

Mamografik Kitle Sınıfının Makine Öğrenmesi Teknikleri ile Tespiti

Ömer ERİŞ^{1*}, Seval BULUT ERİŞ¹, Mehmet Recep BOZKURT²



¹Bursa Uludağ Üniversitesi, İnegöl Meslek Yüksekokulu, Elektrik ve Enerji Bölümü, İnegöl, Bursa

²Sakarya Üniversitesi, Mühendislik Fakültesi, Elektrik-Elektronik Mühendisliği Bölümü, Sakarya
(ORCID: [0000-0003-1687-5912](https://orcid.org/0000-0003-1687-5912)) (ORCID: [0000-0001-8681-1848](https://orcid.org/0000-0001-8681-1848)) (ORCID: [0000-0003-0673-4454](https://orcid.org/0000-0003-0673-4454))

Anahtar kelimeler: GINI algoritması, Karar ağaçları, Yapay sinir ağları, İleri beslemeli geri yayımlı ağ, Mamografi, Hata matrisi.

Öz

Meme kanseri, dünyada kadınlar arasında ölüme neden olabilen kanser tiplerinin en sık görülenlerinden biridir. Günümüzde meme kanseri teşhisinde farklı görüntüleme yöntemleri kullanılmakla birlikte bu yöntemler zaman zaman gereksiz biyopsiye yönlendirebilmektedir. Bu çalışmada, makine öğrenmesi tekniklerinden, karar ağaçları ve yapay sinir ağları yöntemleri kullanılarak mamografik kitlenin sınıfı, hastaya ve kitleye ait özelliklerin değerinden tespit edilmiştir. Karar ağaçlarında, GINI algoritması kullanılmış ve RapidMiner programından yararlanılmıştır. Yapay sinir ağlarında, ileri beslemeli geri yayımlı ağ modeli MATLAB’de yazılan program aracılığı ile kullanılmıştır. Bu çalışmada kullanılan veri seti, Erlangen-Nuremberg Üniversitesi, Radyoloji Enstitüsü, Jinekolojik Radyoloji bölümünden elde edilen 961 örnekten oluşmaktadır. Her örnek için 5 adet özellik mevcuttur. Bu özellikler, BI-RADS (meme görüntüleme raporlama ve veri sistemleri) değerlendirmesi, yaş, kitle şekli, kitlenin kenar boşluğu ve kitlenin yoğunluğu bilgilerini içermektedir. Yaklaşımımız, mamografide tespit edilen kitleleri iyi huylu ve kötü huylu olmak üzere iki farklı sınıfa ayırmaktadır. Her iki yöntemin performanslarının karşılaştırılması, doğruluk, duyarlılık, kesinlik, seçicilik, F-skor ve AUC (eğri altındaki alan) değerlerine bakılarak yapılmıştır.

Detection of Mammographic Mass Class with Machine Learning Techniques

Keywords: GINI algorithm, Decision trees, Artificial neural networks, Feed forward back propagation network, Mammography, Confusion matrix.

Abstract

Breast cancer is one the most common types of cancers among the women in the world. Today different scanning techniques have been used to diagnose breast cancers but these methods are sometimes directed to unnecessary biopsy. In this study, the class of the mammographic mass was determined from the values of the characteristics of the patient and the mass by using decision trees and artificial neural networks methods, which are machine learning techniques. GINI algorithm is used in decision trees and RapidMiner program was used. In artificial neural networks, feed forward back propagation network model is used through the program written in MATLAB. The data set used in this study is consisted of 961 samples obtained at Erlangen-Nuremberg University, Institute of Radiology, Department of Gynecological Radiology. There are 5 attributes in each sample. These attributes contain BI-RADS (breast imaging reporting and data systems) value, age, mass shape, mass margin and information about mass density. Our approach distinguished the masses contained at mammography into two different groups as benign and malign masses. Comparison of the performances of both methods was made by looking at the values of accuracy, sensitivity, precision, selectivity, F-score and AUC (area under the curve).

*Sorumlu yazar: omereris@uludag.edu.tr

Received: 04.10.2021, Accepted: 12.11.2021

1. Giriş

Meme kanseri, memenin süt üreten bezlerindeki anormal hücrelerin kontrolsüz büyümesi ile karakterizedir. Gelişmiş ülkelerin çoğunda kadınlar arasında en sık görülen tümör tipidir. Farklı meme tümörleri sistematik bir şekilde tedaviye yanıt verirler. Bu sebeple meme kanserinin doğru sınıflandırılması ve erken teşhisi önemlidir. Kanserinin erken teşhisi hayatta kalma oranını artırabilir, ancak erken evrede kanseri tespit etmek zordur [1].

Günümüzde meme kanseri taramasında standart inceleme yöntemi mamografidir. Bununla birlikte, mamogram yorumunun düşük pozitif öngörü değeri nedeniyle, iyi huylu sonuçlanan yaklaşık %70 oranında gereksiz biyopsiye yol açmaktadır. Gereksiz sayıda meme biyopsisini azaltmak için, son yıllarda birkaç bilgisayar destekli tanı (CAD) sistemi önerilmiştir. Bu sistemler, doktorlara, mamografide görülen şüpheli bir kitlede meme biyopsisi yapma veya bunun yerine kısa süreli takip muayenesi yapma kararlarında yardımcı olur [2].

Meme kanserlerinin tanısında, ultrasonografi (US), manyetik rezonans görüntüleme (MRG) ve nükleer tıp gibi alternatif görüntüleme yöntemlerinin kullanılabilirliği de bildirilmektedir [3].

Radyolojik yöntemlerin yorumlanmasında disiplinler arası standardizasyon sağlanabilmesi için BI-RADS sınıflandırması kullanılmaya başlanmıştır. Buna göre kanser olguları, iyi huylu (benign) veya kötü huylu (malign) kitleler olarak sınıflandırılmaktadır [4].

