



Hepatit hastalığının tespitinde bulanık mantık ve makine öğrenmesi yöntemlerinin karşılaştırılması

Comparison of fuzzy logic and machine learning methods in detection of hepatitis disease

Cengiz Coşkun^{1*}, Emre Yüksek²

¹ Mardin Artuklu Üniversitesi, Bilgisayar Mühendisliği Bölümü, cengizcoskun@artuklu.edu.tr
ORCID: <https://orcid.org/0000-0001-8552-1363>

² Sivas Bilim ve Teknoloji Üniversitesi, Bilgisayar Mühendisliği Bölümü, eyukse@ivas.edu.tr
ORCID: <https://orcid.org/0000-0002-1885-5539>

MAKALE BİLGİLERİ

Makale Geçmişi:

Geliş 23 Haziran 2023
Revizyon 30 Ağustos 2023
Kabul 16 Kasım 2023
Online 31 Aralık 2023

Anahtar Kelimeler:

hepatit, bulanık mantık, makine öğrenmesi, öznelik seçimi

ÖZ

Yaygın bir karaciğer rahatsızlığı olan hepatit, dünya çapında önemli halk sağlığı sorunlarından biridir. Klinik verilerin doğru yorumlanması, hepatit tanısının yapılabilmesi için ele alınması gereken en önemli sorunlardan birisidir. Bu çalışmada, ölümcül hepatit hastalığının tanısı için öznelik seçimi yöntemi uygulanarak, bulanık modelleme ile çeşitli makine öğrenmesi yöntemlerinin hastalık tespitindeki başarıları karşılaştırılmıştır. Çalışmada UCI makine öğrenimi deposundan edinilen hepatit veri seti kullanılmıştır. Kullanılan veri seti ilk olarak veri ön işlemeden geçirilmiş, sınıflandırma başarısının artırılması için öznelik seçimi ile veri setindeki özellik sayısı azaltılmıştır. Özellik sayısı azaltılan veri seti kullanılarak bulanık model ve makine öğrenmesi modelleri denenmiştir. Elde edilen sonuçlar çeşitli metrikler kullanılarak değerlendirilmiştir. Yapılan çalışmalar sonucunda Bulanık Mantık yöntemi ile doğruluk %94 olurken, Gradient Boosting algoritması ile doğruluk, kesinlik, duyarlılık ve f-skör metriği açısından sırasıyla %98.36, %98.68, %98.95 ve %98.91 olarak hesaplanmıştır. Elde edilen sonuçlar, hepatit hastalığının teşhisinde makine öğrenmesi yöntemlerinden Gradient Boosting yönteminin diğer makine öğrenme yöntemlerine ve bulanık yaklaşıma göre daha başarılı olduğu görülmüştür.

ARTICLE INFO

Article history:

Received 23 June 2023
Received in revised form 30 August 2023
Accepted 16 November 2023
Available online 31 December 2023

Keywords:

hepatitis, fuzzy logic, machine learning, feature selection

ABSTRACT

Hepatitis, a common liver disorder, is one of the major public health problems worldwide. Accurate interpretation of clinical data is one of the most important problems to be addressed in order to diagnose hepatitis. In this study, the success of fuzzy modeling and various machine learning methods in disease detection is compared by applying feature selection method for the diagnosis of fatal hepatitis. The hepatitis dataset obtained from the UCI machine learning repository was used in the study. The dataset was first subjected to data preprocessing and the number of features in the dataset was reduced by feature selection to increase the classification success. Fuzzy model and machine learning models were tested using the reduced number of features. The results obtained were evaluated using various metrics. As a result of the studies, the accuracy with the Fuzzy Logic method was 94%, while the accuracy with the Gradient Boosting algorithm was calculated as 98.36%. The results show that Gradient Boosting algorithm is more successful than other machine learning methods and fuzzy approach in the diagnosis of hepatitis disease.

Doi: 10.24012/dumf.1319102

* Sorumlu Yazar

Giriş

Hastalık teşhisi, tıp ve sağlık alanında bir hastalığın tedavisinde atılması gereken ilk ve en önemli adımdır. Hastalığın yanlış teşhisi, genellikle komplikasyona yol açmakta ve nihayetinde de ölümle sonuçlanabilen, yanlış tedavilere yol açabilmektedir [1]. Hastalık tedavisinde, hastalığın başlıca belirtileri ve semptomlarının düzgün bir şekilde analiz edilerek elde edilen teşhis çerçevesinde doğru tedavinin uygulanması kritik öneme sahiptir. Tedavinin doğru zamanda ve doğru şekilde uygulanması ise oldukça zor olmakla birlikte hastalık ve hastanın geçmişi hakkında çok fazla bilgi gerektirmektedir. Bu sebeple hastalığın teşhisinin doğru bir şekilde yapılması ve hastalık niteliğinin tespiti hayati önem arz etmektedir.

Karaciğer rahatsızlıklarının doğru zamanda tespit edilemediği durumlarda, hastalık, ölüme neden olabilmektedir. Karaciğer rahatsızlıklarının başlıca nedenleri; bağımlılık yapan uyuşturucu vb. maddelerin kullanımı, sürekli alkol ve sigara kullanımı, günlük eşyaların ortak kullanımı ve sterilizasyon olmadan veya doğru koruma önlemleri alınmadan yapılan kan naklidir [2]. Karaciğer rahatsızlıklarının analizi için birçok yöntem ve yaklaşım kullanılmıştır. Bunlardan bazıları fiziki muayene, karaciğer testleri, ultrason, karaciğer biyopsisi ve kan testleridir.

Dünya genelinde, son evredeki karaciğer rahatsızlıkları önemli ölüm sebeplerindedir [3]. Dünya Sağlık Örgütü'nün verilerine göre 2017 yılında hepatit nedeni ile 1,4 milyon ölüm gerçekleşmiş ve 325 milyon insan enfekte olmuştur [4].

