



Tumor detection in MR images of regional convolutional neural networks

Ali Ari^{*} , Davut Hanbay^{*} 

Department of Computer Engineering, Inonu University, 44280, Malatya, Turkey

Highlights:

- Determining tumor markers
- Biomedical image processing based on deep learning
- Brain tumor detection by regional based convolutional neural networks

Keywords:

- MR imaging
- Brain tumor detection
- Deep learning
- Regional based convolutional neural networks

Article Info:

Research Article
Received: 20.02.2018
Accepted: 09.06.2018

DOI:

10.17341/gazimmfd.460535

Graphical/Tabular Abstract

In this study, an automated tumor detection system based on regional convolutional neural network from MR images was developed. At first MR images were preprocessed. After than tumors location and size were labelled manually. Labelled images were applied to the input of the designed different types of RCNN architecture. RCNN1 and RCNN3 compose of seven layer and have different size of filters. RCNN2 compose of eight layer and RCNN4 compose of nine layer. Benchmark, Rembrandt and Harvard data sets were used in this study. Tumor detectors which have the textural and shape features of the tumor were obtained by the RCNNs. These tumor detectors were tested with the data sets. The best performance was obtained by RCNN4 architecture with Benchmark data set is 99.10%. The best average performance was obtained with RCNN4 is 98.66%. These results show that designed RCNNs are successful. Principle of the proposed method is shown in Figure A.

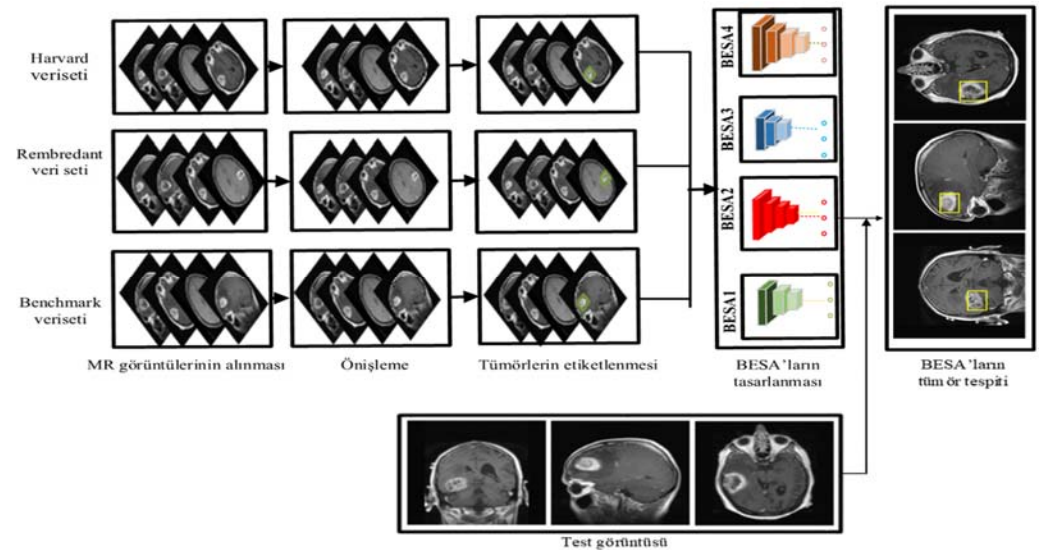


Figure A. Principle of the proposed method.

Correspondence:

Author: Ali Ari
e-mail: ali.ari@inonu.edu.tr
phone: +90 506 367 13 29

Purpose: An automated computer aided tumor detection system for assisting the physicians to detect the tumor in MRI images was proposed.

Theory and Methods:

Suggested brain tumor detection system compose of five steps. These steps are loading images, preprocessing, labelling tumor in MRI images manually, designing RCNNs, obtaining tumor detector and testing. RCNN can be explained as a CNN with the input images and interested area.

Results:

Designed RCNNs were tested with the 3 data set. Obtained results show that the best average performance was obtained with RCNN4 is 98.66%. RCNN4 can be used for to assist physicians to detect tumor in MR images.

Conclusion:

Evaluated results showed that designed RCNN2 and RCNN4 architecture are superior than RCNN1 and RCNN3. Its reasons are RCNN2 and RCNN4 have more layer than RCNN1 and RCNN3. RCNN2 and RCNN4 filters size are bigger than the others. The model performance is relatet with the types of loss function. These results proof that designed RCNNs are robust and superior than the existing studies in the literature.



Bölgesel evrışimsel sinir ağıları tabanlı MR görüntülerinde tümör tespiti

Ali Arı*^{ID}, Davut Hanbay^{ID}

İnönü Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, Malatya, 44280, Türkiye

Ö N E Ç I K A N L A R

- Mikro tümör belirleyicilerinin elde edilmesi
- Derin öğrenme tabanlı biomedikal görüntü işleme
- Bölgesel tabanlı evrışimsel sinir ağıları ile beyin tümörü tespiti

Makale Bilgileri

Araştırma Makalesi

Geliş: 20.02.2019

Kabul: 09.06.2018

DOI:

10.17341/gazimmfd.460535

Anahtar Kelimeler:

MR görüntüleme,
beyin tümör tespiti,
derin öğrenme,
bölgesel tabanlı evrışimsel
sinir ağıları

ÖZET

Beyin tümörlerinden kaynaklı insan ölümleri günümüzde artmaktadır. Beyin tümörü çok hızlı büyüyerek, normal boyutunun iki katına çıkabilir. Bu yüzden uzmanlar, Manyetik Rezonans (MR) görüntülerini inceleme sürecini dikkatli ve hızlı bir şekilde yapmalıdır. Erken teşhis, kanser tanısında, tedavi planlamasında ve tedavi sonucunun değerlendirilmesinde hayati öneme sahiptir. Eğer beyin tümörü olan bir hasta doğru ve erken tedavi görmemişse, hastanın hayatta kalma şansı düşebilir ve ölümle sonuçlanabilir. Bu makalede, beyin MR görüntülerinden tümörü kolayca tespit eden ve tümörün yerini belirten, uzmanlara yardımcı olabilecek bilgisayar destekli otomatik tümör tespit sistemi geliştirilmiştir. Geliştirilen sistem derin öğrenme mimarilerinden olan Bölgesel tabanlı Evrışimsel Sinir Ağları (BESA) tabanlıdır. BESA, Evrışimsel Sinir Ağları (ESA) mimarisini kullanan bir yapı olmakla birlikte giriş görüntüsüne ek olarak ilgilenilen bölgenin de giriş olarak verildiği bir yapı olarak düşünülebilir. Farklı BESA mimarileri tasarlanarak Benchmark, Rembrandt ve Harvard veri setleri üzerinde test edilmiştir. Elde edilen en yüksek doğruluk değeri %99,10 ile BESA4 mimarisi ve Benchmark veri setinden elde edilmiştir. En yüksek ortalama doğruluk ise yine BESA4 mimarisi ile %98,66 olarak hesaplanmıştır. Ayrıca, önerilen yöntemin başarımı, literatürdeki bazı yöntemler ile kıyaslanmıştır. Kıyaslamalar da önerilen yöntemin daha başarılı olduğu görülmüştür.

Tumor detection in MR images of regional convolutional neural networks

H I G H L I G H T S

- Determining tumor markers
- Biomedical image processing based on deep learning
- Brain tumor detection by regional based convolutional neural networks

Article Info

Research Article

Received: 20.02.2019

Accepted: 09.06.2018

DOI:

10.17341/gazimmfd.460535

Keywords:

MR imaging,
brain tumor detection,
deep learning,
regional based convolutional
neural networks


ABSTRACT

Human deaths caused by brain tumors are increasing nowadays. The brain tumor can grow very fast and can get twice of it is usual size. Therefore, physician have to analysis the Magnetic Resonance (MR) images quickly. This step is vital for the diagnosis of cancer, for treatment planning and for evaluation of the treatment outcome. If the patient who has the tumor in his brain is not treated correctly and quickly, the patient's chance of survival may decrease and resulted in death. In this article, we were developed a computer-assisted automated tumor detection system that can assist the physician in detecting and locating the tumor easily from brain MR images. The developed system is based on Regional based Convolutional Neural Networks (RCNN), which is one of the deep learning architectures. Besides RCNN is a structure that uses the architecture of the Convolutional Neural Networks (CNN), it can be considered as a structure in which the interested region is given as input in addition to the input images. In the proposed method, different RCNN architectures were designed and tested on Benchmark, Rembrandt and Harvard datasets. The highest accuracy was obtained from the RCNN4 architecture on Benchmark data set is 99.10%. The highest average accuracy was calculated as 98.66% with RCNN4 architecture. Also, the success of the proposed method was compared with some of the methods exist in the literature. These comparisons showed that the proposed method is more successful and effective.

