



Contents lists available at *Dergipark*

## Journal of Scientific Reports-B

journal homepage: <https://dergipark.org.tr/en/pub/jsrb>



E-ISSN: 2717-8625

Sayı(Number) 8, Aralık(December) 2023

### ARAŞTIRMA MAKALESİ/RESEARCH ARTICLE

Geliş Tarihi(Receive Date): 17.04.2023

Kabul Tarihi(Accepted Date): 09.06.2023

## Anemi hastalığının yapay sinir ağları yöntemleri kullanılarak sınıflandırılması

Nagihan YAĞMUR<sup>1,\*</sup>, Hasan TEMURTAŞ<sup>2</sup>, İdiris DAĞ<sup>3</sup>

<sup>1</sup> Eskişehir Osmangazi Üniversitesi, Mühendislik Mimarlık Fakültesi, Eskişehir, ORCID : 0000-0002-6407-4338

<sup>2</sup> Kütahya Dumlupınar Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, Kütahya, ORCID: 0000-0001-6738-3024

<sup>3</sup> Eskişehir Osmangazi Üniversitesi, Mühendislik Mimarlık Fakültesi, Eskişehir, ORCID: 0000-0002-2056-4968

### Öz

Hemoglobün deęerinin belirli bir referans aralıęının altına düşmesiyle ortaya çıkan ve aynı zamanda kansızlık olarak adlandırılan anemi, teşhis ve tedavisi için birçok kan testine, radyolojik görüntülere, tahlillere ihtiyaç duyar. Bu gibi çok fazla üretilen tıbbi verilerin yanında hastalık teşhisinin konulmasında doktor kararı gereklidir. Hastalardan alınan tıbbi veriler işlenerek yeni hasta bireyler için hastalıkların tahminleri yapılabilir ve bu tahminlerle doktorlar için karar destek mekanizmaları kurulabilmektedir. Doktorların hastalar için koyacağı teşhisteki yanılma payını azaltma konusunda oldukça önemli olan bu yöntemler sayesinde sağlık kurumlarındaki veri kayıtlarının deęerlendirilmesi hasta ve hastaneler için de önem arz etmektedir. Literatürde anemi hastalığı sınıflandırma problemi için çeşitli yöntemler kullanılmış olup, veri setlerindeki hasta kayıt sayılarının deęişiklik göstermesi, kan parametrelerin sayısının ve özelliklerinin farklı olması gibi durumlardan dolayı önerilen algoritmaların performansları veri setlerine göre deęişiklik göstermektedir. Bu çalışmada Kaggle veri tabanından alınan anemi veri seti üzerinde kandaki verilere dayalı olarak anemi hastalığı sınıflandırması problemini çözmek amacıyla Yapay Sinir Ağları (YSA) yöntemleri kullanılmıştır. Öğrenmeli Vektör Kuantalama (LVQ), Rekabetçi Katman Sinir Ağı (CLNN), Örüntü Tanıma Yapay Sinir Ağı (PRNN), Kendiliğinden Organize Olan Harita (SOM) yapay sinir ağı yöntemleri kullanılarak başarı oranları hesaplanmıştır. Elde edilen sonuçların doğruluk deęerleri ve karışıklık matrisleri verilerek önerilen dört yöntem karşılaştırılmıştır. En iyi başarı performansı %100 hassasiyet ve %99,88 doğruluk, %99,86 özgüllük, %99,43 kesinlik ile PRNN olduğu, onu takiben LVQ olduğu sonucuna ulaşılmıştır.

*Anahtar Kelimeler:* Anemi sınıflandırma, Öğrenmeli Vektör Kuantalama, Rekabetçi Katman Sinir Ağı, Örüntü Tanıma Yapay Sinir Ağı, Kendiliğinden Organize Olan Harita

# Classification of anemia disease using artificial neural networks methods

## Abstract

Anemia, which occurs when the hemoglobin value falls below a certain reference range and is also called anemia, needs many blood tests, radiological images and analyzes for its diagnosis and treatment. In addition to such a large amount of produced medical data, a doctor's decision is required in diagnosing the disease. By processing the medical data taken from the patients, predictions of diseases can be made for new patients and decision support mechanisms can be established for doctors with these predictions. Thanks to these methods, which are very important in reducing the margin of error in the diagnosis of doctors for patients, the evaluation of data records in health institutions is also important for patients and hospitals. Various methods have been used for the classification problem of anemia disease in the literature, and the performance of the proposed algorithms varies according to the datasets due to the changes in the number of patient records in the datasets, the number and characteristics of the blood parameters. In this study, Artificial Neural Networks (ANN) methods were used to solve the anemia disease classification problem based on blood data on the anemia dataset taken from the Kaggle database. Performance rates were calculated using the Learning Vector Quantization (LVQ), Competitive Layer Neural Network (CLNN), Pattern Recognition Artificial Neural Network (PRNN), Self-Organizing Map (SOM) methods. The four proposed methods were compared by giving the accuracy values and confusion matrix values of the obtained results. It was concluded that the best success performance was PRNN with 100% sensitivity and 99.88% accuracy, 99.86% specificity, 99.43% precision, followed by LVQ.

*Keywords: Anemia classification, Learning Vector Quantization, Competitive Layer Neural Network, Pattern Recognition Artificial Neural Network, Self-Organizing Map*

*Corresponding Authors:*

*e-mail: nagihan.yagmur@dpu.edu.tr*

© 2023 DPU All rights reserved.

## 1. Giriş

Anemi hastalığı, insan sağlığını etkileyen küresel bir sağlık sorunudur [1]. Özellikle küçük çocukları ve hamile bireyleri etkilemektedir. Dünya Sağlık Örgütü'nün tahminine göre, dünya çapında 5 yaşından küçük çocukların %42' si ve hamile kadınların %40' ı anemiktir [2]. Kansızlığın bu şekilde yaygın olması nedeniyle bu çalışmada anemi hastalığı sınıflandırması üzerine çalışılmıştır. Anemi kan testleri ile teşhisin yapılabilmesi için kan tahlillerinin, radyolojik görüntülerin vb. doktor tarafından gözlenmesi gerekmektedir. Fakat bu süreçler, özellikle gelişmemiş ülkelerde zor ve maliyetli olabilir [3].

Hastalıklar, hastalıkları erken dönemde tespit etmek, hastaya uygun ilaçları reçete etmek ve başlangıç aşamasını kısa keserek kritik aşamaya gelmemek gibi alternatif çözümlerin üretildiği birçok tıbbi veri üretir. Hastalardan elde edilen bu tıbbi veriler kullanılarak yeni hastalar için hastalık tespiti yapılabilir. Bu durum da hekimlerin hasta için yapacakları tanıdaki hata payını en aza indirmesi ve tanı koymasına yardımcı olması açısından önemlidir. Bu sebeple de, sağlık kurumlarındaki veri kayıtlarının değerlendirilmesi hastalar ve hastaneler için oldukça büyük önem arz etmektedir.