Günümüzde yapay zekâ, birçok farklı alandaki tıbbi problemlerin çözümünde etkin olarak kullanılmakta ve bu problemlerin çözülebilmesi için akıllı sistemler geliştirilmektedir [5]. Bulanık çıkarım sistemi (Fuzzy Inference System, FIS) ve makine öğrenmesi yöntemleri, problemleri analiz etmek ve çıkarım yapmak için kullanılan yapay zekâ yöntemleridir. Bu yöntemler otonom robotlar, çeşitli endüstri alanları, bilgisayar bilimleri, tıbbi sistemler, hava tahmin sistemleri ve tarım gibi hayatın birçok alanında kullanılmaktadır.

Literatürde, hastalıkların tespiti için yapay zekâ yöntemlerinin kullanıldığı birçok çalışma bulunmaktadır. Doğrusal Diskriminant Analizi (Linear Discriminant Analysis, LDA) ve Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemi (Adaptive Network based on Fuzzy Inference System, ANFIS) kullanarak geliştirilen modellerle hepatit teşhisinde %94.16 oranında başarı sağlanmıştır [6]. Yapay Bağışıklık Tanıma Sistemi (Artificial Immune Recognition System, AIRS) ve Bulanık Kaynak Tahsis Mekanizmasını (Fuzzy Resource Allocation System) kullanarak hepatit teşhisi yapabilen bir sistemde 10-fold çapraz doğrulama (cross validation) uygulayarak %92.59 oranında doğruluk elde edilmiştir [7]. Doğrusal Olmayan Yinelemeli Kısmi En Küçük Kareler (Non-Linear Iterative Partial Least Squares) ve Kendini Düzenleyen Harita (Self Organizing Map) kullanarak geliştirilen hepatit teşhisinde ROC metriği bakımından %93.06 başarı sağlanmıştır [8]. Çok Katmanlı Mamdani Bulanık Çıkarım Sistemi (Multilayer Mamdani Fuzzy Inference System) kullanılmış hepatit B teşhisi sistemi %92.2 oranında başarı sağlamıştır [9]. ANFIS kullanan bir hepatit teşhis sistemi %95.24 oranında başarı sağlamıştır

[10]. Levenberg-Marquardt algoritması ile Yapay Sinir Ağı (Artificial Neural Network) kullanan bir hepatit teşhis sistemi, 10-fold çapraz doğrulama uygulayarak %91.87 oranında başarı sağlamıştır [11]. Başka bir kalp rahatsızlığı teşhis sisteminde Relief algoritması, Rough Set yöntemi ile C4.5 sınıflandırma algoritması kullanılmış ve Jackknife çapraz doğrulama yöntemi uygulanarak %92.59 oranında başarı sağlanmıştır [12]. Genetik Algoritma ve ANFIS kullanarak hepatit teşhis sistemi %97.44 oranında başarı sağlamıştır [13]. Destek Vektör Makinesi (Support Vector Machine, SVM) ve Benzetilmiş Tavlama (Simulated Annealing) yöntemleri ile geliştirilen hepatit teşhis sisteminde 10-fold çapraz doğrulama ile %96.25 oranında başarı sağlanmıştır [14]. Temel Bileşen Analizi (Principle Component Analysis, PCA) ve En Küçük Kareler Destek Vektör Makinesi (Least Squares Support Vector Machine, LSSVM) kullanan hepatit teşhisinde %95 oranında başarı sağlanmıştır [15]. Başka bir hepatit teşhis sisteminde Fisher Doğrusal Analiz (Local Fisher Discriminant Analysis) ve SVM kullanılmış ve %96.77 oranında başarı sağlanmıştır [16]. Rough Set ve Aşırı Öğrenme Makinesi (Extreme Machine Learning, ELM) kullanan bir hastalık teşhis sisteminde %93.75 oranında başarı elde edilmiştir [17]. ELM ve Tek Katmanlı İleri Beslemeli Sinir Ağı (Single Layer Feed Forward Neural Network) kullanılan sistemde %94.44 oranında başarı sağlanmıştır [18].

Bu çalışmada öznitelik seçimi yöntemi (feature selection) ile bulanık çıkarım sistemi ve makine öğrenmesi kullanılarak hepatit hastalığı tespiti için model geliştirilmeye çalışılmış ve bulanık çıkarım sistemi ile makine öğrenmesi modellerinin başarıları karşılaştırılmıştır. İlk aşamada, öznitelik seçimi ile veri kümesindeki özellik sayısı azaltılmaya çalışılmıştır. Bunun için her bir özneliğin çıktı değişkeni ile sahip olduğu korelasyon değeri kullanılarak hastalıkla ilişkili en önemli özellikler seçilmeye çalışılmış ve bu sayede sınıflandırma doğruluğunun artırılması hedeflenmiştir. İkinci aşamada ise hepatit hastalığının teşhisi için seçilen özellikler kullanılarak bulanık çıkarım sistemi ve makine öğrenmesi modelleri ile sonuç üretilmiştir. Bu yaklaşım, literatürde yapılmış önceki çalışmalara oranla daha az hesaplama süresi gerektirmesi, azaltılmış sınıflandırma karmaşıklığı ve daha yüksek doğrulukta sınıflandırma başarısı sunması gibi sebeplerle bu çalışmada uygulanmıştır.

Çalışmanın kapsamı Bulanık Mantık ve Makine Öğrenmesi algoritmalarının kullanılarak hepatit hastalığının tespiti için kıyaslanmasıdır. Giriş bölümünde, bu alanda yapılan benzer çalışmalara, Materyal ve Metot bölümünde kullanılan modellerin başarı ölçütlerinin hesaplanmasına ve bulanık mantık ve makine öğrenmesi algoritmalarına ve çalışma prensiplerine değinilmiştir. Deneysel Sonuçlar ve Tartışma bölümünde yapılan çalışmalar ve elde edilen sonuçlar tartışılmıştır. Son Bölümde, elde edilen sonuçların değerlendirilmesi yapılmıştır.

