

ARAŞTIRMA MAKALESİ

# Manyetik Rezonans Görüntülerinden Beyin Tümörü Tespitinde Sınıflandırma Algoritmalarının Karşılaştırmalı Analizi

## *Comparative Analysis of Classification Algorithms in Brain Tumour Detection from Magnetic Resonance Images*

Oruç Altay Kırılı<sup>1</sup> Merve Sansarcı<sup>1</sup> Osman Özkaraca<sup>2,\*</sup> Gürcan Çetin<sup>2</sup>

<sup>1</sup> Muğla Sıtkı Koçman Üniversitesi, Fen Bilimleri Enstitüsü, Bilişim Sistemleri Mühendisliği Anabilim dalı, 48000, Muğla, Türkiye.

<sup>2</sup> Muğla Sıtkı Koçman Üniversitesi, Teknoloji Fakültesi, Bilişim Sistemleri Mühendisliği Bölümü, 48000, Muğla, Türkiye.

Geliş / Received: 05.10.2023

Kabul / Accepted: 25.10.2023

\*Sorumlu Yazar (Corresponding Author) Osman Özkaraca [osmanozkaraca@mu.edu.tr](mailto:osmanozkaraca@mu.edu.tr)

**ÖZ:** Beyinde normal hücreleri kontrol eden mekanizmalar tarafından kontrol edilemeyen, kontrolsüz bir şekilde büyüyen ve çoğalan anormal bir doku kütlelerine intrakraniyal tümör ya da beyin tümörü adı verilir. İlk olarak beyin tümörleri baş ağrısı, nöbetler sürekli hasta hissetme (bulantı), hasta olma (kusma) ve uyuşukluk gibi semptomlar göstermeye başlar. Genel olarak, bir beyin tümörü teşhisi manyetik rezonans görüntüleme (MRG) ile başlar. MRG beyinde bir tümör olduğunu gösterdiğinde, beyin tümörünün tipini belirlemenin en yaygın yolu biyopsi veya ameliyat sonrası alınan doku örneğinin sonuçlarına bakmaktır. Bu tümörlerin tedavi edilmesinde erken teşhisin önemi oldukça büyüktür. Son yıllarda gelişen yapay zekâ teknolojileri ve yöntemleri ile bu tür tümörlerin erken tespiti ve analizi daha kolay hale gelmiştir. Tümörlerin bilgisayar destekli algoritmalar ile tespiti sırasında görüntülerin segmentasyonu yapılmaktadır. Etkili bir tıbbi segmentasyon algoritması çıktısı, sınıflandırıcıyı bu tür anormalliklerin aşamalarını belirlemede daha verimli bir şekilde yönlendirmektedir. Bu çalışmada, yapay zekâ teknolojilerinin de içerisinde bulunduğu tıbbi segmentasyon yöntemleri ile MRG görüntülerindeki tümör tespitinde nasıl kullanılabileceği incelenmiş ve çeşitli modellerin analizleri yapılmıştır. En yüksek doğruluk oranı (% 84,4), özellik çıkarımında Chi-Kare testi kullanılan Doğrusal-DVM (Destek Vektör Makinesi) algoritması ile elde edilmiştir. Rassal orman algoritması da % 81,5 doğruluk oranı ile oldukça başarılı bir sonuç vermiştir. Çalışmanın sonuçları değerlendirildiğinde, Rassal Orman ve DVM algoritmalarının en iyi performansı gösterdiği görülmüştür.

**Anahtar Kelimeler:** MRG, beyin tümörü, sınıflandırma, destek vektör makinesi, rassal orman, makine öğrenmesi.

**ABSTRACT:** An abnormal tissue mass that grows and proliferates uncontrollably and cannot be controlled by the mechanisms that control normal cells in the brain is called an intracranial tumour or brain tumour. First, brain tumours begin to show symptoms such as headaches, seizures, feeling sick all the time (nausea), being sick (vomiting), and lethargy. Generally, diagnosing a brain tumour begins with magnetic resonance imaging (MRI). When an MRI shows that there is a tumour in the brain, the most common way to determine the type of brain tumour is to look at the results of a biopsy or tissue sample taken after surgery. Early diagnosis is of great importance in treating these tumours. With the developing artificial intelligence technologies and methods in recent years, early detection and analysis of such tumours has become easier. Segmentation of images is performed during the detection of tumours with computer-aided algorithms. The output of an effective medical segmentation algorithm guides the classifier more efficiently in identifying the stages of such abnormalities. In this study, how medical segmentation methods, including artificial intelligence technologies, can be used to detect tumours in MRI images was examined and various models were analysed. The highest accuracy rate (84,4%) was obtained with the Linear-SVM (Support Vector Machine) algorithm using the Chi Square test in feature extraction. The Random Forest algorithm also gave a very successful result with an accuracy rate of 81,5%. When the results of the study were evaluated, it was seen that Random Forest and SVM algorithms showed the best performance.

**Keywords:** MRI, brain tumour, classification, Support Vector Machine, Random Forest, machine learning.

## 1. GİRİŞ

Beyinde oluşan anormal hücreler, genellikle beyin tümörü olarak adlandırılırlar. Literatürde tümörler iki kategoriye ayrılır: iyi huylu (benign) ve kötü huylu (malign) tümörler. Hastalık ciddi sayılabilecek semptomlara sahip olmakla birlikte ilerleyen zamanlarda bilinç kaybına kadar gidebilmektedir [1]. Beyin tümörünün teşhisine en uygun yöntem MRG (Manyetik Rezonans Görüntüleme) olarak görülmüştür.

