



## LSTM-based deep learning application in brain tumor detection using MR spectroscopy

Sinan Altun<sup>ID</sup>, Ahmet Alkan\*<sup>ID</sup>

Department of Electrical and Electronics Engineering, Faculty Engineering-Architecture, Kahramanmaraş Sütçü İmam University, 46050, Onikişubat, Kahramanmaraş, Türkiye

### Highlights:

- Classification of MRS data with KNN, Support Vector Machines and Decision Trees
- Classification of MRS data by LSTM-based deep learning method
- Comparison of classification achievements

### Keywords:

- MR Spectroscopy
- Brain tumor
- Data mining
- Deep learning

### Article Info:

Research Article  
Received: 09.02.2022  
Accepted: 20.05.2022

### DOI:

10.17341/gazimmfd.1069632

### Acknowledgement:

For his support in the preparation of the data set used in the study, Assoc. Dr. We would like to thank İdris ALTUN

### Correspondence:

Author: Ahmet Alkan  
e-mail: aalkan@ksu.edu.tr  
phone: +90 344 300 1634

### Graphical/Tabular Abstract

As can be seen in Figure A, the classification of tumor is non-tumor was made in the data set created with MRS data with the LSTM deep learning technique, which is frequently used in the classification of data. The method has been quite successful compared to the classification made by classical machine learning methods.

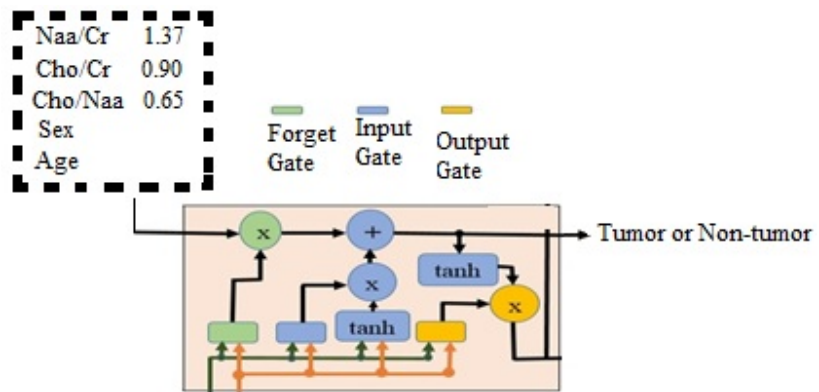


Figure A. LSTM network that predicts Tumor or Non-tumor with MRS data

### Purpose:

Computer aided diagnosis (CAD) systems can be a powerful help in diagnosing a doctor. When the literature is examined, classification, clustering and deep learning methods which are the basis of CAD systems for the diagnosis of different diseases are included. High achievements from these studies are promising for the implementation of the CAD systems. MR Spectroscopy (MRS) is a powerful tool that helps the doctor to detect brain tumor. MRS data need to be interpreted carefully for accurate detection. In this study, CAD system, which may be a powerful adjunct to the doctor in the detection of brain tumor with MRS data, was considered.

### Theory and Methods:

In this study, the data set was obtained by using the ratios of Cho / Cr, Cho / Naa, Naa / Cr metabolites obtained from MRS and gender and age information of the patients. Naïve Bayes, Decision Trees, Support Vector Machines and KNN algorithms are used for classification. The LSTM network is a deep learning technique used for array data. MRS data were also studied with the LSTM network.

### Results:

There are 4 different classification techniques and LSTM deep learning network has achieved high classification success. Deep learning techniques aim at obtaining a higher head by processing more intensively the image or series of data. The LSTM deep learning network has achieved a very high classification success rate of 93%.

### Conclusion:

The highest success for the MRS data set in this study was obtained with “rmsprop” algorithm and 0.01 LR. As a result of the study, very high classification successes were achieved up to 93%. These results indicate that there may be a CAD system assisting doctor using MRS data.



## MR Spektroskopi kullanılarak beyin tümörü tespitinde LSTM tabanlı derin öğrenme uygulaması

Sinan Altun<sup>ID</sup>, Ahmet Alkan\*<sup>ID</sup>

Kahramanmaraş Sütçü İmam Üniversitesi, Mühendislik-Mimarlık Fakültesi, Elektrik-Elektronik Mühendisliği Bölümü, 46050, Onikişubat, Kahramanmaraş, Türkiye

### Ö N E Ç İ K A N L A R

- MRS verilerinin KEYK, Destek Vektör Makineleri ve Karar Ağaçları ile sınıflandırması
- MRS verilerinin LSTM tabanlı derin öğrenme yöntemiyle sınıflandırması
- Sınıflandırma başarımlarının karşılaştırılması

#### Makale Bilgileri

Araştırma Makalesi  
Geliş: 09.02.2022  
Kabul: 20.05.2022

#### DOI:

10.17341/gazimmfd.1069632

#### Anahtar Kelimeler:

MR spektroskopi,  
beyin tümörü,  
veri madenciliği,  
derin öğrenme

#### ÖZ

MR Spektroskopi (MRS) beyindeki su ve yağ haricindeki metabolitlerin ölçümünün yapılabildiği, beyin tümörü tespitinde kritik öneme sahip bir görüntüleme modalitesidir. Yapay zekâ ve veri madenciliğindeki gelişmelerle birlikte, bilgisayar destekli tanı (BDT) sistemlerinin tıp alanında da yaygın olarak kullanıldığı görülmektedir. Elde edilen yüksek başarımlar, BDT uygulamalarının zamandan tasarruf sağlayarak tıbbi teşhis ve tedavi süreçlerini olumlu yönde etkilemektedir. Derin öğrenme, klasik sınıflandırma yöntemlerine göre güncel, veriler üzerinde daha başarılı sonuçlar veren, yüksek sınıflandırma kabiliyetine sahip yapay zekâ algoritmasıdır. Bu çalışmada, MRS ile elde edilen Kolin (Cho), kreatin (Cr) ve N-Asetil Aspartat (Naa) metabolitlerin oranları (Cho/Cr, Cho/Naa ve Naa/Cr) kullanılarak tümör tespitinde doktora yardımcı bir BDT sistemi geliştirilmesi amaçlanmıştır. Sınıflandırmada dizi veriler için, derin öğrenme uygulaması olan, Long Short-Term Memory (LSTM) ve karşılaştırma yapmak için dört adet klasik veri sınıflandırma yöntemi kullanılmıştır. Klasik yöntemlerden k-En Yakın Komşu (KEYK), Destek Vektör Makineleri (DVM) ve Karar Ağaçları (KA) ile elde edilen sınıflandırma başarımları %83±6,36 bulunurken, çalışmada önerilen LSTM tabanlı derin öğrenme yöntemiyle bu değer %93 olarak elde edilmiştir. Bu da derin öğrenmenin yüksek sınıflandırma başarımları göstererek, MRS verilerinin sınıflandırılmasında ilgili alandaki uzmanlara karar sürecinde yardımcı olabilecek bir BDT sisteminde kullanılabileceğini göstermektedir.

## LSTM-based deep learning application in brain tumor detection using MR spectroscopy

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

- Classification of MRS data with KNN, Support Vector Machines and Decision Trees
- Classification of MRS data by LSTM-based deep learning method
- Comparison of classification achievements

#### Article Info

Research Article  
Received: 09.02.2022  
Accepted: 20.05.2022

#### DOI:

10.17341/gazimmfd.1069632

#### Keywords:

MR spectroscopy,  
brain tumor,  
data mining,  
deep learning

#### ABSTRACT

MR spectroscopy (MRS) is a critical imaging modality in brain tumor detection, in which brain metabolites other than water and fat can be measured. Along with the advances in artificial intelligence and data mining, it is seen that computer aided diagnosis (CAD) systems are widely used in medicine. The high achievements achieved have a positive effect on medical diagnosis and treatment processes by providing time saving for CAD applications. Deep learning, based on classical classification methods, the results are more successful on the data, and with high classification ability is the artificial intelligence algorithm. In this study, it was aimed to develop a CAD system to assist physicians in tumor detection by using the ratios of Choline (Cho), creatine (Cr) and N-Acetyl Aspartate (Naa) metabolites (Cho/Cr, Cho/Naa and Naa/Cr) obtained by MRS. For classification data, four classical data classification methods were used, which are deep learning application, Long Short-Term Memory (LSTM) and comparison. While the class performance results obtained with K-Nearest Neighborhood (KEYK), Support Vector Machine (SVM) and Decision Trees (DT) were found to be around 83±6,36 % from classical methods, this value was obtained as 93% with the LSTM-based deep learning method proposed in the study. This shows that deep learning can be used in a CAD system that can assist the experts in the relevant field in the decision-making process in classifying MRS data by demonstrating high classification performance.

