

<b>IDUNAS</b>	<b>NATURAL &amp; APPLIED SCIENCES JOURNAL</b>	2021 Volume:3 Special Issue, No:5
---------------	---	--

## **Beyin Manyetik Rezonans Görüntülerindeki Tümörlü Dilimlerin Özellik Mühendisliği ile Optimize Edilen Transfer Öğrenmesiyle Tespiti**

Salih Çelik<sup>1\*</sup> , Ömer Kasım<sup>1\*</sup> 

<sup>1</sup> Dumlupınar Üniversitesi, Teknoloji Fakültesi, Elektrik-Elektronik Mühendisliği Bölümü, Kütahya, Türkiye.

Author E-mails

msalihhcelikk@gmail.com

\*Correspondance to: Salih Çelik, Dumlupınar Üniversitesi, Teknoloji Fakültesi, Elektrik-Elektronik Mühendisliği Bölümü, Kütahya, Türkiye.

### Özet

Bilgisayar destekli tanı (BDT), uzmanlara klinik süreçteki anormalliklerin tespitinde destek olmaktadır. Tümör, kontrolsüz hücre bölünmesi ile büyüyen bir yapı olarak, anormal bir durumdur. Tıbbi görüntü elde etmek için birçok yöntem vardır. Bunlardan başlıca olanları; Bilgisayarlı tomografi, pozitron emisyonlu tomografi, tek foton emisyonlu bilgisayarlı tomografi, manyetik rezonans görüntüleme (MRG)'dir. BDT alanında en çok çalışma yapılan alanların başında MRG gelmektedir. MRG dilimler halinde elde edildiğinden uzmanların bu görüntüleri incelemesi zaman alıcı olmaktadır. Derin öğrenme modellerinden olan transfer öğrenmesi, görüntüdeki özelliklerin doğrudan elde edilmesini sağlamaktadır. Bu motivasyonla, çalışmada özellik mühendisliği ile transfer öğrenmesi algoritmalarından olan Resnet50 ve Alexnet, Relieff ve Komşuluk Temel Bileşen Analizi algoritmaları ile optimize edilmiştir. Çalışmada veri seti olarak Rembrandt veri seti kullanılmıştır. Bu veri setinde 130 hastaya ait 610 adet axial bölge MRG kullanılarak altı farklı transfer öğrenmesi modeli üzerinde en başarılı modeli belirlemek amacı ile performans analizi yapılmıştır. 610 adet görüntünün %60'ı (366 adet MR görüntüsü) eğitim için kullanılmıştır. Geri kalan %20'si ise doğrulama ve kalan %20'si ise test için kullanılmıştır. Yapılan deneylerde Alexnet ve SVM kullanıldığında 0,28 saniyede MRG dilimi analiz edilmiştir. Başarı ise %95,9 olarak hesaplanmıştır. Alexnet, komşuluk temel bileşen analizi ve SVM birlikte kullanıldığında tümörlü dilim 0,36 saniyede belirlenmiştir. Başarı %95 olarak hesaplanmıştır. Resnet50 ağı ile SVM kullanıldığında tümörlü dilim 0,30 saniyede belirlenmiştir. Başarı ise %93 olarak bulunmuştur. Resnet50, Relieff ve SVM kullandığında süre 0,318 saniyeye çıkmıştır. Başarı ise %96'ya yükselmiştir. Resnet50 komşuluk temel

bileşen analizi ve SVM kullanıldığında 0,31 saniyede tümörlü dilim tespit edilmiştir. Başarı ise %96 olarak bulunmuştur. En optimize sonuç ise Alexnet Relieff ve SVM'nin birlikte kullanılmasıyla elde edilmiştir. Bu yöntemlerin birlikte kullanılmasıyla analiz süresi 0.27 saniye ve başarı %98,4 olarak hesaplanmıştır. Alexnet (SVM) modeline Relieff özellik seçme algoritması uygulanarak başarı oranı %4 oranda artarak %98,4'e yükselmiş; sistemin test edilmesi için geçen süre ise 0.01 saniye azalarak 0,27 saniyeye gerilemiştir. Önerilen yöntemin beyin tümörünü sınıflandırma konusunda etkili olduğu için, geliştirilecek bilgisayar destekli tespit sistemlerinde uzmana destek mahiyetinde kullanılabileceği ön görülmektedir.