MRG, bu tür beyin ve diğer türdeki tümörleri değerlendirmek için yaygın olarak kullanılan bir görüntüleme tekniği olarak kabul edilir. MRG görüntüleri, diğer görüntüleme teknolojilerine göre daha yüksek kalitede görüntüler sunar ve tümörlerin büyüklüğü, şekli ve yerleşimi gibi özelliklerini daha iyi gösterebilir. MRG ile tümörler hakkında kabaca bir fikir elde edilir ve sonrasında patoloji laboratuvar incelemesi ile beyin tümörü olup olmadığı net olarak anlaşılır. Ancak, MR görüntülerinin doğru bir şekilde analiz edilmesi zordur ve insanların gözden kaçırabildiği detaylar olabilmektedir. Aynı görüntüyü farklı radyologlar farklı şekilde yorumlayabilir. Gelişen teknoloji sayesinde yapay zekâ algoritmaları gibi yüksek teknolojik yöntemler kullanılarak MR görüntülerindeki tümör tespitinde daha fazla doğruluk ve hız sağlanabilir. Yapay zekâ algoritmaları, görüntülerdeki nüansları ve detayları daha doğru bir şekilde analiz ederek, insanların kaçırabileceği tümör belirtilerini fark edebilir.

Son yıllarda gelişen bu yapay zekâ teknolojileri ve yöntemleri ile bu tür tümörlerin tespiti ve analizi yapay zekâ destekli tıbbi bilişim segmentasyon yöntemleri ile rahatlıkla yapılmaya başlanmıştır. Bilgisayar teknolojilerindeki hız ve kapasitenin fazlasıyla artması bu tümörlerin erken safhada tespitine olanak sağlamakla birlikte hayati bir önem taşımaktadır. Etkili bir tıbbi segmentasyon algoritması çıktısı, sınıflandırıcıyı bu tür anormalliklerin aşamalarını belirlemede verimli bir şekilde yönlendirmektedir.

Tıbbi segmentasyon algoritmaları, yapay zekâ destekli olmakla birlikte sağlık alanında önemli rol oynayan bir teknolojidir. MRG çıktıları, hastalıkların erken teşhisinde, tedavide ve izlemede

kullanılır. Yapay zekâ teknolojilerinin tıp alanında kullanımı, görüntü analizinde daha fazla doğruluk ve verimlilik sağlamaya olanak tanımıştır.

Bu makale, yapay zekâ teknolojilerinin de içerisinde bulunduğu tıbbi segmentasyon teknikleri ile MRG görüntülerindeki tümör tespitinde nasıl kullanılabileceği incelenmiş ve çeşitli modellerin analizleri yapılmıştır. Ayrıca, gelecekte bu alandaki gelişmeler ve yapay zekâ teknolojilerinin daha da iyileştirilmesi için yapılması gereken çalışmalar hakkında da bilgi vermektedir. Tümör tespitindeki doğruluk ve hızın hayat kurtarıcı bir önemi bulunmaktadır ve yapay zekâ teknolojileri günümüzde sağlık sektöründe yapay zekâ teknolojisi hızla yaygınlaşmaya devam etmektedir. Bu çalışmada, Kaggle'dan elde edilen Navoneel Chakrabarty tarafından paylaşılan Brain MRG Images for Brain Tumor Detection veri seti kullanılarak Destek Vektör Makineleri (DVM), Doğrusal DVM, Toplamalı Chi-Kare Çekirdek, Lojistik Regresyon ve Rassal Orman derin öğrenme modelleri karşılaştırılmıştır. Literatürde beyin tümörü konusunda yapılan çalışmalara bakıldığında iyi sonuçlar verdiğinden dolayı bu modeller tercih edilmiştir [2].

Çalışmada gerçekleştirilen modelin performansı ise karşılaştırma matrisi ile hesaplanan doğruluk, kesinlik, hassasiyet, F-ölçüsü, duyarlılık, özgüllük değerleri üzerinden hesaplanmış ve karşılaştırılmıştır.

## 2. LİTERATÜR TARAMASI

Beyin tümörü, her gün birçok insanın etkilenmesi ve ölmesi nedeniyle dünya çapında önemli bir sorun haline gelmiş rahatsızlıktır. Beyin tümörünün erken teşhisi, büyümenin kontrol altına alınmasına yardımcı olabilir ve etkili tedavi seçeneklerini artırabilir. Literatürde bu alanda yapılmış birçok çalışmaya rastlamak mümkündür. Bu çalışmaların temelinde görüntü işleme algoritmaları ve görüntü segmentasyon algoritmaları önem arz etmektedir. Çünkü görüntü segmentasyonu özellikle anormalliklerin tespitinde hayati bir rol oynar. Segmentasyon algoritmalarının değerlendirilmesi, optimum performans için uygun algoritma ve parametrelerin seçilmesi açısından hayati öneme sahiptir. Bu nedenle Kumar ve arkadaşları, gerçekleştirdikleri çalışmada

segmentasyon algoritmalarının kalitesini değerlendirmek için çeşitli metrikler tanımlamışlardır. Bu çalışma, segmentasyon algoritmalarının etkinliğini analiz etmek için kullanılacak performans değerlendirme parametrelerini sunmaktadır [3].

Balaji tarafından gerçekleştirilen başka bir çalışmada Generative Deep Belief modelini kullanarak insan vücudundaki tümörlerin doğru teşhisini belirlemeyi amaçlamıştır. Çalışmada geleneksel derin ResNet 0.92, AdaResU-Net 0.89 ve HSMA-WOA 0.90 doğruluk elde ederek önerilen yöntemin altında kalmıştır. Bununla birlikte, önerilen yöntem 0,999 doğruluk oranı ile geleneksel yöntemden daha üstün bir performans elde etmiştir [4].

Babu ve Singh'in yaptığı çalışmada standart derin öğrenme modelleri ile U-Net mimarisi karşılaştırılmıştır. Doğruluk açısından U Net, optimum performansın yanı sıra yüksek doğruluk da sağlamıştır. Bu çalışmada sırasıyla Brain Tumor Segmentation Challenge (BraTS) 2017 ve 2018 adlı açık kaynaklı standart veri tabanları kullanılmıştır. Araştırma sonuçlarına göre, Evrimsel Sinir Ağı (CNN), Dense CNN, FCNN, U NET, Res U NET ve NovelNet mimarilerine kıyasla önerilen yeni mimari segmentasyon doğruluğunda %7'lik önemli bir artış elde etmiştir [5].

Ghulam ve arkadaşlarının yaptığı çalışmada Manyetik Rezonans Görüntüleme (MRG) için beyin tümörünü tespit etmek ve segmentlere ayırmak için yeni bir U-Net tabanlı (CNN) tekniği önermişlerdir. Önerilen model BRATS2020 veri kümesi üzerinde %0,98'lik bir doğruluk değeri elde etmiştir ki bu değer mevcut tekniklerle karşılaştırıldığında en yüksek değer olduğu çalışmada belirtilmiştir [6].