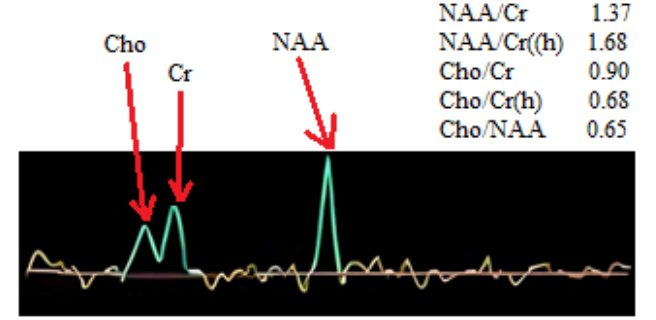
## 1. Giriş (Introduction)

Beyin tümörü teşhisinin değerlendirilmesinde uzmanlar yaygın olarak Manyetik Rezonans (MR) ve Bilgisayarlı Tomografi (BT) gibi farklı görüntüleme tekniklerinden yararlanmaktadır. Kullanılan bu görüntüleme teknikleriyle beyin diğer hastalıkları ile tümör ayrımı kolay bir işlem olmayıp, değerlendirenin uzmanlığına bağlı, sübjektif bir durum arz etmektedir. Beyin tümörü oluşumuyla beyinde diğer beyin hastalıklarında görülmeyen, farklı metabolitler ortaya çıkmaktadır. Bu metabolitlerin ölçülmesi, teşhiste ve hastalığın ayırıcı tanısını koymakta oldukça önemli bilgiler olup, bu alanda kullanılmaktadır. Beyin tümörü teşhisinde oldukça önemli bilgiler sunan ve en çok kullanılan metabolitler kolin (Cho), kreatin (Cr) ve N-Asetil Aspartat (Naa)'dır. Hasarlanmış ve/veya demiyelizan sorun olan metabolik aktivitesi artan hücrelerde Cr ve Naa değişim gösterebilirken, tümör hücrelerinden Cho salınımı olur. Beyin tümör hücrelerine özgü olan Cho artışı tümörün derecesi arttıkça salınımı artacak ve daha yüksek değerler ortaya çıkmaktadır. Beyindeki lezyonların, biyokimyasal değişikliklerini gösteren metabolitler MRS ile ölçülür. MRS metabolit değerlerini ve bunların birbirlerine oranını aynı anda verir. MR spektroskopisi normal beyin ile anormal beyin dokusu arasındaki biyokimyasal karşılaştırmayı yapar. Bu sayede beyindeki lezyonun tümör olup olmadığı hakkında kimyasal harita çıkarır. MRS çekimi normal MR cihazı ile çekilir. Amino asitler, Laktat, Lipit, Alenin gibi farklı metabolitlerin ölçümü de yapılabilir, ancak tümör tespiti için Cho/Cr, Cho/Naa ve Naa/Cr metabolit oranları anlamlıdır. MR Spektroskopisi ile bu metabolit değerleri ölçülebilmektedir. Bu değerlerin seviyelerine ve oranlarına göre tümör ve diğer hastalıkların teşhisi konulabilmekte, Cho seviyesine göre tümör derecesi hakkında bilgi edinilebilmekte olup, bunun sonucuna göre hastaya tedavi yöntemleri veya cerrahi planlama yapılabilmektedir [1, 2]. Beyin gibi en hayati organda yapılacak işlemlerin belirlenmesi bu metabolit değerlerinin yorumlanmasına dayandığından, bu konu oldukça kritik bir karar süreci olup, ciddi bir uzmanlık gerektirmektedir.

Herhangi bir hastalığı olmayan kişiden çekilen MRS'te en büyük değere Naa metaboliti sahiptir. Naa metaboliti 2.0-2.02 ppm (parts per million)'de rezonans yapar. Tümör olan bölgede Naa metabolitinin azalma gösterdiği bilinmektedir. Cr metaboliti beyin hücrelerinin enerji sistemlerinin korunmasında görev yapmakta olup, spektrumda 3.0-3.02 ppm'de pik rezonans yapar. Ayrıca tümör olan bölgede Cr metabolitinde azalma görülür. Spektrumda 3.22 ppm'de pik yapan Cho metaboliti, hücre artışına bağlı olan bir metabolit olup, hücre artışı ne kadar fazla ise bu metabolit değeri de o oranda fazla olur. Tümör de hızlı bir hücre artışı gösterdiğinden, Cho metaboliti tümör olan bölgede yüksektir. İleri seviyedeki beyin tümörü hastalarında bu metabolit değerinin oldukça fazla olduğu görülmektedir [3, 4]. Beyin ve Sinir Cerrahisi uzmanına danışıldığında bu metabolitlerin değerlerinden ziyade Cho/Cr, Cho/Naa ve Naa/Cr oranlarının tümör tespitinde kullanıldığı vurgulanmıştır. Bu nedenle çalışmada kullanılacak veri seti oluşturulurken metabolit oranları özellik olarak alınmıştır. Tümörün en şiddetli olduğu ve tümör olmayan kişilerden alınmış uç örnekler Şekil 1 ve Şekil 2 de sunulmuştur. Bu veriler her zaman bu kadar net olmayıp, doktorun tecrübesine ve yorumlamasına ihtiyaç duyulmaktadır. Dolayısıyla bu verilerin işlenerek doktorun kararını destekleyecek objektif bir süreç önem arz etmektedir. Şekil 1'de beyin tümörü olmayan bir hastadan çekilmiş MRS görüntüsü yer almaktadır. Grafik incelendiğinde en yüksek değere Naa metaboliti sahiptir. Cho metabolitinin diğerlerine göre yüksek olmadığı görülmektedir.


Beyin ve Sinir Cerrahisi uzmanları MRS verilerinin tümör tespiti için incelenmesinde ve cerrahi müdahale kararlarının zaman kaybetmeden verilmesine destek sağlayacak bir karar destek sisteminin oldukça

yararlı olacağını belirtmişlerdir. Bu amaçla çalışmada uzmanın karar sürecinde ona destek olabilecek bir BDT oluşturulması amaçlanmıştır.



Şekil 1. Tümör olmayan bölgeye ait MRS görüntüsü (MRS image of non-tumor region)

Şekil 2'de tümör olan bir hastadan çekilen MRS görüntüsü yer almaktadır. Burada görüleceği üzere, normal bir hastada ki Naa metaboliti, burada en yüksek değere sahip değildir. Naa metaboliti yerine Cho metaboliti diğer metabolitlere göre daha yüksek seviyededir.



Şekil 2. Tümör olan bölgeye ait MRS görüntüsü (MRS image of tumor region)

Bu çalışmada, MR Spektroskopisi ile ölçülen Cho/Cr, Cho/Naa, Naa/Cr metabolit oranları, yaş ve cinsiyet bilgileri ile uzmanın tümör veya tümör değil bilgileri kullanılarak, güncel ve etkili bir sınıflandırma yöntemi olan LSTM tabanlı derin öğrenme yöntemi kullanılmıştır. Önerilen yöntemin başarımını ortaya koymak ve karşılaştırmak amacıyla, veri seti klasik sınıflandırma yöntemleriyle (KEYK, Karar Ağaçları, Destek Vektör Makineleri) 'de analiz edilmiştir. Bölüm 2'de konuyla ilgili literatür özeti sunulmuştur. Bölüm 3'te çalışmada kullanılan materyal ve metotlar verilmiştir. Bölüm 4'te bulgular ve tartışma yapılarak, son bölümde elde edilen sonuçlar verilmiştir.

## 2. Literatür Araştırması (Literature Review)

Literatürde MRS kullanılan değişik çalışmalar mevcut olup, konuyu özetleyecek literatür özeti sunulmuştur. MRS kullanarak teşhis koyulmuş ve farklı evrelerdeki beyin tümörü hastalarına yönelik bir çalışmada [5] Doğrusal Ayırma Analizi, Destek Vektör Makineleri sınıflandırma yöntemleri kullanılmıştır. Doğrusal Ayırma Analizi (DAA) yönteminde %65 başarı, Destek Vektör Makineleri yönteminin DVM, LS çekirdeğini kullanarak yaptıkları çalışmada %94 başarı, RBF çekirdeğinde ise %98 başarı sağlamışlardır. Çalışmamız, hastalık evresiyle değil tümör tespitine yönelik olması yönüyle farklılık arz etmektedir. Nagorive ve Joshi [6] çalışmalarında MR Spektroskopisi ile elde edilen verileri kullanarak beyin tümörünün evresini tahmin etmişlerdir. Çalışmalarında ayrıca MR

Spektroskopide değerleri okuyup bir veri tabanına yazdırma işlemi de vardır. Cho, Cr ve Naa değerleri MRS üzerinden okunmaktadır. Farklı hastanelerden 88 beyin tümörü hastasının bilgilerini kullanmışlardır. Hastaların tamamı beyin tümörüdür. 12 hastanın MRS görüntüsünden Cho, Cr ve Naa verilerini %100 oranında bir başarı ile okuyup veri tabanına yazmışlardır. Beyin tümörünün evresini tahmin etmek için veri setine yazdıkları verileri Destek Vektör Makineleri yöntemi ile sınıflandırmışlar ve %67 sınıflandırma başarıları yakalamışlardır. Beyin tümörü teşhisi konulmuş hastaların hangi evrede olduklarını tahmin etmeye yönelik bir diğer çalışmada MRS spektral görüntüleri kullanılarak yapılmıştır [7]. Gaussian Ayırıştırması ve Yapay Sinir Ağlarını teknikleri ile yapılan bir çalışmada başarının %94 olduğu bildirilmiştir.