Materyal ve Metot

Bu çalışmada hepatit hastalığının teşhisinde kullanılacak modeller oluşturulmadan önce veri ön işleme ve öznitelik seçimi işlemleri uygulanmıştır. Öznitelik seçimi ile, veri setindeki gereksiz özellikler çıkarılarak, çıktı değerini belirleyici özelliklerin modelde yer alması, çıktı değeri üzerinde etkisi az olan özelliklerin modelde kullanılmaması

sağlanmıştır. Çalışmada açık erişimli UCI Makine Öğrenmesi Deposundan alınan Hepatit hastalık [19] veri seti kullanılmıştır. Veri setinde öznitelik seçimi ile kullanılacak özellikler belirlenmeden önce ön işleme yapılarak eksik ve gereksiz veriler silinmiştir.

Kullanılan Veri Seti

Çalışmada açık erişimli UCI Makine Öğrenmesi Deposundan alınan Hepatit hastalık veri seti kullanılmıştır. Veri setinde yer alan özellikler Tablo 1’de gösterilmiştir.

Tablo 1. Çalışmada kullanılan veri seti.

Özellik No	Özellik Adı	Özellik Değer Aralığı
1	Hasta ID	1 – 615
2	Yaş	19 – 77
3	Cinsiyet	E – K
4	ALB (Albümin)	14.9 – 82.2
5	ALP (Alkalen fosfataz)	11.3 – 416.6
6	ALT (Alanin Aminotransferaz)	0.9 – 325.3
7	AST (Aspartat Aminotransferaz)	10.6 – 324
8	BIL (Bilirubin)	0.8 – 254
9	CHE (Kolinesteraz)	1.42 – 16.41
10	CHOL (Kolesterol)	1.43 – 9.67
11	CREA (Kreatinin)	8.0 – 1079.1
12	GGT (Gama Glutamil Transferaz)	4.5 – 650.9
13	PROT (Kan Proteini)	44.8 – 90.0
14	Kategori	0=Kan Bağışçısı, 0s=Şüpheli Kan Bağışçısı, 1=Hepatit Hastası, 2=Fibrozis Hastası, 3=Siroz Hastası

Veri Ön İşleme

Veri ön işleme aşamasında öncelikle veri setindeki eksik veri içeren veriler silindi. Ardından daha az hesaplama süresi ve daha az karmaşıklık için veri seti üzerinde F-test uygulanarak gereksiz özellikler veri setinden çıkarıldı. Ayrıca SMOTE [20] yöntemi kullanılarak eksik sayıdaki sınıf türleri (1=Hepatit Hastası, 2=Fibrozis Hastası, 3=Siroz Hastası) çoğaltıldı. Ayrıca kategorik değerler içeren kategori özelliğinde 0=Kan Bağışçısı ve 0s=Şüpheli Kan Bağışçısı kategorileri kendi aralarında Hasta Değil olarak ve 1=Hepatit, 2=Fibrozis ve 3=Siroz kategorileri de kendi aralarında Hasta olarak birleştirildi. Son olarak da birleştirilen kategorilere Label Encoder işlemi uygulanarak veri ön işleme işlemi bitirildi. Veri ön işlemenin ardından veri setindeki özellikler Tablo 2’de gösterilmiştir.

Tablo 2. Veri ön işleme sonrası veri seti.

Özellik No	Özellik Adı	Özellik Değerleri
1	ALB	14.9 – 82.2
2	AST	10.6 – 324
3	BIL	0.8 – 254
4	GGT	4.5 – 650.9
5	Hastalık Durumu	0 (Hasta Değil), 1 (Hasta)

Bulanık Mantık

Mantık biliminin temel yapı taşı olan önermeler, doğruluk değerine sahip hüküm bildiren ifadelerdir. Antik Yunan döneminden başlayarak günümüze kadar gelen klasik mantıkta önermeler yanlış ve doğru olmak üzere doğruluk değerini $\{0,1\}$ kümesinden alır. Klasik mantığın belirsizlik kavramına yer vermeyen yaklaşımı sonucu, bazı problemlerin çözümünde ortaya çıkan çözümsüzlüklerle birlikte 20. yy başlarından itibaren, felsefi olarak eleştirilmeye; doğada ve bilimde var olan belirsizlikten bahsedilmeye başlandığı görülmektedir [21], [22]. Klasik mantığın karşısında yer alan bulanık mantık teorisi, 1965 yılında Zadeh tarafından ortaya atılmıştır [23]. Bulanık mantık teorisi, iki değerli önermeler yerine belirsizlik kavramının göz önüne alındığı, değerini $[0,1]$ aralığından alan doğruluk derecesine sahip önermeleri temel almaktadır. Böylece Zadeh, klasik iki değerli mantığın dayandığı keskinlik yaklaşımı yerine, insanların düşünmesinde ve akıl yürütmesinde kullandığı belirsizliği öne çıkarmıştır. Bulanık mantık teorisi temel anlamda bulanık küme teorisine dayanır. Bulanık kümeler, keskin sınırlara sahip küme kavramı yerine sınırları belirsiz olan ve elemanların üyeliklerinin kümeye aidiyeti keskin olmayan küme anlayışına dayanmaktadır. Klasik mantıkta akıl yürütme yolu ile çıkarım yapılır, bunun için mantık biliminin farklı yaklaşımları kullanılır. Bulanık akıl yürütme (yaklaşık akıl yürütme) de bulanık küme ve bulanık mantık teorilerini temel alır. Günlük hayatımızda kullandığımız akıl yürütme, klasik mantıkta yer alan akıl yürütme yaklaşımlarına benzemekle birlikte belirsizlik taşıyan kavramlar üzerinden yapıldığından, bulanık akıl yürütme yaklaşımını andırmaktadır. Bulanık modellemede kullanılan çıkarım mekanizmaları, tanımlanmış olan bulanık küme ve bulanık kuralları kullanarak bulanık akıl yürütmenin uygulanmasını ve karşılaşılan yeni değerler için tahmin yapılmasını sağlar. Bulanık modellemede kullanılan üç temel çıkarım mekanizması Mamdani, Sugeno ve Tsukamoto yaklaşımlarıdır. Bu yöntemler sayesinde günümüz dijital sistemlerinde, bulanık küme ve bulanık mantık teorilerinden faydalanılarak bulanık akıl yürütme işleminin yapılması sağlanmış ve insan benzeri akıl yürütmenin bir yansıması olan bulanık modellemenin yolu açılmıştır.

