



## Brain tumors classification with deep learning using data augmentation

Kali Gürkahraman<sup>1\*</sup>, Rukiye Karakış<sup>2</sup>

<sup>1</sup>Department of Computer Engineering, Sivas Cumhuriyet University, Sivas, 58140, Turkey

<sup>2</sup>Department of Software Engineering, Sivas Cumhuriyet University, Sivas, 58140, Turkey

### Highlights:

- Classification of brain tumors with deep learning
- Determination of the effects of data augmentation and transfer learning on classification
- Determination of effect of MR planes on classification

### Keywords:

- Brain Tumor Classification
- Deep Learning
- Data Augmentation
- Feature Extraction
- Support Vector Machine

### Article Info:

Research Article  
Received: 04.04.2020  
Accepted: 07.12.2020

### DOI:

10.17341/gazimmfd.762056

### Correspondence:

Author: Kali Gürkahraman  
e-mail:  
kgurkahraman@cumhuriyet.edu.tr  
phone:+90 346 219 1010

### Graphical/Tabular Abstract

In this study, the Convolutional Neural Network (CNN) was used to classify three different brain tumors (glioma, meningioma and pituitary) from T1-weighted MR images. The initial weights of the CNN architecture were transferred from the DenseNet121 network. The features obtained from the CNN architecture were classified by support vector machine (SVM), k-nearest neighbour (kNN) and Bayes methods. The performance of the classifiers was determined by accuracy, sensitivity, specificity, area under curve, and Pearson correlation coefficient (R) on the test data.

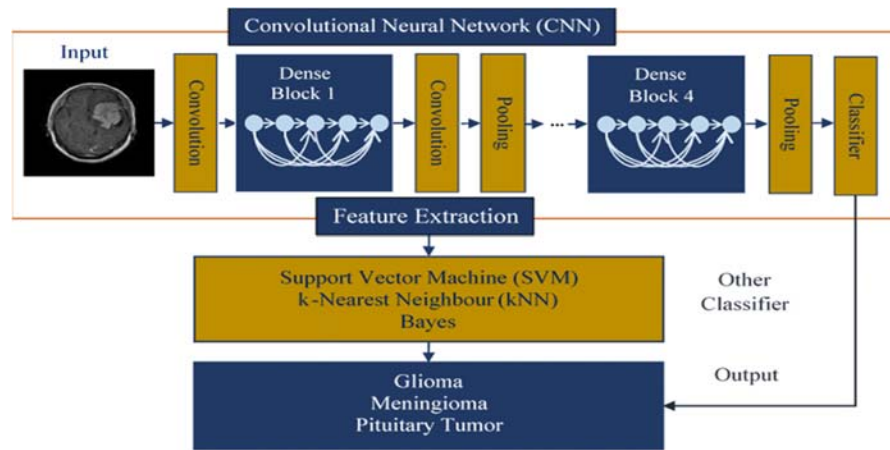


Figure A. Flowchart of the proposed methods

**Purpose:** In this study, the essential aims are the classification of brain tumors on the figshare dataset; determination of which axial, coronal, and sagittal MR plane slices is effective in classification; and measurement of the increase in classifier performance resulting from the data augmentation on the medical image.

### Theory and Methods:

In this study, brain tumors were classified with CNN architecture using 3064 slices of T1-weighted MR images obtained from 233 patients in the figshare data set. Axial, coronal and sagittal MR plane slices were separated. Images were augmented with affine transformation and pixel-level transformation techniques. In the study, the weights of DenseNet121 network developed for ImageNet were transferred to CNN architecture. Features from the first fully connected layer of trained CNN architecture were used as inputs for SVM, kNN and Bayesian classifiers, and the results of these classifiers were compared to CNN result.

### Results:

After data augmentation, the R values of the CNN architecture increased from 0.880 to 0.967 and the accuracy values increased from 0.946 to 0.986. Accuracy values of SVM, kNN and Bayes classifiers were calculated as 0.998, 0.991 and 0.893, and R values as 0.995, 0.989, 0.790, respectively.

### Conclusion:

According to the results obtained with test data, CNN based SVM method has achieved higher performance compared to the literature. Brain coronal plane is more effective in tumor classification



## Veri çoğaltma kullanılarak derin öğrenme ile beyin tümörlerinin sınıflandırılması

Kali Gürkahraman<sup>1\*</sup>, Rukiye Karakış<sup>2</sup>

<sup>1</sup>Cumhuriyet Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, 58140, Sivas, Türkiye

<sup>2</sup>Cumhuriyet Üniversitesi, Teknoloji Fakültesi, Yazılım Mühendisliği Bölümü, 58140, Sivas, Türkiye

### Ö N E Ç I K A N L A R

- Derin öğrenme ile beyin tümörlerinin sınıflandırılması
- Veri çoğaltma ve transfer öğrenmenin sınıflandırma üzerindeki etkilerinin belirlenmesi
- MR kesitlerinin sınıflandırmaya etkisinin belirlenmesi

### Makale Bilgileri

Araştırma Makalesi

Geliş: 04.04.2020

Kabul: 07.12.2020

DOI:

10.17341/gazimmfd.762056

### Anahtar Kelimeler:

Beyin tümör sınıflandırma,  
derin öğrenme,  
destek vektör makineleri,  
öznitelik çıkarımı,  
veri çoğaltma

### ÖZET

Tıbbi görüntü sınıflandırma, veriyi belirli sayıda sınıfa ayırma işlemidir. Son yıllarda, Manyetik Rezonans Görüntüleme (MRG) beyin tümörlerinin tespit edilmesinde ve tanısında yaygın olarak kullanılmaktadır. Bu çalışmada, üç farklı beyin tümörünün (gliyom, menenjiyom ve hipofiz bezi tümörü) T1 ağırlıklı MR görüntüleri üzerinde evrimsel sinir ağı (ESA) kullanılarak sınıflandırılması ve aksiyel, koronel ve sagittal MR kesitlerinin sınıflandırmadaki etkinliğinin belirlenmesi amaçlanmıştır. Ağırlıklar, daha önce ImageNet veri kümesi için eğitilmiş DenseNet121 ağından ESA'ya transfer edilerek ilklendirilmiştir. Ayrıca, MR görüntülerinde afin dönüşümü ve piksel-seviye dönüşümü kullanılarak veri çoğaltma işlemi yapılmıştır. Eğitilen ESA'nın tam bağlantılı ilk katmanından elde edilen öznitelikler, destek vektör makinesi (DVM), k en yakın komşu (kNN) ve Bayes yöntemleriyle de sınıflandırılmıştır. Bu sınıflandırıcıların başarısı test verisi üzerinde duyarlılık, belirlilik, doğruluk, eğri altında kalan alan ve Pearson korelasyon katsayısı ile ölçülmüştür. ESA, ve ESA tabanlı DVM, kNN ve Bayes sınıflandırıcılarının elde ettiği doğruluk değerleri sırasıyla 0,9860, 0,9979, 0,9907 ve 0,8933' dür. Beyin tümör sınıflandırma için önerilen ESA tabanlı DVM modeli literatürdeki benzer çalışmalardan daha yüksek performans değerleri elde etmiştir. Ayrıca, tümör tipinin belirlenmesinde koronel kesitlerin diğer kesitlere göre daha iyi sonuç verdiği görülmüştür.

## Brain tumors classification with deep learning using data augmentation

### H I G H L I G H T S

- Classification of brain tumors with deep learning
- Determination of the effects of data augmentation and transfer learning on classification
- Determination of effect of MR planes on classification

### Article Info

Research Article

Received: 04.04.2020

Accepted: 07.12.2020

DOI:

10.17341/gazimmfd.762056

### Keywords:

Brain tumor classification,  
deep learning,  
data augmentation,  
feature extraction,  
support vector machine.

### ABSTRACT

Medical image classification is the process of separating data into a specified number of classes. In recent years, Magnetic Resonance Imaging (MRI) has been widely used in the detection and diagnosis of brain tumors. In this study, it was aimed to classify three different brain tumors (glioma, meningioma and pituitary) using convolutional neural network (CNN) on T1-weighted MR images and to determine the efficiency of axial, coronal and sagittal MR planes in classification. The weights were initialized by transferring to CNN from DenseNet121 network, which was previously trained with ImageNet dataset. In addition, data augmentation was performed on MR images using affine and pixel-level transformations. The features obtained from the first fully connected layer of the trained CNN were also classified by support vector machine (SVM), k nearest neighbor (kNN), and Bayes methods. The performances of these classifiers were measured by the sensitivity, specificity, accuracy, area under curve, and the Pearson correlation coefficient on the test dataset. The accuracy values of the developed CNN and CNN-based SVM, kNN, and Bayes classifiers are 0.9860, 0.9979, 0.9907, and 0.8933, respectively. The CNN-based SVM model proposed for brain tumor classification obtained higher performance values than similar studies in the literature. In addition, coronal plane of the brain was found to give better results than other planes in determining the tumor type.

\*Sorumlu Yazar/Yazarlar / \*Corresponding Author/Authors: \*kgurkahraman@cumhuriyet.edu.tr rkarakis@cumhuriyet.edu.tr / Tel: +90 346 219 1010

## 1. GİRİŞ (INTRODUCTION)

Manyetik Rezonans Görüntüleme (MRG) güçlü bir manyetik alan içinde radyo dalgaları vasıtasıyla anatomik yapıların birbirlerinden ayrılmasını sağlayan ve sağlıklı olan/olmayan dokuların tespit edilmesinde kullanılan invazif olmayan bir tekniktir. MRG daha iyi yumuşak doku kontrastı sağlar ve kemikte artefakt oluşturmaz. MRG ile hastaların görüntüleri pozisyon değiştirilmeden üç farklı düzlemde (aksiyal, koronal ve sagittal) multiplanar ve çok dilimli olarak elde edilebilir. Ayrıca, bilgisayarlı Tomografi (BT) taramalarına göre düşük radyasyon ve yüksek kontrast özelliğine sahiptir. MR görüntüleri ile doku yapıları hakkında şekil, boyut ve lokalizasyon gibi bilgiler elde edilmektedir. Bu sebeple, son yıllarda MRG beyin lezyonlarının tümör olup olmadığının tespit edilmesinde ve tedavisinde BT yerine yaygın olarak kullanılmaktadır. İleri MR görüntüleme teknikleri ile tümörlerin yaygınlığı, türü, yapısı, beynin diğer alanları ile olan bağlantı ve yolak ilişkilerinin tespiti de mümkündür. Ayrıca, MRG taraması Alzheimer, Parkinson ve demans gibi beyinle ilgili diğer hastalıklar için de etkilidir [1-3].

Araştırmacılar MR gibi tıbbi görüntüler üzerinde temelde bölütleme ya da sınıflandırma problemi ile ilgilenirler. Tıbbi görüntü bölütleme, iki ya da üç boyutlu (2B/3B) farklı modalitelerde çekilmiş bir görüntüyü alt bölgelere ayırtmayı, ilgi alanlarını ya da ön ve arka planları tespit etmeyi amaçlar [1]. Beyin tümör bölütleme ise beyaz madde (BM), gri madde (GM) ve beyin omurilik sıvısı (BOS) gibi normal olan beyin dokularından farklı olan tümör dokularının ayırt edilmesini sağlar. Literatürde önerilen beyin tümör bölütleme yöntemleri; elle, yarı otomatik ve tam otomatik bölütleme olarak sınıflandırılabilir [2]. Elle bölütleme, uzmanlarca anatomik yapıların ve tümör gibi ilgili yapıların sınırlarının çizilmesi ya da boyanmasını içerir. Bu işlem, MR çekimlerinin pek çok kesit içermesi sebebiyle her biri için tekrarlanır. Ancak, farklı uzmanlarca gerçekleştirilen etiketlemelerde farklılık oluşabilir. Ayrıca, elle bölütleme işlemi zorluklar içermesine rağmen, yarı otomatik ve otomatik bölütleme işlemlerinin doğruluğunu kanıtlamada kullanılır [4-5]. Yarı otomatik bölütlemeye süreci başlatan ve kontrol eden insan operatörüne ihtiyaç vardır. Literatürdeki yöntemler olabildiğince insan faktörünü azaltmak istese de, ilgili uzmandan sonucun doğruluğunu göstermesi ve hatta elle sonucu düzeltmesi istenebilir [5]. Bu yöntemde de uzmanların farklılaşması bölütleme sonuçlarını değiştirmektedir. Tam otomatik yöntemlerde ise insan faktörü olmaksızın bilgisayarlarca bölütleme işlemi gerçekleştirilir [5].

