

Meme Kanserinin Tespiti için Yapay Zekâ Tabanlı Hibrit Bir Model Önerisi

Abidin ÇALIŞKAN¹, Feyzi Ferat ATEŞ², Mesut TOĞAÇAR^{3*}

¹ Bilgisayar Mühendisliği, Mühendislik-Mimarlık Fakültesi, Batman Üniversitesi, Batman, Türkiye
² Elektrik Elektronik Mühendisliği, Lisansüstü Eğitim Enstitüsü, Batman Üniversitesi, Batman, Türkiye
³ Yönetim Bilişim Sistemleri, İktisadi ve İdari Bilimler Fakültesi, Fırat Üniversitesi, Elazığ, Türkiye

¹ abidin.caliskan@batman.edu.tr, ² feratates@gmail.com, ³ mtogacar@firat.edu.tr

(Geliş/Received: 07/09/2022;

Kabul/Accepted: 12/09/2022)

Öz: Meme kanseri genellikle memenin lobül, kanal ve bağ dokusu bölgelerinde meydana gelen ve bu bölgelerdeki hücrelerin anormal bir şekilde hareketinden meydana gelen kanser türüdür. Genel olarak bayanlar arasında en sık görülen kanser türleri arasında yer almaktadır. Hastalık erkenden fark edilmediği zaman kan ve lenf damarları yoluyla diğer organlara kanserli hücreler etki edebilir (metastaz durumu). Dolayısıyla meme kanserinin erken tanı ve tedavisi önemlidir. Bu çalışmada meme kanserinin iyi huylu ve kötü huylu türleri arasında sınıflandırma yapabilen yapay zekâ tabanlı erken tanı sistemi önerilmiştir. Önerilen yaklaşımda artık bloklu evrişimsel sinir ağı modelleri kullanıldı. ResNet modellerinin son katmanına yeni bir tam bağlantılı katman eklenerek tür tabanlı öznelikler çıkartıldı. Bir sonraki aşamada tam bağlantılı katmanlardan elde edilmiş öznelikler birleştirilerek yeni bir özellik seti oluşturuldu. Sınıflandırma sürecinde softmax ve makine öğrenme yöntemleri (destek vektör makineleri, en yakın komşu yöntemi, vb.) kullanıldı. Önerilen yaklaşım ile sınıflandırma sürecinde kullanılan tüm yöntemlerden %100 genel doğruluk başarıları elde edildi. Bu çalışmada tür tabanlı tam bağlantılı katmanların elde edilmesi ve birleştirilmesi deneysel analizlerin performansını olumlu etkilediği gözlenmiştir.

Anahtar kelimeler: Yapay zekâ, özellik seçimi, makine öğrenmesi, meme kanseri, sınıflandırma.

An Artificial Intelligence Based Hybrid Model Proposal for the Detection of Breast Cancer

Abstract: Breast cancer is a type of cancer that usually occurs in the lobule, duct and connective tissue regions of the breast and is caused by the abnormal movement of cells in these regions. It is among the most common types of cancer among women in general. When the disease is detected early, cancerous cells can affect other organs through the blood and lymphatic vessels (metastasis state). Therefore, early diagnosis and treatment of breast cancer is important. In this study, an artificial intelligence-based early diagnosis system that can classify between benign and malignant types of breast cancer is proposed. Residual blocky neural network models are used in the proposed approach. Type-based features were extracted by adding a new fully connected layer to the last layer of ResNet models. In the next step, a new feature set was created by combining the features obtained from the fully connected layers. Softmax and machine learning methods (support vector machines, nearest neighbor method, etc.) were used in the classification process. With the proposed approach, 100% overall accuracy was obtained from all the methods used in the classification process. In this study, it was observed that obtaining and combining type-based fully connected layers positively affected the performance of experimental analyzes.

Key words: Artificial intelligence, feature selection, machine learning, breast cancer, classification.

1. Giriş

Kanser, insan vücudunun organındaki veya doku bölgesindeki hücrelerin anormal bir şekilde bölünüp çoğalması ile meydana gelen ölümcül bir hastalıktır. Günümüzde davranış türlerine ve tedaviye verdiği yanıtlara göre 100'ün üzerinde kanser türü bulunmaktadır. Kanser patolojisinde en önemli konu tümörlü hücrelerin iyi ya da kötü huylu olduğunun tespit edilmesidir. Bu durum tanı-tedavi sürecinde önemlidir [1]. İyi huylu tümör kendi bulunduğu alanda sınırlı kalır ve çevre dokulara zarar vermez. Kötü huylu tümör ise bulunduğu alanın dışına çıkmaya çalışır ve çevre dokulara zarar verir. Ayrıca lenf ve kan yolu üzerinden diğer organlara da yayılabilir. Tüm bu sebepler göz önünde bulundurulduğunda kanser tedavisinde erken tanı önemlidir [2].

Hastalıkların iyileştirme süreçlerinde gerçekleştirilen tarama programları, eğitim ve tedavi programları her ne kadar yaşam standardını pozitif yönde etkilese de meme kanseri dünyada her yıl artan bir oran teşkil etmektedir.

