



# Göğüs Verileri Metrikleri Üzerinden Kanser Sınıflandırılması

**Emine CENGİL\***

Fırat Üniversitesi, Bilgisayar Mühendisliği Bölümü, Elazığ  
[ecengil@firat.edu.tr](mailto:ecengil@firat.edu.tr) ORCID: 0000-0003-4313-8694, Tel: (424) 237 00 00 (6335)

**Ahmet ÇINAR**

Fırat Üniversitesi, Bilgisayar Mühendisliği Bölümü, Elazığ  
[acinar@firat.edu.tr](mailto:acinar@firat.edu.tr) ORCID: 0000-0001-5528-2226

Geliş: 17.06.2019, Revizyon: 19.10.2019, Kabul Tarihi: 27.01.2020

## Öz

Göğüs kanseri dünyada kadınlar arasında en sık karşılaşılan kanserlerden birisidir. Hastalık erken teşhis edilmediğinde ölüme yol açabilmektedir. Göğüs kanseri tümörünün doğru bir şekilde sınıflandırılması tıbbi alanda zorlu bir problemdir. Bu çalışmada, iğne aspirasyon tekniği kullanılarak biyopsi parçasından çıkartılmış metrik verileri içeren Breast Cancer Wisconsin (Diagnostic) veri seti kullanılarak kanser veya kanser değil ikili sınıflandırılması gerçekleştirilmektedir. Sınıflandırma işlemi için sinir ağları mimarisi ve keras derin öğrenme kütüphanesi araçlarından yararlanır. Uygulama sonuçları sınıflandırma başarımının % 98 civarında olduğunu göstermektedir. Çalışmada hassasiyet, kesinlik, f1-skoru ve karmaşıklık matrisi gibi performans ölçümlerine ait sonuçlar da verilerek yöntemin başarısı desteklenmiştir.

**Anahtar Kelimeler:** Göğüs Kanseri; Sinir Ağları; Çok Katmanlı Algılayıcılar; Keras;

\* Yazışmaların yapılacağı yazar

## Giriş

İnsanlar için doğal ve sezgisel görünen görme ve işitme gibi algıların sonucu olan tanıma ve ayırt etme gibi durumlar makineler için zorlu beceriler olmaktadır. Makinelerin bu gibi problemlerde başarı sağlamasının amaç edinildiği yapay zekâ her geçen gün daha iyiye gitmektedir.

Makina öğrenme tekniklerinden olan derin öğrenme, son zamanlarda oldukça popülerdir. Görüntü işleme, sinyal işleme ve doğal dil işleme gibi birçok problemin çözümünde son teknoloji başarı göstermektedir (Cengil ve Çınar 2017).

Hastalıkların teşhis ve sınıflandırılması alanı derin öğrenme yöntemlerinin kullanıldığı alanlardandır. Hastalıkların tespit edilmesinde kullanılan birçok yöntem bulunmaktadır. Kullanılan yöntemler hastalığın tipine göre değişmektedir.

Göğüs kanseri oldukça yaygın bir şekilde görülmektedir. Ölümlere de yol açan hastalığın erken teşhisi önemlidir. Göğüsteki nodüllere bakılarak hastanın kanser olup olmadığına karar verilmektedir. Göğüsteki nodüller benign ve malignant olarak sınıflandırılmaktadır. Malignant nodüller hastanın kanser olmasını ifade ederken benign nodüller kanser olmayan hastaya işaret etmektedir (Sette et al. 2018).

Literatürde göğüs kanseri tespiti için birçok sınıflandırma tekniği önerilmektedir. Günümüzde, göğüs kanseri sınıflandırma probleminde uzman sistemler ve makine öğrenme teknikleri yaygın olarak kullanılmaktadır. Yüksek sınıflandırma doğruluğu ve etkili teşhis yetenekleri sağlamaktadırlar.

Douangnoulack et al.(2018), PCA kullanarak minimum sınıflandırma kuralları veren en iyi performans sınıflandırıcıyı bulmayı amaçlamaktadır. Çalışmada, Wisconsin Meme Kanseri veri setindeki deney sonuçlarına dayanarak, J48 karar ağacı sınıflandırıcısının üç sınıflandırıcı arasında en iyi olduğu

bulunmaktadır: J48 karar ağacı, Azaltılmış Hata Budama Ağacı ve Rastgele Ağaç.

