

Kronik Böbrek Hastalığının Teşisi İçin Genetik Algoritma-Dalgacık Çekirdeği-Uç Öğrenme Makinesine Dayalı Uzman Bir Sistem

Derya AVCI^{1*}, Akif DOĞANTEKİN²

¹ Bilgisayar Teknolojileri Bölümü, Teknik Bilimler MYO, Fırat Üniversitesi, Elazığ, Türkiye

² Özel Gaziantep Emek Hastanesi, Gaziantep, Türkiye

*¹ davci@firat.edu.tr, ² akifdogantekin@gmail.com

(Geliş/Received: 05/07/2021;

Kabul/Accepted: 01/01/2022)

Öz: Böbrekler, sağlıklı bir yaşam sürdürebilmemiz için gerekli olan bir takım işlevleri yerine getirmektedir. Kronik Böbrek Hastalığı (KBH), böbreklerin görevini yerine getiremediği durumlarda ortaya çıkmaktadır. KBH verileri UCI makine öğrenimi veri tabanından alınmıştır. KBH veri seti 400 kişiye ait 24 farklı özelliğinden oluşmaktadır. Bu çalışmada, KBH tanısı için KBH verilerine Genetik Algoritma - Dalgacık Çekirdeği - Uç Öğrenme Makinesi (GA-DÇ-UÖM) yöntemi uygulanmıştır. Geliştirilen DÇ-UÖM sınıflandırıcısı, KBH verilerini sınıflandırmak için kullanılmıştır. GA, UÖM 'nin gizli katman nöron sayısı ve dalgacık çekirdeğinin k, l, m parametre değerlerini optimize etmek için kullanılmıştır. Ayrıca, DÇ-UÖM 'nin sınıflandırma performansını artırmak için GA uygulanmaktadır. 400*24 öznitelik vektörü, DÇ-UÖM sınıflandırıcısına girdi olarak verilmiştir. GA-DÇ-UÖM 'nin başarısı, sınıflandırma doğruluğu, duyarlılık ve özgüllük analizi kullanılarak hesaplanmıştır. Önerilen GA-DÇ-UÖM yönteminin sınıflandırma başarısı %98,42 olarak hesaplanmıştır. Dalgacık çekirdek fonksiyonunun k, l, m parametrelerinin optimum değerleri sırasıyla 5, 3 ve 12 olarak bulunmuştur. Gizli katman nöron sayısının optimum değeri 220 olarak bulunmuştur.

Anahtar kelimeler: Uç Öğrenme Makinesi, Dalgacık Çekirdeği, Genetik Algoritma, Kronik Böbrek Hastalığı, Tanı Sistemi.

An Expert System Based On Genetic Algorithm - Wavelet Kernel - Extreme Learning Machine For The Diagnosis of Chronic Kidney Disease

Abstract: The kidneys perform a number of functions that are necessary for us to maintain a healthy life. Chronic Kidney Disease (CKD) occurs when the kidneys can not perform their duty. The CKD data have been taken from the UCI machine learning database. The CKD data set comprise of 24 different properties of 400 individuals. In this study, Genetic Algorithm-Wavelet Kernel-Extreme Learning Machine (GA-WK-ELM) method is applied to CKD data for the diagnosis of CKD. Developed WK-ELM classifier has been used to classify CKD data. GA has been used to optimize the hidden layer neuron number of ELM and the k, l, m parameter values of Wavelet Kernel(WK). In addition, GA is applied to increase the classification performance of WK-ELM. The feature vector of 400 * 24 is given as input to the WK-ELM classifier. The success of GA-WK-ELM is calculated by using classification accuracy, sensitivity and specificity analysis. The classification success of the suggested GA-WK-ELM method has been calculated 98.42%. The optimal values of k, l, m parameters of the wavelet kernel function have been found 5, 3 and 12 respectively. The optimum value of the hidden layer neuron number has been found 220.

Key words: Extreme Learning Machine, Wavelet Kernel, Genetic Algorithm, Chronic Kidney Disease, Diagnostic System.

1. Giriş

Böbrek hastalığı, son yıllarda görülen ve kötü sonuçlar doğurabilen bir halk sağlığı sorunudur. Ayrıca, böbrek fonksiyon kaybı, kardiyovasküler hastalık ve erken ölüm dahil olmak üzere olumsuz sonuçlarla birlikte kronik böbrek hastalığının (KBH) erken aşamalarında daha yüksek bir risk bulunmaktadır[1]. Kronik böbrek hastalığı, böbrek fonksiyonlarında değişikliklere yol açması gereken glomerüler filtrasyon hızında kalıcı bir azalmanın belirtisidir. Bu durum sıklıkla glomerüler uyum oranı 25 ml / dk' nın altına düştüğünde ortaya çıkar. Glomerüler uyum oranı normal miktarın % 75' i kadar azaldığında, bu durum ortadan kaldırılsa da böbrek fonksiyonlarındaki yetersizlik devam eder [2]. Kronik böbrek hastalığı, böbrek hasarının etiyojisine bakılmaksızın en az 3 ay boyunca objektif böbrek hasarı ve / veya <60 mL / dak / 1.73 m² veya daha düşük bir glomerüler uyum oranına sahip olması olarak tanımlanır. Böbrek hasarının varlığı, böbrek histolojisinden üreyen böbreğin yapısal veya fonksiyonel anomalileri veya idrar veya kan kombinasyonundaki anormallikler veya görüntüleme testlerindeki

* Sorumlu yazar: davci@firat.edu.tr. Yazarların ORCID Numarası: ¹ 0000-0002-9708-3425, ² 0000-0001-6078-540X

anormallikler ile tanımlanabilir. Böbrek hasarının en yaygın ve en kolay gerçek belirteci, mikroalbüminüri dahil proteinüri varlığıdır [3], [4].

