şekil 3.1'de pilositik astrositom ve medulloblastom tümörlerinin sınıflandırılması görselleştirilmiştir.



Şekil 3.1. T2 sekansı için pilositik astrositom ve medulloblastom tümörlerinin ayırık dalgacık dönüşümü ile elde edilen basıklık ve varyans özelliklerine göre sınıflandırma sonucu grafik görüntüsü. Görüntüde sarı olanlar pilositik astrositom, mavi olanlar ise medulloblastom tümörüne sahip kişileri ifade etmektedir.

Pilositik astrositom ve ependimom tümörleri arasında yapılan sınıflandırma SVM algoritmasında çapraz doğrulama yapılarak sonuçlar elde edilmiştir.

Yapılan sınıflandırma sonucunda;

TP Oranı: 0.882,


FP Oranı: 0.282,

F-Ölçümü: 0.882,

ROC Alanı: 0.800

Doğruluk : % 88.2353 sonuçları elde edilmiştir.

Pilositik astrositom tümörüne sahip 2 kişi yanlış sınıflanmıştır. Şekil 3.2' de pilositik astrositom ve ependimom tümörlerinin sınıflandırılması görselleştirilmiştir.



Şekil 3.2. T2 sekansı için pilositik astrositom ve ependimom tümörlerinin ayırık dalgacık dönüşümü ile elde edilen maksimum ve ortalama değer özelliklerine göre sınıflandırma sonucu grafik görüntüsü. Görüntüde sarı olanlar pilositik astrositom, mavi olanlar ise ependimom tümörüne sahip kişileri ifade etmektedir.

3.3.2. Kontrastı Artırılmış T1 Sekansı için Posterior Fossa Tümörlerinin Sınıflandırma Sonuçları

Kontrastı artırılmış T1 sekansı için Posterior Fossa tümörlerinden 5 kişi pilositik astoristom, 7 kişi ependimom, 10 kişi medulloblastom olmak üzere toplam 22 kişi üzerinde sınıflandırma işlemi yapılmıştır.

Pilositik astrositom ve medulloblastom tümörleri arasında yapılan sınıflandırma SVM algoritmasında çapraz doğrulama yapılarak sonuçlar elde edilmiştir.

Yapılan sınıflandırma sonucunda;

TP Oranı: 0.933,


FP Oranı: 0.133,

F-Ölçümü: 0.931,

ROC Alanı: 0.900

Doğruluk : % 93.3333 sonuçları elde edilmiştir.

Şekil 3.3'de pilositik astrositom ve medulloblastom tümörlerinin sınıflandırılması görselleştirilmiştir.



Şekil 3.3. T1 sekansı için pilositik astrositom ve medulloblastom tümörlerinin ayırık dalgacık dönüşümü ile elde edilen basıklık ve çarpıklık özelliği üzerinden sınıflandırma sonucu grafik görüntüsü. Görüntüde sarı olanlar pilositik astrositom, mavi olanlar ise medulloblastom tümörüne sahip kişileri ifade etmektedir.

Pilositik astrositom ve ependimom tümörleri arasında yapılan sınıflandırma SVM algoritmasında çapraz doğrulama yapılarak sonuçlar elde edilmiştir.

Yapılan sınıflandırma sonucunda;

TP Oranı: 0.667,


FP Oranı: 0.467,

F-Ölçümü: 0.593,

ROC Alanı: 0.600

Doğruluk : % 66.6667 sonuçları elde edilmiştir.

Şekil 3.4'de pilositik astrositom ve ependimom tümörlerinin sınıflandırılması görselleştirilmiştir.



Şekil 3.4. T1 sekansı için pilositik astrositom ve ependimom tümörlerinin ayırık dalgacık dönüşümü ile elde edilen basıklık ve birinci dereceden elde edilen basıklık özelliği üzerinden sınıflandırma sonucu grafik görüntüsü. Görüntüde sarı olanlar pilositik astrositom, mavi olanlar ise medulloblastom tümörüne sahip kişileri ifade etmektedir.

Medulloblastom ve ependimom tümörleri arasında yapılan sınıflandırma SVM algoritmasında çapraz doğrulama yapılarak sonuçlar elde edilmiştir.