Sağlık biliminde önemli bir yere sahip olan veri madenciliğine dayalı işlemler; çok sayıdaki verileri değerlendirerek yararlı verilere dönüştürme konusunda önemlidir. Dünya sağlık örgütü, bu işlemlerin çeşitli hastalıkların tahmininde önemli bir yerinin olduğunu belirtmiştir [4]. Veri madenciliği yöntemlerinin kullanıldığı tıp alanındaki uygulamalardan biri hastalık teşhisidir. Kanser, obezite, diyabet, tiroid, kalp hastalığı gibi hastalıklar veri madenciliği yöntemlerinin oldukça çok kullanılarak tahmin üretildiği hastalıklardır [5, 6, 7, 8, 9]. Meme kanseri hücrelerinin tahmin edilmesi için yapılan çalışmada C4.5 ve karar ağaçları kullanılmış ve C4.5 karar ağacının hastalık tanı ve teşhisinde %97.4359 doğruluk başarısı verdiği gözlemlenmiştir [6]. Kalp hastalığı teşhisi için yapılan bir çalışmada ZeroR, OneR, Naïve Bayes (NB), J48 Karar Ağacı, Rastgele Orman(RF), Çoklu Algılayıcılar,

k-NN, Lojistik Regresyon (LR), Destek Vektör Makinaları (SVM) gibi sınıflandırma algoritmaları kullanılmıştır [7]. Bu hastalıkların teşhisinde çeşitli yöntemlerin tekil kullanımının yanında hibrit yöntemleri de kullanılmaktadır [10, 11, 12, 13].

Literatürde anemi sınıflandırma probleminde kullanılan birçok veri madenciliği yöntemi mevcuttur. Bu yöntemler k-En Yakın Komşuluk (k-NN), Lojistik Regresyon, Bulanık Mantık (FL), Vektör Nicleme Sinir Ağı (LVQ) vb.dir Çalışmalarda kullanılan bu yöntemler, farklı veri kümelerindeki farklı özellikler nedeniyle iyi performans göstermeyebilir. Veri setlerindeki farklı parametre özellikleri ve sayısı, hasta kayıt sayısı değişikliği gibi farklılıklar anemi hastalığı sınıflandırma yöntemlerinin başarısını önemli ölçüde etkilemektedir. Bu nedenle de çalışılan veri setlerinin özellikleri ve parametre sayıları farklı olabileceğinden yeni tekniklerin geliştirilmesi önemlidir [14].

Yapay sinir ağları; görüntü işleme, makine öğrenimi, doğal dil işleme, biyomedikal vb. alanlarda farklı parametre ve yapılaraya sahip verileri sınıflandırmak için başarıyla kullanılmıştır [15, 16, 17]. Sağlık alanında yapılan çalışmalarda yapay sinir ağları yöntemlerinin yüksek başarı gösterdiği görülmüştür [18, 19].

Bu çalışmada Kaggle veri tabanından alınan 1732 kan verisi, dört farklı yapay sinir ağı yöntemi kullanılarak incelenmiştir. Önerilen yöntemler LVQ, CLNN, PRNN ve SOM yöntemleri ile analiz edilerek veri seti anemili / sağlıklı birey olmak üzere ikili sınıflandırmaya tabii tutulmuştur. Bu çalışmanın özgün değeri çoklu Kaggle veri tabanından alınan anemi hastalığı veri setine LVQ, CLNN, PRNN ve SOM yöntemleri ile çözüm ve sonuçların karşılaştırması ilk defa yapılmıştır. Önerilen dört algoritmanın performansı anemi teşhis etmek için karşılaştırılmıştır ve ayrıca literatürde mevcut olan önceki çalışmalardan daha iyi bulunmuştur. Makalenin bir diğer amacı da önerilen dört yöntemden aneminin sınıflandırılmasında elde edilen sonuçların karşılaştırılmasıdır. Literatürde anemi hastalığı sınıflandırması ile ilgili bazı çalışmalar aşağıda sunulmuştur.

2012 yılında yapılan bir çalışmada LVQ, İleri Beslemeli Ağlar (FFN), Dağıtılmış Gecikme Ağları (DDN), Zaman Gecikmeli Ağlar (TDN), Basamaklı İleri Ağlar (CFN), Olasılıklı Sinir Ağı (PNN) gibi sinir ağı çeşitleri kullanılarak kadınlarda demir eksikliği anemisi tahmini üzerinde çalışılmıştır [3]. En yüksek başarı %99.33 doğrulukla LVQ ile sınıflandırmada olduğu sonucuna varılmıştır. YSA yardımıyla talasemi (akdeniz anemisi) hastalığının tespiti için yapılan bir çalışmada 10 farklı talasemi hastalığının sınıflandırılması için yapılan testler sonucunda ortalama %90 başarı performans elde edilmiştir [20]. Başka bir çalışmada kan merkezlerinden toplanan verilerle anemi tahmini için denetimli makine öğrenme algoritmalarından NB, RF ve Karar ağaçları (DT) kullanılmıştır [21]. Sonuç olarak NB'nin daha iyi performans gösterdiği gözlemlenmiştir. 2019 yılında yapılan başka bir çalışmada Bangladeş'te özellikle beş yaş altı çocuklar için ciddi bir halk sağlığı sorunu olan anemi hastalığını tahmin etmek için makine öğrenmesi algoritmalarından Doğrusal Diskriminant Analizi (LDA), Sınıflandırma ve Regresyon Ağaçları (CART), SVM, RF, Lineer Regresyon kullanılmıştır [22]. Çalışma sonucunda RF algoritmasının en iyi sınıflandırma doğruluğuna ulaştığını, k-NN'in en düşük doğruluğu verdiği görülmüştür. 2019 yılında yapılan başka bir çalışmada ise kan parametrelerine dayalı anemi sınıflandırması için yeni bir makine öğrenimi yöntemi (HEAC - Hemoglobin Tahmini ve Anemi Sınıflandırması) önerilmiş olup, literatürdeki diğer makine öğrenmesi metodlarıyla karşılaştırılmıştır [23]. Sonuçta önerilen yöntemin daha iyi performans gösterdiği kaydedilmiştir. 2020 yılında SVM, Ekstrem Öğrenme Makinesi (ELM), k-NN ve Düzenleştirilmiş Ekstrem Öğrenme Algoritmaları (RELM) gibi algoritmaların kullanıldığı çalışmada HGB, RBC, HCT, MCV, MCH, RDW ve MCHC gibi kan parametreleri kullanılarak beta-talasemi ile demir eksikliği anemisi hastalıklarının tanısı için karar destek sistemleri geliştirilmiş olup %95.59 oranında başarı elde edilmiştir [24]. Dört laboratuvar sonuçlarının (MCV, MCH, MCHC, RBC) temel alınarak geliştirildiği kandaki demir eksikliğinin tahmin edildiği bir çalışmada ANN ve uyarlanabilir bir nöro-bulanık çıkarım sistemi (ANFIS) kullanılmıştır [25]. Sonuç olarak ANN ile %96.29 ile en iyi performans elde edilmiştir. PNN, FFN, Gini algoritması, Klone seçim algoritması kullanılarak demir eksikliği anemisi sınıflandırma probleminde %98.73 başarı elde edilmiştir [26]. Başka bir çalışmada demir eksikliği anemisi için HGB, RBC, MCV, HCT kan değerleri kullanılarak çıkış olarak Anemi (+) ve Anemi (-) değerlendirmesi yapılmıştır [27]. Değerlendirmeler için ANN, CDTA, k-NN yöntemleri kullanılmış ve en yüksek başarı ANN ile %78.31 oranı ile elde edilmiştir. 2021 yılında yapılan bir doktora tezinde geliştirilen bir yapay zeka mimarisi ile 12 farklı anemi tipine teşhis koyma çalışması yapılmıştır. Tezde YSA, SVM, NB ve DT yöntemleri kullanılmıştır. Çalışma sonucunda, anemi türlerinin teşhis edilmesinde DT yöntemlerinin daha anlamlı