Makine Öğrenmesi

Yapay zekânın bir alt dalı olan makine öğrenmesi, karmaşık veriden bir örüntü tespit edilmesi ve akılcı kararlar verebilmek için istatistikten ve bilgisayarların işlem gücünden faydalanmaktadır.

Bu çalışmada sınıflandırma algoritmalarından Random Forest, Decision Tree, XGBoost, Gradient Boosting, MLP, Support Vector Machine (SVM) ve k-Nearest Neighbors algoritmaları kullanılmıştır.

k Nearest Neighbors : Bu algoritma sınıflandırılmak istenen verinin daha önceki verilerden k tanesine olan yakınlığını kullanarak sınıflandırma yapmaktadır. Komşuluk mesafesini ölçmek için Öklid uzaklığı kullanılmaktadır. Uzaklıkları hesaplanan k tane örneğin ait oldukları sınıfların çoğunluğuna göre yeni veri bir sınıfa atanır.

Decision Tree : Bu yöntemde eğitim aşamasında veri setinden faydalanılarak bir ağaç yapısı oluşturulur. Karşılaşılan yeni veri için ağacın kökünden başlanılarak her

düğümde yapılan karşılaştırma ile ağacın yapraklarındaki sınıf etiketlerine giden kollar ile sınıflandırma işlemi yapılmaktadır.

Random Forest : Sınıflandırma işlemi sırasında birden fazla karar ağacı üretmek sınıflandırma oranını yükseltmeye amaçlayan bir algoritmadır. Rastlantısal olarak seçilen karar ağaçları bir araya gelerek karar ormanını oluşturur.

Gradient Boosting : Random Forest algoritmasına benzeyen bu algoritma karar ağaçlarını kullanmaktadır. Aralarındaki temel fark, son tahminin tüm ağaçların doğrusal bir toplamı olması ve her ağacın amacının önceki ağacın hatasını en aza indirmeye çalışmasıdır.

Support Vector Machine : Support Vector Machine, iki sınıftan oluşan ve doğrusal olmayan şekilde ayrılabilen veri kümesi için, veri kümesindeki sınıfları sonsuz sayıda bölün çizginin (karar sınırı) olduğu temel prensibi ile çalışan bir algoritmadır. İki sınıfın en iyi şekilde ayıran çizginin seçimi, eğitim numunelerinin bir alt kümesi kullanılarak gerçekleştirilir.

Multi Layer Perceptron : Multi Layer Perceptron, insan beyninin bilgiyi işleme sürecini taklit eden bir algoritmadır. MLP, giriş katmanı, gizli katman ve çıkış katmanından oluşmaktadır. Giriş katmanı, dışarıdan kendisine gelen bilgileri işlemek üzere gizli katmana iletir. Gizli katmanlarda işlenen bilgiler, çıkış katmanında tahmin sonucu üretilerek sistemden çıkmaktadır.

XGBoost : Gradient Boosting temelli bir algoritmadır. XGBoost, Gradient Boosting farklı olarak aşırı öğrenmeyi önlemek için daha düzenli bir model biçimlendirmesi kullanılmaktadır.

Modellerin Geliştirilmesi

Bu çalışmada hepatit hastalık veri seti kullanılarak Bulanık Mantık ve Makine Öğrenmesi yöntemleri ile modeller oluşturulmuş ve elde edilen modellerin başarımları değerlendirilmiştir. Modellerin başarımlarını arttırmak için veri setinde, F-test kullanılarak öznelik seçimi, SMOTE yöntemi kullanılarak eksik sınıf verilerinin eklenmesi ve kategorik verilerin sayısallaştırılması gibi veri ön işlemleri yapılmıştır. F-test sonucu veri setindeki ALB, AST, BIL, GGT ve Hastalık durumu öznelikleri seçilmiştir.

Çalışmada bulanık modelin geliştirilmesi aşamasında Python programlama dilinde geliştirilmiş olan pyFUME [24] kütüphanesi kullanılmıştır. pyFUME kütüphanesi, bulanık modelleme konusunda oldukça faydalı bir kütüphane olması sebebiyle çalışmada tercih edilmiştir. Bulanık modeldeki üyelik fonksiyonları ve kurallar, pyFUME kütüphanesi kullanılarak oluşturulmuştur.

Modelde, her bir özellik için 3 bulanık küme tanımlanmış – Düşük, Normal, Yüksek–; düşük ve yüksek bulanık kümeler için üçgen üyelik fonksiyonlar, Normal bulanık kümeler için ise yamuk üyelik fonksiyonlar oluşturulmuştur. Her bir özellik için oluşturulan üyelik fonksiyonları Tablo 3’de gösterilmiştir.

Tablo 3. Veri ön işleme sonrası veri seti.