* Sorumlu yazar: mtogacar@firat.edu.tr. Yazarların ORCID Numarası: ¹ 0000-0001-5039-6400, ² 0000-0002-9153-5080, ³ 0000-0002-8264-3899

Dünya Sağlık Örgütü'nün 2020 yılı verilerine göre dünyada 2 milyon 260 bin kişiye meme kanseri teşhisi konuldu ve yaklaşık 685 bin kadın meme kanserinden dolayı o yıl hayatını kaybetti [3]. Ölümcül bir hastalık olan meme kanserinin sağ kalım oranını artırabilmek için erken tanı son derece önemlidir. Meme kanserinin alt tipleri tedavi süreciyle doğrudan ilişkilidir [4]. Hastalığın tanı-tedavi sürecini daha sağlıklı ve hızlı bir şekilde gerçekleştirebilmek için teknolojik tabanlı birçok sistem geliştirilmiştir. Bu sistemler arasında son zamanlarda yapay zekâ teknolojileri daha çok ön plana çıkmaktadır. Yapay zekâ insan akıl ve becerilerini makine ortamına aktarabilen ve insanüstü kararlar alınmasını sağlayan bir yaklaşımdan oluşmaktadır [5]. Dolayısıyla meme kanseri tanı sürecinde bu yaklaşım uzmanların (doktor, radyolog, vb.) kararlarına bağlı olmadan otomatik bir şekilde karar verme iradesine sahiptir. Bu tür karar destek sistemleri günümüzde tanı-tedavi süreçlerinde kullanılmaktadır ve bu tür yaklaşımlar halen kendini geliştirmeye devam etmektedir [6]. Literatürde meme kanseri tanısını yapay zekâ destekli gerçekleştirebilen birçok çalışma yayımlanmıştır. Bunlardan bazıları incelenirse; MA. Najji vd. [7] makine öğrenme yöntemlerini kullanarak analizler gerçekleştirmiştir. Deneysel analizlerinde en iyi performansı destek vektör makineleri (DVM) ile sağlamışlardır ve bu yöntem ile %97,2 genel doğruluk başarısı elde etmişlerdir. CG. Yedjou vd. [8] çalışmasında hücre dokusunun yapısal (çap, büyüklük, iç bükey, dış bükey, vb.) özelliklerini kullanarak makine öğrenme yöntemleriyle analizler gerçekleştirmişlerdir. Çalışmalarında hücrelerin iyi huylu-kötü huylu sınıflandırılmasını başarılı bir şekilde gerçekleştirmişlerdir. Ahmad Kazemi vd. [9] meme kanseri teşhisinde paralel mimari yapısına sahip derin öğrenme modellerini (AlexNet, VGGNet) birleştirerek analizler gerçekleştirdi. Önerdikleri modelde %99,7 genel doğruluk başarısı elde ettiler. DA. Ragab vd. [10] meme kanseri teşhisinde derin evrimsel sinir ağı (D-ESA) modelini önerdiler ve onlar tasarladıkları modelin son katmanına DVM sınıflandırıcısını eklediler. Sonuç olarak, DVM ile %94 genel doğruluk başarısı elde ettiler.


Bu çalışmada, tümör türleri arasında ayrımı başarılı bir şekilde gerçekleştirebilen yapay zekâ tabanlı hibrit bir model önerilmiştir. Önerilen model, tanı süreçlerinde doğru karar verebilen ve uzmanlara yardımcı olabilecek karar destek sistemi tabanlı algoritmalar ile tasarlanmıştır. Önerilen yaklaşım ayrıca diğer maliyetler (zaman, maaş, hız, doğruluk, vb.) ile karşılaştırıldığında performans kazancı sağlayabilmektedir ve nesnel olarak karar verebilme yapısına sahiptir.

Makalenin diğer bölümleri şu şekilde özetlenir; veri kümesi hakkında detaylı bilgiler ikinci bölümde verilmiştir. Derin öğrenme tabanlı hibrit yaklaşım ve bu yaklaşımda kullanılan makine öğrenme yöntemleri ve ESA modelleri üçüncü bölümde detaylandırılmıştır. Deneysel analizler, analiz sonuçları ve tartışma dördüncü bölümde yer almıştır. Sonuç bölümü en son bölümde yer almıştır.

2. BreakHis Veri Kümesi

BreakHis, iyi huylu ve kötü huylu meme tümörlerinin mikroskopik biyopsi görüntülerini içeren açık erişimli veri kümesidir. Veri kümesi, 2014 yılında Brezilya'daki P&D Laboratuvarında başlatılmış kliniksel çalışma yoluyla toplanmıştır ve erişime sunulmuştur. Görüntüler üç kanallı kırmızı renkte alınır ve her bir kanal 8 bittir. BreakHis veri kümesi, 4x, 10x, 100x, 200x, 400x büyütme faktörleri kullanılarak oluşturulmuştur. Her bir görüntü RGB formatında olup, 700×460 piksel çözünürlüğe sahiptir ve görüntü formatları PNG uzantılıdır [11].

Bu çalışmada, orijinal BreakHis veri kümesinin 400x büyütme faktörü ile işlenmiş görüntü kümesinin belirli bir kısmı kullanılarak analizler gerçekleştirildi. 547 adet iyi huylu, 1146 adet kötü huylu olmak üzere toplam 1693 adet görüntü kümesinden oluşmaktadır [12]. Deneysel analizlerde veri kümesinin dağılımı 0,7 oranında eğitim verisi ve 0,3 oranında test verisi olarak ayrılmıştır. Veri kümesinin sınıflarını temsil eden alt görüntü kümesi Şekil 1'de gösterilmiştir.




Şekil 1. BreakHis 400x veri kümesinin sınıfları; a) iyi huylu, b) kötü huylu.