**Anahtar Kelimeler:** Transfer Öğrenmesi, Özellik Mühendisliği, Beyin Manyetik Rezonans Görüntüleme.

### Abstract

Computer-aided diagnosis (CBT) supports experts in detecting abnormalities in the clinical process. A tumor is an abnormal condition as a structure that grows by uncontrolled cell division. There are many methods to obtain medical images. The main ones are; Computed tomography, positron emission tomography, single photon emission computed tomography, magnetic resonance imaging (MRI). MRI is one of the most studied areas in the field of CIS. Since MRI is obtained in slices, it is time-consuming for experts to examine these images. Transfer learning, which is one of the deep learning models, enables the features in the image to be obtained directly. With this motivation, Resnet50 and Alexnet, which are feature engineering and transfer learning algorithms, were optimized with Relieff and Neighborhood Principal Component Analysis algorithms. Rembrandt data set was used as the data set in the study. In this data set, performance analysis was performed to determine the most successful model on six different transfer learning models using 610 axial region MRIs of 130 patients. 60% of 610 images (366 MR images) were used for training. The remaining 20% was used for verification and the remaining 20% for testing. In the experiments, when Alexnet and SVM were used, MRI slices were analyzed in 0.28 seconds. Success was calculated as 95.9%. When Alexnet, neighborhood principal component analysis and SVM were used in combination, the tumor slice was determined in 0.36 seconds. Success was calculated as 95%. Using SVM with the Resnet50 network, the tumor slice was detected at 0.30 seconds. Success was found to be 93%. When using Resnet50, Relieff and SVM, the time increased to 0.318 seconds. Success has increased to 96%. Using the Resnet50 neighborhood principal component analysis and SVM, tumor slices were detected in 0.31 seconds. Success was found to be 96%. The most optimized result was obtained by using Alexnet Relieff and SVM together. By using these methods together, analysis time was calculated as 0.27 seconds and success was calculated as 98.4%. By applying the Relieff feature selection algorithm to the Alexnet (SVM) model, the success rate increased by 4% to 98.4%; the time taken to test the system decreased by 0.01 seconds to 0.27 seconds. Since the proposed method is effective in classifying brain tumors, it is anticipated that it can be used to support the expert in computer-aided detection systems to be developed.

**Keywords:** Transfer Learning, Feature Engineering, Brain Magnetic Resonance Imaging.

## 1. GİRİŞ

Bilgisayar Destekli Tespit Sistemleri (BDT) MR görüntülerinden (MRG) beyin tümörlerini tespit etmede sıkça kullanılmaktadır. Uzmanların direkt olarak MRG'leri incelemekte olduğu manuel tespit sistemlerinde, görüntülerdeki tümör uzman tarafından tespit edilerek, tümörün büyüklüğüne, yapısına ve türüne göre tedavi planlanmaktadır. Manuel incelemeler, direkt olarak uzman hekimin tecrübesine ve yorumlamasına bağlı olduğu için erken teşhis ve teşhisin güvenilirliği açısından problemlidir. Bunlara ek olarak belirli bir büyüklüğün altındaki tümörler de teşhis sırasında gözden kaçabilmektedir. Arakeri ve arkadaşlarının yaptığı çalışmada, radyologlar tarafından yapılan doğru teşhis başarısının %75 oranında olduğu vurgulanmaktadır. Bu sebeple doktorlar ve radyologların özellikle tümörlü MRG dilimlerini yüksek başarı ile tespit edebilecek bir BDT sisteme ihtiyaç duymaktadır.

Bu çalışmada, beyin MR görüntülerindeki dilimlerin sınıflandırılmasında derin öğrenme tabanlı bir bilgisayar destekli tespit sistemi geliştirilmiştir. Çalışmada transfer öğrenmesi algoritmalarından olan Resnet50 ve Alexnet, Relieff ve Komşuluk Bileşen Analizi (NCA) algoritmaları ile optimize edilmiştir. Veri seti olarak REMRANDT veri seti kullanılmıştır [1]. Bu veri setinde bulunan 130 hastaya ait 610 adet axial bölge sağlıklı ve tümörlü MRG kullanılarak altı farklı transfer öğrenmesi modeli üzerinde en başarılı modeli belirlemek amacı ile performans analizi yapılmıştır Yapılan deneylerde; sağlıklı ve tümörlü sınıflara ait öznelikler, Alexnet ve Resnet50 modelleri ile elde edilmiştir.

Deneysel sonuçlarda elde edilen en başarılı sistem ise; Alexnet, Relieff ve SVM'nin birlikte kullanıldığı sistem olarak saptanmıştır. Alexnet ve SVM modeline, Relieff özellik seçme algoritması entegre edilerek oluşturulan bu sınıflandırma sisteminde başarı oranı; %98,4; sınıflandırma süresi ise 0,2851 saniye olarak elde edilmiştir.

Geliştirilen modelde, diğer akademik çalışmalardan farklı olarak, Alexnet transfer öğrenmesi ve SVM metodunun kullanıldığı sınıflandırma sistemi, Relieff özellik seçme algoritması kullanılarak optimize edilerek hibrit bir sınıflandırma algoritması ortaya konulmuştur. Geliştirilen model ile elde edilen MRG sınıflandırma sonucu uzmana sunulurken, uzmanın, sadece patolojik birer bulgu olan MR görüntülerinde, tümörlü bölgenin yerini en doğru ve kısa sürede tespit etmesi amaçlanmıştır. Bu sayede; yüksek başarı oranında ve kısa sürede tespit edilip sınıflandırılan MR görüntüleri ile tümör teşhisinde zaman kazanarak, gözden kaçabilecek durumlar ortadan kaldırılıp, erken teşhis sürecine katkıda bulunulması hedeflenmiştir.