Yapılan sınıflandırma sonucunda;

TP Oranı: 0.706,


FP Oranı: 0.420,

F-Ölçümü: 0.654,

ROC Alanı: 0.643

Doğruluk : % 70.5882 sonuçları elde edilmiştir.

Şekil 3.5’de medulloblastom ve ependimom tümörlerinin sınıflandırılması görselleştirilmiştir.



Şekil 3.5. T1 sekansı için medulloblastom ve ependimom tümörlerinin yüzde 10 ve yüzde 90 değer özelliği üzerinden sınıflandırma sonucu grafik görüntüsü. Görüntüde mavi olanlar ependimom, sarı olanlar ise medulloblastom tümörüne sahip kişileri ifade etmektedir.

3.3.3. ADC Sekansı için Posterior Fossa Tümörlerinin Sınıflandırma Sonuçları

ADC sekansı için Posterior Fossa tümörlerinden 5 kişi pilositik astoristom, 10 kişi ependimom, 9 kişi medulloblastom olmak üzere toplam 24 kişi üzerinde sınıflandırma işlemi yapılmıştır.

Pilositik astrositom ve medulloblastom tümörleri arasında yapılan sınıflandırma SVM algoritmasında çapraz doğrulama yapılarak sonuçlar elde edilmiştir.

Yapılan sınıflandırma sonucunda;

TP Oranı: 1,


FP Oranı: 1,

F-Ölçümü: 1,

ROC Alanı: 1

Doğruluk : % 100 sonuçları elde edilmiştir.

Şekil 3.6'da pilositik astrositom ve medulloblastom tümörlerinin sınıflandırılması görselleştirilmiştir.



Şekil 3.6. ADC sekansı için pilositik astrositom ve medulloblastom tümörlerinin ortalama değer ve standar sapma özellikleri üzerinden sınıflandırma sonucu grafik görüntüsü. Görüntüde sarı olanlar pilositik astrositom, mavi olanlar ise medulloblastom tümörüne sahip kişileri ifade etmektedir.

Medulloblastom ve ependimom tümörleri arasında yapılan sınıflandırma SVM algoritmasında çapraz doğrulama yapılarak sonuçlar elde edilmiştir.

Yapılan sınıflandırma sonucunda;

TP Oranı: 0.842,


FP Oranı: 0.164,

F-Ölçümü: 0.841,

ROC Alanı: 0.839

Doğruluk : % 84.2105 sonuçları elde edilmiştir.

Şekil 3.7’ de medulloblastom ve ependimom tümörlerinin sınıflandırılması görselleştirilmiştir.



Şekil 3.7. ADC sekansı için medulloblastom ve ependimom tümörlerinin birinci dereceden basıklık ve entropi özellikleri üzerinden sınıflandırma sonucu grafik görüntüsü. Görüntüde mavi olanlar ependimom, sarı olanlar ise medulloblastom tümörüne sahip kişileri ifade etmektedir.

ADC sekansında pilositik astrositom ve ependimom tümörleri aralarında anlamlı sayısal özellik çıkarılamadığı için sınıflandırılmamıştır.

Tablo 3.5’de sınıflandırılan Posterior Fossa tümörlerine ait sonuçlar yer almaktadır.

Tablo 3.5. Sınıflandırılan Posterior Fossa tümörlerine ait sonuçlar.

Tümör Tipi	TP Oranı	FP Oranı	F-Ölçümü	ROC Alanı	DOĞRULUK
EM-PA (T2)	0.882	0.282	0.882	0.800	%88.2353
MB-PA (T2)	1	0	1	0.757	%100
EM-MB (T1)	0.706	0.420	0.654	0.643	%70.5882
EM-PA (T1)	0.667	0.467	0.593	0.600	%66.6667
MB-PA (T1)	0.933	0.133	0.931	0.900	%93.3333
EM-MB (ADC)	0.842	0.164	0.841	0.839	%84.2105
MB-PA (ADC)	1	1	1	1	%100

4. BÖLÜM

TARTIŞMA-SONUÇ ve ÖNERİLER

4.1. Tartışma

Bu çalışmada Posterior Fossa tümör tiplerinden en yaygın görülen üç tipi pilositik astrositom, medulloblastom ve ependimom tümörlerinin yüksek doğrulukta sınıflandırılması amaçlanmıştır. Posterior Fossa tümörleri çocuklarda en çok ölüme sebebiyet veren maligniteler arasında bulunması ve tümör çeşitlerinin teşhisi aşamasında oluşan zorlukların giderilmesi amacıyla bu çalışma yapılmıştır. Bu amaçlar doğrultusunda üç farklı çocukluk çağı tümör tipinin birbirinden ayırt edici özellikleri belirlenerek sınıflandırma çalışması yapılmıştır.