*Sorumlu Yazar/Corresponding Author: ali.ari@inonu.edu.tr, davut.hanbay@inonu.edu.tr / Tel: +90 422 521 6743

1. GİRİŞ (INTRODUCTION)

Organizmalarda, hücrelerin vücudun kontrol mekanizmalarının etkisinden kurtularak anormal bir şekilde çoğalması ile oluşan kitlelere tümör denir [1]. Beyin, insan vücudunun hareketlerini kontrol eden duyum ve bilinç merkezidir. Kafatası içinde oluşabilecek tümörler büyüyerek beyine baskı yapabilir ve vücut sağlığına olumsuz etki edebilir. Yan etkisi olmayan ve uzmanların çok kısa süre içerisinde makinalar aracılığıyla yüksek kalitede görüntüler elde ederek hastalıkların teşhisinde avantaj sağlayan görüntüleme yöntemine Manyetik Rezonans Görüntüleme (MRG) adı verilir [2]. MRG, beyin tümörlerinin saptanması ve analizi için yaygın olarak kullanılan bir görüntüleme yöntemidir. Beynin üç farklı düzlemde görüntülenmesi, tümör hakkında şekilsel, dokusal ve hacimsel olarak pek çok bilgi vermektedir. Aksiyal düzlemde beyin üstten görünüşü, koronal düzlemde yandan görünüşü, sagittal düzlemde ise arkadan görünüşü belirlenmektedir. İlgili düzlemlere ait MR görüntüleri Şekil 1’de verilmiştir.




Şekil 1. Düzlemlere ait beyin MR görüntüleri a) aksiyal düzlem b) koronal düzlem c) sagittal düzlem
(Brain MR images of planes (a) axial plane (b) coronal plane (c) sagittal plane)

Tümör birçok biyolojik dokudan oluştuğu için sadece tek bir sekansla çekim yapılan beyin MR görüntüleri tümör dokuları hakkında tüm bilgileri veremeyebilir [3, 4]. Bu nedenle bir MRG’de aynı bölgeye ait üç farklı sekansta görüntüleme yapılır [3, 4]. Bunlar T1 ağırlıklı, T2 ağırlıklı ve proton ağırlıklı görüntülerdir. Aksiyal düzleme ait üç farklı sekans görüntüsü Şekil 2’de sunulmuştur [5, 6]. T1 ağırlıklı sekanslar çok iyi yumuşak doku kontrastı ve uzaysal çözünürlük sağlayarak anatomik değerlendirme için olanak sağlar. T2 ağırlıklı sekanslarda ise patolojik sinyal değişiklikleri ayırt edilir. Az sayıda kullanım alanı olan proton ağırlıklı görüntüler standart incelemelerden kaldırılmıştır. Su; T1 ağırlıklı görüntülerde siyah, T2 ağırlıklı görüntülerde beyaz, proton ağırlıklı görüntülerde ise gri tonlarda görülür [5, 6].

MR görüntülerinden beyin tümörlerinin tespiti uzmanlar için zaman alıcıdır ve hata eğilimi gösterebilmektedir. Hekimlerin teşhis yeteneklerini arttırmak ve doğru teşhis için harcanan sürelerini azaltmak, bilgisayar destekli otomatik tespit ve teşhis sistemleri ile mümkün olmaktadır. Bu sistemlerin amacı, uzmanların hızlı ve doğru karar

verebilmelerine destek olmaktır [7]. Beyin tümörünün erken teşhisi için ihtiyaç duyulan hız ve yüksek doğruluk oranı bu çalışmanın motivasyonudur. Tıbbi görüntülerden tümörün otomatik olarak tespit edilmesi, yeni nesil bilgisayar destekli tanı teknolojilerinin kritik bir bileşenidir ve son yıllarda önem arz eden bir alan olarak ortaya çıkmaktadır [8].



Şekil 2. Her bir sekansa ait MR görüntüleri a) T1 ağırlıklı b) T2 ağırlıklı c) Proton ağırlıklı
(MR Images of each sekans (a) T1 weighted (b) T2 weighted (c) proton weighted)

İftekharuddin vd. [9] tarafından 2009 yılında yapılan çalışmada, tümör olabilecek yapılara ait öznelilikler, Parçalı Üçgen Prizma Alanı metodu ile çıkartılmıştır. Tümör ve tümör olmayan bölgeleri sınıflandırma işlemi için İleri Beslemeli Çok Katmanlı Sinir Ağı tabanlı Bayes sınıflandırıcısı kullanılmıştır. 0,7’lik bir eşik değer kullanıldığında, sistem başarımı farklı hastalar için %90 ile %100 arasında değiştiği ve ortalama başarımının %90 olduğu belirtilmiştir. Mustaqem vd. [10] tarafından 2012 yılında yapılan çalışmada, beyin MR görüntülerinden tümör tespiti morfolojik işlemler ile yapılmıştır.

Kumar Kole vd. [11] tarafından 2012 yılında yapılan çalışmada, nöron aksonlarının oluşturduğu beyaz madde, nöron hücrelerinin karar verme yetisine sahip beyin üst kısmında yer alan gri madde ve omurilik sıvısı gibi beyin dokularının bölütlenmesinde bulanık mantık kullanılmıştır. Meena vd. [12] tarafından yapılan 2013 yılında çalışmada Pozitron Emisyon Tomografisi (PET) görüntülerinden tümör tespiti Uzamsal Bulanık C Ortalamalar yöntemi ile yapılmıştır. Uzamsal Bulanık C Ortalamalar yönteminin performansı Bulanık C ortalamalar ve K-Means kümeleme algoritması ile karşılaştırılmıştır, Uzamsal Bulanık C Ortalamalar yönteminin performansı, diğer iki algoritmaya kıyasla tatmin edici sonuçlar verdiğini belirtmişlerdir.

Nabizadeh vd. [13] tarafından 2014 yılında yapılan çalışmada, Histogram Temelli Yer Çekimsel Optimizasyon algoritması ile tümör tespiti gerçekleştirilmiştir. Ischemic atak inme lezyonları ve tümör lezyonları sırasıyla %91,50 ve %88,10 doğruluk ile bölütlenmiştir. Yaqup vd. [14] tarafından 2014 yılında yapılan çalışmada, MR görüntülerinin tümörlü ve tümörsüz olarak sınıflandırılmasında farklı yapılarda Rastgele Orman sınıflandırıcısı kullanılmıştır. Bu yapılardan Ağırlıklı Hızlı Yerel Rasgele Ormanlar ile %90, Ağırlıklı Lokal Rastgele Ormanlar ile %87 ve Yerel Rasgele Ormanlar ile %88 başarımler elde etmişlerdir.

Eman vd. [15] tarafından 2015 yılında yapılan çalışmada MR görüntülerinden tümör tespitinde, K-Ortalama Kümeleme ve Bulanık C-Ortalama Kümeleme tekniklerinin performansı üç farklı veri setinde karşılaştırılmıştır. K- Ortalama Kümeleme tekniği ile ortalama %92,27 doğruluk başarımları, Bulanık C-Ortalama Kümeleme tekniği ile %96,66 doğruluk elde etmişlerdir.

Nabizadeh vd. [16] tarafından 2015 yılında yapılan çalışmada MR görüntülerinde tümör olabilecek ilgi alanlarına ait öznelik çıkarımında Gabor dalgacık dönüşüm özellikleri ve istatistiksel özellikler kullanılarak farklı sınıflandırıcıların başarımları kıyaslaması yapılmıştır.

Mousavi vd. [17] tarafından 2015 yılında yapılan çalışmada, MR beyin görüntülerinden tümör tespit için ROI metodu kullanılmıştır. Sunulan metod morfolojik işlemler, alçak geçiren filtreleme ve eşikleme gibi farklı görüntü işleme tekniklerinden oluşmaktadır. On farklı veri setinden ortalama %98,48 başarımları ile tümör bölütleme işlemi gerçekleştirilmiştir.

Ahmadvand vd. [18] tarafından 2016 yılında yapılan çalışmada dalgacık dönüşüm özellikleri kullanılmıştır. Tümörlü ve tümörsüz MR görüntülerinin sınıflandırılması için Rassal Orman sınıflandırıcısı kullanılmıştır. Sınıflandırma başarımları ortalama %90 olarak belirtilmiştir.

Sudharani vd. [19] tarafından 2016 yılında yapılan çalışmada T2 ağırlıklı MR görüntülerinden tümör tespiti için önerilen metodlar; eşikleme, Hızlı Fourier Dönüşümü ve ileri seviye morfolojik işlemlerden oluşmaktadır. Tümör tespit başarımları %89,20 olarak belirtilmiştir. Kadam vd. [20] tarafından 2017 yılında yapılan çalışmada tümör olabilecek yapılar için öznelikler Gri Seviye Eşleşim Matrisi (GSEM) ile elde edilmiştir. Çekirdek Destek Vektör Makinaları (ÇDVM) sınıflandırıcısı ile tümör olan ve tümör olmayan yapılar sınıflandırılmıştır. Sınıflandırma başarımlarının %97,50 olduğunu belirtmişlerdir.