ve dengeli sonuçlar verdiği ortaya konulmuştur [28]. 2023 yılında yapılan bir çalışmada YSA kullanarak kan örneği görüntülerinden kaydedilen renk bilgileri kullanarak hemoglobin değerleri tahmin edilmiştir [29]. Yapılan başka bir çalışmada da anemiye tespit etmek için RF, SVM ve diğer makine öğrenme teknikleri kullanılmıştır. Böyle anemi tespit etme süreci otomatikleştirilmeye çalışılmıştır [30]. 2023 yılında yapılan başka bir çalışmada ise avuç içi görüntüleri toplanarak CNN, k-NN, SVM, Naïve Bayes ve Karar ağaçları kullanılarak anemi saptama çalışması yapılmıştır [31].


Çalışmanın bölümleri şu şekilde sıralanabilir: İkinci bölümde önerilen yöntemler hakkında bilgiler verilmiş, üçüncü bölümde önerilen yöntemlerin deneysel çalışmaları sunulmuştur. Dördüncü bölümde yöntemlerin başarı karşılaştırması yapılmış ve sonuçlar vurgulanmıştır.

## 2. Materyal ve Yöntem

### 2.1. Veriseti ve Ön İşleme

Yapılan çalışmada Kaggle veri tabanından alınan 1732 adet hastaya ait kan verisi kullanılmıştır. Veri seti, 351 adet anemi hastası ve 1381 adet anemi hastası olmayan vakalardan oluşmaktadır. Her bir hasta verisinin kandaki kırmızı kan hücresi ya da alyuvar miktarı olan RBC değeri, kırmızı kan hücrelerinde depo edilen demir açısından zengin protein miktarını gösteren hemoglobin miktarı yani HBG değeri, kırmızı kan hücrelerindeki kanın hacimsel miktarı olan HCT değeri, ortalama hücre hacmi olan MCV değeri, belirli bir hacimde bulunan hemoglobin miktarının kırmızı kan hücrelerine oranı olan MCH değeri, tek bir kırmızı kan hücresinin içindeki ortalama hemoglobin miktarı olan MCHC değeri alınarak 6 farklı kan bileşeni ve buna karşılık anemi sonuç bilgisi yer almaktadır.

Şekil 1’de bu çalışmada kullanılan yapının şeması gösterilmiştir.



Şekil 1. Çalışmada kullanılan yapının şemasal gösterimi.

Çizelge 1’de verilerin maksimum ve minimum değerleri gösterilmiştir. Daha tutarlı sonuçlar elde edebilme amacıyla verilerin ön işlenmesi aşamasında kan değerleri 0.1 ile 0.9 arasına çekilerek normalizasyon işlemi yapılmıştır. Verilerin sınıflandırılması için Şekil 1’de görüldüğü gibi LVQ, CLNN, SOM, PRNN yöntemleri kullanılmıştır.

**Çizelge 1.** Veri setindeki özneliklerin listesi.

Özellik Adı	Minimum	Maksimum	Ortalama
<b>HGB</b>	2	13.100	4.484
<b>RBC</b>	3.600	16.700	12.453
<b>MCH</b>	15.700	52.110	38.003
<b>WBC</b>	2.900	116	84.907
<b>MCHC</b>	13.6	39.54	27.884
<b>HCT</b>	22.9	43.7	32.713

## 2.2. Rekabetçi Katman Sinir Ağı

Bir grup nöronun aktif olma hakkı için rekabet ettiği bir sinir ağına rekabetçi sinir ağı denir [32]. Ekstrem durum olarak, eğer birden fazla nöron aktif olma hakkı elde etmişse, en büyük girdiye sahip düğümün aktivasyonu 1’e, diğer tüm düğümlerin aktivasyonu 0’a eşit olarak ayarlanır [33]. Bu durum “kazanan hepsini alır” mantığı olarak bilinir. Rekabetçi katmandaki nöronlar, genellikle girdi vektörlerini tanımak için kendilerini dağıtırlar [33]. Rekabetçi ağların nöronları, benzer girdi vektörlerinin gruplarını tanımayı öğrenir. Kazanan nöronun ağırlıkları Kohonen öğrenme kuralı ile ayarlanır [34]. Kohonen katmanındaki çıkış düğümleri ile ilişkili olarak bir ağırlık vektörü değerleri vardır. Rekabetçi ağların nöronları, benzer girdi vektörlerinin gruplarını tanımayı öğrenir. Çıktı sıfıra (kazanan nöron) eşit değilse, belirli bir nöron için ağırlık vektörü (w) değiştirilir. Böylece ağırlık vektörü giriş vektörüne daha yakın olan nöron daha da yakın olacak şekilde güncellenir [35]. Sonuç olarak, kazanan nöronun bir daha benzer bir vektör sunulduğunda rekabeti kazanma olasılığı daha yüksektir ve çok farklı bir girdi vektörü sunulduğunda kazanma olasılığı daha düşüktür [35].

## 2.3. Kendiliğinden Organize Olan Harita

Girdi alanının düşük boyutlu (genel olarak iki boyutlu), ayrıklaştırılmış bir temsilini üretmek için denetimsiz öğrenme kullanılarak eğitilen bir tür yapay sinir ağıdır. SOM ağları, 1981 yılında Teuvo Kohonen tarafından geliştirilmiş olup veri setindeki elemanları hem haritalandırır hem de kümelendirir [35, 36]. SOM ağlarının amacı çok boyutlu bir veriyi iki boyutlu bir haritaya indirgemektir [36]. Veri setindeki değişken sayısı giriş nöronlarının sayısını belirleyen SOM ağları, giriş ve çıkış nöronlarından oluşmaktadır. Giriş nöronları düğümlere ağırlık katsayısı ile bağlıdır. Çıktıdaki düğüm sayısı tercihe bağlı seçilir [35]. Çalışma kapsamında SOM analizi için Neural Network Toolbox Self Organizing Map aracı kullanılarak yapılmıştır.

## 2.4. Örüntü Tanıma Yapay Sinir Ağı

Örüntü tanıma, ham verileri alan ve desenin kategorisine göre bir eylem yapan bir süreçtir. Belirli koşullara dayalı olarak en uygun şekilde kalıpları çıkarır ve bir sınıfı diğerinden ayırır. Örüntü tanıma ağları, girdileri hedef sınıflara göre sınıflandırmak için eğitilebilen ileri beslemeli, örüntü tanıma tabanlı ağlardır. PRNN için hedef veriler, temsil edecekleri sınıf olan  $i$  ögesindeki 1 hariç tüm sıfır değerlerinin vektörlerinden oluşur [37].