Tıbbi görüntü sınıflandırma; veriyi belirli sayıda sınıfa ayırtma işlemidir. Literatürde yer alan görüntü sınıflandırma teknikleri denetimli ve denetimsiz yaklaşımlar olarak ikiye ayrılır. Denetimli yaklaşımlar, uzmanlarca belirlenen sınıfları tanımlamayı, denetimsiz sınıflandırma yaklaşımları ise görüntülerdeki istatistiksel benzerliklerden yola çıkarak kümelemeyi hedefler. Beyin tümörlerinin

sınıflandırılmasında ise farklı modalitelerdeki beyin görüntülerinden elde edilen öznitelikler vasıtasıyla tümör tipinin belirlenmesi amaçlanır.

Tümörler, beyin zarları, bezler veya sinirler etrafındaki beyin hücrelerinden kaynaklanır. Tümörler kafatasının içinde daha fazla basınca sebep olarak beyin hücrelerine zarar verebilirler [6]. Beyin tümörleri temelde iyi ve kötü huylu olmak üzere ikiye ayrılır. Bununla birlikte Amerikan Nörolojik Cerrahlar Birliği (AANS) beyin tümörlerini; iyi ve kötü huylu beyin tümörleri olmak üzere önce iki gruba, bunları da 11 alt gruba ayırtmaktadır [1]. Bu çalışmanın konusu kontrolsüz bir şekilde çoğalan hücrelerin oluşturduğu iyi ve kötü huylu beyin tümörleridir. Kötü huylu tümörler, her yıl 14 bin ölüme neden olmaktadır ve hastalarda genel sağ kalım oranı bazı tümör tiplerinde (gliyom, gliyoblastoma vb.) sadece 15 aydır [6]. Beyin tümörleri farklı derecelerde değerlendirilir. Derece 1' de en az tehlikeli ve uzun süreli hayatta kalma ihtimali bulunan tümörler ilişkilendirilir. Bu tümörler mikroskopla bakıldığında yavaş büyürler ve normal bir görünüme sahiptirler. Derece 2 tümörler yavaş büyürler, genellikle komşu dokulara yayılmazlar ve mikroskop altında anormal olarak görünürler. Derece 3 tümörler ise kötü huyludur ve Derece 2 ile aralarında büyük bir kontrast farklılığı yoktur. Ancak bu tümörler tekrarladıklarında Derece 4 olarak oluşurlar. Derece 4, en kötü huylu tümörleri derecelendirmek için kullanılır. Bunlar, hızlı çoğalırlar ve mikroskop altında farklı bir görünüme sahiptirler. Ayrıca, Derece 4 tümörler beynin komşu dokularında yayılıp büyüyerek yeni damarların ortaya çıkmasına neden olurlar [6]. Beyin tümörleri, karmaşık yapıları ve derecelendirme zorlukları sebebiyle MR gibi görüntüler üzerinde karar destek sistemleri ile sınıflandırılmakta ve/veya bölütlenmektedirler. Bu nedenle çalışmada iyi huylu ve kötü huylu tümör tipleri seçilmiştir. Büyüme hızları açısından düşünüldüğünde çok yavaş, orta ve hızlı olarak sınıflandırılacak tümör tipleri kullanılmıştır. Bu çalışmanın da konusu olan beyin tümörlerini sınıflandırmada literatürde son yıllarda pek çok makine öğrenme (ML-Machine Learning) yöntemi önerilmiştir. Bunların arasında en çok kullanılan üç teknik; derin öğrenme (DL-Deep Learning) mimarilerinden biri olan evrişimsel sinir ağı (ESA), destek vektör makinesi (DVM) ve temel bileşenler analizi (TBA)' dir [1]. Bu çalışma beyin tümörlerinin öznitelik analizi gerektirmeyen DL tekniğiyle sınıflandırılması ile ilgilenmektedir.

Yapay Zeka (YZ) "bir bilgisayarın ya da bilgisayar denetimli bir makinenin, genellikle insana özgü nitelikler olduğu varsayılan akıl yürütme, anlam çıkartma, genelleme ve geçmiş deneyimlerden öğrenme gibi yüksek zihinsel süreçlere ilişkin görevleri yerine getirme yeteneği" olarak tanımlanmaktadır [7-10]. Yapay zekanın alt ana bilim dallarından biri olan ML, bilgisayar sistemlerinin belirli bir yönerge olmaksızın bir görevi gerçekleştirmek için kullandığı algoritmalar ve istatistiksel modellerle ilgilenen, örüntü ve çıkarımlara dayanan bilim dalıdır. Günümüzde ML yöntemleri, kameralar ve akıllı telefonlarda, web

aramalarında, sosyal ağlarda, görüntülerden nesne tanıma, konuşmayı metne dönüştürmede, haberleri, gönderileri, ürünleri ve listeleri kullanıcıların ilgi alanlarıyla eşleştirmede vb. farklı pek çok alanda yaygın olarak kullanılmaktadır [11]. ML herhangi bir konuda çıkarım yapabilmek için o konuyu ifade eden eğitim verileri (training set) olarak bilinen matematiksel bir örnek veri modeline ihtiyaç duyar. Geleneksel ML teknikleri, bu doğal veri modellerini ham hallerinde işleme yetenekleri açısından sınırlıdır. Bu sebeple, ML için ham verileri uygun bir dahili temsile veya özellik vektörüne dönüştüren bir özellik çıkarıcı tasarlamak gerekir. Böylelikle, ML sınıflandırıcısı kullandığı öğrenme yapısı ile girdideki kalıpları algılayıp sınıflandırmaktadır [11].

Temsil öğrenimi, bir makinenin ham verilerle beslenmesine, algılama veya sınıflandırma için gereken temsilleri otomatik olarak keşfetmesine izin veren bir dizi yöntemdir [11]. İnsan beyni, konuşma algılama veya nesne tanıma gibi bir görevi yerine getirirken duyuşal girdiden birden fazla temsil düzeyi çıkarır [12]. YZ'nin diğer bir araştırma konusu olan DL; çoklu işlem katmanlarına sahip modellere sunulan verilerin çok seviyeli soyutlanarak temsillerinin öğrenilmesini sağlar [11]. DL sahip olduğu basit ama doğrusal olmayan modüllerde ham girdiden başlayarak gösterimi daha yüksek ama daha soyut bir seviyeye dönüştürmektedir. Böylece, daha yüksek temsil katmanları ile girdilerin önemli yönleri güçlendirilirken, ilgisiz özellikleri ise bastırılır. Örneğin; modele piksel dizisi şeklinde sunulan bir görüntüden ilk temsil katmanında, görüntüdeki nesnelere belirli yönleri ve konumları, kenarların varlığı veya yokluğu temsil edilir. İkinci katmanda, belirli kenar düzenlemeleri tespit edilerek motifler tespit edilir. Üçüncü katmanda, motifler, tanıdık nesnelere bölümlerine karşılık gelecek şekilde birleştirilir ve sonraki katmanlarda bu temsiller ile nesnelere algılanır. DL'in en güçlü yönü bu özellik katmanlarının önceden tasarlanmayıp bir öğrenme prosedürü kullanılarak giriş verilerinden elde edilmesidir [11].

DL ile ilgili ilk fikir 1980' lerde ortaya atılmışken G.E. Hinton ancak 2006 yılında derin sinir ağlarının nasıl eğitilebileceğini gösterebilmiştir [11]. DL terimi sinir ağlarının genişletilerek daha derin ağların kurulması teorisi ortaya atıldıktan sonra oluşmuştur [12-14]. 2012 yılında nesne tanıma alanında düzenlenen ImageNet yarışmasında ilk derin öğrenme mimarisi olan ESA en yüksek doğruluk değerini elde etmiştir [15]. Bu yarışma sonrasında geliştirilen farklı pek çok DL mimarisi, görüntü, video, konuşma analizi, robotik, otonom araçlar, gen analizinde, tıpta sınıflandırma ve bölütleme gibi problemlerin çözümünde yüksek boyutlu verilerdeki karmaşık yapıları ortaya koyması sebebiyle etkin olarak kullanılmaktadır [11].

Beyin tümörlerinin sınıflandırılması problemi, tümör tiplerinin karmaşık yapıları ve derecelendirme yöntemlerindeki farklılıkları sebebiyle ciddi zorluklar barındırır. Bu sebeple, bu çalışmada üç farklı beyin tümörüne (gliyom, menenjiyom ve hipofiz bezi tümörü) ait T1 ağırlıklı (T1A) MR görüntüleri içeren açık figshare

veriseti kullanılarak beyin tümörlerinin ML teknikleri ile sınıflandırılması amaçlanmıştır. Ayrıca çalışmada, aksiyel, koronal ve sagittal MR kesitlerinden hangisinin sınıflandırmada etkili olduğunun tespit edilmesi ve medikal görüntüler üzerinde veri çoğaltma işleminin sınıflandırıcıya etkisinin de belirlenmesi hedeflenmiştir. Çalışmada, literatürde beyin tümör sınıflandırmadaki başarısından ötürü ve karmaşık öznelik analizleri içermemesinden dolayı ESA mimarisi kullanılmıştır. Ayrıca, ESA mimarisinin tam bağlantılı ilk katmanından elde edilen öznelikler, destek vektör makinesi (DVM), k-en yakın komşu (kNN-k nearest neighbour) ve Bayes yöntemleriyle de önce eğitilmiş ve ardından test edilmiştir. Kullanılan 4 sınıflandırıcının başarısı test verisi üzerinde doğruluk, duyarlılık, belirlilik, eğri altında kalan alan (AUC: Area Under Curve) ve Pearson korelasyon katsayısı (R) ile belirlenmiştir. Böylece, geliştirilen sınıflandırıcının beyin tümörlerini sadece radyolojik görüntüler üzerinden ek veriler olmadan tespit etmesi ve klinikte tanı tedaviyi kolaylaştırması sağlanmıştır.

Çalışmanın bu bölümünü ilgili çalışmalar takip etmektedir. İkinci bölümde kullanılan yöntemler ve veriseti ile ilgili bilgiler verilmiştir. Deneysel sonuçlar üçüncü bölümde gösterilmiştir. Tartışma ve gelecek çalışmalar için bilgiler son bölümde aktarılmıştır.

### 1.1. İlgili Çalışmalar (Related Works)

Bu çalışmada temelde konusu olan tıpta DL çalışmaları incelendiğinde literatürde Alzheimer, epilepsi, şizofreni, inme, otizm, Hafif Bilişsel Bozukluk gibi çeşitli nörolojik hastalıkların sınıflandırılmasında ya da yerlerinin tespit edilmesinde yapısal MR dışında, fMRG, PET, SPECT, DWI, DTG farklı pek çok modalitede görüntü verileri; veri tümeleştirme ile ya da ayrı ayrı ML yaklaşımları ile analiz edilmiştir [16-21]. DL algoritmaları ile nöro görüntüler üzerinde görüntü algılama, farklı modalitedeki görüntülerin çıkarılması, bölütleme ve sınıflandırma işlemleri daha yüksek doğrulukta gerçekleştirilmektedir [17, 21]. Ayrıca, DL yöntemleri, özellikle ESA mimarisi, tıbbi görüntüleri analiz etmek için tercih edilen bir metodoloji haline gelmiştir [16, 21-25]. MR görüntü sınıflandırma hastalık tanısı koyma ve bilişsel tanımlama yapabilmek için pek çok derin öğrenme ağı kullanılmıştır [21]. Alzheimer tanısını koymak için Suk vd. [26] MR ve PET görüntülerini derin Boltzmann makinesinde eğitmiş ve sınıflandırmıştır. Liu vd. [18] Alzheimer ve hafif bilişsel bozukluk hastalıklarının sınıflandırılmasını oto kodlayıcı ve softmax regresyon katmanı kullanarak sağlamıştır.