Literatürde KBH alanında yapılan sınıflandırma çalışmaları incelendiğinde, yapay sinir ağları [5], naive bayes [6,7], K-En Yakın Komşu (KNN)[7], radial tabanlı sinir ağları [8], destek vektör makinesi [9], rastgele orman [10,11], karar ağacı [12], ve Kyıldız[12] algoritması olarak karşımıza çıkmaktadır. Gunarathne, W.H.S.D. ve ark. [13], KBH alanında teşhis yapabilmek için makine öğrenmesi sınıflandırma algoritmalarını kullanmışlardır. Çalışmada farklı sınıflandırma algoritmaları kullanarak KBH teşhisi yapılmıştır. Veri kümesindeki 25 öznelik, 14 özneliğe indirgenmiştir. Elde edilen bu öznelikler, çok sınıflı karar ormanı algoritması ve farklı modellerle elde edilen özneliklerle karşılaştırılmıştır. Charleonnan, A. ve ark. [14], KBH' yi tahmin etmek için makine öğrenmesi tekniklerini karşılaştırmıştır. Bu çalışmada kullanılan dört adet makine öğrenmesi tekniği sırasıyla, KNN, Destek Vektör Makinesi (DVM), Lojistik Regresyon (LR) ve Karar Ağacı sınıflandırıcılarıdır. KBH' i tahmin etmek ve en iyi sınıflandırıcıyı seçmek için bu çalışma gerçekleştirilmiştir. Sonuç olarak bu çalışmada, DVM ile en iyi sınıflandırma sonucu % 98,3 olarak bulunmuştur. Sharma, S. ve ark. [15], karar ağacı algoritmasını kullanarak bir doğruluk analizi yapmıştır. Bu çalışmada veri kümesinin tüm özelliklerini kullanmak ve karar ağaçlarını kategorize etmek için çoklu karar ağaçları kullanılmıştır. Yıldırım, P. [16], KBH ile ilgili tıbbi karar sistemi için sinir ağı sınıflandırıcısı geliştirmiştir. Ahmad, M. ve ark. [17], KBH'yi DVM kullanarak sınıflandırmıştır. Sistemin geliştirilmesinin amacı, KBH tanısında bir karar destek sistemi kurarak KBH'nin olup olmadığını tahmin etmektir. Bu tanısal karar destek sisteminin doğruluğu %98.34'tür. Sinha, P. ve ark. [18], KBH için KNN ve DVM sınıflandırıcı performansını karşılaştırmıştır. Deneysel sonuçlardan, KNN sınıflandırıcısının başarısının DVM' den daha iyi olduğu sonucuna varılmıştır. Mat, A.N. ve ark. [19], KBH teşhisinde KNN sınıflandırıcının performansını arttırmak amacıyla genetik algoritmalar ve temel bileşenler analizini (PCA) hibrit şekilde kullanmıştır. Arora, M. ve ark.[20], Vijayarani, S. ve ark.[21], çalışmalarında KBH verilerinin sınıflandırması için DVM ve sinir ağları gibi sınıflandırma algoritmalarını kullanarak doğruluk açısından iyi sonuçlar üretmiştir. Baby, P. S. ve ark.[22], ADT ağaçlar, Naive Bayes, J48, Kyıldız algoritmalarını kullanarak KBH verilerini sınıflandırmıştır. Saurabh, N. Ve ark[23], KBH verilerinin sınıflandırması için Naive Bayes, DVM, J48, Rastgele orman ve KNN algoritmalarını kullanmıştır. Shanthakumari, A. S. ve ark.[24], kronik böbrek hastalığı tahmini için toplu öğrenmeli destek vektör makinesi yöntemini kullanarak karşılaştırmalı analiz, sınıflandırma doğruluğu, f-ölçümü, yüzde hatası vb. çeşitli metrikler açısından karşılaştırmıştır.

Bu çalışmada, KBH tanısı için Genetik Algoritma - Dalgacık Çekirdeği – Uç Öğrenme Makinesi (GA-DÇ-UÖM) hibrit yöntemi uygulanmıştır. Geliştirilen DÇ-UÖM sınıflandırıcısı, KBH verilerini sınıflandırmak için kullanılmıştır. GA, UÖM 'nin gizli katman nöron sayısını ve dalgacık çekirdeğinin k, l, m parametre değerlerini optimize etmek için kullanılmıştır.

Bu makalenin organizasyonu şu şekildedir:

Bölüm 2'de, Dalgacık Çekirdeği – Uç Öğrenme Makinesi yöntemi anlatılmıştır. Bölüm 3'te, Genetik Algoritma ile ilgili bilgi verilmiştir. Bölüm 4'te, veri seti tanıtılmaktadır. Bölüm 5'te önerilen yöntem açıklanmıştır. Son olarak, Bölüm 6'da deneysel sonuçlar verilmiştir.