Amrane et al.(2018), iki farklı sınıflandırıcı sunmaktadır: Meme Kanseri sınıflandırması için Saf Bayes (NB) sınıflandırıcısı ve en yakın komşu algoritması(KNN). İki uygulama arasında bir karşılaştırma yapılmaktadır. Çapraz doğrulama kullanarak hassasiyetleri değerlendirilmektedir. Sonuçlar KNN'nin, NB sınıflandırıcısına (% 96.19) göre en düşük hata oranıyla en yüksek doğruluğu (% 97.51) verdiğini göstermektedir.

Aksebzece vd. (2017), çalışmalarında göğüs kanserinin iyi ve kötü huylu tümör görüntülerini içeren bir görüntü veri seti ile çalışmaktadır. Tümör görüntülerinde doku analizi yapmak; birinci dereceden istatistikler, Gabor ve gri seviye birlikte oluşma matrisi (GLCM) özellikli ekstraksiyon yöntemleri uygulanmaktadır. En yüksek sınıflandırma doğruluğu, Gabor ve GLCM yöntemlerinin özellik kombinasyonu ile Rastgele Ormanlar sınıflandırıcısı tarafından % 82.06'ya ulaşılmaktadır.

Fung Ting et al. (2019), Göğüs Kanseri Sınıflandırmasına Yönelik Konvülsiyonlu Sinir Ağı İyileştirme (CNNI-BCC) adı verilen algoritmayı tıp uzmanlarına meme kanseri teşhisinde zamanında yardım konusunda yardımcı olmak için sunmaktadır. CNNI-BCC, meme kanseri teşhisi uzmanlarına yardımcı olmak için meme kanseri lezyon sınıflandırmasını geliştiren evrişimli bir sinir ağı kullanır. CNNI-BCC, gelen göğüs kanseri tıbbi görüntülerini kötü huylu, iyi huylu ve sağlıklı hastalara sınıflandırmaktadır.

Dora et al.(2017), göğüs kanseri sınıflandırması için yeni bir Gauss-Newton temsil tabanlı algoritma (GNRBA) önermektedir. Eğitim örneği seçiminde seyrek temsili kullanır. Önerilen yöntem, sınıflandırmada en uygun ağırlıkları bulmak için yeni bir Gauss-Newton tabanlı bir yaklaşım getirmektedir. Ek olarak, seyrekliği geleneksel l1-norm yöntemine kıyasla

hesaplamalı olarak verimli bir şekilde değerlendirir. GNRBA'nın etkinliği, UCI Makine Öğrenimi deposundaki Wisconsin Meme Kanseri Veri Tabanı (WBCD) ve Wisconsin Teşhis Meme Kanseri (WDBC) veri tabanında incelenmektedir.

Liu et al.(2019), özellik seçiminde simüle edilmiş tavlama genetik algoritma sargısını (IGSAGAW) yönlendiren bilgi kazanımını kullanan yeni bir meme kanseri akıllı teşhis yaklaşımı önermektedir. Önerilen yaklaşımı, Wisconsin Orijinal Meme Kanseri (WBC) ve Wisconsin Teşhis Meme Kanseri (WDBC) veri setleri üzerinde test edilmektedir.

Toğacar vd (2018), göğüs kanseri sınıflandırma görevi için derin öğrenme yaklaşımlarından biri olan AlexNet yöntemini kullanmaktadır. Çalışma halka açık bir veri seti ile test edilmektedir. Sınıflandırma işlemi Destek Vektör Makineleri ile gerçekleştirilmekte ve % 93,4 oranında doğruluk sağlanmaktadır.

Literatürdeki çalışmalar birçok farklı makine öğrenme algoritması kullanılarak yapılmaktadır. Başarım oranları ise kullanılan veri seti ve probleme göre değişiklik göstermektedir.

Çalışmada, göğüs kanserinin erken teşhisinin önemi vurgulanarak kanser ikili sınıflandırması yapılmaktadır. İşlem için derin öğrenme yöntemi tercih edilmektedir. Popüler kütüphanelerden keras (Francois, 2017) yöntemin gerçekleştirilmesi sırasında kullanılmaktadır. Eğitim ve test işlemleri Breast Cancer Wisconsin (Diagnostic) veri seti kullanılarak sonuçlar gösterilmektedir.