Çalışmada önerilen LSTM tabanlı derin öğrenme tekniği oldukça güncel bir sınıflandırma tekniği olup, değişik biyomedikal uygulamalarda kullanılabilir. Şeker hastalığının tedavi etmenin zor olduğu ve her geçen gün şeker hastası sayısının arttığı, görülme yaşının ise düştüğünün vurgulandığı bir çalışmada, şeker hastalığının kandaki glikoz miktarını arttırdığı gibi kalp ritmini de bozduğu ve kalp krizine neden olabileceği belirtilmiştir [8]. EKG sinyalleri ile şeker hastalığı tespitinin, şeker hastalığı sebebiyle kalp hastalığını önlemek için önemli olduğu vurgulanan çalışma da kullanılan veri setinde tip 2 şeker hastalığına sahip 20 bireyden ve şeker hastası olmayanlardan çekilen EKG sinyalleri kullanılmıştır. Bu verilerle tip 2 şeker hastası olup, olmadığı sınıflandırması yapılmıştır. Çalışmada Evrimsel Sinir Ağı (ESA) ve ESA+LSTM yöntemlerine yer verilmiştir. ESA yönteminde %90 sınıflandırma başarıları elde edilirken, ESA+LSTM %95 sınıflandırma başarıları yönteminde elde edilmiştir.

Yüksek tansiyon ve düşük tansiyon, ölümcül sonuçlar doğurabilecek hastalıklar olup kan basıncı ölçümünün düzenli olarak yapılmasının, bu hastalıkların erken teşhisi açısından önemli olduğu vurgulanan çalışmada EKG ve fotopletizmografi (PPG) sinyallerinden çıkan özellikler ile yüksek ve düşük tansiyon tahmini yapılmıştır [9]. MIMIC 1 veri tabanından alınan toplam 39 hastanın, Elektrokardiyografi (EKG) ve PPG sinyallerinden yapay sinir ağı ile çıkartılan özellikler LSTM derin öğrenme ile sınıflandırılmaktadır. Yapılan çalışmanın başarıları, Adaboost veri madenciliği ve LSTM derin öğrenme yöntemleriyle hesaplanan “mean absolute error (MAE)” ve “root mean absolute error (RMSE)” hata oranları karşılaştırılarak yapılmıştır. Çalışmada önerilen ESA-LSTM modelinde daha düşük hata oranları hesaplanmıştır.

EKG üzerinden kalp ritim bozukluklarına bağlı çeşitli hastalıkların tespiti uzman tarafından mümkün olsa da bu işlem iyi bir uzmanlık gerektiren, zor ve zaman alıcı bir işlemdir. Oh vd. [10] EKG sinyallerinden otomatik olarak ritim bozukluğuna bağlı çeşitli hastalıkların sınıflandırılmasını yapabilen bir sistem önermişlerdir. Ritim bozukluğuna bağlı farklı hastalıklar için toplam 16499 veri kullanmışlardır. Sistem ESA ve LSTM kombinasyonu ile gerçekleştirilmiştir. Veri seti MIT-BIT aritmi fizyo bankasındaki veri tabanından alınarak eğitim sürecini hızlandırmak ve EKG sinyal genliğini standart hale getirmek için Z-skor normalizasyon ile veri setinde ön işleme yapılmıştır. ESA ile EKG sinyallerinden çıkartılan özellikler, LSTM ile sınıflandırılmış ve %98 gibi yüksek bir başarı elde edilmiştir. Nöroloji ve psikiyatri alanlarında, zihinsel ve bilişsel insan kapasitesinin belirlenmesi önemli olup bu nöro-bilişsel performans tespiti ile yapılmaktadır [11]. Nöro-bilişsel performans tespitinde uykuya dalış dönemi (N1) önemli olup farklı uyku dönemleri de (W, N1, N2, N3) vardır. Önerilen çalışmada, PhysioBank’tan alınan Elektroensefalografi (EEG) sinyalleri kullanılarak uyku dönemlerinden oluşan dört sınıf ve nöro-bilişsel performans tespiti için önemli olan N1 dönemi ile göz kapaklarının iyice ağırlaşma döneminden oluşan iki sınıf ayrı ayrı çalışılmıştır.

Tüm EEG verileri, 0.3-45 Hz aralığı dışındaki frekans bileşenlerini süzmek için filtrelenmiş ve her 30’ar saniyelik bölümler 1’er saniyelik dilimlere bölünmüştür. Uyku dönemlerinin sınıflandırılması için 10280, N1 ve göz kapağı ağırlaşması dönemleri için toplam 2780 veri kullanılmıştır. Ön işlemeden sonra zaman-domeni ve frekans-domeninden toplam 55 adet özellik elde edilmiştir. Özellik sayısı, “The minimum redundancy maximum relevant (mRMR)” algoritması kullanılarak sınıflandırma için en ilgili 11 adet özellik belirlenerek kullanılmıştır. Ön işleme sonucunda elde ettikleri veri setini LSTM yöntemini kullanarak sınıflandırmışlardır. Uykunun dört aşamasını tahmin eden sınıflandırmada %90 başarı, N1 dönemi ve göz kapağının ağırlaştığı dönem için yapılan sınıflandırmada %83 başarı elde edilmiştir. Beyin tümörü tespitinde karar vermek ciddi bir bilgi birikimi gerektirmektedir. Beyin tümörünün varlığı hakkında önemli bilgi veren Cho, Cr ve Naa metabolit değerleri ve oranları MR Spektroskopisi çekilmesi ile elde edilmektedir. MRS ile bu oranlar grafik halinde de verilebilmektedir. Ranjith vd.[12] çalışmalarında bunları vurgulayarak, bilgisayar destekli tanı sistemlerinin son yıllarda sıkça çalışıldığı ve iyi sonuçlar elde edildiğini belirtmektedirler. Bu nedenle erken ve ileri evre olmak üzere iki sınıf içeren 28 hastanın MRS çekimlerinden elde edilen metabolit oranlarını kullanarak sınıflandırma (yapay sinir ağıları, destek vektör makineleri, rastgele orman yöntemi ve yerel ağırlıklı öğrenme) yapmışlardır. Sınıflandırma başarılarını göstermek için ROC değerlerinin hesaplamışlar ve en yüksek başarı 0.91 ile rastgele orman yönteminden elde etmişlerdir.

### 3. Materyal ve Metot (Material and Method)

#### 3.1. Materyal (Material)

Çalışmada kullanılan MRS veri seti, gerekli etik kurul onayı alınarak, Kahramanmaraş Sütçü İmam Üniversitesi Beyin ve Sinir Cerrahisi Ana Bilim Dalından temin edilmiştir. Veri setinde 49 adet tümör teşhisi konulmuş, 44 adet tümör teşhisi konulmamış toplam 93 adet hastanın bilgileri vardır. Veri setinde MRS’den elde edilen metabolit oranları, yaş ve cinsiyet bilgileri yer almaktadır. Tablo 1’de görüleceği üzere 5 adet özellik, 2 adet sınıf vardır. Beyin ve Sinir Cerrahisi uzmanınca, kullandığımız veri setindeki metabolitlerin değerlerinden ziyade, bunların oranlarının (Cho/Cr, Cho/Naa ve Naa/Cr) tümör tespitinde kullanıldığı ifade edildiğinden, çalışmada kullanılacak veri seti oluşturulurken özellik olarak metabolit oranları kullanılmıştır. Uzman bu özellik bilgilerini ve klinik gözlemlerini dikkate alarak kararlar vermiş, veri setinde bu kararlar tümör (1) veya değil (0) şeklinde sınıflandırmıştır.