Amin vd. [1] tarafından 2017 yılında yapılan çalışmada tümörlü ve tümörsüz MR görüntülerini otomatik olarak ayırt edilebilen bir metod sunulmaktadır. Tümör olabilecek her doku için şekil, yapı ve yoğunluk özellikleri hesaplanmıştır. Farklı geçerlilik testleri belirlenmiş ve sınıflandırıcı olarak Destek Vektör Makinesi (DVM) kullanılmıştır. Sistem başarımlarında %97,10 doğruluk, %91,90 duyarlılık ve %98 özgüllük başarımları elde etmişlerdir. Abbasi vd. [21] tarafından 2017 yılında yapılan çalışmada üç boyutlu görüntülerden beyin tümörü tespiti otomatik olarak yapılmıştır. Histogram eşitleme yöntemi ile görüntüler önışlemeden geçirilmiştir. Tümör olabilecek yapılar arka plandan çıkarılmıştır. Üç farklı düzleme ait MR görüntülerinden Yerel İkili Örüntü (YİÖ) operatörü ile öznelikler çıkarılmıştır. Kullanılan HG veri setinde Dice Benzerlik indeksi 0,93, Jaccard Benzerlik indeksi ise 0,87'dir. Kullanılan diğer LG veri setinde Dice Benzerlik indeksi 0,90, Jaccard Benzerlik indeksi ise 0,82'dir. Bu

çalışma kapsamında BESA tabanlı beyin MR görüntülerinden otomatik tümör tespit sistemi geliştirilmiştir. İlk olarak MR görüntüleri ön işleme tabii tutulmuştur. Daha sonra tümörler, görüntü üzerinde manuel olarak etiketlenerek tümörlerin konumları ve büyüklükleri belirlenmiştir. Etiketlenen görüntüler 32 X 32 boyutunda yeniden boyutlandırılarak farklı BESA mimarilerinin girişine uygulanmıştır. Tasarlanan BESA1 ve BESA3 mimarisi yedi katmandan ve farklı filtre boyutlarından, BESA2 mimarisi sekiz katmandan ve BESA4 mimarisi ise dokuz katmandan oluşmaktadır. Veri seti olarak Benchmark, Rembrandt ve Harvard veri setleri kullanılmıştır. BESA'lar yardımı ile tümörlerin doku ve şekil bilgilerini tutan tümör detektörleri elde edilmiştir. Elde edilen tümör detektörleri veri setleri kullanılarak test edilmiş ve en yüksek doğruluk değeri %99,10 ile BESA4 mimarisi ile Benchmark veri setinden elde edilmiştir. En yüksek ortalama doğruluk ise yine BESA4 mimarisi ile %98,66 olarak hesaplanmıştır. Elde edilen sonuçlar tasarlanan BESA mimarilerinin başarılı olduğunu göstermektedir.

Çalışmanın ikinci bölümünde BESA'nın temelini oluşturan ESA anlatılmıştır. Üçüncü bölümde önerilen yöntem açıklanmıştır. Dördüncü bölümde veri setleri açıklanarak, deneysel sonuçlar görsel ve sayısal olarak sunulmuştur. Son bölümde ise sonuçlar verilmiştir.

2. EVRİŞİMSSEL SİNİR AĞLARI (CONVOLUTIONAL NEURAL NETWORKS)

Makine öğrenmesi, bir sistemin belirli bir problem üzerinde karar vermesini sağlayan yöntemlerin geliştirildiği bilgisayar bilim alanıdır. Yapay Sinir Ağları (YSA), insan beyninin bilgi işleme şeklinden esinlenerek geliştirilmiş bir tekniktir ve problemleri, matematiksel ortamda yapay olarak çözebilmektedir [22]. Derin öğrenme, büyük miktarlarda etiketlenmiş eğitim verilerinden özellik saptama yapabilen sistemler oluşturmak için çok seviyeli "derin" sinir ağlarını kullanılmasıdır. Derin öğrenme, makine öğrenmesi yaklaşımı olup son yıllarda bilgisayar bilimcilerin çalışmalarını yoğunlaştırdığı popüler bir çalışma alanı olmuştur. Derin öğrenme yöntemlerinden biri olan ESA mimarileri, görüntü sınıflama, nesne tanıma ve tespit yöntemi olarak literatürde sıklıkla kullanılmaktadır [23]. Kullanılan bu yöntemler yüksek sınıflama doğruluk oranlarıyla dikkat çekmektedir [24, 25]. ESA, yapay sinir ağlarından esinlenerek oluşturulmuş ve toplanmış bilgileri uçtan uca öğrenebilen bir mimaridir. ESA, yeterli kapasitesi ve akıllı model yapısı sayesinde büyük ölçekli verilerin de üstesinden gelebilmektedir. ESA'nın dezavantajları ise eğitim sürecinin uzun olması ve eğitim sürecinde yerel bir çözüme takılma ihtimalidir.

2.1. ESA'nın Yapısı (Structure of Convolutional Neural Network)

ESA, yapay sinir ağlarının ileriye dönük işlem yapan ve sinir ağlarından farklı olarak özellik çıkarıcı bir katmanın bulunduğu derin öğrenme yaklaşımıdır [25]. ESA'da iki

temel katman bulunmaktadır. Bunlardan biri evrişim diğeri ise havuzlama katmanıdır. ESA'lar bu iki katmanda temel bazı işlemler ile görüntünün önemli olan özelliklerini çıkarmayı amaçlamaktadır [25]. Böylelikle yapay sinir ağına, görüntünün gereksiz kısımlarının gitmesi engellenmekle beraber bu durum sistemin hız ve doğruluk oranını arttırmaktadır [26-28]. ESA'nın geliştirilmesi ile birlikte performansı arttırmak için aktivasyon fonksiyonları ve bırakma katmanları da eklenmiştir. ESA'nın son katmanında ise görev türüne göre kayıp katmanlar da yer alabilmektedir. ESA'nın genel yapısı Şekil 3'de gösterilmiştir.

2.1.1. Evrişim katmanı (Convolution layer)

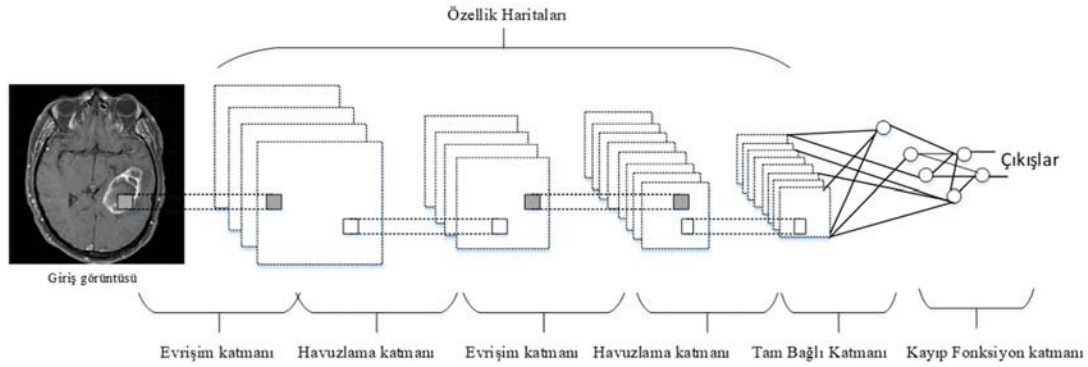
Evrişim işlemi, başlangıçta rastgele değerlere sahip görüntü filtresinin giriş görüntüsü ile evrişim edilmesi işlemidir. Evrişim katmanı geleneksel YSA'da bulunmayan ESA'nın temel yapı taşıdır. Tüm katmanlarda yer alan hücrelerin birbirleri ile bağlantılı olması ve bağlantı ağırlıklarının yenilenmesi yerine küçük bölgelerde evrişim işlemi kullanılmaktadır. ESA'nın en büyük avantajlarından biri evrişim katmanlarında paylaşılan ağırlıklardır. Bu da aynı özellik haritasında aynı filtreleri uygulamak demektir.

Ağırlık paylaşımı, gerekli olan bilgisayar belleğini azaltmaya ve bilgisayarlı görme görevlerindeki ESA performansını arttırmaya yardımcı olmaktadır [29]. Şekil 4'de parametrelerin azaltılmasıyla ilgili ağırlık paylaşımını gösterilmektedir. Görüntü üzerine uygulanacak evrişim işlemi $n \times n$ boyutundaki filtre W ile gösterilmektedir. Evrişim işlem sonucu X , her resimdeki $l-1$ katmanındaki Y piksel değerinin, filtre katsayıları ve sonuçları evrensel toplam şeklinde Eş. 1'de gösterilmiştir [26].

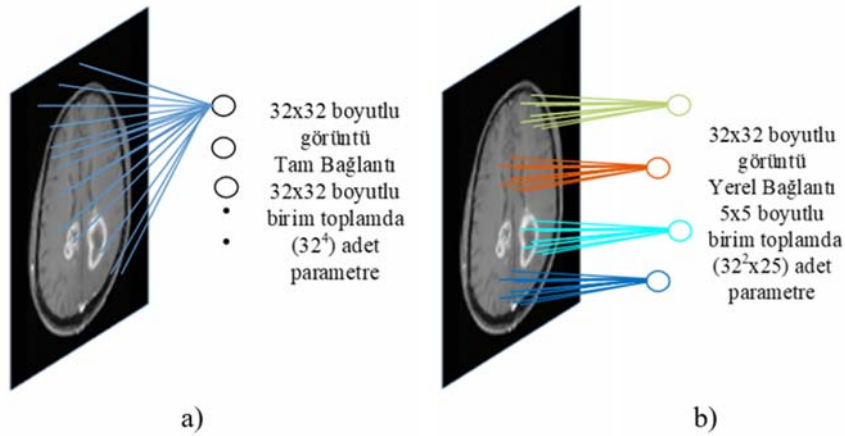
$$x_{i,j}^l = \sum_a \sum_b^n w_{ab} y_{(i+a)(j+b)}^{l-1} \quad (1)$$

Eş. 1'de kullanılan 'w' filtre katsayıları başlangıçta rastgele seçilir ve ağırlık eğitimi sırasında giriş-çıkış ilişkisine göre ayarlanır. Böylece filtre katsayıları eldeki problemi modelleyen katsayılar olarak ifade edilir.