## 2.5. Öğrenmeli Vektör Kuantalama Yapay Sinir Ağı

Temel prensibi belirli sayıda vektör kullanarak bir vektörü temsil etmek olup Kohonen tarafından geliştirilmiştir [34]. SOM ağlarının bir çeşididir. Bir LVQ ağı, birinci rekabetçi katmana ve ikinci bir doğrusal katmana sahiptir [38]. “Kazanan her şeyi alır” prensibinden yola çıkarak geliştirilen LVQ modelini temel felsefesi, girişleri referans vektör olarak ifade etmektir [38]. LVQ ağı; giriş katmanı, Kohonen katmanı ve çıkış katmanı olmak üzere üç katmandan oluşur [39]. Giriş katmanında veriler ağa sunulurken, Kohonen katmanında referans vektörleri bulunur ve bu katmanda gelen veriler komşulukluklarına göre yarışırılır. Çıkış katmanında ise en yakın nöronun sınıf bilgisi yer almaktadır.

### 3. Deneysel Çalışma

Çalışmada anemi ve anemi olmayan/sağlıklı bireyler olarak iki sınıf ifade edilmiştir. Test ve eğitim aşamasında tüm veri seti kullanılmıştır. Çalışmada Intel Core i5 11400 F 2.6 GHz işlemci ve 16 GB DDR4 belleğe sahip bir sistem üzerinde uygulama gerçekleştirilmiştir. Çalışma kapsamında LVQ, PRNN, CLNN ve SOM kullanılarak anemi veri seti üzerinde tahmin çalışması yapılmıştır. 4 farklı algoritmanın performansını kıyaslamak için ROC analizi ölçütü kullanılmıştır. ROC analizi, çeşitli yöntemler ile elde edilen sonuçların performansını karşılaştırmak amacıyla, sonuçların Accuracy (doğruluk), Sensitivity (duyarlılık), Specificity (özgüllük), Precision (kesinlik), F1 skor olarak değerlendirilebilmesini sağlayan bir yöntemdir [40]. Veri madenciliği uygulamalarında sıklıkla kullanılmaktadır [41].

ROC analizi için temel eşitlikler Eş. 1-5 ile gösterilmiştir.

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

$$\text{Sensitivity} = \frac{TP}{TP+FN} \quad (2)$$

$$\text{Specificity} = \frac{TN}{FP+TN} \quad (3)$$

$$\text{Precision} = \frac{TP}{TP+FP} \quad (4)$$

$$\text{F1 - Score} = \frac{2 \cdot \text{Precision} \cdot \text{Sensitivity}}{\text{Precision} + \text{Sensitivity}} \quad (5)$$

ROC değerleri içerisindeki doğruluk değeri Eş. 1 ile, duyarlılık değeri Eş. 2 ile, özgüllük değeri Eş. 3, kesinlik değeri Eş. 4, F1 Skor değeri Eş. 5 ile hesaplanmaktadır. Bu hesaplamalar ile elde edilen sonuçlar, 4 farklı yöntemle karşılaştırılmıştır. ROC analizinin amacı, çeşitli metodlar ile elde edilen sonuçların performansını karşılaştırabilmek için, sonuçların duyarlılık, özgüllük ve doğruluk olarak değerlendirilebilmesini sağlayan bir metottur [40]. Analizde kullanılan ROC parametreleri TP, TN, FP ve FN'dir. TP (True Positive); hasta olarak sınıflandırılmış bir hastanın, analiz sonucunda hasta olarak tespit edilmesiyken, TN (True Negative); sağlıklı olarak sınıflandırılmış bir kayıtn, analiz sonucunda hasta olarak tespit edilmesidir. FP (False Positive); sağlıklı olarak tespit edilen bir kayıtn analiz sonucu test sonuçlarının hasta olarak tespit edilmesiyken, FN (False Negative); hasta olarak tespit edilen kayıtn analiz sonucu test sonuçlarının sağlıklı olarak tespit edilmesidir.

ROC analizi için genel konfüzyon matrisi Çizelge 2'de görülmektedir.

**Çizelge 2.** ROC analiz konfüzyon matrisi.

	Tahmin Edilen	
	0	1
0		
1		

Gerçek	0	TN	FP
	1	FN	TP

Çalışmada kullanılan verisetinin ilk 10 hasta için örneği Çizelge 3'te verilmiştir. Çizelgelerde verilen S sıra, Ö öznitelik, M metot, T test değerlerinin kısaltılmış halidir. Çalışmada her bir yapay sınır ağı için 10 farklı test yapılarak her bir test için sonuçlar ve en iyi sonuçlar Çizelge 3-11'de listelenmiştir.

**Çizelge 3.** Veriseti kayıt örneği.

S	Ö						Sonuç
	RBC	HBG	HCT	MCV	MCH	MCHC	
1	4.98	8.8	31.6	63.52	17.72	27.82	1
2	4.83	10.9	35.9	74.32	22.62	30.42	1
3	4.34	11	34.7	80.02	25.32	31.7	0
4	4.03	11.1	34.9	86.6	27.5	31.8	1
5	3.71	11.1	34.3	92.5	29.9	32.4	0
6	4.37	11.2	35.8	81.92	25.62	31.3	0
7	4.2	12.2	34.4	81.9	29	35.5	0
8	3.62	10.8	33.3	92	29.8	32.4	1
9	4.34	7.72	26.6	61.32	17.72	28.92	1
10	4.05	10.1	32.5	80.22	24.92	31.1	1

**Çizelge 4.** CLNN Yöntemi için ROC Analiz Sonuçları.

T	M				Accuracy	Sensitivity	Specificity	Precision	F1
	TP	TN	FP	FN					
Test 1	291	1026	60	355	0.7604	0.4505	0.9448	0.8291	0.5838
Test 2	294	1028	57	353	0.7633	0.4544	0.9475	0.8376	0.5892
Test 3	298	997	53	384	0.7477	0.4370	0.9495	0.8490	0.5770
Test 4	295	998	56	383	0.7465	0.4351	0.9469	0.8405	0.5734
Test 5	297	999	54	382	0.7483	0.4374	0.9487	0.8462	0.5767
Test 6	299	983	52	398	0.7402	0.4290	0.9498	0.8519	0.5706
Test 7	304	920	47	461	0.7067	0.3974	0.9514	0.8661	0.5448
Test 8	293	1059	58	322	0.7806	0.4764	0.9481	0.8348	0.6066
Test 9	299	957	52	424	0.7252	0.4136	0.9485	0.8519	0.5568
Test 10	298	986	53	395	0.7413	0.4300	0.9490	0.8490	0.5709

Çizelge 4’te gösterildiği üzere CLNN yöntemi anemi hastalığı veriseti üzerinde 10 kere çalıştırılmıştır. Her test sonucunda TP, TN, FP, FN, Accuracy, Sensitivity, Specificity, Precision, F1-Score değerleri hesaplanmıştır. Bu hesaplamalara göre CLNN yöntemi için ortalama ve en iyi sonuç değerleri Çizelge 5’te verilmiştir.

