



Düzce Üniversitesi Bilim ve Teknoloji Dergisi

Araştırma Makalesi

Meme Kanseri Teşhisi İçin Yeni Bir Skor Füzyon Yaklaşımı

 Erdem YAVUZ ^{a,*},  Can EYÜPOĞLU ^b

^a *Bilgisayar Mühendisliği Bölümü, Mühendislik ve Doğa Bilimleri Fakültesi, Bursa Teknik Üniversitesi, Bursa, TÜRKİYE*

^b *Bilgisayar Mühendisliği Bölümü, Hava Harp Okulu, Milli Savunma Üniversitesi, İstanbul, TÜRKİYE*

* Sorumlu yazarın e-posta adresi: erdemyavuz29@gmail.com

DOI : 10.29130/dubited.488460

ÖZET

Meme kanseri tüm dünyada yaygın bir hastalık olması sebebiyle hastalığın erken teşhisi, hastaların bu hastalıktan tamamen kurtulabilmeleri açısından kritik öneme sahiptir. Hastalığın teşhisini kolaylaştırmak için tıp doktorları bilgisayar destekli uzman sistemlerden yararlanabilmektedir. Bu çalışmada meme kanseri veri örneklerini iyi huylu veya kötü huylu sınıflarına ayırmak için genel regresyon sinir ağı (Generalized Regression Neural Network-GRNN) ve ileri beslemeli sinir ağı (Feed Forward Neural Network-FFNN) temelli bir skor füzyon yöntemi önerilmiştir. Önerilen yöntem Wisconsin Teşhis Meme Kanseri (Wisconsin Diagnostic Breast Cancer-WDBC) veri seti üzerinde test edilmiştir. Bu iki temel ağın ve önerilen yöntemin kullanılabilirliği incelenmiş ve performans sonuçları karşılaştırmalı olarak sunulmuştur. Önerilen yöntem sınıflandırma doğruluğu bakımından literatürde WDBC veri setini kullanarak yapılan mevcut çalışmalar ile kıyaslanmıştır. Elde edilen deneysel sonuçlar önerilen yöntemin, meme kanseri teşhisi için umut vadettiğini ve tıp uzmanlarının hastalığa ilişkin karar vermelerinde yardımcı bir araç olarak kullanılabilirliğini göstermektedir.

Anahtar Kelimeler: Skor Füzyon, Meme Kanseri Teşhisi, Sinir Ağı, İleri Besleme, Genel Regresyon

A New Score Fusion Approach for Breast Cancer Diagnosis

ABSTRACT

Early diagnosis of breast cancer disease is critical for patients to recover from this disease entirely as it is a common disease all over the world. In order to facilitate the diagnosis of the disease, medical doctors can benefit from computer-aided expert systems. In this paper, a score fusion method based on generalized regression neural network (GRNN) and feed forward neural network (FFNN) has been proposed so as to split breast cancer data samples into benign or malignant classes. The proposed method is tested on the Wisconsin Diagnostic Breast Cancer (WDBC) dataset. The utilities of these basic neural networks and the proposed method are examined and comparative performance results are presented. The proposed method is compared to the existing studies using WDBC dataset in the literature in terms of classification accuracy. The experimental results show that the proposed method is promising for the diagnosis of breast cancer and may be used as an assisting tool in the decision-making of medical professionals.

Keywords: Score Fusion, Breast Cancer Diagnosis, Neural Network, Feed Forward, Generalized Regression

I. GİRİŞ

Son istatistikler meme kanserinin orta yaşta kadınlar arasında en sık görülen kanser olduğunu göstermektedir [1]. Ayrıca dünya genelindeki tüm kanserler arasında ikinci en yüksek ölüm sayısının sebebidir [2–4]. Meme kanseri her yıl dünyada yaklaşık olarak 1,7 milyon kadını etkilemektedir. Her yıl yaklaşık 230.000 kadına invazif meme kanseri teşhisi konulmaktadır. Bu da yaklaşık 40.000 hastanın ölmesine neden olmaktadır [5]. Batı ülkelerinde kadınların yaklaşık %10'u meme kanserinden muzdarip olmaktadır [6, 7]. Diğer yandan 2012 yılında Mısır'daki tüm kanser vakalarının %18'i meme kanseridir [8, 9]. Kanada Meme Kanseri Derneğinin (Breast Cancer Society of Canada) 2015 yılındaki istatistiklerine göre Kanada'da yaklaşık olarak 481 kadının meme kanserine yakalanacağı tahmin edilmektedir [10].

Tıpta bir hastalığın teşhisi çok karmaşık bir süreçtir. Hastalığın doğru teşhis edilmesi için çeşitli testler gereklidir. Uzman sistemler bilgisayar destekli tanı araçlarıdır ve bir hastalığın erken teşhisi için ön karar vermede tıp uzmanlarına yardım etmek için kullanılır. Erken teşhis sayesinde tedavi süresi kısaldır ve hastanın yaşamı kurtarılabilir. Özellikle meme kanserinde doktorlar hasta vakasının iyi huylu mu, yoksa kötü huylu mu olduğunu erken öğrenmek isterler. Uzman sistemler hastalık teşhisinde iyi huylu veya kötü huylu vakaları başarılı bir şekilde sınıflandırır [1, 11].