3. Yapay Zekâ Modelleri ve Yöntemleri

3.1. Artık tabanlı derin öğrenme modelleri

Derin öğrenme, mimari yapısında gizli evrişimsel katmanlar barındıran ve girdi verilerini işleyerek otomatik bir şekilde özniteliklerin çıkartılmasını sağlayan; sınıflandırma, regresyon, kategorize edebilme, vb. işlemleri çıkış katmanına aktaran, yapay zekânın bir alt dalıdır [13,14]. ESA modellerinin genel yapısı evrişimsel katmanlar, havuzlama katmanları ve tam bağlantılı (TB) katmanlardan oluşmaktadır. Evrişimsel katman, girdi verisinde özniteliklerin çıkartılmasını sağlayarak aktivasyon haritalarını oluşturmaktadır. Havuzlama katmanı, genellikle evrişimsel katmanlardan sonra kullanılır ve girdi boyutunu düşürerek modelin daha kolay eğitilmesini sağlar. TB katmanı diğer katmanlardan elde edilmiş öznitelikleri bütünleştirerek girdi verilerinin çıkış işlemlerini gerçekleştirebilmek için olasılık tabanlı değerlerin oluşmasına yardımcı olur [15,16].

ResNet, yayılım işlemini başarıyla gerçekleştiren bir mimaridir. Başka bir deyişle, ResNet, sonraki artık değer katmanlarını besleyen artık bloklardan oluşur. Bu özelliği ile ResNet klasik bir model değildir. ResNet-18, ResNet-50, ResNet-101, vb. mimari türleri vardır. Bu türlerin model yapısı aynı olmasına rağmen ResNet modelinin yanındaki sayılar katman sayısını ifade eder. ResNet-18 modeli 18 katmanlı bir derin evrişimsel ağ yapısına sahiptir ve ResNet modellerin girdi boyutu 224×224 piksel çözünürlüktedir. Artık bloklar, normal yapay sinir ağından daha derin ve daha derin olan ağı eğitimi kolaylaştırmaya yardımcı olur. Artık bloklar artık özellikle derin ağlarda kullanılan, tahmin sağlayan ve modelin performansına katkı sağlamayan katmanlardan kaçınan katmanlardan oluşmaktadır. Normal evrişimli ağlarda katmanlar arası veri ve özellik aktarımı yapılırken bir önceki katman veya bir sonraki katman ile doğrudan iletişim sağlanır; artık blokların kullanıldığı evrişimsel ağlarda, iki veya üç katmandan sonra katmanlarla doğrudan iletişim sağlanır. Böylece model eğitilirken gereksiz görünen ağlar atlatılarak performansa katkı sağlanır. Evrişimli ağlarda derinlik arttıkça modelin hızı azalmakta ve zaman tüketimi artmaktadır. Ayrıca derin ağların modelde birleştirilmesi sonucunda doğruluk oranlarının düşmesine neden olabilir. Bu durumda artık blokları çözüm noktası olarak kullanmak mümkün olabilir. Derin ağlarda kullanılan artık bloklar sayesinde modelin performansını olumsuz etkileyen katmanlar atlanarak doğruluğa hızlı bir şekilde ulaşılmıştır [17,18]. ResNet-X modelinin genel mimari yapısı Şekil 2’de gösterilmiştir.



Şekil 2. ResNet-X modelinin gelen mimari yapısı.

Bu çalışmada ResNet-18, ResNet-50 ve ResNet-101 modelleri kullanılmıştır. Bu modellerin ortak özellikleri;

- Aynı mimari yapısına sahip olması (paralel yapıya sahip ESA modeli)
- TB katmanların aynı sayıda öznitelik vermesi
- Giriş çözünürlüklerinin 224×224 olması, vs.
- Sınıflandırıcı olarak genellikle Softmax yönteminin son katmanda tercih edilmesi.


ESA modellerin genel yapısında ek bir sınıflandırma yöntemi eklenmediği sürece genellikle sınıflandırma rolünü softmax fonksiyonu üstlenir. ESA modellerinin sınıflandırma işlemini gerçekleştiren ve modellerin son katmanda yer alan aktivasyon fonksiyonu olarak ta bilinen softmax, tam bağlantılı katmanlardan işlenerek elde

edilen giriş değerlerini olasılık tabanlı [0, 1] değerlere dönüştürür. Ardından girdi verisini olasılık tabanlı değerlere göre karşılaştırarak ilgili sınıfa aktarılmasını sağlar [19,20].

3.2. Makine öğrenme yöntemleri

Makine öğrenmesi, deneyimlerden öğrenmeyi sağlayan ve hesaplama işlemini üst düzey algoritmalar kullanarak gerçekleştiren yapay zekânın alt dalıdır. Makine öğrenmesi denetimli ve denetimsiz olmak üzere işlemler gerçekleştirir. Denetimli makine öğrenmede girdi verilerinin tamamı etiketlidir ve etiketli veriler ilgili yöntem tarafından işlenerek sınıflandırma, regresyon gibi işlemleri gerçekleştirir. Denetimsiz makine öğrenmede ise veri kümesinde etiket kullanılmadan gruplaştırılması veya kümeleştirilmesi istenir [21]. Bu çalışma için DVM, en yakın komşu (EYK) yöntemi ve lineer diskriminant analizi (LDA) yöntemi kullanıldı. Bu yöntemlerden kısaca bahsetmek gerekirse;

DVM yöntemi, regresyon ve sınıflandırma işlemleri için tercih edilen popüler bir makine öğrenmesi yaklaşımıdır. Bu yöntem girdi örneklerini işler, bunları koordinat düzlemine yerleştirir ve hiper çizgiler kullanarak türler arasında sınıflandırma yapar. Maksimum marj alanı (w) optimize edilerek belirlenir. DVM yönteminin ikili ve çoklu sınıflandırma işlemlerini gösteren açıklama Şekil 3'te verilmiştir. DVM yöntemlerinde en önemli ölçüt karar limitinin belirlenmesidir. Bu kritik adım için aşağıdaki denklemler kullanılır. Denklem 1'deki matematiksel formül sayesinde, sınıflandırma işlemi sürecinde oluşabilecek problemler en aza indirilmiştir. Önyargı değişkeni b ile temsil edilir. Denklem 2'deki X ve Y değişkenleri, öznelik değerlerini temsil eder ve bu denklem ile etiketleme işlemi gerçekleşir.