## 2. İLGİLİ ÇALIŞMALAR

MRG tümörlerin varlığını veya özelliklerini belirlemek için doktorlar tarafından yaygın olarak kullanılmaktadır [2]. Tümör teşhis süresi ve sınıflandırılma doğruluğu doktorun deneyimine ve bilgisine

bağlıdır [3]. Bu nedenle, otomatik ve kusursuz çalışan bir tümör tespit sistemi kullanmak, uzmana yardımcı olmak için son derece önemlidir. Bu sebeple son yıllarda bu alanda çok sayıda çalışma yapılmıştır. Sompong ve arkadaşları tarafından yapılan çalışmada [4], hibrit bir sistem olarak bulanık c-ortalama kümeleme algoritması ve hücresel otomat temelli beyin tümörü bölütleme yöntemi sunulmuştur. Performans değerlendirmesi için Brats2013 veri kümesi kullanılan çalışmada, öz nitelik çıkarımı için gri seviye ortak oluşum matrisi (GLCM) ve geleneksel segmentasyon algoritmaları kullanılmıştır.

Muhammed Nazir ve arkadaşları beyin MRG'lerini öncelikle filtreleyerek gürültüden temizlemişlerdir. Daha sonra, her görüntünün ortalama renk momenti üzerindeki öz niteliklerini elde etmişlerdir. Çıkarılan özellikleri yapay sinir ağı (YSA) ile sınıflandırmışlardır. Çalışmalarında sınıflandırma başarı oranı %91.8 olarak elde edilmiştir [5]. Muhammed Sajjad ve ark. Yaptıkları çalışmada beyin tümörünün sınıflandırılması için öncelikle MRG'lerden bölütleme ile tümör bölgesi seçilmiştir. Daha sonra, önerilen Evrişimsel Sinir Ağı (CNN) modeli ile sınıflandırma işlemi gerçekleştirilmiştir. Sınıflandırmadaki başarı %94.58 olarak elde edilmiştir [6].

Kanmani ve diğerleri MRG'leri sınıflandırmak için eşik tabanlı bölge optimizasyonu (TBRO) yöntemini kullanmışlardır. TBRO ile yapılan segmentasyon işlemi sonrasında başarı oranı %96.57 olarak elde edilmiştir [7].

Praveen ve arkadaşları MRG'den tümör tespiti için çok aşamalı bir yaklaşım önermişlerdir. Bu yaklaşımın ilk adımı, görüntü filtrelemeyi içermektedir. Bu işlem sırasıyla görüntü kırpmaya, ölçekleme ve histogram eşitleme yöntemlerini içermektedir. Daha sonra özellik çıkarma işlemi, GLCM kullanılarak yapılmıştır. Ön işleme adımından sonra tümörlü görüntüler Rastgele Orman yöntemiyle sınıflandırılmıştır. Değerlendirmede toplam 120 hasta verisi kullanılmış ve geliştirilen modelin sınıflandırma doğruluğu %87,62 olarak saptanmıştır [8].

İbrahim ve arkadaşları tarafından yapılan çalışmada MR görüntüleri, CNN kullanılarak sınıflandırılmıştır. Eğitim verileri olarak CIPR veri tabanındaki veriler kullanılmıştır. Geliştirilen modelde kullanılan her bir görüntünün boyutu 3x58'dir. Elde edilen sonuçlar ile birlikte, Sınıflandırma doğruluğu % 96.33 olarak ortaya konmuştur [9].

Shiu Kumar ve diğerleri beyin tümörlerinin sınıflandırılmasında uzun kısa süreli bellek (LSTM) ağı ve makine öğrenme yöntemleri kullanmışlardır. Çalışmalarında en iyi sınıflandırma başarıları %78.33 olarak elde edilmiştir [10].

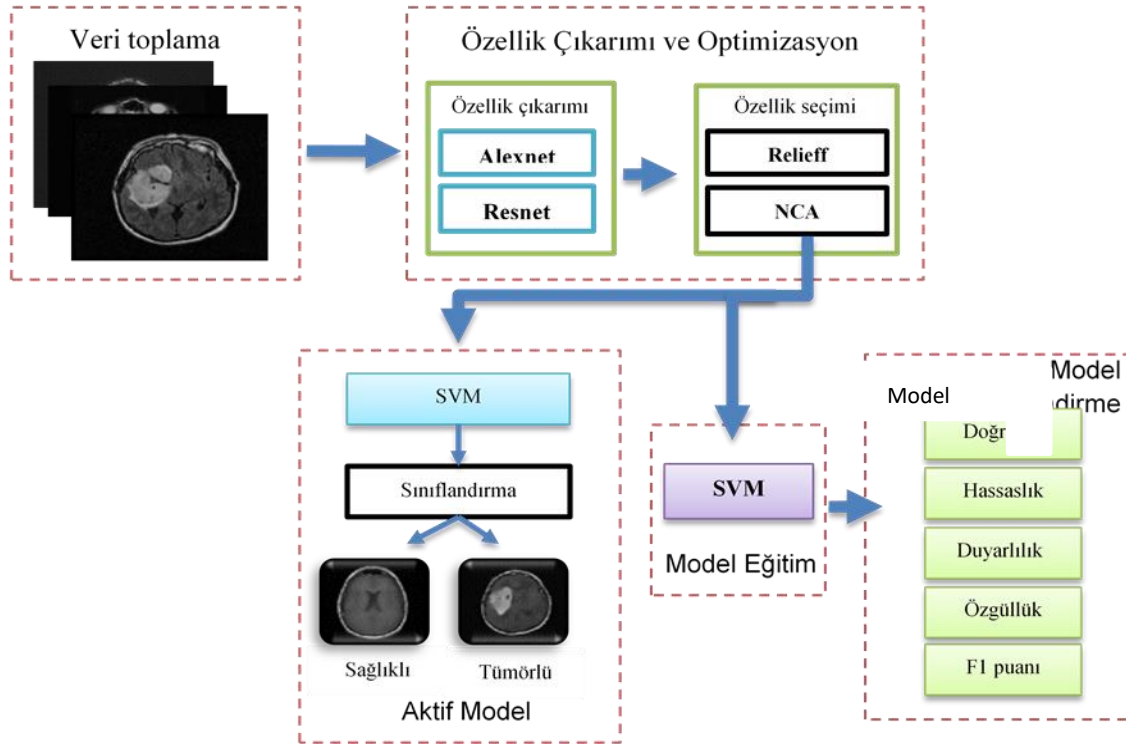
Yalçın ve Razavi, önerdikleri CNN modeli ile bitkileri sınıflandırmışlardır. Önerilen mimari 5 katmanlı konvülsiyon ve 3 tam bağlantı katmanlarından oluşmaktadır. Modellerde önceden eğitilmiş bir ağ kullanılmaktadır. Elde edilen sonuçlara göre önerilen model %97.04 oranında bir başarıya ulaşmıştır [11].