Bu çalışmaya benzer özellikte literatürde bir çok çalışma bulunmaktadır. Aşağıda benzer dört çalışmaya yer verilmiştir. Zarinabad vd. [10] yaptıkları çalışma ile 3T tarayıcılardan elde edilen metabolitlerin EM, PA, MB için ayırt edici potansiyeli araştırılmıştır. 41 pediatrik hasta(17 MB, 20 PA, 4 EM) üzerinde çalışma gerçekleştirilmiştir. Destek vektör makineleri, rastgele orman teknikleri ve doğrusal ayırmacı analiz sınıflandırma işlemi için kullanılmıştır. 3 farklı tümör tipini ayırt etmede en yüksek doğruluğa sahip olan destek vektör makineleri olmuştur. %86 doğrulukla tümörler SVM ile sınıflandırılmıştır.

Li vd. [11] 174 hastadan oluşan iki farklı pediatrik posterior Fossa tümörü(EM, MB) için makine öğrenmesi tabanlı manyetik rezonans biyobelirteçleri analizi yapılmıştır. 300 farklı biyobelirteç için üç farklı özellik çıkarımı yöntemi kullanılmıştır. 10 özellik seçim için ve k-en yakın komşular, SVM, rastgele ormanlar, regresyon ağaçları, sinir ağları gibi 11 farklı sınıflandırıcı analiz edilmiştir. SVM sınıflandırıcısı diğer sınıflandırıcılara nispeten daha iyi performans göstermiş olup %85.38 doğrulukta sınıflandırma işlemi gerçekleştirmişlerdir.

Quon vd. [12] tümör tespiti ve tümör patolojisi sınıflandırılması amacıyla derin

öğrenme modeli geliştirmişlerdir. Toplam 92 çocuktan oluşan 4 farklı posterior Fossa tümörüne(gliom,MB,PA,EM) sahip hastalar üzerinde çalışma gerçekleştirilmiştir. Modifiye edilmiş bir ResNeXt-50-32x4d mimarisi kullanmışlardır ve model tümör sınıflandırma doğruluğu F ile %92 olarak bulunmuştur.

Wang vd. [15] çalışmada MB, PA ve EM tümörleri sınıflandırarak bu tümörlerin non-invaziv MRG tabanlı analizini radyomik olarak incelenmiştir. 27 hastanın 3 farklı sekans MRG kullanılarak çalışma yapılmıştır. Segmente edilen tümörlerden yüksek verim özellikleri çıkarılarak orman tabanlı özellik seçim algoritması benimsenmiştir. Özellikler çıkarılırken histogram, GLCM, Wavelet transform yöntemleri ile toplam 315 özellik çıkarılmıştır. Rastgele orman sınıflandırıcı kullanılarak yapılan sınıflandırmada ADC sekansı ile yapılan sınıflandırma T2 ve T1 sekanslarına göre daha iyi nicel sonuçlar verdiği gözlemlenmiştir. Bu çalışmanın sonucunda tümörler %93.81 doğrulukla sınıflandırılmıştır.

Yapılan çalışma ile diğer çalışmalardan farklı olarak Posterior Fossa tümörleri tiplerini tümörlerde tüm kesitlerde çalışarak üç farklı çekim sekansı içinde sınıflandırılarak yüksek doğrulukta sonuçlar elde edilmiştir. Yapılan çalışma Erciyes Üniversitesi Çocuk Radyolojisi bölümünden alınan görüntüler ile gerçekleştirilmiştir. Hastanede kaydı bulunan Posterior fossa tanılı hasta sayısının az olmasından kaynaklı yapılan çalışmada kişi sayısı azdır. Aynı zamanda tüm hastalar içinde üç farklı çekim sekansı görüntüleri bulunmamaktadır. Bu da çalışmanın daha az hasta görüntüsü üzerinde çalışılmasına neden olmuştur. Daha fazla kişi üzerinde çalışmanın denenmesi sonucu yani sınıflandırmanın doğruluğunu büyük miktarda etkileyen bir faktördür.