Klinikte beyin yapılarının sınırlarının ve tümör, lezyon, ödem gibi oluşumların yerlerinin belirlenmesi çok önemlidir ve bu sebeple MR görüntülerinin bölütlemesiyle ilgili literatürde çok fazla çalışma mevcuttur. Zhang vd. [25] farklı MR (T1, T1, FA vs. ) görüntülerini bölütlemek için dört konvolüsyon ağı önermiştir. Pereira vd. [27] ise bir tür tümör olan gliomları bölütlemek için ESA kullanmıştır. Bulut vd. [28] 23 adet beyin MR görüntüleri üzerinde önceden işaretlenen ilgi bölgelerini Markov Random Field (MRF),

Kapur, Kittler ve Otsu algoritmaları ile arka plan ve tümör olarak bölütlemiştir. Çalışmada, en yüksek doğruluk değeri MRF algoritması ile %87,0 olarak elde edilmiştir [28]. Son yıllarda açık MR veri setleri üzerinden yeni algoritmaların geliştirilmesini sağlamak için çeşitli yarışmalar düzenlenmektedir [21]. Beyin MR görüntülerinin sınıflandırılması ve bölütlenmesinde sıklıkla kullanılan veri setleri; BRATS 2013, BRATS 2015, IBSR, TCIA ve BrainWeb' dir. Ayrıca, araştırmacılar Alzheimer ve bilişsel hastalıklar için ADNI, otizm için ABIDE, inme için ISCHEMIC veri setlerini kullanmaktadır [1, 17]. Bu yarışmalarda pek çok DL yöntemi önerilmiştir [17-19, 27].

Amin vd. [6] beyin tümörlerini otomatik olarak bölütleyip sınıflandıran denetimli bir yöntem önermişlerdir. Çalışmada bölütleme sonrası ilgi bölgelerinden elde edilen öznelikler, DVM aracılığıyla kanser ve kanser değil olarak yüksek doğrulukla sınıflandırılmıştır. Farklı bir çalışmada, öncelikle ESA modeli ve k-ortalama algoritması ile beynin yapıları BM ve GM olarak bölütlenmiştir. İkinci aşamada, DL mimarisi ile bölütlenen yapılar normal/anormal olarak %95 doğruluk ile sınıflandırılmıştır [29]. Talo vd. [30] Imagenet veri seti için geliştirilen Resnet34 ağından öğrenmeyi ESA mimarisine transfer etmiş ve Harvard Tıp Okulu MR veri setindeki görüntüleri normal ve anormal olarak sınıflandırmıştır. Çalışmada farklı veri çoğaltma teknikleri aracılığıyla veri setindeki örnek sayısı artırılmıştır [30]. Arı vd. [31], Brats 2015 Benchmark, Remdrant ve Harvard veri setlerinde bulunan toplam 252 adet MR görüntüsünü kullanarak tümör yerini otomatik olarak tespit eden 4 farklı Bölgesel tabanlı ESA (BESA) mimarisi geliştirmiştir. Çalışmada geliştirilen BESA4 mimarisi ortalama %98,66 doğruluk değeri elde etmiştir. Bu çalışma ise tümörlerin yerini tespit etmekle değil tümörlerin tipinin sınıflandırılması ile ilgilenmektedir.

Bu çalışmada, üç farklı beyin tümörünün (gliyom, menenjiyom ve hipofiz bezesi) T1A MR görüntülerinden bölütlenmesi ve sınıflandırılması için hazırlanan figshare veri seti kullanılmıştır [32]. Deepak vd. [33] figshare veri seti üzerinde 3 farklı beyin tümörünü DL mimarisi ile sınıflandırmıştır. Çalışmada öncelikle ImageNet için geliştirilen GoogleNet'ten ESA için öğrenme transfer edilmiş ve ağ MR görüntüleri üzerinde eğitilmiştir. Ardından geliştirilen ESA mimarisinin havuzlama katmanından alınan öznelikler DVM ve kNN yöntemleri ile sınıflandırılmıştır. ESA, DVM ve kNN mimarilerinin doğruluk sonuçları sırasıyla %92,3, %97,8 ve %98,0 olarak elde edilmiştir [33].

Cheng ve arkadaşları [34] beyin tümörlerini sınıflandırmak için tümörler üzerinde aşındırma morfolojik işlemi ile verileri çoğaltmışlar ve ardından bunları halka-formu yöntemi ile ilgi bölgelerine ayırmışlardır. Öznelik çıkarımında; yoğunluk histogramı, gri seviye eş oluşum matrisi ve kelime çantası yöntemleri kullanılmıştır. Kelime çantası ve veri çoğaltma sonrası DVM sınıflandırıcısı ile doğruluk değerleri %83,54'den %88,19'a yükseltmiştir. Veriyi halka-formu ile ayrıştırmak ise çalışmanın doğruluğunu %91,28'e iletmiştir. Diğer bir çalışmada [35]

elle bölütlenen tümör ilgi bölgesine 2B Gabor filtreleme ve Ayrık Dalgacık Dönüşümü (ADD) uygulanmıştır. Dalgacık düzlemindeki katsayılardan elde edilen istatistiksel öznelikler yapay sinir ağları (YSA) ile sınıflandırılmıştır. Çalışmada doğruluk değeri %91,9 olarak elde edilmiştir.

Pashaei vd. [36] beyin tümörleri için önerdikleri iki aşamalı yöntemde, önce ESA ile öznelikleri elde etmişler ardından kernel aşırı öğrenen makineler (KELM: Kernel Extreme Learning Machines) ile tümörleri sınıflandırmışlardır. Çalışmada önerilen yöntemin doğruluk değeri %93,68'dir. Abiwinanda vd. [37] ESA mimarisi ile ön işlem yapmaksızın beyin tümörlerini T1A MR görüntülerinden sınıflandırmıştır ve eğitim doğruluğunu %98,41, test doğruluğunu %84,19 olarak elde etmiştir. Afshar vd. [38] kapsül ağları (CapsNet: Capsule Neural Network) ile geliştirdikleri modelde beyin tümörlerini üç sınıfa ayırmıştır ve yöntemin doğruluk değerini %90,89 olarak elde etmiştir.

Badza vd. [39] veri çoğaltarak elde ettikleri MR görüntüleri ile eğittikleri ESA mimarisi ile %96,56 doğruluk değeri elde etmişlerdir. Diğer bir çalışmada [40], hızlı bölgesel ESA (HB-ESA) ağı ile ilgi bölgelerine ayrılan görüntülerden hem tümör bölgeleri tespit edilmiş hem de sınıflandırılmıştır. Çalışmanın, ortalama kesinlik (precision) değeri %77,60 olarak tespit edilmiştir. Kullandıkları ESA yapısında VGG16 ağına ağırlıkları modele transfer edilmiştir.

Bu çalışmada, yukarıda anlatılan çalışmalarda kullanılmış olan transfer öğrenme, ESA'dan elde edilen özneliklerin farklı sınıflandırıcıların eğitiminde kullanılması ve veri çoğaltma işlemi bir arada kullanılmıştır. Figshare veriseti için, bu bileşenleri bir araya getirmesi açısından özgün bir yere sahiptir ve elde edilen sonuçlar literatürdeki sonuçlara göre daha yüksektir.

## 2. MATERYAL VE METOT (MATERIAL AND METHOD)

Bu çalışmada, gliyom (1426 kesit), hipofiz bezi (930 kesit) ve menenjiyom (708 kesit) beyin tümörleri, figshare veri setinde yer alan 233 hastadan toplanan 3064 kesit T1A beyin MR görüntülerinin tamamı kullanılarak sınıflandırılmıştır [32]. Veri setinde, 2B görüntülerin orijinal boyutları 512 x 512 ve piksel boyutu 0.49 x 0.49 mm<sup>2</sup>'dir. Kesit genişliği 6 mm ve kesit boşluğu 1 mm'dir [32, 34]. Çalışmada, işlem maliyetini azaltmak amacıyla görüntü çözünürlükleri 128x128 olarak ayarlanmıştır. Tekrar boyutlandırma işlemi, tümör boyutları gözönüne alınarak gerçekleştirilmiş ve tümörlerde yapısal bilgi kaybı oluşmamıştır. ESA için transfer öğrenme kullanılacağından 2B olan görüntüler; kırmızı, yeşil ve mavi kanallarında tekrarlanarak 128 x 128 x 3 boyutlarında 3B olarak ağı sunulmuştur. Transfer öğrenme, önceden eğitilmiş ağların kullanılması sayesinde DL için gereken büyük veri gereksiniminin aşılmasını sağlar. Literatüre göre iki transfer öğrenme stratejisi mevcuttur. Bunlardan ilki öznelik çıkarıcı olarak önceden eğitilmiş bir ağı kullanılması; diğeri ise farklı veriler üzerinde önceden eğitilmiş bir ağı ince ayarının yapılmasıdır. Literatürde yer alan çalışmalar bu iki yöntemin de sınıflandırmanın doğruluk

sonuçlarını arttırdığını göstermektedir [16]. Bu sebeple, bu çalışmada ImageNet veriseti ile eğitilen DenseNet121 ağı üzerinde ince ayar yapılarak beyin tümörlerinin sınıflandırılması sağlanmıştır.

Çalışmada öncelikle, verisetindeki görüntüler aksiyel, koronel ve sagittal kesitlerine ayrılmıştır. Ardından, veri çoğaltma işleminin sınıflandırıcıların doğruluk değerine etkisini gösterebilmek amacıyla ham görüntülerden çoğaltılan ikinci veriseti oluşturulmuştur. Verisetleri içerisinde yer alan aksiyel, sagittal, koronel ve toplam MR kesit sayıları Tablo 1'de görülmektedir. İlk veriseti görüntülerin ham halini içerirken, ikinci veriseti aşağıdaki bölümde ayrıntıları verilen veri çoğaltma teknikleri ile elde edilmiştir. Sınıflandırıcıları eğitmek ve ardından test etmek için kullanılan eğitim ve test veriseti yüzdeleri sırasıyla %70 ve %30 şeklindedir. DL için gereken kodlamalar Keras, Tensorflow kütüphaneleri kullanılarak python diliyle ve karşılaştırma için kullanılan DVM, kNN ve Bayes sınıflandırıcıları ise MATLAB yazılım geliştirme platformunda gerçekleştirilmiştir. Çalışma için gerçekleştirilen tüm kodlamalar ve test görüntüleri Github üzerinde ([https://github.com/rukiyekarakisdeep/brainumor\\_classification](https://github.com/rukiyekarakisdeep/brainumor_classification)) paylaşılmıştır.

### 2.1. Veri Çoğaltma (Data Augmentation)


Veri çoğaltma, derin sinir ağlarının genelleme yeteneklerini geliştirmeye yardımcı olan ve ağları dolaylı olarak düzenlemeyi sağlayan bir tekniktir [41]. Özellikle tıbbi çalışmalarda, veri miktarının sınırlı olduğu ve yeni örneklerin elde edilmesinin maliyetli ve zaman alıcı olduğu durumlarda sonuca ulaşmak için önemli bir rol oynamaktadır [42]. Literatürde beyin tümörlerini sınıflandırmak ya da bölütleme için kullanılan veri setlerinde tercih edilen veri çoğaltma teknikleri sentetik veri üretme ya da orijinal verilerden dönüştürme olarak iki grupta incelenebilir. Orijinal verilerden veri çoğaltma yapılırken afin dönüşümü,

elastik dönüşümü ya da piksel seviye dönüşümleri gerçekleştirilir [41]. Şekil 1'de görülen ve literatürde eğitim veri seti üzerinde örnek sayısını artırmak için sıklıkla kullanılan afin dönüşüm teknikleri döndürme, yakınlaştırma, kırpma, çevirme ve ötelemedir. Elastik dönüşümü, eğitim örneklerinin şeklinin değiştirilerek çoğaltılmasını sağlar. Ancak tümör gibi yapıların çoğaltılmasında görüntülerde çok gürültü ve hasar oluşabilir. Ayrıca, fazla bozulmalar ve tümörün uygun olmayan yerlerde belirmesi gerçek olmayan sentetik görüntüler oluşturabilir. Elastik dönüşümü genelde b-spline ve rastgele deformasyon yöntemlerinden faydalanır. Özellikle diffeomorfik (diffeomorphic) çakıştırma beyin topolojisini koruması ve görüntülerde makul bozulmalar oluşturmasından ötürü çakıştırma işlemlerinde tercih edilir.

