



## Performance of neural networks and heuristic models for disease prediction from liver enzymes: Application to biochemistry device output

Seyit Hamza Çavga\*

Department of Biomedical Device Technology, Vocational School of Health Services, İstanbul Gelişim University, 34310, Avcılar, İstanbul, Türkiye

### Highlights:

- Utilization of direct device outputs for classification system development
- Hybrid utilization of particle swarm optimization and artificial neural networks
- Comparison of artificial neural networks and heuristic methods

### Keywords:

- Liver diseases
- Artificial neural networks
- Particle swarm optimization
- Logistic regression

### Article Info:

Research Article  
Received: 21.03.2023  
Accepted: 09.12.2023

### DOI:

10.17341/gazimmfd.1268957

### Correspondence:

Author: Seyit Hamza Cavga  
e-mail:  
shcavga@gelisim.edu.tr  
phone: +90 538 256 8450

### Graphical/Tabular Abstract

In the application of decision making systems in the field of health, with the developing technology, direct analysis device outputs have become available. With the expansion of the data set, the accuracy of the models also increases. Particle swarm optimization and neural network methods are used in this study. The accuracy of the models tested with the test data is shared in Table A.

Table A. Results of Modals for Test Data

		Number of Particles	Number of Iterations	5 Neuron	10 Neuron	15 Neuron	20 Neuron
Particle Swarm Optimization	20	5		88.82	89.47	90.13	88.82
	20	10		89.47	87.50	89.47	87.50
	20	15		89.47	89.47	88.82	89.47
	50	5		88.82	89.47	88.82	88.82
	50	10		91.45	88.82	89.47	88.82
	50	15		89.47	88.16	90.13	88.82
	100	100		90.1	90.13	90.79	89.47
		Training Algorithm	Learning Algorithm	5 Neuron	10 Neuron	15 Neuron	20 Neuron
Feed Forward Backpropagation Neural Network	trainlm	learnngdm		88.82	88.82	89.47	90.13
		learnngd		92.11	91.45	90.79	90.79
	trainscg	learnngdm		90.13	88.16	88.82	95.39
		learnngd		87.5	88.16	88.82	87.5
	trainbr	learnngdm		86.84	89.47	88.16	88.16
		learnngd		88.82	89.47	90.79	90.79

### Purpose:

Since the data sets used in disease classification studies were created with expert opinion, they are subjective data. For this reason, they contain an extra workload for their use. With the artificial neural network and/or heuristic methods used today, the outputs of the analyzer are processed directly and high accuracy in disease classification has been achieved. In this study, 10 different liver enzyme values and age and gender of the person were used as classification parameters. Accordingly, individuals were assigned to healthy, suspected, hepatitis, cirrhosis and fibrosis classes.

### Theory and Methods:

A multi-classification model was developed using a data set consisting of objective and numerical parameters. For this, particle swarm optimization and artificial neural network are used. Particle swarm optimization was used to find the weights of the neural network. The results were examined by changing the iteration number and particle number parameters. The artificial neural network model was run with different training and learning algorithms and different neuron numbers. The same data set was tested with logistic regression for comparison.

### Results:

When particle swarm optimization is used, less accuracy is achieved in longer time than neural networks. The artificial neural network, in which the Scaled Conjugate Gradient training algorithm and the gradient descent with momentum weight and bias learning algorithm were run with 20 neurons, provided the most 95.39% accuracy.

### Conclusion:

With this study, 95.36% accuracy was obtained in the classification system created by using direct device outputs containing objective and numerical data.



## Karaciğer enzimlerinden hastalık tahmini için yapay sinir ağları ve sezgisel yöntem modellerinin performansları: Biyokimya cihazı çıktılarına uygulanması

Seyit Hamza Çavga\*<sup>ORCID</sup>

İstanbul Gelişim Üniversitesi, Sağlık Hizmetleri Meslek Yüksek Okulu, Biyomedikal Cihaz Teknolojisi Bölümü, 34310, Avcılar, İstanbul, Türkiye

### Ö N E Ç I K A N L A R

- Doğrudan cihaz çıktılarını kullanarak oluşturulan sınıflandırma sistemi
- Parçacık sürü optimizasyonu ve yapay sinir ağlarının hibrit kullanımı
- Yapay sinir ağı ve sezgisel yöntemlerin karşılaştırılması

### Makale Bilgileri

Araştırma Makalesi

Geliş: 21.03.2023

Kabul: 09.12.2023

### DOI:

10.17341/gazimmfd.1268957

### Anahtar Kelimeler:

Karaciğer hastalıkları

Yapay sinir ağları

Parçacık sürüsü

optimizasyonu

Lojistik regresyon

### ÖZ

Karar verme sistemlerinin sağlık alanında uygulanmasında, gelişen teknolojiyle birlikte, direkt analiz cihazı çıktıları kullanılabilir hale gelmiştir. Veri setinin zenginleşmesiyle birlikte modellerin doğrulukları da artmaktadır. Bu çalışmada kullanılan veri seti parametreleri nicelik ve nitelik yönünden eski çalışmalara kıyasla gerçek duruma daha yakın ham veriler içermektedir. Karaciğer hastalıklarını tanımlamak için kurulan modeller incelendiğinde uzman görüşü içeren parametreler kullanılması sebebiyle model performansının yanında uzman performansının da etkisi olduğu görülmektedir. Bu çalışmada kullanılan veri seti sınıf değerleri dışında subjektif verilere yer vermeyerek uzman görüşünü sadece modelin eğitiminde kullanmıştır. Bu sayede model performansının veri setine diğer çalışmalardan daha az bağımlı olacaktır. Gerçek hayat verileri farklı modeller ile çalışılarak, hangi yapıların daha iyi olduğu görülmüştür. Çalışmada yapay sinir ağları ve parçacık sürü optimizasyonu metotları sınıflandırma problemini çözebilmek için eğitilmiş ve test verileri ile sınanarak sonuçlar analiz edilmiştir.

## Performance of neural networks and heuristic models for disease prediction from liver enzymes: Application to biochemistry device output

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

- Utilization of direct device outputs for classification system development
- Hybrid utilization of particle swarm optimization and artificial neural networks
- Comparison of artificial neural networks and heuristic methods

### Article Info

Research Article

Received: 21.03.2023

Accepted: 09.12.2023

### DOI:

10.17341/gazimmfd.1268957

### Keywords:

Liver diseases

Artificial neural networks

Particle swarm optimization

Logistic regression

### ABSTRACT

In the application of decision-making systems in the field of healthcare, with advancing technology, the outputs of direct analysis devices have become usable. As the dataset becomes richer, the accuracy of models also increases. The parameters of the dataset used in this study contain raw data closer to real conditions in terms of both quantity and quality compared to previous studies. When examining the models established to identify liver diseases, it is observed that besides the model performance, the performance of experts also affects due to the use of parameters containing expert opinions. The data set used in this study did not include subjective data other than class values, and only expert opinions were used in training the model. Thus, the model performance will be less dependent on the dataset compared to other studies. Real-life data has been worked on with different models to see which structures are better. Artificial neural networks and particle swarm optimization methods were trained to solve the classification problem and results were analyzed by testing with training and test data in the study.