Fondón ve ark. (2018), histolojik görüntülerin işlenmesine dayanarak meme dokusu örneklerinin otomatik malignite değerlendirmesi için CAD sistemi önermişlerdir. Sistemin çıktısı olarak dört düzey sunmaktalar: normal, iyi huylu, noninvasive (yayılma eğilimi olmayan) ve invasive (yayılma eğilimi olan). Yöntem, çekirdeğe, renk bölgelerine ve dokulara ilişkin üç özellik kümesinin yerel özellikleri ve küresel görüntü özelliklerini dikkate alarak hesaplanmasına dayanır. Yerleşik görüntü işleme tekniklerinden yararlanarak, her görüntü için ikinci dereceden bir çekirdeğe sahip bir destek vektör makinesi (SVM) sınıflandırıcısına girdi görevi gören bir özellik vektörü oluşturulmuştur. Deneysel

sonuçlar, önerilen yöntemin, dört düzeyi yüksek doğrulukla ayırt edebildiğini göstermiştir [5].

Helwan ve ark. (2017), iki makine öğrenme tekniğini kullanarak meme dokusunun otomatik sınıflandırmasını sunmaktadırlar: Geri yayılma öğrenme algoritması (back propagation neural network - BPNN) ve radyal temelli fonksiyon ağı (radial basis function network - RBFN). Meme dokusu sınıflandırması için en iyi modeli tanımlamayı amaçlamışlardır. Veri toplamada elektriksel empedans spektroskopisi yöntemi kullanılırken, BPNN ve RBFN sınıflandırma görevinin yerine getirilmesinde kullanılan modellerdir. Yaklaşım özellik çıkarma, özellik seçimi ve sınıflandırma adımlarından oluşmaktadır. İki algoritmanın performans ölçümü, BPNN ve RBFN modellerinin doğruluklarına bakılarak yapılmıştır. RBFN, meme dokusunun sınıflandırılmasındaki doğruluk, minimum karesel hata (MSE) ve öğrenme süresi açısından BPNN'den daha iyi performans gösterdiğini ortaya koymuşlardır [6].

Vo ve ark. (2019), meme kanseri sınıflamasında en kullanışlı görsel özellikleri çıkarmak için evrişimli katmanları olan derin öğrenme modelini (deep convolutional neural network) kullanan bir yaklaşım önermişlerdir. Sistem hematoksilen ve eozin lekeli meme biyopsi görüntülerini iki ana gruba (karsinom ve karsinom olmayan) ve dört sınıfa (normal dokular, iyi huylu lezyonlar, in situ karsinomlar ve invaziv karsinomlar) ayırmak için kullanılır. Elde ettikleri sonuçlara göre, meme kanseri sınıflandırıcısının, derin öğrenme modeli ile gelişmiş teknolojilerden daha iyi performans gösterdiğini ortaya koymuşlardır [7].

Bu çalışmada, karar ağaçları ve yapay sinir ağları yöntemleri kullanılarak doğru tedaviyi mümkün olduğunca erken tanımlamak için, mamografik kitle verilerinden yararlanarak meme kitlelerini iyi huylu ve kötü huylu olarak yüksek doğruluk, duyarlılık ve seçicilik ile sınıflandırılması amaçlanmıştır. Çalışmada meme kitlelerinin sınıflandırıldığı birey sayısı 961'dir. Sınıflandırmak için kullanılan özellikler; BI-RADS, yaş, kitlenin biçimi, kitlenin kenarı ve kitlenin yoğunluğu olmak üzere 5 adettir. Kullanılan veri setinde BI-RADS için 2, yaş için 5, kitlenin biçimi için 31, kitlenin kenarı için 48 ve kitlenin yoğunluğu için 76 adet eksik veri bulunmaktadır.

2. Materyal ve Metot

2.1. Verilerin Toplanması

Uygulamada kullanılacak olan mamografik kitle veri seti “uci machine learning repository” sitesinden alınmıştır. Veri kümesinin orijinal değerleri Erlangen-Nuremberg Üniversitesi, Radyoloji Enstitüsü, Jinekolojik Radyoloji bölümünden Prof. Dr. Rüdiger Schulz-

Wendtland tarafından elde edilmiştir. Veri setinde eksik veriler bulunmakla birlikte toplam 961 adet örnek bulunmaktadır. Her bir örneğe ait 5 adet nitelik verisiyle birlikte toplam 4805 verinin 162 adedi eksiktir. Nitelik değerleri, mamografik görüntülemeye elde edilmiştir. 961 örnekten, 516’sı benign kitle iken, 445’i malign kitledir. Veri setinde bulunan nitelikler ve değer aralıkları Tablo 1’de, bu niteliklerin sınıfı ve değer aralıkları Tablo 2’de verilmiştir.

Tablo 1. Mamografik kitle veri setindeki özellikler ve değer aralıkları

Özellikler	Sembol	Değerler	Açıklama
BI-RADS değerleri	Bi-rads	1-5	1-5 arasında tamsayı değerleri
Yaş	Age	18-96	Minimum 18, maksimum 96 arasında tamsayı değerleri
Kitlenin Biçimi	Shape	1-4	Yuvarlak (Round) = 1 Oval (oval) = 2 Lobüler (Lobular) = 3 Şekilsiz (irregular) = 4
Kitlenin Kenarı	Margin	1-5	Keskin Sınırlı (circumscribed) = 1 Mikrolobüler (microlobulated) = 2 Çevre doku tarafından gizlenmiş (obscured) = 3 Sınırları Belirsiz (ill-defined) = 4 Spiküle (spiculated) = 5
Kitlenin Yoğunluğu	Density	1-4	Yüksek Yoğunluklu (High) = 1 İzodens – Parankimle eş (iso) = 2 Düşük Yoğunluklu (low) = 3 Yağ Yoğunluklu (fat-containing) = 4

Tablo 2. Mamografik kitle veri setindeki özelliklerin sınıfı ve değer aralıkları

Özellikler	Sembol	Değerler	Açıklama
Sınıf	Severity	0-1	İyi Huylu kitle (Benign) = 0 Kötü Huylu kitle (Malign) = 1

2.2. Eksik Verilerin Tamamlanması

Eksik verilerin tamamlanmasında k-en yakın komşu (kNN) algoritması kullanılmıştır. Bu algoritma, daha önceden değeri bilinen k adet veriyi kullanarak değeri bilinmeyen veriyi tahmin eden bir algoritmadır. k adet veri, değeri tahmin edilecek veriye en yakın veri grubundan seçilir. Çeşitli makine öğrenme algoritmaları arasında kNN, uygulamasının basit ve hızlı olması, nispeten yüksek doğruluğa sahip olması, gürültülü verilere karşı da dayanıklı olup başarılı sonuçlar elde edebilmesi nedeniyle eksik verilerin tamamlanmasında tercih edilmiştir [8,9].