Mevcut veri çoğaltma teknikleri görüntülerin geometrik özelliklerini korurlar. Ancak, görüntü piksel yoğunluk değerleri bu işlemlerden etkilenmektedir. Piksel düzeyinde veri çoğaltma ile medikal veri analizinde farklı cihazlardan farklı gradyan ya da saturasyonla veri elde etme etkisi yaratılmak istenmektedir. Bunun için, görüntülerin piksel yoğunlukları rastgele ya da sıfır ortalama Gauss gürültüsü eklenerek değiştirilir. Piksel yoğunluk değerlerinin kaydırılması ya da ölçeklendirilmesi (görüntü parlaklığının değiştirilmesi), gama düzeltmesi, keskinleştirme, bulanıklaştırma gibi işlemlerle de gerçekleştirilerek medikal görüntülerin çoğaltılması sağlanır (Şekil 2). Son yıllarda, medikal görüntüler üzerinde veri çoğaltmak için sentetik veri üretme teknikleri de kullanılmaktadır. 2014 yılında Goodfellow tarafından tanıtılan ve ESA mimarisinden farklı olan çekişmeli üretken ağlar (GAN: Generative Adversarial Network) ile ilk yapay görüntüler üretilmiştir. Genel GAN mimarisinde üretici ve ayırıcı olan iki derin ağ mevcuttur. Ayırıcı ağı sahte ve gerçek görüntüleri ayırmaya çalışırken, üretici ağı gürültü ekleyerek gerçeğe yakın görüntüler üretmeyi hedefler. Ayırıcı ve üretici ağların çekişmeli eğitimi sonucunda öğrenen ağ ile de yapay görüntüler üretilmektedir [41, 43]. Tıbbi görüntüleme alanında farklı

**Tablo 1.** Veri seti özellikleri (Dataset Description)

Veri Seti Adı	Gliyom				Hipofiz Bezi tümörü				Menenjiyom			
	Aksiyel	Koronel	Sagittal	Toplam	Aksiyel	Koronel	Sagittal	Toplam	Aksiyel	Koronel	Sagittal	Toplam
Veri-Seti1	494	499	433	1426	291	321	318	930	208	232	268	708
Veri-Seti2	5434	5489	4763	15686	3201	3531	3498	10230	2288	2552	2948	7788



**Şekil 1.** Afin dönüşüm teknikleri (a) orijinal görüntü (b) yatay çevirme (c) dikey çevirme (d) öteleme (e) döndürme (Affine transform (a) original image (b) horizontal flip (c) vertical flip (d) translation (e) rotation)

GAN mimarileri, görüntü iyileştirme, bölütleme, algılama, sınıflandırma ve çapraz-modalite sentezlemede son yıllarda fazlaca kullanılmaktadır [41, 43-48]. Bu çalışmada, mevcut medikal görüntülerden veri çoğaltma için literatürde sıklıkla tercih edilmeleri ve işlem maliyetlerinin azlığı sebebiyle afin dönüşümü ve piksel-seviye dönüşüm tekniklerinden yararlanılmıştır. Kullanılan yöntemlerde birden fazla aynı örnek oluşturmaktan ve anatomik olarak hatalı görüntüler oluşturmaktan kaçınılmıştır. Bu çalışmada, veri çoğaltma işlemleri ile her bir MR kesitinden 10 farklı görüntü elde edilmiştir. Şekil 3'te görülen bu işlemler: (1) sağdan-sola yatay çevirme, (2) yukarıdan aşağıya dikey çevirme, (3) farklı açılarla 4 farklı döndürme (açılar: -90, -45, 45 ve 90), (4) 2 farklı bulanıklaştırma (miktarlar: 0.50 ve 1.0), (5) keskinleştirme, (6) gamma düzeltme (1.0) şeklindedir.


## 2.2. Geliştirilen Derin Öğrenme Mimarisi (Developed Architecture of Deep Learning)

Bu çalışmada, literatürde beyin tümörlerinin sınıflandırılmasında başarıyı arttırdığı gösterilmiş olan transfer öğrenme kullanılmıştır. DenseNet121 ağından ESA


mimarisine transfer işlemi gerçekleştirilmiştir. DenseNet121 ağının sınıflandırıcı katmanının önüne 1024 proses elemanına sahip 2 tam bağlantılı katman eklenerek ESA mimarisi genişletilmiştir. Ağın ezberlemesini engellemek amaçlı bu katmanlarda 0,2 oranında dropout işlemi uygulanmıştır. Ayrıca, çalışmada ESA modeli ile elde edilen sonuçlar, ağı tam bağlantılı ilk katmanından elde edilen özneteliklerin giriş olarak kullanıldığı DVM, k-NN ve Bayes sınıflandırıcıları ile elde edilen sonuçları ile karşılaştırılmıştır. Şekil 4'te, önerilen mimarinin ayrıntıları verilmiştir. Bu kısımda, ESA mimarisinin ve DenseNet ağına ayrıntılarından bahsedilecektir.

### 2.2.1. Evrimsel Sinir Ağı (Convolutional Neural Network)

DL'de geri yayılım algoritması kullanılarak ağı sunulan büyük veri kümelerindeki karmaşık yapı keşfedilir. Bu algoritma, öndeki katmandaki temsilden elde edilen bilgilerin sonraki katmandaki gösterimini hesaplamada kullanılan parametrelerin nasıl değiştirileceğini belirler [11]. DL'nin temelini oluşturan geri beslemeli çok katmanlı ağlar (ÇKA), giriş verilerinin birden fazla temsil edildiği

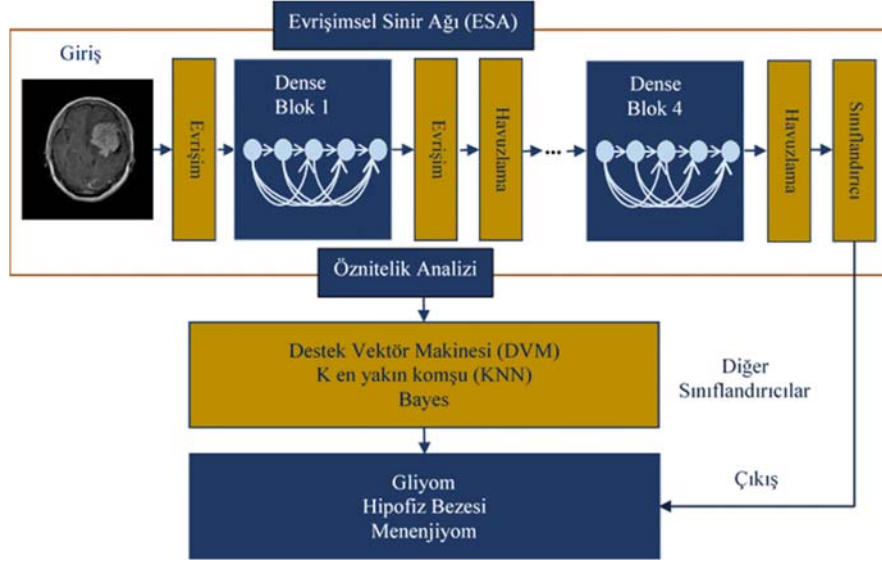


**Şekil 2.** Piksel-seviye dönüşüm teknikleri (a) orijinal görüntü (b) Gauss gürültüsü (c) bulanıklaştırma (d) parlaklaştırma (e) keskinleştirme (Pixel-level transformation (a) original image (b) Gaussian noise (c) blurring (d) brightness (e) sharpening)



**Şekil 3.** Veri çoğaltma teknikleri (a) orijinal görüntü (b) yatay çevirme (c) dikey çevirme (d) döndürme (e) bulanıklaştırma (f) gamma düzeltme (g) keskinleştirme

(Data augmentation (a) original image (b) horizontal flip (c) vertical flip (d) rotation (e) blurring (f) Gamma correction (g) sharpening)



Şekil 4. Önerilen modelin akış diyagramı (Flowchart of the proposed model)

katmanlarda nasıl öğrenme gerçekleştirildiğini gösteren ve hesaplama maliyeti verimli olan ilk modeldir. Giriş, çıkış ve aradaki gizli katmanlardan oluşan bu ağlarda,  $W$  ve  $B$  sırasıyla ağırlık ve bias kümesi olmak üzere  $\theta = \{W, B\}$  parametrelerini öğrenen en uygun fonksiyonu elde etmek için  $y = f(x; \theta)$  ile ağırlık girişleri çıkışlara haritalanır. Gizli katmanlardaki nöronlarda  $x$  girdisi ve parametrelerden elde edilen doğrusal bilgi, sigmoid ve hiperbolik tanjant gibi bir aktivasyon fonksiyonundan  $\sigma(w^T x + b)$  geçirilerek doğrusal olmayan hale getirilir. ÇKA'da Eş. 1'de verilen dönüşüm gerçekleştirilir [16].

$$f(x; \theta) = \sigma(W^T \sigma(W^T \dots \sigma(W^T x + b))) + b \quad (1)$$

Burada  $W$ ; çıkışa ait  $k$  aktivasyonu ile ilişkili  $w_k$ 'yi kapsayan matrisi ifade eder. Girişten ileri yönde yayılan bilgi ile çıktı katmanındaki sınıflar arasındaki dağılım  $P(y|x; \theta)$  softmax fonksiyonu ile Eş. 2'deki gibi hesaplanır [16].

$$P(y|x; \theta) = \text{softmax}(x; \theta) = \frac{e^{w_i^T x + b_i}}{\sum_{k=1}^K e^{w_k^T x + b_k}} \quad (2)$$

Burada,  $w_i$   $i$ . sınıfla ilişkili çıkış nöronundaki ağırlık vektörünü ifade etmektedir. Çok katmanlı modelde,  $\theta$  parametrelerini  $\mathcal{D}$  eğitim veri setine uydurmak için bir amaç fonksiyonu kullanılır. Amaç fonksiyonunu optimize etmek için literatürde en yaygın kullanılan olasılıksal eğitim iniş (SGD-Stochastic Gradient Descent) yönteminde, tam veri seti yerine verilerin küçük bir alt kümesi (mini-yığın) ile her iterasyonda gradyan güncellemesi gerçekleştirilir. Burada, maksimum olasılığı optimize etmek için negatif log-olasılığı Eş. 3'deki gibi hesaplanır [16].

$$\text{argmin}_{\theta} - \sum_{n=1}^N \log[P(y_n|x_n; \theta)] \quad (3)$$

ÇKA, etiketli eğitim verileri üzerinde sığ bir öğrenme yapar ve derin ağ tasarımlarında iyi çalışmazlar [11]. Bu sebeple, 1004

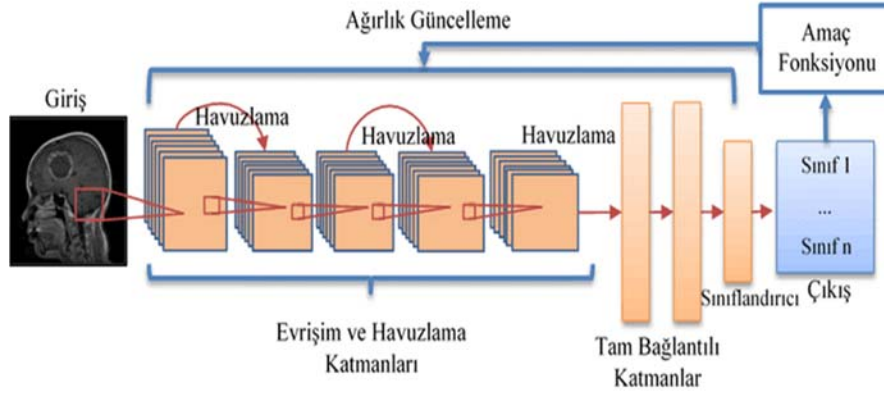
geliştirilen ilk derin ağ modeli olan ve çok katmanlı yapıya sahip ESA, tıbbi görüntülerin analizinde en çok kullanılan DL mimarisidir. Şekil 5'te görülen ESA; evrişim ve havuzlama katmanlarını içeren öznitelik katmanına ve ardından sınıflandırma işini yapan tam bağlantılı katmanlara sahiptir. ESA'nın ilk katmanı olan giriş katmanı aldığı 2B ya da 3B görüntüleri ağa ileri yönde dağıtır. Ağırlık parametre sayısı sadece giriş görüntü boyutuna bağlı değildir ve ağda çeşitli işlemlerle azaltılır [16].