**Çizelge 5.** CLNN yöntemi için ortalama ve en iyi sonuç.

<b>M</b> <b>T</b>	<b>Accuracy</b>	<b>Sensitivity</b>	<b>Specificity</b>	<b>Precision</b>	<b>F1</b>
<b>Ortalama</b>	0.7460	0.4361	0.9484	0.8456	0.5750
<b>En iyi</b> <b>(8.Test)</b>	0.7806	0.4764	0.9481	0.8348	0.6066

**Çizelge 6.** SOM yöntemi için ROC analiz sonuçları.

<b>M</b> <b>T</b>	<b>TP</b>	<b>TN</b>	<b>FP</b>	<b>FN</b>	<b>Accuracy</b>	<b>Sensitivity</b>	<b>Specificity</b>	<b>Precision</b>	<b>F1</b>
<b>Test 1</b>	241	1232	110	149	0.8505	0.6179	0.9180	0.6866	0.6505
<b>Test 2</b>	236	1248	115	133	0.8568	0.6396	0.9156	0.6724	0.6556
<b>Test 3</b>	235	1250	116	131	0.8574	0.6421	0.9151	0.6695	0.6555
<b>Test 4</b>	240	1240	111	141	0.8545	0.6299	0.9178	0.6838	0.6557
<b>Test 5</b>	236	1248	115	133	0.8568	0.6396	0.9156	0.6724	0.6556
<b>Test 6</b>	240	1241	111	140	0.8551	0.6316	0.9179	0.6838	0.6566
<b>Test 7</b>	232	1257	119	124	0.8597	0.6517	0.9135	0.6610	0.6563
<b>Test 8</b>	237	1246	114	135	0.8562	0.6371	0.9162	0.6752	0.6556
<b>Test 9</b>	234	1250	117	131	0.8568	0.6411	0.9144	0.6667	0.6536
<b>Test 10</b>	236	1248	115	133	0.8568	0.6396	0.9156	0.6724	0.6556

Çizelge 6’da gösterildiği üzere SOM yöntemi ile yapılan testler verilmiştir. Bu test sonucuna göre SOM yöntemi için ortalama ve en iyi sonuç değerleri Çizelge 7’de verilmiştir.

**Çizelge 7.** SOM yöntemi için ortalama ve en iyi sonuç.

<b>M</b> <b>T</b>	<b>Accuracy</b>	<b>Sensitivity</b>	<b>Specificity</b>	<b>Precision</b>	<b>F1</b>
<b>Ortalama</b>	0.8561	0.6370	0.9160	0.6744	0.6551
<b>En iyi</b> <b>(7.Test)</b>	0.8597	0.6517	0.9135	0.6610	0.6563



Çizelge 8. PRNN yöntemi için ROC analiz sonuçları.

<b>M</b> <b>T</b>	<b>TP</b>	<b>TN</b>	<b>FP</b>	<b>FN</b>	<b>Accuracy</b>	<b>Sensitivity</b>	<b>Specificity</b>	<b>Precision</b>	<b>F1</b>
<b>Test 1</b>	345	1380	6	1	0.9960	0.9971	0.9957	0.9829	0.9900
<b>Test 2</b>	347	1380	4	1	0.9971	0.9971	0.9971	0.9886	0.9928
<b>Test 3</b>	349	1381	2	0	0.9988	1	0.9986	0.9943	0.9971
<b>Test 4</b>	347	1380	4	1	0.9971	0.9971	0.9971	0.9886	0.9928
<b>Test 5</b>	347	1380	4	1	0.9971	0.9971	0.9971	0.9886	0.9928
<b>Test 6</b>	346	1380	5	1	0.9965	0.9971	0.9964	0.9858	0.9914
<b>Test 7</b>	346	1380	5	1	0.9965	0.9971	0.9964	0.9858	0.9914
<b>Test 8</b>	346	1380	5	1	0.9965	0.9971	0.9964	0.9858	0.9914
<b>Test 9</b>	347	1380	4	1	0.9971	0.9971	0.9971	0.9886	0.9928
<b>Test 10</b>	348	1380	3	1	0.9977	0.9971	0.9978	0.9915	0.9943

Çizelge 8’de gösterildiği üzere PRNN yöntemi anemi hastalığı veriseti üzerinde 10 kere çalıştırılmıştır. Her test sonucunda TP, TN, FP, FN, Accuracy, Sensitivity, Specificity, Precision, F1-Score değerleri hesaplanmıştır. Bu hesaplamalara göre PRNN yöntemi için ortalama ve en iyi sonuç değerleri Çizelge 9’da verilmiştir.

Çizelge 9. PRNN yöntemi için ortalama ve en iyi sonuç.

<b>M</b> <b>T</b>	<b>Accuracy</b>	<b>Sensitivity</b>	<b>Specificity</b>	<b>Precision</b>	<b>F1</b>
<b>Ortalama</b>	0.9970	0.9974	0.9970	0.9881	0.9927
<b>En iyi (3.Test)</b>	0.9988	1	0.9986	0.9943	0.9971

Çizelge 10. LVQ yöntemi için ROC analiz sonuçları.

<b>M</b> <b>T</b>	<b>TP</b>	<b>TN</b>	<b>FP</b>	<b>FN</b>	<b>Accuracy</b>	<b>Sensitivity</b>	<b>Specificity</b>	<b>Precision</b>	<b>F1</b>
<b>Test 1</b>	312	1354	39	27	0.9619	0.9204	0.9720	0.8889	0.9043
<b>Test 2</b>	316	1349	35	32	0.9613	0.9080	0.9747	0.9003	0.9041
<b>Test 3</b>	316	1354	35	27	0.9642	0.9213	0.9748	0.9003	0.9107
<b>Test 4</b>	313	1355	38	26	0.9630	0.9233	0.9727	0.8917	0.9072
<b>Test 5</b>	307	1349	44	32	0.9561	0.9056	0.9684	0.8746	0.8899
<b>Test 6</b>	314	1349	37	32	0.9602	0.9075	0.9773	0.8946	0.9010
<b>Test 7</b>	318	1357	33	24	0.9671	0.9298	0.9763	0.9060	0.9177
<b>Test 8</b>	313	1351	38	30	0.9607	0.9125	0.9726	0.8917	0.9020

<b>Test 9</b>	311	1352	40	29	0.9602	0.9147	0.9713	0.8860	0.9001
<b>Test 10</b>	303	1346	48	35	0.9521	0.8964	0.9656	0.8632	0.8795

Çizelge 10’da gösterildiği üzere LVQ yöntemi ile yapılan testler verilmiştir. Bu test sonucuna göre LVQ yöntemi için ortalama ve en iyi sonuç değerleri Çizelge 11’de verilmiştir.