Şekil 5'de, 5×5 boyutundaki girdi verisi üzerinde 3×3 boyutundaki evrişim filtresi gezdirilerek evrişim operatörünün uygulanışı ve çıkış görüntüsünün piksel değerleri gösterilmiştir.

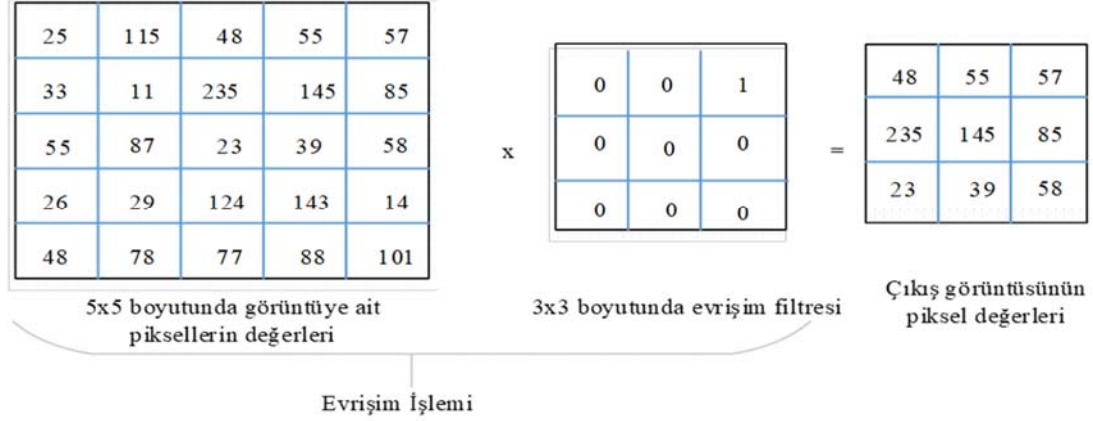


Şekil 3. ESA'nın blok şeması (Block diagram of CNN)



Şekil 4. Ağırlığı paylaşılan evrişim katmanları ile tam bağlı katmanın karşılaştırılması a) Tam bağlı katman parametre sayısı b) Ağırlığı paylaşılan evrişim katmanı parametre sayısı


(Comparison of fully connected layer and weighted sharing convolution layer (a) The number of fully connected layer parameters (b) the number of weighted sharing convolution layer parameters.)



Şekil 5. Evrişim operatörünün uygulandığı (Implementation of convolution operator)

2.1.2. Havuzlama katmanı (Pooling layer)

ESA'nın havuzlama katmanında kullanılan filtreler ya ortalama değer ya da maksimum değer hesaplama prensibine göre çalışır. Havuzlama işlemi genellikle $2 \times 2, 3 \times 3, \dots, n \times n$ boyutunda filtreler uygulanarak yapılır. Ortalama havuzlama, filtre boyutunun alanına giren piksel değerlerin toplamının filtre pencere boyutuna bölünmesi prensibiyle çalışır. Maksimum havuzlama ise filtre boyutunun alanına giren piksel değerlerinden büyük olan değer belirlenmesi işlemidir. İki temel havuzlama katmanı farklı BESA mimarilerinde kullanılarak mimarilerin başarımları incelenmiştir. Maksimum havuzlama katmanı daha etkili olduğu görülmüştür. Havuzlama katmanlarına ait işlemlerin uygulanması Şekil 6'da gösterilmiştir.



Şekil 6. Ortalama ve havuzlama işlemi örneği (The sample of averaging and pooling operation)

Evrişim işleminden sonraki resme havuzlama işlemi uygulanarak özellik vektöründe boyut indirgenmiş olur. Filtre boyutu F ve adım sayısı S olsun ve veri girdi boyutu $X \times Y \times Z$ olarak kabul edilsin. $\hat{X} \times \hat{Y} \times \hat{Z}$ boyutlu bir çıkış özellik haritası üretmek için Eş. 2 kullanılmaktadır [28].

$$\hat{X} = \frac{X - F + S}{S}, \hat{Y} = \frac{Y - F + S}{S}, Z = \hat{Z} \quad (2)$$

2.1.3. Aktivasyon fonksiyonu (Activation function)

ESA'da en önemli işlemlerden birisi de aktivasyon fonksiyonunun uygulanmasıdır. Aktivasyon fonksiyonları,

giriş yığınının yüksek düzeyde anlaşılmasını sağlayan ağlardaki doğrusalsızlıkları arttırmaktadır. Ayrıca aktivasyon fonksiyonu, aşırı veri değerleri olmadan bir sonraki katmandaki nöronların bağımsızlığını arttıran bir özellik haritası çıkarmaktadır ve bu sayede tüm ağın istikrarı arttırılmaktadır. Aktivasyon işlemi için kullanılan Sigmoid fonksiyonu, piksel değerlerini 0 ile 1 aralığına bastırmaktadır. Özellikle büyük negatif değerler 0, büyük pozitif değerler ise 1 olma eğilimindedirler. Hiperbolik Tanjant fonksiyonu, Sigmoid fonksiyonuna benzer şekilde piksel değerlerini $[-1, 1]$ sayı aralığındaki bir reel değere bastırmaktadır. Bu fonksiyonunda da doymuş aktivasyon problemi mevcuttur. Tanjant fonksiyonu, Sigmoid fonksiyonundan daha başarılı olmasına rağmen, uygulamada hala iyi performans göstermemektedir. Doğrultulmuş Doğru Birim fonksiyonu $\max(0, x)$ şeklinde tanımlanmaktadır. Bu aktivasyon son zamanlarda ESA mimarisinde en çok kullanılan aktivasyon fonksiyonudur [26-31].

2.1.4. Çıktı katmanı (Output layer)

Çıktı, büyük sinir ağının genel hatasını azaltan aşırı öğrenme problemini çözmek için sunulan güçlü bir algoritmadır [29]. Bir bırakma algoritmasında tek bir nöron diğer nöronların oluşumlarına güvenmeyeceği için nöronların uyum karmaşıklıklarını azaltır. Böylece bırakma, daha sağlam özellikleri ve istikrarlı yapıyı öğrenebilmek için ESA'yı geliştirmiştir [27-33]. Bu durumda bırakma terimi bir sinir ağındaki birimlerin bazılarının bir sonraki katmana dahil etmeme anlamına gelmektedir

2.1.5. Kayıp fonksiyonu (Loss function)

ESA'lardaki farklı görevler için farklı kayıp fonksiyonları seçilmektedir.

2.1.6. Öklid fonksiyonu (Oklid function):

Öklid kaybı, gerçek değerli regresyon görevleri için kullanılmaktadır. Tek bir reel sayı olduğu için Öklid kaybı ile ESA'nın son katmanı 1×1 boyutlu olmaktadır. Öklid

kaybının matematiksel fonksiyonu Eş. 3'te verilmiştir [28, 30].

$$L = \frac{1}{2N} \sum_{i=1}^N \left\| \hat{d}_i - d_i \right\|^2 \quad (3)$$

\hat{d}_i ; indirgenmiş çıkışları, d_i ; hedef çıkışları ve N ise çıkış sayısını göstermektedir.

2.1.7. Softmax fonksiyonu (Softmax function):

Softmax kaybı, karşılıklı olarak k kadar sınıfı tahmin etmek için kullanılır ve $1 \times k$ boyutlu olasılık vektörünü çıkarır. Vektöre ait tüm olasılıkların toplamı bire eşit olmaktadır [28, 30].

$$L = - \sum_j y_j \log(p_j) \quad (4)$$

Burada y_j ; j 'nci sınıfa ait hedef $y_j = 1$ olduğunda kesin doğrudur. Aksi halde $y_j = 0$ 'dır. P_j , girdinin j 'nci sınıfına ait tahmin edilen olasılığını belirtir. Tahmin edilen olasılık vektörü çıkarıldığında, Softmax fonksiyonunun matematiksel fonksiyonu Eş. 5'de verilmiştir [28, 30].