ESA'nın evrişim (Convolution) katmanında, giriş katmanından gelen görüntü farklı kernel boyutlarında (2x2, 3x3, 5x5 vb.),  $K$  adet filtre ile konvolüsyon işlemine ( $W = \{W_1, W_2, \dots, W_K\}$ ) tabii tutulur ve üzerlerine bias değerleri  $B = \{b_1, b_2, \dots, b_K\}$  eklenir. Konvolüsyon katmanından çıkan değerler,  $l$  tane konvolüsyon katmanında tekrarlanmak üzere sigmoid, hiperbolik tanjant, düzeltilmiş doğrusal birim katmanı (ReLU: Rectified Linear Unit) gibi bir aktivasyon fonksiyonundan geçirilerek öznitelik haritaları elde edilir (Eş. 4), [11, 16, 22-23, 49-51].

$$X_k^l = \sigma(W_k^{l-1} * X^{l-1} + b_k^{l-1}) \quad (4)$$

Aktivasyon fonksiyonlarından gelen bilgi, havuzlama (pooling) katmanında kullanılan filtrelerde adım sayısı ile maksimum ya da ortalama gibi bir işlemle birlikte aşağıya örneklenir. Böylece ağırlık işlem yükü azaltılır. Konvolüsyon ve havuzlama işlemleri DL'de istenilen sayıda tekrarlanabilir. ESA'da havuzlama katmanından sonra öndeki tüm alanlara bağlanarak bilgiyi düzleştiren tam bağlantılı katman (Fully Connected Layer) kullanılır. Bu katmanlar farklı proses elemanlarıyla öndeki tam bağlantılı katmanın tüm elemanlarına bağlanarak tekrarlanabilir. Sınıflandırma (classification) katmanı ise ağırlık çıktıları softmax transfer fonksiyonu ile sınıflar üzerinde bir dağılım belirleyerek oluşturulur ve böylece ağ maksimum olasılıkla eğitilir [11, 16, 22-23, 49-51]. Şekil 5'te görüldüğü gibi ESA, katmanlar arasındaki ağırlıkların güncellenmesi ile





Şekil 5. ESA mimarisi (Architecture of CNN)

problemi anlar ve çıktı üretir. Bu sebeple ağır çıktısı ile gerçek çıktı arasındaki farktan hesaplanan hatayı geriye yayan amaç fonksiyonu, SGD, ADAM, kök ortalama kare yayılımı (RMSProp: Root Mean Square Propagation) gibi bir eniyileme yöntemi ile minimize edilir ve ağı tüm öğrenilebilir parametreleri güncellenerek ağı eğitimi tamamlanır. ESA'da ağı mimarisini şekillendiren hiper parametrelerin optimize edilmesi önemlidir. Her probleme özgü olarak konvolüsyon katman ve havuzlama işlem sayısı, filtre sayısı, kernel boyutları, adım sayısı, aktivasyon fonksiyon tipi dikkatlice belirlenmelidir. Yine tam bağlantılı katmandan sonra aşırı öğrenmeyi engelleme amaçlı dropout kullanılıp kullanılmayacağı ve sınıflandırma fonksiyonunun tipi çalışmalarda deneysel olarak belirlenir [11, 16, 22-23, 49-51].

### 2.2.2. DenseNet Ağı (Network of DenseNet)

Transfer öğrenmede kullanılan ESA tabanlı ağ mimarilerinin (AlexNet, VGG19, GoogLeNet, ResNet, DenseNet vb.) zamanla artan örnek sayısına paralel olarak katman sayısı da artmıştır. ImageNet için önerilen ilk LeNet ve AlexNet ağları sırasıyla 2 ve 5 evrişimli katmandan oluşmaktadır. 2014'te ImageNet yarışmasını kazanan 19 katmanlı VGG19 modelinde her katmanda küçük ve sabit boyutlu kerneller kullanılmıştır. Sonraki yıllarda önerilen daha derin ağ modelleri ile eğitim prosedürünün verimliliği artarken, parametre miktarını azaltan yapı taşları tanıtılmıştır. 22 katmanlı GoogLeNet, Eş 4'te tanımlanan eşlemeyi farklı boyutlarda bir dizi konvolüsyon ile değiştiren ve her bir işlevin daha az parametre ile temsil edilmesini sağlayan bir modül olan başlangıç (Inception) bloklarına sahiptir. 2015 yılında önerilen 100'ün üzerinde katmana sahip olan ResNet mimarisi ise artık (residual) bloklarından oluşur. Artık bloklarda, bir işlevi öğrenmek yerine yalnızca artık öğrenilir ve bu artık değerlerin diğer katmanları koşullandırması sağlanır [16]. ResNet'te derinliği azaltmak ve ağdaki bilgi akışını daha iyi sağlamak için eğitim katmanlarında rastgele düşürme (dropping) yapılıdır. ResNet ve DenseNet mimarileri derinleşen ağdaki unutma problemini çözmeye odaklanmışlardır. Bu yönüyle diğer transfer öğrenme mimarilerinden farklı bir konuma sahiptirler.

Bu çalışmada ESA mimarisine transfer edilen DenseNet ağında, katmanlar boyunca bilgi akışı farklı boyutlarda öznelik haritaları kullanılarak sağlanır. Eğitimdeki ileri besleme yapısı, her katmanın önceki katmanlardan ek bilgiler alması ve öznelik haritalarını sonraki katmanlara aktarması ile sağlanır [50-51]. DenseNet'te, ResNet ağındaki gibi bir katmandan diğerine öznelikler özetlenerek aktarılmaz, her katmanda önceki katmanlardan gelen bilgiler birleştirilir. DenseNet ağındaki  $\ell$ . katman kendinden önceki evrişim katmanlarından gelen özneliklere sahip  $\ell$  tane girişe sahiptir. Bu durum, her öznelik haritasının  $L - \ell$  tane alt bloğa bağlanmasına sebep olur. Klasik ağda  $L$  tane katman  $\ell$  tane bağlantıya sahipken, DenseNet ağında  $L(\ell + 1)/2$  adet bağlantı oluşmaktadır.

Bir evrişimsel ağa  $x_0$  görüntüsünün sunulduğunu farz edelim. Bu görüntü ağa ileri doğru sunularak her katmanda işleme tabii tutulur. Örneğin,  $L$  adet katmana sahip ağda,  $\ell$  indeksli her bir alt katman için  $H_\ell(\cdot)$  olarak sembolize edilen doğrusal olmayan bir dönüşüm gerçekleştirilir.  $H_\ell(\cdot)$  dönüşümü, yığın normalizasyon (BN:Batch Normalization), ReLU, havuzlama ve evrişim gibi işlemleri içerir [50, 51].

Geleneksel geri-beslemeli ESA'da  $\ell$ . katmanın ürettiği çıkış olan  $x_\ell$  aynı zamanda ilerdeki  $\ell + 1$ . katmanın girişidir. Katmanlar arasındaki bu geçiş,  $x_\ell = H_\ell(x_{\ell-1})$  genel formülü ile ifade edilir. ResNet ağında geleneksel ESA formülüne birim fonksiyonu ile birlikte doğrusal olmayan bir dönüşümü içeren geçiş bağlantısı eklenmektedir. Bu formül Eş. 5'te verilmiştir.

$$x_\ell = H_\ell(x_{\ell-1}) + x_{\ell-1} \quad (5)$$

ResNet'te kullanılan birim fonksiyonu katmanlar arasında gradyanın aktarılmasını sağlar. Ancak, birim fonksiyonu ve  $H_\ell$ 'nin çıkışının özetlenerek birleştirilmesi bu derin ağdaki bilgi akışını geciktirir. DenseNet ağında ResNet'teki mevcut bilgi akışı problemini gidermek için her bir katmanın diğer alt katmanlarla direkt bağlantı olduğu örüntü bağlantısı yaklaşımı kullanılmaktadır. Ağdaki  $\ell$ . katman, girişleri  $x_0, \dots, x_{\ell-1}$  olmak üzere, önceki katmanların öznelik haritalarını Eş. 6'daki gibi alır.

$$x_\ell = H_\ell([x_0, x_1, \dots, x_{\ell-1}]) \quad (6)$$

Eş. 6'daki  $H_\ell(\cdot)$  fonksiyonu farklı girişleri tek bir tensör halinde birleştiren bir fonksiyondur. Burada gerçekleşen işlemler BN, ReLU ve evrişimdir. ESA'da, özellik haritalarının boyutu evrişim katmanlarında aşağı örnekleme ile değiştirilir. DenseNet ağında aşağı örnekleme işlemini kolaylaştırmak için ağ blokları ayrılmıştır ve bloklar arasında BN, 1x1 evrişim ve 2x2 havuzlama katmanlarını içeren geçiş (transient) katmanı olarak adlandırılan katman kullanılmaktadır. DenseNet121 ağında bu özelliklere bağlı 4 dense blok yer almaktadır [50-51].

### 2.3. Karşılaştırma Yöntemleri (Comparison Methods)

Çalışmada beyin tümörlerinin sınıflandırılmasında kullanılan ESA, DVM, kNN ve Bayes sınıflandırıcılarının başarısı, test verisi üzerinde doğruluk oranı, duyarlılık, belirlilik, eğri altında kalan alan (AUC) ve Pearson korelasyon katsayısı ( $R$ ) ile belirlenmiştir.