Önerilen yöntemde ise 610 adet axial bölge beyin MRG'leri sağlıklı ve tümörlü olmak üzere sınıflandırılmak istenmiştir. Bu sebeple kullanılan Alexnet ve Resnet50 transfer algoritmalarına entegre edilen Relieff ve NCA özellik seçme algoritmaları sayesinde altı farklı sınıflandırma sistemi modeli oluşturulmuş, sistemlerin başarımlarına ait performans analizi yapılmıştır. Elde edilen sonuçlara göre Alexnet transfer öğrenmesi algoritmasının, Relieff özellik seçme algoritması ile optimize edilmesiyle

oluşturulan sistem en başarılı model olarak saptanmıştır. Bu modelde sınıflandırıcı olarak SVM kullanılmıştır. Sisteme ait başarı oranı %98,4 olarak saptanmıştır. Test için harcanan süre ise 0,28 saniye olarak tespit edilmiştir.

### 3. MATERYAL VE YÖNTEM


BDT sistemleri, özellikle medikal alanda birçok uygulama için görüntü anlama, özellik çıkarma, analiz ve yorumlamada önemli bir rol oynar. Tıp biliminde doku sınıflandırması, tümörlerin lokalizasyonu, tümör hacmi tahmini, kan hücrelerinin tanımlanması, cerrahi planlama ve görüntü kaydı gibi yaygın uygulamalara sahiptir. Bu çalışmada kullanılan Alexnet ve Resnet50 transfer öğrenmesi algoritmaları, Relieff ve NCA özellik seçim algoritmaları kullanılarak optimize edilmiş ve MRG'ler sağlıklı ve tümörlü olmak üzere sınıflandırılarak sonuçlar karşılaştırılmıştır. Çalışmanın akış diyagramı şekil 1'de verilmiştir.



Şekil 1. Çalışmaya ait akış diyagramı.

MR görüntülerini içeren veri seti, iki farklı yöntem olan AlexNet ve Resnet50 modelinde kullanılmaktadır. Her bir modelde öncelik olarak, AlexNet ve Resnet50 modellerinden elde edilen öznelik vektörleri ile sınıflandırma işlemleri gerçekleştirilmiştir. Sınıflandırıcı olarak her modelde SVM sınıflandırıcısı kullanılmıştır. Ardından elde edilen öznelik vektörleri öncelikle Relieff, ardından NCA özellik seçme algoritmalarına uygulanarak, ortaya çıkan sınıflandırma sonuçları karşılaştırılmıştır.

Çalışmada kullanılan veri seti, literatürde kullanılan ve bilimsel araştırmalara açık National Institutes of Health (NIH) kanser görüntüleme arşivinde bulunan Rembrandt veri setinden elde edilmiştir. Şekil 2’de veri setine ait örnek görüntüler verilmiştir.



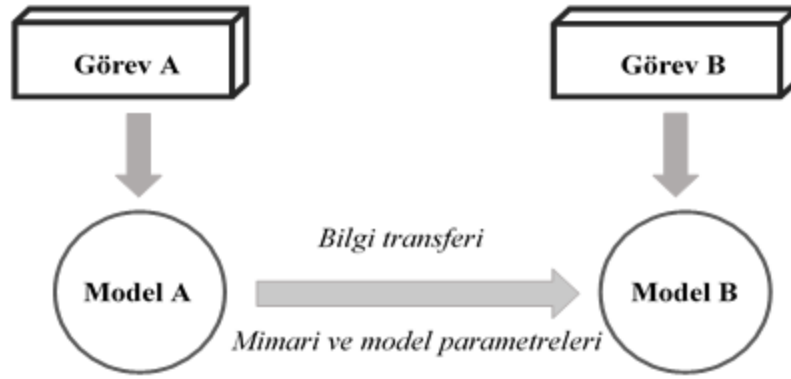
**Şekil 2.** Çalışmada kullanılan veri setine ait sağlıklı (a) ve tümörlü (b) beyin MR görüntüleri.