$$p_j = \frac{e^{o_j}}{\sum_k e^{o_k}} \quad (5)$$

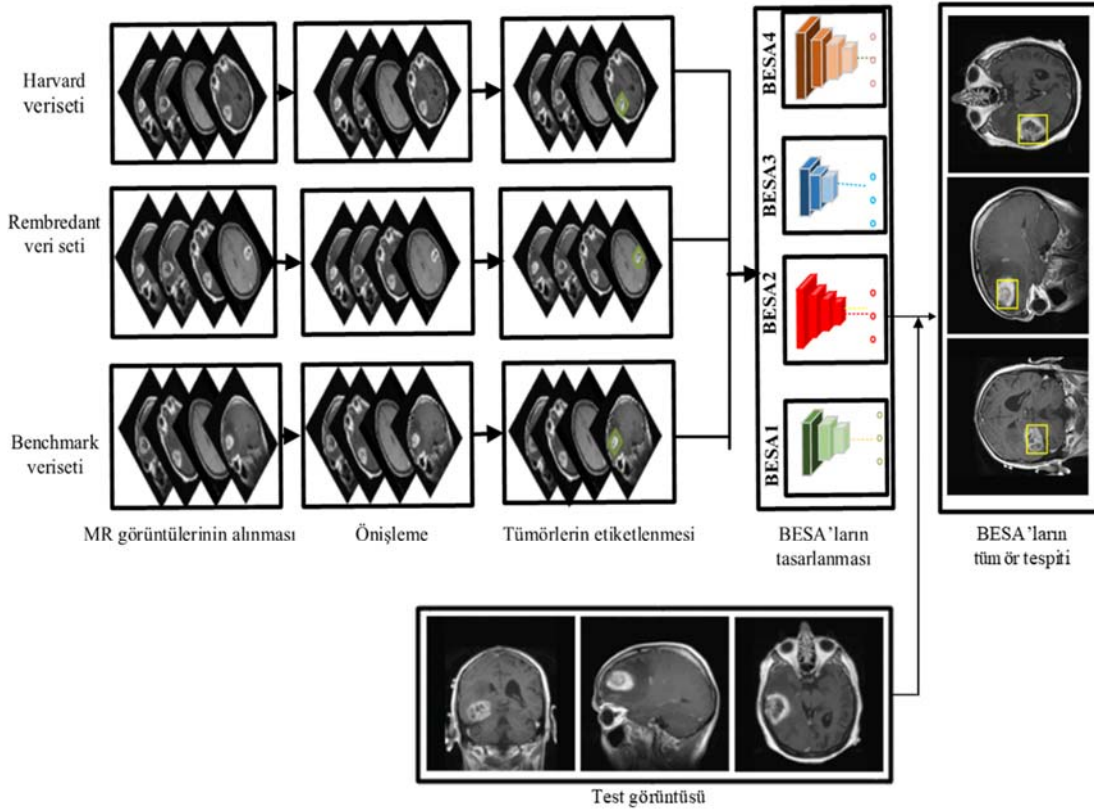
Eş. 5'deki o_j ; ESA'nın son katmanındaki j 'nci çıktıyı, e ; ise exponansiyel ifadeyi belirtmektedir.

3. ÖNERİLEN YÖNTEM (PROPOSED METHOD)

Önerilen beyin tümörü tespit yöntemi, beş ana adımdan oluşmaktadır. Adımlar; veri setinin yüklenmesi, ön işlem, MR görüntülerinden tümörlerin manuel olarak etiketlenmesi, BESA'nın tasarımı ile tümör detektörünün elde edilmesi ve elde edilen tümör detektörünün değerlendirilmesidir. Önerilen yöntemin üçüncü aşamasında, tümörlü bölgelerin etiketlenmesi aşamasından sonra elde edilen tümörlü alanlar BESA'ların girişine 32×32 boyutunda yeniden boyutlandırılarak verilmiştir. Sistemin testi için asıl görüntü üzerinde tarama işlemi seçici arama (selective search) yöntemi ile gerçekleştirilmiştir. Önerilen yöntemin çalışma prensibi Şekil 7'de gösterilmiştir.

3.1. Ön işleme (Preprocessing)

MRG esnasında MR görüntüleri çeşitli gürültü kaynaklarından etkilenebilir. Olabilecek gürültüler yanlış yoğunluk düzeylerine neden olur ve sistemin başarımını olumsuz etkiler. Gürültü etkisinin minimize edilmesi için histogram germe işlemi uygulanmıştır. Histogram germe işlemi, histogram eşitlemeye benzer bir işlevi yerine getirir.



Şekil 7. Önerilen yöntemin çalışma prensibi (Principle of the proposed method)

Histogram germe işleminde, histogram daha geniş bir alana yayılır [34].

Böylece renk seviyelerinin aralığı genişlediğinden MR görüntülerinin analizi daha iyi yapılabilir. Histogram germe işlemi Eş. 6'daki eşitliğe göre yapılır.

$$x_{yeni} = (A - B) \frac{x_{eski} - a}{b - a} + B \quad (6)$$

Eş. 6'da verilen a değişkeni, görüntü içerisindeki en küçük gri-ton değeri, b ise en büyük gri-ton değerini sırası ile göstermektedir. Histogram eğrisini $0 - 255$ gri-ton değerleri arasına germek için $A=255$ ve $B=0$ olarak seçilmelidir.

3.2. Eğitim seti verilerinin etiketlenmesi (Labelling of training dataset)

Bu bölümde, deneysel çalışmalarda kullanılan üç farklı veri setine ait toplam 252 adet MR görüntüsünde mevcut olan tümörlü bölgelerin manuel olarak işaretlenmesi gerçekleştirilmiştir.

3.3. BESA'nın Tasarımı (Design of RCNN)

Tasarlanan BESA'lara ait parametreler ve değerleri Tablo 1'de sunulmuştur.

3.4. Tümör detektörünün elde edilmesi (Obtaining tumor detector)

Eğitilmiş ESA, daha sonra bir tümör detektörü olarak kullanılmaktadır. Test görüntülerinde eğer bir bölgenin tümör olma ihtimali $0,8$ ' den büyük ise o bölge tümörlü bölge olarak işaretlenmekte, eğer değil ise de sağlıklı bölge olarak değerlendirilmektedir. Bu değer gerçekleştirilen deneysel çalışmalar sırasında deneme ve yanılma yoluyla elde edilmiştir.

3.5. Kullanılan başarımlar ölçütleri (Used performance criteria)

Önerilen yöntemin gerçek verilere benzerlikteki başarımlar kriterleri Eş. 7-11'deki doğruluk, duyarlılık, özgüllük, yanlış pozitif oranı ve yanlış negatif oranlarına dayalı olarak yapılmıştır [1]. Tümör piksellerinin doğru yeri (DP) ile ifade edilmiştir. Doğru Negatif (DN) tümör dışı pikselleri belirtmektedir. Yanlış Pozitif (YP), sağlıklı piksellerin tümör dokusu pikseli gibi algılanmasını temsil etmektedir. Tasarlanan sistem tarafından tespit edilmeyen tümör pikselleri Yanlış Negatif (YN) olarak gösterilmiştir [1].

$$\text{Doğruluk} = \frac{DP+DN}{DP+DN+YP+YN} \quad (7)$$

$$\text{Duyarlılık} = \frac{DP}{DP+YN} \quad (8)$$

$$\text{Özgüllük} = \frac{DN}{DN+YP} \quad (9)$$

$$\text{Yanlış pozitif oran} = 1 - \text{Özgüllük} \quad (10)$$

$$\text{Yanlış negatif oran} = 1 - \text{Duyarlılık} \quad (11)$$

4. UYGULAMALAR (APPLICATIONS)

4.1. Veri setleri (Data Sets)

Rembredant, Harvard ve Benchmark veri setleri kullanılarak tasarlanan sistemlerin performans değerlendirilmesi yapılmıştır. Kullanılan ilk veri seti BRATS 2015 arşivinde yer alan Benchmark veri setidir [35]. Benchmark veri seti; BRATS 2012, 2013 ve NIH Kanser Görüntüleme Arşivi (TCIA)'dan alınan verileri içermektedir. Her hastaya ait T1, T2, T1c (Kontrast ağırlığı artırılmış) ve Flair ağırlıklı beyin MR görüntüleri yer almaktadır. MR görüntüleri 1mm kalınlığında ve 256×256 piksel çözünürlüğündedir. Veri seri tümör çeşitleri ve hastalık seviyelerine göre kategorize edilmiştir. Aynı zamanda uzmanlar tarafından bölütlenmiş beyin MR görüntüleri de yer almaktadır [35]. Yapılan çalışmada Benchmark veri setinden 170 adet tümörlü beyin MR görüntüsü kullanılmıştır.

Kullanılan İkinci veri seti Rembredant veri seti [36]'dir. Rembrandt veri seti National Cancer Institute tarafından paylaşılan The Cancer Imaging Archive (TCIA) veri tabanına ait bir veri setidir. TCIA medikal görüntüler içeren erişilebilir geniş bir arşivdir. REMBRANDT veri setine ait tüm görüntüler 256×256 piksel çözünürlüğünde ve 16 bit gri seviyede dijital hale getirilmiştir. Her bir kesit 5 mm kalınlığındadır. Görüntüler DICOM ve JPG formatındadır [36]. Yapılan çalışmada Rembredant veri setinden 125 adet tümörlü beyin MR görüntüsü kullanılmıştır.

Kullanılan üçüncü veri seti ise Harvard veri setidir [37]. Harvard veri seti; T1, T2, Flair ağırlıklı olmak üzere 3 boyutlu MR görüntülerinin yer aldığı veri setidir. Arşivdeki görüntüler hastalık ve görüntüleme yöntemine göre organize edilmiştir. Veri setine ait tüm görüntüler 256×256 piksel çözünürlüğünde ve DICOM dosya formatındadır [37]. Yapılan çalışmada Harvard veri setinden 65 adet tümörlü beyin MR görüntüsü kullanılmıştır.

4.2. Deneysel çalışmalar (Experimental studies)

Programların koşturulduğu bilgisayar, 3,50GHz işlemci ve 8 GB bellek özelliklerine sahiptir. Program kodlamaları MATLAB 2016 ortamında yapılmıştır.