Özellik çıkarımı aşamasında bazı çekim sekansları veya bazı tümör grupları arasında özellik seçimi aşamasında anlamlı sayısal özellikler belirlenememiştir. Bu çalışma kapsamında 40 sayısal özellik üzerinde çalışılmıştır. Daha fazla özellik çıkarımı çalışılarak ayırt edici özellik bulunamayan tümör çeşitleri üzerinde çalışılabilir.

Aynı zamanda sınıflandırma aşamasında farklı makine öğrenmesi algoritmaları(kNN, Naive Bayes, Rastgele Orman) kullanılarak sonuçlar elde edilerek karşılaştırılabilir.

4.2. Sonuç ve Öneriler

Çocukluk çağı beyin tümörlerinin sınıflandırılması için yapılan bu çalışmada Posterior Fossa tümör tipleri pilositik astrositom, medulloblastom ve ependimom tümörleri iki farklı görüntü işleme algoritması kullanılarak bölütlendikten sonra tümörler üzerinde sayısal özellik çıkarımı için dört farklı yöntem üzerinden kırk farklı sayısal özellik çıkarımı yapılmıştır. Çıkarılan bu sayısal özellikler tüm tümörler için anlam ifade etmediği için kırk farklı özellikten tüm tümörler için ayrı olarak anlamlı sayısal özellikler belirlenmiştir. Belirlenen anlamlı özellikler üzerinden de makine öğrenmesi algoritması olan destek vektör makineleri ile tümörler sınıflandırılmıştır.

Özellik çıkarımı aşamasında tüm tümör grupları için anlamlı özellik belirlenememiştir. ADC sekansı üzerinden yapılan özellik çıkarımında daha fazla anlamlı özellik belirlenirken kontrastı artırılmış T1 sekansı için çok az sayıda anlamlı sayısal özellik belirlenmiştir. T1 sekansında anlamlı sayısal özelliklerin az olması sebebi ile sınıflandırma aşamasında doğruluk değeri diğer sekansların sınıflandırma sonuçlarına göre daha düşük çıkmıştır. İlerleyen çalışmalar için daha fazla sayısal özellik(gabor filtreler gibi.) üzerinde çalışılarak tümörler için daha fazla sayıda anlamlı sayısal özellik belirlenebilir.

Tümörlerin sınıflandırılması destek vektör makineleri ile yapılmıştır. Yapılan çalışmada kişi sayısının az olması ve verilerin karmaşık olmaması sebebi ile SVM makine öğrenmesi algoritması seçilmiştir. Tümörler yüksek doğrulukta sınıflandırılmıştır. T2 ve ADC sekansında pilositik astrositom ve medulloblastom tümörleri tamamen doğru sınıflandırılmıştır ve %100 doğruluk elde edilmiştir. Sınıflandırma sonuçları diğer sekanslara göre düşük çıkan kontrastı artırılmış T1 sekansı için farklı makine öğrenmesi algoritmaları denenerek daha yüksek doğrulukta sınıflandırılabilir.

İlerleyen çalışmalarda Posterior Fossa tümörlerinin sınıflandırılması için örnek bir çalışma yapılmış olup kişi sayısı artırılarak farklı özellik seçme algoritmaları kullanılıp daha fazla sayıda özellik üzerinde çalışılarak anlamlı özellikler üzerinden bir kaç farklı makine öğrenmesi ile sınıflandırılarak sınıflandırıcılar arasında karşılaştırma yapılabilir.