\*Sorumlu Yazar/Yazarlar / Corresponding Author/Authors : \*shcavga@gelisim.edu.tr / Tel: +90 538 256 8450

## 1. Giriş (Introduction)

Hepatit, iltihaplanmaya neden olan bir karaciğer enfeksiyonudur. Dünya sağlık örgütüne göre; hepatit genellikle virüslerden kaynaklanır ancak farklı enfeksiyonlar, toksik maddeler ve otoimmün hastalıklardan da kaynaklanabilir. Günümüzde altı farklı insan hepatit virüsü türü ayrıntılı olarak karakterize edilmektedir: hepatit A virüsü (HAV), B virüsü (HBV), C virüsü (HCV), D virüsü (HDV), E virüsü (HEV) ve G Virüsü (HGV) [1]. Bu virüslerin her biri akut hepatite neden olabilir ancak hepatit B ve C virüsleri kronik hastalıklarla ilişkilidir ve viral hepatit en yaygın ölüm nedeni olarak kabul edilmektedir [2].

Hepatit C, kan yoluyla bulaşan en yaygın patojendir. Enfekte hastaların yaklaşık %20'si fibrozis, hepatoselüler karsinom ve siroz gibi başka komplikasyonlar da yaşarlar [3].

Karaciğer fibrozu veya yaralanması, etiyolojiden bağımsız olarak kronik karaciğer hastalığına verilen genel bir yara iyileşme yanıtıdır. Progresif fibroz, sonunda fibrotik bantlar, parankimal nodüller ve karaciğer hücre disfonksiyonuna, portal hipertansiyona (PHT), hepatoselüler karsinom (HCC) ve erken ölüme yol açan vasküler distorsiyon ile siroza dönüşür. Karaciğer fibrozu, klinik olarak sessiz bir süreçtir, öyle ki birçok hastaya, hastalığa özgü tedavinin sınırlı etkiye sahip olduğu ileri bir aşamada tanı konulur. Bunun merkezinde sirozun sadece şiddetli fibroz olmadığı, geri döndürülebilir ve döndürülemeyen bileşenleri olan daha karmaşık bir patolojik durum olduğunun kabul edilmesi yer alır [4]. Karaciğer herhangi bir şekilde hasar gördüğünde, hepatositler kaybedilebilir. Ancak hücreler hızla yenilenme kapasitesine sahiptir ve fibroz oluşmayabilir. Hasara neden olan etkenin frekansı ölüm-rejenerasyon frekansından yüksek olduğunda ise karaciğerde fibroz dokusu birikmeye başlar ve karaciğer sertleşir. Karaciğer sirozu; karaciğerdeki bu aşırı fibroz birikimini tanımlamak için kullanılır [5].

HCV enfeksiyonunun viral tanısında standartlaştırılmış serolojik ve moleküler testler kullanılmaktadır. Serolojik testler, enzime bağlı immüno sorbent testleri kullanılarak serum veya plazmada HCV'ye özgü antikorların saptanmasını içerir. Tedavinin aciliyetini belirlemek için karaciğer biyopsisi veya invaziv olmayan testlerle karaciğer fibrozisinin derecesini değerlendirmek gerekir [6]. Hepatit, fibroz ve siroz hastalıklarının tanısı için sıklıkla kullanılan parametrelere örnek olarak; albümin (ALB), alkaline fosfatase (ALP), alanin aminotransferaz (ALT), aspartat aminotransferaz (AST), bilirubin (BIL), cholinesterase (CHE), kolesterol (CHOL), creatin kinase (CREA) ve gamma-glutamyl transferase (GGT) ve Protein (PROT) verilebilir. Bu parametrelerin değerleri, hastalığın aktivitesini ve evresini değerlendirmek için de kullanılır.

Bu çalışmada biyokimya cihazı çıktılarının direkt kullanımı ile karaciğer hastalıklarının tespiti amaçlanmıştır. Çalışmada; 10 'u karaciğer enzimi olmak üzere 12 parametre kullanılarak 5 farklı karaciğer durumunu için sınıflandırma yapılmıştır. Bu amaçla yapay sinir ağları, lojistik regresyon ve parçacık sürü optimizasyonu metotları kullanılmıştır.

## 2. Deneysel Metot (Experimental Method)

Bu çalışmada yapay sinir ağları, parçacık sürü optimizasyonu ve lojistik regresyon metotları, sınıflandırma problemi için farklı parametrelerle çalıştırılıp performans analizleri yapılmıştır. Günümüzde karar verme sistemi olarak yapay sinir ağları ve sezgisel yöntemlerin kullanımlarıyla, hepatit C'nin yanı sıra birçok hastalığın teşhisini kolay ve hızlıdır.

## 2.1. Literatür Taraması (Literature Review)

Sağlık alanında makine öğrenmesi ve sezgisel yöntemlerdeki gelişmelerle birlikte hız kazanmıştır. Bir çalışmada makine öğrenmesi teknikleri kullanılarak diyabet ve kardiyovasküler hastalıkların teşhisi [7], yapay sinir ağı kullanılarak epileptik nöbet sınıflandırması [8], prostat dokularının sınıflandırılması [9], stres sınıflandırması [10] veya yapay zeka ile yapılan kardiyoloji çalışmaları verilebilir [11]. Yapay sinir ağı, makine öğrenmesi veya yapay zeka metotları sağlık alanında başarılı modeller oluşturmak için giderek daha fazla kullanılmaktadır [12-15]. Ses analizi üzerine yapılan bir çalışmada; 57 sağlıklı 150 patolojik olarak etiketlenmiş popülasyon YSA (Yapay Sinir Ağı) kullanarak sınıflandırılmıştır. Sistemin sınıflandırma başarısı %90,47 olarak ölçülmüştür [16]. 2019 yılında geliştirilen EfficientNet mimarileri, geçmişteki modellere kıyasla hesaplama verimliliğini artırırken [17], özellikle meme kanseri (AUC (Area Under the ROC Curve) 0,95) [18], akciğer kanseri (AUC 0,93) [19] ve beyin kanseri (doğruluk %98) [20] gibi diğer birçok kanser türünü yüksek performansla teşhis etmek için başarıyla uygulanmıştır. İyi/kötü huylu sınıflandırma görevlerine ek olarak lezyon tanımlama ve segmentasyon için U-Net [21] ve V-Net [22] modelleri gibi birçok bilişsel nöral ağ mimarisi de mevcuttur. Bu tür modeller, iki segmentasyon maskesi arasındaki örtüşme derecesini değerlendiren Zar benzerlik katsayısı/puanı kullanarak değerlendirme yapmaktadır. Mamografik meme lezyonu segmentasyonu için Dice skoru (zar katsayısı) %96 olan bir U-Net modeli de geliştirilmiştir [23]. Bunların yanında farklı parametreler ve farklı metotlar kullanarak yapılan birçok kanser çalışması da mevcuttur [24].