**Çizelge 11.** LVQ yöntemi için ortalama ve en iyi sonuç.

<b>M</b> <b>T</b>	<b>Accuracy</b>	<b>Sensitivity</b>	<b>Specificity</b>	<b>Precision</b>	<b>F1</b>
<b>Ortalama</b>	0.9607	0.9140	0.9726	0.8897	0.9017
<b>En iyi</b> <b>(7.Test)</b>	0.9671	0.9298	0.9763	0.9060	0.9177

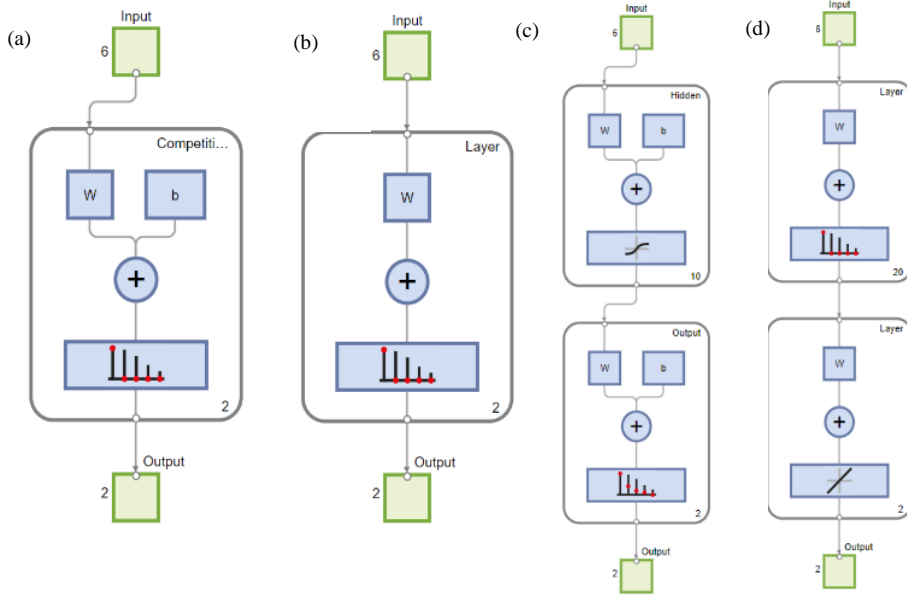
#### 4. Sonuçlar

Bu çalışma kapsamında Kaggle veri tabanından 1732 adet hastaya ait kan verisi alınarak anemi hastalığı tahmin problemi üzerinde çalışılmıştır. Her bir hasta verisinin RBC, HBG, HCT, MCV, MCH ve MCHC kan değerlerinden olmak üzere 6 farklı kan bileşeni ve buna karşılık anemi sonuç bilgisi yer aldığı veri tabanındaki bilgilerin sınıflandırılması için yapay sinir ağları yöntemlerinden LVQ, PRNN, CLNN ve SOM ağları kullanılmıştır. MATLAB Neural Network Toolbox arayüzü kullanılarak modelleme yapılmıştır [42].

Eğitim sürecinde kullanılan adımlar Çizelge 12’de listelenmiştir. Performans fonksiyonu olarak tüm yöntemler için Ortalama Kare Hatası (Mse) kullanılmıştır. Önerilen ağların iterasyonları, hızları, hata oraları, eğitim fonksiyonları ve uyarlamalı öğrenme fonksiyonu olarak kullanılan fonksiyonlar Çizelge 12’de sunulmuştur. Çalışmada Matlab Toolbox kullanıldığı için kullanılan fonksiyonlara müdahale edilmemiştir. Eğitim sürecinde tüm veriler kullanılmış, test sürecinde yine tüm veriler test edilmiştir. RBC, HGB, HCT, MCH, MCHC ve MCV değerlerine sahip 1732 hastadan alınan kan örneğinin kan analizi 6 giriş nöronu olarak kullanılmış ve sonuç verisi çıkış olarak sisteme girilmiştir. Önerilen yöntemlerin Network Diagram’ı Şekil 2’de verilmiştir.

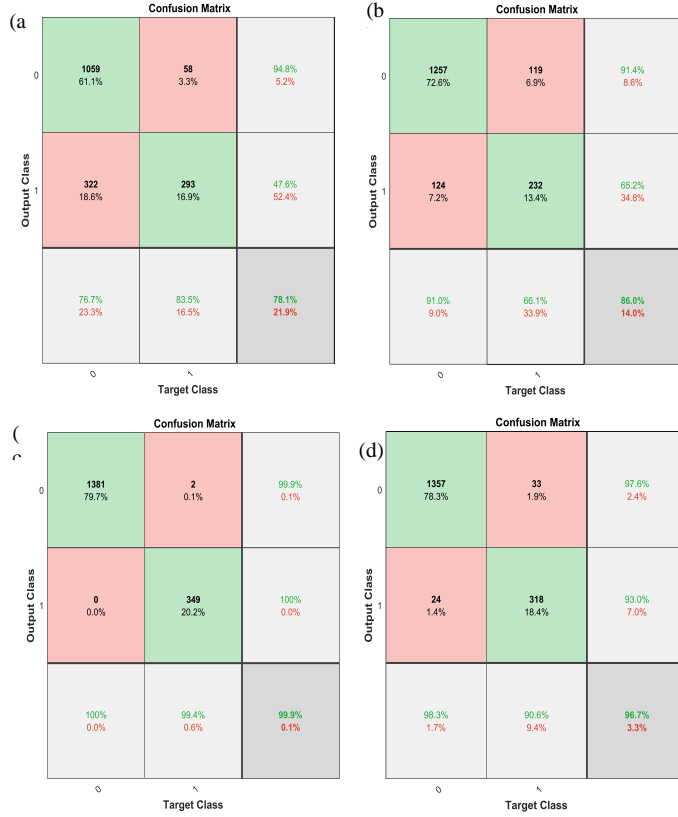
**Çizelge 12.** Ağ eğitiminin karşılaştırılması.

	<b>İterasyonlar</b>	<b>Zaman (sn)</b>	<b>Hata (mse)</b>	<b>Eğitim Fonksiyonu</b>	<b>Uyarlamalı Öğrenme Fonksiyonları</b>
<b>CLNN</b>	1000	264	Eğitim Yok	Trainr (Random Weight/Bias Rule)	adaptwb
<b>SOM</b>	200	0	Eğitim Yok	Trainbu (Batch Weight/Bias Rule)	adaptwb
<b>PRNN</b>	1000	2	0.005	Trainscg(Scaled Conjugate Gradient)	adaptwb
<b>LVQ</b>	1000	925	0.041	Trainr (Random Weight/Bias Rule)	adaptwb



**Şekil 2.** Önerilen yöntemlerin Network Diyagramları; (a) CLNN Network Diyagram, (b) SOM Network Diyagram, (c) PRNN Network Diyagram, (d) LVQ Network Diyagram.

Şekil 2’de görüldüğü üzere önerilen dört yöntemin diyagramları açıklanmak istenirse; Şekil 2(a) ve (b)’da verilen CLNN ve SOM ağının diyagramında transfer fonksiyonu olarak ‘compet’ kullanılmıştır. Şekil 2(c) PRNN ağının diyagramı 1 gizli katman ve 1 çıkış katmanı olarak oluşturulmuştur. Gizli katmanda transfer fonksiyonu ‘tansig’, çıkış katmanında ‘softmax’ kullanılmıştır. Şekil 2(d) LVQ ağının diyagramı 2 katmanla oluşturulmuştur. 1. katmanda transfer fonksiyonu olarak ‘compet’, 2. katmanda ‘purelin’ kullanılmıştır.