Özellik	Destek Aralığı, Bulanık Küme Adı, Tipi
ALB	0 – 65, Düşük, üçgen
	30 – 100, Normal, yamuk
	75 – 150, Yüksek, üçgen
AST	0 – 175, Düşük, üçgen
	130 – 360, Normal, yamuk
	300 – 400, Yüksek, üçgen
BIL	0 – 70, Düşük, üçgen
	30 – 200, Normal, yamuk
	150 – 300, Yüksek, üçgen
GGT	0 – 100, Düşük, üçgen
	35 – 600, Normal, yamuk
	500 – 700, Yüksek, üçgen

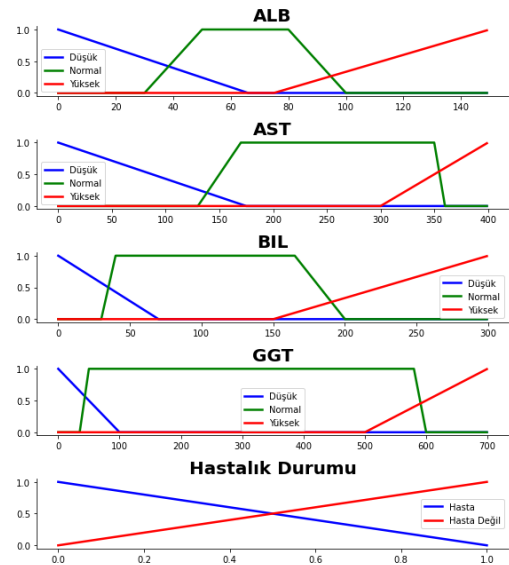
Her bir özellik için oluşturulan üyelik fonksiyonları Şekil 2’de gösterilmiştir.

Üyelik fonksiyonlarının oluşturulmasının ardından bulanık modeldeki kurallar oluşturulmuştur. Kurallar uzman görüşü ile oluşturulmuş ve 14 kural bulanık modele eklenmiştir.

Bulanık modelde çıkarım mekanizması olarak Mamdani çıkarım yöntemi kullanılmıştır. Modelde durulaştırma yöntemi olarak ağırlık merkezi yöntemi kullanılmıştır. Ağırlık merkezi yönteminde, tetiklenen kurallardan gelen üyelik değerlerinin, bulanık çıkış kümeleri üzerinde kestiği alanlar toplanır. Daha sonra bu alanların geometrik ağırlık merkezi hesaplanır. Ortaya çıkan değer ise durulaştırılmış çıkış değeridir.

1. If (ALB is yüksek) and (AST is düşük) and (BIL is düşük) and (GGT is düşük) then (HASTA is 1) (1)
2. If (ALB is yüksek) and (AST is düşük) and (BIL is düşük) and (GGT is normal) then (HASTA is 1) (1)
3. If (ALB is düşük) and (AST is normal) and (BIL is düşük) and (GGT is düşük) then (HASTA is 1) (1)
4. If (ALB is düşük) and (AST is düşük) and (BIL is normal) and (GGT is düşük) then (HASTA is 1) (1)
5. If (ALB is düşük) and (AST is düşük) and (BIL is düşük) and (GGT is düşük) then (HASTA is 1) (1)
6. If (ALB is düşük) and (AST is düşük) and (BIL is düşük) and (GGT is normal) then (HASTA is 1) (1)
7. If (ALB is düşük) and (AST is normal) and (BIL is düşük) and (GGT is normal) then (HASTA is 0) (1)
8. If (ALB is normal) and (AST is düşük) and (BIL is düşük) and (GGT is düşük) then (HASTA is 0) (1)
9. If (ALB is normal) and (AST is düşük) and (BIL is normal) and (GGT is normal) then (HASTA is 0) (1)
10. If (ALB is normal) and (AST is düşük) and (BIL is düşük) and (GGT is normal) then (HASTA is 0) (1)
11. If (ALB is normal) and (AST is normal) and (BIL is düşük) and (GGT is düşük) then (HASTA is 1) (1)
12. If (ALB is düşük) and (AST is yüksek) and (BIL is normal) and (GGT is normal) then (HASTA is 1) (1)
13. If (ALB is normal) and (AST is normal) and (BIL is düşük) and (GGT is normal) then (HASTA is 1) (1)
14. If (ALB is normal) and (AST is normal) and (BIL is normal) and (GGT is normal) then (HASTA is 1) (1)

Şekil 1. Bulanık modeldeki kurallar.



Şekil 2. Bulanık model üyelik fonksiyonları.

Çalışmada makine öğrenmesi modellerinin geliştirilmesi Python 3.10 ortamında yapılmıştır. Çalışmada makine öğrenmesi modelleri, en başarılı sonucu veren parametrelerin

bulunması amacıyla GridSearch yöntemi ile geliştirilmiştir. Ayrıca her bir model için 10-çapraz doğrulama uygulanmıştır.

Deneysel Sonuçlar ve Tartışma

Eğitim verisi ile modeller eğitildikten sonra test verisi ile modellerin başarımları test edilmiştir. Modellerin başarımlarının karşılaştırılması için çeşitli değerlendirme kriterleri kullanılmaktadır. Bu çalışmada değerlendirme kriteri olarak doğruluk, kesinlik, duyarlılık ve F-Skor kullanılmış; bu ölçütler hesaplanırken karmaşıklık matrisinden faydalanılmıştır. Karmaşıklık matrisi Tablo 4’de gösterilmiştir.

Tablo 4. Karmaşıklık Matrisi.