Bu çalışmanın yapısı şu şekildedir; 2. Kısım derin öğrenme yapısını anlatır. 3. Kısım, önerilen yöntem ve deneysel sonuçları ihtiva eder. Son olarak 4. kısım ise çalışmanın sonuçlarını anlatır.

## Çok Katmanlı Algılayıcılar

Geçmişte olasılık ve istatistik ile başlamış olan makine öğrenmesi bazı süreçlerden geçerek önemli ilerlemeler kaydetmiştir. 1950'li yıllarda

yapay zekâ ile uğraşan akademik çevreler bilgisayar görmesi için Yapay Sinir Ağları(YSA) ve Karar Ağaçları yöntemlerini ortaya attı.

YSA, insan beyninin çalışma mekanizmasından esinlenilerek ortaya atılmış bir yöntemdir ve sinir hücrelerinin çalışma şekli simüle edilerek katmanlı ağ yapısı oluşturulmuştur. Bu yapı 1980'li yılların sonundan 2000'li yılların başına kadar geçen sürede büyük başarılar sağlamıştır (Doğan, 2010).

YSA'nın ilk modellerinde doğrusal olan problemlerin çözümleri başarı ile uygulanmıştır. Doğrusal olmayan problemlerin çözümünde ise bu modeller ile fayda sağlanamadığından çok katmanlı algılayıcılar geliştirilmiştir.

ÇKA, doğrusal olmayan problemlerin çözümünde başarılı sonuçlar göstermektedir. Çok katmanlı algılayıcılar, en çok bilinen ve çokça kullanılan sinir ağı türüdür. Çoğu durumda, mimari ileri besleme kullanır. İleri besleme, sinyallerin girişten çıkışa olacak şekilde tek yönde iletilmesidir(Popescu, 2009). Bazı durumlarda ise geri yayılım mimarisi kullanılmaktadır.

Çok katmanlı algılayıcılar, mimarilerinde bir giriş, bir çıkış ve birden fazla gizli katman bulundurlar. Bu katmanlarda kaç tane işlem elemanının olacağı problemin tipine göre değişiklik göstermektedir. Katman sayısı ve katmanlardaki işlem elemanı sayısının kaç olacağının kararını vermek için herhangi bir metot bulunmamaktadır. Buna karar verme süreci deneme yanılma yoluyla sağlanır.

Şekil.1. yöntemde de kullanılmış olan bir Çok Katmanlı Algılayıcı mimarisini vermektedir. Ağda, bir giriş, iki gizli ve bir de çıkış katmanı bulunmaktadır. Katmanlardaki işlem akışı girdi katmanından çıktı katmanına olacak şekilde ileriye doğrudur.

## Önerilen Yöntem

Önerilen yöntemde, keras kütüphanesi göğüs kanseri tanı prosedürü için kullanılır. Keras, python dili ile yazılmış olup Tensorflow, CNTK ve Theano kütüphaneleri üzerinde çalıştırılabilmektedir. Hızlı deneyler sağlamaya odaklanarak geliştirilmiştir (Francois, 2017).

**Tablo 1:** Veri setine ait bazı özellik ve veriler

DIAG NOSİS	RADIÜS _MEAN	TEXTUR E_MEAN	PERİMETE R_MEAN	AREA_ MEAN	SMOOTHN ESS_MEAN	COMPACTN ESS_MEAN	CONCAVİ TY_MEAN	...	FRACTAL_DİME NSİYON_WORST
0	17.99	10.38	122.8	1001	0.1184	0.2776	0.3001	...	0.1189
0	20.57	17.77	132.9	1326	0.08474	0.07864	0.0869	...	0.08902
1	11.52	18.75	73.34	409	0.09524	0.05473	0.03036	...	0.07036
0	14.25	22.15	96.42	645.7	0.1049	0.2008	0.2135	...	0.1132
1	9.173	13.86	59.2	260.9	0.07721	0.08751	0.05988	...	0.0849
1	11.31	19.04	71.8	394.1	0.08139	0.04701	0.03709	...	0.06641
0	19.1	26.29	129.1	1132	0.1215	0.1791	0.1937	...	0.09203
0	14.87	16.67	98.64	682.5	0.1162	0.1649	0.169	...	0.1065
1	11.64	18.33	75.17	412.5	0.1142	0.1017	0.0707	...	0.09097
..	...	....	....	....	....	.....	.....	...	.....