Şekil 3. DVM sınıflandırma süreci; a) ikili sınıflandırma, b) çoklu sınıflandırma [22].

$$u = w \cdot x - b \quad (1)$$

$$y_i (w \cdot x_i - b) \geq 1, \forall i \quad (2)$$

EYK yöntemi, denetimli öğrenme modeli içerisinde yer alan ve algoritma modelindeki girdi verilerinin sınıflandırma problemini çözebilen bir makine öğrenmesi yaklaşımıdır. Sınıflandırma işleminde, veri özelliklerine benzer özellikler aynı sınıf içinde etiketlenir. Bu hesaplanırken örnek veri öznelikleri rastgele seçilir ve örnek veri özneliklerine göre diğer veri özneliklerinin uzaklıkları hesaplanır. Sonuç olarak, her özellik için EYK özellik sayısına (en fazla) bakılır. Burada parametre genellikle $\{2,3, \dots\}$ değerler seçilir. EYK yönteminin dezavantajı, her bir özellik verisi için mesafe bilgisini tutmak için bir hafıza gereksinimine ihtiyaç duymasındır. Özellikler arası mesafe ölçümleri için; "Öklid", "Manhattan", "Minkowski" yöntemlerinden biri tercih edilir [23]. Öklid formülü ile uzaklık (d) Denklem 3'e göre hesaplanır. Burada p ve q değişkenleri özellikleri temsil eder.

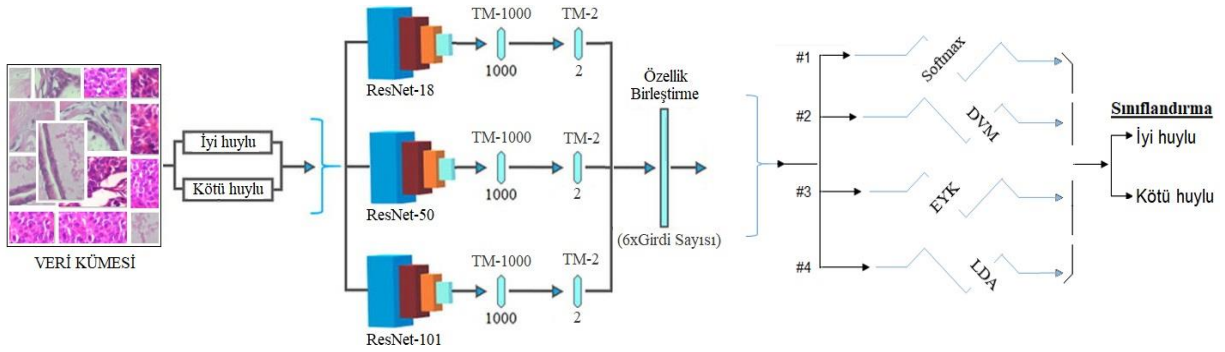
$$d(p, q) = \sqrt{(p_1 - q_1)^2 + (p_2 - q_2)^2} \quad (3)$$

Diskriminant analizi, sınıflandırma ve boyut indirgemede kullanılacak hem sınıflandırma hem de boyut indirgeme yöntemlerini içerir. En popüler diskriminant analiz yöntemi LDA' dır. LDA, yorumlama olasılığı olan bir sınıflandırma yöntemidir. Başka bir deyişle, çok sınıflı etiketler için en iyi ayrımı sağlamak için değişkenleri doğrusal bir kombinasyonda aramaya dayanır [24].

Bu çalışmanın sınıflandırma sürecinde kullanılan makine öğrenme yöntemleri (DVM, EYK, LDA), MATLAB yazılımının hazır araç kutuları kullanılarak derlendi. Makine öğrenme yöntemlerinin parametre değerleri, MATLAB yazılımı tarafından tercih edilmiş varsayılan değerlerden oluşmuştur.

3.3. Önerilen hibrit yaklaşım

Önerilen yaklaşım, mikroskopik biyopsi görüntülerini kullanarak iyi huylu ve kötü huylu meme kanseri türlerinin sınıflandırılmasını gerçekleştiren, yapay zekâ tabanlı hibrit bir modeldir. Bu yaklaşım aynı mimariye sahip artık blokluk modellerin paralel bir yapıda kullanılmasına dayalıdır. ResNet-18, ResNet-50 ve ResNet-101 modellerinin TB katmanları aynı sayıda öznetelik vermektedir. Üç modele yeni bir TB_{tür sayısı} katmanı ekleyerek, veri kümesinin tür sayısı kadar çıkışa $TB_{tür\ sayısı} = [tür\ sayısı \times girdi\ sayısı]$ boyutunda öznetelik seti aktarılmaktadır. Örneğin iki sınıflı (iyi huylu-kötü huylu) bir veri setinin transfer öğrenme tabanlı ResNet modelleri ile eğitim sürecinde TB katmanları tarafından işlem görmekte ve sınıflandırma işlemi öncesi oluşturulmuş yeni tam bağlantılı katman (TB_2) sayesinde, $2 \times girdi\ veri\ sayısı$ boyutunda aktivasyon setleri oluşturulmaktadır. Buradaki amaç model maliyetini düşürmek ve verimliliği artırmaktır. Toplam 3 ResNet modeli bu çalışmanın deneysel analizlerinde kullanıldı ve $3x(2 \times girdi\ veri\ sayısı)$ kadar birleştirilmiş özellik seti yeniden softmax yöntemine girdi olarak verilerek sınıflandırma işlemi gerçekleştirildi. Ayrıca softmax'a alternatif olarak sınıflandırma işlemini başarılı bir şekilde gerçekleştirebilen makine öğrenme yöntemleri de (DVM, EYK, LDA) sınıflandırma sürecinde kullanıldı. Tür sayısı kadar aktivasyon seti verebilen tam bağlantılı katmanlar ($TB_{tür\ sayısı}$) artık blokluk ESA modellerinin iş yükünü (zaman, hız maliyeti) azaltmayı sağlamıştır. $TB_{tür\ sayısı}$ katmanlarının birleştirilerek yeni bir özellik setinin oluşturulması ve yeniden makine öğrenme yöntemleri ile sınıflandırılması işlemi de önerilen yaklaşımın sınıflandırma sürecine katkı sunmuştur. Önerilen yaklaşımın genel mimari tasarımı Şekil 4'te gösterilmiştir.