2. Uç Öğrenme Makinesi

Uç Öğrenme Makinesi(UÖM), tek gizli katmanlı ileri beslemeli Yapay Sinir Ağlarını (YSA) eğitmek için önerilen bir yöntemdir [25], [26]. Bu modelde UÖM, giriş ve çıkış ağırlıkları rastgele hesaplanmaktadır. UÖM, gizli katmanda sigmoid, sinüs, gauss ve sabit limit aktivasyon fonksiyonlarını kullanmaktadır [27]. UÖM, çıkış katmanında doğrusal fonksiyonlar kullanmaktadır. Ayrıca türevi olmayan veya aralıklı aktivasyon fonksiyonlarını da kullanabilir [28].

Bir tek gizli katmanlı ileri beslemeli ağdaki eşik değerleri ve giriş-çıkış ağırlıkları ağ performansını etkilemez. UÖM'de eşik değerleri ve girdi ağırlıkları rastgele oluşturulur, çıkış ağırlıkları hesaplanır. Bu nedenle UÖM, geleneksel yöntemlerden daha iyi ve daha hızlıdır[29]. UÖM, gizli katmanın başlangıç parametrelerini ayarlamaz. Bu algoritma, doğrusal olmayan fonksiyonlarda gizli nöronları kullanır. Farklı örnek veri setleri için $\{p_j, m_j\} | p_j \in Q^l, m_j \in Q^k, j = 1, \dots, M\}$ k, UÖM' nin gizli bir nöron olarak hedef fonksiyonudur [30].

$$u_K(p) = \sum_{j=1}^K N_j h_j(p) = h(p)N, \quad (1)$$

$h = [h_1(p), h_2(p), \dots, h_K(p)]$ p, gizli katmanın hedef vektörünü temsil eder. hedef nöronlar ve gizli katman nöronları arasındaki ağırlık vektörünü temsil eder. h vektörü, girdi alanını UÖM özellik alanına dönüştürür [15]. UÖM' yi

optimize etmek için çeşitli yöntemler geliştirilmiştir. Eğitim ve çıkış hatalarını azaltmak için ağırlıklar en aza indirilebilir. Böylece sinir ağının tüm performansı iyileştirilir [31].

$$\text{Minimize: } \|TN - W\|, \quad \|N\| \quad (2)$$

$$N = T^T \left(\frac{1}{R} + TT^T \right)^{-1} W \quad (3)$$

T, gizli katman hedef matrisini W, örneklerin beklenen hedef matrisini R, regresyon katsayısını temsil etmektedir. Denklem 4'te UÖM öğrenme algoritması için çıkış fonksiyonu gösterilmektedir.

$$u(p) = h(p)T^T \left(\frac{1}{R} + TT^T \right)^{-1} W \quad (4)$$

Özellik vektörü bilinmiyorsa, UÖM' nin çekirdek matrisi Mercer' in koşullarıyla açıklanabilir [32].

$$K = TT^T: \quad k_{jz} = h(p_j)h(p_z) = b(p_j, p_z), \quad (5)$$

UÖM fonksiyonuna dayalı dalgacık çekirdeği Denklem 6'da gösterilmektedir.

$$u(p) = [b(p, p_1), \dots, b(p, p_M)] \left(\frac{1}{R} + K \right)^{-1} W \quad (6)$$

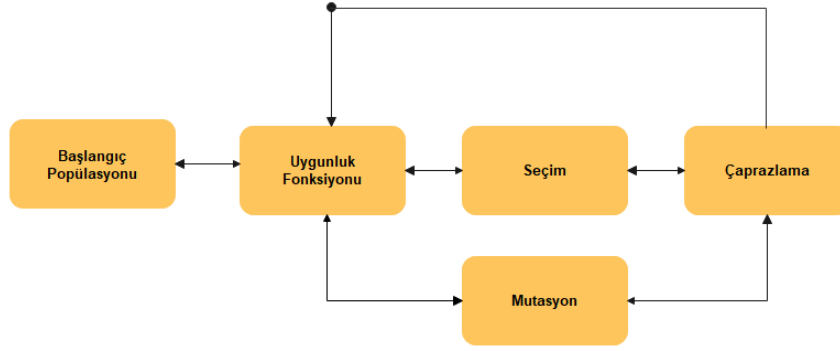
$K = TT^T$ çekirdek matrisini, $b(p, g)$ UÖM' nin çekirdek fonksiyonunu temsil etmektedir. Bu çalışmada, DÇ-UÖM performans testi için Denklem 7 kullanılmıştır[33], [34].

$$b(p, g) = \cos \left(k \frac{\|p - g\|}{l} \right) \exp \left(- \frac{\|p - g\|^2}{m} \right) \quad (7)$$

DÇ' nin k, l ve m ayarlanabilir parametreleri sınıflandırmanın başarısını etkilemektedir. Bu nedenle k, l ve m parametrelerinin değerleri dikkatlice ayarlanmalıdır. DÇ-UÖM öğrenme algoritması, literatürdeki diğer algoritmalarından daha iyi genelleme yeteneğine sahiptir. DÇ-UÖM, klasik UÖM' den daha hızlıdır [35-38].