Çalışma, göğüs kanseri sınıflandırması için eğitim ve test işlemlerinde WBDC veri setini kullanır. İşlem üç katmanlı bir sinir ağı ile gerçekleştirilmektedir.

#### a) Veri Seti

Breast Cancer Wisconsin Diagnostic Dataset (WBDC) veri kümesi, 357 benign ve 212 malignant olan 569 örnekten oluşmaktadır. Her bir örnek kimlik numarası, teşhis (B = iyi huylu, M = kötü huylu) ve 30 özellikten oluşmaktadır. Özellikler, bir göğüs kitlesinin ince iğne aspirasyonunun (FNA) sayısallaştırılmış görüntüsünden hesaplanır (Wolbergh et al. 2011). Veri setine ait bazı özellik ve veriler tablo 1'de gösterildiği gibidir. Bu özelliklerden;

Radius\_mean: merkezden çevreye olan noktaların ortalamaları,

Texture\_mean: gri skala değerlerinin standart sapması,

perimeter\_mean: çekirdek tümörünün ortalama büyüklüğü,


Smoothness\_mean: yarıçap uzunluklarındaki yerel varyasyon ortalamasını ifade etmektedirler.

#### b) Ağ Mimarisi

Önerilen yöntemde, üç katmanlı bir sinir ağı keras kütüphanesi ile inşa edilmektedir. İlgili ağ şekil 1.'de görüldüğü gibidir. 30 giriş özelliği ve

bir hedef değişkene sahibiz. Ağ iki tane gizli katman içermektedir. Her gizli katmanın 4 adet düğümü bulunur.

Gizli katmanlar için aktivasyon işlemi olarak Relu kullanılmaktadır. Son katmanda sınıflandırma işlemi için Sigmoid fonksiyonu kullanılmaktadır. İkili sınıflandırma yapıldığı için kayıp fonksiyonu olarak binary crossentropy tercih edilmektedir.



**Şekil 1:** Kullanılan ağ yapısı

#### c) Deneysel Sonuçlar

Sınıflandırma başarımını ölçmek için birçok metriktten faydalanılmaktadır. Bunlardan bazıları kesinlik (precision), hassasiyet (recall), f1-skor (f1-score), karmaşıklık matrisi, Jaccard İndeksi, zar katsayısı (dice coefficient), Accuracy (Doğruluk), Özgünlük (Specificity) metrikleridir (Hossin ve Sulaiman 2015).

İşlemin başarımını sadece doğruluk veya başka herhangi bir metrikle değerlendirmek doğru

olmamaktadır. Birden fazla metriğe bakılması sonucun doğru değerlendirilmesi açısından önem arz etmektedir.

Çalışmada sınıflandırma başarımını ölçmek için kesinlik, hassasiyet, f1-skoru, doğruluk ve karmaşıklık matrisi değerlerine bakıldı. Tablo I, deneysel sonuçları vermektedir. Şekil 2. ise yöntemin test karmaşıklık matrisini göstermektedir.

**Tablo 2:** Deneysel sonuçlar

	PRECİSİON	RECALL	F1- SCORE	SUPPORT
MALİGNANT	0.98	0.98	0.98	42
BENİGN	0.99	0.99	0.99	72

Performans kriterleri hesaplanırken TP, TN, FP ve FN değerlerine bakılmaktadır.

**TP:** Verinin gerçek sınıfı ve tahmin edilen sınıf doğru,

**TN:** Verinin gerçek sınıfı yanlış ve tahmin edilen sınıf yanlış,

**FP:** Verinin gerçek sınıfı yanlış ve tahmin edilen sınıf doğru,

**FN:** Verinin gerçek sınıfı doğru ve tahmin edilen sınıf yanlıştır.

**Doğruluk (Accuracy):** Doğru sınıflandırılan sınıfların tüm sınıflara oranını ifade etmektedir.

$$\text{Doğruluk} = (\text{TP} + \text{TN}) / (\text{TP} + \text{TN} + \text{FP} + \text{FN})$$

$$= (41 + 71) / (41 + 71 + 1 + 1) = 0,98$$

**Kesinlik (Precision):** Pozitif bir sınıftaki toplam öngörülen biçimlerden doğru şekilde öngörülen pozitif kalıpları ölçmek için kullanılır (Hossin ve Sulaiman 2015).