Bunların yanında bu çalışmanın konusu olan karaciğer hastalıklarıyla ilgili tanı destek sistemleri de sıklıkla çalışılmaktadır. 800'ü Hepatit C tanısı konulmuş 1000 kişi ile yapılan, 7 parametreye göre oluşturulan veri seti üzerinde 3 farklı ağ yapısı denenmiştir. Bunlar; ölçekli gradyan, Levenberg-Marquardt ve bayes düzenlemeli sinir ağlarıyla çalışılmış ve en düşük ortalama karesel hata sonucunu veren gizli katmanda 20 nörona sahip Levenberg-Marquardt algoritmasıyla bir sistem kurulmuştur. Önerilen YSA-PSO (Parça Sürü Optimizasyonu) yapısı, YSA çıktıların PSO'nun girdisi olarak kullanılarak iki sınıflandırma yönteminin peşe çalıştırılması oluşturulmuştur. Bu sistem ile %97,78 doğruluk elde edilmiştir [25]. Sağ alt karın ağrısı şikâyetiyle gelen 156 hastadan toplanan 9 parametreye göre kurgulanan geri yayımlı 3 katmanlı YSA çalışmasında; duyarlılık, özgüllük ve pozitif-negatif tahmin değerleri sırasıyla %100, %97,2, %96,0 ve %100 bulunmuştur [26]. Karaciğer hastalığı teşhisi için; 155 kişi ve 19 parametreden oluşan veri setini Levenberg-Marquardt algoritmasıyla çalışarak doğruluğu %91,9 hesaplanmıştır. Çalışmada 4 farklı aktivasyon fonksiyonu kullanılmış ve en yüksek doğruluğun sigmoid ile bulunduğu tespit edilmiştir. Çalışmanın son aşamasında 10 katlı çapraz validasyon kullanılarak doğruluk %93,2'ye çıkartılmıştır [27]. Oto-kodlayıcı sinir ağı ile hepatit tespiti yapılması amaçlanan çalışmada, 24 gizli katman ve ölçekli eşlenik eğitim algoritması ile kodlama kısmı, Levenberg-Marquardt algoritması ve ortalama karesel hata yöntemi ile de kod çözme bölümü oluşturulmuştur. Maksimum 1000 iterasyonda çalıştırılarak 20 kez tekrar çalıştırılan bu oto-kodlayıcı sinir ağı modeli ile toplam 155 örneğin 19 özneliğe göre araştırılması sağlanmış ve %97,82 doğruluk hesaplanmıştır [28].

Diğer bir çalışmada 21 hastaneden toplanan 298 kişilik veri seti YSA ve lojistik regresyonla analiz edilmiştir. YSA için 7 nöronluk bir girdi katmanı, 4 nöronluk bir gizli katman ve bir nöronlu çıktı katmanı vardır. Çalışmadaki lojistik regresyon ve YSA'nın AUC değerleri sırasıyla  $0,809 \pm 0,062$  ve  $0,756 \pm 0,059$  olarak bulunmuştur [29]. YSA, Radyal Temelli Fonksiyon (RBF), Konik Kesit Fonksiyonu Sinir Ağı (CSFNN) ile modeller kurarak 155 kişilik 19 parametrelili

setin denendiği bir çalışmada, veri seti 5 ayrı alt kümeye bölünerek 5 katlı çapraz validasyon yapılmış ve modellerin başarıları incelenmiştir. En başarılı sonucu 93,75 doğruluk ile CSFNN yapısı sağlamıştır [30]. 15 parametrelili 300 kişilik veri seti ile k-NN, geri beslemeli YSA ve RBF denenen sistemde 2'li ve 5'li sınıflandırma yapılmıştır. Geri beslemeli YSA, ikili sınıflandırma için beşer nöronlu iki gizli katman sigmoid aktivasyon fonksiyonu ile çalıştırılmıştır. RBF, ikili sınıflandırma için 19 nöronlu bir gizli katman gauss aktivasyon fonksiyonuyla çalıştırılmıştır. Son olarak k-NN algoritması ikili sınıflandırma için Manhattan uzaklık hesaplama denklemi kullanılarak yapılmıştır. Kurulan modeller süre ve doğruluk kıyaslamasına tutulmuştur. Buna göre k-NN ile 2 sınıfa ayrılan model %99,33 ile en başarılı bulunan model olmuştur [31].

Modellerin sınıflandırma performanslarını daha iyi kıyaslayabilmek adına; literatürde sıklıkla kullanılan 155 kişinin 19 parametre ile incelendiği ve uzman görüşleri ile değerlendirildiği veri seti ile yapılan çalışmaların yer aldığı genişletilmiş literatür taraması Tablo 1'de paylaşılmıştır.

**Tablo 1.** Karaciğer hastalıkları teşhisinde kullanılan modellerin incelemesi

(A review of models used in the diagnosis of liver diseases)

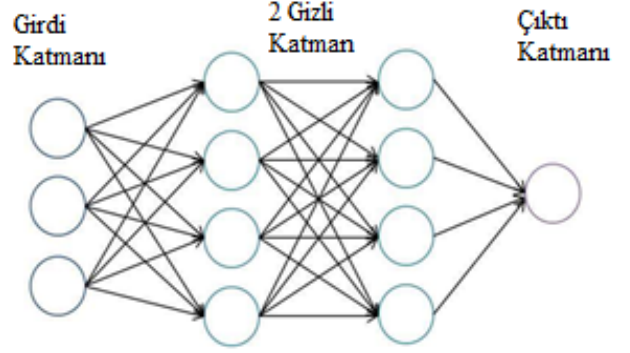
Referans	Algoritma	Sınıflandırma Doğruluğu
[30]	MLP	81,37
	RBF	85
	NB	87,83
	BNNF	88,76
	CSFNN	90
	BNND	90
	TAN	90,1
	C4.5	93,6
	CLN	66,36
	PNN	80
[32]	ELMAN	86,18
	BPN	88,07
	LVQ	92,72
[33]	FFNN	91,33
	GRNN	92
	SELF-(SOM)	-
	FDT	75,39
[34]	Naive Bayes	82,05
	PSO	82,66
	KNN	83,45
	SVM	86,92
	CBR+PSO	92,83
[35]	MLP	80
	MLP+GS	82,58
	SVM	87,1
[36]	FDA+SVM	93,55
	LFDA+SVM	96,77
	IACA+LSSVM	91,6
	LSSVM	79,1
[37]	LFDA+LSSVM	83,3
	IACA+LSSVM	91,6
[38]	MLP+LM (10 FC)	91,87
[39]	FS-AIRS	92,59
[40]	FS-AIRS (10 FC)	94,12
[41]	LDA+ANFIS	94,16
[42]	ABCFS+SVM	94,92
[43]	IG+ANFIS	95,24
[44]	SVM-SA	96,2
[45]	GA-WK-ELM	97,56

Tablo 1'deki kısaltmalar semboller bölümünde paylaşılmıştır.