Veri setinde 130 hastaya ait 610 adet (295 sağlıklı ve 315 tümörlü) aksiyal bölge beyin MRG’si bulunmaktadır. MRG verileri, hold-out yöntemi ile %60’ı eğitim (366 adet MR görüntüsü), %20’si doğrulama (122 adet MR görüntüsü) ve %20’si test (122 adet MR görüntüsü) olmak üzere rastgele bölünmüştür. Özellikle test için kullanılacak verilerin, daha önce sistemin karşılaşmadığı veriler olmasına dikkat edilmiş, bu sayede geliştirilen derin öğrenme modellerinde ortaya çıkacak overfitting (ezberleme) ihtimali ortadan kaldırılmıştır.

### **Çalışmada Kullanılan Derin Öğrenme Mimarileri ve Optimizasyon Algoritmaları** **Alexnet ve Resnet50 Transfer Öğrenimi Algoritmaları**

Transfer öğrenmesi (Transfer Learning), daha önceden bir problem çözümü için eğitilen derin öğrenme modelinin, temel yapısını koruyarak; yeni bir problem için uyarlanmasını inceleyen öğrenme yaklaşımıdır. Gerçek hayatta bir insan karşısına çıkan bir problemin çözümü için nasıl geçmiş tecrübelerinden yardım alıyorsa, transfer öğrenmesi de temelde insanın bu yeteneğini taklit etme amacıyla ortaya çıkmıştır. Şekil 3’de transfer öğrenmesine ait akış şeması verilmiştir.






Şekil 3. Transfer öğrenimi akış diyagramı.

Şekil 3’de gösterildiği gibi, transfer öğrenmenin geleneksel makine öğrenme algoritmalarından farkı; bir problemi çözmek için, daha önce benzer problemi çözmeye kullanılan mimariden kazanılan bilgiler kullanılır. Çalışmada daha önceden özellikle sınıflandırma problemleri için eğitilmiş ve başarılı sonuçlar elde etmiş; Alexnet ve Resnet50 transfer öğrenme algoritmaları kullanılmıştır.

### Alexnet Transfer Öğrenimi Algoritması

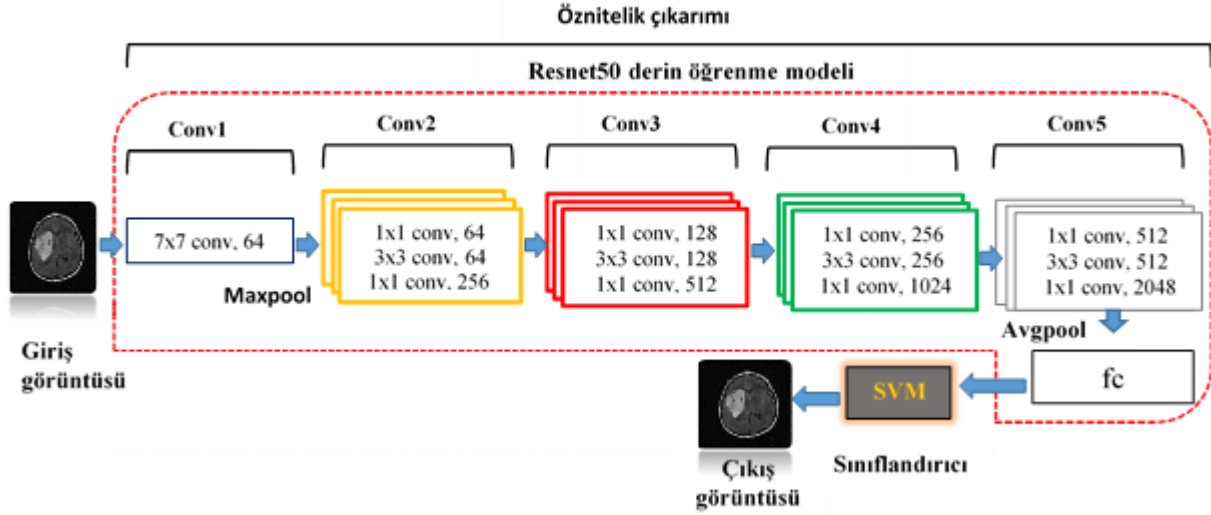
Alexnet, Krizhevsky ve arkadaşları tarafından 2012 yılında oluşturulmuştur. Görüntü sınıflandırma alanında kullanılan ilk büyük ölçekli derin ağ modelidir. Diğer derin öğrenme modellerinin aksine, bu mimaride; konvolüsyon ve havuzlama katmanları paralel olarak birbirine bağlı modüller şeklinde kullanılmıştır. Bu sayede katmanları yığılabilir ve çok sayıda filtre ekleyerek meydana gelen mimarilerde ortaya çıkan bellek maliyetlerinin önüne geçilmiştir [12]. Alexnet ILSVRC 2012’de ImageNet veri setinde %16.4’lük ilk 5 hata oranı ile en başarılı sonucu elde etmiştir. Şekil 4’de AlexNet’in ağ mimarisi verilmiştir.



Şekil 4. Alexnet’in ağ mimarisi.

## Resnet50 Transfer Öğrenimi Algoritması

Çalışmada kullanılan ResNet50 [13] şuna kadarki tüm mimarilerden daha derin olarak tasarlanan bir mimaridir. 152 katmandan oluşmaktadır. Bu mimari Residual bloklardan oluşmaktadır. Şekil 5'te Resnet50 derin öğrenme modeline ait ağ mimarisi verilmiştir.