$$\text{Kesinlik} = \text{TP} / (\text{TP} + \text{FP})$$

$$= 41 / (41 + 1) = 0,98$$

**Hassasiyet (Recall):** Doğru pozitiflerin doğru pozitif ve yanlış negatif toplamına oranıdır.

$$\text{Hassasiyet} = \text{TP} / (\text{TP} + \text{FN})$$

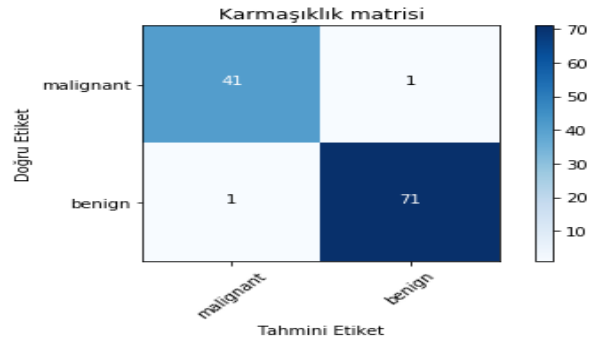
$$= \text{TP} / (\text{TP} + \text{FN}) = 0,98$$

**F1-skor:** Kesinlik ve hassasiyet kavramları üzerinden hesaplanır.

$$\text{F1-skor} = 2 * (\text{Hass.} * \text{Kes.}) / (\text{Hass.} + \text{Kes.})$$

$$= 2 * (0,98 * 0,98) / (0,98 + 0,98) = 0,98$$

**Karmaşıklık matrisi:** Modelin doğruluğunu bulmak için kullanılan en basit ve sezgisel metriklerden bir tanesidir.



**Şekil 2:** Modelin test ve karmaşıklık matrisi


Şekil 3. ve Şekil 4. ağız eğitimine ait doğruluk ve kayıp grafiklerini vermektedir. Verilen grafiklerde modelin kaybının 0,1 ve başarımının % 98 civarında olduğu görülmektedir. Veri setindeki değerlerin %80'i eğitim ve %20'si test için kullanılmıştır.

**Tablo 3:** Karmaşıklık Matrisleri


		B	M
GNRBA	MALİGNANT ÖRNEKLER	131	0
	BENİGN ÖRNEKLER	2	39
BİZİMKİ	MALİGNANT ÖRNEKLER	41	1
	BENİGN ÖRNEKLER	1	71

Test için kullanılan 114 veriden 72 tanesi benign ve kalan 42 tanesi ise malignant örnektir. Tablo 3. giriş kısmında bahsedilen bir çalışma ile çalışmamızın sonuçlarını vermektedir. Dora ve arkadaşlarının yöntemi olan, GNRBA ismi verilen yöntem, veri setinde işlem yaparken verileri farklı oranlarda eğitim ve test kısımlarına bölmüştür. Bizim çalışmaya en yakın olduğundan %70 eğitim ve %30 test olarak kısımlandırılan uygulamanın sonucu gösterilmiştir. GNRBA yöntemi, kendi çalışmalarında önceki çalışmalarla kıyaslandığında en iyi sonuçları göstermiştir. Bizim çalışmamız ile ise yaklaşık olarak aynı sonuçları vermektedir.

Tablo 2’de ise çalışmamıza ait kesinlik, hassasiyet ve f1-skoru performans kriterleri verilmektedir.



Şekil 3: Modelin eğitim kayıp grafiği



Şekil 4: Modelin eğitim Doğruluk grafiği

## Sonuç

Bu çalışma göğüs kanseri erken teşhisine dikkat çekmektedir. Göğüs kanseri nodülü sınıflandırması malignant ve benignidir. Çalışmada, sınıflandırma işlemi için bir sinir ağı tercih edilmektedir. WBDC veri seti kullanılarak yapılan deneylerle önerilen yöntemin başarımı bazı metrikler ile gösterilmektedir. Sonuçlar, kanser sınıflandırmada yöntemin başarısını ortaya koymaktadır.

## Kaynaklar

Cengil E., Çınar, A., (2017). Image classification with caffe deep learning framework. In Computer Science and Engineering (UBMK), International Conference on (pp. 440-444). IEEE.