KAYNAKÇA

1. Lannering, B., Marky, I., and Nordborg, C., 1990. Brain tumors in childhood and adolescence in west sweden 1970–1984 epidemiology and survival, **Cancer**, **66**(3):604–609.
2. Prasad, K.S.V., Ravi, D., Pallikonda, V., and Raman, B.V.S., 2017. Clinicopathological study of pediatric posterior fossa tumors, **Journal of pediatric neurosciences**, **12**(3):245.
3. Orphanidou-Vlachou, E., Vlachos, N., Davies, N.P., Arvanitis, T.N., Grundy, R.G., and Peet, A.C., 2014. Texture analysis of T1-and T2-weighted MR images and use of probabilistic neural network to discriminate posterior fossa tumours in children, **NMR in Biomedicine**, **27**(6):632–639.
4. KIZILKILIÇ, O. and ÇALLI, C., 2017. Posterior Fossa Tümörlerinde Radyoloji, **Türk Nöroşirürji Dergisi**, **27**(1):8–23.
5. TAŞCIOĞLU, T. and AKPINAR, A., 2019. POSTERİOR FOSSA TÜMÖRLERİ: CERRAHİ DENEYİM 47 OLGU, **Ankara Eğitim ve Araştırma Hastanesi Tıp Dergisi**, **52**(3):201–205.
6. Arle, J.E., Morriss, C., Wang, Z.J., Zimmerman, R.A., Phillips, P.G., and Sutton, L.N., 1997. Prediction of posterior fossa tumor type in children by means of magnetic resonance image properties, spectroscopy, and neural networks, **Journal of neurosurgery**, **86**(5):755–761.
7. Bidiwala, S. and Pittman, T., 2004. Neural network classification of pediatric posterior fossa tumors using clinical and imaging data, **Pediatric neurosurgery**, **40**(1):8–15.
8. Gutierrez, D.R., Awwad, A., Meijer, L., Manita, M., Jaspan, T., Dineen, R.A., Grundy, R.G., and Auer, D.P., 2014. Metrics and textural features of MRI diffusion to improve classification of pediatric posterior fossa tumors, **American Journal of Neuroradiology**, **35**(5):1009–1015.
9. Fetit, A.E., Novak, J., Rodriguez, D., Auer, D.P., Clark, C.A., Grundy, R.G., Peet, A.C., and Arvanitis, T.N., 2018. Radiomics in paediatric neuro-oncology: a multicentre study on MRI texture analysis, **NMR in Biomedicine**, **31**(1):e3781.

10. Zarinabad, N., Abernethy, L.J., Avula, S., Davies, N.P., Rodriguez Gutierrez, D., Jaspán, T., MacPherson, L., Mitra, D., Rose, H.E., Wilson, M., et al., 2018. Application of pattern recognition techniques for classification of pediatric brain tumors by in vivo 3T 1H-MR spectroscopy—A multi-center study, **Magnetic Resonance in Medicine**, **79**(4):2359–2366.
11. Li, M., Shang, Z., Yang, Z., Zhang, Y., and Wan, H., 2019. Machine learning methods for MRI biomarkers analysis of pediatric posterior fossa tumors, **Biocybernetics and Biomedical Engineering**, **39**(3):765–774.
12. Quon, J., Bala, W., Chen, L., Wright, J., Kim, L., Han, M., Shpanskaya, K., Lee, E., Tong, E., Iv, M., et al., 2020. Deep learning for pediatric posterior fossa tumor detection and classification: a multi-institutional study, **American Journal of Neuroradiology**, **41**(9):1718–1725.
13. Zhou, H., Hu, R., Tang, O., Hu, C., Tang, L., Chang, K., Shen, Q., Wu, J., Zou, B., Xiao, B., et al., 2020. Automatic machine learning to differentiate pediatric posterior fossa tumors on routine MR imaging, **American Journal of Neuroradiology**, **41**(7):1279–1285.
14. Li, M., Wang, H., Shang, Z., Yang, Z., Zhang, Y., and Wan, H., 2020. Ependymoma and pilocytic astrocytoma: Differentiation using radiomics approach based on machine learning, **Journal of Clinical Neuroscience**, **78**:175–180.
15. Wang, S., Wang, G., Zhang, W., He, J., Sun, W., Yang, M., Sun, Y., and Peet, A., 2022. MRI-based whole-tumor radiomics to classify the types of pediatric posterior fossa brain tumor, **Neurochirurgie**, **68**(6):601–607.
16. Sotoudeh, H., Saadatpour, Z., Rezaei, A., Sotoudeh, M., Wheeler, C.A., Singhal, A., and Tanwar, M., 2023. Radiomics for differentiation of the posterior fossa pilocytic astrocytoma versus hemangioblastomas in adults. A pilot study, **Clinical Imaging**, **93**:26–30.
17. Osmanoğlu, U.Ö., Mutlu, F., Gürsoy, H., and ŞANLISOY, S., 2016. Görüntü işleme ve analizinin tıpta kullanımı ve bir uygulama, **Osmangazi Tıp Dergisi**, **41**(1):6–16.
18. Perihanoğlu, G.M., 2015. Dijital görüntü işleme teknikleri kullanılarak görüntülerden detay çıkarımı, Doktora Tezi, Fen Bilimleri Enstitüsü.