**Şekil 3.** Dört yöntem için en iyi sonuç veren testlerin konfüzyon matrisi; (a) CLNN konfüzyon matrisi, (b) SOM konfüzyon matrisi, (c) PRNN konfüzyon matrisi, (d) LVQ konfüzyon matrisi

**Çizelge 13.** Tüm yöntemler için en iyi sonuç.

Yöntem	En iyi Accuracy	En iyi Sensitivity	En iyi Specificity	En iyi Precision	En iyi F1-Skor
CLNN	0.7806	0.4764	0.9481	0.8348	0.6066
SOM	0.8597	0.6517	0.9135	0.6610	0.6563
PRNN	0.9988	1	0.9986	0.9943	0.9971
LVQ	0.9671	0.9298	0.9763	0.9060	0.9177

Şekil 3(a)'da CLNN ağı için yapılan 10 test sonucunda için en iyi sonucu veren 8.testin, Şekil 3(b)'de SOM için en iyi sonucu veren 7.testin, PRNN için en iyi sonucu veren 3.testin ve LVQ için en iyi sonucu veren 1.testin konfüzyon matrisleri verilmiştir. Çizelge 13'te tüm yöntemlerin en iyi sonuçları tek bir çizelgede gösterilmiştir.

Matrisler ve sonuçlar karşılaştırıldığında PRNN test işlemi sonucunda %100 hassasiyet ve %99,88 doğruluk, %99,86 özgüllük, %99,43 kesinlik ile anemi hastalığı tespit etmede iyi bir performans gösterdiği sonucuna ulaşılmıştır. Çizelge 14’te literatür taraması yapıldığı kadarıyla veri seti benzerliği gösteren diğer çalışmaların doğruluk performansları listelenmiştir. Çizelgede yer alan sonuçlara göre önerdiğimiz yöntem ile tıbbi veri sınıflandırmasının çok yüksek doğrulukla mümkün olduğu gösterilmiştir. PRNN’yi takiben doğruluk başarısının %96,71 ile LVQ, %85,97 ile SOM, %78,06 ile CLNN olduğu sonucuna varılmıştır. Sonuçlar değerlendirildiğinde LVQ, PRNN, CLNN ve SOM kullanılarak yapılan tahmin sürecinde 351’i anemili ve 1381’i anemisiz olmak üzere toplam 1732 vakada 6 farklı kan bileşeni kullanılarak hedeflenen çıktıları başarıyla ulaşılmıştır. Bilindiği kadarıyla bu çalışma ile Kaggle veritabanından alınan anemi hastalığı veri setine LVQ, CLNN, PRNN ve SOM yöntemleri ile çözüm ve çözümlerin karşılaştırması ilk defa yapılmıştır. Böylece bir hasta kaydının anemi olup olmadığının doğru bir şekilde teşhis edilmesi ve hekimlerin karar vermesine yardımcı olacak bir karar destek sistemi geliştirilmiştir. Bu sunulan algoritmalar için hastanın kanından alınan yaş, cinsiyet, kilo ve farklı bileşenler gibi ekstra parametreler eklenerek aneminin en iyi sınıflandırması bulunabilir. Bundan sonraki hedefimiz ise, Türkiye’deki bir hastaneden daha fazla parametreyi içeren yeni veri seti alınarak anemi tiplerini belirlemektir.

**Çizelge 14.** Çalışmamıza benzer ilgili çalışmalar.

Parametre	Yöntem	Kaynak	Accuracy
HGB, RBC, MCH, WBC, MCHC, HCT	FFN, CFN, DDN, TDN, LVQ, PNN	[3]	%99.33
MCV, RBC HGB, HCT, MCHC MCH, RDW	k-NN, LR, SVM, Ekstrem Öğrenme Makinesi ve Düzenli Ekstrem Öğrenme Makinesi	[24]	%95.59
MCV MCH, MCHC, HGB, RBC	ANN ve uyarlanabilir bir nöro-bulanık çıkarım sistemi (ANFIS)	[25]	%96.29
MCH, MCHT, MCV, RBC HGB, HCT	PNN, FFN, Gini algoritması, Klon seçim algoritması	[26]	%98.73
HGB, RBC MCV, HCT	ANN, CDTA k-NN,	[27]	%78.31
HGB, HCT, MCH, MCV	RF, Naïve Bayes ve CDTA	[21]	%96.09
<b>Önerdiğimiz Yöntemler için Sonuçlar</b>			
Parametre	Yöntem		Accuracy
HGB, RBC, MCH, WBC, MCHC, HCT	CLNN		%78.06
	SOM		%85.97
	PRNN		%99.88
	LVQ		%89.67

### Teşekkür

Yazarların özellikle teşekkür edecekleri kimse bulunmamaktadır.