Sedlar çalışmasında çok yollu CNN dayalı otomatik bir beyin tümörü segmentasyonu yaklaşımı sunmaktadır. Modelin eğitimi ve hiper-parametre ayarlaması BraTS 2017 eğitim veri kümesi üzerinde, modelin doğrulaması BraTS 2017 doğrulama veri kümesi üzerinde yapılmış ve nihai sonuçlar BraTS 2017 test veri kümesi üzerinde raporlanmıştır. Test veri kümesinde elde edilen ortalama Dice skorları tümör, tüm tümör ve tümör çekirdeği için sırasıyla 0.6049, 0.8436 ve 0.6938'dir [7].

Zhao ve arkadaşları yapılan son çalışmalarda, derin evrişim sinir ağı (DCNN) tıbbi görüntü segmentasyonu için en güçlü yöntemlerden biri olduğunu gözlemlemişlerdir. Bu makalede de, BraTS2019 çevrimiçi test seti üzerinde değerlendirildiğinde, gelişmiş tümör çekirdeği, tüm tümör ve tümör çekirdeği için sırasıyla 0,810, 0,883 ve 0,861 Dice puanları ve 2,447, 4,792 ve 5,581 Hausdorff Uzaklıkları (95. yüzdeler dilim) elde edilmiştir. Ancak bu model küçük anatomik bölgeler için yanlış tahminler yapma eğilimindedir [8].

Liu ve arkadaşlarının çalışmasında, beyin tümörü görüntülerinin segmentasyonu için bir dikkat mekanizmasına sahip hafif bir otomatik 3D algoritması önerilmiştir. BraTS 2019 test setine uygulanan önerilen ağ modelinin sonuçları, tümör, tüm tümör ve tümör çekirdeği için Dice katsayılarının sırasıyla %77,91, %89,94 ve %83,89 olduğunu ortaya koymuştur. BraTS 2018, BraTS 2019 ve BraTS 2020 veri setleri üzerinde yapılan kapsamlı deneyler, önerilen modelin küçük beyin tümörü bölgelerinin verimli segmentasyonu açısından daha iyi bir potansiyele sahip olduğunu göstermektedir [9].

Behrad ve arkadaşlarının yaptığı çalışmada, U-Net tabanlı ağın gereksiz filtrelerini belirlemek için genetik algoritma kullanılmıştır. Filtre budama işlemini, performans ve çıkarım süresinin aynı anda optimize edildiği çok amaçlı bir optimizasyon problemi olarak ele almışlardır. Ardından, beyin tümörü segmentasyonu için sıkıştırılmış ağ kullanılmaktadır. Çalışmada, Dice katsayıları sırayla %80,19, %78,77, %79,58 ve %77,45 elde edilmiştir ve en başarılı performansın genetik algoritmada elde edildiği saptanmıştır [10].

Pereira ve arkadaşları CNN'e dayalı otomatik bir segmentasyon yöntemi önermektedir. Çalışmada CNN tabanlı segmentasyon yöntemlerinde yaygın olmasa da veri büyütme ile birlikte MRG görüntülerinde beyin tümörü segmentasyonu için çok etkili olduğu kanıtlanan yoğunluk normalizasyonunun kullanımı ile ön işleme adımı araştırılmıştır. Çalışmanın 2013 BRATS veritabanında Dice benzerliği katsayı ölçümü %88, %83 ve %77 çıkmıştır ve çevrimiçi yapılan değerlendirmeyi birincilikle bitirmiştir. Aynı

çalışma 2015 BRATS veri setinde denendiğinde ise Dice değerleri %78, %65 ve %75 çıkmıştır [11].

Bhagat ve Kaur yaptığı bu çalışmada, doğru segmentasyon için multimodal bilgilerin daha yeterli bir şekilde kullanılmasını amaçlayan, multimodal MRG'da derin semantik ve kenar bilgilerinin füzyonuna dayanan bir beyin tümörü segmentasyon yöntemi önermektedir. Önerilen yöntem temel olarak bir semantik segmentasyon modülü, bir kenar algılama modülü ve bir özellik füzyon modülünden oluşmaktadır. Çalışmanın doğruluk, kesinlik ve duyarlılık değerleri sırasıyla %99,24, %95,83 ve %95,30'dur. Performans parametreleri açısından sonuçlar, sistemin verimliliğinin daha önceki çalışmalarla karşılaştırıldığında daha iyi olduğu görülmektedir [1].

Anand ve arkadaşları, MRG taramalarını kullanarak beyin tümörlerini segmente etmek ve sınıflandırmak için makine öğrenimi ve tıbbi destekli multimodal bir yaklaşım önermektedir. Analize hazır MRG görüntülerini DVM, RBF, ANN ve AdaBoost gibi çeşitli makine öğrenimi yöntemleri kullanılarak kategorize edilmiştir. DVM RBF algoritmasının performansı, beyin tümörlerinin sınıflandırılması ve tespiti konusunda en başarılı algoritma olarak gözlenmiştir [12].

Ragupathy ve arkadaşlarının çalışmasında, mevcut kısıtlamaların ve engellerin üstesinden gelmek için bilgisayar destekli beyin tümörü segmentasyonu yaklaşımı önerilmiştir. Önerilen konvolüsyonel sinir ağı ve destek vektör makinesi yaklaşımı aşağıdaki aşamalardan oluşmaktadır. Ön işleme aşamasında, istenmeyen gürültü ve yoğunluk homojensizliği bir anizotropik difüzyon filtresi kullanılarak bastırılır. Ardından, derin evrişimli sinir ağı kullanılarak özellikler çıkarılır ve özelliklere dayalı olarak; giriş beyin görüntüsü bir destek vektör makinesi sınıflandırıcısı kullanılarak normal veya anormal olarak sınıflandırılır. Önerilen yöntem (Proposed CNN-DVM) kendisine en yakın yönteme göre (Dual force CNN) %2,11 ile daha başarılı bir doğruluk oranı vermektedir. Diğer yöntemlerle karşılaştırıldığında (SWT-GCNN, Patch-based CNN, Multi-grade, Dual force CNN) duyarlılık ve özgüllük değerleri de %4,79 ve %1,19'a yükselmiştir [13].

