



Kahramanmaraş Sütçü İmam University

Journal of Engineering Sciences



Geliş Tarihi : 15.11.2018
Kabul Tarihi : 04.04.2019

Received Date : 15.11.2018
Accepted Date : 04.04.2019

MR SPEKTROSKOPİ TEMELLİ BEYİN TÜMÖRÜ TEŞHİSİNDE LOJİSTİK REGRESYON UYGULAMASI

APPLICATIONS OF LOGISTIC REGRESSION IN MR SPECTROSCOPY BASED BRAIN TUMOR DIAGNOSIS

*Sinan ALTUN, Ahmet ALKAN**

Kahramanmaraş Sütçü İmam Üniversitesi, Elektrik Elektronik Mühendisliği Bölümü, Kahramanmaraş, Türkiye

*Sorumlu Yazar / Corresponding Author: Ahmet ALKAN, aalkan@ksu.edu.tr

ÖZET

Beyin tümörü teşhisinin, birçok hastalık teşhisinde olduğu gibi farklı yöntemler kullanılarak doğrulanması gerekmektedir. Çünkü yanlış teşhis doğrudan insan hayatını etkilemektedir. MR Spektroskopi ilk başta laboratuvar çalışmalarında kullanılmıştır. Daha sonra MR Spektroskopinin su ve yağ haricindeki metabolitleri ölçebildiği keşfedilmiştir. Bu keşifle beraber, MR Spektroskopi beyin tümörü teşhisinde doğrulayıcı bir yöntem olarak kullanılmaya başlanmıştır. MR Spektroskopi ile kolin, kreatin ve N-Asetil Aspartat metabolit değerleri ölçülür. Bu değerlerin doğru yorumlanması ciddi bir uzmanlık gerektirir. Yapılacak bir uzman karar destek sistemi hızlı ve doğru teşhis açısından önemlidir. Çalışma MRS temelli beyin tümörü teşhisi için yapılabilecek uzman karar destek sisteminin temeli olan sınıflandırma yöntemlerinin başarımlarının karşılaştırmasını içermektedir. Naive Bayes' de %87 başarımla, Lojistik regresyonda %90 başarımla elde edilmiştir. AUC alan değerleri ise Naive Bayes için 0,912, Lojistik Regresyon için 0,977 olarak hesaplanmıştır. %87 sınıflandırma ve 0,912 AUC alan hesaplaması yüksek bir başarıdır, ancak Lojistik Regresyon daha iyi sınıflandırma ve AUC alan sonucu vermiştir. Bu da MRS temelli beyin tümörü teşhisinde uzman karar destek sistemi oluşturmak için Lojistik Regresyonun, Naive Bayes yöntemine göre daha uyumlu olabileceğini göstermektedir.

Anahtar Kelimeler: MR Spektroskopi, Beyin Tümörü, Makine Öğrenmesi.

ABSTRACT

Diagnosis of brain tumor should be verified using different methods, as in many disease diagnoses. Because misdiagnosis directly affects human life. MR spectroscopy was first used in laboratory studies. It was later discovered that it can measure metabolites other than water and oil. With this discovery, MR spectroscopy has been used as a confirmatory method in the diagnosis of brain tumor. It measures choline, creatine and N-Acetyl Aspartate metabolites. Accurate interpretation of these values requires serious expertise. An expert decision support system is important for quick and accurate diagnosis. The study includes a comparison of the performance of classification methods, which are the basis of expert decision support system for MRS based brain tumor diagnosis. %87 performance in Naive Bayes and 90% performance in logistic regression were obtained. AUC area values were calculated as 0,912 for Naive Bayes and 0,977 for Logistic Regression. The 87% classification and the 0.912 AUC area calculation were high successes, but the Logistic Regression had better classification and the AUC area calculation. This suggests that Logistic Regression may be more compatible than Naive Bayes method to create an expert decision support system for MR spectroscopy-based brain tumor diagnosis.

Keywords: MR Spectroscopy, Brain Tumor, Machine Learning.

GİRİŞ

MR Spektroskopi genelde beyin ve sinir cerrahisi kliniği tarafından radyoloji kliniğinden istenir. Ayrıca MRS değerlerinin doğru okunup yorumlanması ciddi bir uzmanlık gerektirir. Bunun anlamı beyin kanaması veya farklı bir durumun beyin tümörü olarak değerlendirilmemesi ve hastaya gereksiz bir cerrahi müdahalenin yapılmaması gibi


yanlış tedavide uygulanmamasıdır. Ayrıca beyin tümörü olan bir vakaya ivedi olarak müdahale etmeyip yanlış tedaviler uygulamak hastanın kaybına veya kalıcı bir hasar almasına neden olabilir. Ayrıca klinikler arası gidip gelme ile oluşacak zaman kaybı da istenmeyen bir durumdur.