**Tablo 1.** Veri seti özellikleri (Data set features)

Adı	Açıklama	Tip
Yaş	Yaş bilgileri.	Sayısal
Cinsiyet	İlgililerin cinsiyeti.	0/1
Cho/Cr	MR Spektroskopide ölçülen kolin(Cho) değerinin, kreatin(Cr) değerine oranıdır.	Sayısal
Cho/Naa	MR Spektroskopisi de ölçülen kolin(Cho) değerinin, N-Asetil Aspartat(Naa) oranıdır.	Sayısal
Naa/Cr	MR Spektroskopide ölçülen N-Asetil Asetat değerinin kreatin(Cr) değerine oranıdır.	Sayısal
Sınıf	Tümör teşhisi konulan(1) veya tümör teşhisi konulmayan(0).	0/1

#### 3.2. Metotlar (Methods)

##### 3.2.1. Karar ağaçları (Decision tree)

Karar ağaçları tepeden aşağı doğru dallanma yaparak, verileri alt kollara ayırarak ilgili sınıfta etiketler. Dallanmanın oluşturulması,

yöntemin önemli bir aşaması olup çeşitli kararlar verilerek yapılır. Karar ağaçları, entropiye dayalı dallanma oluşturanlar (ID3, C4.5) ve regresyon ağaçları olarak ikiye ayrılır. Bu çalışmada literatürde sıkça kullanılan C4.5 entropiye dayalı ağaç oluşturan algoritma kullanılmıştır. Entropi, rassal değişkenin belirsizlik ölçüsü olup, herhangi bir işlemde örneklerin taşıdığı bilginin beklenen değeridir. Bilgi ise rassal olayın gerçekleşmesine dair bilgi ölçüsüdür. Karar ağaçlarında dallanma yapısı oluşturulurken entropi; birden fazla özelliğe sahip veri setini, özellik üzerindeki şartlara göre parçalara ayırır. Bu parçalama işleminde hangi özellik üzerindeki hangi şarta göre işlem yapılacağına karar verilmesi, veri setinin büyüklüğüne göre artan kombinasyon çözümü gerektirir. ID3 algoritması, çalışmada kullanılan C4.5 algoritmasının atası olarak nitelendirilebilir. ID3'te özellikler tek tek incelenir ve en yüksek bilgi kazancına sahip özellikte dallanma yapılır. Her bir iterasyonda, özellik vektörlerinin sınıfla ilişkili entropileri ve örnek verilere ait sınıf bilgilerinin entropileri hesaplanarak farkı alınır. Özelliğe ait kazancı veren bu hesaplama ile o iterasyonda hangi özellik için dallanma yapılacağı belirlenir. Sayısal değerlerin kategorik hale gelmesini sağlayan bir eşik değeri kullanan C4.5 algoritması, ID3'ün sayısal verilerde de uygulanmasını sağlar. Sayısal özellik vektöründeki değerler, ikişer ikişer incelenir ve ortalamaları eşik değeri olarak alınır. Kazanç hangisinde iyiyse o eşik değeri olarak seçilir ve sayısal olan özellik vektörü kategorize edilir. Eş. 1'de; C4.5 algoritmasında kullanılan formül yer alırken, burada I taşınan bilgiyi, H entropiyi ifade etmekteyken, Pi olasılıklara bağlı bir değerdir [13].

$$H(x) = \sum_{1 \leq i \leq n} P(x_i) \times I(x_i) = \sum_{i=1}^n P(x_i) \times \log_2 \frac{1}{P(x_i)} = - \sum_{i=1}^n P_i \times \log_2 P_i \quad (1)$$

### 3.2.2. Destek vektör makineleri (Support vector machines)

İstatistiksel veri analizine dayanan DVM ile ilk oluşturulan algoritma iki sınıflı lineer verilerin sınıflandırılmasını yapılırken daha sonra algoritma geliştirilerek ikiden fazla sınıf içerebilen ve/veya lineer olmayan verilerin sınıflandırılması için kullanılabilir hale getirilmiştir. Lineer olmayan veriler için doğrusal bir hiper-düzlem çizilemeyeceğinden burada "kernel trick" adı verilen çekirdek yöntemleri kullanılmaktadır. Polinom çekirdek, Pearson VII (PUK) çekirdek, literatürde yer alan yaygın çekirdek yöntemleridir. Çekirdek yöntemler, lineer olarak ayrılamayan verilerin özelliklerini, lineer olarak ayrılabilir hale getirirler [14-16].

### 3.2.3. K-en yakın komşu algoritması (K nearest neighbor algorithm)

Sınıflandırma yöntemlerinden olan KEYK, "k" parametresi kadar komşu verilerin etiketine bakar ve hangi sınıftan daha fazla komşu varsa yeni veriyi o sınıfa ait olarak etiketler. İncelenen komşuların

sayısı eşit sayıda olması istenmeyen bir durum olduğundan "k" sayısı tek sayı olması tercih edilir. Test verisinin komşuları ile olan uzaklığı çeşitli tekniklerle hesaplanır. Bunlar: Euclidean Distance, Manhattan ve Minkowski'dir. Eş. 2'de Euclidean, Eş. 3'te Manhattan, Eş. 4'te Minkowski uzaklık hesaplama fonksiyonları yer almaktadır. Eş. 2, Eş. 3, Eş. 4'te yer alan "x" aralarındaki uzaklık hesaplanacak iki komşudan ilkinin konumunu, "y" ise ikincinin konumunu ifade eder [16, 17].

$$\text{Euclidean} = \sqrt{\sum_{i=1}^k (x_i - y_i)^2} \quad (2)$$

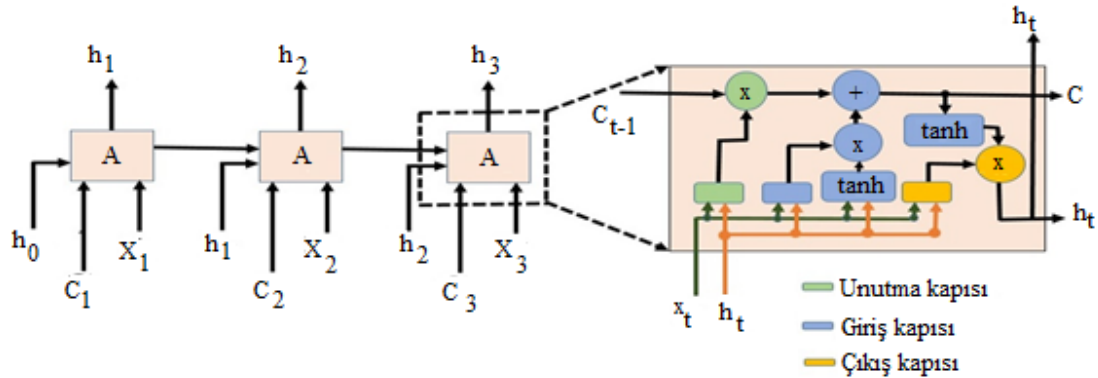
$$\text{Manhattan} = \sum_{i=1}^k |x_i - y_i| \quad (3)$$

$$\text{Minkowski} = \left( \sum_{i=1}^k (|x_i - y_i|^q) \right)^{\frac{1}{q}} \quad (4)$$

### 3.2.4. Long short-term memory-LSTM derin öğrenme (Long short-term memory-LSTM deep learning)

İnsanlar, düşünmeye her seferinde sıfırdan başlamazlar. Mesela okunan makalede kelime anlamları ve bütün makale anlamı önceki bilgilere göre kolayca anlaşılır, herhangi bir harfi eksik olan kelime önceki bilgiler kullanılarak tamamlanabilir, birbiri ile ilişkili olan iki cümleden ikincisindeki eksik bir kelime varsa ilk cümledeki anlam ve ikinci cümledeki kelimelerden yola çıkarak bu kelime bulunabilir. Geleneksel yapay sinir ağları kalıcı hafıza sağlayamadıkları için kelime tamamlama, anlam tamamlama gibi problemlerin çözümünde etkili olmamaktadır. Yinelenen sinir ağları (YSA) bilginin devamlılığını sağlayarak bu problemlere çözüm sunmaktadır. Bilginin devam etmesi her bir YSA hücresi içindeki döngülerle sağlanır. YSA'nın çok sayıda hücreleri içererek, veriler üzerinde derin bir öğrenme işlemi yapması da geleneksel yapay sinir ağlarından farkını ortaya koymaktadır. Literatüre bakıldığında, YSA ses tanıma, dil modellemesi gibi alanlarda oldukça başarılı olmaktadır ve dizi verilerde kullanıldığında yüksek başarılar elde edilebileceğini göstermektedir [18].

YSA; örneğin ilişkili iki cümleden ikincisindeki eksik bir kelimeyi ilk cümlede ve ikinci cümlede yer alan diğer kelimelere bakarak bulmada başarısız olmaktadır. Bu başarısızlık, YSA hücrelerine ilave döngüler ekleyen Hochreiter ve Schmidhuber [19] tarafından 1997 yılında geliştirilen LSTM yöntemi ile giderilmiştir. LSTM derin öğrenme yöntemi, soruna çözüm bulabilmek için uzun veya kısa dönem hafızanın hepsini kontrol eder ve sonucu bu şekilde çıkarır. Şekil 3'te görüleceği üzere; LSTM hücre yapısında "mavi renkle" gösterilen giriş kapısı, "yeşil renkle" gösterilen unutmaya kapısı, "sarı renkle" gösterilen çıkış kapısı ve "c" ile isimlendirilebilecek hafıza hücresi vardır. Unutmaya kapısı bilginin ne kadarının geçirileceğine karar verir.