Sette G., Salvati V., Giordani I., Pillozzi E., Quacquareni D., Duranti E., De Nicola F., Pallocca M., Fanciulli M., Falchi M., Pallini R., Conditionally reprogrammed cells (CRC) methodology does not allow the in vitro expansion of patient-derived primary and metastatic lung

cancer cells. *International journal of cancer*. 2018.

Phonethep D., Boonjing V., Building Minimal Classification Rules for Breast Cancer Diagnosis. *2018 10th International Conference on Knowledge and Smart Technology (KST)*. IEEE, 2018.

Amrane M., Oukid S., Gagaoua I., Ensarî T., Breast cancer classification using machine learning. In *2018 Electric Electronics, Computer Science, Biomedical Engineerings' Meeting (EBBT)* (pp. 1-4). IEEE. 2018.

Aksebzeçi H. B., ve Kayaaltı Ö., Computer-aided classification of breast cancer histopathological images. *Medical Technologies National Congress (TIPTEKNO)*, 2017. IEEE, 2017.

Ting, F.F., Yen J.T., and Kok S. S., Convolutional neural network improvement for breast cancer classification. *Expert Systems with Applications* 120 (2019): 103-115.

Dora, L., Agrawal S., Panda R. And Abraham A., Optimal breast cancer classification using Gauss–Newton representation based algorithm." *Expert Systems with Applications* 85 (2017): 134-145.

Liu N., Qi E.S., Xu M., Gao B., Liu G.Q., A novel intelligent classification model for breast cancer diagnosis. *Information Processing & Management*, 56(3), 609-623, 2019.

Toğacar M., and Ergen B., Deep Learning Approach For Classification Of Breast Cancer. *2018 International Conference on Artificial Intelligence and Data Processing (IDAP)*. IEEE, p. 1-5, 2018.

Francois C., *Deep learning with python*. Manning Publications Co., 2017.

Doğan G., (2010). Yapay Sinir Ağları Kullanılarak Türkiye’deki Özel Bir Sigorta Şirketinde Portföy Değerlendirmesi, Yüksek Lisans Tezi, Hacettepe Üniversitesi, İstatistik Bölümü.

Popescu, Marius-Constantin, et al. "Multilayer perceptron and neural networks." *WSEAS Transactions on Circuits and Systems* 8.7 (2009): 579-588.

Wolbergh W.H., Street W.N., Mangasarian OL. March 2011. Breast Cancer Wisconsin (Diagnostic) Data Set.

Hossin M., and Sulaiman M.N., "A review on evaluation metrics for data classification evaluations." *International Journal of Data Mining & Knowledge Management Process* 5.2 (2015): 1.

## Cancer Classification by Breast Data Metrics

### Extended abstract

*Breast cancer is one of the most common cancers in the world. The disease can lead to death if not diagnosed early. Correct classification of breast cancer tumor is a challenging problem in the medical field. There are many machine learning methods for cancer diagnosis. Deep learning has become a popular method in recent years.*

*The latest technology is used to solve many problems according to performance criteria. Binary or multiple classification is a popular area where neural network based methods are used.*

*In this study, dual classification of cancer, not cancer, is performed using the Breast Cancer Wisconsin (Diagnostic) data set, which includes metric data extracted from the biopsy specimen using needle aspiration technique. The Wisconsin Diagnostic Dataset (WBDC) data set for Breast Cancer consists of 569 samples, 357 benign and 212 malignant. Each sample identification number consists of identification (B =benign, M = malignant) and 30 features. Properties are calculated from the digitized image of fine needle aspiration (FNA) of a breast mass.*

*Neural networks architecture and keras deep learning library tools are used for the classification process. In the proposed method, the keras library is used for breast cancer diagnostic procedure. Keras is written in python and can be run on Tensorflow, CNTK and Theano libraries. Developed with a focus on providing quick experiments.*

*In the method, a three-layer neural network is constructed with a library of keras. We have 30 input properties and one target variable. The network comprises two hidden layers. Each hidden layer has 4 nodes. Relu is used as the activation process for hidden layers. In the last layer, sigmoid function is used for classification. Since binary classification is made, binary crossentropy is preferred as loss function.*

*In this study, the results of performance measurements such as precision, accuracy, f1-score and complexity matrix were given and the success of the method was supported. Application results show that the classification performance is around 98%.*

**Keywords:** Breast Cancer; Neural Networks; Multilayer Perceptrons; Keras.