MRS ile yapılan işlem beynin şüphelenilen bölgesinde, beyin tümörü teşhisi için önemli olan kolin (Cho), kreatin (Cr) ve N-Asetil Asetat (Naa) metabolit değerlerini ölçmek ve bunların oranlarını Cho / Cr, Cho / Naa ve Naa / Cr belirlemektir. Bu değerler özellikle kolin tümör bölgesinde peek yapar ve ileri evredeki tümörlerde bu değer çok daha yüksektir (Esen ve ark., 2014; Karatağ, 2005; Cüce, 2005).

MR ile farklı hastalıkların teşhisi için su ve yağ metabolit değerleri ölçülür. Oysa beyin tümörü için özellikle kolin, kreatin ve N-Asetil Asetat metabolit değerleri ölçülmelidir. MRS ile bunun mümkün olduğunun fark edilmesinin tarihi çok eski değildir. MRS' in laboratuvar çalışmalarında kullanılmasının tarihi çok daha eskiye dayanır (Esen ve ark., 2014; Karatağ, 2005).

Tümör olmayan alanda N-Asetil Asetat (Naa), kolin (Cho) ve kreatin (Cr) metabolit değerleri düşüktür. Tümör olan alanında ise N-Asetil Asetat (Naa) azalmış, kolin (Cho) artmış, kreatin (Cr) azalmıştır. Tümör bölgesinde ölçülen kolin (Cho) değeri yüksektir. MRS ayrıca ölçülen metabolitlerin değerlerini grafiksel olarak da çizmekte oransal olarak da vermektedir: Cho/Naa, Cho/Cr ve Naa/Cr şeklindedir. Kolin değeri yüksek olduğu için Cho/Naa ve Cho/Cr oranları tümörde yüksektir. MRS temelli beyin tümörü tespitinde Cho/Cr oranının yüksek çıkması teşhiste en önemli faktördür (Esen ve ark., 2014; Cüce, 2005).

MRS ile ölçümü gösteren Şekil 1.'de görüleceği üzere, uzman doktor şüphelenilen bölgeyi cihazda seçer. Sarı olarak Şekil 1.'de görülen bu bölge cihazda 5 satır ve 5 sütun ile 25 kareye ayrılır ve her bir kare için ölçülen kolin, kreatin ve N-Asetil Asetat değerleri yazılarak bunların grafiksel çizimi de yapılır.



Şekil 1. MRS Görüntüsü

Tümör olmayan bölgede kolin metaboliti pik yapmamıştır. Ayrıca Cho/Cr, Cho/Naa ve Naa/Cr metabolit oranları düşüktür. Özellikle kolin metabolitinin diğer metabolitlere oranı düşüktür.

Tümör olan bölgede kolin metaboliti diğer metabolitlere göre daha yüksektir. Ayrıca Cho/Cr, Cho/Naa ve Naa/Cr metabolit oranları yüksektir. Özellikle kolin metaboliti yüksek olduğundan diğer metabolitlerle oranı yükseltmektedir.

Yaptığımız bu çalışmada beyin tümörü teşhisi için kullanılan ve MRS ile ölçülen değerlerin yorumlanması ayrıca bir beyin ve sinir cerrahisi uzmanı gözetiminde olmuştur. Uzmanında belirttiği üzere MRS temelli teşhis için dikkatli olmak ve iyi bir uzmanlık gereklidir. Ayrıca MRS cihazı ile ölçülen değerlere göre doktora yardımcı bir sistemin geliştirilmesi oldukça faydalı olacaktır.

Bu çalışmada, MR Spektroskopisi ile ölçülen Cho/Cr, Cho/Naa, Naa/Cr değerler kullanılarak tümör veya tümör değil teşhisi için WEKA programında çeşitli tekniklerdeki AUC alan değeri hesaplanacaktır. İlgili tekniklerde sınıflandırmalar yapılacaktır. Bununla birlikte önceden elimizdeki verilere göre tümör veya tümör değil denilen hasta bilgilerini kullanarak makine öğrenmesine dayalı bir sistemin temelini oluşturabilecek bir sınıflandırma yapılmak istenmektedir. Tasarlanabilecek bu sistem ivedi olarak beyin tümörü teşhisi ve müdahalesinin yanı sıra eğer şüpheli bölgede herhangi bir olumsuz durum söz konusu değilse yanlış tedavinin önüne geçilebilecektir. Özetle doğru ve hızlı teşhis yapabilen, yardımcı bir sistem için bu çalışma yapılmıştır. Ancak olabilecek bu sistem teşhis koymada kesin ve bağlayıcı nitelikte teşhis koyma aracı olmayıp son karar elbette uzmanlara aittir.