İki veri arasındaki yakınlık, öklid mesafe hesaplama ile eşitlik 1 kullanılarak belirlenmiştir.

Öklid mesafesi, 2 boyutlu çözüm kümesi örneğinde x düzlemindeki doğrusal uzaklık x_i 'ye ve y düzlemindeki doğrusal uzaklık y_i 'ye bağlı olarak bulunabilir [10].

$$\text{Öklid Mesafesi} = \sqrt{\sum_{i=1}^k (x_i - y_i)^2} \quad (1)$$

Komşuluk değeri k için farklı değerler kullanılarak, en iyi sonucu k=5 değerinin verdiği belirlenmiştir.

Veri setinin bir kesitine ait, Tablo 3'te orijinal ekran görüntüsü ve Tablo 4'te eksik verilerin tamamlandığı ekran görüntüsü verilmiştir.

Tablo 3. Orijinal veri setinden bir kesit

BI-RADS	Yaş	Kitlenin Biçimi	Kitlenin Kenarı	Kitlenin Yoğunluğu	Kitlenin Sınıfı
5	67	3	5	3	Kötü Huylu
4	43	1	1		Kötü Huylu
5	58	4	5	3	Kötü Huylu
4	28	1	1	3	İyi Huylu
5	74	1	5		Kötü Huylu
4	65	1		3	İyi Huylu
4	70			3	İyi Huylu
5	42	1		3	İyi Huylu
5	57	1	5	3	Kötü Huylu
5	60		5	1	Kötü Huylu
5	76	1	4	3	Kötü Huylu
3	42	2	1	3	Kötü Huylu
4	64	1		3	İyi Huylu
4	36	3	1	2	İyi Huylu

Tablo 4. Eksik verileri tamamlanmış veri setinden bir kesit

BI-RADS	Yaş	Kitlenin Biçimi	Kitlenin Kenarı	Kitlenin Yoğunluğu	Kitlenin Sınıfı
5	67	3	5	3	Kötü Huylu
4	43	1	1	2.63	Kötü Huylu
5	58	4	5	3	Kötü Huylu
4	28	1	1	3	İyi Huylu
5	74	1	5	3	Kötü Huylu
4	65	1	1	3	İyi Huylu
4	70	2.75	1.57	3	İyi Huylu
5	42	1	1	3	İyi Huylu
5	57	1	5	3	Kötü Huylu
5	60	3.8	5	1	Kötü Huylu
5	76	1	4	3	Kötü Huylu
3	42	2	1	3	Kötü Huylu
4	64	1	1	3	İyi Huylu
4	36	3	1	2	İyi Huylu

2.3. Min-Max Normalizasyonu

Veriler tamamlandıktan sonra farklı minimum-maksimum aralıklarında buldukları için “min-max normalizasyonu” yöntemi ile veriler eşitlik 2 kullanılarak, Tablo5’te görüldüğü gibi 0-1 arasına normalize edilmiştir.

$$xi' = \frac{(xi - \min(x))}{(\max(x) - \min(x))} \quad (2)$$

xi' = 0-1 arasına normalize edilmiş veri
xi = Orijinal veri
min(x) = Orijinal verideki minimum değer
max(x) = Orijinal verideki maksimum değer

Tablo 5. Normalize edilmiş veri setinden bir kesit

BI-RADS	Yaş	Kitlenin Biçimi	Kitlenin Kenarı	Kitlenin Yoğunluğu	Kitlenin Sınıfı
0.09	0.63	0.67	1.00	0.67	1.00
0.07	0.32	0.00	0.00	0.54	1.00
0.09	0.51	1.00	1.00	0.67	1.00
0.07	0.13	0.00	0.00	0.67	0.00
0.09	0.72	0.00	1.00	0.67	1.00
0.07	0.60	0.00	0.00	0.67	0.00
0.07	0.67	0.58	0.14	0.67	0.00
0.09	0.31	0.00	0.00	0.67	0.00
0.09	0.50	0.00	1.00	0.67	1.00
0.09	0.54	0.93	1.00	0.00	1.00
0.09	0.74	0.00	0.75	0.67	1.00
0.05	0.31	0.33	0.00	0.67	1.00
0.07	0.59	0.00	0.00	0.67	0.00
0.07	0.23	0.67	0.00	0.33	0.00

2.4. GINI Algoritması

GINI algoritması karar ağacı oluşturulmasında kullanılan bir algoritmadır. Sınıflandırma ve regresyon ağacı (CART) olarak tanımlanır [11].

CART, kendi kendini yenileyen ikili olarak dallara ayrılan yapıdadır. Dallara ayrılma ölçütü olarak GINI indeksinden yararlanan CART, durmadan daima bölünerek büyümekte ve ağacı oluşturmaktadır [12,13]. Bölünemediği durumda uçtan köke doğru budama işlemi gerçekleştirir. Muhtemel en başarılı karar ağacı her budama işleminden sonra bağımsız seçilmiş test verisi ile değerlendirilerek tespit edilmeye çalışılır [12,14].

Bir niteliğin $GINI_{sol}$ ve $GINI_{sağ}$ değerleri ve bu değerler kullanılarak hesaplanan GINI değeri sırasıyla eşitlik 3, 4 ve 5'te gösterildiği gibi yapılmaktadır.