Şekil 3. LSTM ağı (LSTM Network)

0 ile 1 arasında değer alır ve 1 verinin olduğu gibi geçmesini 0 ise bilginin hiçbir şekilde geçmemesini sağlar. Giriş kapısında ise hangi verilerin güncellenmesi “tanh” fonksiyonu kullanılarak yapılır. Son çıkış kapısında ise ilk iki kapıdan geçen veri -1 ile 1 arasına getirilecek şekilde “tanh” fonksiyonu ile çarpılarak sonuç elde edilir.

Lineer olmayan problemlerin çözümünde ideal değeri bulmak için optimizasyon algoritmaları kullanılır. LSTM ağı için; “adam”, “sgdm” ve “rmsprop” optimizasyon algoritmaları kullanılmakta olup MRS veri seti bu 3 optimizasyon için ayrı ayrı sınıflandırılarak başarımlar karşılaştırılması yapılmıştır [18].

### 3.2.4.1. SGDM optimizasyonu

(Stochastic gradient descent with momentum optimization)

Stochastic gradient descent (SGD) algoritması, her iterasyonda kaybı en aza indirmek amacıyla kaybın negatif değişimi için ağı parametrelerinde (ağırlıklar) küçük değişiklikler yapar. Eş. 5'te görülen fonksiyonda “ $\ell$ ” iterasyon numarasını, “ $E(\theta_\ell)$ ” kayıp fonksiyonunu göstermektedir. Stochastic gradient descent (SGD) algoritması en keskin değişimde optimum seviye için salınım yapabilir. Bu salınımı azaltmak Eş. 6'da yer alan fonksiyona bir momentum terimi eklenerek stochastic gradient descent with momentum (SGDM) algoritması elde edilir [20].

$$\theta_{\ell+1} = \theta_\ell - \alpha \nabla E(\theta_\ell) \quad (5)$$

$$\theta_{\ell+1} = \theta_\ell - \alpha \nabla E(\theta_\ell) + \gamma(\theta_\ell - \theta_{\ell-1}) \quad (6)$$

### 3.2.4.2. RMSProp optimizasyonu

(Root mean square propagation optimization)

SGDM optimizasyonunda öğrenme oranı sabittir ve her iterasyonda aynı değer kullanılır. Root mean square propagation (RMSProp) algoritmasında öğrenme oranı küçük değişimler için öğrenme oranı artırılırken büyük değişimlerde öğrenme oranı azaltılır. Eş. 7'de gösterilen “ $v_\ell$ ” fonksiyonu eleman tabanlı parametre değişimlerinin karesinin hareketli ortalamasıdır, Eş. 8'de RMSProp algoritmasının parametre fonksiyonu yer alıyor. Burada  $\beta_2$  hareketli ortalamanın bozulma oranıdır [20].

$$v_\ell = \beta_2 v_{\ell-1} + (1 - \beta_2)[\nabla E(\theta_\ell)]^2 \quad (7)$$

$$\theta_{\ell+1} = \theta_\ell - \frac{\alpha \nabla E(\theta_\ell)}{\sqrt{v_\ell + \epsilon}} \quad (8)$$

### 3.2.4.3. Adam optimizasyonu

(Derived from adaptive moment estimation optimization)

Adam optimizasyon algoritması, RMSProp'a bir moment ifadesi ekleyerek moment ve adaptif öğrenmeyi birleştirmektedir. Eş. 9'da kullanılan moment fonksiyonu yer almaktadır. Burada “ $E(\theta_\ell)$ ” kayıp fonksiyonunu, “ $\beta$ ” hareketli ortalamanın bozulma oranını göstermektedir. Eş. 10'da Adam optimizasyon algoritmasının parametre fonksiyonu yer alıyor. Eş. 8 ile Eş. 10 parametre fonksiyonları kıyaslandığında da Adam algoritmasının, RMSProp algoritmasına bir moment ifadesi ilave edilerek elde edildiği görülmektedir [20].

$$m_\ell = \beta_1 m_{\ell-1} + (1 - \beta_1) \nabla E(\theta_\ell) \quad (9)$$

$$\theta_{\ell+1} = \theta_\ell - \frac{\alpha m_\ell}{\sqrt{v_\ell + \epsilon}} \quad (10)$$

## 4. Sonuçlar ve Tartışmalar (Result and Discussions)

Klasik ve derin öğrenme yöntemlerinin hepsi Python dilinde ve Central Process Unit (CPU) kullanılarak çalışılmıştır. Python, veri

madenciliği için çok sayıda kütüphaneye sahiptir. Bu çalışmada da Numpy, Keras, Tensorflow, Pandas, Scikit-learn kütüphaneleri kullanılmıştır.

Çapraz doğrulama işlemi, yapılan bir analizin bağımsız bir veri setinde nasıl bir başarımlar elde edileceğini sınıyan bir model doğrulama tekniğidir. “k kat çapraz doğrulama” veri setini bir bütün olarak ele alarak işlem yapar. Veri setini rastgele eğitim ve test için bölümlere ayırarak, belirlenen “k” değerince işlem yapar. En sonunda da bu başarımların ortalamasını alarak sonuç verir. “k” değerince farklı verilerin eğitilmesi ve test edilmesi elbette daha doğru bir sonuç verecektir. Bu nedenle çalışmada kullanılan bütün yöntemlerde “k=5 kat çapraz doğrulama” kullanılmıştır.

Çalışmada kullanılan LSTM, ESA, ESA+LSTM derin öğrenme yöntemlerinin hepsinde, aktivasyon fonksiyonu olarak LSTM'de verileri -1 ile 1 arasına sığdıran “tanh” fonksiyonu kullanılmıştır. “mini-batch size” büyük verilerde işlem süresini kısaltmak için kullanılmaktadır. Bu çalışmada kullanılan veri seti çok fazla olmadığı için “mini-batch size=ön belirlenmiş” olarak ayarlanmıştır.

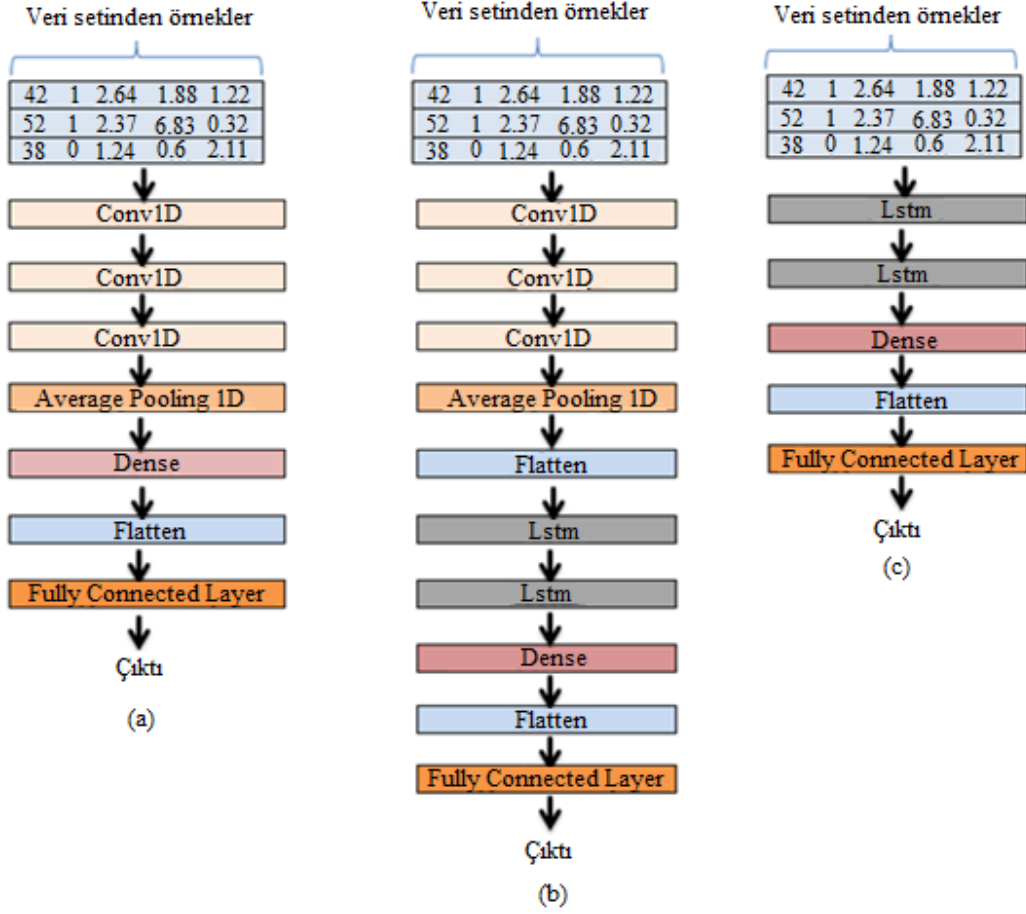
ESA, özellikle görüntü işlemlerde sıkça kullanılan ve oldukça başarılı bir derin öğrenme yöntemidir. Sahip olduğu yetenekler ESA'yı tek boyutlu işaretlerin işlenmesinde de kullanılmasını sağlamıştır. Yöntemin temelini bir filtre/çekirdek oluşturarak veri setinden özellik haritalarının elde edilmesidir. Elde edilen bu haritalar modelin en sonunda yer alan tam bağlaşıklık katmanında (Fully Connected Layer) sınıflandırılarak başarımlar elde edilir. Çalışmada kullanılan ESA yönteminin mimarisi Şekil 4a'da yer almaktadır.

