



Kahramanmaraş Sütçü İmam University

Journal of Engineering Sciences



Geliş Tarihi : 06.05.2023
Kabul Tarihi : 19.07.2023

Received Date : 06.05.2023
Accepted Date : 19.07.2023

BEYİN MR GÖRÜNTÜLERİNDEN TÜMÖR TESPİTİ İÇİN DERİN ÖĞRENMEYE DAYALI HİBRİT MODELLER

DEEP LEARNING BASED HYBRID MODELS FOR TUMOR DETECTION FROM BRAIN MR IMAGES

İclal ÖZCAN* (ORCID: 0000-0001-7414-7425)
Serkan ÖZTÜRK² (ORCID: 0000-0002-0309-3420)

^{1,2}Erciyes Üniversitesi, Bilgisayar Mühendisliği Bölümü, Kayseri, Türkiye

Sorumlu Yazar / Corresponding Author: İclal ÖZCAN, iclaltemizsoy@erciyes.edu.tr

ÖZET

İnsan hücrelerinin aşırı bölünmeye bağlı anormal bir şekilde çoğalmasına tümör denmektedir. Vücudun birçok noktasında oluşabilen tümörler, oluştuğu yere göre tehlikelilik derecesine sahiptir. Beyin, tümör oluşumunda en tehlikeli bölgelerden birisidir. Beyin bölgesindeki tümörlerin tespiti için son yıllarda yoğun çalışmalar gerçekleştirilmiştir. Yapay zeka temelli yöntemler bu çalışmaların başında gelmektedir. Bir derin öğrenme yöntemi olan evrişimli sinir ağları (CNN) sınıflandırma, özellik çıkarma ve transfer öğrenme amaçlarıyla kullanılmaktadır. Bu çalışmada CNN yöntemi beyin MR görüntülerinden özellik çıkarma amacıyla kullanılmıştır. Bu kapsamda ön eğitilmiş CNN modellerinden DarkNet53 modeli özellik çıkarımı için seçilmiştir. DarkNet53 modelinin özellik çıkarıcı katmanları sırasıyla conv52, res23, avg1 ve conv53 katmanlarıdır. Özellik çıkarımından sonra özellik seçimi işlemi uygulanmıştır. Relief ve Ki-Kare Test yöntemleri özellik seçici yöntemler olarak seçilmiştir. Özellik çıkarımından sonra klasik makine öğrenme yöntemlerinden birisi olan destek vektör makineleri algoritması sınıflandırıcı yöntem olarak belirlenmiştir. Önerilen yöntem, "Brain MRI Images for Brain Tumor Detection" veri seti üzerinde denenmiştir. Deneysel sonuçlara göre: res23 katmanının özellik çıkarıcı, Ki-Kare Test yönteminin özellik seçici olarak belirlendiği önerilen yöntemle en iyi sonuç elde edilmiştir.

Anahtar Kelimeler: Beyin MR görüntüleri, tümör tespiti, derin özellikler, özellik seçimi, SVM.

ABSTRACT

An abnormal proliferation of human cells due to excessive division is called a tumor. Tumors, which can form in many parts of the body, have a degree of danger according to where they occur. The brain is one of the most dangerous areas of tumor formation. Intense studies have been carried out in recent years for the detection of tumors in the brain region. Artificial intelligence-based methods are at the forefront of these studies. Convolutional neural networks (CNN), a deep learning method, are used for classification, feature extraction and transfer learning purposes. In this study, CNN method was used for feature extraction from brain MR images. In this context, DarkNet53 model, one of the pre-trained CNN models, was selected for feature extraction. The feature extractor layers of the DarkNet53 model are conv52, res23, avg1, and conv53, respectively. After feature extraction, feature selection process was applied. Relief and Chi-Square Test methods were chosen as feature-selective methods. After feature extraction, the support vector machine algorithm, which is one of the classical machine learning methods, was determined as the classifier method. The proposed method has been tested on the "Brain MRI Images for Brain Tumor Detection" dataset. According to the experimental results, the best result was obtained with the proposed method in which the res23 layer was determined as feature extractor and the Chi-Square Test method as feature selective.

Keywords: Brain MR images, tumor detection, deep features, feature selection, SVM.

To Cite: ÖZCAN, İ. & ÖZTÜRK, S., (2023). BEYİN MR GÖRÜNTÜLERİNDEN TÜMÖR TESPİTİ İÇİN DERİN ÖĞRENMEYE DAYALI HİBRİT MODELLER. *Kahramanmaraş Sütçü İmam Üniversitesi Mühendislik Bilimleri Dergisi*, 26(3), 718-733.

GİRİŞ

İnsan hücrelerinin aşırı bölünmesi ile anormal şekilde çoğalmasına tümör denir. Tümör, vücudun birçok farklı noktasında oluşabilmektedir. Oluştığı yere, büyüklüğüne, türüne göre durumun ciddiyeti değişkenlik gösterir. Ölümcül olabilen bir hastalık olan beyin tümörü, insan hayatını tehdit etmektedir. Bir doktorun tümörü doğru ve hızlı bir şekilde teşhis etmesi zor bir iştir (Pranitha vd., 2022). Tümörün büyümeden alınması çoğu hastada yaşamının devamı için önemlidir. Erken teşhis bunun için çok önemli ve hayatidir. Bilgisayarlı tomografi (BT) ve manyetik rezonans görüntüleme (MRI) tümörün erken evrelerinde teşhis edilmesine yardımcı olabilecek hücre boyutu, konumu veya şekli gibi beyin dokularındaki anomalileri incelemek için yaygın olarak kullanılan iki yöntemdir (Tiwari vd., 2020).

Bu çalışmada ön eğitilmiş CNN modeli DarkNet53 kullanılarak 4 farklı katmanından çıkarılan derin özellikler ve SVM algoritması kullanılarak beyin MR görüntülerinden tümör tespit sistemi geliştirilmiştir. Sistem temelde 3 ana fazdan oluşmaktadır. Bunlardan ilki özellik çıkarmadır. Özellik çıkarma için güçlü bir yöntem olan ön eğitilmiş evrişimli sinir ağlarından (CNN) faydalanılmıştır. CNN'ler görüntülerden ayırt edici anlamlı özellikler çıkarma konusunda başarılıdır. Bu sebeple nesne algılama, görüntü sınıflandırma ve bölütleme gibi görevler için idealdir. Bu başarı, ön eğitilmiş CNN modellerinin özellik çıkarmı fazında tercih edilmesinde ana sebeptir. İkinci fazda ise özellik seçme işlemi yapılmaktadır. Özellik seçimi ile yüksek boyutlu özelliklere sahip veriler için özellik seçme algoritmaları kullanarak boyut indirgeme hedeflenmiştir. Bu fazda Relief ve Ki-Kare Test yöntemleri tercih edilmiştir. Relief algoritması gürültülü verilerdeki gürbüzlüğü, büyük veri setlerindeki etkinliği, özellik önem puanlarının yorumlanabilirliği ve çeşitli uygulamalardaki kullanılabilirliği gibi avantajlarından dolayı tercih edilmiştir. Bir diğer özellik seçici olarak kullanılan Ki-Kare test tekniği; özelliklerin ilgi düzeyinin değerlendirilebilmesi, sadelik ve yorumlanabilirlik gibi avantajlarından dolayı tercih edilmiştir. Son fazda ise popüler bir klasik makine öğrenme yöntemi olan SVM ile sınıflandırma işlemi gerçekleştirilmiştir. SVM; ezberlemeye karşı dayanıklı bir algoritmadır. Ayrıca az veri ile etkili öğrenme gerçekleştirebilen bir yapıya sahiptir. Sistem "Brain MRI Images for Brain Tumor Detection" veri seti üzerinde değerlendirilmiştir.