Görüldüğü üzere literatürde birçok çeşitli makine öğrenimine yönelik sınıflandırma algoritması başarıyla denendikten sonra tıbbi tedavi ve teşhis için en iyi sonucu verebilecek algoritma bulunmaya çalışılmıştır. Tüm bu algoritmaları karşılaştırarak ve geliştirerek tıbbi tedavi ve teşhiste doğru sonuç verecek en iyi görüntü deseni tanıma algoritmasına ulaşabileceği düşünülmektedir.

### 3. MATERYAL VE METOD

Bu çalışmada, tümör tespiti için üç farklı sınıflandırma algoritması (Rassal Orman, Doğrusal Regresyon ve DVM) ve iki farklı özellik çıkarım yöntemi (Chi-Kare ve HOG) kullanılmıştır. Veri seti, negatif ve pozitif tümör görüntülerini içermektedir. Veri seti üzerinde görüntü işleme yöntemleri kullanılarak özellik çıkarılmış ve sınıflandırma algoritmaları kullanılarak tümör tespiti yapılmıştır.


Özellik çıkarımı için, Chi-Kare ve HOG yöntemleri kullanılmıştır. Chi-Kare yöntemi, özellik vektörlerinin tümör sınıfları arasındaki farklılıklarını vurgulamak için kullanılan bir yöntemdir. HOG yöntemi ise, görüntüyü küçük parçalara ayırır ve her parçanın histogramını hesaplar. Bu histogramlar daha sonra, tümör sınıflarını ayırt etmek için kullanılır.

Sınıflandırma algoritmaları olarak, Rassal Orman, Doğrusal Regresyon ve DVM kullanılmıştır. Rassal Orman, birden çok ağaç kullanarak sınıflandırma yapar. Doğrusal Regresyon, görüntü özelliklerinin doğrusal bir kombinasyonunu kullanarak sınıflandırma yapar. DVM ise, iki sınıf arasındaki ayrım çizgisini belirlemek için kullanılır. Performans ölçütleri olarak, doğruluk, hassasiyet, özgüllük ve F1-score kullanılmıştır. Doğruluk, tümör teşhisi doğru yapılan örneklerin yüzdesini, hassasiyet ise tümör olan örneklerin ne kadarının doğru bir şekilde tespit edildiğini göstermektedir.

#### 3.1 Rassal Orman Yöntemi

Rassal Orman algoritması, birden fazla karar ağacının oluşturulması ve bu ağaçların sonuçlarının bir araya getirilerek ortak bir sonuç üretilmesine dayanmaktadır. Şekil 1'de yer alan karar ağaçları, veri kümesindeki özelliklerin belirli bir sıraya göre sıralanarak bir ağaç yapısı oluşturulmasıyla elde edilir. Her bir düğümde belirli bir özellik değeri

kontrol edilir ve ağacın dallarına ayrılır. Rassal Orman algoritması, bu işlemi birden fazla karar ağacı ile gerçekleştirir ve her bir ağacın sonucunu bir araya getirerek daha doğru ve stabil bir sonuç üretmeyi hedefler.




Şekil 1: Rassal Orman algoritmasının blok gösterimi.

Rassal Orman Sınıflandırıcı, Rassal Orman algoritmasını uygulamak için birden fazla karar ağacı oluşturur. Ağaçların sayısı ve diğer parametreler, sınıfın yapıcı (constructor) yöntemi aracılığıyla belirlenir. Oluşturulan ağaçlar, veri kümesindeki özelliklerin belirli bir alt kümesini kullanarak rastgele seçilir, böylece her bir ağacın farklı özellikleri kullanarak farklı sonuçlar üretmesi sağlanır. Sonuçlar bir araya getirilirken, örneğin sınıflandırma yapıyorsa, sınıflandırma sonuçlarının oylaması (voting) yöntemi kullanılır [3].

### 3.2 Destek Vektör Makineleri (DVM)

Destek vektör makineleri, sınıflandırma, regresyon ve aykırı değerlerin tespiti için kullanılan bir dizi denetimli öğrenme yöntemidir. Destek vektör makinesi algoritmasının amacı, N boyutlu bir uzayda (N - özellik sayısı) veri noktalarını belirgin bir şekilde sınıflandıran bir hiperdüzlem bulmaktır [1]. Şekil 2’de görüldüğü gibi iki veri noktası sınıfını ayırmak için seçilebilecek birçok olası hiperdüzlem vardır. Amacımız maksimum kenar boşluğuna, yani her iki sınıfın veri noktaları arasındaki maksimum mesafeye sahip bir düzlem bulmaktır. Kenar boşluğu mesafesini maksimuma çıkarmak, gelecekteki veri noktalarının daha güvenle sınıflandırılabilmesi için bir miktar güçlendirme sağlar.



Şekil 2: Destek vektör makineleri çalışma şekli.

### 3.3 Doğrusal-DVM


DVM algoritması, bir sınıflandırma problemi için veri kümesindeki örnekleri bir hiperdüzlemle iki sınıfa ayırmayı hedeflerken Doğrusal-DVM algoritması ise, bu hiperdüzlemi Doğrusal bir fonksiyonla ifade etmektedir. Doğrusal-DVM algoritmasının temelinde yatan optimizasyon problemi olan çift yönlü kararlılık yöntemini kullanır. Bu yöntem, veri kümesindeki örnekleri iki sınıfa ayırmak için bir hiperdüzlem bulurken, bu hiperdüzlemi en iyi şekilde ayıracak olan destek vektörlerini bulmaya çalışır. Bu işlem, hiperdüzlemi tanımlayan ağırlık vektörü ve bias terimini tahmin etmek için kullanılır.