Tomak, L., Bek, Y. tanı testlerinde hastalık teşhisi için ROC eğrisi ve altında kalan alan AUC için hesaplamalara dayalı bir çalışma yapmışlardır. Çalışmalarında örnek bir tanı testi sınıflaması hesabı da yaparak ROC eğrisi ve AUC alan analizinin hesaplamasının kolay olduğunu ve görsel nitelik taşıdığından anlaşılmasının da kolay olduğunu vurgulamışlardır (Alan, 2014).

Beyin tümörü teşhisi konulmuş hastaların evrelerini tahmin etmek için Lukas, A ve arkadaşları çalışmalarında beyin tümörü olan hastaların, Doğrusal Ayırma Analizi, Destek Vektör Makineleri tekniği ile LS, RBF çekirdeklerini kullanarak sınıflandırmışlardır. MR Spektroskopinin bütün spektrumunu kullandıkları çalışmalarında Doğrusal Ayırma Analizi (PCA/LDA) tekniğinde %64,69 başarı ile Destek Vektör Makineleri tekniğinin (SVM), LS çekirdeğini kullanarak yaptıkları çalışmada %93,98 başarı ile, RBF çekirdeği ile yapılan çalışmada %97,8142 başarı sağlamışlardır (Lukas ve ark., 2014).

Dirican A. çalışmasında tanı testleri için ROC analizini, formülleri ile detaylı olarak incelemiştir. Çalışmasında "Uygulama örneğimizde BERA yönteminin duyarlılığı "1" özgüllüğü "0.77" ve doğruluğu "0.83", CT yönteminin ise duyarlılığı, özgüllüğü ve doğruluğu "1" olarak bulunmuştur. Yine eğri altı alanlar ve standart hata ölçütleri de sırasıyla 0.7733 ± 0.0624 ve 1.00 ± 0.00 'dır." sonucuna varmıştır (İşler ve Narin, 2012).

MRS' de değerlerin okunması zaman aldığından bu değerleri hem okuyup hem de tümörün evresini saptamak için Nagori, M. Joshi, M, çalışmalarında, MRS' de verileri okuyup veri tabanına yazılmasını sağlayan bir sistem üzerinde yoğunlaşmışlardır. Bu çalışmada kolin (Cho), kreatin (Cr) ve N-Asetil Aspartat değerleri MRS üzerinden okunmaktadır. Çalışmada 88 adet hasta bilgisi yer almaktadır ve bu bilgileri farklı hastanelerden almışlardır. Hastaların tamamı beyin tümörüdür ve farklı evrededirler. 12 hastanın MRS görüntüsünden kolin (Cho), kreatin (Cr) ve N-Asetil Aspartat (Naa) verilerini %100 oranında bir başarı ile okuyup veri tabanına yazmışlardır. Veri tabanına yazılan bu değerlere göre beyin tümörü evre sınıflandırmalarındaki başarı %66,67 olmuştur (Nagori ve Joshi, 2013).

Başka bir beyin tümörü evresini tahmin etmeye yönelik çalışmayı Carlos A ve arkadaşları yapmıştır. Çalışmada MRS spektral görüntüleri kullanılmıştır. Bu çalışmada MRS ile elde edilen metabolit değerleri yerine grafikler kullanılmış ve çalışma Gaussian Ayırıştırması ve Yapay Sinir Ağları teknikleri ile yapılmıştır. Gaussian Ayırıştırması uygulanarak ilgisi az olan veriler sistemden çıkarılmıştır. Çalışmalarındaki en yüksek başarı %93.847 ile gerçekleşmiştir (Arizmendi ve ark., 2014).


MATERYAL VE METOT

Materyal

Yaptığımız çalışma 49 adet tümör teşhisi konulmuş, 44 adet tümör teşhisi konulmamış toplam 93 adet hastanın MRS 'den elde edilen veriler ve yaş, cinsiyet gibi farklı bilgileri içermektedir. Bu bilgileri gerekli etik kurul izni alınarak Ocak 2009 ve Mayıs 2017 tarihleri arasında, Kahramanmaraş Sütçü İmam Üniversitesi Beyin Cerrahisi polikliniğine başvurup tümör şüphesi ile MRS çekilen hasta bilgilerinden oluşmaktadır. Her bir hastamız için 5 adet özellik vardır. Tablo 1' de özellikler ve açıklamaları yer almaktadır. Şekil 2' de özelliklerin dağılımının WEKA programında elde edilen grafiği yer almaktadır.