Çalışmanın bundan sonraki planlaması şu şekildedir: Bölüm 2'de beyin MR görüntülerinden tümör tespiti üzerine sınıflandırma çalışmaları literatür taramasında toplanmıştır. Bölüm 3'te tümör sınıflandırması için geliştirilmiş yöntem tüm fazlarıyla detaylı olarak anlatılmış olup, yöntemin "Brain MRI Images for Brain Tumor Detection" veri seti üzerindeki başarımı Bölüm 4 ile incelenmiştir. Son bölümde değerlendirme ve gelecek çalışmalardan bahsedilmiştir.

LİTERATÜR İNCELEMESİ

Makine öğrenme yöntemleri kullanılarak tümör tespiti üzerine çokça çalışma yapılmıştır. Raporun bu bölümünde yapılan çalışmalar sunulmaktadır. Sachdeva ve ekibi, genetik algoritma (GA) ve destek vektör makinelerinin (SVM) kullanıldığı yeni hibrit bir yaklaşım önermişlerdir. Genetik algoritma bu çalışmanın özellik seçimi fazında yer almıştır. SVM sınıflandırıcı ile elde edilen doğruluk oranı, GA optimizasyon tekniği kullanılarak %52,9'dan %93,5'e kadar çıkarılmıştır (Sachdeva vd., 2011). Geleneksel özellik çıkarma yöntemlerinden elde edilen özelliklerle, derin özellikler kullanılarak elde edilen sonuçlar kadar başarı genelde elde edilememektedir. Russakovsky ve ark. ön eğitilmiş CNN modelleri kullanarak derin özellik tabanlı bir yöntem önermişlerdir. Önerilen yöntem ile %95'e kadar doğruluk oranı elde etmişlerdir (Russakovsky vd., 2015). Heba M ve ekibi, beyin tümörünün üç türü olan glioblastoma (en yaygın), sarkom (en yaygın ikinci) ve metastatik bronkojenik kanser (en yaygın üçüncü) türleri için CNN tabanlı bir sınıflandırma yöntemi geliştirmiştir. Geliştirilen yöntem %84 doğruluk oranı ile başarı sağlamıştır (Mohsen vd., 2018). Histopatoloji sınıflandırma görevleri ve histopatoloji görüntü segmentasyonu için, Yan Xu ve ark., nispeten minimal eğitim verilerine dayalı olarak derin konvolüsyonel etkinleştirici özellikler üretmişlerdir. Histopatoloji fotoğrafları çok büyük olduğundan, bir görüntüyü sınıflandırmak üzere gereken özellik vektörlerinin sayısını azaltmak için özellik havuzu kullanılmıştır. Deneysel sonuçlara göre %97,5 sınıflandırma doğruluğu elde edilmiştir (Xu vd., 2015). Özellik seçimi ve SVM ile sınıflandırma içeren bütünleşik yöntemle, I Zacharaki ve ekibi, beyin tümör tespiti üzerine çalışmıştır. Simülasyon sonuçlarına göre %97 doğruluk oranı elde edilmiştir (Zacharaki vd., 2009). Bir CNN sınıflandırmasına dayalı otomatik beyin tümör tespit sistemi, 2018'de Seetha J. ve S Selvakumar (Seetha ve Raja, 2018) tarafından önerilmiştir. Yaptıkları çalışmada %98,6 doğruluk oranı elde etmişlerdir. Beyin tümörlerinin sınıflandırılması ve segmentasyonu için Amin Javeria ve ekibi tarafından derin sinir ağları tabanlı bir yöntem geliştirilmiştir (Amin vd., 2018). Önerilen model 7 katmanlı olup içerisinde 5 evrişim, 6 ReLU ve 1 softmax işlemi barındırmaktadır. %89,5 doğruluk oranında başarı deneysel sonuçlara göre elde edilmiştir.

Bu çalışmada kullanılan "Brain MRI Images for Brain Tumor Detection" veri seti farklı çalışmalarda deneysel simülasyonlarda yer almıştır. Siddique ve ekibi derin evrişimli sinir ağı temelli beyin tümör tespit çalışmaları yapmıştır. Deneysel kurulumda veri seti 207 görüntü eğitim, 24 görüntü test ve 22 görüntü validasyon olarak ayrılmıştır. VGG16 modeline benzer bir mimarinin kurulduğu önerilen yöntemle %96 oranında başarı elde edilmiştir (Siddique vd., 2020). Febrianto ve arkadaşları, MR görüntülerinden tümör tespiti üzerine 2 CNN modeli geliştirmişlerdir. 253 veri barındıran veri setini veri çoğullama işlemi uygulayarak 2065 görüntülü çoğullanmış bir veri setine çevirmişlerdir. Deneysel çalışmalarında %93'e kadar başarı elde etmişlerdir (Febrianto vd., 2020). U-Net kullanarak beyin görüntülerinden anomali tespiti çalışması, Rai ve Chatterjee tarafından gerçekleştirilmiştir. %80 eğitim %20 test verisi olacak şekilde veri bölütlemesi yapılmıştır. Deneysel sonuçlara göre kırılmış MR görüntülerinde %98, kırılmamış görüntülerde %94 doğruluk oranı elde edilmiştir (Rai ve Chatterjee, 2021).

MATERYAL ve METOT

Bu çalışmada beyin MR görüntülerinden tümör tespiti için derin öğrenme tabanlı hibrit bir yöntem önerilmiştir. Bu yöntem 3 fazdan oluşmaktadır. İlk faz ile MR görüntülerinden özellikler çıkarılmaktadır. İkinci fazda yüksek boyutlu özelliklere sahip veriler için özellik seçme algoritmaları kullanarak boyut indirgeme hedeflenmiştir. Son fazda SVM algoritması ile sınıflandırma yapılmaktadır. Önerilen sistem ayrıntılı olarak aşağıdaki alt bölümlerde sunulmuştur:

Özellik Çıkarma Yöntemleri

Özellik çıkarımı, ham veriyi, orijinal veri setindeki bilgileri korurken işlenebilecek sayısal özelliklere dönüştürme sürecini ifade etmektedir. Makine öğrenimini doğrudan ham verilere uygulamaktan daha iyi sonuçlar vermektedir (Mathworks, 2019). Bu çalışmada özellik çıkarımı için etkin bir yöntem olan ön eğitilmiş CNN modelleri kullanılmıştır.