## 2.2. Yapay Sinir Ağları (Artificial Neural Networks)

YSA'lar insan beynine benzeyen katmanlı yapıyla birbirine bağlı düğüm veya nöronları vasıtasıyla bilgi toplayabilen, depolayabilen ve öğrenebilen sistemlerdir. Bu sayede YSA kullanılarak, örüntü tanımlanabilir, veri sınıflandırılabilir veya tahminleme yapabilmektedir.

Biyolojik sinir sisteminden yararlanılarak geliştirilen yapay sinir ağları, paralel çalışan ögeler kullanarak birkaç işleme katmanının birleştirilmesiyle oluşur. Ağ bir girdi katmanı, bir veya daha fazla gizli katman ve bir çıktı katmanından oluşur. Her katmanda birkaç düğüm veya nöron vardır ve her katmandaki düğümler bir önceki katmandaki düğümlerin çıktısını girdi olarak kullanır. Böylece tüm nöronlar farklı katmanlar aracılığı ile çıktıya katkı sağlamış olur. Her nörona öğrenme süreci sırasında belirli kurullarla değişebilecek ağırlıklar ve sapma faktörleri atanır. Bu parametrelere göre de ağın öğrenme hızı ve doğruluğu değiştirilebilir [46]. Şekil 1'de 3 nöronlu bir girdi (input) ve 1 nöronlu bir çıktı (output) katmanı olan ayrıca her biri 4 nöron içeren 2 gizli (hidden) katmana sahip basit bir ileri beslemeli yapay sinir ağ yapısı örneği paylaşılmıştır [47].



**Şekil 1.** Örnek yapay sinir ağı modeli  
(Example artificial neural network model)

## 2.3. Parçacık Sürü Optimizasyonu (Particle Swarm Optimization)

Hayvan gruplarının sosyal davranışlarına ilişkin çalışmalar sonucunda bazı sürülerin bilgi paylaşımları sayesinde hayatta kalma avantajı elde ettiği görülmüştür. Kenedy ve Eberhart buradan yola çıkarak doğrusal olmayan sürekli fonksiyonları optimize etmek için parçacık sürü optimizasyonunu önermiştir. Bu algoritmada arama işlemi her bir bireyin kendi durumunun sürüdeki diğer bireylere kıyasına dayanır. Aynı zamanda her bir bireyin önceki durumu da dikkate alınır. Buna göre en optimal sonucu sağlayan bireye doğru yönelim her iterasyonda devam eder. Kabul edilebilir maksimum hata veya iterasyon sayısı kısıtlarına göre problemin en iyilemesi gerçekleştirilir [48].

PSO algoritmasının uygulama adımları şu şekildedir;

- Bireylerden oluşan bir sürü ve bu sürünün dağılımı için alan belirlenir.
- Sürü belirlenen alanda rastgele pozisyonlandırılır.
- Her bir birey için amaç fonksiyonuna göre uygunluk değeri hesaplanır.
- Sürüdeki bireyler, yeni veya bir önceki uygunluk değerlerini kıyaslayarak en iyi değer hafızada tutulur.
- Sürüdeki bireyler arasında en iyi değere sahip olduğu bulunan bireyin konumu da sürü en iyi değeri olarak hafızada tutulur.

- vi. Her bir bireyin hızı ve konumu sürü en iyi değerine göre yeniden düzenlenerek iterasyon adımları gerçekleştirilir.
- vii. Belirlenen durdurma şartları sağlanıncaya kadar adımlar devam ettirilir.

#### 2.4. Lojistik Regresyon Analizi (Logistic regression analysis)

Lojistik regresyon; bağımlı değişkenin ikili, üçlü veya daha fazla kategoride incelendiği durumlarda bağımsız değişkenlerle neden-sonuç ilişkisini belirlemede kullanılan bir yöntemdir. Lojistik regresyon kullanım kolaylığı ile diğer regresyon yöntemlerine göre ön plana çıkmıştır. Diğer regresyon modellerinden en büyük farkı, sonuç değerinin kesikli (kategorik) ikili veya daha çok değer alabilmesidir. Yaygın şekilde sağlık, biyoloji, finans gibi sektörlerde kullanılmaktadır [49].

#### 2.5. Uygulama (Application)

Çalışmadaki kullanılan karaciğer enzimleri veri seti için bu alandaki çalışmaların sıklıkla kullandığı Kaliforniya Üniversitesi'nin yayınladığı veri seti kullanılmıştır [50]. Kullanılan veri setinde 12 parametre (yaş, cinsiyet, albümin, alkalik fosfat, alanin transaminaz, aspartat transaminaz, bilirubin, kolinesteraz, kolesterol, kreatin kinaz, gama-glutamil transferaz ve protein) ve 5 sınıf (karaciğer donörü olabilir, donörlük şüpheli, hepatit, siroz ve fibroz) vardır. 615 veriden oluşan setteki her bir sınıfa ait veri sayısı sırasıyla; 533, 7, 24, 21 ve 30'dur. Parametreler biyokimya cihazının direkt sonuçlarından ve hasta anemnezlerinden toplanmıştır. Diğer bir deyişle subjektif veri içermemektedir. Veri seti her bir sınıf verisi kendi içinde ayrılacak şekilde %75 eğitim, %25 test seti olarak, 463 eğitim ve 152 test verisi olacak şekilde bölünmüştür. Önceki çalışmalarda sıklıkla denenen algoritmalar kullanılarak gerçek hayat problemi üzerindeki sonuçların analizi amaçlanmaktadır. Veri setinin bir kısmı Ek A'da paylaşılmıştır.