Doğrusal-DVM algoritması, bir hiperdüzlemi bulmak için örnekleri iki sınıfa ayırmaya çalışırken, ayrılabilir bir veri kümesi için doğrudan çözüm bulabilir. Ancak, eğer veri kümesi ayrılabilir değilse, DVM algoritması yumuşatmalı sınıflandırma adı verilen bir yöntemle çalışır. Bu yöntem, bazı örneklerin hiperdüzlemin ötesinde yer almasına izin verir, böylece DVM algoritması daha iyi bir sınıflandırma performansı elde eder. Özetle, Doğrusal-DVM algoritması, veri kümesindeki örnekleri iki sınıfa ayırmak için bir hiperdüzlem bulmaya çalışırken DVM algoritmasının dual-formulation yöntemini kullanarak, hiperdüzlemi en iyi şekilde ayıracak olan destek vektörlerini bulmaya çalışmaktadır.

### 3.4 Doğrusal Regresyon (DR)

Doğrusal regresyon, bir bağımsız değişken (X) ile bir veya daha fazla bağımlı değişken (Y) arasındaki doğrusal ilişkiyi modellemektedir. Doğrusal regresyon, en uygun bir doğru veya düzlem (eğer çoklu değişkenler varsa) çizerek, verilerin değişkenler arasındaki ilişkisini en iyi şekilde temsil eden Şekil 3’deki gibi bir model oluşturur. Burada

yeşil noktalar verilerin konumu kırmızı doğrusal çizgi regresyon çizgisidir.



Şekil 3: Doğrusal regresyon grafiği.

Bu çalışmadaki Doğrusal regresyon sınıflandırıcısı, Python programlama kütüphanesinde yer alan "Linear Regression" sınıfı kullanılarak uygulanmıştır. Bu sınıf, doğrusal regresyon için temel özellikleri ve parametreleri içermektedir ve regresyon modeli oluşturmak için veriler üzerinde en küçük kareler yöntemini kullanır. Doğrusal regresyon, veri kümesindeki değişkenler arasındaki ilişkiyi modellerken, hataların en aza indirilmesi prensibine dayanır. Bu nedenle, doğrusal regresyon, en küçük kareler yöntemi olarak da adlandırılmaktadır [14].

Bu model, veri noktaları arasındaki doğrusal ilişkiyi temsil eden bir doğru ile ifade edilir. Bu doğru, eğitim verilerindeki hataların en aza indirilmesi prensibine göre en iyi uyumu sağlar. Eğitim verilerindeki özellikler, Şekil 3'de görüleceği üzere sınıflandırıcının X girdisi olarak kullanılırken, etiketler (pozitif ve negatif tümör durumları) sınıflandırıcının Y çıktısı olarak kullanılmıştır.

### 3.5 Chi-Kare

Chi-Kare (Chi-Square) testi, kategorik verilerin analizinde kullanılan bir istatistiksel testtir. Bu test, iki kategorik değişken arasındaki ilişkinin varlığını veya yokluğunu belirlemek için kullanılmaktadır [15]. Çalışma içinde, Chi-Kare sınıflandırıcısı özellik çıkarımı için Select KBest sınıfı kullanılarak uygulanmıştır. Bu sınıf, verilerden en önemli özellikleri seçmek için kullanılır. Özellik seçimi, sınıflandırıcı için en anlamlı ve önemli olan özelliklerin seçilmesi amacıyla yapılır ve sınıflandırma doğruluğunu artırmayı hedefler. Select KBest sınıfı, veri özelliklerinin önemini, istatistiksel bir test olan Chi-kare testini kullanarak

belirler. Bu test, her özelliğin her sınıftaki frekanslarını ve beklenen frekanslarını karşılaştırarak, sınıf etiketleriyle ilişkisini ölçer. Sonuç olarak, özellikler sıralanır ve en önemli olanları seçmek için bir kriter belirlenir.

### 3.6 HOG

Yönlendirilmiş Gradyan Histogramı (HOG), bilgisayarlı görüş ve nesne tanıma alanında yaygın olarak kullanılan bir özellik çıkarım yöntemidir. Bu yöntem, özellikle nesne tanıma ve insan algılama gibi uygulamalarda kullanılır. HOG, görüntüleri bloklara böler, her bloktaki kenar ve gradient bilgilerini hesaplar, ardından bu bilgileri bir özellik vektörü olarak birleştirir.

Bu çalışmada, HOG özellikleri kullanılarak nesne tanıma yapılacaktır. HOG, görüntülerdeki kenarları ve yapıları yakalamak için kullanılan bir özellik vektörüdür. Bu özellik vektörü, görüntülerin kenar ve gradient bilgilerini temsil eder. HOG özellikleri genellikle nesne tanıma sistemlerinde ve insan algılama uygulamalarında kullanılır.

### 3.7 Veri Seti


Bu çalışmada, beyin tümörü için MRG görüntülerinden oluşan Brain MRG Images for Brain Tumor Detection veri seti kullanılmıştır. Veri seti, pozitif ve negatif olmak üzere iki sınıfa ayrılmıştır. Toplamda 100'ü pozitif ve 100'ü negatif olan 200 MRG görüntüsü bulunmaktadır. Pozitif örnekler, beyin tümörü bulunduran görüntüler olmakla beraber negatif örneklerde ise beyin tümörü bulunmamaktadır [16]. Çalışmada veri setinin model içerisinde kullanılabilir hale getirilmesi için veri ön işleme gereklidir. Verilerin ön işleme aşaması aşağıdaki adımlardan oluşmaktadır:

- Verilerin yüklenmesi
- Verilerin önemli özelliklerinin seçilmesi
- Verilerin temizlenmesi
- Verilerin ölçeklendirilmesi

Verilerin yüklenmesi aşaması Python'daki Pandas kütüphanesi kullanılarak gerçekleştirilmiştir. Önemli özelliklerin seçilmesi aşamasında, görüntülerin RGB renk uzayındaki histogram eşitleme özellikleri kullanılmıştır. Verilerin temizlenmesi aşamasında, boş veya eksik verilerin bulunduğu örnekler silinmiştir. Verilerin

ölçeklendirilmesi, görüntülerin yeniden boyutlandırılmasıyla gerçekleştirilmiştir. Bu işlem, ölçeklendirme işlemlerini kolaylaştırdı ve ayrıca öğrenme algoritmaları için daha uygun bir boyut sağlamıştır.