Literatürde bugüne kadar Wisconsin Teşhis Meme Kanseri (Wisconsin Diagnostic Breast Cancer-WDBC) veri seti üzerinde geliştirilen birçok yöntem vardır. Law vd. [12] karışım tabanlı kümeleme (mixture-based clustering) algoritması önermiş ve WDBC veri setinde test etmiştir. Bu algoritmanın sınıflandırma doğruluğu %90,7'dir. Luukka ve Leppälampi [13] meme kanseri teşhisi için C4.5 sınıflandırıcısını kullanmış ve %94,06 başarı elde etmiştir. Li ve Lu [14] ilk olarak veri setindeki nitelik boyutlarını azaltmak için temel bileşen analizini (Principle Component Analysis-PCA) kullanmış ve ardından destek vektör makinelerine (Support Vector Machines-SVM) dayalı bir sınıf olasılık tabanlı çekirdek (Class Possibility Based Kernel-CPBK) yöntemi ileri sürmüştür. Önerilen yöntemin doğruluğu %93,26'dır. Aynı yıl yapılan diğer bir çalışmada Liu ve Ren [15] geliştirdikleri aksiyomatik bulanık küme (Axiomatic Fuzzy Set-AFS) teorisine dayalı teknikte %94,6 başarıya ulaşmıştır. Miao vd. [16] ise bir kaba eş-egitim (rough co-training) modeli önererek %88,63'lük sınıflandırma doğruluğu elde etmiştir. Lavanya ve Rani [17] karar ağacı sınıflandırıcıların tıbbi veri setleri üzerindeki başarısını incelemiş ve WDBC veri setinde en iyi başarıya (%94,84) sınıflandırma ve regresyon ağacı (Classification and Regression Trees-CART) ile ulaşmıştır. Maldonado vd. [18] en popüler SVM türlerinden biri olan öz yinelemeli boyut eliminasyonu (Recursive Feature Elimination-SVM-RFE) tabanlı bir teknik ileri sürmüştür. Bu yöntemin ortalama sınıflandırma doğruluğu oranı %95,25'tir. Koloseni vd. [19] tarafından geliştirilen diferansiyel evrim tabanlı veri sınıflandırma yöntemi ile %93,64'lük başarıya ulaşılmıştır. Astudillo ve Oommen [20] yarı-danışmanlı (semi-supervised) örüntü sınıflandırma için ağaç yapısına dayalı özdüzenleyici haritalar (Tree-based Topology Oriented Self-Organizing Maps-TTOSOM) yönteminden yararlanmıştır. Bu yöntemin doğruluğu %93,32'dir. Tabakhi vd. [21] karınca kolonisi optimizasyonu (Ant Colony Optimization) tabanlı bir danışmansız (unsupervised) özellik seçimi algoritması önerdikten sonra Naïve Bayes sınıflandırıcı ile %92,42 başarıya ulaşmıştır. Lim ve Chan [22] basit bulanık küme teorisine dayanan bir Bandler-Kohout Subproduct (BKS) çıkarımı geliştirmiştir. Yöntemin en iyi sınıflandırma doğruluğu oranı %95,26'dır. Aynı veri seti üzerinde yapılan diğer bir çalışmada Kong vd. [23] meme kanseri teşhisindeki sınıflandırma doğruluğu artırmada gerekli olan en önemli özellikleri çıkarmak için ortak aralıklı diskriminant analizi (Jointly Sparse Discriminant Analysis-JSDA) adında bir metod önererek %93,85 başarı elde etmiştir. Xue vd. [24] ise meme kanseri sınıflandırmasında özellik seçimi

için parçacık sürü optimizasyonu (Particle Swarm Optimisation-PSO) yönteminden yararlanarak %93,98'lik doğruluğa ulaşmıştır. Son yıllarda yapılan çalışmalardan birinde ise Nilashi vd. [25] ilk olarak benzer gruplardaki verileri kümelemek için beklenti maksimizasyonunu (Expectation Maximization-EM) kullanmıştır. Ardından çoklu-doğrusallık (multi-collinearity) probleminin üstesinden gelmek için PCA'dan yararlanmıştır. Daha sonra hastalığın sınıflandırmasında kullanılacak olan bulanık kuralları CART metodu ile oluşturmuş ve son olarak bulanık mantıkla %93,2 sınıflandırma doğruluğu elde etmiştir. Bu makalede ise yukarıda bahsedilen tekniklerden farklı olarak meme kanseri tanısı için temel yapay sinir ağlarından oluşan bir skor füzyon yöntemi önerilmiştir.

Makalenin kalan kısmının organizasyonu şöyledir. Bölüm 2 meme kanseri teşhisi için kullanılan iki sinir ağını, bu temel ağların birleşimi olarak önerilen hibrit yöntemi ve çalışmada kullanılan veri setini tanıtmaktadır. Bölüm 3'te model doğrulaması ve deneyler gösterilmektedir. Son olarak çalışmanın sonuçları ve literatürdeki çalışmalarla kıyaslanması Bölüm 4'te sunulmuştur.

II. MALZEME VE YÖNTEM

A. ÇALIŞMADA KULLANILAN VERİ SETİ

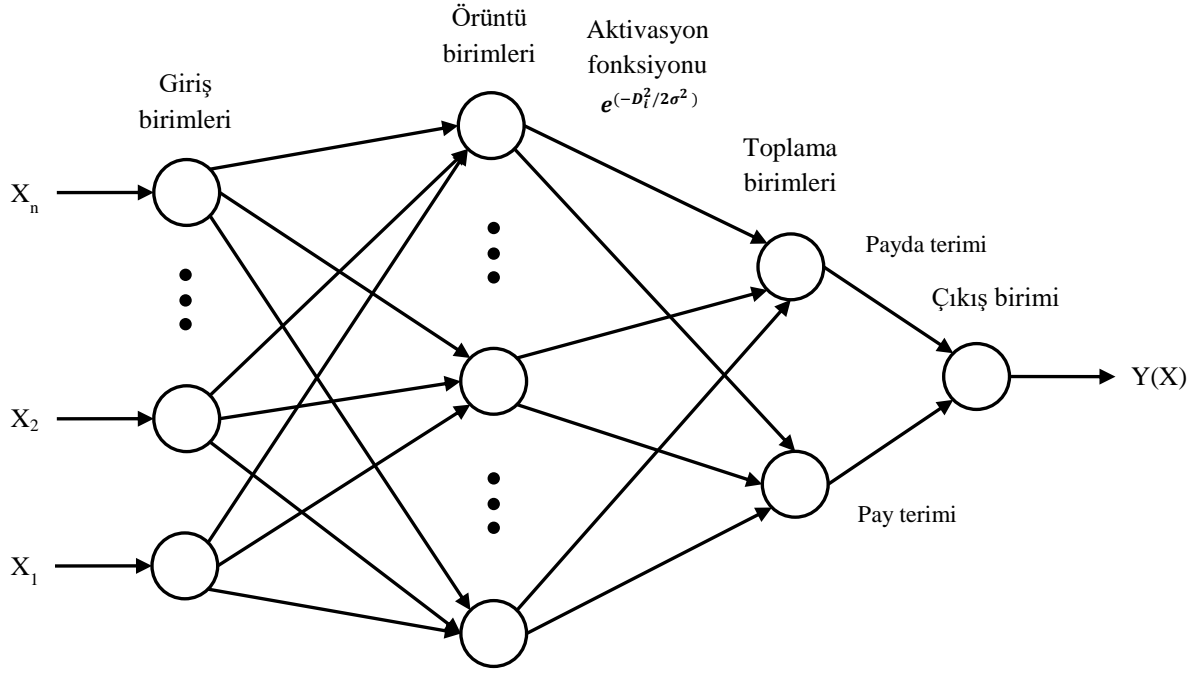
Bu çalışmada önerilen yöntem meme kanseri hastalığının teşhisi için WDBC veri seti üzerinde uygulanmıştır. WDBC veri seti 1995 yılında Wisconsin Üniversitesi Genel Cerrahi Bölümünden Dr. William H. Wolberg, Bilgisayar Bilimleri Bölümünden W. Nick Street ve Olvi L. Mangasarian tarafından oluşturulmuştur [26–32]. Ayrıca veri seti, California Üniversitesi-Irvine'de bulunan Makine Öğrenmesi Deposunda (Machine Learning Repository) çevrimiçi olarak mevcuttur [33] ve 569 örnek içermektedir. Nitelik sayısı 32'dir (ID, teşhis, 30 gerçek değerli girdi özellikleri). Yarıçap, doku, çevre uzunluğu, alan, pürüzsüzlük, kompaktlık, konkavlık, konkav noktalar, simetri ve fraktal boyut olmak üzere 10 gerçek değerli nitelik vardır. Veri setinde 357 örnek iyi huylu, 212 örnek ise kötü huyludur. Eksik bilgi içeren nitelik yoktur. WDBC veri setinin özeti Tablo 1'de gösterilmektedir.