Farklı katmanlar denenmekle beraber en yüksek başarımlar üç adet Conv1D, bir adet Dense ve bir adet Pooling katmanı ile elde edilmiştir. Yine en yüksek başarımları bulabilmek için öğrenme oranı (Learning Rate (LR)) ve üç adet optimizasyon fonksiyonu (rmsprop, adam, sgdm) hiper parametreleri kullanılmış ve bu hiper parametrelerde elde edilen sonuçlar Tablo 2'de verilmiştir.

Çalışmada kullanılan LSTM yönteminin mimarisi Şekil 4c'de yer almaktadır. Veri setinde 5 adet özellik olduğu için “Giriş vektörü” 5 olarak belirlenmiştir. 100 adet nörona sahip iki LSTM katmanı ve 2 adet sınıf olduğu için tam bağlaşıklık katmandaki (Fully Connected Layer) sınıf sayısı 2 olarak belirlenmiştir. Çalışmada LSTM sınıflandırma başarımları Tablo 3'te verilmiştir. En yüksek başarımlar elde edilenler kullanılmıştır. Çalışmadaki ESA ve LSTM başarımları ise Tablo 3'e bakıldığında “rmsprop” algoritması ve “0,01” LR değerinde %93 olarak elde edilmiştir.

Literatür incelendiğinde görüntü işleme ve makine öğrenmesi çalışmalarında farklı yöntemler birleşimli olarak kullanılmaktadır. Çalışmada da ESA+LSTM aktarmalı yöntemi kullanılmıştır. Yöntemin mimarisi Şekil 4b'de yer almaktadır. ESA+LSTM yönteminde üç adet Conv1D, bir adet Pooling, bir adet Dense katmanı yer almaktadır. Bu katmanlar farklı sayılarda çalışılarak en yüksek başarımlar elde edilenler kullanılmıştır. Çalışmadaki ESA ve LSTM yöntemlerinde olduğu gibi bu yöntemde farklı hiper parametrelerde çalışılmıştır. Tablo 4'te farklı hiper parametreler için sınıflandırma başarımları gösterilmiştir.

Şekil 5'te görüleceği üzere karar ağaçları (KA) yöntemi Cho/Cr oranını, ağacın başlangıcı olarak almıştır. Yöntem 1,88'den büyük Cho/Cr oranlarını başka verilere bakmadan beyin tümörü olarak sınıflandırmıştır. Ağacın alt dallarına bakıldığı zaman Cho/Cr oranı 1,22'den küçük olanlar başka bir veriye bakılmaksızın beyin tümörü değildir olarak sınıflandırılmıştır. Cho/Cr oranı 1,22 ile 1,88 olanlar için Cho/Naa oranına bakılmıştır. Cho/Naa oranı 2,53'ten büyük olanlar beyin tümörü olarak sınıflandırılmıştır. Cho/Naa oranı 2,53'ten küçük olanlar için cinsiyete bakılmıştır. Cinsiyeti erkek (1)



**Şekil 4.** (a) ESA mimarisi, (b) ESA+LSTM mimarisi, (c) LSTM mimarisi  
(a) ESA architecture, (b) ESA+LSTM architecture, (c) LSTM architecture)

**Tablo 2.** ESA Başarıları (ESA Successes)

Optimizasyon Fonksiyonu	0,1 LR	0,01 LR	0,001 LR	0,0001 LR	0,00001 LR
adam	%86	%89	%89	%86	%86
sgdm	%86	%86	%89	%86	%85
rmsprop	%86	%89	%89	%89	%89

**Tablo 3.** LSTM Başarıları (LSTM Successes)

Optimizasyon Fonksiyonu	0,1 LR	0,01 LR	0,001 LR	0,0001 LR	0,00001 LR
adam	%81	%90	%89	%91	%84
sgdm	%87	%88	%91	%89	%48
rmsprop	%82	%93	%90	%88	%81

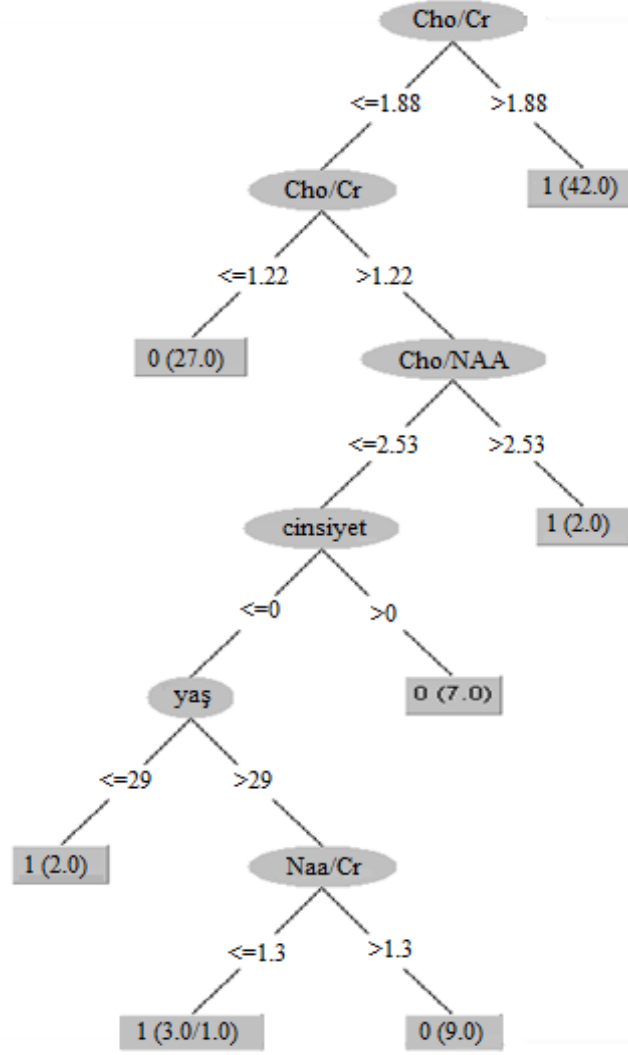
**Tablo 4.** ESA+LSTM Başarıları (ESA+LSTM Successes)

Optimizasyon Fonksiyonu	0,1 LR	0,01 LR	0,001 LR	0,0001 LR	0,00001 LR
adam	%86	%89	%89	%86	%89
sgdm	%82	%86	%86	%86	%85
rmsprop	%86	%86	%85	%89	%89

olanlar beyin tümörü değil olarak sınıflandırılmıştır. Bayan (0) olanlar için ise yaşa bakılmıştır. Yaşı 29'dan küçük olanlar beyin tümörü olarak sınıflandırılmıştır. 29'dan büyük olanlar için Naa/Cr oranına bakılmıştır. Naa/Cr 1,3'den büyük olanlar beyin tümörü değil olarak sınıflandırılmıştır. Naa/Cr 1,3'den küçük olanlar ise beyin tümörü olarak sınıflandırılmıştır. Çalışmada, daha önce de belirtildiği üzere, beyin tümörü olan bölgede en belirgin artış Cho metabolitindedir. Bu durum karar ağacında da görülmekte olup,

dallanma Cho/Cr metabolit oranı ile başlamıştır. Karar Ağaçları yöntemiyle %90 sınıflandırma başarımları elde edilmiştir.

Materyal bölümünde ayrıntıları sunulan 93 adet veri Karar Ağaçları, DVM, KEYK ve derin öğrenme teknikleri kullanılarak ayrı ayrı çalışılmıştır. KEYK tekniğinde "k" değeri 3 olarak seçilmiştir. Mesafe hesaplamada Öklid Mesafesi kullanılarak KEYK %80 başarı elde edilmiştir.