Tıbbi testlerde elde edilen sonuçlar pozitif ya da negatif olarak ikiye ayrılır. Ardından, sınıflama tablosunda her sınıf için hesaplanan Doğru Pozitif ( $DP$ ), Yanlış Negatif ( $YN$ ), Doğru Negatif ( $DN$ ) ve Yanlış Pozitif ( $YP$ ) değerleri yerleştirilir. Buna göre  $DP$ , gerçek çıktı pozitif iken işlenen örneğin de pozitif bulunduğunu,  $YN$  ise çıktı pozitifken negatif sonuç elde edildiğini ifade eder.  $DN$ , gerçek çıktı negatifken negatif sonuç elde edildiğini,  $YP$  ise gerçek çıktı negatif iken pozitif sonuç elde edildiğini göstermektedir [52]. Sınıflama tablosunda yer alan  $DP$ ,  $YN$ ,  $DN$ ,  $YP$  değerleri ile belirlilik, duyarlılık, doğruluk oranı hesaplanarak, tıbbi sonuçların istatistiksel başarısı ortaya konur. Buna göre, belirlilik oranı (specificity-  $P(B)$ ) bir sınıflandırıcının gerçekten pozitif olmayanları ayırma başarısını değerlendirir. Duyarlılık oranı (sensitivity- $P(D)$ ) sınıflandırıcının gerçekten pozitif olanları tespit etme başarısını hesaplar. Doğruluk oranı ( $P(DO)$ ) bir sınıflandırıcının pozitif sonuçları pozitif, negatif olanları negatif olarak tespit etmesini değerlendirir. Bu formüller Eş. 7'de verilmiştir [52].

$$\begin{aligned} P(B) &= \frac{DN}{DN + YP} \\ P(D) &= \frac{DP}{DP + YN} \\ P(DO) &= \frac{DP+DN}{DP+DN+YP+YN} \end{aligned} \quad (7)$$

Pearson korelasyon katsayısı ( $R$ ) bağımsız değişkenler arasındaki bağlantıyı ifade etmek için kullanılır. Buna göre, gerçek tümör sınıfları ( $x$ ) ile sınıflandırıcıların elde ettiği sonuçlar ( $y$ ) arasındaki ilişkiyi gösteren  $R$  değeri Eş. 8 ile hesaplanır.

$$R = \frac{\sum(x-\bar{x})(y-\bar{y})}{\sqrt{\sum(x-\bar{x})^2}\sqrt{\sum(y-\bar{y})^2}} \quad (8)$$

Eş. 8' deki  $\bar{x}$  gerçek tümör sınıflarının ortalaması ve  $\bar{y}$  sınıflandırıcının elde ettiği tümör sınıflarının ortalamasıdır.

$R$ , +1 ile -1 arasında bir değer alır. +1 değeri pozitif doğrusal korelasyonu, 0 korelasyon olmadığını ve -1 ise negatif doğrusal korelasyonu ifade etmektedir.

### 3. DENEYSEL SONUÇLAR VE TARTIŞMA (EXPERIMENTAL RESULTS AND DISCUSSION)

Çalışmada 128x128x3 çözünürlükte T1A MR görüntülerinden oluşturulan ham ve çoğaltılmış veriler ile, DenseNet121 ağından öğrenme transfer edilen ESA eğitilmiş ve ardından test edilmiştir. Eğitim deneylerinde öğrenme katsayısı (learning rate) 0,001, eğitim dönem (epoch) sayısı 30, yığın boyutu (batch size) 16 olarak ayarlanmıştır. Tüm deneyler 5 çaprazlama korelasyon değeri ile tekrarlanmıştır. Ağın ağırlıklarının güncellenmesinde RMSProp eniyileme yöntemi kullanılmıştır.

Çalışmada Tablo 1'de sayıları verilen aksiyel, koronel ve sagittal kesitleri birbirlerinden ayrılarak ağa sunulmuştur. Temelde amaç hangi kesitin (aksiyel, koronel ve sagittal) tümörün sınıflandırılmasında etkin olduğunu belirleyebilmektir. Tablo 2'de farklı kesitler ile eğitilip test edilen ağların elde ettiği sonuçların minimum, maksimum ve ortalama performans değerleri verilmiştir. Buna göre ham veri setindeki aksiyel kesitlerin ortalama duyarlılık, belirlilik, doğruluk ve AUC değerleri sırasıyla  $0,86 \pm 0,103$ ,  $0,938 \pm 0,046$ ,  $0,919 \pm 0,055$  ve  $0,899 \pm 0,075$ 'dur. Veri çoğaltma uygulanan aksiyel kesitlerin aynı değerleri ise sırasıyla  $0,976 \pm 0,011$ ,  $0,988 \pm 0,008$ ,  $0,982 \pm 0,014$  ve  $0,982 \pm 0,009$  olarak elde edilmiştir. Koronel kesitlerin duyarlılık, belirlilik, doğruluk ve AUC değerleri sırasıyla  $0,899 \pm 0,059$ ,  $0,950 \pm 0,028$ ,  $0,935 \pm 0,030$ ,  $0,925 \pm 0,044$  olarak hesaplanmıştır. Çoğaltılan koronel kesitlerin aynı değerleri sırasıyla  $0,985 \pm 0,010$ ,  $0,993 \pm 0,004$ ,  $0,991 \pm 0,006$ ,  $0,989 \pm 0,007$ 'dur. Sagittal kesitlerin duyarlılık, belirlilik, doğruluk ve AUC değerleri sırasıyla  $0,884 \pm 0,060$ ,  $0,944 \pm 0,029$ ,  $0,925 \pm 0,041$ ,  $0,914 \pm 0,044$  olarak hesaplanmıştır. Çoğaltılan sagittal kesitlerin aynı değerleri sırasıyla  $0,972 \pm 0,010$ ,  $0,987 \pm 0,005$ ,  $0,984 \pm 0,005$ ,  $0,979 \pm 0,007$ 'dir.

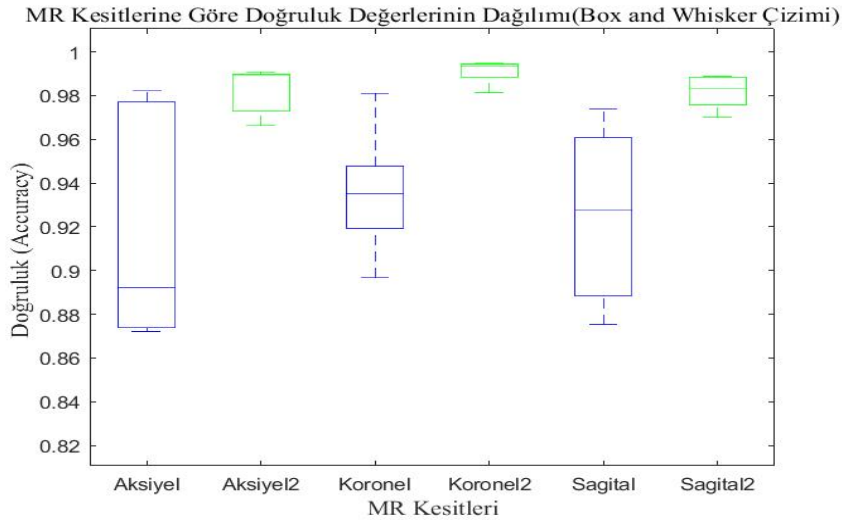
Şekil 6'da tüm MR kesitlerinin veri çoğaltma öncesi ve sonrasında 5 kez çapraz-doğrulama ile elde edilen doğruluk değerlerinin kutu dağılım grafiği verilmiştir. Buna göre veri çoğaltma sonrasında tüm doğruluk değerleri arasındaki minimum-maksimum aralığı azalmıştır. Ayrıca, Tablo2'den de görüldüğü üzere standart sapma değerleri de veri çoğaltma sonrası azalmıştır. Buna göre, daha az veri ile eğitilen ve test edilen DL mimarisi, k kez çapraz doğrulamada daha kararsız sonuçlar elde etmiştir ve aynı mimari veri çoğaltma sonrası daha kararlı hale gelmiştir.

Tüm kesitlere ait  $R$  değeri sonuçları ise Şekil 7'de verilmiştir. Buna göre, aksiyel kesitler ile eğitilen ağların veri çoğaltma sonrasında ortalama  $R$  değerleri  $0,814 \pm 0,126$ 'ten  $0,958 \pm 0,030$ 'e yükselmiştir. Veri çoğaltma, koronel kesitlerle eğitilen ağın  $R$  değerlerini  $0,854 \pm 0,069$ 'ten  $0,978 \pm 0,014$ 'e yükseltmiştir. Benzer şekilde, sagittal kesitlerle eğitilen ESA ağının ortalama  $R$  değeri

**Tablo 2.** ESA mimarisi ile eğitilen veri setlerinin sınıflandırma sonuçları (Classification results of CNN trained with dataset)

Veri Seti	Dilimler	Duyarlılık				Belirlilik				Doğruluk				AUC			
		Min	Mak.	Ort.	SS*	Min	Mak.	Ort.	SS*	Min	Mak.	Ort.	SS*	Min	Mak.	Ort.	SS*
Veriseti-1	Aksiyel	0,704	0,963	0,860	0,103	0,874	0,986	0,938	0,046	0,872	0,982	0,919	0,055	0,789	0,975	0,899	0,075
	Koronal	0,812	0,976	0,899	0,059	0,909	0,988	0,950	0,028	0,897	0,981	0,935	0,030	0,861	0,982	0,925	0,044
	Sagital	0,819	0,960	0,884	0,060	0,915	0,980	0,944	0,029	0,875	0,974	0,925	0,041	0,868	0,970	0,914	0,044
Veriseti-2	Aksiyel2	0,964	0,983	0,976	0,011	0,978	0,993	0,988	0,008	0,966	0,991	0,982	0,014	0,971	0,988	0,982	0,009
	Koronal2	0,971	0,992	0,985	0,010	0,987	0,996	0,993	0,004	0,981	0,995	0,991	0,006	0,979	0,994	0,989	0,007
	Sagital2	0,959	0,982	0,972	0,010	0,981	0,991	0,987	0,005	0,978	0,989	0,984	0,005	0,970	0,986	0,979	0,007

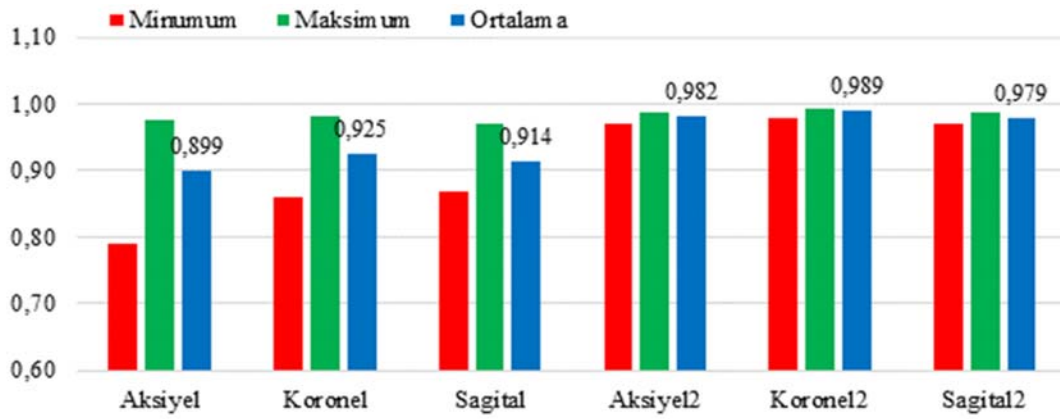
SS\*=Standart Sapma

**Şekil 6.** MR kesitlerinin veri çoğaltma öncesi ve sonrası 5 kez çapraz-doğrulama ile elde edilen doğruluk değerlerinin dağılımı (Distribution of accuracy values of MR slices obtained before and after data augmentation by 5 times cross-validation)

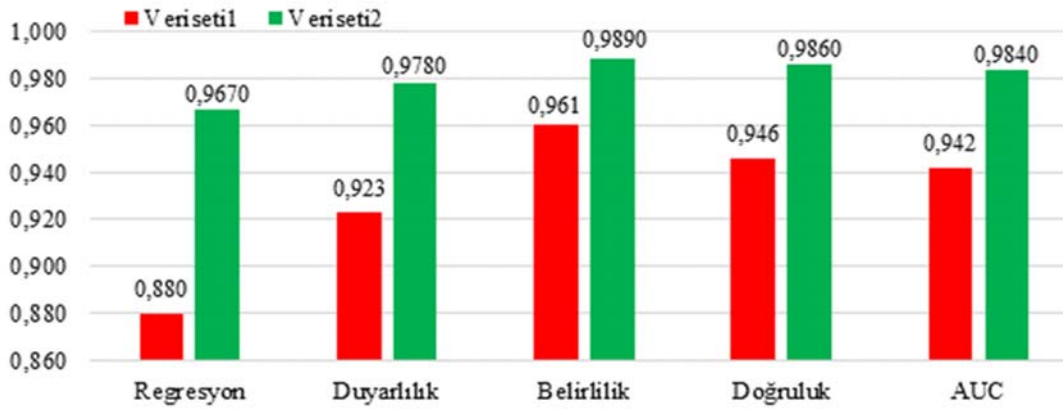
öncesinde  $0,835 \pm 0,085$  iken çoğaltılan veri ile eğitildikten sonra  $0,964 \pm 0,011$  olarak elde edilmiştir. Tablo 2 ve Şekil 7'den yola çıkarak beyin tümör sınıflandırmada koronal kesitler ile daha yüksek performans değerleri elde edilmiştir. Buna göre MR kesitlerinin tümör sınıflandırma için önem sıralaması koronal, aksiyel ve sagital şeklindedir. Şekil 8'de tüm MR dilimlerini içeren ham veriseti ile bunlardan çoğaltılan görüntüleri içeren verisetinin ESA mimarisi ile eğitilip test edilmesi sonucunda elde edilen performans sonuçları verilmiştir. Buna göre ham verisetinin R değerleri çoğaltma sonrasında  $0,880$ 'den  $0,967$ 'e yükselmiştir. Duyarlılık değeri iki veriseti için sırasıyla  $0,923$  ile  $0,978$ 'dir. Belirlilik değeri verisetleri için sırasıyla  $0,961$  ile  $0,989$ 'dir. Doğruluk değeri ilk veriseti için  $0,946$  iken, ikinci veriseti için  $0,986$  olarak elde edilmiştir. AUC değeri ise çoğaltma sonrası  $0,942$ 'den  $0,984$ 'e yükselmiştir. Buna göre, tüm MR kesitleri ağa sunulduğunda ayrı kesitlerle eğitilen ESA modellerine göre daha yüksek sonuçlar elde etmiştir. Benzer şekilde, çoğaltma yapılan veriseti ile beyin tümör sınıflandırma sonuçları koronal kesitleri ile eğitilen ağa göre daha yüksek performans sonuçları elde etmiştir.