Benchmark veri setinden 119 adet tümörlü görüntü eğitim için 51 adet tümörlü görüntü ise test için kullanılmıştır. Şekil 8 ve Tablo 2'de Benchmark veri setine ait elde edilen sonuçlar sırası ile verilmiştir. Şekil 8'de görüleceği üzere tespit edilen beyin tümörleri sarı bir çerçeve ile gösterilmiştir. Gerçek tümör bölgesi ile tespit edilen tümör bölgesinin değerlendirilmesi ile elde edilen oranlar Tablo 2'de sunulmuştur. Sistemin testi için asıl görüntü üzerinde tarama işlemi seçici arama yöntemi ile gerçekleştirilmiştir. Üç farklı test MR görüntüsü ve bu görüntülere uygulanan 4 farklı BESA mimarisi sonuçları Şekil 8'in 1, 2 ve 3 numaralı satırlarında gösterilmiştir. Şekil 8 görsel olarak

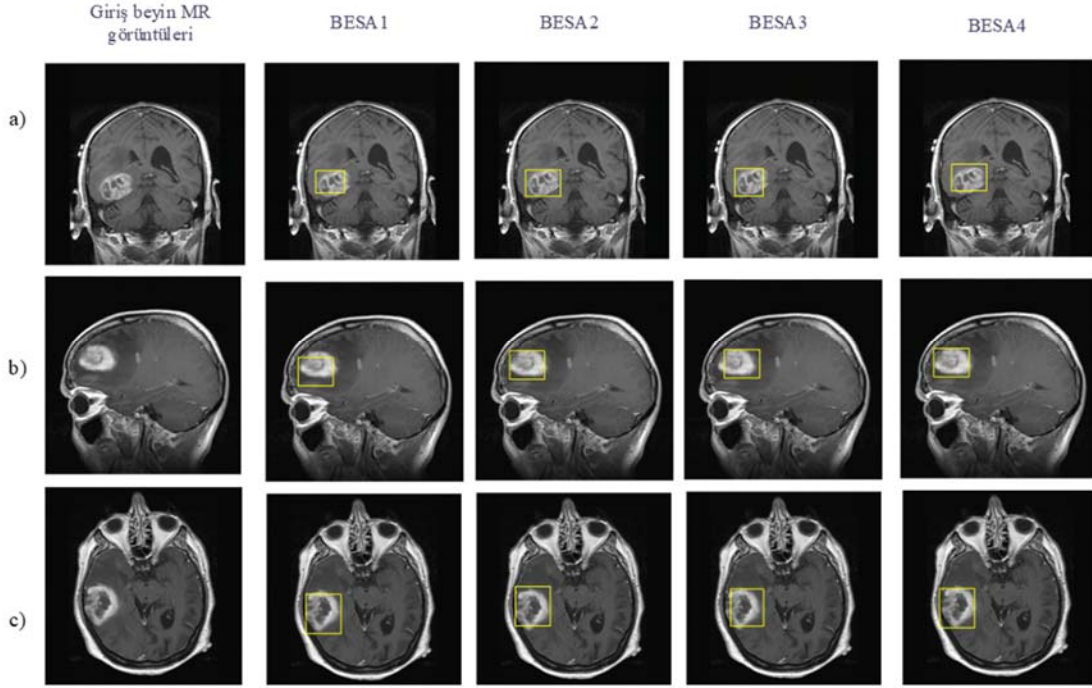
Tablo 1. Tasarlanan BESA'ların parametreleri ve değerleri (Parameters and values of the proposed RCNN)

Tasarlanan BESA	Evrişim filtre boyutu	Havuzlama filtre boyutu	Havuzlama operatörü	Aktivasyon Fonksiyonu	Çıktı katmanı	Kayıp Fonksiyon
BESA1						
BESA2						
BESA3						
BESA4						

incelendiğinde, BESA1 ve BESA3 mimarilerinin ürettiği çerçevelerin ilgili tümörleri tespitinin kabul edilebilir olduğu fakat tam olarak da çerçeveleyemediği görülmektedir. Bununla beraber, BESA4 mimarisinin BESA1, BESA2 ve BESA3 mimarilerine oranla ilgili tümörleri daha iyi tespit ettiği ürettiği çerçevelerden görülmektedir.

Tablo 2'de verilen sayısal değerler, yapılan görsel değerlendirmeyi doğrulamaktadır. Tablo 2'de satırlar BESA mimarilerini gösterirken, sütunlar ise hesaplanan sayısal başarımlarını göstermektedir. Tablo 2'den görüleceği gibi BESA1 için hesaplanan doğruluk, duyarlılık ve özgüllük değerleri sırası ile %97,81, %96,45, %95,66 iken bu değerler BESA2 için sırası ile %98,92, %94,13, %97,24, BESA3 için

%97,27, %93,87, %96,11 ve BESA4 için ise %99,10, %98,36, %99,82 olarak hesaplanmıştır. Rembrandt veri setinden 87 adet tümörlü görüntü eğitim için 38 adet tümörlü görüntü ise test için kullanılmıştır. Şekil 9 ve Tablo 3'de Rembrandt veri setine ait elde edilen sonuçlar sırası ile verilmiştir. Şekil 9'da tasarlanan sistemler tarafından tespit edilen beyin tümörleri sarı bir çerçeve ile gösterilmiştir. Ayrıca gerçek tümör bölgesi ile tespit edilen tümör bölgesinin değerlendirilmesi ile elde edilen sayısal değerler de Tablo 3'de sunulmuştur. Sistemin testi için asıl görüntü üzerinde tarama işlemi seçici arama yöntemi ile gerçekleştirilmiştir. Üç farklı test MR görüntüsü ve bu görüntülere uygulanan 4 farklı BESA mimarisi sonuçları Şekil 9'un 1, 2 ve 3 numaralı satırlarında gösterilmiştir. Şekil



Şekil 8. Tasarlanan sistem tarafından doğru olarak etiketlenen Benchmark veri setine ait örnek görüntüler
(The sample images of the Benchmark dataset correctly labeled by the proposed system)

Tablo 2. Tasarlanan sistemlerin Benchmark veri seti için başarımları sonuçları
(Performance results of the designed systems for Benchmark data set)

Tasarlanan BESA	Doğruluk	Duyarlılık	Özgüllük	Yanlış pozitif oran	Yanlış negatif oran
BESA1	%97,80	%96,45	%95,66	0,04	0,03
BESA2	%98,92	%94,13	%97,24	0,02	0,05
BESA3	%97,27	%93,87	%96,11	0,03	0,07
BESA4	%99,10	%98,36	%99,82	0,01	0,01

9 görsel olarak incelendiğinde, BESA1 ve BESA3 mimarilerinin tümörlerin tespiti kabul edilebilir olduğu, fakat ürettiği çerçevelerin tam olarak da tümörleri çerçeveleyemediği görülmektedir. Bununla beraber, BESA4 ve BESA2 mimarilerinin diğer mimarilere oranla ilgili tümörleri daha iyi tespit ettiği ürettiği çerçevelerden anlaşılmaktadır.

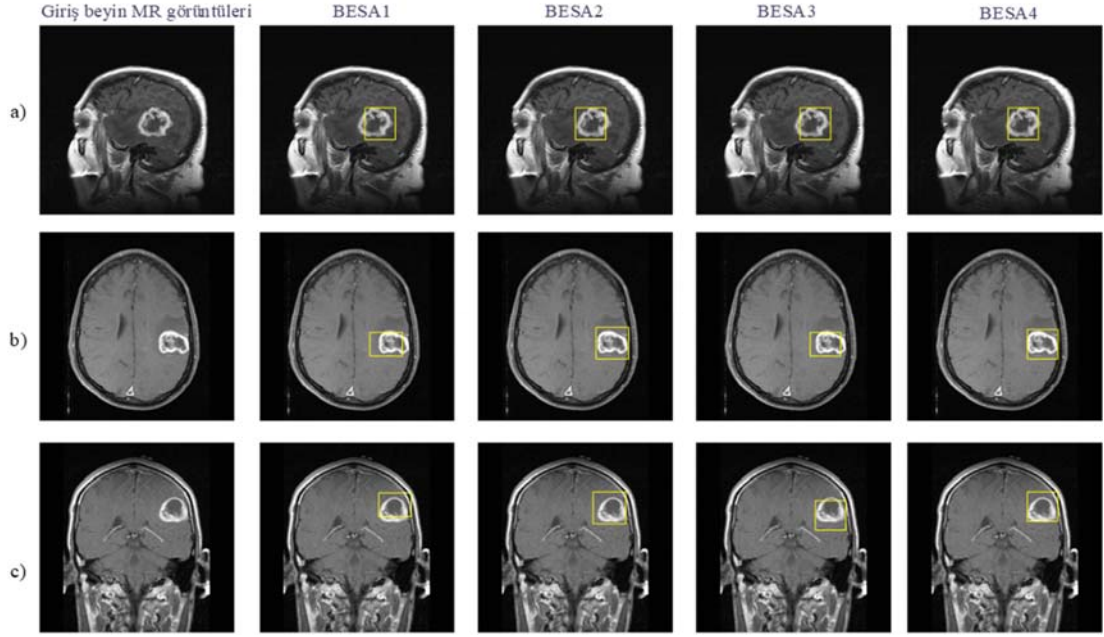
Tablo 3’de verilen sayısal değerler, görseller ile ilgili olarak yapılan yorumları desteklemektedir. Tablo 3’de satırlar BESA mimarilerini gösterirken, sütunlar ise hesaplanan sayısal başarımlar ölçütlerini göstermektedir. Tablo 2’den görüleceği gibi BESA1 için hesaplanan doğruluk, duyarlılık ve özgüllük değerleri sırası ile %96,91, %95,77, %96,80 iken, bu değerler BESA2 için sırası ile %97,41, %96,92, %98,54, BESA3 için %95,20, %94,53, %93,19 ve BESA4 için ise %98,31, %95,62, %98,43 olarak hesaplanmıştır.