		Gerçek Değerler	
		Pozitif (1)	Negatif (0)
Tahmin Değerleri	Pozitif (1)	TP	FP
	Negatif (0)	FN	TN

TP : True Positive (Doğru Pozitif): Gerçek sınıfı pozitif olan bir örnek doğru sınıflandırıldı

FP : False Positive (Yanlış Pozitif) : Gerçek sınıfı negatif olan bir örnek yanlış sınıflandırıldı

FN : False Negative (Yanlış Negatif) : Gerçek sınıfı pozitif olan bir örnek yanlış sınıflandırıldı

TN : True Negative (Doğru Negatif) : Gerçek sınıfı negatif olan bir örnek doğru sınıflandırıldı

Doğruluk, doğru sınıflandırılan örnek sayısının tüm örneklerin sayısına oranıdır. Bir modelin başarısını ölçmek için sık kullanılır, ancak tek başına yeterli değildir.

$$\text{Doğruluk} = \frac{TP + TN}{TP + FP + FN + TN} \quad (1)$$

Kesinlik, pozitif olan ve doğru tahmin edilen örnek sayısının pozitif olarak tahmin edilen örnek sayısına oranıdır.

$$\text{Kesinlik} = \frac{TP}{TP + FP} \quad (2)$$

Duyarlılık, pozitif olan ve doğru olarak tahmin edilen örnek sayısının pozitif örnek sayısına oranıdır.

$$\text{Duyarlılık} = \frac{TP}{TP + FN} \quad (3)$$

F-Skor, eşit dağılmayan veri kümelerinde hatalı bir model seçimi yapmamak için doğruluk metriğinin yanı sıra tercih edilen bir metriktir ve kesinlik ve duyarlılık değerlerinin harmonik ortalaması alınarak hesaplanmaktadır.

$$F - \text{Skor} = \frac{2 \times \text{Duyarlılık} \times \text{Kesinlik}}{\text{Duyarlılık} + \text{Kesinlik}} \quad (3)$$

Bulanık modelin üyelik fonksiyonlarının ve kuralların oluşturulmasının ardından modelin başarısı ölçülmüştür.

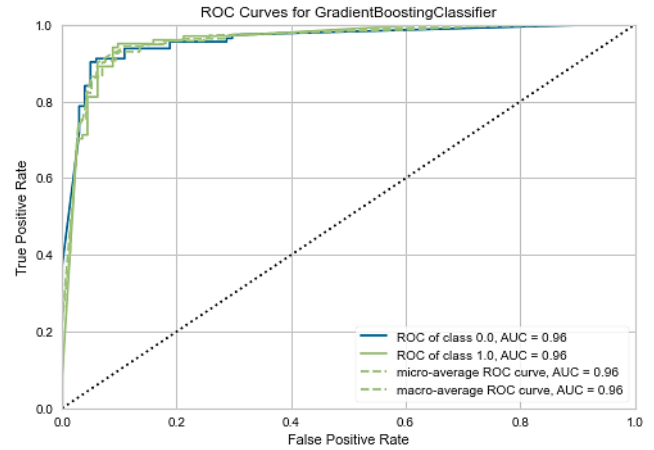
Yapılan ölçümlerin neticesinde bulanık model ile %94 doğruluk değeri elde edilmiştir.

Makine öğrenmesi modellerinden elde edilen sonuçlar Tablo 5’de gösterilmiştir. Yapılan ölçümler neticesinde hepatit hastalık tespitinde en başarılı sonuç, %98.36 doğrulukla Gradient Boosting algoritması ile alınmıştır.

Bulanık mantık yöntemi ve makine öğrenmesi algoritmalarından elde edilen sonuçlara bakıldığında makine öğrenmesinin bulanık mantığa göre daha başarılı olduğu gözlenmektedir. Kullanılan makine öğrenmesi modelleri karşılaştırıldığında en başarılı sonucun, makine öğrenmesi algoritmalarından Gradient Boosting algoritması ile alındığı görülmektedir. Gradient Boosting algoritmasına ait karmaşıklık matrisi Şekil 3’de ve ROC eğrisi grafiği Şekil 4’de gösterilmiştir.

	Gerçek Değerler	
	Hasta Değil	Hasta
Hasta Değil	TN 98	FP 15
Hasta	FN 5	TP 96

Şekil 3. Gradient Boosting algoritmasına ait karmaşıklık matrisi.



Şekil 4. Gradient Boosting algoritmasına ait ROC-AUC grafiği.

Tablo 5. Sınıflandırma algoritmalarının başarı oranları.

Algoritma ve Hiperparametreleri	Doğruluk	Kesinlik	Duyarlılık	F-Skor	Çapraz Doğrulama (10)	ROC-AUC
Gradient Boosting (loss='log_loss', learning_rate=0.1, n_estimators=200, criterion='friedman_mse')	0.9836	0.9868	0.9895	0.9891	0.9824	0.9699
Random Forest (n_estimators=200, criterion='gini')	0.9703	0.9795	0.9885	0.9840	0.9698	0.9432
XGBoost (learning_rate=0.001, n_estimators=100, objective='binary:logistic')	0.9702	0.9773	0.9885	0.9829	0.9669	0.8660
SVM (C=1.0, kernel='rbf', degree=3, gamma='scale')	0.9682	0.9752	0.9908	0.9829	0.9618	0.8516
Decision Tree (criterion='gini', splitter='best')	0.9639	0.9838	0.9771	0.9804	0.9583	0.8885
MLP (hidden_layer_sizes=(200,), activation='sigmoid', solver='adam', batch_size='auto', learning_rate='constant', learning_rate_init=0.001, max_iter=200)	0.9626	0.9727	0.9794	0.9760	0.9555	0.9450
kNN (n_neighbors=3, weights='distance', algorithm='auto', leaf_size=30, metric='euclidean')	0.9588	0.9706	0.9839	0.9727	0.9576	0.8702
Bulanık Model (Mamdani)	0.9400	0.9689	0.9759	0.9723	0.9387	0.8342