Çalışmada Matlab yazılımı kullanılmıştır. Eğitim algoritması seçimi için literatür analizi sonuçlarına göre; ileri beslemeli ağ yapısı, Levenberg-Marquardt (LM), Ölçekli Eşlenik Gradyan (Scaled Conjugate Gradient - SCG), Bayes Düzenleştirme Geri Yayılımı (Bayesian Regularization Backpropagation - BR) eğitim algoritmaları kullanılmıştır. PSO algoritması ile hibrit sistem çalışması için ağın

tanımlanmasının ardından ağırlıkların ve sapma (bias) değerlerinin bulunması için PSO algoritması kurulmuştur. Literatür incelendiğinde yapay sinir ağlarının eğitiminde LM algoritması hızlı yakınsama ve kararlılığı nedeniyle tercih edilmektedir. Ancak ağıdaki ağırlık sayısı arttıkça daha düşük ortalama kare hataları elde edilir ve diğer avantajları da hızlı şekilde düşme eğilimi gösterir. Genellikle geri yayılım algoritması ile tercih edilen LM, Newton algoritma hızını ve dik iniş (steepest descent) metodunun kararlılığını birleştirerek günümüzde ağ eğitiminde etkili şekilde kullanılmaktadır [51]. SCG algoritması özellikle çok sayıda ağırlığa sahip ağlarda iyi performans göstermektedir. SCG algoritmasında adım büyüklüğü ölçeklendirme mekanizması kullanıldığından öğrenme döngüsü için yol araştırmasından kurtulmaktadır. Bu sebeple de zaman kaybetmesi önlenip ikinci derece algoritmalarına kıyasla hızlı çalışabilir [52, 53]. BR; ağırlık ve sapma değerlerini LM'ye göre güncelleyen bir eğitim algoritmasıdır. Hata karelerini ve ağırlıkların kombinasyonunun bir kombinasyonunu, genelleme yeteneği yüksek bir ağ oluşturmak için kullanır [53].

### 3. Sonuçlar ve Tartışmalar (Results and Discussions)

Problem çözümünde kullanılan tüm algoritmalar için doğruluk değeri; doğru sonuç sayısının tüm sonuçlara bölünmesiyle bulunmuş ve yüzdesel olarak incelenmiştir. Toplam verinin %75'ini oluşturan eğitim verisi sonuçları Tablo 2 ve Tablo 3'de paylaşılmıştır.

Önerilen model için PSO ve yapay sinir ağı algoritmaları farklı parametrelerle denenmiştir. Literatürde sıklıkla kullanılan 20 ve 50 parçacık 5, 10 ve 15 parçacık ile denenmiştir. Ulaşılabilecek en yüksek seviye doğruluğun tespiti için de 100 parçacık ve 100 iterasyon denenmiştir fakat eğitimin tamamlanması uzun süreceği de göz önüne alınarak bu parametrelerle çalışılmamıştır. YSA yapısı için LM, SCG ve BR algoritmaları ve gradyan azaltımı yalın ve momentum eklentili olarak 5, 10, 15 ve 20 nöron ile denenmiştir.

Test verileriyle sınanan modellerde en yüksek doğruluk değeri yüzde 95,39 ile SCG-gdm (Momentumlu Gradyan Azaltma) algoritmasının 20 nöronlu modeli ile kurulan YSA yapısı ile bulunmuştur. Veri setinde eğitimde kullanılmamış %25'lik kısım ile denenen modelin doğruluk değeri çıktıları Tablo 4 ve Tablo 5'da paylaşılmıştır.

**Tablo 2.** Eğitim Verisi için YSA Sonuçları (ANN Results for Training Data)

Parçacık Sürü Optimizasyonu									
Parçacık Sayısı	İterasyon Sayısı	1 Nöron	2 Nöron	3 Nöron	4 Nöron	5 Nöron	10 Nöron	15 Nöron	20 Nöron
20	5	87,69	87,26	86,39	86,61	83,59	88,98	89,63	90,71
20	10	86,83	86,39	90,06	86,61	88,55	90,06	91,58	89,63
20	15	86,61	87,04	89,20	88,77	88,98	92,44	91,36	90,93
50	5	89,20	87,90	86,83	86,83	87,26	90,71	90,06	91,58
50	10	86,83	89,85	89,85	90,06	49,88	92,44	93,09	92,01
50	15	88,34	91,58	87,90	88,55	91,36	92,87	92,66	93,09
100	100	95,46	94,6	94,82	94,17	94,82	95,46	96,76	96,33

**Tablo 3.** Eğitim Verisi için YSA Sonuçları (ANN Results for Training Data)

İleri Beslemeli Geri Yayılım Ağı						
Eğitim Algoritması	Öğrenme Algoritması	5 Nöron	10 Nöron	15 Nöron	20 Nöron	
trainlm	learnsgdm	96,76	97,19	97,41	97,19	
	learnsgd	92,87	95,03	96,33	96,98	
trainscg	learnsgdm	92,22	90,5	90,93	92,22	
	learnsgd	86,39	91,14	92,22	86,39	
trainbr	learnsgdm	97,84	97,62	98,7	98,06	
	learnsgd	97,84	98,27	98,06	99,14	

**Tablo 4.** Test Verisi için YSA Sonuçları (ANN Results for Test Data)

Parçacık Sürü Optimizasyonu					
Parçacık Sayısı	İterasyon Sayısı	5 Nöron	10 Nöron	15 Nöron	20 Nöron
20	5	88,82	89,47	90,13	88,82
20	10	89,47	87,50	89,47	87,50
20	15	89,47	89,47	88,82	89,47
50	5	88,82	89,47	88,82	88,82
50	10	91,45	88,82	89,47	88,82
50	15	89,47	88,16	90,13	88,82
100	100	90,1	90,13	90,79	89,47

**Tablo 5.** Test Verisi için YSA Sonuçları (ANN Results for Test Data)

İleri Beslemeli Geri Yayılım Ağı					
Eğitim Algoritması	Öğrenme Algoritması	5 Nöron	10 Nöron	15 Nöron	20 Nöron
trainlm	learnrdm	88,82	88,82	89,47	90,13
	learnrd	92,11	91,45	90,79	90,79
trainscg	learnrdm	90,13	88,16	88,82	95,39
	learnrd	87,5	88,16	88,82	87,5
trainbr	learnrdm	86,84	89,47	88,16	88,16
	learnrd	88,82	89,47	90,79	90,79

En yüksek doğrulukla çalışan yapay sinir ağı yapısı 12 nöronlu girdi katmanı, 20 nöronlu gizli katman, 5 nöronlu çıktı katmanı ile 5 sınıf çıktısını içeren modeldir.

Önerilen model, karışıklık matrisi ile incelenmiştir. Çok sınıflı bir çalışma olduğundan yapı kurulmadan önce her bir sınıfın gerçek ve tahmini değerlerinin tablosu oluşturulmalıdır. Bu değerler Tablo 6’da incelenmiştir. Tablo üzerinden, gerçekte birinci sınıfa ait olup modelin 1. sınıfa atadığı girdilerin sayısının 130, 1. Sınıf olması gerekirken 5. Sınıfa atadığı veri sayısının 2 olduğu görülmektedir.