Ön Eğitilmiş CNN Modelleri

Evrişimli sinir ağları (convolutional neural networks, CNN) özelleşmiş ve çok katmana sahip özel bir yapay sinir ağı sistemidir (Krizhevsky vd., 2017). En az bir evrişim katmanı barındırması gereken CNN temel olarak, evrişim katmanı, ortaklama katmanı, aktivasyon fonksiyonları, tam bağlı katman, kayıp katmanı, düzenleme ve optimizasyon bileşenlerinden oluşmaktadır (Krizhevsky vd., 2017).

Daha önceden eğitilmiş ve başarılı olmuş CNN modelleri ön eğitilmiş CNN modelleri olarak adlandırılırlar. Bu modeller transfer öğrenme, özellik çıkarma ve sınıflandırma amaçlarıyla kullanılabilir (Özcan ve Basturk). Ön eğitilmiş modelden genellikle son katmanlardan birisi belirlenerek derin özelliklerin çıkarımı sağlanmaktadır.

DarkNet53 CNN Modeli

Bu çalışmada özellik çıkarımı için Darknet53 ön eğitilmiş CNN modelinin 'conv52', 'res23', 'avg1' ve 'conv53' katmanları özellik çıkarıcı katmanlar olarak kullanılmıştır. Önerilen yöntemde kullanılacak olan katmanlara ait detaylı bilgi Tablo 1 ile sunulmuştur.

Tablo 1. Özellik Çıkarıcı Katmanlara Ait Bilgiler

Katman Sırası	Adı	Açıklama	Özellik Sayısı
177	conv52	Konvolüsyon Katmanı	65536
180	res23	Ekleme Katmanı	65536
181	avg1	Ortalamaya Ortaklama Katmanı	1024
182	conv53	Konvolüsyon Katmanı	1000

Özellik Seçme Yöntemleri

Bir model oluşturmak için özellik seçme algoritmaları kullanılarak veri setinden en iyi alt kümenin seçimidir (Budak, 2018). Özellik seçiminin avantajları;

- Özellik kümesinin boyutunu küçültmek ve kullanılan algoritmanın performansını artırmak,
- Gürültüyü veriyi ortadan kaldırır ve veri kalitesini geliştirir,
- Veri depolamak için gerekli olan hafızayı azaltır ve kaynak tasarrufu sağlar,
- Modelin performansını iyileştirir.

Özellik Seçme Yöntemlerini 3 gruba ayrılabilir (Hakverdi, 2019);

- Filtre Yöntemleri
- Sarma Yöntemleri
- Gömülü Yöntemler

Özellik seçme için Filtre yöntemleri olarak; Fisher Skor, t-Skor, Welch t-İstatistiği, Ki-Kare testi, One-R, ve Relief gibi yöntemler kullanılmaktadır. Bu çalışmada, kullanım esnekliği, nispeten hızlı ve genel kabul görmüş yöntem olan Relief ve Ki-Kare testi kullanılmıştır.

Relief Algoritması

Bu yöntem Kira ve Rendell tarafından önerilmiştir (Wikipedia, 2013). Özellikleri aralarındaki ilişkiye göre ağırlıklandırılan bir özellik seçme yöntemidir. Relief methodu, veri setinden bir örneğin kendi sınıfındaki diğer örneklerle yakınlığı ve farklı sınıflara uzaklığına bağlı olarak işlemi gerçekleştirir.

Relief Algoritması Adımları:

Adım 1. Bir örneğin kendi sınıfına ait en yakın örnekteki ilgili özellik değeri ve farklı sınıfa sahip en yakın örnekteki ilgili özellik değerinin belirlenmesi (Budak, 2018),

Adım 2. İlgili özelliğin ağırlığının hesaplanması (Budak, 2018), formül n kere tekrarlanarak hesaplanmaktadır.

$$W_i = W_{i-1} - (x_i - nearHit_i)^2 + (x_i - nearMiss_i)^2 \quad (1)$$

x_i = i. örneği temsil etmektedir,

n = örnek sayısını,

W_i = i özelliğinin ağırlığını (önem derecesi),

$nearHit_i$ = aynı sınıfa sahip en yakın örnekteki ilgili özellik değerini göstermektedir.

$nearMiss_i$ = farklı sınıfa sahip en yakın örnekteki ilgili özellik değerini göstermektedir.

Adım 3. Özelliklerin ağırlıklarına göre sıralanması ve belirli bir eşik değeri veren üstteki k adet özelliğin seçilmesi (Budak, 2018).

Ki-Kare Testi

Bu yöntem Liu ve Setiono tarafından önerilmiştir (Liu ve Setiono, 1997). İki değişken arasındaki ilişkinin bağımlı mı bağımsız mı olduğunu belirlemeye yarayan yöntemdir. Yöntemi ikiye ayırırsak, ilk kısımda özelliklerin sınıflara göre Ki-Karesi hesaplanır daha sonraki kısımda ise serbestlik derecesi ve belirlenen önemlilik seviyesine göre Ki-kaynaşımı prensibi ile Ki-Kare değerlerine bakılarak veri seti içerisindeki tutarsız özelliklerin bulunana kadar özelliklerin ayrıştırılmasıdır (Sahin, 2017).

Denklem şu şekildedir:

$$X^2 = \sum_{i=1}^2 \sum_{j=1}^k \frac{(A_{ij} - E_{ij})^2}{E_{ij}} \quad (2)$$

$$E_{ij} = \frac{R_i * C_j}{N} \quad (3)$$

k = Sınıf Sayısı

A_{ij} = Gözlenen Değer

E_{ij} = Beklenen Değer

R_i = Aralık (i. satırdaki)


C_j = Sınıf (j. sütündeki)

N = Ana kütle Hacmi

SVM Algoritması

Regresyon ve sınıflandırma problemlerinde kullanılabilen SVM algoritması 1992 yılında Vapnik ve arkadaşları tarafından önerilmiştir (Boser vd., 1992). Bu çalışmada sınıflandırma işlemi gerçekleştirmek üzere SVM

kullanılmıştır. Uygulaması kolay esnek bir algoritma olan SVM, yapısal risk minimizasyonu ve istatistiksel öğrenme teorisine dayanmaktadır. Bir düzlemde bulunan iki grup arasına bir sınır çizgisi çekilerek iki grup ayrılabilir. Bu sınır çizgisinin bulunacağı konum iki grubun üyelerine en uzak olan konumda olmalıdır. Algoritma, bu sınırın nasıl çizileceği konusunda görev almaktadır. Overfitting (ezberleme) sorununun bulunmaması ve yüksek doğruluk oranları gibi avantajlarının olmasıyla birlikte, olasılıksal tahminler yürütememe ve çekirdek fonksiyonlarının pozitif tanımlı sürekli fonksiyonlar olma zorunluluğu dezavantajları vardır (Tas, 2016). SVM için örnek gösterim Şekil 1 ile sunulduğu gibidir. Burada iki farklı sınıfı ayıran bir vektör çizimi gösterilmektedir. Bu vektör öyle bir noktadan çizilebilmeli ki sınıfları ayırma gücü kuvvetli olabilsin. Hiper düzlem (hyperline) bu vektörün SVM'deki karşılığıdır.