Harvard veri setinden 46 adet tümörlü görüntü eğitim için 19 adet tümörlü görüntü ise test için kullanılmıştır. Şekil 10 ve Tablo 3’de Harvard veri setine ait elde edilen sonuçlar sırası ile verilmiştir. Şekil 10’da görüleceği üzere tespit edilen beyin tümörleri sarı bir çerçeve ile gösterilmiştir. Tablo 3’de

gerçek tümör bölgesi ile tespit edilen tümör bölgesinin değerlendirilmesi ile elde edilen sayısal sonuçlar verilmiştir. Sistemin testi için asıl görüntü üzerinde tarama işlemi seçici arama yöntemi ile gerçekleştirilmiştir. Üç farklı test MR görüntüsü ve bu görüntülere uygulanan 4 farklı BESA mimarisi sonuçları Şekil 10’un 1, 2 ve 3 numaralı satırlarında gösterilmiştir. Şekil 10 görsel olarak incelendiğinde, BESA1 ve BESA3 mimarilerinin ürettiği çerçevelerin ilgili tümörlerin tespiti kabul edilebilir olduğu fakat tam olarak da çerçeveleyemediği ve küçük yapıdaki tümörleri tespit edemediği görülmektedir. Bununla beraber, BESA2 ve BESA4 mimarilerinin BESA1 ve BESA3 mimarilerine göre ilgili tümörleri daha iyi tespit ettiği görülmektedir. Fakat BESA3’de, BESA4’ün tespit ettiği küçük tümörü tespit edememiştir.

Tablo 4’de verilen sayısal değerler, görseller ile ilgili olarak yapılan yorumları desteklemektedir. Tablo 4’de satırlar BESA mimarilerini gösterirken, sütunlar ise hesaplanan sayısal başarımlar ölçütlerini göstermektedir. Tablo 4’den görüleceği gibi BESA1 için hesaplanan doğruluk, duyarlılık ve özgüllük değerleri sırası ile %97,31, %94,43, %95,65 iken bu değerler BESA2 için sırası ile %98,12, %95,10, %96,24,


BESA3 için %97,28, %92,56, %93,11 ve BESA4 için ise %98,62, %94,33, %94,74 olarak hesaplanmıştır.



Şekil 9. Tasarlanan sistem tarafından doğru olarak etiketlenen Rimbredant veri setine ait örnek görüntüler
(The sample images of the Rimbredant dataset correctly labeled by the proposed system)

Tablo 3. Tasarlanan sistemlerin Rimbredant veri seti için performans sonuçları
(Performance results of the designed systems for Rimbredant data set)

Tasarlanan BESA	Doğruluk	Duyarlılık	Özgüllük	Yanlış pozitif oran	Yanlış negatif oran
BESA1	%96,91	%95,77	%96,80	0,03	0,04
BESA2	%97,41	%96,92	%98,54	0,01	0,03
BESA3	%95,20	%94,53	%93,19	0,06	0,05
BESA4	%98,31	%95,62	%98,43	0,01	0,04



Şekil 10. Tasarlanan sistem tarafından doğru olarak etiketlenen Harvard veri setine ait örnek görüntüler
(Example MR images of the Harvard dataset correctly labeled by the proposed system)

Şekil 11’de, önerilen yöntemin gerçek tümörlerle birlikte, tümör olmayıp ta tümör olarak belirlediği bazı örnek görüntüler verilmiştir. Ayrıca, daha öncede belirtildiği üzere, tümörü belirleyen çerçeve eğer tümörü %80 oranında kapsamıyorsa, bu tespitler de doğru pozitif olarak kabul edilmemiştir. Şekil 11-(a,b)’de verilen sonuçta, tümörün bir kısmı tespit edilebilmişse de bu tespit oranı (piksel sayısı) %80’in altında kaldığı için bu tespit doğru olarak değerlendirilmemiştir. Ayrıca Şekil 11-(c)’den de görüleceği üzere, önerilen sistem tümörleri tespit etmesine rağmen aynı zaman da göz çukurlarını da tümör olarak tespit ettiği için hatalı kabul edilmiştir.

Kullanılan veri tabanlarına ait tasarlanan BESA’ların eğitim ve test süreleri Tablo 5’de sunulmuştur. Satırlar veri tabanlarını gösterirken sütunlar ise tasarlanan BESA mimarilerine ait eğitim ve test sürelerini ifade etmektedir.


Eğitim süreleri dakika/saniye cinsinden ifade edilirken test süreleri ise saniye cinsinden ifade edilmiştir. Veri tabanlarına ait eğitim ve test sürelerindeki fark kullanılan görüntü sayısı ile ilgili iken BESA’larda eğitim ve test sürelerinin farklılaşması ise mimarilerin farklı yapılarda tasarlanmasından kaynaklanmaktadır.

Önerilen yöntemin performans değerlendirmesinin daha iyi yapılabilmesi amacıyla bu çalışma için kullanılan veri setleri kullanılarak literatürdeki yöntemler ile karşılaştırılmıştır. Elde edilen ortalama doğruluk sonuçları Tablo 6’da verilmiştir.

Tablo 6’da görüldüğü gibi üç veri seti için de BESA2 ve BESA 4 mimarilerinden elde edilen doğruluk oranları karşılaştırılan her iki yöntemden daha yüksektir. Diğer yandan Tablo 6’den görüleceği gibi Amin vd. [1] önerdikleri

Tablo 4. Tasarlanan sistemlerin Harvard veri setinde başarımlar ölçüt sonuçları
(Performance results of the designed systems for Harvard data set)

Tasarlanan BESA	Doğruluk	Duyarlılık	Özgüllük	Yanlış pozitif oran	Yanlış negatif oran
BESA1	%97,31	%94,43	%95,65	0,04	0,05
BESA2	%98,12	%95,10	%96,24	0,03	0,04
BESA3	%97,28	%92,56	%93,11	0,06	0,07
BESA4	%98,62	%94,33	%94,74	0,05	0,05



Şekil 11. Tasarlanan sistemler tarafından yanlış olarak etiketlenen örnek MR görüntüleri
(Example MR images incorrectly labeled by the proposed systems)

Tablo 5. Tasarlanan BESA’ların çalışma süreleri (Working time of the designed RCNN)

Veri Setleri	BESA 1		BESA2		BESA3		BESA4	
	Eğitim Süresi (dk/sn)	Test Süresi (sn)	Eğitim Süresi (dk/sn)	Test Süresi (sn)	Eğitim Süresi (dk/sn)	Test Süresi (sn)	Eğitim Süresi (dk/sn)	Test Süresi (sn)
Benchmark	15/12	35,19	17/45	33,25	15/43	35,15	19/26	32,12
Rembredant	11/36	26,22	13/42	29,16	11/56	27,26	15/17	28,11
Harvard	7/25	13,11	8/16	12,13	7/56	12,58	9/26	13,05

Tablo 6. Önerilen yöntemin mevcut yöntemler ile doğruluk oranlarının karşılaştırılması
(Comparison of accuracy rate of proposed method with existing methods)

Veri setleri	Amin vd.	Nabizadeh vd,	Önerilen Mimariler			
	[1]	[13]	BESA1	BESA2	BESA3	BESA4
Benchmark	%98,12	%94,52	%97,80	%98,92	%97,27	%99,10
Rembredant	%95,11	%91,14	%96,91	%97,41	%95,20	%98,31
Harvard	%97,45	%93,28	%97,31	%98,12	%97,28	%98,62

metotların ortalama doğruluğu Benchmark ve Harvard veri setinde BESA1 ve BESA3'e göre daha yüksek olmasına rağmen Rembredant veri setinde BESA1 ve BESA3 mimarilerinin ortalama doğruluğu daha yüksektir. Nabizadeh vd. [13] önerdikleri metod ise tasarladığımız dört mimarinin ortalama doğruluk değerlerinin gerisinde kalmıştır.

Bu veriler ışığında, önerilen mimarilerin beyin MR görüntülerinden tümör tespitinde etkin bir şekilde kullanılabilceği görülmektedir.