Tablo 1. Her Bir Hasta İçin Veriler

Özellik	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 Spektroskopi 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



Şekil 2. Çalışmada Kullanılan Veriye Ait Özelliklerin Dağılımı

Metot

A. Lojistik Regresyon

Tıp biliminde kullanımı yaygın olan bir yöntemdir. Yöntemle kanser olma ihtimali (Evet/Hayır) belirlenebilir... Vb. Lineer regresyonda veriler arasında doğrusal bir çizgi çizilebilirken burada logaritmik bir çizgi elde edilir. Logaritmik oluşturulacak çizgi özellik sayısı fazla olan yani boyutu fazla olan veri setlerinde her veriye daha yakın bir doğru çizilmesini sağlayacaktır. Lojistik regresyon bir veya daha fazla bağımsız değişken bulunan bir veri setinde sınıflandırma yapmak için kullanılan bir yöntemdir. Lojistik regresyon, 0 ile 1 arasındaki değerlerle sınırlı lojistik eğrisi üretir. Lojistik regresyonun temeli lojistik fonksiyondur. Lojistik fonksiyon ise 0 ile 1 arasında değer üretir (Şeker, 2017; Girginer ve Cankuş, 2008).

Lineer regresyon için fonksiyon denklem 1' de görüldüğü gibidir. Burada X değişkeni a0 ise değişkenin katsayısıdır. Denklemi yorumlarsak değişkendeki her bir 1 birimlik artış veya azalış sonucu doğrudan etkilemektedir. Lojistik fonksiyonun amacı ise değişkenin bir sınıfa dâhil olma olasılığını hesaplamaktır. Bu nedenle lineer regresyon denkleminin sol tarafını 0 ile 1 arasında değer alacak şekilde denklemin sağ tarafına lojistik fonksiyonu uygulanır ve denklem 2 elde edilir (Şirin, 2018).

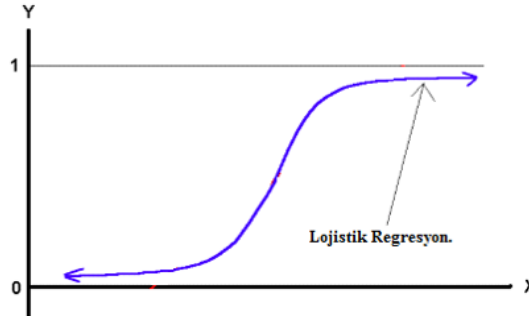
$$y = a_0 + a_1X \quad (1)$$

$$y = \frac{e^{a_0+a_1X}}{1+e^{a_0+a_1X}} \quad (2)$$

Denklem 2 üzerinde basit matematiksel eşitleme işlemleri yapınca denklem 3 elde edilir. Her iki tarafın logaritmasını alırsak bu bize lojistik regresyon formülünü verecektir. Denklem 4’de lojistik regresyon formülü yer almaktadır. Şekil 3’ de lojistik regresyon için örnek bir grafik yer almaktadır (Şirin, 2018).

$$\frac{y}{1-y} = e^{a_0+a_1x} \quad (3)$$

$$\log\left(\frac{y}{1-y}\right) = \log(e^{a_0+a_1x}) \quad (4)$$



Şekil 3. Lojistik Regresyon İçin Oluşturulan Doğru (Şirin, 2018)

B. Naive Bayes

Naive Bayes sınıflandırma yöntemi de olasılık tabanlı bir yöntemdir. Olasılık söz konusu olduğu için her bir veri, sistem için önemlidir. Veri setinde yer alan özelliklerin sisteme katkısı çok az olduğunda sistem bu özelliği almayabilir (Altun, 2018).

Denklem 5’ de Naive Bayes yöntemi temelini oluşturan Bayes teoremi formülü yer almaktadır. Buradaki $P(c|x)$, “x” in olması durumunda “c” nin olma olasılığı olup, koşullu olasılık olarak adlandırılır. $P(x|c)$ olayların her birinin ihtimallerinin çarpımını ifade eder. $P(c)$ sınıfın olasılığıdır (Haltaş ve Alkan, 2014; Kaya ve Pehlivan, 2014; Alkuşak ve Gök, 2014).

$$P(c|x) = \frac{P(x|c)P(c)}{P(x)} \quad (5)$$

ROC Eğrisi/ AUC Alanı

ROC eğrisi, ikili sınıflandırma sistemlerinde ayırım eşik değerinin farklılık gösterdiği durumlarda, hassasiyetin kesinliğe olan oranıyla ortaya çıkmaktadır. Daha basit anlamda ise doğru pozitiflerin yanlış pozitiflere olan kesri olarak da ifade edilebilir. AUC alanı tespit edilirken doğru pozitif oranı ve yanlış pozitif oranı hesaplamalarının yapılması gerekir. Doğru pozitif oranı ve yanlış pozitif hesaplamasının da kullanılan veriler ve açıklamaları Tablo 2’de yer almaktadır. Şekil 4’ de örnek bir ROC eğrisi grafiği vardır (Altun, 2018).