Bu işlemleri tüm görüntülere uyguladıktan sonra, HOG özellikleri çıkarılmaktadır. HOG, bilgisayarla görme ve görüntü işlemede nesnelere tespit etmek için kullanılan bir özellik tanımlayıcısıdır. HOG kullanımına alternatif olarak PCA (Temel Bileşen Analizi) de kullanılmaktadır. Şekil 4’de bir MR görüntüsünün HOG uygulandıktan sonraki çıktısı gösterilmiştir.



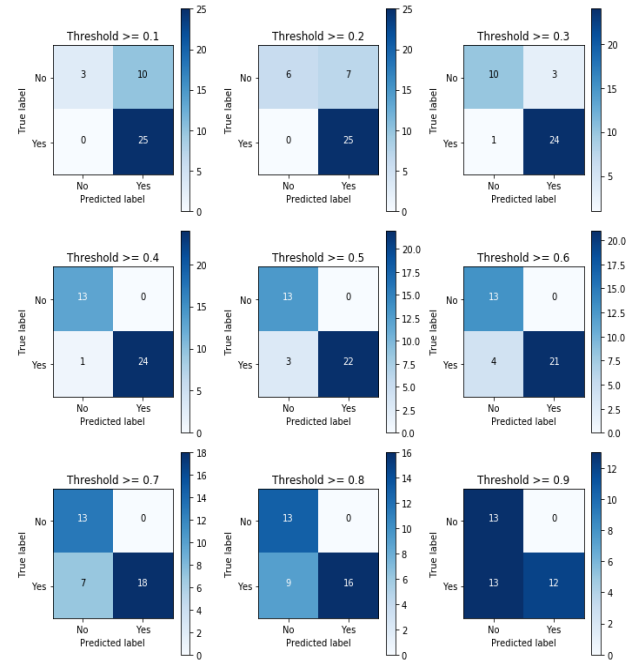
Şekil 4: MR görüntülerine Yönlendirilmiş Gradyan Histogramının uygulanması.

Uygulamadaki sınıflandırma probleminin tahmin sonuçlarının özetini sunmak için Tablo 1’deki karışıklık matrisi kullanılmıştır. Algoritmaların kullanımı için, ön işlem aşaması bittikten sonra Duyarlılık metriğini 1’e eşitlemek amaçlanmaktadır. Böylece FN (False Negative) parametresi 0 olacaktır. Bu şekilde, sınıflandırıcı tümörlü görüntüleri istenilen şekilde tespit edecektir.

Tablo 1: Karışıklık matrisi.

		Tahmini Değer	
		Pozitif	Negatif
Gerçek Değer	Pozitif	TP	FP
	Negatif	FN	TN

Şekil 5’te metriğin en iyi olduğu optimum eşik aranmaktadır. Bu eşik, modelin doğruluğuna ve doğrulama setindeki duyarlılık performansına göre seçilir. Program %10’dan başlayıp %90’a kadar farklı yakınsama değerlerine göre olasılıklar yapmakta ve her bir eşik değeri için matris tablosunun değeri değişmektedir. Bu yakınsama değerleri, sağlıklı ve sağlıklı veri setlerinin karşılaştırılması sırasında, ne kadarlık bir yüzdeyle rastgele karşılaştırılacağı konusunda uygulanır. Böylece performans ölçümleri (doğruluk, hassasiyet, duyarlılık, f1) üzerinden en iyi sonuç bulunmaya çalışılmıştır. %10 eşikinde %73,68, %20 eşikinde %81,58, %30 eşikinde %89,47, %40 eşikinde %97,37, %50 eşikinde %92,11, %60 eşikinde %89,47, %70 eşikinde %81,58, %80 eşikinde %65,79 doğruluk oranları elde edilmiştir. Sonuçlardan incelenebileceği üzere, en optimum doğruluk oranı %40 eşikinde elde edilmiştir ve çalışma kodlarında %40 eşik değeri baz alınarak ilerleme sağlanmıştır.



Şekil 5: 0,1-0,9 arası farklı eşik değerlerine göre karşılaştırma matrisi sonuçları.

### 3.7.1 Özellik Çıkarımı

Özellik çıkarımı, öğrenme algoritmalarının kullanabileceği temel özelliklerin belirlenmesi için gereklidir. Bu çalışmada, histogram eşitleme tekniği kullanılarak görüntülerden özellikler çıkarılmıştır. Görüntülerin RGB renk uzayındaki

histogram eşitleme özellikleri, veri kümesindeki özellikler olarak kullanılmıştır.

### 3.7.2 Öğrenme Algoritmaları

Bu çalışmada Doğrusal Regresyon, Destek Vektör Makineleri ve Rassal Orman olmak üzere 3 farklı öğrenme algoritması kullanılmıştır. Bu algoritmalar da Python'daki scikit-learn kütüphanesi kullanılarak uygulanmıştır.

### 3.8 Değerlendirme Ölçütleri

Model performansının ölçülmesi, makine öğrenmesi ve yapay zekâ alanlarında oldukça önemlidir. Modelin veriler üzerinde nasıl bir performans sergilediğinin anlaşılmasını sağlayan bu metrikler, modellerin geliştirilmesi ve olası eksikliklerin belirlenmesine yardımcı olmaktadır. Doğruluk, kesinlik, duyarlılık, F-Ölçüsü ve özgüllüğü, yapay zekâ ve makine öğrenmesi alanında model performansının ölçülmesinde kullanılan temel metriklerdir. Bu metrikler, modelin doğruluğunu, hassasiyetini, hatırlamasını, ölçülebilirliğini ve özgüllüğünü ölçmek için kullanılır.