Şekil 5. Resnet50 derin öğrenme modeli ağ mimarisi

## Relieff ve NCA Özellik Seçme Algoritmaları

Özellik seçimi kısaca, bir sınıfa ait olan ve derin öğrenme modelleri ile elde edilen özelliklerin alt kümesini oluşturarak, temel özellik vektörüne eşdeğer ve daha işlevsel, boyut olarak daha küçük bir öznitelik vektörünün oluşturulmasıdır. Özellik seçim algoritmaları genel olarak; filtre tipi, sarıcı tip ve gömülü tip olmak üzere üç farklı türe sahiptir. Bu çalışmada kullanılan Relieff ve NCA özellik seçim algoritmaları filtre tipi özellik seçim algoritmasıdır.

*Relieff* özellik seçim algoritması, yanıtı tahmin etmek için gözlemler arasında çift mesafeler kullanan, mesafeye dayalı denetimli modeller için, özellik önemini tahmin etmekte en iyi sonucu verir [14]. Bu algoritma,  $y$  çok sınıflı kategori içeren bir değişken olduğu durumda; özellik belirleyicilerinin ağırlıklarını bulur. Algoritma, aynı sınıfa ait komşu değişkenlere farklı değerler atayan tahminçileri devre dışı bırakır. Buna karşılık farklı sınıflara ait değişkenlere farklı değerler atayan tahminçileri ise eğitime dahil eder.

*Komşuluk bileşeni analizi (NCA)* özellik seçim algoritması, regresyon ve sınıflandırma algoritmalarının tahmin doğruluğunu en üst düzeye çıkarmak amacıyla özellikleri seçmek için parametrik olmayan bir yöntemdir.



Bu çalışmada, Alexnet ve Resnet50 derin öğrenme ağlarından elde edilen öznelik vektörlerine uygulanacak özellik seçim algoritmaları olarak, özellikle gürültülü görüntülerdeki yüksek başarıları göz önüne alınmasından dolayı Relieff ve NCA algoritmaları uygun görülmüştür (Kononenko ve Igor, 1994). Bu sayede tahmin performansını iyileştirmek ve daha hızlı bir sonuç elde edebilmek amaçlanmıştır.

## SVM ile Sınıflandırma

Önerilen modelde sınıflandırıcı olarak SVM(Support Vector Machine) kullanılmıştır. SVM sınıflandırma konusunda kullanılan oldukça etkili ve basit yöntemlerden birisidir. Sınıflandırma için bir düzlemde bulunan iki grup arasında bir sınır çizilerek iki grubu ayırmak mümkündür. Bu sınırın çizileceği yer ise iki grubun da üyelerine en uzak olan yer olmalıdır. İşte SVM bu sınırın nasıl çizileceğini belirler. SVM'ler hiçbir parametre almayan sınıflayıcıdır. Dağılım hakkında herhangi bir ön bilgi veya varsayım yoktur. Eğitim setlerinde girdi ve çıktılar eşlenir. Eşler aracılığıyla test setlerinde ve yeni veri setlerinde girdi değişkenini sınıflayacak karar fonksiyonları elde edilir.

## Çalışmada Geliştirilen Derin Öğrenme Modellerinin Test Edilmesi

Derin öğrenme modellerinin eğitiminde kullanılan veri setlerinin kaliteli, çeşitli, geniş ve sayısal anlamda yeterli olması; ağ başarımını doğrudan etkilemektedir. Geliştirilen modelin güvenilirliği, probleme uygun seçilen derin öğrenme modelinin eğitilmesi ve ardından eğitilen modelin test edilmesi ile ölçülebilmektedir. Test işlemleri sonucunda elde edilen başarı oranları, hem modelin güvenilirliği hem de eğitilen modelde var olan temel problemler hakkında kullanıcıya bilgi aktarabilmektedir.

Geliştirilen modelde, test seti içinde bulunan görüntülerin sistemin daha önce hiç karşılaşmadığı görüntülerden oluşmasına dikkat edilerek, ezberleme (overfitting) ihtimalinin ortadan kaldırılması hedeflenmiştir. Bu sebeple derin öğrenme modellerinde kullanılacak olan veri seti hold-out yöntemi ile eğitim, doğrulama ve test olmak üzere 3'e ayrılmıştır. Test işlemleri sonucunda modellerin performanslarını karşılaştırmak için karmaşıklık matrisleri kullanılmıştır.

Karmaşıklık matrisleri, sınıflandırma modellerinin performans temsilidir. Matris, test edilen verilerin gerçek sonuçlara kıyasla doğru veya yanlış sınıflandırılmış veri sayısını gösterir. Karmaşıklık matrisini değerlendirme aracı olarak kullanmanın avantajlarından birisi de daha ayrıntılı analizlere izin vermesidir. Çalışmada elde edilen karmaşıklık matrisleri 2x2 şeklindedir. Burada 2 sınıf sayısını belirtmektedir. Elde edilen test sonuçlarına ait karmaşıklık matrisleri şekil 6'da verilmiştir.