Şekil 4. Önerilen yaklaşımın mimari yapısı.

4. Deneysel Analizler ve Tartışma

Bu çalışmanın analizleri için MATLAB 2020 yazılımı kullanıldı. Derin öğrenme modelleri ve makine öğrenme yöntemleri için MATLAB tarafından varsayılan değerler korunarak eğitimler gerçekleştirildi. Eğitimlerin gerçekleştirilmesinde kullanılan donanımlar ve bilgileri şu şekildedir; Intel® Xeon® CPU @3.20 GHz CPU, 8 GB RAM ve 4 GB GPU destekli Nvidia Geforce ekran kartı kullanıldı. MATLAB yazılımında derlenen ResNet-18, ResNet-50 ve ResNet-101 modelleri için tercih edilmiş parametreler Tablo 1'de gösterilmiştir.

Tablo 1. ResNet modellerinin eğitimi sürecinde tercih edilmiş parametre değerleri.

Parametre	Tercih / Değer
İterasyon sayısı	420
Dönem/Devir sayısı	4
Öğrenme oranı	0,0001
Optimizasyon	SGD
Donanım kaynağı	Tekli GPU
Mini – topluluk (mini-batch)	16
Eğitim oranı: test oranı	0.7:0.3

Karmaşıklık matrisi bu çalışmanın deneysel analizlerinde ölçüt olarak belirlenmiştir ve ölçütte kullanılan metrikler; doğruluk, kesinlik, f1-skor, geri çağırma'dır. Bu metriklerin hesaplanmasında Denklem 4-7'deki matematiksel formüller kullanıldı. Denklem 4-7 arasında kullanılan kısaltmalar; doğru (D), yanlış (Y), negatif (N), pozitif (P) anlamına gelir [25-27].


$$\text{Geri çağırma} = \frac{DP}{DP+YN} \quad (4)$$

$$\text{Kesinlik} = \frac{DP}{DP+YP} \quad (5)$$

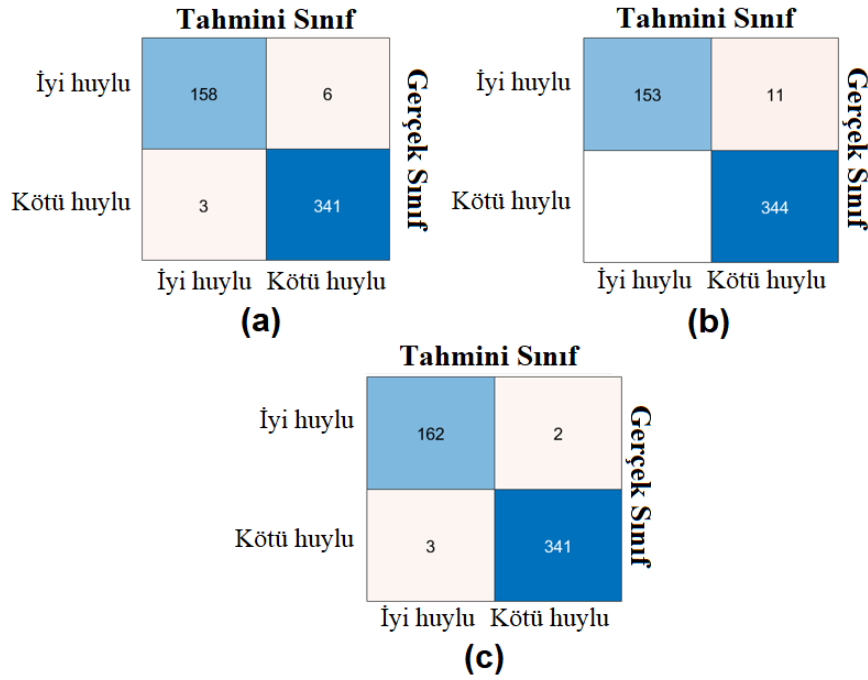
$$\text{F-skor} = \frac{2 \times DP}{2 \times DP + YP + YN} \quad (6)$$

$$\text{Doğruluk} = \frac{DP+DN}{DP+DN+YP+YN} \quad (7)$$

Bu çalışmada üç deney gerçekleştirildi. Birinci deney analizinde veri kümesi ResNet-18, ResNet-50 ve ResNet-101 modelleriyle eğitildi. Eğitim sürecinde sınıflandırma işlemi için softmax yöntemi kullanıldı ve softmax'a girdi verisi olarak her bir modelin TB_{1000} katmanından elde edilmiş 1000 özellik verildi. Bu deneyde modellerden elde edilmiş eğitim başarı grafikleri Şekil 5'te ve karmaşıklık matrisleri Şekil 6'da gösterilmiştir. Birinci deneyin analiz sonuçları Tablo 2'de verilmiştir.