3. Genetik Algoritma

Genetik algoritma(GA), doğada gözlemlenen evrimsel süreçlere benzer şekilde çalışan bir optimizasyon yöntemidir. GA, sorunlara tek bir çözüm üretmek yerine, farklı çözümlerden oluşan bir dizi çözüm üretir. Böylelikle arama alanında birçok nokta aynı anda değerlendirilmekte ve bütüncül çözüme ulaşma olasılığı artmaktadır [39]. Sorunun olası çözümlerini simgeleyen kümeler GA'da popülasyon denir. Popülasyon, birey adı verilen bir sayı dizisinden oluşur. Etkili bireyler, evrimsel bir süreçte GA tarafından tespit edilir. Popülasyondaki her bir bireyin soruna bir çözüm olup olmayacağına karar veren bir uygunluk fonksiyonu vardır [40]. Uygunluk fonksiyonları, diğer bireylerle çoğalma fırsatı verir. Bu bireyler geçiş sürecinin sonunda çocuk adı verilen yeni bireyler üretirler. Çocuk, ebeveynlerin (anne, baba) özelliklerini taşır. Yeni popülasyon, önceki popülasyondaki yüksek uyumlu bireylerin bir araya gelmesiyle oluşur [41, 42]. En yüksek uygunluk değerine sahip bireyler ne kadar çok bir araya gelir ve yeni bireyler oluşturursa, arama alanında o kadar iyi çalışma alanı elde edilir. GA'nın yapısı Şekil 1'de gösterilmektedir.



Şekil 1. GA'da Evrim Döngüleri

4. Veri Seti Özellikleri

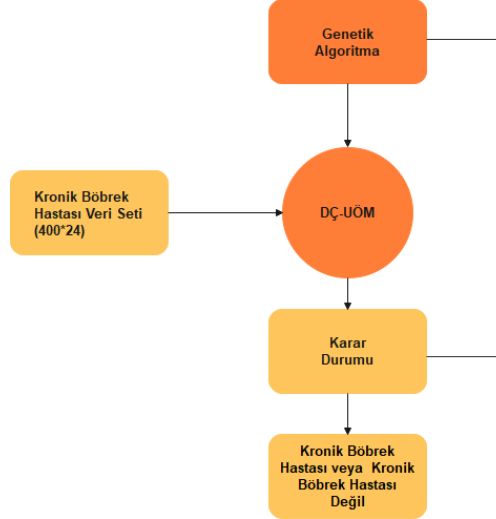
KBH verileri, UCI makine öğrenimi veritabanından alınmıştır [43]. Veri seti, 2-90 yaş aralığındaki insanlara ait 250 kronik böbrek hastası ve 150 sağlıklı kişi olmak üzere toplam 400 kişinin özelliklerini içermektedir. Çalışmada kronik böbrek hastalığının belirlenmesinde 400 kişiye ait 24 farklı özellikten oluşan veri seti kullanılmıştır. 24 farklı değer miktarının hastalığın oluşumunda etkili olduğu düşünülmektedir. Veri setinde kullanılan öznitelikler Tablo 1'de gösterilmiştir.

Tablo 1. Veri seti özellikleri

Öznitelik	Açıklama	Değer
age	yaş	sayısal
bp	kan basıncı	sayısal
sg	idrarda özgül ağırlık	sayısal (1.005,1.010,1.015,1.020,1.025)
al	albumin	sayısal (0,1,2,3,4,5)
su	şeker	sayısal (0,1,2,3,4,5)
rbc	kırmızı kan hücreleri	nominal (normal,anormal)
pc	iltihap hücresi	nominal(normal,anormal)
pcc	iltihap hücre kümeleri	nominal (mevcut,mevcut değil)
ba	bakteri	nominal (mevcut,mevcut değil)
bgr	rastgele kan şekeri	sayısal
bu	kanda üre	sayısal
sc	serum kreatinin	sayısal
sod	sodyum	sayısal
pot	potassium	sayısal
hemo	hemoglobin	sayısal
pcv	paketlenmiş hücre hacmi	sayısal
wc	Beyaz kan hücre sayısı	sayısal
rc	kırmızı kan hücresi sayısı	sayısal
htn	Hipertansiyon	nominal (Evet,Hayır)
dm	şeker hastalığı	nominal (Evet,Hayır)
cad	koroner arter hastalığı	nominal(Evet,Hayır)
appet	iştah	nominal (iyi,kötü)
pe	ödem	nominal (Evet,Hayır)
ane	anemi	nominal (Evet,Hayır)
class	sınıf	nominal (KBH, KBH değil)

5. Materyal Metot

Bu çalışmadaki uygulama Matlab R2018b kullanılarak yapılmıştır[44]. Genetik Algoritma –Dalgacık Çekirdeği-Uç Öğrenme Makinesi(GA-DÇ-UÖM) üç aşamadan oluşmaktadır. İlk aşama, Kronik Böbrek Hastalığı(KBH) veri setinden alınan verileri içermektedir. Veri seti toplam 400 vaka ve 24 özneliği içermektedir. İkinci aşamada, GA ile UÖM'nin gizli katman nöron sayısı ve dalgacık çekirdeğinin parametreleri optimize edilir. 3. aşamada, veri setindeki 24 öznelik, GA tarafından hesaplanan optimum değerlerle DÇ-UÖM sınıflandırıcısına verilir. Çıkışta kronik böbrek hastalığı olan veya kronik böbrek hastalığı olmayan şekilde iki sınıf bulunmaktadır. Kronik böbrek hastalığı için akıllı teşhis sistemine dayalı GA-DÇ-UÖM sisteminin akış şeması Şekil 2'de gösterilmektedir.