5. SONUÇLAR (CONCLUSIONS)

Bu çalışmada, beyin MR görüntülerinden tümörlü bölgelerin otomatik olarak tespit edilmesi için derin öğrenme tabanlı yeni bir yöntem önerilmiştir. Yöntem temel olarak beş adımdan oluşmaktadır. Üç adet veri seti kullanılarak önerilen mimariler test edilmiştir. Yapılan çalışmada dört farklı BESA mimarisi kullanılmış ve elde edilen sonuçlar hem görsel hem de sayısal olarak değerlendirilmiştir. Üç veri seti kullanıldığında mimarilerin ortalama doğruluk başarımları BESA1 için %97,34, BESA2 için %98,15, BESA3 için %96,58 ve BESA4 için %98,66 olarak hesaplanmıştır. BESA4 mimarisi tasarlanan diğer mimarilere oranla daha başarılı sonuçlar ürettiğini göstermiştir. BESA4'ün performansının, diğer mimarilerden daha iyi olmasının sebebi, evrişim ve havuzlama katmanlarının sayısı ve bu katmanlarda kullanılan filtre boyutu ile kayıp ve aktivasyon katmanlarındaki kullanılan fonksiyonlardan kaynaklanmaktadır. Önerilen yöntemin performansı daha önceden yapılan benzer çalışmalar ile kıyaslanmış önerilen yöntemin başarımının yüksek olduğu görülmüştür. İleriki çalışmalarda önceden eğitilmiş bazı ESA mimarilerinin altıncı ve yedinci katmanlarından elde edilen özneliklerin, farklı eğitimci sınıflandırıcılar kullanılarak tümör tespiti yapılması planlanmaktadır.

KAYNAKLAR (REFERENCES)

1. Amin, J., Sharif, M., Yasmin, M., Fernandes, S.L., A distinctive approach in brain tumor detection and classification using MRI, Pattern Recognition Letters, 2017.
2. Shang, H., Zhao, W., Zhang, W., Preoperative Assessment Using Multimodal Functional Magnetic Resonance Imaging Techniques in Patients with Brain Gliomas, Turkish Neurosurgery, 22 (5), 558-565, 2012.
3. M. Rohit, S. Kabade, M.S. Gaikwad, Segmentation of brain tumour and its area calculation in brain MRI images using K-mean clustering and Fuzzy C-mean

algorithm, Int. J. Comput. Sci. Eng. Technol. (IJCSSET) 4 (5), 524–531, 2013.

4. H.A. Aslam, T. Ramashri, M.I.A. Ahsan, A new approach to image segmentation for brain tumor detection using pillar K-means algorithm, Int. J. Adv. Res. Comput. Commun. Eng. 2 (3), 1429–1436, 2013.
5. Tüm Radyoloji Teknisyenleri ve Teknikerleri Derneği. http://www.tumrad.net/FileUpload/ds58732/File/manyetik_rezonans_goruntuleme_mrg.pdf. Erişim Tarihi Kasım 25, 2017.
6. Herek, D., Karabulut, N., Manyetik Rezonans Görüntüleme, TTD Toraks Cerrahisi Bülteni, 1 (3), 214–222, 2010.
7. Kaya, H., Çavuşoğlu, A., Çakmak, H.B., Şen, B., Delen, D., Supporting the diagnosis process and processes after treatment by using image segmentation and image simulation techniques: Keratoconus example, Journal of The Faculty of Engineering and Architecture of Gazi University, 31 (3), 737-747, 2016.
8. İftekaruddin, K.M., Zheng, J., Islam, M.A., Ogg, R.J., Fractal-based brain tumor detection in multimodal MRI, Applied Mathematics and Computation, 207 (1), 23–41, 2009.
9. Mustaqeem, A., Javed, A., Fatima, T., An efficient brain tumor detection algorithm using watershed and thresholding based segmentation, International Journal of Image, Graphics and Signal Processing (IJIGSP), 4 (10), 34–39, 2012.
10. Kole, D.K., Halder, A., Automatic brain tumor detection and isolation of tumor cells from MRI Images, International Journal of Computer Applications in Technology, 39 (16), 26–30, 2012.
11. Meena, A., Raja, R., Spatial fuzzy c means pet image segmentation of neurodegenerative disorder, Computer Vision and Pattern Recognition, 4 (1), 50–55, 2013.
12. Nabizadeh, N., N., John, C., Wright, Histogram-based gravitational optimization algorithm on single MR modality for automatic brain lesion detection and segmentation, Expert Systems with Applications, 41 (17) 7820–7836, 2014.
13. Yaqub, M., Javaid, M. K., Cooper, C., Noble, J. A., Investigation of the role of feature selection and weighted voting in random forests for 3-D volumetric segmentation. IEEE Transactions on Medical Imaging, 33 (2), 258–271, 2014.
14. Eman, A.M., Mohammed, E., Rashid A.A., Brain tumor segmentation based on a hybrid clustering technique, Egyptian Informatics Journal, 16 (1), 71–81, 2015.
15. Nabizadeh, N., & Kubat, M., Brain tumors detection and segmentation in MR images: Gabor wavelet vs.

- statistical features, *Computers & Electrical Engineering*, 45, 286–301, 2015.
16. Mousavi, S.M., Naghsh, A., Abu-Bakar, S.A.R., A heuristic automatic and robust ROI detection method for medical image watermarking, *Journal of Digital Imaging*, 28 (4), 417–427, 2015.
 17. Ahmadvand, A., & Kabiri, P., Multispectral MRI image segmentation using Markov random field model. *Signal, Image and Video Processing*, 10, 251–258, 2016.
 18. Sudharani, K., Sarma, T.C., Prasad, K.S., Advanced morphological technique for automatic brain tumor detection and evaluation of statistical parameters, *Procedia Technology*, 24, 1374–1387, 2016 .
 19. Kadam, M., & Dhole, A., Brain tumor detection using GLCM with the help of KSVM, *International Journal of Engineering & Technical Research*, 7 (2), 2454–4698, 2017.
 20. Abbasi, S., Tajeripour, F., Detection of brain tumor in 3D MRI images using local binary patterns and histogram orientation gradient, *Neurocomputing*, 219, 526–535, 2017.
 21. Başoğlu, B., Bulut, M., Development of a hybrid system based on neural networks and expert systems for shortterm electricity demand forecasting, *Journal of The Faculty of Engineering and Architecture of Gazi University*, 32 (2), 575-583, 2017.
 22. Cengil, E. Çınar, A., Güler, Z., A GPU-Based Convolutional Neural Network Approach for Image Classification, *Artificial Intelligence and Data Processing Symposium (IDAP)*, Malatya, Türkiye, 16-17 Eylül, 2017.
 23. Gao, X., Li, W., Loomes, M., Wang, L., A fused deep learning architecture for viewpoint classification of echocardiography, *Information Fusion*, 36, 103–113, 2017.
 24. Gao, X. W., Hui, R., Tian, Z., Classification of CT brain images based on deep learning networks, *Computer Methods and Programs in Biomedicine*, 138, 49–56, 2017.
 25. Ari, B., Sengur, A., Ari, A., Hanbay D., Apricot Plant Classification Based On Leaf Recognition by Using Convolutional Neural Networks, *International Conference on Natural Science and Engineering (ICNASE'16)*, Kilis, Türkiye, 19-20 Mart, 2016.
 26. Berna Ari: Kayısı Yapraklarının Evrimsel Sinir Ağları Kullanılarak Sınıflandırılması, *Fen Bilimleri Enstitüsü, Elektrik-Elektronik Teknolojileri Mühendisliği, Fırat Üniversitesi*, 2017.
 27. Ümit Budak: Uydu görüntülerinde havaalanlarının tespit edilmesi, *Fen Bilimleri Enstitüsü, Elektrik-Elektronik Mühendisliği, Fırat Üniversitesi*, 2017.
 28. CS231n: Convolutional Neural Networks for Visual Recognition. <http://cs231n.github.io/convolutional-networks/#fc>. Erişim Tarihi: Ekim 20, 2017.
 29. <https://github.com/Kulbear/deep-learning-nano-foundation/wiki/ReLU-and-Softmax-Activation-Functions>. Erişim Tarihi: Mayıs 22, 2018.
 30. Hinton, G., Osindero, S., Teh, Y., A Fast Learning Algorithm for Deep Belief Nets, *Neural Computation*, 18(7), 1527-1554, 2006.
 31. Alper Ulu: “Deep Convolutional Neural Network Based Representations For Person Re-Identification”, *Department of Computer Engineering Computer Engineering Programme, Istanbul Technical University*, June 2016.
 32. Havaei, M., Davy, A., Warde-Farley, D., Biard, A., Courville, A., Bengio, Y., Pal, C., Jodoin, P.M., Larochelle, H., Brain tumor segmentation with deep neural networks, *Medical Image Analysis*, 35, 18–31, 2017.
 33. Alpaslan, N., Kara, A.i Zencir, B., Hanbay, D., Classification of breast masses in mammogram images using KNN, *Signal Processing and Communications Applications Conference (SIU)*, 1469-1472, Malatya, Türkiye, 16-19 Mayıs 2015.
 34. Multimodal Brain Tumor Segmentation. <https://www.smir.ch/BRATS/Start2015>. Erişim tarihi: Eylül 7, 2017.
 35. The image data in The Cancer Imaging Archive (TCIA), <https://wiki.cancerimagingarchive.net/display/Public/REMBRANDT>. Erişim Tarihi: Aralık 25, 2017.
 36. Summers, D., Harvard whole brain atlas: www.med.harvard.edu/AANLIB/home.html, *J. Neurol. Neurosurg. Psychiatry* 74 (3), 288–288, 2003.