$$GINI_{sol} = 1 - \sum_{i=1}^k \left[\frac{L_i}{|T_{sol}|} \right]^2 \quad (3)$$

$$GINI_{sağ} = 1 - \sum_{i=1}^k \left[\frac{R_i}{|T_{sağ}|} \right]^2 \quad (4)$$

$$GINI_j = \frac{1}{n} (|T_{sol}|GINI_{sol} + |T_{sağ}|GINI_{sağ}) \quad (5)$$

k = Sınıfların sayısı

T = Bir düğümdeki örnek sayısı

T_{sol} = Sol koldaki örneklerin sayısı

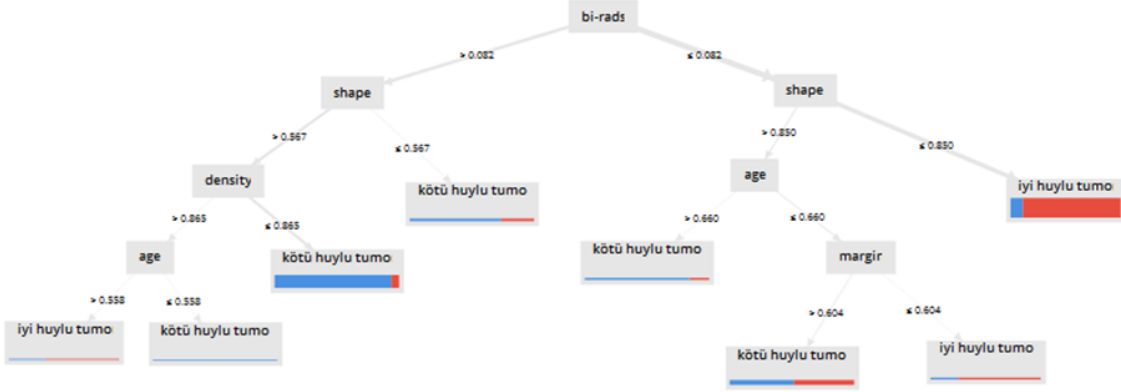
$T_{sağ}$ = Sağ koldaki örneklerin sayısı

L_i = Sol kolda i kategorisindeki örneklerin sayısı

R_i = Sağ kolda i kategorisindeki örneklerin sayısı

Her bir nitelik için hesaplanan GINI değerleri arasından en küçük olanı seçilir ve bölünme bu nitelik üzerinden gerçekleşir. Kalan veri seti üzerinde yukarıda bahsedilen adımlar tekrar uygulanır ve diğer bölünme hesaplanır [11].

Bu çalışmada, hazırlanan veri setinde önce son sütun karar niteliği olarak etiketlenmiştir. Ardından veri setinin %70'i eğitim ve %30'u test için ayrılmıştır. Eğitim için ayrılan %70'lik veri karar ağaçlarından GINI algoritması kullanılarak eğitilmiştir. Karar ağaçlarının maksimum derinliği denemeler sonucunda 5 olarak belirlenmiştir. Karar ağacı yapısı Şekil 1'de ve bu yapının açıklamasına ait ekran görüntüsü Şekil 2'de verilmiştir.



Şekil 1. Karar ağacı yapısı

```

bi-rads > 0.082
| shape > 0.567
| | density > 0.865
| | | age > 0.558: iyi huylu tumor {kötü huylu tumor=1, iyi huylu tumor=2}
| | | age <= 0.558: kötü huylu tumor {kötü huylu tumor=2, iyi huylu tumor=0}
| | density <= 0.865: kötü huylu tumor {kötü huylu tumor=196, iyi huylu tumor=13}
| shape <= 0.567: kötü huylu tumor {kötü huylu tumor=22, iyi huylu tumor=8}
bi-rads <= 0.082
| shape > 0.850
| | age > 0.660: kötü huylu tumor {kötü huylu tumor=16, iyi huylu tumor=3}
| | age <= 0.660
| | | margin > 0.604: kötü huylu tumor {kötü huylu tumor=35, iyi huylu tumor=33}
| | | margin <= 0.604: iyi huylu tumor {kötü huylu tumor=4, iyi huylu tumor=12}
| shape <= 0.850: iyi huylu tumor {kötü huylu tumor=36, iyi huylu tumor=290}
    
```

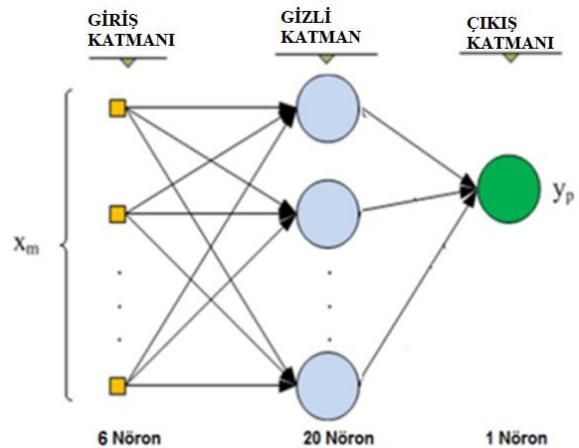
Şekil 2. Karar ağacı yapısının açıklaması

2.5. İleri Beslemeli Geri Yayılımlı Yapay Sinir Ağları


Yapay sinir ağları modelinde; giriş, gizli ve çıkış olmak üzere üç farklı katman bulunmaktadır. Her katman bir ya da birden çok nörondan oluşmakta ve katmanlar birbirlerine aralarında ağırlık kümeleri ile bağlanmaktadır. Bağlanma şekli ve her kısımdaki nöron sayısı değişebilmektedir.

Yapay sinir ağı, Şekil 3'te görüldüğü gibi giriş katmanı 6 nöron, gizli katman 20 nöron ve çıktı katmanı 1 nörona oluşmaktadır. Aynı katmandaki nöronlar arasında iletişim yoktur. Nöronlar girdiyi ya başlangıç girdilerinden ya da ara bağlantılardan almaktadır.

Bu çalışmada, Şekil 4'te akış şeması görülen ileri beslemeli geri yayılımlı yapay sinir ağı modeli, MATLAB ortamında yazılan program ile gerçekleştirilmiştir.