Şekil 2. GA-DÇ-UÖM'nin akış şeması

Kronik böbrek hastalığı veritabanındaki 400X24 boyutundaki özellik vektörü, DÇ-UÖM sınıflandırıcısına girdi olarak verilir. DÇ-UÖM'nin yapısında, dalgacık çekirdeğinin ayarlanabilir üç parametresi vardır. Bu parametreler UÖM'nin dalgacık çekirdeğinin k, l, m parametreleri ve gizli katman nöron sayısı UÖM'nin performansında önemli bir rol oynamaktadır. Bu nedenle bu parametreler ve gizli katman nöron sayısı değerleri dikkatli seçilmelidir. Bu çalışmada, DÇ-UÖM'nin k, l, m değerleri ve gizli katman nöron sayısı parametrelerinin optimum değerleri GA kullanılarak elde edilmiştir. GA yapısında, bir birey toplam 20 bitten oluşur. 20 kişinin 1., 2., 3. ve 4. bitleri, dalgacık çekirdeğinin k parametre değerlerini, 5., 6., 7. ve 8. bitleri, dalgacık çekirdeğinin l parametre değerini, 9., 10., 11. ve 12. bitleri, dalgacık çekirdeğinin m parametre değerini (1 ile 16 arası) temsil etmektedir. Son 8 bit gizli katman nöron sayısını (5 ile 259 arasında) temsil etmektedir. İlk popülasyonda bireyler rastgele seçilmektedir. GA kullanılarak DÇ-UÖM sınıflandırıcısının en iyi performansının elde edilmesi amaçlanmaktadır. DÇ-UÖM sınıflandırıcı 260 veri seti ile eğitilmiştir. Kalan 140 veri seti, DÇ-UÖM'yi test etmek için kullanılır. Kronik böbrek hastalığı olan veya kronik böbrek hastalığı olmayan şekildeki 2 durum, sınıflandırıcının çıkışı temsil etmektedir. DÇ fonksiyonunun parametresinin ve UÖM'nin gizli katman nöron sayısının optimum değerleri, önerilen GA-DÇ-UÖM yöntemi ile hesaplanmıştır. Sonuç olarak GA-DÇ-UÖM, kronik böbrek hastalığının teşhisi için çok güçlü ve gerçek zamanlı bir sistemdir. Bu çalışmada, GA-DÇ-UÖM'nin performansını bulmak için ortalama değerler hesaplanmıştır. GA'da ilk popülasyon, 40 bireyden rastgele seçilmektedir.

Tablo 2'de DÇ fonksiyonunun k, l, m parametrelerinin kodlama değerleri, Tablo 3'te gizli katman nöron sayısını kodlanması verilmiştir. GA'daki 20 bireyin ilk dört biti (1., 2., 3. ve 4. bitler) DÇ fonksiyonunun k parametre değerlerini (1 ile 16 arası), 5., 6., 7. ve 8. bitler DÇ fonksiyonunun l parametre değerini (1 ile 16 arası), 9., 10., 11. ve 12. bitler DÇ fonksiyonunun m parametre değerini (1 ile 16 arası), son 8 bit ise gizli katman nöron sayısını (5 ile 259 arasında) temsil etmektedir [38].

Tablo 2. Çekirdek fonksiyon parametreleri için kodlama

k, l, m parametrelerinin değerleri	Kodlama
1	0 0 0 0
2	0 0 0 1
3	0 0 1 0
4	0 0 1 1
5	0 1 0 0
6	0 1 0 1
7	0 1 1 0
8	0 1 1 1
9	1 0 0 0
10	1 0 0 1
11	1 0 1 0
12	1 0 1 1
13	1 1 0 0
14	1 1 0 1
15	1 1 1 0
16	1 1 1 1

Tablo 3. Gizli katman nöron sayısının kodlanması

Gizli katman nöron sayısı	Kodlama
5	0 0 0 0 0 0 0 0
6	0 0 0 0 0 0 0 1
7	0 0 0 0 0 0 1 0
8	0 0 0 0 0 0 1 1
.	.
.	.
.	.
259	1 1 1 1 1 1 1 1

GA-DÇ-UÖM 'nin başarısı, sınıflandırma doğruluğu, ROC eğrileri, duyarlılık ve özgüllük analizi kullanılarak hesaplanmaktadır. Veri setleri için sınıflandırma performansı Denklem 8 kullanılarak hesaplanmaktadır. Duyarlılık ve özgüllük analizi ise Denklem 9, Denklem 10 kullanılarak hesaplanmaktadır.

$$Correct\ accuracy(C) = \frac{\sum_{k=1}^{|C|} assess(c_k)}{|C|}, \quad c_k \in C \quad (8)$$

$$assess(C) = \begin{cases} 1 & \text{if } classify(c) = c.m \\ 0 & \text{otherwise} \end{cases}$$

$$assess(c) = \begin{cases} 1, & \text{if } classify(c) = c.d \\ 0, & \text{otherwise} \end{cases} \quad (9)$$

$$sensitivity(\%) = \frac{TP}{TP + FN} \quad (10)$$

$$specificity(\%) = \frac{TN}{FN + TN} \quad (11)$$

Burada; TP gerçek pozitifleri, TN gerçek negatifleri, FP yanlış pozitifleri, FN yanlış negatifleri sembolize etmektedir [45], [46].