19. Borman, S., 2004. The expectation maximization algorithm-a short tutorial, **Submitted for publication, 41.**
20. Sammaknejad, N., Zhao, Y., and Huang, B., 2019. A review of the expectation maximization algorithm in data-driven process identification, **Journal of process control, 73:123–136.**
21. Kwon, G.R., Basukala, D., Lee, S.W., Lee, K.H., and Kang, M., 2016. Brain image segmentation using a combination of expectation-maximization algorithm and watershed transform, **International Journal of Imaging Systems and Technology, 26(3):225–232.**
22. Lankton, S. and Tannenbaum, A., 2008. Localizing region-based active contours, **IEEE transactions on image processing, 17(11):2029–2039.**
23. Bozkurt, F., Köse, C., and Sarı, A. Bolge-tabanlı Aktif Kontur ve Sınıflandırma ile BTA Goruntulerinden Karotid Arterlerin Bolutlenmesi.
24. Chan, T.F. and Vese, L.A., 2001. Active contours without edges, **IEEE Transactions on image processing, 10(2):266–277.**
25. Mathew, A.R., Anto, P.B., and Thara, N., 2017. Brain tumor segmentation and classification using DWT, Gabour wavelet and GLCM, *2017 International Conference on Intelligent Computing, Instrumentation and Control Technologies (ICICT)*, 1744–1750, IEEE.
26. Zulpe, N. and Pawar, V., 2012. GLCM textural features for brain tumor classification, **International Journal of Computer Science Issues (IJCSI), 9(3):354.**
27. Saman, S. and Jamjala Narayanan, S., 2019. Survey on brain tumor segmentation and feature extraction of MR images, **International journal of multimedia information retrieval, 8:79–99.**
28. Hussain, A. and Khunteta, A., 2020. Semantic segmentation of brain tumor from MRI images and SVM classification using GLCM features, *2020 second international conference on inventive research in computing applications (ICIRCA)*, 38–43, IEEE.

29. Chaudhary, A. and Bhattacharjee, V., 2020. An efficient method for brain tumor detection and categorization using MRI images by K-means clustering & DWT, **International Journal of Information Technology**, **12**:141–148.
30. Faisal, Z. and El Abbadi, N.K., 2020. Detection and recognition of brain tumor based on DWT, PCA and ANN, **Indonesian Journal of Electrical Engineering and Computer Science**, **18**(1):56–63.
31. Mahesh, B., 2020. Machine learning algorithms-a review, **International Journal of Science and Research (IJSR)**.**[Internet]**, **9**(1):381–386.
32. Ray, S., 2019. A quick review of machine learning algorithms, *2019 International conference on machine learning, big data, cloud and parallel computing (COMITCon)*, 35–39, IEEE.
33. Nasteski, V., 2017. An overview of the supervised machine learning methods, **Horizons. b**, **4**:51–62.
34. Singh, A., Thakur, N., and Sharma, A., 2016. A review of supervised machine learning algorithms, *2016 3rd international conference on computing for sustainable global development (INDIACom)*, 1310–1315, Ieee.
35. BİLGİN, G., 2021. Makine öğrenmesi algoritmaları kullanarak erken dönemde diyabet hastalığı riskinin araştırılması, **Journal of Intelligent Systems: Theory and Applications**, **4**(1):55–64.
36. Uddin, S., Khan, A., Hossain, M.E., and Moni, M.A., 2019. Comparing different supervised machine learning algorithms for disease prediction, **BMC medical informatics and decision making**, **19**(1):1–16.

ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı, Soyadı : Nuray DEMİRÖZ

Uyruğu : Türkiye (T.C.)

EĞİTİM

Derece	Kurum	Mez.Yılı
Yüksek Lisans	Erciyes Üniversitesi, Biyomedikal Mühendisliği	2023
Lisans	Erciyes Üniversitesi, Biyomedikal Mühendisliği	2019
Lise	Mareşal Çakmak Anadolu Öğretmen Lisesi	2014

YABANCI DİL

İngilizce