Şekil 3. Yapay sinir ağı yapısı



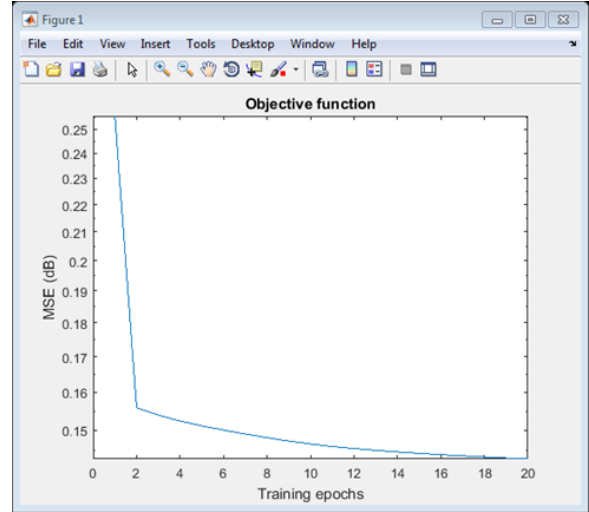
Şekil 4. İleri beslemeli geri yayımlı öğrenme algoritmasının kullanılması [15]

Bu algoritma iki aşamadan oluşmaktadır:

1. Çıkış katmanındaki çıktı, bilgi sinyali hesaplamak için giriş nöronlarındaki dış girdi bilgisini ileriye doğru ileten bir ileriye doğru besleme aşaması
2. Çıkış katmanındaki hesaplanan ve gözlenen bilgi sinyalleri arasındaki farklara dayanarak bağlantı kuvvetleri üzerinde değişikliklerin yapıldığı bir geriye doğru ilerleme aşaması [13].

Ağı eğitme sürecinin başında, ağırlık katsayıları rastgele değerler olarak atanmaktadır. Öğrenme algoritması her eğitim turunda ağırlık katsayılarını, hata minimum olacak şekilde değiştirmektedir. Yapılan çalışmaya ait ağırlık katsayılarına bağlı MSE grafiği Şekil 5'de gösterilmiştir.

Yeni bir girdi grubu sunulduğunda, ileriye doğru besleme ile yapay sinir ağlarının bağlantı kuvvetlerindeki öğrenilmiş ve saklanan bilgi sayesinde bir çıktı grubu elde edilmektedir [16].



Şekil 5. Hata-eğitim turu sayısı grafiği

2.6. Başarı Ölçütleri

Bu çalışmada; hata matrisinden elde edilen doğruluk, duyarlılık, kesinlik, seçicilik, F-skor değerleri ve ROC (Alıcı işlem karakteristikleri, Receiver Operating Characteristic) eğrisinden elde edilen AUC değeri başarı ölçütleri olarak kullanılmıştır.

Hata matrisi, çıktının 2 ya da daha fazla sınıf olduğu makine öğrenmesi sınıflandırmalarında bir performans ölçümüdür. 2 çıktının olduğu sınıflandırmalar, Şekil 6'da görüldüğü gibi tahmini ve gerçek değerlerden oluşan 4 farklı durumdan oluşur.

		Gerçek Değerler	
		Pozitif (1)	Negatif (0)
Tahmin Edilen Değerler	Pozitif (1)	TP	FP
	Negatif (0)	FN	TN

Şekil 6. Hata matrisi

TP (True Positive) = Gerçekte iyi huylu tümörü, iyi huylu tahmin etme

TN (True Negative) = Gerçekte kötü huylu tümörü, kötü huylu tahmin etme

FP (False Positive) = Gerçekte kötü huylu tümörü, iyi huylu tahmin etme

FN (False Negative) = Gerçekte iyi huylu tümörü, kötü huylu tahmin etme

Hata matrisindeki değerler kullanılarak çeşitli başarı ölçütleri geliştirilmiştir. Bunlardan en yaygın kullanılanı doğruluktur. Doğruluk sınıflandırıcı tarafından yapılan doğru

tahminlerin bir ölçüsüdür ve kaç örneğin doğru ya da yanlış sınıflandırıldığı hakkında bilgi verir. Doğruluk, eşitlik 6 kullanılarak hesaplanır [17].

$$\text{Doğruluk} = \frac{TP + TN}{TP + TN + FP + FN} \quad (6)$$

Duyarlılık, gerçekte pozitif olan değerlerin ne kadarının pozitif olarak tahmin edildiğini gösteren bir ölçüttür ve eşitlik 7 kullanılarak hesaplanır [17].

$$\text{Duyarlılık} = \frac{TP}{TP + FN} \quad (7)$$

Kesinlik, pozitif olarak tahmin edilen değerlerden kaç tanesinin gerçekte pozitif olduğunu gösterir ve eşitlik 8 kullanılarak hesaplanır [17].

$$\text{Kesinlik} = \frac{TP}{TP + FP} \quad (8)$$

Seçicilik, gerçekte negatif olan değerlerin ne kadarının negatif tahmin edildiğinin bir göstergesidir ve eşitlik 9 kullanılarak hesaplanır [17].

$$\text{Seçicilik} = \frac{TN}{TN + FP} \quad (9)$$

F-skoru, duyarlılık ve kesinlik değerlerinin harmonik ortalamasını gösterir. Özellikle eşit dağılmayan veri kümelerinde doğruluk ile kıyaslandığında daha başarılı bir ölçüttür. Eşitlik 10 kullanılarak hesaplanır [17].


F-skor değeri 0-1 arasında değişir. 0 en kötü değeri gösterirken, 1 en iyi değeri göstermektedir [18].

$$F - \text{skor} = \frac{2 * \text{Duyarlılık} * \text{Kesinlik}}{\text{Duyarlılık} + \text{Kesinlik}} \quad (10)$$

ROC eğrileri, sonuç değişkenlerinin, iyi huylu kitle-kötü huylu kitle gibi özellikle iki olasılıklı olduğu, sonuç değişkenlerini belirleyen nitelik değişkenlerinin ise kitlenin biçimi, kitlenin kenarı, kitlenin yoğunluğu, yaş, BI-RADS değeri gibi çok olduğu durumlarda kullanılır. ROC eğrileri ile sürekli değişkenler için TP, TN, FP, FN noktaları hakkında kestirimler yapılabilir. Bir testin en iyi kesim noktasının saptanmasına ve farklı tanı testlerinin doğru tanı koymadaki başarısının karşılaştırılmasına olanak sağlar. ROC eğrilerinde; x ekseninde yanlış pozitif oranı ve y ekseninde doğru pozitif oranı yer alır. Farklı eşik değerlerinde doğru pozitif oranı ve yanlış pozitif oranı sırasıyla duyarlılık ve 1-seçicilik

değerleri ile hesaplanır. ROC eğrisi, (0,0) ile (1,1) arasında artan bir fonksiyondur. ROC analizi yapılarak bir testin doğru tanı koymada başarı olup olmadığına karar verilebilir. Testlerin doğru karar vermede başarısının değerlendirilmesinde kullanılan bir diğer ölçütte ROC eğrisi altında kalan alanı gösteren AUC değeridir. Eğri altında kalan alan en büyük 1 değerini alabilir. Pratik olarak alabileceği en küçük değer ise 0.5'tir [19].