**Doğruluk:** Modelin veriler üzerinde doğru tahmin yapma oranını ifade etmektedir. Modelin doğru tahmin yapma oranı, tüm verilere uygulandığında modelin tahmin ettiği doğru sonuçların toplamını, tüm verilerin sayısına bölünmesi ile Denklem 1 ile bulunmaktadır. Modelin doğruluk değeri 0 ile 1 arasında değişir ve 1'e yakın olması, modelin verileri doğru tahmin ettiğini gösterir.

$$\text{Doğruluk} = \frac{TP + TN}{TP + FP + TN + FN} \quad (1)$$

**Kesinlik:** Modelin pozitif tahminlerinin doğru olma oranını ifade etmektedir. Kesinlik, Denklem 2'de görüldüğü üzere, pozitif tahminlerinin doğru olma oranını, pozitif tahminlerinin toplamını, pozitif tahminlerin doğru olma sayısına bölünmesi ile bulunmaktadır. Modelin kesinliği, 0 ile 1 arasında değer alır ve 1'e yakın olması, modelin pozitif tahminlerinin doğru olduğunu gösterir.

$$\text{Kesinlik} = \frac{TP}{TP + FP} \quad (2)$$

**Duyarlılık:** Modelin pozitif verilerinin doğru tahmin edilme oranını ifade etmektedir. Duyarlılık, pozitif verilerinin doğru tahmin edilme oranı, pozitif verilerinin doğru tahmin edilme sayısını, pozitif verilerin toplamına bölünmesi ile Denklem 3 kullanılarak bulunmaktadır. Modelin duyarlılığı, 0 ile 1 arasında değer alır ve 1'e yakın olması, modelin pozitif verileri doğru tahmin ettiğini gösterir.

$$\text{Duyarlılık} = \frac{TP}{TP + FN} \quad (3)$$

**Hassasiyet:** Modelin negatif verilerinin doğru tahmin edilme oranını ifade etmektedir. Hassasiyet, negatif verilerinin doğru tahmin edilme oranı, negatif verilerin doğru tahmin edilme sayısını, negatif verilerin toplamına bölünerek Denklem 4 ile bulunmaktadır. Modelin hassasiyeti, 0 ile 1 arasında değer alır ve 1'e yakın olması modelin tüm negatif verilerinin doğru tahmin edildiğini göstermektedir.

$$\text{Hassasiyet} = \frac{TP}{TP + FN} \quad (4)$$

F-ölçüsü kesinlik ve duyarlılığın harmonik ortalamasıdır ve modelin pozitif verileri üzerindeki performansının ölçülmesinde kullanılmaktadır. F-Ölçüsü, kesinlik ve duyarlılık değerlerine göre modelin pozitif veriler üzerindeki performansının genel bir değerlendirmesini yapar.

F-Ölçüsü, bir denge oranıdır ve hem Kesinlik hem de Duyarlılık değerlerinin yüksek olmasını hedefler ve Denklem 5 ile hesaplanır. F-Ölçüsü, harmonik ortalama formülü kullanılarak hesaplanır ve 0 ile 1 arasında değer almaktadır. 1 değeri modelin hem kesinlik hem de duyarlılık değerlerinin maksimum olduğunu göstermektedir.

$$F_1 = 2 \times \frac{\text{Kesinlik} \times \text{Duyarlılık}}{\text{Kesinlik} + \text{Duyarlılık}} \quad (5)$$

## 4. TARTIŞMA VE SONUÇ

Sonuçlar, farklı özelliklere sahip öğrenme algoritmaları kullanılarak elde edildi. En yüksek doğruluk oranı, Rassal Orman algoritması kullanılarak elde edilmiştir. Ancak, Destek Vektör



Makineleri algoritmasının verdiği yüksek performans da göz ardı edilmemelidir.

F-ölçüsü (F1) değeri, harmonik ortalama değeri verdiği için Rassal Orman modelinin MRG görüntülerini işleme konusundaki sorunu, ileride yapılacak benzer çalışmalarda göz önünde bulundurulmalıdır.

Ayrıca, çalışma sonucunda elde edilen değerlere göre, DVM tek başına kullanıldığında doğruluk ve kesinlik değerinin, diğer modellere kıyasla daha kötü performans verdiği görülmüştür. Doğrusal-DVM ve Ki Kare-DVM uygulamalarının, sıradan DVM modeline göre bazı noktalarda %40'a kadar daha yüksek doğruluk avantajı sunduğu görülmüştür.

**Tablo 2:** Sınıflandırma algoritmalarının karşılaştırmalı analizi.

	Doğru luk	Kesin lik	Duyarl ılık	Fölç üsü	Duyarl ılık
DR	0.842	0.8	1.0	0.888	0.571
DVM	0.815	0.774	1.0	0.872	0.5
<b>Doğru sal- DVM</b>	0.868	0.827	1.0	0.905	0.642
RF	0.815	0.793	0.958	0.867	0.571
<b>DVM- Chi<sup>2</sup></b>	0.894	0.857	1.0	0.923	0.714

Tablo 2'de incelendiğinde çalışmanın sonunda alınan sonuçlar, çalışmanın ana konusu olan beyin tümörlerinin sınıflandırılması için kullanılan modellerinin performanslarını kapsamlı bir şekilde değerlendirmemizi sağlamaktadır.

Bu çalışmada, MRG görüntülerinin histogram eşitleme özellikleri kullanılarak farklı makine öğrenimi algoritmaları kullanılarak sınıflandırıldı. Çalışmanın sonuçları değerlendirildiğinde, Rassal Orman ve DVM algoritmaları en iyi performansı göstermiştir.

Değerlendirme ölçütlerinin sonuçları incelenecek olursa, en yüksek doğruluk değerini 0.894 ile DVM-Additive Chi<sup>2</sup> algoritması elde etmiştir. Ayrıca, bu algoritma en yüksek Kesinlik (0.857), Duyarlılık (1.0) ve F-Ölçüsü (0.923) değerlerini de elde etmiştir. Bu sonuçlar, DVM-Additive Chi<sup>2</sup>

algoritmasının tümör tespit etmede en başarılı algoritma olduğunu göstermektedir.

DVM-Additive Chi<sup>2</sup> algoritmasının takibinde %86,8 doğruluk oranıyla, Chi-Kare testinin kullanıldığı Doğrusal-DVM algoritması bulunmaktadır.

Rassal Orman algoritması da %81,5 doğruluk oranı ile oldukça başarılı bir sonuç vermiştir. Sonuçlar ayrıca, özellik seçimi yöntemlerinin performanslarının model doğruluğuna önemli ölçüde katkıda bulunduğunu göstermiştir. Hem özellik çıkarımı hem de özellik seçimi yöntemleri, tümör sınıflandırma performansını arttırmada kritik rol oynamaktadır.