6. Sonuçlar ve Karşılaştırmalar

Önerilen GA-DÇ-UÖM 'nin performansı, sınıflandırma doğruluğu, ROC eğrileri, duyarlılık ve özgüllük analizi kullanılarak hesaplanmaktadır. Farklı gizli katman nöron sayısı ve çekirdek fonksiyonlarından oluşan klasik UÖM sınıflandırıcıların performansı, optimal gizli katman nöron sayısı ve optimal k, l, m parametrelerinden oluşan GA-DÇ-UÖM yönteminin performansı ile karşılaştırılmaktadır. Tablo 4'te Önerilen GA-DÇ-UÖM 'nin dalgacık çekirdeği k, l ve m parametre değerleri ve gizli katman nöron sayısının en iyi 5 performansının parametre değerleri verilmektedir. UÖM'nin optimum parametrelerini bulmak için farklı aktivasyon fonksiyonları kullanılmaktadır. En iyi performans, gizli katman nöron sayısı sayısının aşamalı olarak l'den 100 adıma çıkarılmasıyla test edilmiştir. Tablo 5'te ise klasik UÖM'nin farklı parametreler ve farklı aktivasyon fonksiyonları için performansı verilmiştir. Tablolardan görüldüğü gibi önerilen GA-DÇ-UÖM 'nin sınıflandırma başarımı klasik UÖM' den daha başarılı sonuçlar vermektedir.

Tablo 4. Önerilen GA-DÇ-UÖM 'nin en iyi 5 performansının parametre değerleri

<i>k</i>	<i>l</i>	<i>m</i>	Gizli Katman Nöron Sayısı	Doğruluk (%)
5	3	12	220	98.42
5	13	16	188	97.84
10	9	10	207	96.68
16	5	9	198	95.97
15	16	4	166	95.2

Tablo 5. UÖM'nin farklı parametreler ve farklı aktivasyon fonksiyonları için performansı

Aktivasyon Fonksiyonu	Gizli Katman Nöron	Doğruluk (%)	
		Eğitim	Test
<i>Logarithmic-sigmoid</i>	10	79.69	76.02
	20	78.65	75.00
	30	77.60	76.50
	40	77.08	76.04
	50	77.08	76.04
	60	80.73	75.52
	70	77.60	75.52
	80	80.73	79.17
	90	80.73	72.40
	100	81.25	74.48
<i>Tangent - sigmoid</i>	10	78.47	78.13
	20	81.03	80.21
	30	82.05	81.25
	40	80.73	77.08
	50	85.02	84.61
	60	80.73	80.21
	70	82.64	76.56
	80	84.03	76.56
	90	84.03	75.52
	100	84.55	79.69

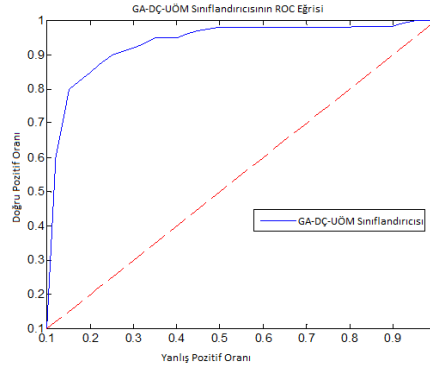
Önerilen GA-DÇ-UÖM için en iyi sınıflandırma başarımı % 98.42 olarak bulunmuştur. Buna bağlı olarak dalgacık çekirdeğinin k, l, m parametrelerinin değerleri 5, 3 ve 12 olarak, gizli katman nöron sayısı 220 olarak bulunmuştur.

Tablo 6'da, önerilen GA-DÇ-UÖM 'nin en iyi performansının doğruluk ve duyarlılık değerleri gösterilmektedir.

Tablo 6. Önerilen GA-DÇ-UÖM yönteminin duyarlılık ve özgüllük değerleri

Method	Sınıflandırma Başarımı (%)
Doğruluk Analizi	97.96
Duyarlılık Analizi	98.88
Ortalama	98.42

ROC eğrileri ve AUC değerleri TP, TN, FP ve FN değerleri kullanılarak bulunur. Bu uygulamanın ROC eğrisi şekil 3'te gösterilmektedir. ROC eğrilerinin AUC değeri, kronik böbrek hastalığı verileri için GA-DÇ-UÖM kullanılarak 0,984 olarak hesaplanmaktadır.

**Şekil 3.** GA-DÇ-UÖM'nin ROC eğrisi

Kronik böbrek hastalığı teşhisi için önerilen GA-DÇ-UÖM yönteminin eğitim ve test süresi Tablo 7'de gösterilmektedir.