Sonuçlar

Bu çalışmada, hepatit hastalığının kan değerlerini kullanarak doğru tespit edilmesi için bulanık model ve makine öğrenmesi modellerinin geliştirilmesi ve çıkan sonuçların karşılaştırılması amaçlanmıştır. Çalışmada kullanılan ve kan değerleri bilgilerinden oluşan veri seti, UCI Makine Öğrenmesi deposundan edinilmiştir. Veri seti ilk olarak ön işlemeden geçirilmiş ve hatalı/eksik veriler silinmiştir. Ardından bulanık model için üyelik fonksiyonları ile bulanık kurallar oluşturulmuş ve makine öğrenmesi modelleri geliştirilmiştir. Son olarak hem bulanık modelin hem de makine öğrenmesi modellerinin başarı test edilmiş ve en iyi sonuç %98.36 doğruluk oranı Gradient Boosting algoritması ile elde edilmiştir. Ayrıca Gradient Boosting algoritmasıyla kesinlik, duyarlılık, f-skor ve roc-auc metriklerinden sırasıyla 98.68, 98.95, 98.91, 96.99 skorları elde edilmiştir. Gradient Boosting algoritması ile bulanık mantık yönteminden elde edilen sonuçlara bakıldığında Gradient Boosting algoritmasının daha başarılı sonuç verdiği görülmektedir. Bu sonuç makine öğrenmesi modellerinin bulanık modellere göre hastalık tespiti problemlerinde daha başarılı sonuçlar verdiğini göstermektedir. Ayrıca bu çalışmada kullanılan

yöntemlerle elde edilen başarı oranının literatürdeki diğer çalışmalara oranla daha yüksek olduğu görülmektedir. Bu çalışma ile literatürdeki diğer çalışmaların detaylı kıyaslanması Tablo 6'da gösterilmiştir.

Bu çalışmada makine öğrenmesi modelleri ile bulanık modellerin hepatit hastalığının tespitinde kıyaslanması yapılmıştır. Yapılan kıyaslama sonucunda makine öğrenmesi modellerinin bulanık modellere göre hepatit hastalığının tespitinde kullanılmasının daha doğru sonuçlar vereceği kanıtlanmıştır. Makine öğrenmesi modellerinin kendi içerisinde kıyaslanması sonucunda ise en başarılı makine öğrenmesi modelinin Gradient Boosting algoritması ile oluşturulan model olduğu gözlemlenmiştir.

Gelecek çalışmalarda sistemin başarısı sinir ağları, bulanık mantık temelli sinir ağları ve derin öğrenme yöntemleri kullanılarak artırılabilir. Ayrıca sistem diğer hastalıkların teşhisinde kullanılmak üzere genişletilebilir.

Tablo 6. Veri ön işleme sonrası veri seti.

Çalışma - Yıl	Kullanılan Yöntem	Başarı Ölçüm Metriği	Başarı Oranı
[6] - 2009	ANFIS, LDA	Doğruluk	94.16
[7] - 2006	AIRS, FRAS, Çapraz Doğrulama (10)	Doğruluk	92.59
[8] - 2019	NIPALS, SOM	ROC	93.06
[9] - 2019	MMFIS	Doğruluk	92.20
[10] - 2019	ANFIS	Doğruluk	95.24
[11] - 2011	YSA, Levenberg-Marquardt, Çapraz Doğrulama (10)	Doğruluk	91.87
[12] - 2017	Relief, Rough Set, C4.5, Jackknife Çapraz Doğrulama	Doğruluk	92.59
[13] - 2013	Genetik Algoritma, ANFIS	Doğruluk	97.44
[14] - 2012	SVM, Benzetilmiş Tavlama, Çapraz Doğrulama (10)	Doğruluk	96.25
[15] - 2011	LSSVM, PCA	Doğruluk	95.00
[16] - 2011	SVM, LFDA	Doğruluk	96.77
[17] - 2013	ELM, Rough Set	Doğruluk	93.75
[18] - 2016	Tek Katmanlı İleri Beslemeli Sinir Ağı, ELM	Doğruluk	94.44
Bu çalışma	Bulanık Mantık, Makine Öğrenmesi, Çapraz Doğrulama (10)	Doğruluk	98.36

Etik kurul onayı ve çıkar çatışması beyanı

Hazırlanan makalede etik kurul izni alınmasına gerek yoktur.

Hazırlanan makalede herhangi bir kişi/kurum ile çıkar çatışması bulunmamaktadır.

Yazar Katkıları

Yazar 1 ve Yazar 2

-Çalışma konsepti ve tasarım

-Veri toplama, verilerin analizi ve yorumlanması

-Taslağın oluşturulması

Kaynaklar

- [1] J. M. Ntaganda and M. Gahamanyi, "Fuzzy Logic Approach for Solving an Optimal Control Problem of an Uninfected Hepatitis B Virus Dynamics," *Applied Mathematics*, vol. 06, no. 09, Art. no. 09, 2015, doi: 10.4236/am.2015.69136.
- [2] P. A. Ejegwa and E. S. Modom, "Diagnosis of viral hepatitis using new distance measure of intuitionistic fuzzy sets," *Int J Fuzzy Math Arch*, vol. 8, no. 1, pp. 1–7, 2015.
- [3] J. F. Perz, G. L. Armstrong, L. A. Farrington, Y. J. F. Hutin, and B. P. Bell, "The contributions of hepatitis B virus and hepatitis C virus infections to cirrhosis and primary liver cancer worldwide," *Journal of Hepatology*, vol. 45, no. 4, pp. 529–538, Oct. 2006, doi: 10.1016/j.jhep.2006.05.013.
- [4] W. H. Organization, *Global hepatitis report 2017*. World Health Organization, 2017.
- [5] A. Sardesai, P. Sambarey, V. Kharat, and A. Deshpande, "Fuzzy logic application in gynecology: A