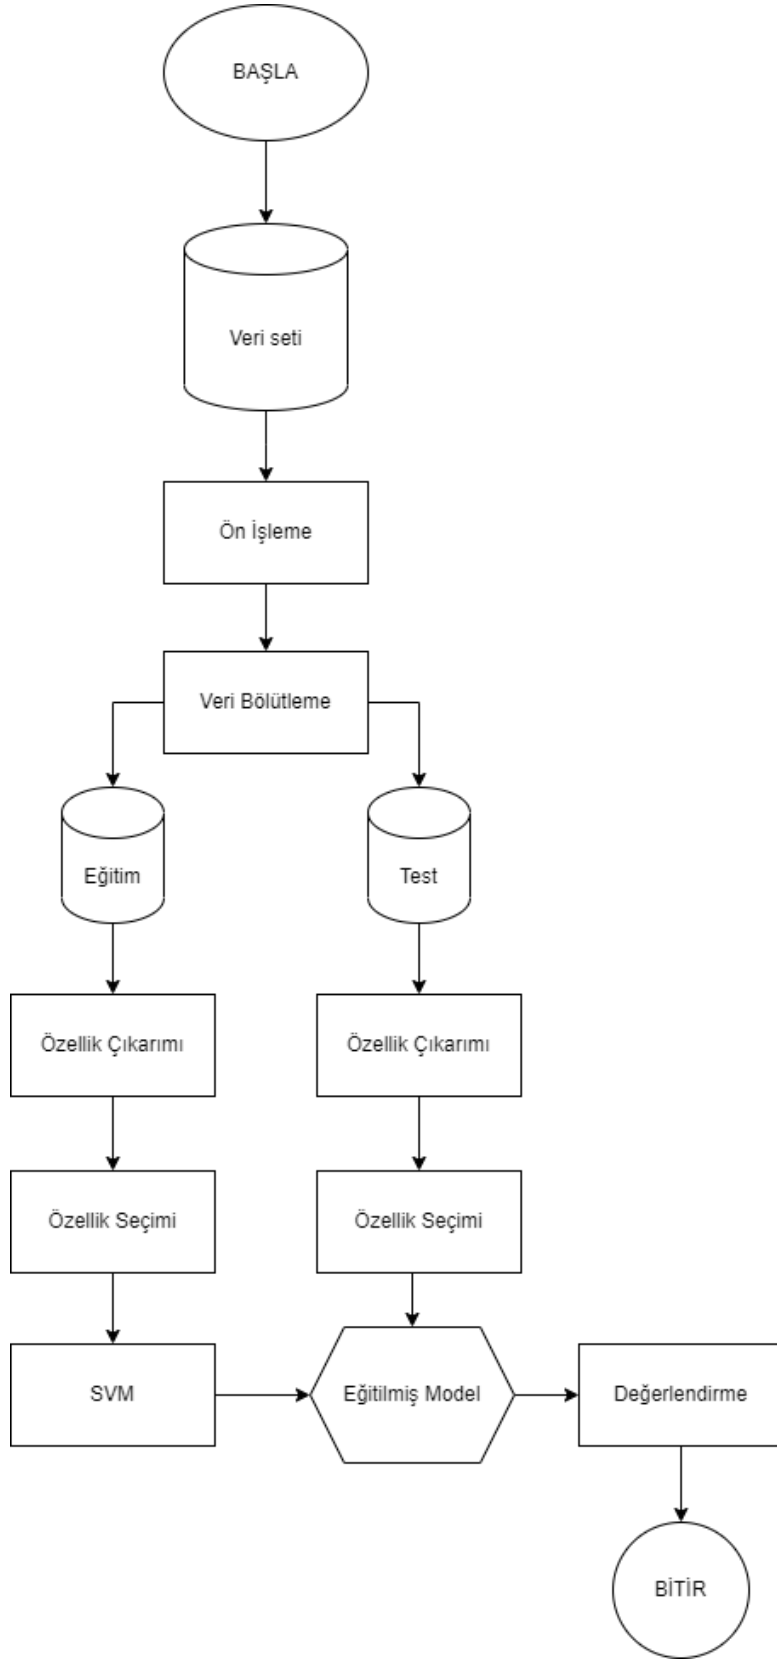
Şekil 1. SVM Gösterimi

Önerilen Yöntem

Bu çalışmada beyin MR görüntülerinden tümör tespiti yapan bir sınıflandırma sistemi önerilmiştir. Bu yöntem özellik çıkarma, özellik seçme ve sınıflandırma temel fazlarından oluşmaktadır. Önerilen yöntem Şekil 2 ile sunulmuştur.

Bu yöntemde izlenen adımlar şu şekildedir:

- Adım 1. Sisteme öncelikle simülasyon aşamalarında kullanılacak olan veri seti yükle.
- Adım 2. Özellik çıkarımında kullanılacak olan ön eğitilmiş CNN modeline göre imgelere ön işleme adımları uygula.
 - Adım 2.1. İmge boyutu 1 mi? 1 ise 3 boyutlu hale getir.
 - Adım 2.2. İmgenin genişliğini ve yüksekliğini 256 X 256 olarak yeniden ölçeklendir.
- Adım 3. Veri setini %70 Eğitim %30 Test verisi olacak şekilde bölütle.
- Adım 4. Ön eğitilmiş CNN ile eğitim verisinden özellik çıkar.
 - Adım 4.1. darknet53 ön eğitilmiş CNN modelini yükle.
 - Adım 4.2. Özellik çıkarıcı katmanı belirle.
 - Adım 4.3. Eğitim verisi, darknet53 modeli ve özellik çıkarıcı katmanı kullanarak derin özellikleri çıkar.
- Adım 5. Özellik seçimi gerçekleştir.
 - Adım 5.1. Adım 4'te çıkarılan özellikleri ve etiketleri özellik seçici algoritmaya girdi olarak ver.
 - Adım 5.2. Özelliklerin sınıflandırmayı etkilediği ağırlık skorları ve özellik önem sırasını değişkenlere ata.
 - Adım 5.3. Özellik boyutu kaç özelliğe indirilecekse önem sırasına göre ilk o kadar özelliği ayıkla.
- Adım 6. Seçilmiş özellikleri ve etiketleri SVM algoritmasına gönder ve eğitimi gerçekleştir.
- Adım 7. Ön eğitilmiş CNN ile test verisinden özellik çıkar.
 - Adım 7.1. Test verisi, darknet53 modeli ve özellik çıkarıcı katmanı kullanarak derin özellikleri çıkar.
- Adım 8. Özellik seçimi gerçekleştir.
 - Adım 8.1. Özellik boyutu kaç özelliğe indirilecekse önem sırasına göre ilk o kadar özelliği ayıkla.
- Adım 9. Değerlendirme
 - Adım 9.1. Adım 6 ile elde edilen eğitilmiş model ile Adım 8 ile elde edilen test verisi seçilmiş özellikleri predict komutuna girdi olarak gönderilir.
 - Adım 9.2. Sistemin test verisi üzerindeki başarımı sonuç olarak döndürülür.