ROC eğrilerinde daha kuzey batıdaki nokta daha iyidir. İyi bir ROC eğrisinde, duyarlılık yüksek, 1-seçicilik değeri ise düşük olmalıdır. Koordinat olarak (0,1) noktası en iyi sınıflandırmayı gösterir. Şekil 7'de farklı testlerin karar vermedeki başarıları ROC eğrisinde gösterilmiştir. Buna göre; A testi (0,1) noktası ile mükemmel bir testtir çünkü ROC eğrisi altında kalan alan 1'dir. Buna karşılık D testi en başarısız testtir. Çünkü ROC eğrisi altında kalan alanı 0.5'tir [19].



Şekil 7. ROC Eğrisi

3. Bulgular ve Tartışma

Eğitim verileri kullanılarak çıkarılan karar ağaçları kuralları, veri setinden ayrılan %30'luk test verilerini tahmin etmek için kullanılmıştır. İleri beslemeli geri yayımlı yapay sinir ağı yapısında da MATLAB ortamında yazılan kodlar ile aynı oranlar kullanılarak testin performansı ölçülmüştür.

Karar ağaçları ve yapay sinir ağları yöntemlerinin hata matrisleri ve başarı ölçütleri sırasıyla Tablo 6 ve Tablo 7'de gösterilmiştir. Tablo 6 ve Tablo 7 incelendiğinde karar ağaçları %82.99, yapay sinir ağları %80.55 doğruluğa sahip oldukları görülmektedir. Karar ağaçları 239 doğru sınıflandırma ve 49 yanlış sınıflandırma, yapay sinir ağları 232 doğru sınıflandırma ve 56 yanlış sınıflandırma yapmışlardır.

Karar ağaçları, %85.71 seçicilik ve %86.8 kesinlik değerleri ile daha iyi performans gösterirken, yapay sinir ağları, %81.33 ile

duyarlılık değeri açısından daha iyi performans göstermiştir.

Tek başına duyarlılık ve kesinliğe bakılarak performans ölçümü yapmak yeterli olmadığından, duyarlılık ve kesinliğin harmonik ortalaması olan F-skor değeri hesaplanmış ve Şekil 8 ve Şekil 9’da görüldüğü gibi her iki yöntemin ROC eğrisi çizdirilmiş ve ROC eğrileri altında kalan alanı ifade eden AUC değeri hesaplatılmıştır.

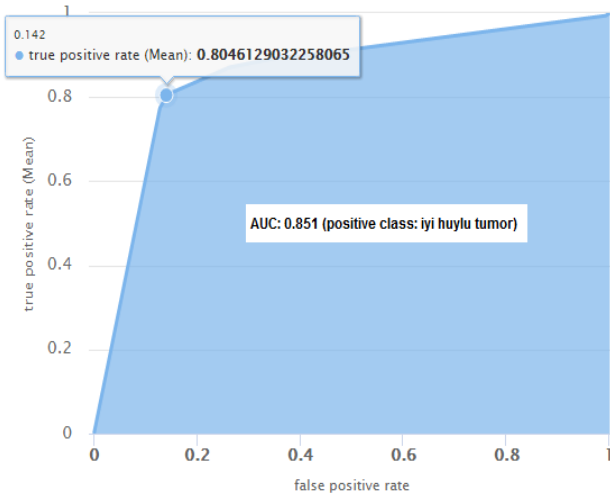
F-skor değeri, karar ağaçları yönteminde 0.836, yapay sinir ağlarında 0.8133 elde edilmiştir. Bu değere bakarak karar ağaçları ile yapılan tahminin yapay sinir ağları ile yapılan tahminden daha başarılı olduğu görülmüştür. Şekil 8 ve Şekil 9’da görülen ROC eğrileri ve bunlara bağlı hesaplanan AUC değerlerine de bakıldığında yine karar ağaçlarının yapay sinir ağlarına kıyasla daha iyi performans gösterdiği görülmektedir.

Tablo 6. Karar ağaçları hata matrisi ve başarı ölçütleri


Karar Ağaçları	Tahmini Değer	Gerçek Değer		Başarı Ölçütleri				
		Kötü Huylu	İyi Huylu	Doğruluk (%)	Duyarlılık (%)	Kesinlik (%)	Seçicilik (%)	F-skor
	Kötü Huylu	114	30	82.99	80.64	86.8	85.71	0.836
	İyi Huylu	19	125					

Tablo 7. Yapay sinir ağları hata matrisi ve başarı ölçütleri

Yapay Sinir Ağları	Tahmini Değer	Gerçek Değer		Başarı Ölçütleri				
		Kötü Huylu	İyi Huylu	Doğruluk (%)	Duyarlılık (%)	Kesinlik (%)	Seçicilik (%)	F-skor
	Kötü Huylu	110	28	80.55	81.33	81.33	79.71	0.8133
	İyi Huylu	28	122					



Şekil 8. Karar ağaçları ROC eğrisi



Şekil 9. Yapay sinir ağları ROC eğrisi

Literatürde hazır veri setleri kullanılarak, çeşitli makine öğrenmesi teknikleri ile meme kanseri teşhisi için yapılmış çalışmalar bulunmaktadır [20-24]. Kullanılan veri setinde; nitelik sayısının fazla olması, önemli olan niteliklerin önceden belli olması, eksik veri bulunmaması ve toplam veri sayısının daha fazla olması gibi sebeplerden dolayı sınıflandırma doğrulukları Tablo 8’de görüldüğü gibi %90’ın üzerinde çıkmıştır [20-23]. Veri setinde eksik verilerin bulunması veya veri setinde bulunan veri sayısının düşüklüğü benzer makine öğrenmesi teknikleri

kullanılmasına rağmen sınıflandırma doğruluğu değerlerinde ciddi düşümlere sebep olmaktadır [24]. Bu açılarından değerlendirildiğinde çalışma, kullanılan veri setinde eksik veriler bulunmasına rağmen yine de tatmin edici sonuçlara ulaşmıştır. Tablo 8’de belirtilen çalışmalarda, elde edilen başarı oranları yüksek doğruluk içermekle birlikte, benzer makine öğrenimi kullanımına rağmen algoritmalar tarafından elde edilen sınıflandırma doğruluklarının farklı olması dikkat çekicidir [20-24]. Etkili bir makine öğrenme modeli tasarlamak, başarılı bir ön işleme, özellik

seçme ve sınıflandırma işlemleri gerektirir [17]. Bu çalışmada, mevcut tüm özellikler kullanılarak sınıflandırma yapılmıştır. Sınıflandırma işleminden önce özellik seçim algoritmaları ile önemli özelliklerin belirlenerek yapılacak bir çalışma, sınıflandırma sisteminin hem hızını hem de başarısını arttıracaktır.