**Tablo 6.** Önerilen Metodun Gerçek Sınıf ve Model Tahmini Karışıklık Matrisi Sonuçları (Target Class and Model Estimated Confusion Matrix Results of Proposed Method)

		Gerçek Değer				
		1	2	3	4	5
Tahmini Değer	1	130	0	0	0	2
	2	0	4	1	0	0
	3	2	0	2	0	0
	4	0	0	1	6	0
	5	1	0	0	0	3

**Tablo 7.** Modelin Kesinlik, Duyarlılık ve F1 Puan Değerleri (Precision, Recall and F1 Score Values of the Model)

	Doğru P.	Doğru N.	Yanlış P.	Yanlış N.	Kesinlik	Duyarlılık	F1 Puanı
1	130	17	2	3	0,98	0,98	0,98
2	4	147	1	0	0,8	1	0,89
3	2	146	2	2	0,5	0,5	0,5
4	6	145	1	0	0,85	1	0,92
5	3	146	1	2	0,75	0,6	0,67

Tablo 6’daki bilgiler doğrultusunda oluşturulan karışıklık matrisi kullanılarak;

- Kesinlik değeri;  $TP/(TP+FP)$ ,
- Duyarlılık değeri ise  $TP/(TP+FN)$  ile hesaplanır.

Burada TP doğru pozitif, FP yanlış pozitif, FN yanlış negatif anlamına gelmektedir. Değerler Tablo 4 ile hesaplanmıştır. Kesinlik, tahmin edilen tüm pozitiflerden kaç tanesinin gerçekten pozitif olduğunun ölçüsüdür. Duyarlılık ise kaç pozitif kaydın doğru tahmin edildiğinin ölçüsüdür. Her iki değer de 1’e yakın olması istenmektedir. Önerilen modelin performans metrikleri Tablo 7’de verilmiştir.

Kesinlik ve duyarlılık değerleri kullanılarak model ölçümü için F1 puanı hesaplanabilir. F1 puanı; duyarlılık ve kesinliğin çarpımlarının iki katının, kesinlik ve duyarlılık toplamına bölünmesiyle bulunur. Diğer bir deyişle F1 puanı kesinlik ve duyarlılığın harmonik ortalamasıdır ve modelin genelleme kabiliyetinin göstergelerinden biridir. Bu değer de 1’e yakın olması istenir. Tablo 4 üzerinden incelenebileceği gibi 3. Sınıf ile kodlanmış hepatit hastalığında veri sayısının dengesizliği sebebiyle Tablo 5’de paylaşılan F1 puanı değerleri bu sınıf için diğer sınıflara göre daha düşük hesaplanmıştır. Bu durum için sentetik veri artırma algoritmaları kullanılabilir. Bu çalışma gerçek hayat verileriyle sağlık alanında olduğundan veri manipülasyonunu engelleme amacıyla sentetik veri üretimi tercih edilmemiştir.

Model başarısının kıyası için aynı veri seti ile yapılan çalışma olmadığından model başarısı lojistik regresyon ile kıyaslanmıştır. Uygulamada kullanılan veri setine lojistik regresyon modeli uygulandığında lojistik regresyon diğer çalışmalarda olduğu ve beklendiği gibi güncel modellerden kısmen daha düşük sonuçlar vermiştir. Lojistik regresyonun sınıflandırma başarısı %90,1 olarak bulunmuştur. Lojistik regresyon modelinin karışıklık matrisi sonuçları Tablo 8’de, performans metrikleri Tablo 9’da paylaşılmıştır.

**Tablo 8.** Lojistik Regresyonun Karışıklık Matrisi Tablosu (Confusion Matrix Table of Logistic Regression)

		Gerçek Değer				
		1	2	3	4	5
Tahmin Değeri	1	131	1	0	2	2
	2	0	2	0	0	0
	3	1	0	0	1	2
	4	0	1	2	3	0
	5	1	0	2	2	1

#### 4. Simgeler (Symbols)

- BNNF : Bayesian Network with Naive Dependence and Feature selection  
 BNND : Bayesian Network with Naive Dependence  
 TAN : Tree Augmented Naive Dependence  
 C4.5 : C4.5 Decision Tree

**Tablo 9.** Lojistik Regresyonun Kesinlik, Duyarlılık ve F1 Puan Değerleri  
(Precision, Recall and F1 Score Values of Logistic Regression)

	Doğru P.	Doğru N.	Yanlış P.	Yanlış N.	Kesinlik	Duyarlılık	F1 Puanı
1	131	16	5	2	0,96	0,98	0,97
2	2	150	0	2	1	0,5	0,67
3	0	146	4	4	0	0	0
4	3	141	3	5	0,5	0,37	0,43
5	1	144	5	4	0,17	0,2	0,18

Hastalıklar	Age	Sex M:0, F:1	ALB Albumin	ALP Alkaline Phosphatase	ALT Alanine Transaminase	AST Aspartate Transaminase	BIL Bilirubin	CHE Cholinesterase	CHOL Cholesterol	CREA Creatine Kinase	GGT Gamma- Glutamyl Transferase	PROT Protein	
0:sağlıklı,	0	0,32	0	38,5	52,5	7,7	22,1	7,5	6,93	3,23	106	12,1	69
1:şüpheli,	0	0,32	0	38,5	70,3	18	24,7	3,9	11,17	4,8	74	15,6	76,5
2:hepatit,	1	0,47	0	22,5	124	79,5	46,7	2,3	6,83	4,3	170	345,6	58,6
3:Siroz,	1	0,59	1	19,3	208,2	325,3	146,6	6,9	5,33	4,72	32	295,6	53,1
4:Fibroz	2	0,33	1	43	29,6	3,8	16,7	6	6,88	5,72	58,8	11,5	78,2
	2	0,41	1	37	31,2	8,2	38,3	7	7,08	5,3	60,8	24,7	82,4
	3	0,71	0	37	68,3	130	90	15	9,92	4,7	79	77	76
	3	0,36	1	46	39,3	67,1	161,9	13	9,24	4,81	65,3	60	73,9
	4	0,38	0	44	68,3	94	60	12	4,37	3,2	61	99	77
	4	0,39	0	34	137,8	4,8	35,6	9	3,65	4,82	519	133,4	57,5

CNN : Competitive Neural Network  
 PNN : Probabilistic Neural Network  
 BPN : Backpropagation  
 LVQ : Learning Vector Quantization  
 FFNN : Feedforward Backpropagation Neural Network  
 GRNN : Generalized Regression Neural Network  
 SOM : Self Organizing Map. 500 epoc ile %2 doğruluk sağlandığı için kullanımı uygun görülmemiştir.  
 FDT : Fuzzy Decision Tree  
 CBR : Case-Based Reasoning  
 GS : Genetic Search  
 LFDA : Local Fisher Discriminant Analysis  
 LSSVM : Least Squares Support Machines  
 IACA : Improved Ant Colony Algorithm  
 FS-AIRS : Feature Selection - Artificial immune recognition system  
 LDA : Linear Discriminant Analysis  
 ANFIS : Adaptive Network based on Fuzzy Inference System  
 ABCFS : Artificial Bee Colony Algorithm Feature Selection  
 IG : Information Gain  
 SVM-SA : Support Vector Machine and Simulated Annealing  
 GA-WK-ELM: Genetic Wavelet Kernel Extreme Learning Machine

## 5. Sonuçlar (Conclusions)

YSA ve/veya sezgisel yöntemlerle analiz edilen veri setine göre modellerin doğrulukları kıyaslanmıştır. Kıyas sonucunda tablolardan incelenebileceği gibi SCG eğitim algoritmasıyla kurulan sistemin en doğru sonuçlara ulaştığı tespit edilmiştir. Literatürdeki yapay sinir ağları ile belirli iterasyon sayıları sonucunda elde edilen ağırlık değerlerini sezgisel yöntemlerle artırılması gibi bir yöntem bu çalışmada tercih edilmemiş olup bunun yerine sezgisel yöntemin öğrenme algoritması olarak kullanılması uygun görülmüştür. Çalışmanın en önemli çıktısı; biyokimya cihaz verilerinin direkt olarak kullanması ve bu veriler ışığında sübjektif değerlendirmeler kullanmadan sınıflandırma yapabilesidir.