Şekil 2. Önerilen Yöntem


Bu çalışmada simülasyonlarda kullanılmak üzere 4'ü özellik seçici barındırmayan, 2'si barındıran toplamda 6 yöntem türetilmiştir. Bu yöntemler M1'den M6'ya kadar isimlendirilmiştir. Yöntemlere ait bilgiler Tablo 2 ile gösterildiği gibidir.

Tablo 2. Önerilen Yöntemler


Model Adı	Özellik Çıkarıcı	Özellik Seçici
M1	conv52	Yok
M2	res23	Yok
M3	avg1	Yok
M4	conv53	Yok
M5	res23	Relief
M6	res23	Ki-Kare Test

Kullanılan Veri Seti

Bu çalışmada önerilen yöntemin simülasyonlarında kullanılmak üzere public bir veri seti olan "Brain MRI Images for Brain Tumor Detection" veri seti (Chakrabarty, 2018) kullanılmıştır. Bu veri seti toplamda iki sınıftan oluşmaktadır. Bunlar tümörün varlığını belirten yes sınıfı, tümör olmadığını belirten no sınıfıdır. Veri setinde; yes sınıfına ait 155 örnek, no sınıfına ait 98 örnek olmak üzere toplamda 253 örnek imge bulunmaktadır. Veri setine ait örnek imgeler Şekil 3-4 ile sunulmuştur. Şekil 3 tümör olan beyin MR görüntüsünü içerirken Şekil 4 tümör olmayan beyin MR görüntüsünü içermektedir.



Şekil 3. Tümör Olan Beyin MR Görüntüsü



Şekil 4. Tümör Olmayan Beyin MR Görüntüsü

DENEYSEL SONUÇLAR

Deneysel çalışmalar her bir önerilen yöntem için ayrı ayrı uygulanmış olup elde edilen deneysel sonuçlar şu şekildedir:

M1 Yöntemi İle Elde Edilen Sonuçlar

M1 yöntemi ile eğitim ve test verilerinden 65536 tane özellik çıkarımı gerçekleştirilmiştir. Özellik seçicinin kullanılmadığı bu yöntem eğitim verileri ile eğitilmiş ve test verisi üzerinde doğruluk kriterinin performans metriği olacağı şekilde değerlendirilmiştir. Çalışma 30 defa koşurulmuştur. 30 koşmaya ait doğruluk oranları Tablo 3 ile sunulmuştur. Bu koşmalar içerisinde en başarılı doğruluk oranı yüzde cinsinden %93,33 olarak elde edilmiştir. En başarılı sonuca ait karmaşıklık matrisi Şekil 5 ile gösterilmiştir. Şekle göre gerçekte 26 tane no sınıfına ait örnek no (%89,7), 3 tane no sınıfına ait örnek yes olarak tahmin edilirken (%10,3); gerçekte 44 tane yes sınıfı yes (%95,7), 2 tane yes sınıfına ait örnek no olarak tahmin edilmiştir (%4,3). Ayrıca tüm koşmalara ait ortalama doğruluk değeri 0,9169'dur. 30 koşma için geçen toplam süre 3,7572 saniyedir.

Tablo 3. M1 Yöntemi İçin Elde Edilen Doğruluk Oranları

Koşma	Doğruluk Oranı	Koşma	Doğruluk Oranı	Koşma	Doğruluk Oranı
1	0,9333	11	0,9333	21	0,9067
2	0,9200	12	0,9333	22	0,9200
3	0,9067	13	0,9200	23	0,9200
4	0,9333	14	0,9067	24	0,9200
5	0,9200	15	0,9200	25	0,9333
6	0,8800	16	0,9067	26	0,9067
7	0,9200	17	0,9200	27	0,9200
8	0,9200	18	0,9200	28	0,9200
9	0,9067	19	0,9200	29	0,8933
10	0,9200	20	0,9200	30	0,9067




Şekil 5. M1 İçin En İyi Koşmaya Ait Karmaşıklık Matrisi

M2 Yöntemi İle Elde Edilen Sonuçlar

M2 yöntemi ile eğitim ve test verilerinden 65536 tane özellik çıkarımı gerçekleştirilmiştir. Özellik seçicinin kullanılmadığı bu yöntem eğitim verileri ile eğitilmiş ve test verisi üzerinde doğruluk kriterinin performans metriği olacağı şekilde değerlendirilmiştir. Çalışma 30 defa koşturulmuştur. 30 koşmaya ait doğruluk oranları Tablo 4 ile sunulmuştur. Bu koşmalar içerisinde en başarılı doğruluk oranı yüzde cinsinden %97,33 olarak elde edilmiştir. En başarılı sonuca ait karmaşıklık matrisi Şekil 6 ile gösterilmiştir. Şekle göre gerçekte 28 tane no sınıfına ait örnek no (%96,6), 1 tane no sınıfına ait örnek yes olarak tahmin edilirken (%3,4); gerçekte 45 tane yes sınıfı yes (%97,8), 1 tane yes sınıfına ait örnek no olarak tahmin edilmiştir (%2,2). Ayrıca tüm koşmalara ait ortalama doğruluk değeri 0,9267'dir. 30 koşma için geçen toplam süre 3,2163 saniyedir.

Tablo 4. M2 Yöntemi İçin Elde Edilen Doğruluk Oranları

Koşma	Doğruluk Oranı	Koşma	Doğruluk Oranı	Koşma	Doğruluk Oranı
1	0,9467	11	0,9200	21	0,8800
2	0,9200	12	0,9200	22	0,9067
3	0,9200	13	0,9067	23	0,9200
4	0,9600	14	0,9733	24	0,9067
5	0,9200	15	0,9067	25	0,9067
6	0,9067	16	0,9733	26	0,9200
7	0,9200	17	0,9333	27	0,9467
8	0,9067	18	0,9333	28	0,9067
9	0,9467	19	0,9467	29	0,9333
10	0,9200	20	0,9200	30	0,9733



Şekil 6. M2 İçin En İyi Koşmaya Ait Karmaşıklık Matrisi

M3 Yöntemi İle Elde Edilen Sonuçlar

M3 yöntemi ile eğitim ve test verilerinden 1024 tane özellik çıkarımı gerçekleştirilmiştir. Özellik seçicinin kullanılmadığı bu yöntem eğitim verileri ile eğitilmiş ve test verisi üzerinde doğruluk kriterinin performans metriği olacağı şekilde değerlendirilmiştir. Çalışma 30 defa koşturulmuştur. 30 koşmaya ait doğruluk oranları Tablo 5 ile sunulmuştur. Bu koşmalar içerisinde en başarılı doğruluk oranı yüzde cinsinden %93,33 olarak elde edilmiştir. En başarılı sonuca ait karmaşıklık matrisi Şekil 7 ile gösterilmiştir. Şekle göre gerçekte 28 tane no sınıfına ait örnek no (%96,6), 1 tane no sınıfına ait örnek yes olarak tahmin edilirken (%3,4); gerçekte 42 tane yes sınıfı yes (%91,3), 4 tane yes sınıfına ait örnek no olarak tahmin edilmiştir (%8,7). Ayrıca tüm koşmalara ait ortalama doğruluk değeri 0,8871'dir. 30 koşma için geçen toplam süre 1,8258 saniyedir.