Tablo 1. WDBC veri setinin özeti

Nitelik #	Nitelik ismi	Tanım kümesi	Ortalama	Standart hata	Maksimum
1	ID numarası	ID numarası	–	–	–
2	Teşhis	İyi huylu Kötü huylu	–	–	–
3	Yarıçap	Gerçek değer	6,98 – 28,11	0,112 – 2,873	7,93 – 36,04
4	Doku	Gerçek değer	9,71 – 39,28	0,36 – 4,89	12,02 – 49,54
5	Çevre uzunluğu	Gerçek değer	43,79 – 188,50	0,76 – 21,98	50,41 – 251,20
6	Alan	Gerçek değer	143,50 – 2501,00	6,80 – 542,20	185,20 – 4254,00
7	Pürüzsüzlük	Gerçek değer	0,053 – 0,163	0,002 – 0,031	0,071 – 0,223
8	Kompaktlık	Gerçek değer	0,019 – 0,345	0,002 – 0,135	0,027 – 1,058
9	Konkavlık	Gerçek değer	0,000 – 0,427	0,000 – 0,396	0,000 – 1,252
10	Konkav noktalar	Gerçek değer	0,000 – 0,201	0,000 – 0,053	0,000 – 0,291
11	Simetri	Gerçek değer	0,106 – 0,304	0,008 – 0,079	0,157 – 0,664
12	Fraktal boyut	Gerçek değer	0,050 – 0,097	0,001 – 0,030	0,055 – 0,208

B. GENEL REGRESYON SİNİR AĞI

Genel regresyon sinir ağı (Generalized Regression Neural Network-GRNN), radyal tabanlı fonksiyon ağının (Radial Basis Function Network-RBFN) değişik bir halidir ve genellikle olasılıksal sinir ağları (Probabilistic Neural Networks-PNN) ile birlikte anılmaktadır. Bu ağ türü, 1990 yılında Donald F. Specht tarafından ağırlıklandırılmış-komşu metodu formülize edilerek (sinir ağı biçiminde) ortaya atılmıştır [34]. GRNN ağının genel yapısı Şekil 1’de görülmektedir.



Şekil 1. GRNN yapısı

Bu ağ türü genellikle dört katmandan oluşmaktadır: giriş katmanı (input layer), gizli katman (hidden layer), toplama katmanı (summation layer) ve çıkış katmanı (decision/output layer). Giriş katmanı nöronları, medyan çıkarılarak ve çeyrekler arası aralığın bölünmesiyle değerleri normalleştirme ve bunları bir sonraki katmana iletme işini üstlenir. Eğitim veri setinde her gözlem vakası için bir nöron vardır. Gizli katman nöronları, hedef değerlerin yanı sıra gözlem vakalarına ait öngörü değişkenlerinin değerlerini de tutar. Bu katmandaki nöronlar, test vakalarının merkezlerine olan Öklit uzaklıklarını hesaplar. Toplama katmanında pay ve payda birimleri olarak adlandırılan iki nöron vardır. Payda birimi, ağırlık değerlerini toplayarak tüm gizli katman nöronlarının katkılarını birleştirir. Diğeri ise ağırlık değerlerini hedef değerleriyle çarparak tüm gizli katman nöronlarının genel katkısını hesaplar. Son olarak çıkış katmanı basitçe pay biriminde biriktirilen değeri paydaya bölerek tahmin sonucunu üretir.

Çalışan bir sistemden toplanan veriler geri-beslemeli sinir ağlar için genellikle yetersiz kalırken GRNN ağı, diğer PNN’ler gibi sadece bir miktar eğitim numunesine ihtiyaç duyar [34]. GRNN’nin bir avantajı da şudur: Geri-beslemeli ağlardan farklı olarak arzulan sonuca yaklaşmak için birden fazla iterasyona ihtiyaç duymaz [35]. Tek seferde öğrenme yapısına dayalı bir ağ türü olarak GRNN, sürekli değerli değişkenleri tahmin etmede, modelleme ve sınıflandırma problemlerinde rahatlıkla kullanılabilir [36–38]. GRNN, olasılık yoğunluk fonksiyonu olarak normal dağılımı kullanır.

Her bir X_i eğitim örneği, normal dağılım ortalaması olarak kullanılır [37] ve ifadesi Denklem 1 ve 2’de verilmiştir.

$$D_i = (X - X_i)^T (X - X_i) \quad (1)$$

$$Y(X) = \frac{\sum_{i=1}^n Y_i e\left(-\frac{D_i^2}{2\sigma^2}\right)}{\sum_{i=1}^n e\left(-\frac{D_i^2}{2\sigma^2}\right)} \quad (2)$$


Burada σ standart sapma değeri, aynı zamanda yayılım (spread) değeri olarak da anılır. Bu çalışmada kurulan GRNN modeline ilişkin parametreler Tablo 2’de verilmiştir. Bu modelde gizli katmandaki radyal tabanlı nöron sayısı, eğitim verisinin durumuna göre 448 olarak ortaya çıkmıştır. Ağa eğitim veya test aşamasında giriş olarak uygulanan örüntüler 1x30’luk vektör şeklindedir.