Şekil 5. MRS veri seti için karar ağaçları algoritmasında çıkan karar ağacı  
(Decision tree in decision trees algorithm for MRS data set)

Destek vektör makinelerinde polinom çekirdeği, PUK çekirdeği ve RBF çekirdeği için ayrı ayrı kullanılmıştır. Polinom ve RBF çekirdeklerinde yapılan sınıflandırma da başarı %59'larda kalmış iken PUK çekirdeğinde yapılan çalışma %78 sınıflandırma başarısı elde edilmiştir. Destek vektör makineleriyle en yüksek başarı PUK çekirdeğinde hesaplanmasına rağmen, çalışmadaki MRS veri seti için en başarısız sınıflandırma yöntemidir. %78 sınıflandırma başarısı kötü bir sınıflandırma olmamakla beraber diğer algoritmalarla %12'lik fark oluşması bir algoritmanın her veri setinde başarılı olamayacağını ortaya konması açısından dikkat çekicidir.

Tablo 5'te tıp bilimi için oldukça önemli olan değerler her bir yöntem için hesaplanmıştır. Görüleceği üzere yüksek sınıflandırma başarısı elde ettiğimiz LSTM'de diğer değerlerde oldukça yüksektir ve tanı açısından yöntemin başarısını ortaya koymaktadır. Bunlardan biri olan ROC eğrileri ise Şekil 6'da verilmiştir. En başarılı yöntem olan LSTM için AUC değeri 0.93 hesaplanmıştır.

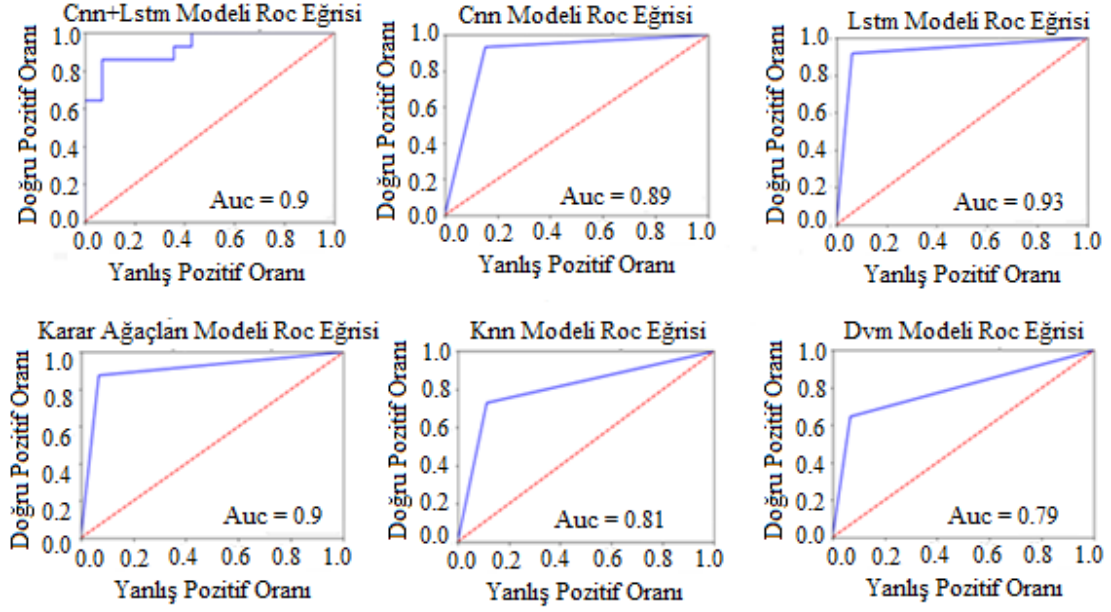
Önerilen model beyin tümör tespiti konusunda yardımcı bir tanı destek sistemi için makine öğrenme yöntemlerini incelemektedir. Literatüre yer alan MRS ile çalışmaların bir kısmı görüntü işleme, bir kısmı işaret işleme ile ilgilidir. MRS metabolit değerlerinin

birbirlerine oranlarını Şekil 1 ve Şekil 2'de görüldüğü gibi grafik olarak çizdirebilmektedir. Literatürde yer alan görüntü işleme üzerine olan çalışmalarda bu grafik görüntüleri üzerinden değer okuma, grafik görüntüsünden özellik çıkartıp sınıflandırma ile ilgilidir. Metabolit oranlarının grafiği ile sayısal değerleri de MRS ile hesaplandığı için, bu verileri derin öğrenme yöntemi ile sınıflandıran bir model önerilmiştir. Tablo 6'da önerilen model ve bazı çalışmaların başarıları ile ilgili bilgiler yer almaktadır. Nagori & Joshi., MRS grafik görüntüleri üzerinden özellik çıkartarak sınıflandırma yapmışlardır.

Görüntü işleme de %100 başarı elde eden Nagori & Joshi, sınıflandırma da ise %66 başarı elde etmişlerdir. Hastalık evreleri sınıflandırması yapan Luka vd., metabolit oranlarını klasik yöntemleri kullanarak çalışmışlardır ve %97 başarı elde etmişlerdir.

Önerilen modele benzer bir tümör tespit sınıflandırması yapan Ranjith vd. 0,9100 AUC hesaplamışlardır. Oysa önerilen model k=5 çapraz doğrulama ile daha detaylı sınıflandırma yapmasına rağmen 0,933 ile oldukça yüksek bir AUC hesaplamıştır. Son yıllarda sıkça çalışılan ve oldukça başarılı sonuçlar veren derin öğrenme yönteminin önerilen modelde de başarısı ortaya konmuştur. Kahramanmaraş Sütçü İmam Üniversitesi Tıp Fakültesinden temin edilen MRS veri seti





Şekil 6. ROC Eğrileri (ROC curves)

Tablo 5. Başarı ölçütleri (Success criteria)

Yöntem Adı	Doğru Pozitif Oranı (DPO)	Yanlış Pozitif Oranı (YPO)	Hassasiyet
Karar Ağaçları	0,902	0,095	0,904
KEYK	0,804	0,189	0,815
DVM	0,783	0,205	0,814
ESA	0,875	0,083	0,933
ESA+LSTM	0,833	0,062	0,909
LSTM	0,933	0,078	0,933

Tablo 6. Önerilen Model İçin Başarı Karşılaştırması (Success Comparison for the Proposed)

Çalışma Adı:	Yazar:	Yıl:	Sınıflandırma Başarısı:
Brain tumor classification based on long echo proton MRS signals	Luka vd. [5]	2004	%97
Methods and algorithms for extracting values from MRS Graph for brain tumor detection	Nagori & Joshi [6]	2013	%66-%100
Machine learning methods for the classification of gliomas: Initial results using features extracted from MR spectroscopy	Ranjith vd. [12]	2015	-
Cascaded LSTM recurrent neural network for automated sleep stage classification using single-channel EEG	Michielli vd. [11]	2019	%83-90
Detection of pseudo brain tumors via stacked LSTM neural networks using MR spectroscopy signals	Dandil & Karaca [21]	2021	%85-93
<i>Bu Çalışmada Önerilen Model</i>	-	-	<i>%93</i>

kullanılarak teşhis ve müdahale öncesi beyinde tümörün varlığı konusunda doktorun kararını destekleyecek çalışmada kullanılan modellerin başarı ölçütleri Tablo 5'te verilmiştir. Çalışmada kullanılan DVM, KEYK, KA, ESA, ESA+LSTM ve LSTM modellerini sınıflandırma başarımları %80 ile %93 arasında değişmektedir.

## 5. Sonuçlar (Conclusions)

Beyin tümörünün ivedi olarak ve farklı bir hastalıkla karıştırılmadan tespit edilmesi oldukça önemlidir. MRS'in su ve yağ haricindeki metabolitleri ölçerek beyin tümörü tespitinde kullanılmaya başlanması, tarihi çok eski değildir. Tümör olan bölgede metabolit

değerleri farklılık gösterirken, MRS bunların değişimini göstermektedir. Beyin tümörü oluşumu ile beyinde diğer beyin hastalıklarında görülmeyen, farklı metabolitler ortaya çıkmaktadır. Tümör gibi beyin diğer hastalıklarında da metabolit değerleri farklılık gösterebildiği için tümör ayırımı kolay bir işlem olmayıp, değerlendirilen uzmanlığa bağlı olup doğru teşhis ve tedavi için doğru yoruma ihtiyaç duyulmaktadır.

Yaşadığımız çağda tıptan, otonom araçlara kadar birçok alanda yapay zekâ çok başarılı uygulamalarla hayatımızı kolaylaştırmaktadır. Literatüre bakıldığında, ister kan tahlili elde edilen veriler, ister tıbbi görüntüleme yöntemleri ile elde edilen görüntüler kullanılarak, teşhis konusunda uzmana yardımcı BDT sistemi oluşturma gayretleri

dikkati çekmektedir. Elbette BDT sistemleri son karar verici olmayacaktır, ama sübjektif hataları azaltarak, uzmana kararlarında yardımcı olacak iyi bir destek aracı olarak kullanımı her geçen gün yaygınlaşmaktadır.