Tablo 7. GA-DÇ-UÖM yönteminin eğitim ve test süresi

	Zaman (s)	
	Eğitim	Test
GA-DÇ-UÖM	0.0164	0.0141

7. Tartışma

Bu çalışmada, kronik böbrek hastalığı teşhisi için GA-DÇ-UÖM 'ye dayalı akıllı bir teşhis sistemi geliştirilmiştir. Önerilen yöntem, özellik vektörünü doğrudan kullanma yeteneği, hızlı eğitim-test süresi ve geleneksel sinir ağları üzerinde genelleme gibi birçok avantaja sahiptir. Kronik böbrek hastalığı veritabanındaki 400X24 boyutundaki özellik vektörü, DÇ-UÖM sınıflandırıcısına girdi olarak verilir. DÇ-UÖM 'nin yapısında, dalgacık çekirdeğinin ayarlanabilir üç parametresi vardır. Bu parametreler UÖM'nin dalgacık çekirdeğinin k, l, m parametreleri ve gizili katman nöron sayısı UÖM'nin performansında önemli bir rol oynamaktadır. Bu nedenle bu parametreler ve gizili katman nöron sayısı değerleri dikkatli seçilmelidir. Bu çalışmada, DÇ-UÖM'nin k, l, m değerleri ve gizili katman nöron sayısı parametrelerinin optimum değerleri GA kullanılarak elde edilmiştir. GA kullanılarak elde edilen optimum değerler, DÇ-UÖM sınıflandırıcısının yapısında kullanılmıştır. GA-DÇ-UÖM tabanlı kronik böbrek hastalığı teşhis sistemi %98.42'lik sınıflandırma performansına sahiptir. Önerilen yöntem yardımıyla doktorlar hastalıkla ilgili nihai bir karar verebilirler. Bu noktada doktorlar, kronik böbrek hastalığı teşhisi konusunda daha doğru bir karar vermek için önerilen yöntemi kullanabilirler.

Kaynaklar

- [1] Levey, A. S., Eckardt, K. U., Tsukamoto, Y., Levin, A., Coresh, J., Rossert, J., ... & Eknoyan, G. (2005). Definition and classification of chronic kidney disease: a position statement from Kidney Disease: Improving Global Outcomes (KDIGO). *Kidney international*, 67(6), 2089-2100.
- [2] Türkiye'de, Nefroloji-Diyaliz ve Transplantasyon. Registry 2009 İstanbul: Türk Nefroloji Derneği 2010.