Sonraki çalışmalarda farklı sezgisel algoritmalar kullanarak model genişletilebilir. Bu veri setine farklı cihazları çıktıları eklenerek sonuçların daha anlamlı hale getirilmesi veya komorbitide tespit edilmesi mümkün kılınabilir.

## Kaynaklar (References)

- Guirao, A.A., Yuste, S.R and Regueiro, B.J., Epidemiology and clinical manifestations of viral hepatitis, Infectious Diseases and Clinical Microbiology, 24 (4), 264-276, 2006.
- Lanini, S., Ustianowski, A., Pisapia, R., Zumla, A., Ippolito, G., Viral Hepatitis: Etiology, Epidemiology, Transmission, Diagnostics, Treatment, and Prevention. Infectious disease clinics of North America, 33 (4), 1045–1062, 2019.
- Mukherjee, R., Burns, A., Rodden, D., Chang, F., Chaum, M., Garcia, N., Bollipalli, N., Niemz, A., Diagnosis and Management of Hepatitis C Virus Infection, Journal of laboratory automation, 20 (5), 519–538, 2015.
- Fallowfield, J., & Hayes, P., Pathogenesis and treatment of hepatic fibrosis: is cirrhosis reversible?, Clinical Medicine, 11 (2), 179, 2011.
- Lefton, H. B., Rosa, A., & Cohen, M., Diagnosis and epidemiology of cirrhosis, The Medical clinics of North America, 93 (4), 787–vii, 2009.
- Wilkins, T. Akhtar, M., Gititu, E., Jalluri, C., Ramirez, J., Diagnosis and Management of Hepatitis C, American family physician, 91 (12), 835–842, 2015.
- Alić, B., Gurbeta, L., & Badnjević, A., Machine learning techniques for classification of diabetes and cardiovascular diseases, In 2017 6th mediterranean conference on embedded computing (MECO), 1-4 Feb, 2017.
- Sarić, R., Jokić, D., Beganović, N., Pokvić, L. G., & Badnjević, A., FPGA-based real-time epileptic seizure classification using Artificial Neural Network, Biomedical Signal Processing and Control, 62, 102-106, 2020.
- Spahić, L., & Čordić, S., Prostate tissue classification based on prostate-specific antigen levels and mitochondrial DNA copy number using artificial neural network, In International conference on medical and biological engineering, IFMBE proceedings, 649-654, 2019.
- Alić, B., Sejdinović, D., Gurbeta, L., & Badnjevic, A., Classification of stress recognition using artificial neural network, In 2016 5th Mediterranean Conference on Embedded Computing (MECO), 297-300, 1-5 June 2016.
- Šećkanović, A., Šehovac, M., Spahić, L., Ramić, I., Mamatanzarova, N., Pokvić, L. G., ... & Kacila, M., Review of artificial intelligence application in cardiology, In 2020 9th Mediterranean Conference on Embedded Computing (MECO), Budva-Montenegro, June, 2020.
- Üzülmöz S., Çiftçi M.A., Early diagnosis of lung cancer using deep learning and uncertainty measures, Journal of the Faculty of Engineering and Architecture of Gazi University, 39 (1), 385-400, 2024.
- Kadiroğlu, Z., Deniz, E., & Şenyiğit, A., A comparison of deep learning models for pneumonia detection from chest x-ray images, Journal of the