Çıktı sınıfı	Hedef sınıf			Çıktı sınıfı	Hedef sınıf			Çıktı sınıfı	Hedef sınıf		
	Sağlıklı	Tümörlü			Sağlıklı	Tümörlü			Sağlıklı	Tümörlü	
Sağlıklı	57 %46,7	4 %3,3	%93,4 %6,6	Sağlıklı	58 %47,5	1 %0,8	%98,3 %1,7	Sağlıklı	58 %47,5	3 %2,5	%95,1 %4,9
Tümörlü	2 %1,6	59 %48,4	%96,6 %3,3	Tümörlü	1 %0,8	62 %50,8	%98,4 %1,6	Tümörlü	1 %0,8	60 %49,2	%98,4 %1,6
	%96,6 %3,4	%93,7 %6,3	%95,1 %4,9		%98,3 %1,7	%98,3 %1,6	%98,4 %1,6		%98,3 %1,7	%95,2 %4,8	%96,7 %3,3
Sağlıklı	Tümörlü		Sağlıklı	Tümörlü		Sağlıklı	Tümörlü				
Alexnet (SVM)			Alexnet (Relieff+SVM)			Alexnet (NCA+SVM)					
Çıktı sınıfı	Hedef sınıf			Çıktı sınıfı	Hedef sınıf			Çıktı sınıfı	Hedef sınıf		
Sağlıklı	57 %46,7	4 %3,3	%93,4 %6,6	Sağlıklı	57 %46,7	2 %1,6	%96,6 %3,4	Sağlıklı	57 %46,7	4 %3,3	%93,4 %6,6
Tümörlü	2 %1,6	59 %48,4	%96,6 %3,3	Tümörlü	2 %1,6	61 %50,0	%96,8 %3,2	Tümörlü	2 %1,6	59 %48,4	%96,6 %3,3
	%96,6 %3,4	%93,7 %6,3	%95,1 %4,9		%96,6 %3,4	%96,8 %3,2	%96,7 %3,3		%96,6 %3,4	%93,7 %6,3	%95,1 %4,9
Sağlıklı	Tümörlü		Sağlıklı	Tümörlü		Sağlıklı	Tümörlü				
Resnet50 (SVM)			Resnet50 (Relieff+SVM)			Resnet50 (NCA+SVM)					

Şekil 6. Deneysel çalışmalara ait elde edilen karmaşıklık matrisleri.

Şekil 6 da verildiği gibi, altı farklı transfer öğrenmesi modelinin sınıflandırma performansları karşılaştırılmıştır. Elde edilen sonuçlara göre en başarılı model Alexnet (Relieff+SVM) modeli olarak saptanmıştır. Modele ait başarılı sınıflandırma oranı %98,4 olarak elde edilmiştir. Bu sonuçlar ile birlikte Alexnet derin öğrenme modelinin Relieff özellik seçme algoritması ile optimize edilerek elde edilen başarı oranı, temel Alexnet transfer öğrenimi algoritması ve SVM kullanılarak sınıflandırılması ile elde edilen başarı oranından yaklaşık %3,5 daha başarılı bir sınıflandırma elde edilmiştir. Çizelge 1’de çalışmalara ait doğrulama değerleri ve test süreleri verilmiştir.

**Çizelge 1.** Elde edilen deneysel sonuçlara ait doğrulama değerleri ve test süreleri.

	Dışarıda tutma (Hold-out)	Çapraz doğrulama (Cross-validation)	Test süresi (Saniye)
Alexnet(SVM)	0,959	0,9481	0,3204
Alexnet(Relieff+SVM)	0,9754	0,9757	0,2851
Alexnet(NCA+SVM)	0,9672	0,959	0,3337
Resnet50(SVM)	0,9486	0,9309	0,5769
Resnet50(Relieff+SVM)	0,9672	0,9372	0,3124
Resnet50(NCA+SVM)	0,9508	0,9563	0,3614

Çizelge 1’de verildiği gibi, deneysel sonuçlar ile birlikte, test işlemleri için geçen süreler göz önünde bulundurulduğunda en başarılı model Alexnet (Relieff+SVM) olarak belirlenmiştir. Modele ait test için geçen süre 0,2851 saniyedir.

#### 4. SONUÇLAR VE TARTIŞMA

Bu çalışmada geliştirilen derin öğrenme tabanlı sınıflandırma sistemi ile literatür çalışmaları da incelendiğinde başarılı ve hızlı bir sistem önerilmiştir. Mevcut transfer öğrenmesi algoritmalarından olan Alexnet ve Resnet50 modelleri, Relieff ve NCA özellik seçme algoritmaları ile optimize edilmiştir. Optimize edilen modellerden elde edilen özellik vektörleri soft-max katmanı yerine SVM sınıflandırıcısına uygulanmış ve sonuçlar karşılaştırılmıştır. Altı farklı deneysel sonuca ait elde edilen sonuçlar karmaşıklık matrisleri ve onlara bağlı değişkenler ile değerlendirilip analiz edilmiştir. Ortaya çıkan deneysel sonuçlar ile birlikte optimizasyon işlemi özellikle Alexnet transfer öğrenimi algoritması ve Relieff özellik seçme algoritmasının birlikte kullanıldığı model ile en başarılı sonuç elde edilmiştir.