Şekil 5. ResNet modellerinin eğitim-test başarı grafikleri (1000 özellikli);
a) ResNet-18, b) ResNet-50, c) ResNet-101.



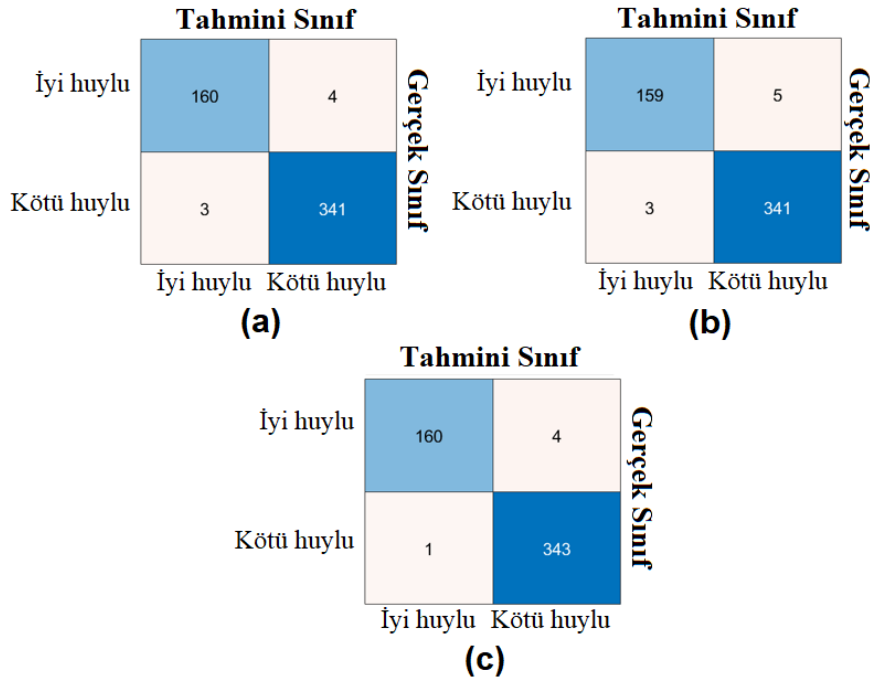
Şekil 6. ResNet modellerinden elde edilmiş karmaşıklık matrisleri (1000 özellikli);
a) ResNet-18, b) ResNet-50, c) ResNet-101.

Tablo 2 incelendiğinde ResNet-18 model ile %98.23, ResNet-50 model ile %97.83 ve ResNet-101 model ile %99.02 genel doğruluk başarısı elde edilmiştir. En iyi performansı modeller arasında ResNet-101 vermiştir. Üç modelinde sınıflandırma sürecinde softmax yöntemi kullanıldı ve bu modellerin tam bağlantılı son katmanından elde edilmiş 1000 özellik seti softmax yöntemine girdi olarak verildi.

Tablo 2. ResNet modellerinden elde edilmiş karmaşıklık matrislerin (1000 özellikli) metrik sonuçları.

ESA model	Sınıf	Kesinlik	Geri çağırma	F1-skor	Doğruluk (%)
ResNet-18	İyi huylu	0,96	0,98	0,97	98,23
	Kötü huylu	0,99	0,98	0,99	
ResNet-50	İyi huylu	0,93	1,0	0,97	97,83
	Kötü huylu	1,0	0,97	0,98	
ResNet-101	İyi huylu	0,99	0,98	0,98	99,02
	Kötü huylu	0,99	0,99	0,99	

İkinci deneyde ResNet modellerin son katmanına yeni TB katman eklendi ve tür sayısı kadar çıkış veren özellik setleri elde edildi. Modeller eğitilerek TB_2 katmanından elde edilen ($2xgirdi$ sayısı) boyutundaki özellik setleri softmax yöntemi ile yeniden sınıflandırıldı. Bu deneyde modellerden elde edilmiş karmaşıklık matrisleri Şekil 7’de gösterilmiştir. İkinci deneyin analiz sonuçları Tablo 3’te verilmiştir. Tablo 3 incelendiğinde ResNet-18 model ile %98,62, ResNet-50 model ile %98,43 ve ResNet-101 model ile %98,62 genel doğruluk başarısı elde edilmiştir. Üç modelinde sınıflandırma sürecinde softmax yöntemi kullanıldı ve bu modellerin tam bağlantılı son katmanından elde edilmiş 2 özellik seti softmax yöntemine girdi olarak verildi. Tablo 2 ve Tablo 3 analizleri karşılaştırıldığında tür tabanlı tam bağlantılı katmanın (TB_2) performans anlamında TB_{1000} katmanıyla yakın performans gösterdiği gözlemlenmiştir.



Şekil 7. ResNet modellerinden elde edilmiş karmaşıklık matrisleri (2 özellikli); a) ResNet-18, b) ResNet-50, c) ResNet-101.


Tablo 3. ResNet modellerinden elde edilmiş karmaşıklık matrislerin (2 özellikli) metrik sonuçları.