Bu çalışmada, performans sonuçlarında elde edilen değerler hastalığı tespit etmede kabul

edilebilir değerlerdir. Veriler, eksik veri tamamlama algoritması ile tamamlanmayıp; eksiksiz bir şekilde elde edilmiş olması modellerin daha yüksek performans vermelerini sağlayabilirdi. Ayrıca veri çoğaltma algoritmaları kullanılarak veri sayısının artırılması durumunda da yine modellerin daha yüksek performans vermeleri sağlanabilirdi.

Tablo 8. Literatürdeki çalışmaların başarı oranları

Yazar ve Yılı	Veri Sayısı	Veri Seti	Makine Öğrenmesi Teknikleri	Doğruluk (%)
Polat ve Güneş, 2007	683	Wisconsin breast cancer dataset (WBCD)	Destek Vektör Makinesi (SVM)	98.53
Akay, 2009	683	Wisconsin breast cancer dataset (WBCD)	Destek Vektör Makinesi (SVM)	99.51
Mert ve ark., 2015	569	Wisconsin diagnostic breast cancer dataset	a. k-En Yakın Komşu (kNN) b. Yapay Sinir Ağları (ANN) c. Radyal Temelli Fonksiyon Sinir Ağı (RBFNN) d. Destek Vektör Makinesi (SVM)	a. 93.14 b. 97.53 c. 87.17 d. 95.25
Milosevic ve ark., 2015	300	The Mini Mammographic Database	a. Destek Vektör Makinesi (SVM) b. k-En Yakın Komşu (kNN) c. Naive Bayes	a. 83.7 b. 54.3 c. 77.3
Asri ve ark., 2016	699	Wisconsin breast cancer dataset (WBCD)	a. Destek Vektör Makinesi (SVM) b. Karar Ağacı (Decision Tree) c. Naive Bayes d. k-En Yakın Komşu (kNN)	a. 97.13 b. 95.13 c. 95.99 d. 95.27

4. Sonuç ve Öneriler

Bu çalışmada, meme kanseri tümörlerini iyi huylu veya kötü huylu olarak kategorize etmek için karar ağaçları ve yapay sinir ağları olmak üzere iki farklı makine öğrenme yönteminin başarısı incelenmiştir. Uygulamada, karar ağaçları yöntemi için RapidMiner, yapay sinir ağları yöntemi için MATLAB programları kullanılmıştır. Yöntemlerin performanslarını ölçmek için doğruluk, duyarlılık, kesinlik, seçicilik, F-skor, ROC eğrisi ve AUC değerlerine bakılmıştır. Sınıflandırmada, karar ağaçları %82.99 doğruluk, %85.71 seçicilik, %86.8 kesinlik, 0,836 F-skor ve 0.851 AUC değerleri ile yapay sinir ağlarının önüne geçmiştir. Karar

ağaçları sınıflandırma performansı daha başarılı olduğu görülmüştür.

Karar ağaçları incelendiğinde, başlangıç değişkeninin veriyi ikiye ayırdığı ve daha sonra diğer değişkenlerin sonuç olarak çıkan grupları tekrar ayırdığı görülmektedir. Bu durum veriyi analiz ederken arka planındaki işleyişi daha anlaşılır kılmaktadır. Bu durum karar ağaçlarının, yapay sinir ağlarından daha kolay eğitilebilmesini sağlamaktadır. Ayrıca yapay sinir ağlarında oluşturulan modelde değişken seçimi, girdilerin önem düzeyleri hakkında bilgi sahibi olmak açısından önemlidir [25]. Oluşturulan sistemde tüm özellikler kullanılarak ağ eğitilip başarı ölçütleri elde edilmesi nedeniyle yapay sinir ağları, karar ağaçlarından daha düşük

doğruluk elde edilmesine neden olmuştur. Özellik seçimi ile yapılacak bir analiz yapay sinir ağlarının performansını yükseltecektir.

Bu çalışmada, sonuçlarımız Milosevic ve ark.'nın (2015) çalışması ile karşılaştırıldığında [24], kullandığımız veri seti eksik veriler içermesine rağmen aynı makine öğrenmesi teknikleri (k-En Yakın Komşu) kullanıldığı durumda daha yüksek doğruluk değeri elde edilmiştir.

Ayrıca literatürde yer alan hazır veri setleri kullanılarak gerçekleştirilen çalışmalar incelendiğinde [20-24] farklı makine öğrenmesi teknikleri hazır araçlar kullanılarak elde edilmesine karşın, bu çalışmada kullandığımız makine öğrenmesi tekniklerinden olan yapay sinir ağlarında ilgili algoritma, Şekil 4'te görülen akış şemasına göre kendi yazmış olduğumuz

kodlar ile oluşturulmuş olup, çalışmamız diğer çalışmalardan bu yönüyle farklılık göstermiştir.

Yazarların Katkısı

Bu çalışmaya tüm yazarlar eşit katkıda bulunmuşlardır.

Çıkar Çatışması Beyanı

Yazarlar arasında herhangi bir çıkar çatışması bulunmamaktadır.

Araştırma ve Yayın Etiği Beyanı

Yapılan çalışmada araştırma ve yayın etiğine uyulmuştur.