## Kaynakça

- [1] Baldi, A., Pasricha, S. R. (2022). Anaemia: Worldwide Prevalence and Progress in Reduction, Nutritional Anemia. Springer International Publishing, 3-17.
- [2] World Health Organization (WHO), [https://www.who.int/healthtopics/anaemia#tab=tab\\_1](https://www.who.int/healthtopics/anaemia#tab=tab_1)
- [3] Yılmaz, Z., Bozkurt, M. R. (2012). Determination of women iron deficiency anemia using neural networks. Journal of medical systems, 36, 2941-2945.
- [4] Vijayarani, S., Sudha, S. (2013). Disease prediction in data mining technique—a survey. International Journal of Computer Applications & Information Technology, 2(1), 17-21.
- [5] Dörterler, S. (2023). Kanser Hastalığı Teşhisinde Ölüm Oyunu Optimizasyon Algoritmasının Etkisi. Mühendislik Alanında Uluslararası Araştırmalar VIII, 15.
- [6] Danacı, M., Çelik, M., Akkaya, A. E. (2010). Veri madenciliği yöntemleri kullanılarak meme kanseri hücrelerinin tahmin ve teşhisi. Akıllı Sistemlerde Yenilikler ve Uygulama Sempozyumu, 21(24), 9-12.
- [7] Taşçı, M. E., Şamlı, R. (2020). Veri madenciliği ile kalp hastalığı teşhisi. Avrupa Bilim ve Teknoloji Dergisi, 88-95.
- [8] Başer, B. Ö., Yangın, M., Sarıdaş, E. S. (2021). Makine öğrenmesi teknikleriyle diyabet hastalığının sınıflandırılması. Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Dergisi, 25(1), 112-120.
- [9] Akgül, G., Çelik, A. A., Aydın, Z. E., Öztürk, Z. K. (2020). Hipotiroidi Hastalığı Teşhisinde Sınıflandırma Algoritmalarının Kullanımı. Bilişim Teknolojileri Dergisi, 13(3), 255-268.
- [10] Yeh, W. C., Chang, W. W., Chung, Y. Y. (2009). A new hybrid approach for mining breast cancer pattern using discrete particle swarm optimization and statistical method. Expert Systems with Applications, 36(4), 8204-8211.
- [11] Devi, R. D. H., Bai, A., Nagarajan, N. (2020). A novel hybrid approach for diagnosing diabetes mellitus using farthest first and support vector machine algorithms. Obesity Medicine, 17, 100152.
- [12] Dörterler, S. (2022). Hybridization of k-means and meta-heuristics algorithms for heart disease diagnosis. NEW TRENDS IN ENGINEERING AND APPLIED NATURAL SCIENCES, 55.
- [13] Dörterler, S., Dumlu, H., Özdemir, D., & Temurtaş, H. (2022). Melezlenmiş K-means ve Diferansiyel Gelişim Algoritmaları ile Kalp Hastalığının Teşhisi. In International Conference on Engineering and Applied Natural Sciences, 1840-1844.
- [14] Kilicarslan, S., Celik, M., Sahin, Ş. (2021). Hybrid models based on genetic algorithm and deep learning algorithms for nutritional Anemia disease classification. Biomedical Signal Processing and Control, 63, 102231.
- [15] Ergezer, H., Dikmen, M., Özdemir, E. (2003). Yapay sinir ağları ve tanıma sistemleri. PiVOLKA, 2(6), 14-17.
- [16] Uğur, A., Kınacı, A. C. (2006). Yapay zeka teknikleri ve yapay sinir ağları kullanılarak web sayfalarının sınıflandırılması. XI. Türkiye'de İnternet Konferansı (inet-tr'06), Ankara, 1(4).
- [17] Akgündoğdu, A. (2003). Bulanık-yapay sinir ağları ile biyomedikal görüntü işlenmesi, Yüksek Lisans Tezi, İstanbul Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.
- [18] Gil, D., Johnsson, M., Chamizo, JMG, Paya, AS, Fernandez, DR. (2009). Yapay sinir ağlarının ürolojik fonksiyon bozukluklarının teşhisinde uygulanması. Uygulamalı uzman sistemler, 36 (3), 5754-5760.
- [19] Gönül, Y., Ulu, Ş., Bucak, A., Bilir, A. (2015). Yapay sinir ağları ve klinik araştırmalarda kullanımı. Genel Tıp Dergisi, 25(3).
- [20] Wongseeree, W., Chaiyaratana, N., Vichittumaros, K., Winichagoon, P., Fucharoen, S. (2007). Thalassaemia classification by neural networks and genetic programming. Information Sciences, 177(3), 771-786.
- [21] Jaiswal, M., Srivastava, A., Siddiqui, T. J. (2019). Machine learning algorithms for anemia disease prediction. Recent Trends in Communication, Computing, and Electronics: Select Proceedings of IC3E 2018, Springer Singapore, 463-469.

- [22] Khan, J. R., Chowdhury, S., Islam, H., Raheem, E. (2021). Machine learning algorithms to predict the childhood anemia in Bangladesh. *Journal of Data Science*, 17(1), 195-218.
- [23] El-kenawy, E. S. M. T. (2019). A Machine Learning Model for Hemoglobin Estimation and Anemia Classification. *International Journal of Computer Science and Information Security (IJCSIS)*, 17(2), 100-108.
- [24] Çil B., Ayyıldız H., Tuncer T. (2020). Discrimination of  $\beta$ -thalassemia and iron deficiency anemia through e treme learning machine and regularized e treme learning machine-based decision support system. *Medical Hypotheses*, 138, 1- 6, DOI: <https://doi.org/10.1016/j.mehy.2020.109611>.
- [25] Azarkhish, I., Raoufy, M. R., & Gharibzadeh, S. (2012). Artificial intelligence models for predicting iron deficiency anemia and iron serum level based on accessible laboratory data. *Journal of medical systems*, 36, 2057-2061
- [26] Çarklı Yavuz, B., Karagül Yıldız, T., Yurtay, N., Pamuk, Z. (2014). Comparison Of K Nearest Neighbours And Regression Tree Classifiers Used With Clonal Selection Algorithm to Diagnose Haematological Diseases. *AJIT-e: Online Academic Journal of Information Technology*, 5(16).
- [27] İlaslaner, T., Güven, A. (2019). Demir Eksikliği Anemisinde Biyokimya Değerlerinin Etkisinin İncelenmesi. *Tıp Teknolojileri Kongresi*.
- [28] Karagül Yıldız, T. (2021). Hematolojik hastalıkların teşhisinde yapay zeka tekniklerinin performans karşılaştırması, Doktora Tezi, Sakarya Üniversitesi, Fen Bilimleri Enstitüsü
- [29] Ghosh, A., Mukherjee, J., Chakravorty, N. (2023). A Low-Cost Test for Anemia Using an Artificial Neural Network. *Computer Methods and Programs in Biomedicine*, 229, 107251.
- [30] Dixit, A., Jha, R., Mishra, R., & Vhatkar, S. (2023). Prediction of Anemia Disease Using Machine Learning Algorithms. In *Intelligent Computing and Networking: Proceedings of IC-ICN 2022*, Singapore: Springer Nature Singapore, 229-238.
- [31] Appiahene, P., Asare, J. W., Donkoh, E. T., Dimauro, G., & Maglietta, R. (2023). Detection of iron deficiency anemia by medical images: a comparative study of machine learning algorithms. *BioData Mining*, 16(1), 1-20.
- [32] Behnke, S., Karayiannis, N. B. (1988). Competitive neural trees for pattern classification. *IEEE Transactions on Neural Networks*, 9(6), 1352-1369.
- [33] Sowmya, B., & Rani, B. S. (2011). Colour image segmentation using fuzzy clustering techniques and competitive neural network. *Applied Soft Computing*, 11(3), 3170-3178.
- [34] Kohonen, T. (2012). *Self-organization and associative memory*. Springer Science & Business Media.
- [35] Turias, I. J., Gonzalez, F. J., Martín, M. L., Galindo, P. L. (2006). A competitive neural network approach for meteorological situation clustering. *Atmospheric Environment*, 40(3), 532-541.
- [36] Kalan, O. (2009). Lejyoner hastalığının istatistiksel risk analizi, Yüksek Lisans Tezi.
- [37] Al-Allaf, O. N. A., AbdAlKader, S. A., Tamimi, A. A. (2013). Pattern recognition neural network for improving the performance of iris recognition system. *Int'l Journal of Scientific & Engineering Research*, 4(6), 661-667.
- [38] Çetin, O., & Temurtaş, F. (2018). Öğrenmeli Vektör Kuantalama ile Beyin Bilgisayar Arayüzü Üzerine Bir Çalışma. *Sakarya University Journal of Computer and Information Sciences*, 1(2), 1-7.
- [39] Er, O., Yumusak, N., Temurtas, F. (2010). Chest diseases diagnosis using artificial neural networks. *Expert Systems with Applications*, 37(12), 7648-7655.
- [40] Obuchowski, N. A. (2005). ROC analysis. *American Journal of Roentgenology*, 184(2), 364-372.
- [41] Slaby, A. (2007). ROC analysis with Matlab. 2007 29th International Conference on Information Technology Interfaces, 191-196.
- [42] Matlab, S. (2012). *Matlab. The MathWorks*, Natick, MA.