Tablo 2. GRNN parametreleri

Parametreler	GRNN
Yayılım değeri	50
Gizli katmandaki nöron sayısı	448
Gizli katmandaki nöronların transfer fonksiyonu türü	‘radbasn’

C. İLERİ BESLEMELİ SİNİR AĞI

İleri beslemeli sinir ağı (Feed Forward Neural Network-FFNN), iki veya daha fazla işlem katmanının arka arkaya bağlanmasıyla oluşan bir ağ yapısıdır. Birinci katman ağa uygulanan girişler için bir kapı görevi görür [39]. Çıkış katmanı nihai izdüşüm veya yaklaşım sonucunu üretir. Probleme ilişkin temel karmaşık ilişkileri tutan nöronlardan oluşan bir veya daha fazla gizli katman vardır. Farklı katmanlardaki işlem birimleri arasındaki ağırlıklar, problem hakkında dağıtık bir depolama yapısı ve her katmanda üretilen sonuçların sonraki katmana iletimini sağlar. FFNN’nin genel yapısı Şekil 2’de görülmektedir. Çok katmanlı ileri beslemeli bir ağ, katmanlarında bileşik bir fonksiyon uygulamasına sahip olabilir. Her katman, bazı aktivasyon fonksiyonları vasıtasıyla belirli bir fonksiyonu barındırır. Böylece, FFNN tarafından sağlanan nihai izdüşüm, bileşik bir fonksiyon ile karakterize edilir. Yaygın olarak kullanılan bu ağın matematiksel temelleri hakkında ayrıntılar için okuyucular [39, 40] kaynaklarına başvurabilirler.



Şekil 2. FFNN yapısı

Bu çalışmada kullanılan FFNN modeline ilişkin parametreler Tablo 3'te yer almaktadır. Ağın gizli katmanındaki nöron sayısı 200 ve bu nöronların aktivasyon türü 'tansig' (*tangent-sigmoidal*) yapılmıştır. Ağın eğitiminde Levenberg–Marquardt eğitim ('trainlm') algoritması kullanılmıştır ve eğitim sonlandırma kriteri olarak ortalama karesel hata eşiği 0,001 yapılmıştır. Oluşturulan ağın parametreleri eldeki veri seti için en iyi performansı verecek şekilde deneysel olarak belirlenmiştir. Ağa eğitim veya test aşamasında giriş olarak uygulanan örüntüler 1x30'luk vektör şeklindedir.

Tablo 3. FFNN parametreleri

Parametreler	FFNN
Gizli katmandaki nöron sayısı	200
Gizli katmandaki nöronların transfer fonksiyonu türü	'tansig'
Ortalama karesel hata hedefi	10^{-3}
Eğitim fonksiyonu	'trainlm'

D. ÖNERİLEN SKOR FÜZYON YÖNTEMİ

Önerilen yöntem, yukarıda bahsedilen iki temel sinir ağ yapısından oluşmaktadır. Metot özünde, belirli bir düzende bütün değerlendirme skorlarını birleştirmek suretiyle, her ağ türünün bireysel sınıflandırma sonucunu iyileştirerek toplam başarıyı yukarıya çekmiş olur. Şekil 3, meme kanseri sınıflandırması için önerilen skor füzyon yönteminin blok diyagramını göstermektedir. Önerilen yöntemde, meme kanseri veri seti, önce k -kat çapraz geçişleme şemasında eğitim ve test setlerine bölünür. Ardından GRNN ve FFNN olmak üzere iki sinir ağı oluşturulur. Bu sinir ağları eğitilir ve daha sonra test numuneleri için bağımsız olarak çalıştırılır. Kötü huylu veya iyi huylu vakalar olmak