Bu çalışmada da MRS verileri ile oluşturulan veri setinin klasik veri madenciliği yöntemlerinin kendi arasında ve veri madenciliği yöntemlerinin derin öğrenme yöntemi ile elde ettiği sınıflandırma başarıları karşılaştırılmak amaçlanmıştır. MRS veri seti kullanılarak gerçekleştirilen analizlerde veri madenciliği ve derin öğrenme yöntemlerinin hepsinde de kabul edilebilir, yüksek sınıflandırma başarıları elde edilmiştir. Veri madenciliği yöntemlerinden; KEYK için %80, DVM için %78, KA için %90 sınıflandırma başarıları elde edilirken, derin öğrenme yöntemlerinden; ESA için %89, LSTM için %93 ve ESA+LSTM için %89 sınıflandırma başarımları elde edilmiştir. LSTM temelli derin öğrenme yöntemiyle %93 sınıflandırma başarımları ile en yüksek başarımları elde edilmiştir. Son yıllarda tıbbi veri analizinde sıkça çalışılan derin öğrenme tekniklerinin MRS verilerine uygulanması çalışmanın yenilikçi yönünü ortaya koymaktadır. Çalışmada elde edilen sonuçlar, derin öğrenme tekniklerinin klasik sınıflandırma yöntemlerine göre oldukça yüksek sınıflandırma başarımları verdiğini göstermiştir. Dizi verilerin sınıflandırılması için kullanılan tüm teknikler arasında en yüksek sınıflandırma başarımları LSTM tabanlı derin öğrenme uygulamasıyla %93 olarak elde edilmiştir. Klasik veri madenciliği yöntemleri ile kıyaslandığında en yüksek başarımları ile sınıflandırma yapan yöntemle bile arasında %3'lük fark vardır. Bu da derin öğrenmenin diğer birçok çalışmada elde edilen yüksek sınıflandırma başarımlarına, MRS veri seti ile sınıflandırmada da etkili sınıflandırma başarımları gösterdiğini ortaya koymaktadır. Elde edilen sonuçlar, klasik sınıflandırma yöntemlerine göre derin öğrenme tabanlı LSTM uygulamasının MRS verilerinin sınıflandırılmasında elde edilen yüksek sınıflandırma başarımları ise doktora tanı ve teşhis konusunda yardımcı olacak BDT sisteminin oluşturulmasında kullanılabilirliğini göstermektedir.

Birçok beyin rahatsızlığı arasından tümör teşhis ve tedavi planlamasının doğru yapılması çok önemli bir işlemdir. Bu işlemlerin belirli merkezlerde yapılması ciddi bir iş yükü ve yoğunluğu ortaya çıkarmaktadır. BDT sistemleri, bu gibi yoğunlukların belirli merkezler de oluşmasını engelleyerek, ülke genelinde teşhis ve tedavinin eşit yapılmasına da katkı sağlayabilir. Çalışmada ilgili alandaki tıp uzmanının, konunun önemine dönük görüşleri dikkate alınmıştır. Beyin gibi en hayati organdaki müdahaleler öncesinde, tamamen doktorun sübjektif uzmanlığına bağlı değerlendirmelerden kaynaklanabilecek problemler yaşanabilmektedir. Yanlış tanı, bu en hayati organa dönük yanlış tedavi anlamına gelmektedir. Birçok tıbbi alanda her geçen gün kullanımı artan, doktora tanıda destek olabilecek, objektif bir BDT sistemiyle, oluşabilecek zararların azaltılması sağlanabilmektedir. Bu amaçla önerilen bu çalışmada, beyin tümör tanısında kullanılan en etkili tetkiklerden olan MRS verileri en güncel tekniklerle analiz edilmiştir. Elde edilen sınıflandırma başarımları umut vaat etmektedir.

#### Teşekkür (Acknowledgement)

Çalışmada kullanılan veri setinin hazırlanmasında desteklerinden dolayı KSÜ Tıp Fakültesi Beyin Cerrahisi Bölümünden Doç. Dr. İdris ALTUN'a teşekkür ederiz.

#### Kaynaklar (References)

1. Esen S.Ö., Bozkurt M., Adıbelli H.Z., Aykut E., Canverenler S., Proton MR Spektroskopinin beyin tümörlerinde tanısal değeri, İTÜ Tepecik Eğitim Hast Derg, 24 (2), 93-98, 2014.

2. Karatağ O., İntrakranyal kaplayıcı lezyonların ayırıcı tanısında MR spektroskopinin yeri, Radyoloji Uzmanlık Tezi, Sağlık Bakanlığı Şişli Etfal Eğitim ve Araştırma Hastanesi, İstanbul, 2005.
3. Cüce A.M., Beyin kitlelerinin tanısında MR spektroskopinin yeri ile kısa ve uzun TE MR spektroskopinin karşılaştırılması, Uzmanlık Tezi, Gazi Üniversitesi, İstanbul, 2005.
4. Wendt S.L., Welinder P., Sorensen H.B.D., Peppard P.E., Jennum P., Peroa P., Mignot E., Warby S.C., Inter-expert and intra-expert reliability in sleep spindle scoring, Clin. Neurophysiol., 126, 1548-1556, 2015.
5. Luka, A., Devosa J.A.K., Suykens L., Vanhamme F.A., Howe C., Majo's A., Moreno-Torres M., Van Der Graaf A.R., Tate C. Aru's S., Van H., Brain tumor classification based on long echo proton MRS signals, Artif. Intell. Med., 31, 73-89, 2004.
6. Nagori M., Joshi M., Methods and algorithms for extracting values from MRS Graph for brain tumor detection, 2013 International Conference on Electronic Engineering and Computer Science (EECS 2013), Beijing, China, 331-336, 22-23 May, 2013.
7. Carlos A., Daniel A.S., Alfredo V., Enrique R., Automated classification of brain tumors from short echo time in vivo MRS data using gaussian decomposition and bayesian neural networks, Expert Syst. Appl., 41, 5296-5307, 2014.
8. Swapna G., Soman K.P., Vinayakumar R., Automated detection of diabetes using ESA and ESA-LSTM network and heart rate signals Procedia Comput. Sci., 132, 1253-1262, 2018.
9. Tanveer S., M Hasan., Cuffless blood pressure estimation from electrocardiogram and photoplethysmogram using waveform based ANN-LSTM network, Biomed. Signal Process. Control, 51, 382-392, 2019.
10. Oh S.L., Eddie Y.K.N., Tan S., Acharya R.U., Automated diagnosis of arrhythmia using combination of ESA and LSTM techniques with variable length heart beats, Comput. Biol. Med., 102, 278-287, 2018.
11. Michielli N., Acharya R.U., Molinari F., Cascaded LSTM recurrent neural network for automated sleep stage classification using single-channel EEG, Comput. Biol. Med., 106, 71-81, 2019.
12. Ranjith G., Parvathy R., Vikas V., Chandrasekharan K., Nair S., Machine learning methods for the classification of gliomas: Initial results using features extracted from MR spectroscopy, The Neuroradiology Journal, 28 (2), 106-111, 2015.
13. Kaya Y., Pehlivan H., KEYK, NN, BAYES, DT ve SVM Kullanılarak EKG Vurularının Sınıflandırılması, ISITES 2014 Sempozyumu (ISITES'2014), Karabük-Türkiye, 1413-1423, 18-20 Haziran, 2014.
14. Karal C., Compression of ECG data by support vector regression method, Journal of the Faculty of Engineering and Architecture of Gazi University, 33 (2), 743-755, 2018.
15. Yabanova İ., Yumurtacı M., Classification of dynamic egg weight using support vector machine, Journal of the Faculty of Engineering and Architecture of Gazi University, 33 (2), 393-402, 2018.
16. Kaya, A., Keçeli, S., A., Can, B., A., Examination of various classification strategies in classification of lung nodule characteristics, Journal of the Faculty of Engineering and Architecture of Gazi University, 34 (2), 709-725, 2019.
17. Altun S., MR spektroskopisi temelli beyin tümörü teşhisinde veri madenciliği uygulamaları, Yüksek Lisans Tezi, Kahramanmaraş Sütçü İmam Üniversitesi, Fen Bilimleri Enstitüsü, Kahramanmaraş, 2018.
18. MATLAB. <https://www.mathworks.com/help/deeplearning/examples/classify-sequence-data-using-lstm-networks.html>. Erişim tarihi Mart 31, 2019.
19. Hochreiter S., Schmidhuber J., Long-Short Term Memory, Neural Comput, 9(8), 1735-1780, 1997.
20. MATLAB. <https://www.mathworks.com/help/deeplearning/ref/trainingoptions.html>. Erişim tarihi Mayıs 15, 2019.
21. Dandil E., Karaca S., Detection of pseudo brain tumors via stacked LSTM neural networks using MR spectroscopy signals, Biocybernetics and Biomedical Engineering, 41 (1), 173-195, 2021.