ESA model	Sınıf	Kesinlik	Geri çağırma	F1-skor	Doğruluk (%)
ResNet-18	İyi huylu	0,98	0,98	0,98	98,62

	Kötü huylu	0,99	0,99	0,99	
ResNet-50	İyi huylu	0,97	0,98	0,98	98,43
	Kötü huylu	0,99	0,99	0,99	
ResNet-101	İyi huylu	0,98	0,98	0,98	98,62
	Kötü huylu	0,99	0,99	0,99	

Üçüncü deneyde önerilen yaklaşım veri kümesine uygulandı. Üç modelden elde edilmiş FC_2 katmanları birleştirilerek ($3 \times FC_2$) sırasıyla softmax, DVM, EYK ve LDA yöntemleri ile sınıflandırıldı. Sınıflandırma sürecinde softmax ve makine öğrenme yöntemlerinden %100 genel doğruluk başarısı elde edildi. Önerilen yaklaşımla elde edilmiş karmaşıklık matrisi ve ROC eğrisi Şekil 8’de gösterilmiştir. Üçüncü deneyin metrik sonuçları Tablo 4’te verilmiştir.

DeneySEL analizler önerilen yaklaşımın meme kanseri türlerini başarılı bir şekilde ayırt ettiğini göstermiştir. Bu çalışmada önerilen yaklaşımın her bir adımı deneylerde (deney 1, deney 2, deney 3) uygulanarak, tür tabanlı tam bağlantılı katmanın performanslarına katkı sağladığı görüldü. Ayrıca özellik setlerinin birleştirilmesi ile %100’lük genel doğruluk başarısı sınıflandırma yöntemleriyle elde edildi.



Şekil 8. Önerilen yaklaşımda, softmax ve makine öğrenme yöntemleri ile gerçekleştirilmiş analiz sonuçları; a) karmaşıklık matrisi, b) ROC eğrisi.

Tablo 4. Önerilen yaklaşımın analiz sonuçları.

ESA model	Sınıf	Kesinlik	Geri çağırma	F1-skor	Doğruluk (%)
Önerilen yaklaşım	İyi huylu	1,0	1,0	1,0	100
	Kötü huylu	1,0	1,0	1,0	

5. Sonuç

Kanser hastalığının oluşmasına sebep olan tümör, iyi huylu ve kötü huylu olmak üzere iki sınıfa ayrılır. Bu çalışmada meme kanserine neden olabilecek iyi huylu ve kötü huylu tümörlerin sınıflandırılması gerçekleştirildi. Erken tanı, bu hastalığın sağ kalım oranını artırmaktadır. Bu çalışmada önerilen yaklaşım derin öğrenme modelleriyle makine öğrenme yöntemlerini bir araya getiren yeni bir karar destek sistemi sunmaktadır. Tür tabanlı yeni bir TB katmanının ESA modellerinin son katmanına entegre edilmesi, modellerin performansına katkı sağladığını göstermiştir. Ayrıca sınıflandırma sürecinde tek bir yöntem ile destek sağlanmamış, DVM, EYK, LDA yöntemleriyle de sınıflandırma işlemi gerçekleştirilmiştir. Bu seçim genel doğruluk başarısını sağlamlaştırmıştır, ancak önerilen modelin maliyetini artırmıştır. Son olarak önerilen yaklaşım da tür tabanlı TB katmanlarından elde

edilmiş özniteliklerin birleştirilmesi, sınıflandırma başarısını artırmıştır. Sonuç olarak bu çalışmanın deneysel analizlerinde %100 genel doğruluk başarıları elde edilmiştir.

Gelecek çalışmada farklı görüntüleme yöntemiyle elde edilmiş veri setleri kullanılarak meme kanserinin tanı sürecinde derin öğrenme tabanlı yeni yaklaşımlar tasarlanacaktır. Veri kümelerine ön işlem adımları eklenerek girdi görüntüsünden daha verimli yararlanılacaktır. Ayrıca öznitelik seçiminde daha verimli özelliklerin ön plana çıkartılabilmesi için meta-sezgisel yöntemler de önerilen yaklaşıma ilave edilecektir.

Teşekkür

Bu makale, Batman Üniversitesi Lisansüstü Eğitim Enstitüsü tarafından yürütülmüş “Meme Kanserinin İyi Huylu veya Kötü Huylu Durum Tespitinde Derin Öğrenme Modellerinin Kullanılması” adlı yüksek lisans tezinden üretilmiştir. A.Ç., fikir sahibidir. F.F.A. ve M.T. deneyleri gerçekleştirdi. A.Ç. ve F.F.A., sonuçları yorumladı ve F.F.A., M.T., makaleyi yazdı.