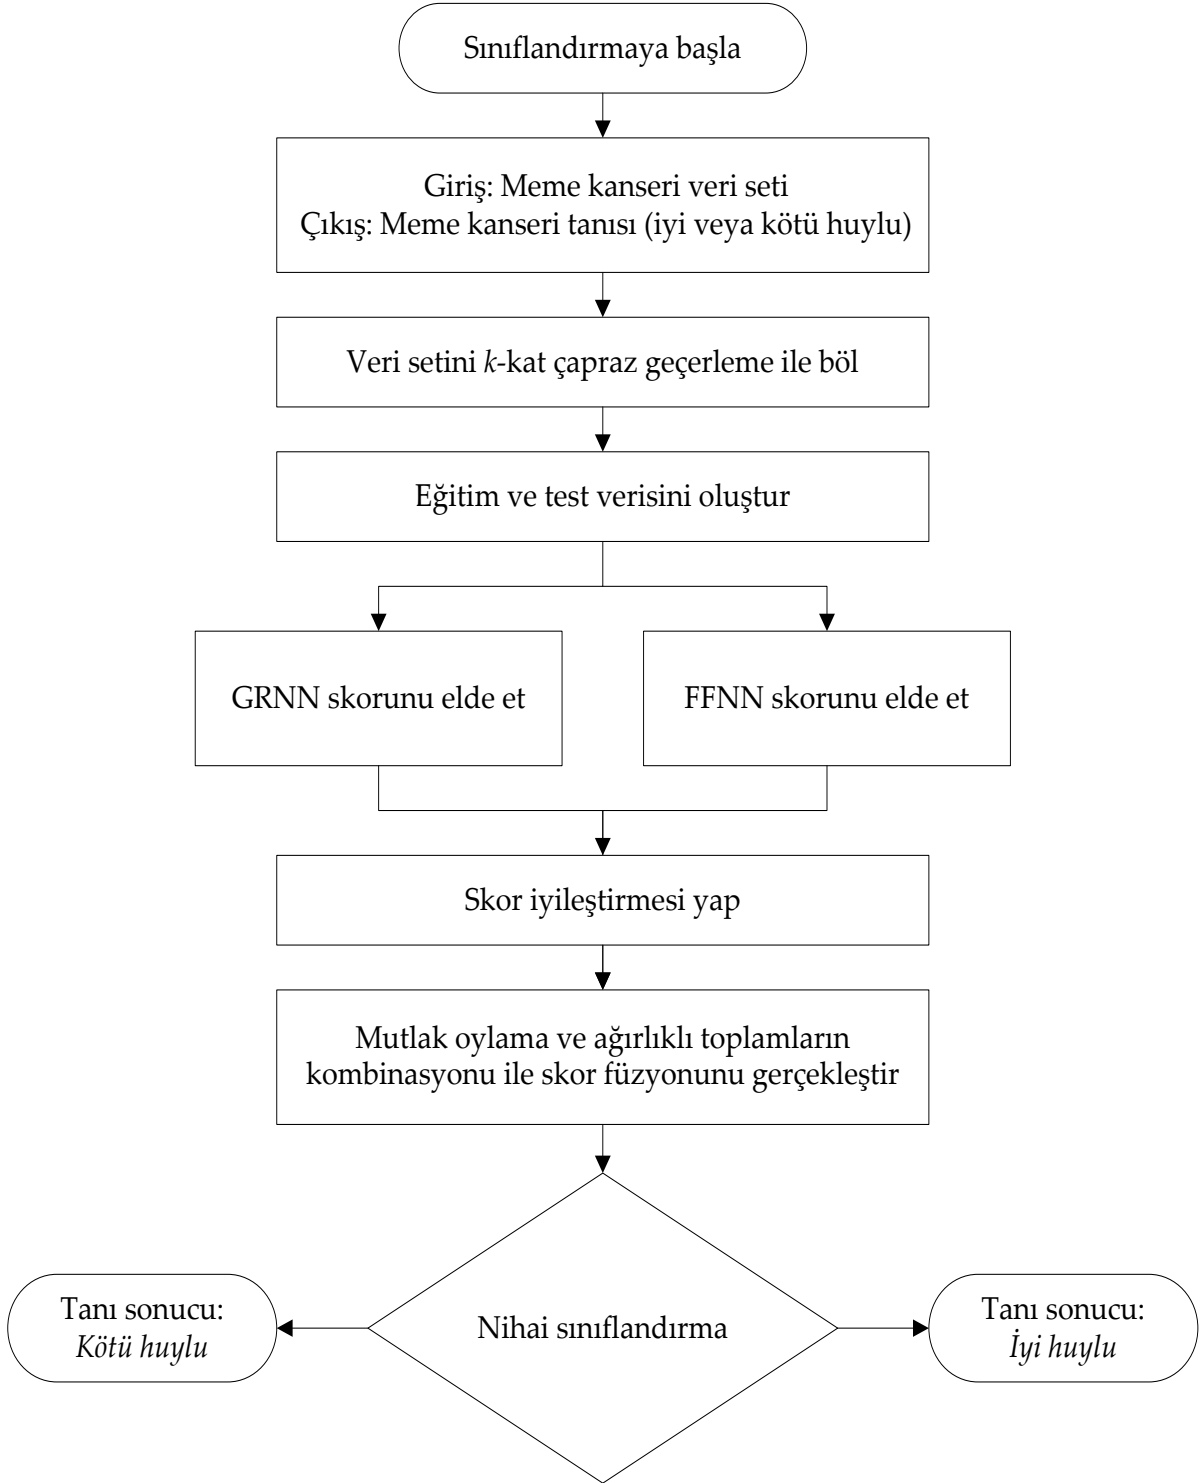
üzere iki sınıfa ait hedef değerler sırasıyla 0 ve 1'dir. Her bir temel ağ tarafından üretilen değerlendirme skoru, 1'den büyük skorla sonuçlanan vakalar için önce 1'e sabitlenir. Bu işlem tüm skorların 0-1 aralığında olmasını sağlar. Ardından sabitlenmiş skorlar aşağıdaki formül yardımıyla düzeltilir ve daha da iyileştirilir:

$$skor = \text{yuvarla} (skor^2 + 0,15) \quad (3)$$


Denklem 3'teki karesel ifade, ağların bireysel skorlarındaki karar eşiğini 0,5 seviyesinden uzaklaştırır ve 0,15 ofset değeri karesel ifadeyle 0,25 seviyelerine inen eşiğin tekrar 0-1'in orta noktasına yaklaşmasını sağlar. Yuvarlama fonksiyonu ile tüm bireysel skorların nihayet 0 veya 1'e haritalanmasını sağlar. Optimum performans sağlamak için Denklem 3'teki ofset değeri deneysel olarak 0,15 olarak belirlenmiştir. Denklem 3 yardımıyla FFNN sonucu üzerinde yapılan skor iyileştirme işlemi Şekil 4'teki örnek ile görselleştirilmiştir. 56 test vakası için ağın ürettiği ham skorlar ve bunların iyileştirilmesi sırasıyla Şekil 4a ve Şekil 4b'de verilmiştir. Grafikte mavi çizgi ham puana, kırmızı çizgi ise yuvarlama sonucuna karşı düşmektedir. Şekil 4a'dan görüldüğü gibi 7. test vakasının yuvarlama sonucu 1 çıkmıştır. Bu test vakasının etiket bilgisi ise sonucun 0 çıkması gerektiğine işaret etmektedir. Denklem 3 yardımıyla elde edilen iyileştirilmiş skorun yuvarlanması sonucunda ise aynı (7.) test vakasının sonucu 0 çıktığı Şekil 4b'den net bir şekilde görülmektedir. Bu iyileştirme nihai başarı oranının artmasına katkı sağlamaktadır.

Şekil 3'te görülen skor füzyonu bloğu mutlak oylama ve ağırlıklı toplam işlemlerinden oluşur. Her bir ağın ürettiği skor 0 veya 1 olduğu için bunların toplamı 0, 1 veya 2 olabilir. Toplam 0 veya 2 ise, nihai sınıflandırma mutlak oyla belirlenir. Başka bir deyişle eğer toplam 2 ise nihai sınıflandırma sonucu iyi huyludur veya toplam 0 ise sonuç kötü huyludur. Toplam değerinin 1 olduğu durumlarda nihai sınıflandırma, ağ birleşiminin bireysel puanlarının ağırlıklı toplamı hesaplanarak belirlenir. Bu durum için ağırlıklandırma çarpanları deneysel olarak sırasıyla GRNN ve FFNN için 0,45 ve 0,55 olarak belirlenmiştir.

Önerilen skor füzyon yöntemi ve bu yöntemle temel oluşturan yapay sinir ağı (Artificial Neural Network-ANN) modelleri, 4GB RAM ve Intel Core i5 M460 (2.53GHz) işlemci ile Windows 7 64-bit işletim sisteminde çalışan MATLAB R2016a'da gerçekleştirilmiştir. Önerilen yöntemde kullanılan ANN parametreleri Tablo 2 ve Tablo 3'te belirtilmiş ve bu parametreler, dayatılan hesaplama yükü bakımından veri seti için optimum başarı verecek şekilde deneysel olarak doğrulanmıştır.