Tablo 2. ROC Eğrisi Test Sonucu İfadeleri

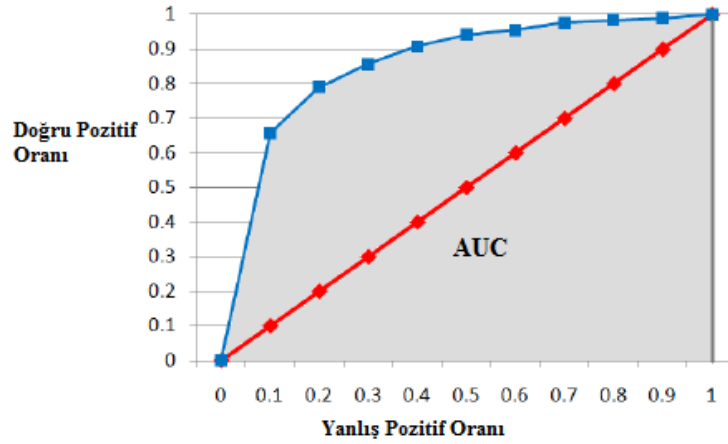
Test Sonucu	Açıklama
DP:	Gerçek durum pozitifken test sonucu pozitif
YP:	Gerçek durum negatifken test sonucu pozitif
DN:	Gerçek durum negatifken test sonucu negatif
YN:	Gerçek durum pozitifken test sonucu negatif

Denklem 6 ve denklem 7’ de ROC hesaplaması için kullanılan parametrelerin formülü yer almaktadır.

$$\text{Doğru Pozitif Oranı} = \frac{DP}{(DP + YN)} \quad (6)$$

$$\text{Yanlış Pozitif Oranı} = \frac{YP}{(YP + DN)} \quad (7)$$

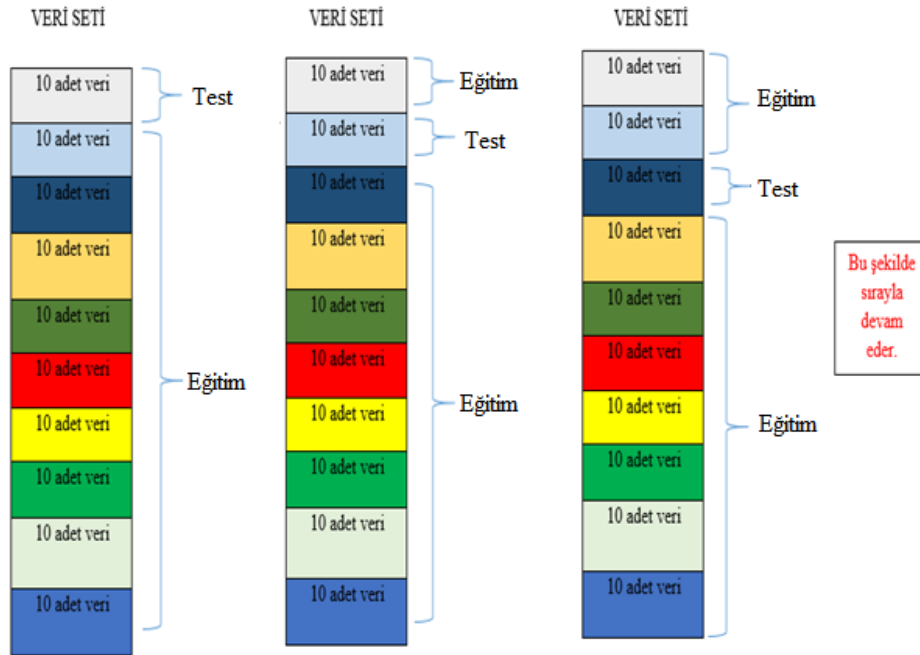
Koordinat sisteminde X eksenini yanlış pozitif oranı, Y eksenini doğru pozitif oranı yer alır ve kesim noktalarına karşılık gelen noktalar birleştirilerek ROC eğrisi çizilir. ROC eğrisi altında kalan alan AUC olarak isimlendirilir. Pozitif ve negatifler birbirinden tamamen ayrılırsa AUC değeri 1 olur. AUC değeri azaldıkça başarı oranı azalır (Alan, 2014, İşler ve Narin, 2012).