- case study," in 2014 International Conference on Informatics, Electronics Vision (ICIEV), May 2014, pp. 1–5. doi: 10.1109/ICIEV.2014.6850715.
- [6] E. Dogantekin, A. Dogantekin, and D. Avci, "Automatic hepatitis diagnosis system based on Linear Discriminant Analysis and Adaptive Network based on Fuzzy Inference System," *Expert Systems with Applications*, vol. 36, no. 8, pp. 11282–11286, Oct. 2009, doi: 10.1016/j.eswa.2009.03.021.
- [7] K. Polat and S. Güneş, "Hepatitis disease diagnosis using a new hybrid system based on feature selection (FS) and artificial immune recognition system with fuzzy resource allocation," *Digital Signal Processing*, vol. 16, no. 6, pp. 889–901, Nov. 2006, doi: 10.1016/j.dsp.2006.07.005.
- [8] M. Nilashi, H. Ahmadi, L. Shahmoradi, O. Ibrahim, and E. Akbari, "A predictive method for hepatitis disease diagnosis using ensembles of neuro-fuzzy technique," *Journal of Infection and Public Health*, vol. 12, no. 1, pp. 13–20, Jan. 2019, doi: 10.1016/j.jiph.2018.09.009.
- [9] G. Ahmad, M. A. Khan, S. Abbas, A. Athar, B. S. Khan, and M. S. Aslam, "Automated Diagnosis of Hepatitis B Using Multilayer Mamdani Fuzzy Inference System," *Journal of Healthcare Engineering*, vol. 2019, p. e6361318, Feb. 2019, doi: 10.1155/2019/6361318.
- [10] W. Ahmad et al., "Intelligent hepatitis diagnosis using adaptive neuro-fuzzy inference system and information gain method," *Soft Comput*, vol. 23, no. 21, pp. 10931–10938, Nov. 2019, doi: 10.1007/s00500-018-3643-6.
- [11] M. S. Bascil and F. Temurtas, "A Study on Hepatitis Disease Diagnosis Using Multilayer Neural Network with Levenberg Marquardt Training Algorithm," *J Med Syst*, vol. 35, no. 3, pp. 433–436, Jun. 2011, doi: 10.1007/s10916-009-9378-2.
- [12] X. Liu et al., "A Hybrid Classification System for Heart Disease Diagnosis Based on the RFRS Method," *Computational and Mathematical Methods in Medicine*, vol. 2017, p. e8272091, Jan. 2017, doi: 10.1155/2017/8272091.
- [13] M. Adeli, N. Bigdeli, and K. Afshar, "New hybrid hepatitis diagnosis system based on Genetic algorithm and adaptive network fuzzy inference system," in 2013 21st Iranian Conference on Electrical Engineering (ICEE), May 2013, pp. 1–6. doi: 10.1109/IranianCEE.2013.6599872.
- [14] J. S. Sartakhti, M. H. Zangoeei, and K. Mozafari, "Hepatitis disease diagnosis using a novel hybrid method based on support vector machine and simulated annealing (SVM-SA)," *Computer Methods and Programs in Biomedicine*, vol. 108, no. 2, pp. 570–579, Nov. 2012, doi: 10.1016/j.cmpb.2011.08.003.
- [15] D. Çalışır and E. Dogantekin, "A new intelligent hepatitis diagnosis system: PCA–LSSVM," *Expert Systems with Applications*, vol. 38, no. 8, pp. 10705–10708, Aug. 2011, doi: 10.1016/j.eswa.2011.01.014.
- [16] H.-L. Chen, D.-Y. Liu, B. Yang, J. Liu, and G. Wang, "A new hybrid method based on local fisher discriminant analysis and support vector machines for hepatitis disease diagnosis," *Expert Systems with*

- Applications, vol. 38, no. 9, pp. 11796–11803, Sep. 2011, doi: 10.1016/j.eswa.2011.03.066.
- [17] Y. Kaya and M. Uyar, “A hybrid decision support system based on rough set and extreme learning machine for diagnosis of hepatitis disease,” *Applied Soft Computing*, vol. 13, no. 8, pp. 3429–3438, Aug. 2013, doi: 10.1016/j.asoc.2013.03.008.
- [18] K. B. Nahato, K. H. Nehemiah, and A. Kannan, “Hybrid approach using fuzzy sets and extreme learning machine for classifying clinical datasets,” *Informatics in Medicine Unlocked*, vol. 2, pp. 1–11, Jan. 2016, doi: 10.1016/j.imu.2016.01.001.
- [19] “UCI Machine Learning Repository: HCV data Data Set.” <https://archive.ics.uci.edu/ml/datasets/HCV+data> (accessed Jun. 25, 2021).
- [20] N. V. Chawla, K. W. Bowyer, L. O. Hall, and W. P. Kegelmeyer, “SMOTE: Synthetic Minority Over-sampling Technique,” *Jair*, vol. 16, pp. 321–357, Jun. 2002, doi: 10.1613/jair.953.
- [21] B. Russell, “Vagueness,” *The Australasian Journal of Psychology and Philosophy*, vol. 1, no. 2, pp. 84–92, 1923.
- [22] M. Black, “Vagueness: An exercise in logical analysis,” *Philosophy of Science*, vol. 4, no. 4, pp. 427–455, Oct. 1937, doi: 10.1086/286476.
- [23] L. A. Zadeh, “Fuzzy sets,” *Information and Control*, vol. 8, no. 3, pp. 338–353, Jun. 1965, doi: 10.1016/S0019-9958(65)90241-X.
- [24] C. Fuchs, S. Spolaor, M. S. Nobile, and U. Kaymak, “pyFUME: a Python Package for Fuzzy Model Estimation,” in *2020 IEEE International Conference on Fuzzy Systems (FUZZ-IEEE)*, Jul. 2020, pp. 1–8. doi: 10.1109/FUZZ48607.2020.9177565.