Şekil 3. Meme kanseri sınıflandırması için önerilen skor füzyon yaklaşımı



Şekil 4. FFNN sonucu üzerinde skor iyileştirme

III. BULGULAR VE DEĞERLENDİRME

İkili tahmin yaparken, Gerçek Pozitif (*True Positive-TP*), Yanlış Negatif (*False Negative-FN*), Yanlış Pozitif (*False Positive-FP*), Gerçek Negatif (*True Negative-TN*) olmak üzere dört sonuç çıktısı olabilir [41]. İlgilenilen sınıflandırma problemi için *TP*, uzman sistemin doğru şekilde kötü huylu bir tümör teşhisi koymasına anlamına gelir. *FN*, uzman sistemin kötü huylu bir tümörün teşhisinde başarısız olduğu anlamına gelir. *FP*, uzman sistemin iyi huylu vakayı kötü huylu bir tümör olarak gördüğü anlamına gelir. *TN*, uzman sistemin iyi huylu bir tümörü kötü huylu olarak teşhis etmediği anlamına gelir. Konfüzyon matrisi, model tarafından yapılan tüm öngörülerin üzerinden geçmek suretiyle bu dört sonucun her birinin kaç kez oluştuğu sayılarak hesaplanır. Rastgele seçilmiş belirli bir vaka için iki sinir ağına ve önerilen skor füzyon yöntemine ilişkin konfüzyon matrisleri Şekil 5’te verilmiştir. Performans ölçümlerinden sınıflandırma doğruluğu, doğru sınıflandırılan örneklerin tüm örnekler bölünmesiyle hesaplanır. Hassasiyet (sensitivity), sistem tarafından kötü huylu olarak değerlendirilen pozitif vakaların gerçekte olan tüm pozitif vakalara bölünmesiyle bulunur ($TP/(TP+FN)$). Serpinti (fall-out) oranı, sistem tarafından yanlışlıkla pozitif olarak değerlendirilen negatif vakaların gerçekteki tüm negatif vakalara bölünmesiyle ortaya çıkan orana karşı düşer ($FP/(FP+TN)$). Belirlilik (specificity) oranı, serpinti oranı 1’den çıkarılarak hesaplanır. Şekil 5’te konfüzyon matrisleri verilen duruma ilişkin performans metrik sonuçları Tablo 4’te gösterilmiştir. Sonuçlar, önerilen yöntemin doğruluk oranını bir miktar arttırdığı ve duyarlılık oranını dikkate değer bir şekilde arttırdığını göstermektedir.

Tablo 4. Belirli bir durum için sınıflandırma doğruluğu, hassasiyet ve belirlilik oranları

Sınıflandırma metotları	Sınıflandırma Doğruluğu (%)	Hassasiyet (%)	Belirlilik (%)
GRNN	93,75	85,71	97,18
FFNN	94,64	90,47	97,14
Önerilen yöntem	95,53	95,23	95,71

Tablo 5, önerilen yaklaşım ve iki temel ağın k -kat çapraz geçerdeki sınıflandırma sonuçlarını içermektedir. Böylece Tablo 1’de verilen örnek verilerin %20’si (5-kat) ve %10’u (10-kat) sırasıyla test için ayrılmıştır ve gerisi, k -kat çapraz geçerde eğitim için kullanılmıştır. Test için saklanan veriler geliştirilen sistemin başarısını ve etkililiğini ispatlamak için ağı sunulur.

		Tahmin edilen sınıf	
		Kötü huylu	İyi huylu
GRNN	Kötü huylu	36	6
	İyi huylu	2	69

(a)

		Tahmin edilen sınıf	
		Kötü huylu	İyi huylu
FFNN	Kötü huylu	38	4
	İyi huylu	2	68

(b)

		Tahmin edilen sınıf	
		Kötü huylu	İyi huylu
Önerilen	Kötü huylu	40	2
	İyi huylu	3	67

(c)

Şekil 5. Belirli bir durum için konfüzyon matrisleri: (a) GRNN, (b) FFNN ve (c) Önerilen yöntem

100 rastgele tekrar için 5-kat ve 10-kat çapraz geçerdeki sınıflandırma doğruluğu, hassasiyet ve belirlilik oranları Tablo 5’te gösterilmektedir. 5-kat çapraz geçerdeki GRNN ve FFNN için sınıflandırma doğruluk oranları sırasıyla %91,21 ve %93,74 olarak ölçülmüştür. İki temel ağdan oluşan önerilen yöntem, bu temel ağları aşarak %93,78 oranına ulaşmıştır. Önerilen füzyon yaklaşımı, belirlilik oranı açısından GRNN’yi geçmiştir, ancak FFNN’nin biraz gerisinde kalmıştır. Önerilen

yaklaşım, hassasiyet oranında diğer tüm modellerden daha iyi sonuç üretmiştir. Bu yöntem hassasiyet oranında ise FFNN'den yaklaşık olarak en az %3 daha başarılı olmuştur.

Tablo 5. Gerçeklenen yöntemlerin k-kat çapraz geçerylemede 100 tekrar için performans metrik sonuçları

Sınıflandırma metotları		5-kat çapraz geçeryleme		10-kat çapraz geçeryleme	
		Ortalama	Std. sapma	Ortalama	Std. sapma
GRNN	Sınıflandırma Doğruluğu (%)	91,21	2,46	91,48	3,49
	Hassasiyet (%)	85,79	5,58	86	6,96
	Belirlilik (%)	94,46	2,61	94,77	3,92
FFNN	Sınıflandırma Doğruluğu (%)	93,74	3,3	94,41	3,55
	Hassasiyet (%)	88,83	6,36	89,33	8,01
	Belirlilik (%)	96,69	2,89	97,46	2,75
Önerilen yöntem	Sınıflandırma Doğruluğu (%)	93,78	3,43	94,54	3,28
	Hassasiyet (%)	92,07	5,7	92,57	6,43
	Belirlilik (%)	94,8	3,85	95,71	3,78

10-kat çapraz geçerylemede benzer performans metrik sonuçları gözlemlenmiştir. GRNN ve FFNN için sınıflandırma doğruluk oranları sırasıyla %91,48 ve %94,41 olarak ölçülmüştür. Önerilen yöntem, temel ağılardan daha iyi performans göstererek %94,54'lük bir orana ulaşmıştır. Bu yöntem, belirlilik oranı açısından GRNN'yi aşmış, ancak FFNN'nin biraz gerisinde kalmıştır. Diğer taraftan bu yöntem, hassasiyet oranı açısından diğerlerini en az %3 oranında geride bıraktığı görülmektedir. Elde edilen sonuçlar, önerilen skor füzyon yönteminin temel ağılarda elde edilen hassasiyet oranında hissedilir bir artış sağladığını ortaya koymaktadır.