Şekil 4. ROC Eğrisi Altında Kalan Alan AUC

“n” Kat Çapraz Doğrulama Eğitim Verisi

Klasik doğrulamada, eğitimde eldeki verilerin belirli bir kısmı ve diğer kalan ise test için kullanılır. Klasik doğrulama tekniğinde genelde, eldeki verilerin %66’sı eğitim, %33 test için kullanılır. “n” katlı çapraz doğrulamada veri seti “n” kadar bölüme ayrılır. Veri madenciliği genel uygulaması olarak “n” 10 seçilir. Şekil 5’ te 10 kat çapraz doğrulamanın çalışma şeması yer almaktadır.



Şekil 5. 10 Kat Çapraz Doğrulama Yöntemi

DENEYSEL ÇALIŞMALAR

Çalışma 10 kat çapraz doğrulama yöntemi kullanılarak yapılmıştır. Tablo 3’ de lojistik regresyon ile veri setinde yer alan 93 veriden 84 tanesi doğru, 9 tanesi yanlış sınıflandırılmıştır. Bu da lojistik regresyonda %90 gibi bir başarı elde edilmesini sağlamıştır. %90 başarı yüksek bir başarı olup yöntemin MR Spektroskopi verileri için iyi bir sonuç verdiği söylenebilir.

Tablo 3. Lojistik Regresyon İstatistik Sonuçları

Doğru Sınıflandırılan Örnek Sayısı (Correctly Classified Instances)	84	90.3226 %
Yanlış Sınıflandırılan Örnek Sayısı (Incorrectly Classified Instances)	9	9.6774 %

Doğru pozitif oranı(TP Rate), “1” e ne kadar yakınsa ve Yanlış pozitif oranı(FP Rate) “0” ne kadar yakınsa daha doğru bir sınıflandırma yapılmış anlamına gelir. Tablo 4’ de MR Spektroskopi verileri için elde edilen TP Rate ve FP Rate oranları görülmektedir. AUC Area bir anlamda çalışmanın ayırt etme gücünü gösterir ve “1” e yakın olması sistemin daha iyi çalıştığını gösterir (Altun ve Alkan, 2018).

AUC alanının 1’ e ne kadar yakın olursa, sınıfların birbirinden o oranda daha iyi ayrılacağı daha önce belirtilmişti. Tablo 4’ de görüleceği üzere MR Spektroskopi veri setinde 0.977 gibi yüksek bir değer elde edilmiştir. 0.977 AUC alanı, tümör ve tümör olmayan verilerin birbirinden ne kadar iyi ayrıldığını ifade etmektedir.

Tablo 4. Lojistik Regresyon Doğruluk Sonuçları

	Doğru Pozitif Oranı	Yanlış Pozitif Oranı	AUC Alanı	Sınıf
	0,898	0,091	0,977	1
	0,909	0,102	0,977	0
Ortalama:	0,903	0,096	0,977	

Tablo 5’ de lojistik regresyon ile veri setinde yer alan 93 veriden 81 tanesi doğru, 12 tanesi yanlış sınıflandırılmıştır. Bu da Naive Bayes %87 gibi bir başarı elde edilmesini sağlamıştır. %87 başarı yüksek bir başarı olup ama lojistik regresyonda daha yüksek bir başarı elde edilmiştir.

Tablo 5. Naive Bayes İstatistik Sonuçları

Doğru Sınıflandırılan Örnek Sayısı (Correctly Classified Instances)	81	87.09 %
Yanlış Sınıflandırılan Örnek Sayısı (Incorrectly Classified Instances)	12	12.9 %

Tablo 6’ da Naive Bayes yöntemiyle, MR Spektroskopi verileri için elde edilen TP Rate ve FP Rate oranları görülmektedir. AUC alanının 1’ e ne kadar yakın olursa sınıfların birbirinden o oranda daha iyi ayrılacağı daha önce belirtilmişti. Tablo 6’ da görüleceği üzere MR Spektroskopi veri setinde 0.912 gibi yüksek bir değer elde edilmiştir. 0.912 AUC alanı tümör ve tümör olmayan verilerin birbirinden ne kadar iyi ayrıldığını göstermektedir. Ancak lojistik regresyonda sınıflar arası daha iyi bir ayırım söz konusudur.