### 3.1. Diğer Sınıflandırıcıların Elde Ettiği Sonuçlar (Obtained Results of the Other Classifiers)

Bu çalışmada aksiyel, koronal ve sagital MR kesitlerini içeren ve çoğaltılan görüntülerle eğitilen ESA modeli, DVM, kNN ve Bayes sınıflandırıcıları ile karşılaştırılmıştır. ESA'nın tam bağlantılı ilk katmanından elde edilen öznetelikler diğer sınıflandırıcıların girişi olarak kullanılmıştır. Bayes sınıflandırıcısının belirlilik, duyarlılık, doğruluk ve AUC değerleri sırasıyla  $0,949$ ,  $0,909$ ,  $0,893$  ve  $0,519$  olarak elde edilmiştir. Pearson korelasyon katsayısı değeri ise  $0,7903$ 'tür. kNN sınıflandırıcısında k en yakın komşu değeri 1 ile 200 arasında değerlendirilmiştir. Tablo 3'te, 5 farklı k değeri ile elde edilen en yüksek performans sonuçları sıralanarak verilmiştir. k değeri 50 iken kNN sınıflandırıcısının AUC, R, belirlilik, duyarlılık ve doğruluk değerleri sırasıyla  $0,607$ ,  $0,989$ ,  $0,995$ ,  $0,989$  ve  $0,991$  olarak elde edilmiştir. Tablo 3'de DVM sınıflandırıcı için farklı kernel fonksiyonlarıyla (rbf, doğrusal, Gaussian ve çok terimli) yapılan analizlerin sonuçları görülmektedir. Çok terimli kernel kullanan DVM sınıflandırıcısı ile test seti



Şekil 7. Farklı MR kesitleri ile eğitilen ağların Pearson korelasyon katsayısı değerleri  
(Correlation coefficient values of the trained network with different MR slices)



Şekil 8. Tüm MR dilimleri ile eğitilen ağların sonuçları (Results of trained network with all MR slices)

Tablo 3. Sınıflandırıcıların test seti ile elde ettiği performans sonuçları  
(Performance results of the classifiers with test dataset)

Sınıflandırıcılar	R	Belirlilik	Duyarlılık	Doğruluk	AUC	
Bayes	0,7903	0,9492	0,9090	0,8933	0,5190	
DVM	RBF	0,9948	0,9960	0,9985	0,9979	0,9972
	Gaussian	0,9949	0,9961	0,9985	0,9978	0,9971
	Doğrusal	0,9929	0,9843	0,9881	0,9871	0,9962
	Çok terimli	0,9949	0,9959	0,9986	0,9979	0,9972
	kNN	0,9890	0,9952	0,9888	0,9907	0,6066
kNN	k=60	0,9881	0,9949	0,9879	0,9900	0,6070
	k=10	0,9811	0,9926	0,9831	0,9859	0,6092
	k=90	0,9801	0,9922	0,9822	0,9850	0,6098
	k=105	0,9796	0,9921	0,9819	0,9848	0,6103
ESA	0,9670	0,9890	0,9780	0,9860	0,9840	

üzerinde ortalama R, belirlilik, duyarlılık, doğruluk ve AUC değerleri sırasıyla 0,995, 0,996, 0,999, 0,998 ve 0,997 olarak hesaplanmıştır. Şekil 8 ve Tablo 3'te görüleceği üzere bu çalışmada önerilen DenseNet121 ağı ile öğrenme transfer edilen ESA mimarisinin elde ettiği R, belirlilik, duyarlılık, doğruluk ve AUC değerleri sırasıyla 0,967, 0,978, 0,986 ve 0,984'tür.

### 3.2. Literatür Karşılaştırması ve Tartışma (Literature Comparison and Discussion)

Bu çalışmada, figshare veriseti üzerinde 3 farklı beyin tümörünü sınıflandırmak için DL mimarisi kullanılmıştır. Tablo 4'te literatürde figshare verisetini kullanarak DL tabanlı sınıflandırıcı geliştiren çalışmalar ile bu çalışmada

**Tablo 4.** Literatür karşılaştırması (Literature Comparison)

Çalışma	Öznitelik Seçimi	Sınıflandırıcı	Ön Eğitim	Veri Çoğaltma	Test Seti Doğruluk
	-	ESA	GoogleNet	Hayır	0,9230
Deepak vd. [33]	ESA	DVM			0,9780
	ESA	kNN			0,9800
Cheng vd. [34]	Kelime çantası	DVM	-	Evet	0,9110
Ismael vd. [35]	Gabor filtreleme + ADD	YSA	-	Hayır	0,9190
Pashaei vd. [36]	ESA	KELM	-	-	0,9370
Abiwinanda vd. [37]	-	ESA	-	-	0,8420
Afshar vd. [38]	-	CapsNet	-	-	0,9090
Badza vd. [39]	-	ESA	-	Evet	0,9660
Gungen vd. [49]	-	ESA	-	-	0,9775
	-	ESA	DenseNet121	Evet	0,9860
Önerilen Yöntem	ESA	DVM			0,9979
	ESA	kNN			0,9907
	ESA	Bayes			0,8933

önerdiğimiz yöntemin karşılaştırılması verilmiştir. Bu çalışmaların hepsinde figshare verisetinde yer alan 3041 adet T1A MR görüntülerinin tamamı kullanılmıştır. Ayrıca Bölüm 1'den de ilgili çalışmaların detayları incelenebilir. Buna göre, transfer öğrenme kullanmayan ve veri çoğaltma yapmayan standart bir ESA mimarisinin test seti üzerindeki doğruluğu 0,8420 olarak elde edilmiştir [37]. Gungen vd. [49] dört evrişim katmanı içeren ESA mimarisi ile yine transfer öğrenme ve veri çoğaltma yapmadan 0,9775 doğruluk değeri elde etmiştir. GoogleNet'ten öğrenme transfer eden ESA mimarisi ise beyin tümör sınıflandırma başarısını 0,9230 olarak hesaplamıştır [33]. Aynı çalışmada ESA'dan elde edilen öznitelikler, DVM ve kNN ile kullanıldığında doğruluk oranları sırasıyla 0,9780 ve 0,9800 olarak bulunmuştur. Benzer şekilde, transfer öğrenme dışında figshare veriseti üzerinde veri çoğaltma uygulamak sınıflandırıcıların doğruluk oranını pozitif yönde artırmıştır. Cheng vd. [34] veri çoğaltma sonrası kelime çantası ile seçtikleri öznitelikleri DVM ile sınıflandırdıklarında 0,9110 doğruluk değeri elde etmişlerdir. Ayrıca, Badza vd. [39] veri çoğaltma sonrası eğittikleri ESA'nın test seti doğruluğunu 0,9660 olarak bulmuştur. Tablo 4'te görüldüğü gibi ESA'dan elde edilen öznitelikler ile eğitilen sınıflandırıcıların [33, 36] başarısı, standart öznitelik analizi kullanan yöntemlere [34, 35] göre daha yüksektir.

Bu çalışmada ise hem veri çoğaltma hem de transfer öğrenme kullanılarak ESA mimarisi eğitilmiştir. Literatürdeki çalışmalara benzer şekilde veri çoğaltma işlemi ESA'nın doğruluk değerini 0,946'dan 0,986'a, R değerlerini 0,880'den 0,967'e yükseltmiştir. ESA'nın tam bağlantılı katmanlarından alınan öznitelikler ile eğitilen DVM, kNN ve Bayes sınıflandırıcılarının doğruluk değeri sırasıyla 0,9979, 0,9907 ve 0,8933 olarak, R değerleri ise sırasıyla 0,995, 0,989, 0,790 olarak hesaplanmıştır. Tablo 4'te görüldüğü gibi, bu çalışmada geliştirilen ESA mimarisinin DenseNet121 ağından transfer edilmesi ve veri çoğaltma tekniklerinin kullanılması sebepleri ile elde edilen performans değerleri literatür ile kıyaslandığında daha yüksektir. Ayrıca çalışmada hangi MR kesitinin tümör sınıflandırmada daha etkin olduğu da ortaya konulmuştur. Tablo 2 ve Şekil 6'a göre T1A koronel kesit, aksiyel ve

sagittal kesitlere göre beyin tümör sınıfının tespitinde daha etkilidir.

#### 4. SONUÇLAR (CONCLUSIONS)

Son yıllarda araştırmacılar, beyin tümörlerinin yerlerinin ve tipinin belirlenmesi için MR görüntüleri üzerinde DL yöntemlerinden faydalanmaktadır. Yüksek doğrulukla çalışan tıbbi görüntü bölütleyiciler ya da sınıflandırıcılar, uzmanları tanı ve tedavide desteklemektedir. Bu sebeple, bu çalışmada figshare veriseti üzerinde bulunan T1A MR görüntülerinden üç farklı beyin tümörünün (gliyom, menenjiyom ve hipofiz bezi tümörü) sınıflandırılması için DL yönteminden faydalanılmıştır. Veri çoğaltma ve DenseNet121 ağı ile transfer öğrenme aracılığıyla desteklenen ESA farklı MR kesitleri (aksiyel, koronel, sagittal) ile önce ayrı ayrı ardından tüm kesitlerle toplu olarak eğitilmiştir. Çalışmada, ESA mimarisinin test seti üzerindeki başarısı belirlilik, duyarlılık, doğruluk, AUC ve Pearson korelasyon katsayısı ile tespit edilmiştir. Yapılan eğitim ve test deneyleri neticesinde, beyin koronel kesitinin tümör sınıflandırmada daha etkin görüldüğü görülmüştür. Ayrıca, tüm MR kesitleriyle eğitilen ESA daha yüksek başarı göstermiştir. Çalışmada, ESA'nın tam bağlantılı ilk katmanından alınan öznitelikler, DVM, kNN ve Bayes gibi sınıflandırıcıların girişi olarak kullanılmıştır. Literatüre paralel şekilde, ESA'dan elde edilen öznitelikler ile beslenen bu sınıflandırıcıların başarısı yükselmiştir. Test veriseti üzerindeki performans analizleri sonucunda, çalışmada eğitilen ESA tabanlı DVM yöntemi literatürdeki benzer çalışmalara göre beyin tümörü sınıflandırılmasında daha yüksek başarı elde etmiştir.