A. LİTERATÜRDEKİ ÇALIŞMALAR İLE KIYASLAMA

Bu bölümde WDBC veri seti üzerinde son on beş yılda çeşitli tekniklerle elde edilen başarı oranlarına yer verilmiştir. Tablo 6'da yer alan mevcut çalışmaların sınıflandırma doğruluğu yaklaşık yüzde 88 ile yüzde 95 arasında değişim göstermektedir. Bu çalışmada önerilen skor füzyon yaklaşımı elde ettiği yüzde 94,54'lük sınıflandırma doğruluğu ile literatürdeki mevcut yöntemler arasında kendisine iyi bir yer edinmiştir.

Tablo 6. Mevcut çalışmalarda kullanılan yöntemler ve başarı oranları

Çalışma	Yöntem	Sınıflandırma Doğruluğu (%)
Law vd. [12]	Karışım tabanlı kümeleme	90,7
Luukka ve Leppälampi [13]	C4.5	94,06
Li ve Lu [14]	PCA – SVM – CPBK	93,26
Liu ve Ren [15]	Aksiyomatik bulanık küme (AFS)	94,6
Miao vd. [16]	Kaba eş-egitim (Rough co-training)	88,63
Lavanya ve Rani [17]	CART	94,84
Maldonado vd. [18]	Destek vektör makinesi-Özyinelemeli boyut eliminasyonu (SVM-RFE)	95,25
Koloseni vd. [19]	Diferansiyel evrim algoritması	93,64
Astudillo ve Oommen [20]	Ağaç yapısına dayalı özdenetleyici haritalar (TTOSOM)	93,32
Tabakhi vd. [21]	Naïve Bayes	92,42
Lim ve Chan [22]	Bandler-Kohout Subproduct (BKS) tabanlı çıkarım	95,26
Kong vd. [23]	Ortak aralıklı diskriminant analizi (JSDA)	93,85
Xue vd. [24]	Parçacık sürü optimizasyonu (PSO)	93,98
Nilashi vd. [25]	EM – PCA – CART – Bulanık mantık	93,2
Önerilen yöntem	GRNN ve FFNN birleşimi	94,54

IV. SONUÇ

Meme kanseri dünyadaki tüm toplumlarda yaygın bir hastalıktır. Bu sebeple bu hastalıktaki erken teşhis, hastaların geri döndürülemez bir evreye gelmeden önce tedavisi için hayati öneme sahiptir. Uzman sistemler hastalığın teşhisini kolaylaştırmak için geliştirilmektedir. Bu çalışmada meme kanseri teşhisi için GRNN ve FFNN'den oluşan bir skor füzyon yaklaşımı sunulmuştur. Çalışma bu temel sinir ağlarının ve önerilen yaklaşımın performanslarını karşılaştırmıştır. Deneysel sonuçlar önerilen skor füzyon yönteminin temel yöntemlerle elde edilen sınıflandırma doğruluğunu koruyarak hassasiyet oranını önemli derecede geliştirdiğini göstermektedir. Literatürde WDBC veri setini kullanarak yapılan son yıllardaki çalışmalarla kıyaslandığında, önerilen skor füzyon yaklaşımı nispeten iyi bir başarı oranı elde etmiştir. Önerilen yaklaşım biraz daha geliştirilmesi durumunda, tıp uzmanlarının hastalığa ilişkin karar vermelerine yardımcı olabilecek bir araç olarak kullanılmada umut vadetmektedir.

V. KAYNAKLAR

- [1] Ł. Jeleń, A. Krzyżak, T. Fevens and M. Jeleń, "Influence of feature set reduction on breast cancer malignancy classification of fine needle aspiration biopsies," *Computers in Biology and Medicine*, vol. 79, pp. 80-91, 2016.
- [2] S. Mittal, H. Kaur, N. Gautam and A.K. Mantha, "Biosensors for breast cancer diagnosis: A review of bioreceptors, biotransducers and signal amplification strategies," *Biosensors and Bioelectronics*, vol. 88, pp. 217-231, 2017.
- [3] C. DeSantis, J. Ma, L. Bryan and A. Jemal, "Breast cancer statistics, 2013," *CA: A Cancer Journal for Clinicians*, vol. 64, no. 1, pp. 52-62, 2014.
- [4] D.E. Misek and E.H. Kim, "Protein Biomarkers for the Early Detection of Breast Cancer," *International Journal of Proteomics*, vol. 2011, pp. 1-9, 2011.
- [5] Y. Tang, Y. Wang, M.F. Kiani and B. Wang, "Classification, Treatment Strategy, and Associated Drug Resistance in Breast Cancer," *Clinical Breast Cancer*, vol. 16, no. 5, pp. 335-343, 2016.
- [6] M. Nilashi, O. Ibrahim, H. Ahmadi and L. Shahmoradi, "A knowledge-based system for breast cancer classification using fuzzy logic method," *Telematics and Informatics*, vol. 34, no. 4, pp. 133-144, 2017.
- [7] L.E.M. Duijm, J.H. Groenewoud, F.H. Jansen, J. Fracheboud, M. van Beek and H.J. de Koning, "Mammography screening in the Netherlands: delay in the diagnosis of breast cancer after breast cancer screening," *British Journal of Cancer*, vol. 91, no. 10, pp. 1795-1799, 2004.
- [8] A.M. Abdel-Zaher and A.M. Eldeib, "Breast cancer classification using deep belief networks," *Expert Systems With Applications*, vol. 46, pp. 139-144, 2016.
- [9] G.I. Salama, M.B. Abdelhalim and M.A. Zeid, "Breast Cancer diagnosis on three different datasets using multi-classifiers," *International Journal of Computer and Information Technology*, vol. 1, pp. 36-43, 2012.
- [10] Breast cancer society of Canada incidence statistics for 2015, (13 Aralık 2017). [Online]. Erişim: <http://www.cbef.org/central/AboutBreastCancerMain/FactsStats/Pages/Breast-Cancer-Canada.aspx>
- [11] C. Eyupoglu, "Breast cancer classification using k-nearest neighbors algorithm," *The Online Journal of Science and Technology*, vol. 8, no. 3, pp. 29-34, 2018.
- [12] M.H.C. Law, M.A.T. Figueiredo and A.K. Jain, "Simultaneous feature selection and clustering using mixture models," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 26, no. 9, pp. 1154-1166, 2004.