Tablo 5. M3 Yöntemi İçin Elde Edilen Doğruluk Oranları

Koşma	Doğruluk Oranı	Koşma	Doğruluk Oranı	Koşma	Doğruluk Oranı
1	0,8933	11	0,8933	21	0,9067
2	0,8800	12	0,8667	22	0,8933
3	0,8800	13	0,9067	23	0,8933
4	0,8933	14	0,8533	24	0,8667
5	0,8800	15	0,8667	25	0,8800
6	0,8533	16	0,8667	26	0,8667
7	0,9067	17	0,8933	27	0,8667
8	0,8800	18	0,8800	28	0,9200
9	0,9067	19	0,9200	29	0,8667
10	0,9333	20	0,8933	30	0,9067




Şekil 7. M3 İçin En İyi Koşmaya Ait Karmaşıklık Matrisi

M4 Yöntemi İle Elde Edilen Sonuçlar

M4 yöntemi ile eğitim ve test verilerinden 1000 tane özellik çıkarımı gerçekleştirilmiştir. Özellik seçicinin kullanılmadığı bu yöntem eğitim verileri ile eğitilmiş ve test verisi üzerinde doğruluk kriterinin performans metriği olacağı şekilde değerlendirilmiştir. Çalışma 30 defa koşturulmuştur. 30 koşmaya ait doğruluk oranları Tablo 6 ile sunulmuştur. Bu koşmalar içerisinde en başarılı doğruluk oranı yüzde cinsinden %89,33 olarak elde edilmiştir. En başarılı sonuca ait karmaşıklık matrisi Şekil 8 ile gösterilmiştir. Şekle göre gerçekte 27 tane no sınıfına ait örnek no (%93,1), 2 tane no sınıfına ait örnek yes olarak tahmin edilirken (%6,9); gerçekte 40 tane yes sınıfı yes (%87,0), 6 tane yes sınıfına ait örnek no olarak tahmin edilmiştir (%13,0). Ayrıca tüm koşmalara ait ortalama doğruluk değeri 0,8351'dir. 30 koşma için geçen toplam süre 1,4582 saniyedir.

Tablo 6. M4 Yöntemi İçin Elde Edilen Doğruluk Oranları

Koşma	Doğruluk Oranı	Koşma	Doğruluk Oranı	Koşma	Doğruluk Oranı
1	0,8267	11	0,8267	21	0,8133
2	0,8533	12	0,8933	22	0,8400
3	0,8000	13	0,8133	23	0,8800
4	0,8533	14	0,8400	24	0,8667
5	0,8267	15	0,8133	25	0,7867
6	0,7333	16	0,8000	26	0,8667
7	0,8667	17	0,8267	27	0,8400
8	0,8667	18	0,8267	28	0,8133
9	0,8533	19	0,8400	29	0,8267
10	0,8667	20	0,8400	30	0,8533



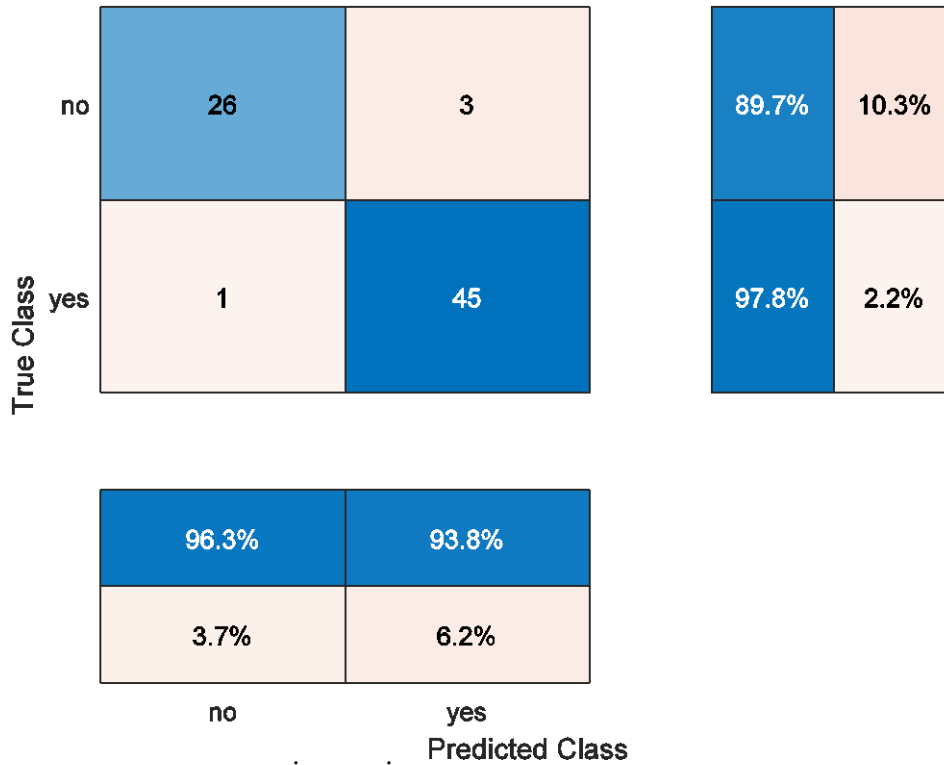
Şekil 8. M4 İçin En İyi Koşmaya Ait Karmaşıklık Matrisi

M5 Yöntemi İle Elde Edilen Sonuçlar

M1, M2, M3, M4 yöntemlerinden en başarılı sonuç res23 katmanının özellik çıkarıcı olarak kullanıldığı M2 yöntemidir. Bu nedenle özellik seçici olarak Relief algoritmasının kullanıldığı M5 yönteminde özellik çıkarıcı olarak res23 katmanı kullanılmıştır. Res23 katmanı ile bir görüntüden 65536 tane özellik çıkarılırken özellik seçiminde 6500 özellik tercih edilmiştir. Çalışma 30 defa koşturulmuştur. 30 koşmaya ait doğruluk oranları Tablo 7 ile sunulmuştur. Bu koşmalar içerisinde en başarılı doğruluk oranı yüzde cinsinden %94,67 olarak elde edilmiştir. En başarılı sonuca ait karmaşıklık matrisi Şekil 9 ile gösterilmiştir. Şekle göre gerçekte 26 tane no sınıfına ait örnek no (%89,7), 3 tane no sınıfına ait örnek yes olarak tahmin edilirken (%10,3); gerçekte 45 tane yes sınıfı yes (%97,8), 1 tane yes sınıfına ait örnek no olarak tahmin edilmiştir (%2,2). Ayrıca tüm koşmalara ait ortalama doğruluk değeri 0,9227'dir. 30 koşma için geçen toplam süre 1,0203 saniyedir.