Kaynaklar

- [1] G. Cooper, *The Development and Causes of Cancer*, 2nd ed., Sinauer Associates, Sunderland (MA), 2000. <https://www.ncbi.nlm.nih.gov/books/NBK9963/>.
- [2] A. Patel, Benign vs Malignant Tumors, *JAMA Oncol.* 6 (2020) 1488. doi:10.1001/jamaoncol.2020.2592.
- [3] N.S. Ariffin, RUNX1 as a Novel Molecular Target for Breast Cancer, *Clin. Breast Cancer.* 22 (2022) 499–506. doi:https://doi.org/10.1016/j.clbc.2022.04.006.
- [4] M.N. Uddin, X. Wang, Identification of Breast Cancer Subtypes Based on Gene Expression Profiles in Breast Cancer Stroma, *Clin. Breast Cancer.* 22 (2022) 521–537. doi:https://doi.org/10.1016/j.clbc.2022.04.001.
- [5] K. Kersting, Machine Learning and Artificial Intelligence: Two Fellow Travelers on the Quest for Intelligent Behavior in Machines, *Front. Big Data.* 1 (2018). doi:10.3389/fdata.2018.00006.
- [6] A. Gastounioti, S. Desai, V.S. Ahluwalia, E.F. Conant, D. Kontos, Artificial intelligence in mammographic phenotyping of breast cancer risk: a narrative review, *Breast Cancer Res.* 24 (2022) 14. doi:10.1186/s13058-022-01509-z.
- [7] M.A. Naji, S. El Filali, K. Aarika, E.L.H. Benlahmar, R.A. Abdelouahid, O. Debauche, Machine Learning Algorithms For Breast Cancer Prediction And Diagnosis, *Procedia Comput. Sci.* 191 (2021) 487–492. doi:https://doi.org/10.1016/j.procs.2021.07.062.
- [8] C.G. Yedjou, S.S. Tchounwou, R.A. Aló, R. Elhag, B. Mochona, L. Latinwo, Application of Machine Learning Algorithms in Breast Cancer Diagnosis and Classification., *Int. J. Sci. Acad. Res.* 2 (2021) 3081–3086.
- [9] A. Kazemi, M. Ebrahim, A. Sheikahmadi, M. Khodamoradi, A new parallel deep learning algorithm for breast cancer classification, *12 (2021) 1269–1282.*
- [10] D.A. Ragab, M. Sharkas, S. Marshall, J. Ren, Breast cancer detection using deep convolutional neural networks and support vector machines, *PeerJ.* 7 (2019) e6201. doi:10.7717/peerj.6201.
- [11] F.A. Spanhol, L.S. Oliveira, C. Petitjean, L. Heutte, A Dataset for Breast Cancer Histopathological Image Classification, *IEEE Trans. Biomed. Eng.* 63 (2016) 1455–1462. doi:10.1109/TBME.2015.2496264.
- [12] K. Muzaki, BreaKHis 400X, Kaggle Web. (2020). <https://www.kaggle.com/datasets/forderation/breakhis-400x?resource=download>.
- [13] W. Alsaggaf, Z. Cömert, M. Nour, K. Polat, H. Brdese, M. Toğaçar, Predicting fetal hypoxia using common spatial pattern and machine learning from cardiocography signals, *Appl. Acoust.* 167 (2020) 107429. doi:10.1016/j.apacoust.2020.107429.
- [14] M. Toğaçar, B. Ergen, Z. Cömert, Tumor type detection in brain MR images of the deep model developed using hypercolumn technique, attention modules, and residual blocks, *Med. Biol. Eng. Comput.* 59 (2021) 57–70. doi:10.1007/s11517-020-02290-x.
- [15] A. Diker, Z. Comert, E. Avci, M. Togacar, B. Ergen, A Novel Application based on Spectrogram and Convolutional Neural Network for ECG Classification, in: 2019 1st Int. Informatics Softw. Eng. Conf., IEEE, 2019: pp. 1–6. doi:10.1109/UBMYK48245.2019.8965506.
- [16] E. Başaran, A new brain tumor diagnostic model: Selection of textural feature extraction algorithms and convolution neural network features with optimization algorithms, *Comput. Biol. Med.* 148 (2022) 105857. doi:https://doi.org/10.1016/j.compbiomed.2022.105857.
- [17] A. Venkata, S. Abhishek, Resnet18 Model With Sequential Layer For Computing Accuracy On Image Classification Dataset, *10 (2022) 176–181.*

- [18] S. Xie, R. Girshick, P. Dollár, Z. Tu, K. He, Aggregated Residual Transformations for Deep Neural Networks, (2016). doi:10.1109/cvpr.2017.634.
- [19] B. Gao, L. Pavel, On the Properties of the Softmax Function with Application in Game Theory and Reinforcement Learning, (2017). <http://arxiv.org/abs/1704.00805>.
- [20] Y. Luo, Y. Wong, M. Kankanhalli, Q. Zhao, Softmax: Improving Intra-class Compactness and Inter-class Separability of Features, *IEEE Trans. Neural Networks Learn. Syst.* 31 (2020) 685–699. doi:10.1109/tnnls.2019.2909737.
- [21] I. Olier, O.I. Orhobor, T. Dash, A.M. Davis, L.N. Soldatova, J. Vanschoren, R.D. King, Transformational machine learning: Learning how to learn from many related scientific problems, *Proc. Natl. Acad. Sci.* 118 (2021) e2108013118. doi:10.1073/pnas.2108013118.
- [22] H. Wu, L. Wang, Z. Zhao, C. Shu, C. Lu, Support Vector Machine based Differential Pulse-width Pair Brillouin Optical Time Domain Analyzer, *IEEE Photonics J.* 10 (2018) 1–11. doi:10.1109/jphot.2018.2858235.
- [23] A. Niwatkar, Y.K. Kanse, Feature Extraction using Wavelet Transform and Euclidean Distance for speaker recognition system, in: 2020 Int. Conf. Ind. 4.0 Technol., 2020: pp. 145–147. doi:10.1109/I4Tech48345.2020.9102683.
- [24] H. Mandelkowitz, J.A. de Zwart, J.H. Duyn, Linear Discriminant Analysis Achieves High Classification Accuracy for the BOLD fMRI Response to Naturalistic Movie Stimuli, *Front. Hum. Neurosci.* 10 (2016). doi:10.3389/fnhum.2016.00128.
- [25] E. Başaran, Z. Cömert, Y. Çelik, Neighbourhood component analysis and deep feature-based diagnosis model for middle ear otoscope images, *Neural Comput. Appl.* 34 (2022) 6027–6038. doi:10.1007/s00521-021-06810-0.
- [26] A. Çalışkan, Classification of Tympanic Membrane Images based on VGG16 Model, *Kocaeli Journal of Science and Engineering*, 5(1), 105-111. doi:<https://doi.org/10.34088/kojose.1081402>
- [27] H. Polat, M. Turkoglu, O. Polat, Deep network approach with stacked sparse autoencoders in detection of DDoS attacks on SDN-based VANET, *IET Commun.* 14 (2020) 4089–4100. doi:10.1049/iet-com.2020.0477.