- Faculty of Engineering and Architecture of Gazi University, 39 (2), 729-740, 2024.
14. Bećirović, L. S., Deumić, A., Pokvić, L. G., & Badnjević, A., Artificial Intelligence Challenges in COPD management: a review, In 2021 IEEE 21st International Conference on Bioinformatics and Bioengineering (BIBE), 1-7, October, 2021.
  15. Hafizović, L., Čaušević, A., Deumić, A., Bećirović, L. S., Pokvić, L. G., & Badnjević, A., The Use of Artificial Intelligence in Diagnostic Medical Imaging: Systematic Literature Review, In 2021 IEEE 21st International Conference on Bioinformatics and Bioengineering (BIBE), 1-6, October, 2021.
  16. İleri, R., Latifoğlu, F., & Güven, A. (2019, October). Classification of Healthy and Pathological Voices Using Artificial Neural Networks, In 2019 Medical Technologies Congress (TIPTEKNO), 1-4, 2019.
  17. Tan, M., & Le, Q., Efficientnet: Rethinking model scaling for convolutional neural networks, In International conference on machine learning (PMLR), 6105-6114, 2019.
  18. Suh, Y. J., Jung, J., & Cho, B. J., Automated breast cancer detection in digital mammograms of various densities via deep learning, Journal of personalized medicine, 10 (4), 211, 2020.
  19. Astaraki, M., Zakko, Y., Dasu, I. T., Smedby, Ö., & Wang, C., Benign-malignant pulmonary nodule classification in low-dose CT with convolutional features, *Physica Medica*, 83, 146-153, 2021.
  20. Guan, Y., Aamir, M., Rahman, Z., Ali, A., Abro, W. A., Dayo, Z. A., ... & Aamir, M., A framework for efficient brain tumor classification using MRI images, *Math. Biosci. Eng.*, 18, 5790-5815, 2021.
  21. Ronneberger, O., Fischer, P., & Brox, T., U-net: Convolutional networks for biomedical image segmentation, In International Conference on Medical image computing and computer-assisted intervention, Proceedings Part III, Springer International Publishing, Munich-Germany, 234-241, 5-9 October, 2015.
  22. Milletari, F., Navab, N., & Ahmadi, S. A., V-net: Fully convolutional neural networks for volumetric medical image segmentation, In 2016 fourth international conference on 3D vision (3DV), 565-571, 25-28 October, 2016.
  23. Baccouche, A., Garcia-Zapirain, B., Castillo Olea, C., & Elmaghraby, A. S., Connected-UNets: a deep learning architecture for breast mass segmentation, *NPJ Breast Cancer*, 7 (1), 1-12, 2021.
  24. Hunter, B., Hindocha, S., & Lee, R. W., The role of Artificial Intelligence in early cancer diagnosis, *Cancers*, 14 (6), 1524, 2022.
  25. Drobo, A., Bećirović, L. S., Pokvić, L. G., Džambo, L., Bečić, E., Badnjević, A., ... & Smajović, A., Application of artificial neural networks in diagnosis of Hepatitis C, In 2022 XXVIII International Conference on Information, Communication and Automation Technologies (ICAT), 1-5, 16-18 June, 2022.
  26. Yoldaş, Ö., Tez, M., & Karaca, T., Artificial neural networks in the diagnosis of acute appendicitis, *The American journal of emergency medicine*, 30 (7), 1245-1247, 2012.
  27. Çetin, O., Temurtas, F., & Gülgönül, Ş., An application of multilayer neural network on hepatitis disease diagnosis using approximations of sigmoid activation function, *Dicle Tıp Dergisi*, 42 (2), 150-157, 2015.
  28. Deperlioğlu, Ö., Hepatitis Disease Diagnosis with Deep Neural Network, *Ecsac'19 IVth European Conference On Science, Artculture*, 467-473, 18-21 April, 2019
  29. Wei, Wei & Wu, Xiaoning & Zhou, Jialing & Sun, Yameng & Kong, Yuanyuan & Yang, Xu., Noninvasive Evaluation of Liver Fibrosis Reverse Using Artificial Neural Network Model for Chronic Hepatitis B Patients, *Computational and Mathematical Methods in Medicine*, 2019, 1-8, 2019
  30. Ozyilmaz, L., & Yildirim, T., Artificial neural networks for diagnosis of hepatitis disease, In Proceedings of the International Joint Conference on Neural Networks, 1, 586-589, 2003.
  31. Muhi, S. H., Abdullah, H. N., & Abd, B. H., Modeling for predicting the severity of hepatitis based on artificial neural networks, *International Journal of Intelligent Engineering and Systems*, 13 (3), 154-166, 2020.
  32. Janghel, R. R., Shukla, A., & Verma, K., Soft computing based expert system for Hepatitis and liver disorders, In 2016 IEEE international conference on engineering and technology (ICETECH), 740-744, 17-18 March, 2016.
  33. Ansari, S., Shafi, I., Ansari, A., Ahmad, J., & Shah, S. I., Diagnosis of liver disease induced by hepatitis virus using artificial neural networks, In 2011 IEEE 14th international multitemic conference, 8-12, 22-24 December, 2011
  34. Neshat, M., Sargolzaei, M., Nadjaran Toosi, A., & Masoumi, A., Hepatitis disease diagnosis using hybrid case based reasoning and particle swarm optimization, *International Scholarly Research Notices*, 2012.
  35. Mishra, S., Mishra, B. K., & Tripathy, H. K., A neuro-genetic model to predict hepatitis disease risk, In 2015 IEEE International Conference on Computational Intelligence and Computing Research (ICIC), 1-3, 10-12 December, 2015.
  36. Chen, H. L., Liu, D. Y., Yang, B., Liu, J., & Wang, G., A new hybrid method based on local fisher discriminant analysis and support vector machines for hepatitis disease diagnosis, *Expert systems with applications*, 38 (9), 11796-11803, 2011.
  37. Husain, N. P., Arisa, N. N., Rahayu, P. N., Arifin, A. Z., & Herumurti, D., Least squares support vector machines parameter optimization based on improved ant colony algorithm for hepatitis diagnosis. *Jurnal Ilmu Komputer dan Informasi*, 10 (1), 43-49, 2017.
  38. Bascil, M. S., & Temurtas, F., A study on hepatitis disease diagnosis using multilayer neural network with Levenberg Marquardt training algorithm, *Journal of medical systems*, 35 (3), 433-436, 2011.
  39. Polat, K., & Güneş, S., 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*, 16 (6), 889-901, 2006
  40. Polat, K., & Güneş, S., Medical decision support system based on artificial immune recognition immune system (AIRS), fuzzy weighted pre-processing and feature selection, *Expert Systems with Applications*, 33 (2), 484-490, 2007.
  41. Dogantekin, E., Dogantekin, A., & Avci, D., Automatic hepatitis diagnosis system based on linear discriminant analysis and adaptive network based on fuzzy inference system, *Expert Systems with Applications*, 36 (8), 11282-11286, 2009.
  42. Uzer, M. S., Yilmaz, N., & Inan, O., Feature selection method based on artificial bee colony algorithm and support vector machines for medical datasets classification, *The Scientific World Journal*, 1-10, 2013.
  43. Ahmad, W., Ahmad, A., Iqbal, A., Hamayun, M., Hussain, A., Rehman, G., ... & Huang, L., Intelligent hepatitis diagnosis using adaptive neuro-fuzzy inference system and information gain method, *Soft Computing*, 23 (21), 10931-10938, 2019.
  44. Sartakhti, J. S., Zangoeei, M. H., & Mozafari, K., Hepatitis disease diagnosis using a novel hybrid method based on support vector machine and simulated annealing (SVM-SA), *Computer methods and programs in biomedicine*, 108 (2), 570-579, 2012.
  45. Avci, D., An automatic diagnosis system for hepatitis diseases based on genetic wavelet kernel extreme learning machine, *Journal of Electrical Engineering and Technology*, 11 (4), 993-1002, 2016.
  46. Smith, A. E., X-bar and R control chart interpretation using neural computing, *The International Journal of Production Research*, 32 (2), 309-320, 1994.
  47. Ma, X., Spinner, S., Venditti, A., Li, Z., & Tang, S., Initial Margin Simulation with Deep Learning, *Social Science Research Network*, 2019.
  48. Juneja, M., & Nagar, S. K., Particle swarm optimization algorithm and its parameters: A review, In 2016 International Conference on Control, Computing, Communication and Materials (ICCCCM), 1-5, 21-22 October, 2016.
  49. Özdamar, K., Statistical data analysis with packet programs, *Eskişehir-Turkey, Nisan Yayıncılık*, 2013.
  50. Dua, D. and Graff, C. (2019). UCI Machine Learning Repository, Irvine, CA: University of California, School of Information and Computer Science, <http://archive.ics.uci.edu/ml>. Accessed: December, 10, 2022.
  51. Çavuşlu, M. A., Becerikli, Y., & Karakuzu, C., Levenberg-Marquardt algoritması ile YSA eğitiminin donanımsal gerçekleştirilmesi, *Türkiye Bilişim Vakfı Bilgisayar Bilimleri ve Mühendisliği Dergisi*, 5 (1), 2012.
  52. Orozco, J., & Garcia, C. A. R., Detecting pathologies from infant cry applying scaled conjugate gradient neural networks, In European symposium on artificial neural networks, Bruges-Belgium, 23, 25, April, 2003.
  53. Baghirli, O., Comparison of Lavenberg-Marquardt, scaled conjugate gradient and Bayesian regularization backpropagation algorithms for multistep ahead wind speed forecasting using multilayer perceptron feedforward neural network, *DIVA*, 2015.