Tablo 7. M5 Yöntemi İçin Elde Edilen Doğruluk Oranları

Koşma	Doğruluk Oranı	Koşma	Doğruluk Oranı	Koşma	Doğruluk Oranı
1	0,8933	11	0,9200	21	0,9067
2	0,9200	12	0,9333	22	0,9200
3	0,9200	13	0,8933	23	0,9333
4	0,9067	14	0,9333	24	0,9200
5	0,9200	15	0,9333	25	0,9200
6	0,9333	16	0,9067	26	0,9200
7	0,9467	17	0,9200	27	0,9200
8	0,9333	18	0,9333	28	0,9467
9	0,9333	19	0,9200	29	0,9333
10	0,9200	20	0,9200	30	0,9200




Şekil 9. M5 İçin En İyi Koşmaya Ait Karmaşıklık Matrisi

M6 Yöntemi İle Elde Edilen Sonuçlar

Özellik seçici olarak Ki-Kare Test yönteminin kullanıldığı M6 yönteminde özellik çıkarıcı olarak res23 katmanı kullanılmıştır. Res23 katmanı ile bir görüntüden 65536 tane özellik çıkarılırken özellik seçiminde 6500 özellik tercih edilmiştir. Çalışma 30 defa koşturulmuştur. 30 koşmaya ait doğruluk oranları Tablo 8 ile sunulmuştur. Bu koşmalar içerisinde en başarılı doğruluk oranı yüzde cinsinden %96,00 olarak elde edilmiştir. En başarılı sonuca ait karmaşıklık matrisi Şekil 10 ile gösterilmiştir. Şekle göre gerçekte 28 tane no sınıfına ait örnek no (%96,6), 1 tane no sınıfına ait örnek yes olarak tahmin edilirken (%3,4); gerçekte 44 tane yes sınıfı yes (%95,7), 2 tane yes sınıfına ait örnek no olarak tahmin edilmiştir (%4,3). Ayrıca tüm koşmalara ait ortalama doğruluk değeri 0,9328'dir. 30 koşma için geçen toplam süre 0,9453 saniyedir.

Tablo 8. M6 Yöntemi İçin Elde Edilen Doğruluk Oranları

Koşma	Doğruluk Oranı	Koşma	Doğruluk Oranı	Koşma	Doğruluk Oranı
1	0,9200	11	0,9467	21	0,9600
2	0,9333	12	0,9600	22	0,9600
3	0,9067	13	0,9200	23	0,9200
4	0,9600	14	0,9067	24	0,9200
5	0,9200	15	0,9600	25	0,9600
6	0,9200	16	0,9200	26	0,9200
7	0,9467	17	0,9333	27	0,9333
8	0,9200	18	0,9067	28	0,9467
9	0,9333	19	0,9067	29	0,9467
10	0,9333	20	0,9067	30	0,9600



Şekil 10. M6 İçin En İyi Koşmaya Ait Karmaşıklık Matrisi

Tüm simülasyon sonuçlarını değerlendirmek için Tablo 9 hazırlanmıştır. Bu tabloya göre tüm koşmalar içerisinde en iyi başarı oranı %97,33 ile M2 yönteminden elde edilmiştir. Daha kabul edilir bir başarı kriteri olan ortalama doğruluk oranı değerine göre ise %93,28 ile M6 yöntemi en başarılı sonucu vermiştir. Yöntemlerin performansını karşılaştırmak için kullanılabilir bir diğer metrik; zamansal karmaşıklığıdır. Her bir yöntem için 30'ar koşma süresince saniye cinsinden geçen zaman, yöntemlerin zamansal karmaşıklığını vermektedir. Bu kapsamda en iyi zamansal karmaşıklık değeri 0,9453 sn ile M6 yönteminden elde edilmiştir.

Önerilen modellerin literatürde yer alan diğer çalışmalarla karşılaştırılması Tablo 10 ile sunulduğu gibidir. Veri bölütleme tipi farklı olsa da önerilen yöntemin literatürde yer alan diğer çalışmalar kadar başarılı olduğu görülmektedir.

Tablo 9. Önerilen Yöntemlerin Performans Değerlendirmesi

Yöntem	Özellik Çıkarıcı	Özellik Seçici	En İyi Başarı (%)	Ortalama Başarı (%)	Zamansal Karmaşıklık (sn)
M1	conv52	Yok	93,33	91,69	3,7572
M2	res23	Yok	97,33	92,67	3,2163
M3	avg1	Yok	93,33	88,71	1,8258
M4	conv53	Yok	89,33	83,51	1,4582
M5	res23	Relief	94,67	92,27	1,0203
M6	res23	Ki-Kare Test	96	93,28	0,9453

Tablo 10. Önerilen Yöntemlerin Diğer Çalışmalarla Karşılaştırılması

Çalışma	Algoritma	Veri Bölütleme	Sınıflandırma Başarısı
Amin ve ekibi, 2018	7 layered 2D CNN	Bilinmiyor	%95,1
Mohsen ve ekibi, 2017	SMO + SVM	7-kat çaprazlama %80 eğitim - %10	%93,9
Siddique ve ekibi, 2020	DCNN (VGG16) DarkNet53 + Ki-Kare	validasyon - %10 test	%96,0
Önerilen Model (M6)	Test + SVM	%70 eğitim- %30 test	%96,0

DEĞERLENDİRME

Bu çalışmada beyin MR görüntüleri kullanılarak tümör tespiti üzerine yöntemler geliştirilmiş ve uygulanmıştır. Geliştirilen yöntem 3 ana fazdan oluşmaktadır. Birinci fazda DarkNet53 ön eğitilmiş CNN modeli kullanılarak özellik çıkarımı gerçekleştirilmektedir. DarkNet53 modelinin 'conv52', 'res23', 'avg1' ve 'conv53' katmanları özellik çıkarıcı katmanlar olarak kullanılmıştır. İkinci fazda özellik seçimi işlemi yapılmıştır. Relief ve Ki-Kare Test Algoritmaları özellik seçiminde tercih edilmiştir. Son fazda ise sıklıkla kullanılan popüler bir sınıflandırma yöntemi olan SVM algoritması kullanılmıştır. Özellik çıkarıcı katman ve özellik seçme yöntemlerinin ikili kombinasyonuna göre 6 farklı model (M1, M2, M3, M4, M5, M6) önerilmiştir.

Önerilen yöntemlerin eğitimi için kamuya açık "Brain MRI Images for Brain Tumor Detection" veriseti kullanılmıştır. **yes** ve **no** sınıflarına sahip görüntülerden oluşan bu veri seti %70 eğitim %30 test olacak şekilde ayrılmıştır. Doğruluk oranı ve zamansal karmaşıklık, performans metriği olarak kullanılmıştır. Her bir yöntem 30 defa koşturulmuştur.

Deneysel sonuçlara göre koşmalar içerisinde en iyi başarı oranı (%97,33) M2 ile edilirken, ortalama başarı oranlarına bakıldığında en iyi ortalama başarı oranı (%93,28) 'res23' katmanının özellik çıkarıcı, Ki-Kare Test algoritmasının özellik seçici olarak kullanıldığı M6 ile elde edilmiştir. Zamansal karmaşıklıklar incelendiğinde M6 modeli ile en hızlı (0,9453 sn) yöntem elde edilmiştir.