Tablo 6. Naive Bayes Doğruluk Sonuçları

	Doğru Pozitif Oranı	Yanlış Pozitif Oranı	AUC Alanı	Sınıf
	0,816	0,068	0,912	1
	0,932	0,184	0,912	0
Ortalama:	0,871	0,123	0,912	

SONUÇ ve DEĞERLENDİRME

Beyin tümörü teşhisinin ivedi olarak yapılması oldukça önemlidir. MRS teknolojisi kullanılarak beyin tümörü teşhisi oldukça iyi bir uzmanlık gerektirdiğinden, doktora yardımcı bir uzman karar destek sisteminin oluşturulması faydalı olacaktır.

Çalışmada MRS verilerini kullanarak beyin tümörü teşhisinde, uzman karar destek sisteminin temeli olan sınıflandırma yöntemlerinden Naive Bayes ve Lojistik Regresyon sınıflandırma teknikleri kullanılarak, elde edilen analiz sonuçları karşılaştırılmıştır. Naive Bayes yöntemiyle %87 sınıflandırma başarısı ve 0,912 AUC alanı elde edilmiştir. Lojistik Regresyon tekniğinde ise %90 sınıflandırma başarısı ve 0,977 AUC alanı hesaplanmıştır. Elde edilen sınıflandırma başarımları incelendiğinde, Naive Bayes yönteminin de ilgili alanda hekimin kararını oldukça yüksek bir başarıyla destekleyebilecektir. Ancak MRS verileri kullanılarak yapılan bu çalışmada, sınıflandırma işleminde Lojistik regresyon tekniğinin daha başarılı olduğu görülmüştür. Bu sonuçlar, MRS verilerini kullanarak beyin tümörü teşhisi yapabilen uzman karar destek sistemleri için, sınıflandırma yöntemlerinden Lojistik Regresyon yöntemi Naive Bayes yöntemine göre daha uyumlu olduğunu ortaya koymaktadır.

Teşekkür

Çalışmada kullanılan veri seti KSÜ Tıp Fakültesi Beyin Cerrahi Anabilim Dalı'ndan temin edilmiştir. İlgili Anabilim dalından Doç. Dr. İdris ALTUN' a destekleri için teşekkür ederiz.

KAYNAKLAR

Alan, M.A. 2014. “ Sivas Erzincan Kalkınma Projesi (SEKP) Verilerinin Veri Madenciliği ile Sınıflandırılması ve Kümelenmesi” Manas Sosyal Araştırmalar Dergisi 2014; Cilt: 03 Sayı: 10 2014: 129-144.s

Alkan, A., Günay, M., “Identification of EMG signals using discriminant analysis and SVM classifier”, Expert Systems with Applications 39, (2012) 44–47.

Alkuşak, E., Gök, M., “Karaciğer Yetmezliğinin Teşhisinde Makine Öğrenmesi Algoritmalarının Kullanımı”, ISITES 2014 Sempozyumu (ISITES'2014), 18-20 June 2014, Karabük, Türkiye.

Altun, S., “MR Spektroskopi Temelli Beyin Tümörü Teşhisinde Veri Madenciliği Uygulamaları”, KSÜ FBE, Elektrik Elektronik Mühendisliği Anabilim Dalı, Yüksek Lisans Tezi, 2018.

Arora, R., Suman. 2012. “Comparative Analysis of Classification Algorithms on Different Datasets using WEKA” International Journal of Computer Applications (0975 – 8887) Volume 54– No.13, September 2012, 21-25s.

Carlos A., Daniel A., S., Alfredo V., Enrique R. 2014. “Automated classification of brain tumours from short echo time in vivo MRS data using Gaussian Decomposition and Bayesian Neural Networks” Expert Systems with Applications 41 (2014) 5296–5307s.

Cüce, A.M. 2005. “Beyin Kitlelerinin Tanısında MR Spektroskopinin Yeri İle Kısa ve Uzun TE MR Spektroskopinin Karşılaştırılması”. G.Ü. Uzmanlık Tezi, İstanbul, 98s.

Dirican A. “Tanı Testi Performanslarının Değerlendirilmesi ve Kıyaslanması” Cerrahpaşa Tıp Dergisi. 2001; 32 (1): 25-30.

Esen, S.Ö., Bozkurt, M., Adıbelli, H.Z., Aykut, E., Canverenler, S. 2014. “Proton MR Spektroskopinin Beyin Tümörlerinde Tanısal Değeri.” ITÜ Tepecik Eğit Hast Derg 2014; 24 (2): 93-98.s

Girginer,G., Cankuş, B. “Tramvay Yolcu Memnuniyetinin Lojistik Regresyon Analiziyle Ölçülmesi: Estram Örneği” YÖNETİM VE EKONOMİ Yıl:2008 Cilt:15 Sayı:1 Celal Bayar Üniversitesi İ.İ.B.F. MANİSA.