Gelecekte, figshare verisetinde bulunan MR görüntülerdeki tümörlerden yola çıkarak sentetik veri çoğaltma teknikleri ile yeni tümör görüntülerinin elde edilmesi ve bunların DL ile sınıflandırılması üzerine çalışılabilir.

#### KAYNAKLAR (REFERENCES)

1. Tiwari, A., Srivastava, S., Pant, M., Brain tumor segmentation and classification from magnetic

- resonance images: Review of selected methods from 2014 to 2019. *Pattern Recognition Letters*, 131, 244-260, 2020.
2. Liu, J., Pan, Y., Li, M., Chen, Z., Tang, L., Lu, C., Wang, J., Applications of Deep Learning to MRI Images: A Survey, *Big Data Mining and Analytics*, 1 (1), 1-18, 2018.
  3. Internet: Manyetik Rezonans (MR), [http:// www.tumrad.net/FileUpload/ds58732/File/manyetik\\_rezonans\\_goruntuleme\\_mrg .pdf](http://www.tumrad.net/FileUpload/ds58732/File/manyetik_rezonans_goruntuleme_mrg.pdf). Erişim tarihi Kasım 17, 2020.
  4. Gordillo, N., Montseny, E., Sobrevillac, P., State of the art survey on MRI brain tumor segmentation. *Magnetic Resonance Imaging*, 31 (8), 1426-1438, 2013.
  5. Smistad, E., Falch, T.L, Bozorgi, M., Elster, A.C., Lindseth, F., Medical image segmentation on GPUs-A comprehensive review, *Medical Image Analysis*. 20 (1), 1-18, 2015.
  6. Amin, J., Sharif, M., Yasmin, M., Fernandes, S.L., A distinctive approach in brain tumor detection and classification using MRI, *Pattern Recognit. Lett.*, 1-10, 2017.
  7. Nabiyev, V.V., *Yapay Zeka-Problemler-Yöntemler-Algoritma*, Seçkin Yayıncılık, Ankara, 34-100, 2005.
  8. Elmas, Ç., *Yapay Sinir Ağları*, Seçkin Yayınevi, Ankara, 21-65, 2003.
  9. Haykin, S., *Neural networks: a comprehensive foundation*, Prentice Hall, USA, 1-50, 117-156,156-256, 1999.
  10. Fausett, L., *Fundamentals of neural networks: Architectures, Algorithms and Applications*, Prentice-Hall, USA, 1-100, 1994.
  11. LeCun, Y., Bengio, Y., Hinton, G.E., *Deep Learning Nature*, 521, 436-444, 2015.
  12. Hinton, G.E., Osindero, S., Teh, Y.-W., A fast learning algorithm for deep belief nets. *Neural Computation*, 18 (7), 1527-1554, 2006.
  13. Hinton, G.E., Learning multiple layers of representation, *Trends Cogn. Sci.*, 11 (10), 428-434, 2007.
  14. Bengio, Y., LeCun, Y., *Scaling learning algorithms towards AI*. MIT Press, 2007.
  15. Krizhevsky, A., Sutskever, I., Hinton, G.E., ImageNet classification with deep convolutional neural networks. *NIPS'12 Proceedings of the 25th International Conference on Neural Information Processing Systems*, 1, 1097-1105, 2012.
  16. Litjens, G., Kooi, T., Bejnordi, B.-E., Adiyoso Setio, A.A., Ciompi, F., Ghafoorian, M., Laak, J.-A.W.M., Ginneken, B., Sanchez, C.I., A survey on deep learning in medical image analysis, *Medical Image Analysis*, 42, 60-88, 2017.
  17. Liu, J., Pan, Y., Li, M., Chen, Z., Tang, L., Lu, C., Wang, J., Applications of Deep Learning to MRI Images: A Survey, *Big Data Mining And Analytics*, 1 (1), 1-18, 2018.
  18. Liu, S.Q., Liu, S.D., Cai, W.D., Pujol, S., Kikinis, R., Feng, D.G., Early diagnosis of Alzheimer's disease with deep learning. in *Proc. 2014 IEEE 11th Int. Symposium on Biomedical Imaging (ISBI)*, Beijing, China, 1015-1018, 2014.
  19. Zaharchuk, G., Gong, E., Wintermark, M., Rubin, D., Langlotz, C.P., *Deep Learning in Neuroradiology, AJNR Am. J. Neuroradiol.*, 39 (10), 1776-1784, 2018.
  20. Yapıcı, M., Tekerek, A., Topaloğlu, N., Literature Review of Deep Learning Research Areas, *Gazi Journal of Engineering Sciences (GJES)*, 5 (3), 188-215, 2019.
  21. Vieira, S., Pinaya, W.H.L., Mechelli, A., Using deep learning to investigate the neuroimaging correlates of psychiatric and neurological disorders: Methods and applications, *Neuroscience and Biobehavioral Reviews*, 74, 58-75, 2017.
  22. Yamashita, R., Nishio, M., Do, R.K.G., Togashi, K., Convolutional neural networks: an overview and application in radiology, *Insights Imaging*, 9, 611-629, 2018.
  23. Gu, J., Wang, Z., Kuen, J., Ma, L., Shahroudy, A., Shuai, B., Liu, T., Wang, X., Wang, G., Cai, J., Chen, T., Recent advances in convolutional neural networks, *Pattern Recognition*, 77, 354-377, 2018.
  24. Mazurowski, M.A., Buda, M., Saha, A., Bashir, M.R., Deep learning in radiology: an overview of the concepts and a survey of the state of the art. *arXiv:1802.08717*, 2018.
  25. Zhang, W.L., Li, R.J., Deng, H.T., Wang, L., Lin, W.L., Ji, S.W., Shen, D.G., Deep convolutional Neural networks for multi-modality isointense infant brain image segmentation, *NeuroImage*, 108, 214-224, 2015.
  26. Suk, H.I., Lee, S.W, Shen, D.G., Hierarchical feature representation and multimodal fusion with deep learning for AD/MCI diagnosis, *NeuroImage*, 101, 569-582, 2014.
  27. Pereira, S., Pinto, A., Alves, V., Silva, C.A., Brain tumor segmentation using convolutional neural networks in MRI images, *IEEE Trans. Med. Imaging*, 35 (5), 1240-1251, 2016.
  28. Bulut, F., Kılıç, İ., İnce, İ.F, Beyin tümörü tespitinde görüntü bölütleme yöntemlerine ait başarımların karşılaştırılması ve analizi, *Dokuz Eylül Üniversitesi Mühendislik Fakültesi Fen ve Mühendislik Dergisi*, 20 (58), 173-186, 2018.
  29. Kebir, S.T., Mekaoui, S., An efficient methodology of brain abnormalities detection using CNN deep learning network, in: *international Conference on Applied Smart Systems (ICASS)*, Medea, Algeria, 1-5, 2018.
  30. Talo, M., Baloglu, U.B., Yıldırım, Ö., Acharya, U.R., Application of deep transfer learning for automated brain abnormality classification using MR images, *Cognit. Syst. Res.*, 54, 176-188, 2019.
  31. Arı A., Hanbay D., Tumor detection in MR images of regional convolutional neural networks, *Journal of the Faculty of Engineering & Architecture of Gazi University*, 34 (3), 1395-1408, 2019.
  32. Figshare brain tumor dataset. [https://figshare.com/articles/brain\\_tumor\\_dataset/1512427](https://figshare.com/articles/brain_tumor_dataset/1512427). Erişim tarihi Kasım 17, 2020.
  33. Deepak, S., Ameer, P.M., Brain tumor classification using deep CNN features via transfer learning, *Comput. Biol. Med.*, 111, 103345, 1-7, 2019.

34. Cheng, J., Huang, W., Cao, S., Yang, R., Yang, W., Yun, Z., Feng, Q., Enhanced performance of brain tumor classification via tumor region augmentation and partition, *PLoS One*, 10 (10), e0140381, 2015.
35. Ismael, M.R., Abdel-Qader, I., Brain tumor classification via statistical features and back-propagation neural network, *IEEE International Conference on Electro/Information Technology, EIT*, 0252-0257, 2018.
36. Pashaie, A., Sajedi, H., Jazayeri, N., Brain tumor classification via convolutional neural network and extreme learning machines, *IEEE 8th International Conference on Computer and Knowledge Engineering, ICCKE*, 314-319, 2018.
37. Abiwinanda, N., Hanif, M., Hesaputra, S.T., Handayani, A., Mengko, T.R., Brain tumor classification using convolutional neural network, *Springer World Congress on Medical Physics and Biomedical Engineering*, 183-189, 2018.
38. Afshar, P., Plataniotis, K.N., Mohammadi, A., Capsule networks for brain tumor classification based on MRI images and course tumor boundaries, *IEEE International Conference on Acoustics, Speech and Signal Processing, ICASSP*, 1368-1372, 2019.
39. Badža, M.M., Barjaktarović, M.C., Classification of Brain Tumors from MRI Images Using a Convolutional Neural Network, *Applied Sciences*, 10 (6), 1999, 1-13, 2020.
40. Bhanothu, Y., Kamalakannan, A., Rajamanickam, G., Detection and Classification of Brain Tumor in MRI Images using Deep Convolutional Network, *2020 6th International Conference on Advanced Computing and Communication Systems (ICACCS)*, 00, 248-252, 2020.
41. Nalepa, J., Marcinkiewicz, M., Kawulok, M., Data Augmentation for Brain-Tumor Segmentation: A Review, *Frontiers in Computational Neuroscience*, 13 (83), 1-18, 2019.
42. Bulut F., A new clinical decision support system with instance based ensemble classifiers, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 32 (1), 65-76, 2017.
43. Çelik, G., Talu, M.F., Çekişmeli üretken ağ modellerinin görüntü üretme performanslarının incelenmesi, *BAUN Fen Bil. Enst. Dergisi*, 22 (1), 181-192, 2020.
44. Yia, X., Walia, E., Babyn, P., Generative adversarial network in medical imaging: A review, *Medical Image Analysis*, 58, 101552, 2019.
45. Frid-Adar, M., Diamant, I., Klang, E., Amitai, M., Goldberger, J., Greenspan, H., GAN-based Synthetic Medical Image Augmentation for increased CNN Performance in Liver Lesion Classification, *arXiv:1803.01229*, 2018.
46. Iqbal, T., Ali, H., Generative Adversarial Network for Medical Images (MI-GAN), *Journal of Medical Systems* 42, 231, 2018.
47. Kazuhiro, K., Werner, R.A., Toriumi, F., Javadi, M.S., Pomper, M.G., Solnes, L.B., Verde, F., Higuchi, T., Ro, S.P., Generative Adversarial Networks for the Creation of Realistic Artificial Brain Magnetic Resonance Images, 4 (4), 159-163, 2018.
48. Armanious, K., Jiang, C., Fischer, M., Küstner, T., Hepp, T., Nikolaou, K., Gatidis, S., Yang, B., MedGAN: Medical image translation using GANs, *Computerized Medical Imaging and Graphics*, 79, 101684, 1-13, 2020.
49. Gungen, C., Polat, O., Karakis, R., Evrişimsel Sinir Ağı Kullanılarak MR Görüntülerinden Beyin Tümörlerinin Sınıflandırılması, *The 28th IEEE Conference on Signal Processing And Communications Applications, Gaziantep*, 2020.
50. Huang, G., Liu, Z., Maaten, L. van der, Weinberger, K.Q., Densely Connected Convolutional Networks, *arXiv:1608.06993*, 2017.
51. Huang, G., Liu, Z., Pleiss, G., Maaten, L. van der, Weinberger, K.Q. Convolutional Networks with Dense Connectivity, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 1-12, 2019.
52. Karakis, R., Tez, M., Kılıç, Y.A., Kuru, B., Guler, I., A genetic algorithm model based on artificial neural network for prediction of the axillary lymph node status in breast cancer, *Engineering Applications of Artificial Intelligence*, 26 (3), 945-950, 2013.