- [3] Süleymanlar, G., Utaş, C., Arinsoy, T., Ateş, K., Altun, B., Altıparmak, M. R., ... & Serdengeçti, K. (2010). A population-based survey of Chronic REnal Disease In Turkey—the CREDIT study. *Nephrology Dialysis Transplantation*, 26(6), 1862-1871.
- [4] Tanrıverdi, M. H. (2010). Kronik böbrek yetmezliği. *Konuralp tıp dergisi*, 2010(2), 27-32.
- [5] İLKUÇAR, M. (2015). Kronik Böbrek Hastalarının Yapay Sinir Ağı ve Radyal Temelli Fonksiyon Ağı ile Teşhisi. *Mehmet Akif Ersoy Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 6(2), 82-88.
- [6] Eroğlu, K., & Palabaş, T. (2016, December). The impact on the classification performance of the combined use of different classification methods and different ensemble algorithms in chronic kidney disease detection. In *2016 National Conference on Electrical, Electronics and Biomedical Engineering (ELECO)* (pp. 512-516). IEEE.
- [7] Alm Mustafa, K. M. (2021). Prediction of chronic kidney disease using different classification algorithms. *Informatics in Medicine Unlocked*, 100631.
- [8] İlkuçar M. Kronik Böbrek Hastalarının Yapay Sinir Ağı ve Radyal Temelli Fonksiyon Ağı ile Teşhisi. *Mehmet Akif Ersoy Üniversitesi Fen Bilimleri Enstitüsü Dergisi* 2015; 6.2: 82-88.
- [9] Polat H, Mehr H, Cetin A. Diagnosis of Chronic Kidney Disease Based on Support Vector Machine by Feature Selection Methods, *Journal of Medical Systems* 2017; 41.4: 55.
- [10] Kumar M. Prediction of Chronic Kidney Disease Using Random Forest Machine Learning Algorithm Running Title: Prediction of Chronic Kidney Disease, *International Journal of Computer Science and Mobile Computing* 2016; 52522: 24-33.1
- [11] Kılıçarslan S, Çelik M. (2019). Rotasyon orman sınıflandırma algoritması kullanarak kronik böbrek rahatsızlığının tahmini.
- [12] Baby P, Vital P. Statistical Analysis and Predicting Kidney Diseases using Machine Learning Algorithms, *International Journal of Engineering Research & Technology* 2015; 407: 206-210.
- [13] Gunarathne, W. H. S. D., Perera, K. D. M., & Kahandawaarachchi, K. A. D. C. P. (2017, October). Performance Evaluation on Machine Learning Classification Techniques for Disease Classification and Forecasting through Data Analytics for Chronic Kidney Disease (CKD). In *Bioinformatics and Bioengineering (BIBE), 2017 IEEE 17th International Conference on* (pp. 291-296). IEEE.
- [14] Charleonnann, A., Fufaung, T., Niyomwong, T., Chokchueypattanakit, W., Suwannawach, S., & Ninchawee, N. (2016, October). Predictive analytics for chronic kidney disease using machine learning techniques. In *Management and Innovation Technology International Conference (MITicon), 2016*(pp. MIT-80). IEEE.
- [15] Sharma, S., Sharma, V., & Sharma, A. (2016). Performance Based Evaluation of Various Machine Learning Classification Techniques for Chronic Kidney Disease Diagnosis. arXiv preprint arXiv:1606.09581
- [16] Yıldırım, P. (2017, July). Chronic Kidney Disease Prediction on Imbalanced Data by Multilayer Perceptron: Chronic Kidney Disease Prediction. In *Computer Software and Applications Conference (COMPSAC), 2017 IEEE 41st Annual* (Vol. 2, pp. 193-198). IEEE.
- [17] Ahmad, M., Tundjungsari, V., Widiyanti, D., Amalia, P., & Rachmawati, U. A. (2017, November). Diagnostic decision support system of chronic kidney disease using support vector machine. In *Informatics and Computing (ICIC), 2017 Second International Conference on* (pp. 1-4) IEEE.
- [18] Sinha, P., & Sinha, P. (2015). Comparative study of chronic kidney disease prediction using KNN and SVM. *International Journal of Engineering Research and Technology*, 4(12), 608-12.
- [19] MAT, A. N., & Onur, İ. N. A. N. (2020). Tiroid Ve Kronik Böbrek Hastalığı Verilerinin Sınıflandırılmasında Genetik Algoritmalar Ve Pca İle Hibrit Özellik Seçimi. *Selçuk-Teknik Dergisi*, 19(3), 137-155.
- [20] Chronic Kidney Disease Detection by Analyzing Medical Datasets in Weka. *International Journal of Computer Application*, 6(4), 20-26.
- [21] Vijayarani, S., Dhayanand, S., & Phil, M. (2015). Kidney disease prediction using SVM and ANN algorithms. *International Journal of Computing and Business Research (IJCBR)*, 6(2), 1-12.
- [22] Baby, P. S., & Vital, T. P. (2015). Statistical analysis and predicting kidney diseases using machine learning algorithms. *International Journal of Engineering Research and Technology*, 4(7), 206-210.
- [23] Saurabh, N., & Nargis, T. (2019). Chronic Disease Prediction Using Effective Feature Selection. *Int J Recent Technol Eng*, 8(2).
- [24] Shanthakumari, A. S., & Jayakarthish, R. (2021). Utilizing support vector machines for predictive analytics in chronic kidney diseases. *Materials Today: Proceedings*.
- [25] Huang, G. B., Ding, X., & Zhou, H. (2010). Optimization method based extreme learning machine for classification. *Neurocomputing*, 74(1-3), 155-163.
- [26] Zhu, Q. Y., Qin, A. K., Suganthan, P. N., & Huang, G. B. (2005). Evolutionary extreme learning machine. *Pattern recognition*, 38(10), 1759-1763
- [27] Huang, G. B., Zhu, Q. Y., & Siew, C. K. (2006). Extreme learning machine: theory and applications. *Neurocomputing*, 70(1-3), 489-501.
- [28] Suresh, S., Saraswathi, S., & Sundararajan, N. (2010). Performance enhancement of extreme learning machine for multi-category sparse data classification problems. *Engineering Applications of Artificial Intelligence*, 23(7), 1149-1157.
- [29] Li, B., Rong, X., & Li, Y. (2014). An improved kernel based extreme learning machine for robot execution failures. *The Scientific World Journal*, 2014.

- [30] Min, M., Chen, X., Lei, Y., Chen, Z., & Xie, Y. (2020). A Novel Kernel-based Extreme Learning Machine with Incremental Hidden Layer Nodes. *IFAC-PapersOnLine*, 53(2), 11836-11841.
- [31] Jahromi, A. N., Hashemi, S., Dehghantanha, A., Choo, K. K. R., Karimipour, H., Newton, D. E., & Parizi, R. M. (2020). An improved two-hidden-layer extreme learning machine for malware hunting. *Computers & Security*, 89, 101655.
- [32] Cortes, C., & Vapnik, V. (1995). Support-vector networks. *Machine learning*, 20(3), 273-297.
- [33] Ding, S., Zhang, J., Xu, X., & Zhang, Y. (2016). A wavelet extreme learning machine. *Neural Computing and Applications*, 27(4), 1033-1040.
- [34] K.,Kayaer, & T. Yıldırım, (2003). Medical diagnosis on pima indian diabetes using general regression neural networks, artificial neural networks and neural information processing (ICANN/ICONIP) (pp. 181–184), Istanbul, Turkey, June 26–29.
- [35] Ertam, F., & Avcı, E. (2017). A new approach for internet traffic classification: GA-WK-ELM. *Measurement*, 95, 135-142.
- [36] Huang, G. B., & Chen, L. (2008). Enhanced random search based incremental extreme learning machine. *Neurocomputing*, 71(16-18), 3460-3468.