Özellik optimizasyon işlemi gerçekleştirilen derin öğrenme modelinden elde edilen öznelikler SVM sınıflandırıcısı kullanılarak sınıflandırılmıştır. Sisteme ait başarımlar temel Alexnet ve SVM modeline göre yaklaşık %3,5 artarak %98,4’e yükselmiş; test işlemi için geçen süre ise yaklaşık 0.04 saniye kısalarak

0.28 saniyeye gerilemiştir. Çizelge 2’de literatürde yapılan çalışmalara ait örnekler ve önerilen yöntemin karşılaştırılması verilmiştir.

**Çizelge 2.** Literatürde yapılan çalışmalar ve başarı oranları.

Çalışma	Kullanılan Metodoloji	Kullanıcı etkileşim düzeyi	Tümör algılama başarısı
Muhammed nazir vd.	Yapay sinir ağları	Otomatik	%91,8
Kanmani vd.	Eşik tabanlı bölge optimizasyonu	Otomatik	%96,57
Praveen vd.	GLCM ve Rastgele orman	Otomatik	%87,62
İbrahim vd.	CNN	Otomatik	%96,33
Shiu Kumar	LSTM	Otomatik	%78,33
Yalçın ve Razavi	CNN	Otomatik	%97,04
Önerilen yöntem	Alexnet ve Relieff özellik seçme algoritması	Otomatik	%98,4

Çizelge 2’de verilen çalışmaları ile birlikte özellikle derin öğrenme modelleri ile önerilen yöntemin karşılaştırıldığında; geliştirilen modelin başarısı görülmektedir.

Bu sonuçlar ile birlikte geliştirilen sistem, uzmana MRG dilimlerini incelemede ve yorumlamada destek olabilecek bir sistemdir. İleride geliştirilecek BDT sistemlerinde kullanılarak yüksek başarı oranı ve düşük hızda teşhisi ile birlikte uzmana yardımcı olarak hem tedavinin doğru planlanması hem de erken teşhis konusunda oluşabilecek zaman kayıplarının önüne geçilmesi öngörülmektedir.

## 5. KAYNAKLAR

1. Clark K, Vendt B, Smith K, Freymann J, Kirby J, Koppel P, Moore S, Phillips S, Maffitt D, Pringle M, Tarbox L, Prior F. “The Cancer Imaging Archive (TCIA): Maintaining and Operating a Public Information Repository”, *Journal of Digital Imaging*, Volume 26 (2013), s. 1045-1057
2. Pereira S, Pinto A, Alves V, Silva CA. “Brain tumor segmentation using convolutional neural networks in MRI images”. *IEEE T Med Imaging*, 35 (2016), s. 1240-1251.
3. Dandil E, Çakıroğlu M, Ekşi Z. “Computer-aided diagnosis of malignant and benign brain tumors on MR images” ICT Innovations, Skopje, Macedonia, 18-23 September, 2017.

4. Sompong C, Wongthanavas S. “Brain tumor segmentation using cellular automata-based fuzzy c-means” 13th International Joint Conference on Computer Science and Software Engineering (JCSSE), Khon Kaen, Thailand, 13-15 July 2016.
5. Nazir M, Wahid F, Ali Khan S. “A simple and intelligent approach for brain MRI classification”, *Journal of Intelligent & Fuzzy Systems*, 28(3), 1127-1135, 2015.
6. Sajjad M, Khan S, Muhammad K, Wu W, Ullah A, Baik, S. W. “Multi-grade brain tumor classification using deep CNN with extensive data augmentation” *Journal of computational science*, 30, 174-182, 2019.
7. Kanmani P, Marikkannu P. “MRI Brain Images Classification: a multi-level threshold based region optimization technique”, *Journal of medical systems*, 42(4), 62, 2018.
8. Praveen GB, Agrawal A. “Multi stage classification and segmentation of brain tumor” 3rd International Conference on Computing for Sustainable Global Development (INDIACom), New Delhi, India, 16-18 March 2016.
9. Ibrahim, W. H., Osman, A., and Mohamed Y. I., 2013."MRI Brain Image Classification Using Neural Networks" IEEE International Conference on Computing, Electrical and Electronics Engineering, ICCEEE.
10. Kumar S, Sharma A, Tsunoda T. “Brain wave classification using long short-term memory network based OPTICAL predictor”, *Scientific reports*, 9(1), 1-13, 2019.
11. Yalçın, H., Razavi, S., “Plant Classification using Convolutional Neural Network” Fifth International Conference on Agro-Geoinformatics (Agro-Geoinformatics), 1-5, 2016.
12. A. Krizhevsky and G.E. Hinton, “Using Very Deep Autoencoders for Content Based Image Retrivel” European Symposium on Artificial Neural Networks, s.489-494, 2011.
13. He KM, XY Zhang, SQ Ren, J Sun, "Deep Residual Learning for Image Recognition". IEEE Conference on Computer Vision and Pattern Recognition, s.770-778, 2016.
14. Kira, Kenji ve Rendell, Larry, “Özellik Seçimi Problemi: Geleneksel Yöntemler ve Yeni Bir Algoritma” AAI, 1992.Kononenko, Igor, “Özniteliklerin tahmin edilmesi: RELIEF'in analizi ve uzantıları. Makine Öğrenimi” ECML Bilgisayar Bilimlerinde Ders Notları, 784. Bahar, Berlin, Heidelberg. s.171–182, 1994.