- [13] P. Luukka and T. Leppälampi, "Similarity classifier with generalized mean applied to medical data," *Computers in Biology and Medicine*, vol. 36, no. 9, pp. 1026-1040, 2006.
- [14] D.-C. Li and C.-W. Liu, "A class possibility based kernel to increase classification accuracy for small data sets using support vector machines," *Expert Systems with Applications*, vol. 37, no. 4, pp. 3104-3110, 2010.
- [15] X. Liu and Y. Ren, "Novel artificial intelligent techniques via AFS theory: Feature selection, concept categorization and characteristic description," *Applied Soft Computing*, vol. 10, no. 3, pp. 793-805, 2010.
- [16] D. Miao, C. Gao, N. Zhang and Z. Zhang, "Diverse reduct subspaces based co-training for partially labeled data," *International Journal of Approximate Reasoning*, vol. 52, no. 8, pp. 1103-1117, 2011.
- [17] D. Lavanya and K.U. Rani, "Performance evaluation of decision tree classifiers on medical datasets," *International Journal of Computer Applications*, vol. 26, no. 4, pp. 1-4, 2011.
- [18] S. Maldonado, R. Weber and J. Basak, "Simultaneous feature selection and classification using kernel-penalized support vector machines," *Information Sciences*, vol. 181, no. 1, pp. 115-128, 2011.
- [19] D. Koloseni, J. Lampinen and P. Luukka, "Differential evolution based nearest prototype classifier with optimized distance measures for the features in the data sets," *Expert Systems with Applications*, vol. 40, no. 10, pp. 4075-4082, 2013.
- [20] C.A. Astudillo and B.J. Oommen, "On achieving semi-supervised pattern recognition by utilizing tree-based SOMs," *Pattern Recognition*, vol. 46, no. 1, pp. 293-304, 2013.
- [21] S. Tabakhi, P. Moradi and F. Akhlaghian, "An unsupervised feature selection algorithm based on ant colony optimization," *Engineering Applications of Artificial Intelligence*, vol. 32, pp. 112-123, 2014.
- [22] C.K. Lim and C.S. Chan, "A weighted inference engine based on interval-valued fuzzy relational theory," *Expert Systems with Applications*, vol. 42, no. 7, pp. 3410-3419, 2015.
- [23] H. Kong, Z. Lai, X. Wang and F. Liu, "Breast cancer discriminant feature analysis for diagnosis via jointly sparse learning," *Neurocomputing*, vol. 177, pp. 198-205, 2016.
- [24] B. Xue, M. Zhang and W.N. Browne, "Particle swarm optimisation for feature selection in classification: Novel initialisation and updating mechanisms," *Applied Soft Computing*, vol. 18, pp. 261-276, 2014.
- [25] M. Nilashi, O. Ibrahim, H. Ahmadi and L. Shahmoradi, "A knowledge-based system for breast cancer classification using fuzzy logic method," *Telematics and Informatics*, vol. 34, no. 4, pp. 133-144, 2017.

- [26] W.H. Wolberg, W.N. Street and O.L. Mangasarian, Wisconsin Breast Cancer Database, University of Wisconsin Hospitals, Madison, Wisconsin, USA, November 1995.
- [27] W.N. Street, W.H. Wolberg and O.L. Mangasarian "Nuclear feature extraction for breast tumor diagnosis," International Symposium on Electronic Imaging: Science and Technology, vol. 1905, pp. 861-870, San Jose, CA, 1993.
- [28] O.L. Mangasarian, W.N. Street and W.H. Wolberg, "Breast cancer diagnosis and prognosis via linear programming," *Operations Research*, vol. 43, no. 4, pp. 570-577, July-August 1995.
- [29] W.H. Wolberg, W.N. Street and O.L. Mangasarian, "Machine learning techniques to diagnose breast cancer from fine-needle aspirates," *Cancer Letters*, vol. 77, pp. 163-171, 1994.
- [30] W.H. Wolberg, W.N. Street and O.L. Mangasarian, "Image analysis and machine learning applied to breast cancer diagnosis and prognosis," *Analytical and Quantitative Cytology and Histology*, vol. 17, no. 2, pp. 77-87, April 1995.
- [31] W.H. Wolberg, W.N. Street, D.M. Heisey and O.L. Mangasarian, "Computerized breast cancer diagnosis and prognosis from fine needle aspirates," *Archives of Surgery*, vol. 130, pp. 511-516, 1995.
- [32] W.H. Wolberg, W.N. Street, D.M. Heisey and O.L. Mangasarian, "Computer-derived nuclear features distinguish malignant from benign breast cytology," *Human Pathology*, vol. 26, pp. 792-796, 1995.
- [33] M. Lichman, UCI Machine Learning Repository, University of California, School of Information and Computer Science, Irvine, California, USA, 2013.
- [34] D.F. Specht, "Probabilistic neural networks," *Neural Networks*, vol. 3, pp. 109-118, 1990.
- [35] D.F. Specht, "A general regression neural network," *IEEE Transactions on Neural Networks*, vol. 2, no. 6, pp. 568-576, 1991.
- [36] S.A. Hannan, R.R. Manza and R.J. Ramteke, "Generalized Regression Neural Network and Radial Basis Function for Heart Disease Diagnosis," *International Journal of Computer Applications*, vol. 7, no. 13, pp. 7-13, 2010.
- [37] M.M. Bauer, "General Regression Neural Network for Technical Use," Master's Thesis, University of Wisconsin-Madison, 1995.
- [38] E. Yavuz, M.C. Kasapbaşı, C. Eyüpoğlu and R. Yazıcı, "An epileptic seizure detection system based on cepstral analysis and generalized regression neural network," *Biocybernetics and Biomedical Engineering*, vol. 38, no. 2, pp. 201-216, 2018.
- [39] R.J. Schalkoff, *Artificial Neural Networks*, McGraw-Hill, pp. 337-341, 1997.
- [40] K.L. Du and M.N.S. Swamy, *Neural Networks in a Softcomputing Framework*, Springer Science & Business Media, pp. 251-254, 2006.

[41] E. Yavuz, C. Eyupoglu, U. Sanver and R. Yazici, "An ensemble of neural networks for breast cancer diagnosis," IEEE International Conference on Computer Science and Engineering (UBMK), Antalya, Turkey, 5-8 October 2017, pp. 538-543.