Gelecek çalışmalarda beyin tümör tespiti için farklı veri setleri kullanılacaktır. Ayrıca mevcut yöntemler farklı özellik çıkarıcı ve seçici yöntemlerle geliştirilecek ve performans analizi yapılacaktır. Buna ilaveten, önerilen yöntemde kullanılan hiperparametreler seçme algoritmaları ile optimize edilerek performans artırımı yapılacak sonuçlar karşılaştırılacaktır.

KAYNAKLAR

- Amin, J., Sharif, M., Yasmin, M., & Fernandes, S.L. (2018). Big data analysis for brain tumor detection: Deep convolutional neural networks. *Future Generation Computer Systems*, 87,290–297. <https://doi.org/10.1016/j.future.2018.04.065>.
- Boser, B.E., Guyon, I.M., & Vapnik, V.N. (1992). A training algorithm for optimal margin classifiers. *Proceedings of the fifth annual workshop on Computational learning theory*, 144–152. <https://doi.org/10.1145/130385.130401>.
- Budak, H. (2018). Özellik seçim yöntemleri ve yeni bir yaklaşım. *Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 22:21–31. DOI: 10.19113/sdufbed.01653.
- Febrianto, D., Soesanti, I., & Nugroho, H. (2020). Convolutional neural network for brain tumor detection. *IOP Conference Series: Materials Science and Engineering*, volume 771, 012031, IOP Publishing. <https://doi.org/10.1088/1757-899X/771/1/012031>.
- Fırat HAKVERDİ, (2019), Veri Önleme. <https://prezi.com/p/vk31emxjhl4y/veri-on-isleme/>, online; accessed 14 December 2022.
- Krizhevsky, A., Sutskever, I., & Hinton, G.E. (2017). Imagenet classification with deep convolutional neural networks. *Communications of the ACM*, 60(6):84–90. <https://doi.org/10.1145/3065386>.
- Ozcan, T., & Basturk, A. (2021). Performance improvement of pre-trained convolutional neural networks for action recognition. *The Computer Journal*, 64(11), 1715-1730. <https://doi.org/10.1093/comjnl/bxaa029>
- Liu, H., & Setiono, R. (1997). Feature selection via discretization. *IEEE Transactions on knowledge and Data Engineering*, 9(4), 642-645. <https://doi.org/10.1109/69.617056>.
- Mathworks, (2019). Feature Extraction, <https://www.mathworks.com/discovery/feature-extraction.html>, online; accessed 17 December 2022.
- Mohsen, H., El-Dahshan, E., El-Horbaty, E., & Salem, A. (2017). Brain tumor type classification based on support vector machine in magnetic resonance images. *Annals Of "Dunarea De Jos" University Of Galati, Mathematics, Physics, Theoretical mechanics, Fascicle II, Year IX (XL), 1*.
- Mohsen, H., El-Dahshan, E.S.A., El-Horbaty, E.S.M., & Salem, A.B.M. (2018). Classification using deep learning neural networks for brain tumors. *Future Computing and Informatics Journal*, 3(1):68–71. <https://doi.org/10.1016/j.fcij.2017.12.001>.
- NAVONEEL CHAKRABARTY, (2018). Brain MRI Images for Brain Tumor Detection, <https://www.kaggle.com/datasets/navoneel/brain-mri-images-for-brain-tumor-detection?resource=download>, online; accessed 14 December 2022.
- Oğuzhan Taş, (2016). Destek Vektör Makineleri, <https://www.slideshare.net/oguzhantas/destek-vekr-makineleri-support-vector-machine>, online; accessed 15 December 2022.
- Pranitha, K., Vurukonda, N., & Nayak, R.K. (2022). A Comprehensive Survey on MRI Images Classification for Brain Tumor Identification using Deep Learning Techniques. *2022 3rd International Conference on Smart Electronics and Communication (ICOSEC)*, 1206–1212, IEEE. <https://doi.org/10.1109/ICOSEC54921.2022.9951913>.
- Rai, H.M. & Chatterjee, K. (2021). 2D MRI image analysis and brain tumor detection using deep learning CNN model LeU-Net. *Multimedia Tools and Applications*, 80(28):36111–36141. <https://doi.org/10.1007/s11042-021-11504-9>.
- Russakovsky, O., Deng, J., Su, H., Krause, J., Satheesh, S., Ma, S., Huang, Z., Karpathy, A., Khosla, A., Bernstein, M., et al. (2015). Imagenet large scale visual recognition challenge. *International journal of computer vision*, 115(3):211–252. <https://doi.org/10.1007/s11263-015-0816-y>.
- Sachdeva, J., Kumar, V., Gupta, I., Khandelwal, N., & Ahuja, C.K. (2011). Multiclass brain tumor classification using GA-SVM. *2011 Developments in E-systems Engineering*, 182–187, IEEE. <https://doi.org/10.1109/DeSE.2011.31>.
- Sahin, E. (2017). Özellik seçimi algoritmaları kullanılarak heyelanda etkili faktörlerin belirlenmesi ve heyelan duyarlılık haritalarının üretilmesi. *İstanbul Teknik Üniversitesi Geomatik Mühendisliği Anabilim Dalı, Doktora Tezi, Doktora Tezi*, İstanbul.

- Seetha, J. & Raja, S.S. (2018). Brain tumor classification using convolutional neural networks. *Biomedical & Pharmacology Journal*, 11(3):1457-1461. <https://dx.doi.org/10.13005/bpj/1511>.
- Siddique, M.A.B., Sakib, S., Khan, M.M.R., Tanzeem, A.K., Chowdhury, M., & Yasmin, N. (2020). Deep convolutional neural networks model-based brain tumor detection in brain MRI images. *2020 Fourth International Conference on I-SMAC (IoT in Social, Mobile, Analytics and Cloud)(I-SMAC)*, 909–914, IEEE. <https://doi.org/10.1109/I-SMAC49090.2020.9243461>.
- Tiwari, A., Srivastava, S., & Pant, M. (2020). Brain tumor segmentation and classification from magnetic resonance images: Review of selected methods from 2014 to 2019. *Pattern Recognition Letters*, 131:244–260. <https://doi.org/10.1016/j.patrec.2019.11.020>.
- Wikipedia, (2013). Relief (feature selection), [https://en.wikipedia.org/wiki/Relief_\(feature_selection\)](https://en.wikipedia.org/wiki/Relief_(feature_selection)), online; accessed 14 December 2022.
- Xu, Y., Jia, Z., Ai, Y., Zhang, F., Lai, M., Eric, I., & Chang, C. (2015). Deep convolutional activation features for large scale brain tumor histopathology image classification and segmentation. *2015 IEEE international conference on acoustics, speech and signal processing (ICASSP)*, 947–951, IEEE. <https://doi.org/10.1109/ICASSP.2015.7178109>.
- Zacharaki, E.I., Wang, S., Chawla, S., Soo Yoo, D., Wolf, R., Melhem, E.R., & Davatzikos, C. (2009). Classification of brain tumor type and grade using MRI texture and shape in a machine learning scheme. *Magnetic Resonance in Medicine: An Official Journal of the International Society for Magnetic Resonance in Medicine*, 62(6):1609–1618. <https://doi.org/10.1002/mrm.22147>.