Kaynaklar

- [1] S. K. M. Hamouda, M. E. Wahed, R. H. Abo Alez, and K. Riad, "Robust breast cancer prediction system based on rough set theory at National Cancer Institute of Egypt," *Comput. Methods Programs Biomed.*, vol. 153, pp. 259–268, 2018.
- [2] M. Elter, R. Schulz-Wendtland, and T. Wittenberg, "The prediction of breast cancer biopsy outcomes using two CAD approaches that both emphasize an intelligible decision process: Prediction of breast biopsy outcomes using CAD approaches," *Med. Phys.*, vol. 34, no. 11, pp. 4164–4172, 2007.
- [3] M. R. Killi, "Meme kanserlerinin tanısında ve taramasında ultrasonografi," *Türkiye Klinikleri Genel Cerrahi - Özel Konular*, vol. 6, no. 2, pp. 7–14, 2013.
- [4] Ş. U. Sürücü, "BIRADS Sınıflamasına Göre Değerlendirilen Meme Lezyonlu Hastalarda Progresyon Varlığının Araştırılması Ve Risk Faktörleriyle İlişkilendirilmesi," in *Tıpta Uzmanlık Tezi (Basılmış)*, Selçuk Üniversitesi, Tıp Fakültesi, Konya, 2015, pp. 1–51.
- [5] I. Fondón et al., "Automatic classification of tissue malignancy for breast carcinoma diagnosis," *Comput. Biol. Med.*, vol. 96, pp. 41–51, 2018.
- [6] A. Helwan, J. B. Idoko, and R. H. Abiyev, "Machine learning techniques for classification of breast tissue," *Procedia Comput. Sci.*, vol. 120, pp. 402–410, 2017.
- [7] D. M. Vo, N.-Q. Nguyen, and S.-W. Lee, "Classification of breast cancer histology images using incremental boosting convolution networks," *Inf. Sci. (Ny)*, vol. 482, pp. 123–138, 2019.
- [8] E. Aydemir and İ. Karşlıoğlu, "Akıllı Telefonların İvmeölçer Sensörü Yardımıyla Yürüyüş Deseni Analizi," *Afyon Kocatepe Üniversitesi Fen Ve Mühendislik Bilimleri Dergisi*, vol. 21, pp. 283–299.
- [9] R. Pan, T. Yang, J. Cao, K. Lu, and Z. Zhang, "Missing data imputation by K nearest neighbours based on grey relational structure and mutual information," *Appl. Intell.*, vol. 43, no. 3, pp. 614–632, 2015.
- [10] A. Altunkaynak, E. E. Başakin, and E. Kartal, "Dalgacık K-En Yakın Komşuluk Yöntemi ile Hava Kirliliği Tahmini," *Uludağ Univ. J. Fac. Eng.*, pp. 1547–1556, 2020.
- [11] M. F. Adak and N. Yurtay, "Gini algoritmasını kullanarak karar ağacı oluşturmayı sağlayan bir yazılımın geliştirilmesi," *Bilişim Teknolojileri Dergisi*, vol. 6, no. 3, pp. 1–6, 2014.
- [12] E. Sezer, A. Bozkir, S. Yagiz, and C. Gokceoglu, "Karar ağacı derinliğinin CART algoritmasında kestirim kapasitesine etkisi: bir tünel açma makinesinin ilerleme hızı üzerinde uygulama," *Akıllı Sistemlerde Yenilikler ve Uygulamaları Sempozyumu*, pp. 21–24, 2010.
- [13] H. Zheng, L. Chen, X. Han, X. Zhao, and Y. Ma, "Classification and regression tree (CART) for analysis of soybean yield variability among fields in Northeast China: The importance of phosphorus application rates under drought conditions," *Agric. Ecosyst. Environ.*, vol. 132, no. 1–2, pp. 98–105, 2009.
- [14] X. Wu, *The top ten algorithms in data mining*. London, England: CRC Press, 2009.

- [15] B. Ataseven, “Yapay sinir ağları ile öngörü modellemesi,” *Öneri Dergisi*, vol. 10, pp. 101–115, 2013.
- [16] A. Dahamshah and H. Aksoy, “Kurak bölge aylık yağışlarının Markov zinciri eklenmiş koşullu ileri beslemeli geri yayılım yapay sinir ağları ile tahmini,” *İTÜ Dergisi Seri D: Mühendislik*, vol. 8, no. 6, pp. 37–48, 2009.
- [17] İ. Ateş and T. T. Bilgin, “The investigation of the success of different machine learning methods in breast cancer diagnosis,” *Konuralp tıp derg.*, 2021.
- [18] J. Brownlee, “A gentle introduction to the fbeta-measure for machine learning,” *Machine Learning Mastery*, 23-Feb-2020. [Online]. Available: <https://machinelearningmastery.com/fbeta-measure-for-machine-learning/>. [Accessed: 02-Oct-2021].
- [19] S. Kılıç, “Klinik karar vermede ROC analizi,” *Journal of Mood Disorders*, vol. 3, 2013.
- [20] K. Polat and S. Güneş, “Breast cancer diagnosis using least square support vector machine,” *Digit. Signal Process.*, vol. 17, no. 4, pp. 694–701, 2007.
- [21] M. F. Akay, “Support vector machines combined with feature selection for breast cancer diagnosis,” *Expert Syst. Appl.*, vol. 36, no. 2, pp. 3240–3247, 2009.
- [22] A. Mert, N. Kılıç, E. Bilgili, and A. Akan, “Breast cancer detection with reduced feature set,” *Comput. Math. Methods Med.*, vol. 2015, p. 265138, 2015.
- [23] H. Asri, H. Mousannif, H. A. Moatassime, and T. Noel, “Using machine learning algorithms for breast cancer risk prediction and diagnosis,” *Procedia Comput. Sci.*, vol. 83, pp. 1064–1069, 2016.
- [24] M. Milosevic, D. Jankovic, and A. Peulic, “Comparative analysis of breast cancer detection in mammograms and thermograms,” *Biomed. Tech. (Berl.)*, vol. 60, no. 1, pp. 49–56, 2015.
- [25] D. Altaş and V. Gülpınar, “Karar ağaçları ve yapay sinir ağlarının sınıflandırma performanslarının karşılaştırılması,” *Trakya Üniversitesi Sosyal Bilimler Dergisi*, vol. 14, no. 1, pp. 1–22, 2012.