Bununla birlikte, elde edilen sonuçlar birçok yönden ilginç ve değerlidir, ancak çalışmanın bazı sınırlamaları da vardır. Veriler sadece beyin tümörünü içermektedir. Bu sebeple beyin tümörü haricindeki diğer tümör türleri için kullanılabilirliğinin başka veri setleri ile test edilmesi gerekmektedir.

Ayrıca, çalışmadaki veri seti sınırlı sayıda görüntü içermektedir, gelecekte daha büyük veri setleri kullanılarak model performansının daha fazla değerlendirilmesi önerilmektedir.

Sonuç olarak, bu çalışma, tümör sınıflandırma modellerinin geliştirilmesi için özellik çıkarımı ve özellik seçimi yöntemlerinin önemli olduğunu göstermektedir. Elde edilen sonuçlar, tümör sınıflandırması için farklı makine öğrenimi algoritmalarının kullanılabileceğini ve özellik seçimi ve çıkarımı yöntemlerinin başarılı sonuçlar elde etmek için kullanılabileceğini göstermektedir. Bu çalışma, tümör sınıflandırma alanında daha fazla araştırma yapılması için bir temel sağlamaktadır.

**Yazar Katkısı:** Oruç Altay Kırlı ve Merve Sansarcı çalışmada literatür taraması ve uygulamanın gerçekleştirilmesi alanında katkı vermişlerdir. Osman Özkaraca ve Gürcan Çetin verilerin yorumlanması uygulamanın doğrulanması noktasında katkı sağlamışlardır.

**Çıkar Çatışması:** Bu çalışmanın yazarları olarak, herhangi bir kurum/kuruluş ya da kişi ile çıkar çatışması bulunmadığını onaylarız.

## 5. KAYNAKLAR

- [1] N. Bhagat and G. Kaur, "MRI brain tumor image classification with support vector machine," *Mater. Today: Proc.*, vol. 51, no. 8, pp. 2233-2244, 2022.
- [2] P. Sutradhar, P. K. Tarefder, I. Prodan, M. S. Saddi and V. S. Rozario, "Multi-modal case study on MRG brain tumor detection using support vector machine, random forest, decision tree, k-nearest neighbor, temporal convolution transfer learning," *AJSE*, vol. 20, no. 3, pp. 107-117, Sep. 2021.
- [3] S. N. Kumar, A. L. Fred, H. A. Kumar and P. S. Varghese, "Performance metric evaluation of segmentation algorithms for gold standard medical images," *Recent Findings in Intelligent Computing Techniques*, Springer, Singapore, Nov. 2018, pp. 457-469.
- [4] P. Balabil, "Generative deep belief model for improved medical image segmentation," *Intell. Autom. Soft Comput.*, vol. 35, no. 1, pp. 1-14, 2023.
- [5] K. D. Babu and C. S. Singh, "Brain tumor segmentation through level based learning model," *Comput. Syst. Sci. Eng.*, vol. 44, no. 1, pp. 709-720, 2023.
- [6] R. Ghulam, S. Fatima, T. Ali, N. A. Zafar, A. A. Asiri, H. A. Alshamrani, S. M. Alqhtani and K. M. Mehdar, "A U-Net-based CNN model for detection and segmentation of brain tumor," *Comput. Mater. Contin.*, vol. 74, no. 1, pp. 1333-1349, 2023.
- [7] S. Sedlar, "Brain tumor segmentation using a multi-path CNN based method," *Brainlesion: Glioma, Multiple Sclerosis, Stroke and Traumatic Brain Injuries, Lecture Notes in Computer Science*, Springer, Cham, Feb. 2018, vol. 10670, pp. 403-422.
- [8] Y.-X. Zhao, Y.-M. Zhang ve C.-L. Liu, "Bag of tricks for 3D MRG brain tumor segmentation," *Brainlesion: Glioma, Multiple Sclerosis, Stroke and Traumatic Brain Injuries*, Springer, Cham, May 2020, vol. 11992, pp. 210-220.
- [9] H. Liu, G. Huo, Q. Li, X. Guan and M.-L. Tseng, "Multiscale lightweight 3D segmentation algorithm with attention mechanism: Brain tumor image segmentation," *Expert Syst. Appl.*, vol. 214, pp. 119166, Mar. 2023.
- [10] F. Behrad and M. S. Abadeh, "Evolutionary convolutional neural network for efficient brain tumor segmentation and overall survival prediction," *Expert Systems with Applications*, vol. 213, no. Part B, pp. 118996, 2023.
- [11] S. Pereira, A. Pinto, V. Alves and C. A. Silva, "Brain tumor segmentation using convolutional neural networks in MRG images," *IEEE Trans. Med. Imaging.*, vol. 35, no. 5, pp. 1240-1251, Mar. 2016.
- [12] L. Anand, K. P. Rane, L. A. Bewoor, J. L. Bangare, J. Surve, M. P. Raghunath and S. Sankaran, "Development of machine learning and medical enabled multimodal for segmentation and classification of brain tumor using MRG images," *Comput. Intell. Neurosci.*, pp. 7797094, Aug. 2022.
- [13] B. Ragupathy, B. Subramani and S. Arumugam, "A novel approach for MR brain tumor classification and detection using optimal CNN-SVM model," *Int. J. Imaging Syst. Technol.*, vol. 33, no. 2, pp. 746-759, Nov. 2022.
- [14] J. Wu and H. Yang, "Linear regression-based efficient SVM learning for large-scale classification," *IEEE Trans. Neural Netw. Learn. Syst.*, vol. 26, no. 10, pp. 2357-2369, Jan. 2015.
- [15] The Chi squared tests., 1997. [Online]. Available: <https://www.bmj.com/about-bmj/resources-readers/publications/statistics-square-one/8-chi-squared-tests>.
- [16] M. Nickparvar, "Brain Tumor MRG Dataset," 2021. Retrieved from <https://www.kaggle.com/datasets/masoudnickparvar/brain-tumor-mri-dataset/metadata>.