Göker, H.,Şahin. İ., Tekedere. H. 2015. “ Erken Çocukluk Döneminde Otizm Teşhisine Yönelik Dinamik Uzman Sistem Tasarımı” Bilişim Teknolojileri Dergisi, Cilt: 8, Sayı: 3, 167–172.s

Haltaş, A., Alkan, A. İmmunohistokimyasal Boyalar ile Tiroid Tümörü Teşhisinde Naive Bayes Algoritması Kullanılması, Akademik Bilişim 2016 Sempozyumu(ab'2014) 5-7 Şubat, 2014, Mersin, Mersin-Türkiye), s. 931-935

İşler, Y., Narin, A. 2012. “ WEKA Yazılımında k-Ortalama Algoritması Kullanılarak Konjestif Kalp Yetmezliği Hastalarının Teşhisi” SDU Teknik Bilimler Dergisi 2012; Cilt: 2 Sayı: 4 2012: 21-29.s

Karatağ, O. 2005. “İntrakranyal Yer Kaplayıcı Lezyonların Ayırıcı Tanısında MR Spektroskopinin Yeri”. Sağlık Bakanlığı Şişli Etfal Eğitim ve Araştırma Hastanesi. Radyoloji Uzmanlık Tezi, İstanbul, 50s.

Kavzoğlu, T., Çölkesen, İ. 2010. “Destek Vektör Makineleri ile Uydu Görüntülerinin Sınıflandırılmasında Kernel Fonksiyonlarının Etkilerinin İncelenmesi” Harita Dergisi Temmuz 2010 Sayı 144: 73-82.s

Kaya, Y., Pehlivan, H., “ KNN, NN, BAYES, DT ve SVM Kullanılarak EKG Vurularının Sınıflandırılması”, ISITES 2014 Sempozyumu(ISITES’2014), 18-20 June 2014, Karabük, Türkiye.

Lukasa, A. Devosa, J.A.K. Suykensa, L. Vanhammea, F.A. Howeb, C. Majo’sc, A. Moreno-Torresd, M. Van Der Graafe, A.R. Tateb, C. Aru’sf, S. Van Huffela. 2004. “Brain tumor classification based on long echo proton MRS signals” Artificial Intelligence in Medicine (2004) 31, 73—89s.

Nagori, M. Joshi, M. 2013. “Methods and Algorithms for Extracting Values from MRS Graph for Brain Tumour Detection” IERI Procedia 4 (2013) 331 – 336s.

Sarıoğlu, M.K., Gökaşan, M., Boğosyan, S. (2003). Asenkron makinalar ve kontrolü, Birsen Yayınevi, İstanbul.

Shokry, A. 2012. “MRS of brain tumors: Diagrammatic representations and diagnostic approach” The Egyptian Journal of Radiology and Nuclear Medicine (2012) 43, 603–612.s

Solmaz, R., Günay, M., Alkan, A., “Uzman Sistemlerin Tiroit Teşhisinde Kullanılması”, Akademik Bilişim 2013 Sempozyumu(ab’2013), 23-25 Ocak 2013, Antalya, Türkiye.

Şeker E. Ş. Bilgisayar Kavramları. <http://bilgisayarkavramlari.sadievrenseker.com> (2017)

Şirin E. Bilgisayar Kavramları. <http://www.datascience.istanbul> (2018).


Tomak, L., Bek, Y. 2010. “İşlem karakteristik eğrisi analizi ve eğri altında kalan alanların karşılaştırılması” Journal of Experimental and Clinical Medicine 27 (2010) 58-65.s


Trzynadlowski, A.M., (2000). Control of Induction Motors. Academic press, USA.

Yücebaş, C., S., “ Prostat Kanseri Teşhisinde Veri Madenciliği Yöntemlerinin Başırım Karşılaştırması”, Akademik Bilişim 2016 Sempozyumu(ab’2016), 30 Ocak-5 Şubat 2016, Aydın, Türkiye

Zhang, M.G., Li, W.H., Liu, M.Q. (2005). Adaptive PID control strategy based on RBF neural network identification, IEEE International Conference on Neural Networks and Brain, 1854-1857.

ORCID

Sinan ALTUN  <https://orcid.org/0000-0002-2356-0460>

Ahmet ALKAN  <https://orcid.org/0000-0003-0857-0764>