

Ultrason Tabanlı Meme Kanseri Görüntülerinin Derin Öğrenme Yaklaşımları ile Sınıflandırılması

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: 04/09/2022;

Kabul/Accepted: 12/09/2022)

Öz: Meme kanseri bayanlar arasında en sık görülen kanser türlerinden biridir. Diğer kanser türlerinde olduğu gibi meme kanseri hastalarının tedavisinde erken tanı önemlidir. Son zamanlarda yapay zekâ birçok alanda adını duyurmuştur. Sağlık alanında da yapay zekâ tanı ve tedavi süreçlerinde teknolojik alt yapı olarak kullanılmaya başlamıştır. Bu çalışma da ultrason tabanlı görüntüler kullanılarak meme kanseri teşhisini gerçekleştirebilecek yapay zeka tabanlı bir yaklaşım önerilmektedir. Önerilen yaklaşım önceden eğitilmiş evrimsel sinir ağlarından oluşmaktadır. Her bir evrimsel sinir ağının son katmanına yeni bir tam bağlantılı katman eklenmiştir. Tam bağlantılı katmanı önceki tam bağlantılı katmanlardan ayırt eden özelliği girdi türü sayısı kadar öznelik vermesidir. Ardından evrimsel sinir ağlarının tam bağlantılı katmanları birleştirilerek sınıflandırma işlemi gerçekleştirilmiştir. Bu çalışmada iyi huylu, kötü huylu ve normal olmak üzere üçlü bir sınıflandırma işlemi gerçekleştirilmiştir. Deneysel analiz sonucunda önerilen yaklaşım ile %99,57 genel doğruluk başarıları elde edilmiştir. Önerilen yaklaşım deneyde kullanılan evrimsel sinir ağı modellerinden daha iyi performans göstermiştir.

Anahtar kelimeler: Derin öğrenme, özellik seçimi, özellik birleştirme, meme kanseri, sınıflandırma.

Classification of Ultrasound-Based Breast Cancer Images with Deep Learning Approaches

Abstract: Breast cancer is one of the most common types of cancer among women. As with other types of cancer, early diagnosis is important in the treatment of breast cancer patients. Recently, artificial intelligence has made its name in many fields. In the field of health, artificial intelligence has started to be used as a technological infrastructure in diagnosis and treatment processes. In this study, an artificial intelligence-based approach that can diagnose breast cancer using ultrasound-based images is proposed. The proposed approach consists of pre-trained convolutional neural networks. A new fully connected layer is added to the last layer of each convolutional neural network. The feature that distinguishes the fully connected layer from the previous fully connected layers is that it gives as many features as the number of input types. Then, the classification process was carried out by combining the fully connected layers of the convolutional neural networks. In this study, a triple classification process was carried out as benign, malignant and normal. As a result of the experimental analysis, 99.57% overall accuracy was achieved with the proposed approach. The proposed approach outperformed the convolutional neural network models used in the experiment.

Key words: Deep learning, feature selection, feature merging, breast cancer, classification.

1. Giriş

Meme kanseri dünya genelinde 2 milyonun üzerinde bayanda teşhis edilen ve yılda ortalama 685 bin ölüm ile sonuçlanan bir kanser türüdür. Bayanlarda en sık görülen kanser türleri arasında meme kanseri de yer almaktadır. Sağ kalım oranını iyileştirebilmek için kanser türünün erken teşhisi önemlidir. Meme kanseri hastalarının erken tanı ve tedavisi sağ kalım oranlarını artırmaktadır [1]. Bu hastalığın teşhisinde birçok görüntüleme yöntemi kullanılır. Görüntüleme yöntemlerinden bazıları; mamografi, manyetik rezonans (MR), ultrason etkin bir şekilde hastanın tanı-tedavi sürecinde kullanılmaktadır [2].

Meme kanseri teşhisi sürecinde tarama programları birçok ülkede uygulanmaktadır ve artan meme kanseri vakalarının sayısı uzmanlara (doktor, radyolog, vb.) iş yükü getirmektedir. Ayrıca artan maliyet, zamandan kayıplarda düşünüldüğünde teknolojik tabanlı sistemlerin insanların karar verme süreçlerinde etkin bir rol oynamaları kaçınılmaz olmuştur. Geleneksel tabanlı bilgisayar destekli tanı sistemleri mevcut gereksinimleri

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

karşılayamaz hale gelmiştir. Teknolojik gelişmeler bilgisayar destekli tanı sistemlerini yapay zekâ tabanlı yaklaşımlarla buluşturmuştur. Son zamanlarda yapay zekâ yaklaşımlarıyla geliştirilen sistemler insan iş yükünü azaltmaya başarmış ve daha başarılı analiz sonuçları alarak diğer alanlarda da olduğu gibi sağlık alanında da adını duyurmuştur [3].

Yapay zekâ tabanlı yaklaşımlar insan duygu ve düşünme yetilerini makine ortamlarına aktarılmasını öngören, insanüstü kararlar vermeyi amaç edinen teknik, yöntem ve modellerden oluşmaktadır. Yapay zekâ makine öğrenmesi, derin öğrenme gibi alt katmanlardan oluşmaktadır. Bilgisayar görüşü, regresyon, sınıflandırma, bölütleme gibi birçok işlemi gerçekleştirebilen bu yaklaşım (yapay zekâ) hastalıkların tanı ve tedavi süreçlerinde de kullanılmaya başlamıştır [4,5]. Literatürde yapay zekâ destekli birçok tanı sistemi geliştirilmiştir. Aljuaid, Hanan vd. [6] “BreakHis” veri kümesini kullanarak derin öğrenme modelleri ile analizler gerçekleştirdi. ResNet-18, InceptionV3 ve ShuffleNet modelleriyle sınıflandırma girdi görüntülerini sınıflandırdılar. Aljuaid, Hanan vd. [6] deneysel analizlerde ResNet modeliyle en iyi başarıyı sağladılar ve %99,7 genel doğruluk başarıları elde ettiler. Saliha Zahoor vd. [7] meme kanseri türlerini sınıflandırabilmek için derin öğrenme modelleri ile birlikte meta-sezgisel optimizasyon yöntemini birlikte kullandılar. Analizlerden çıkardıkları öznelikleri sınıflandırmak için çoklu makine öğrenme yöntemlerini kullandılar. Açık erişimli üç farklı veri kümesini kullanarak gerçekleştirdikleri analizlerde sırasıyla; %99.7, %99.8 ve %93.8 doğruluk başarıları elde ettiler. Essam Houssein vd. [8] meta-sezgisel yöntemleri özellik seçim işlemlerini gerçekleştirmek için önerdikleri yaklaşımda kullandılar. Essam Houssein vd. [8] meme kanseri türlerini sınıflandırma işlemlerinde iki veri kümesi kullandılar ve özneliklerin çıkarımında artık bloklara dayalı bir ESA modeli geliştirdiler. Analiz sonuçlarına göre iki veri kümesi için elde ettikleri genel doğruluk başarıları sırasıyla, %98,32 ve %98,88’di. M. Thilagaraj vd. [9] meme kanseri türlerini sınıflandırma işleminde radyal tabanlı ESA modelini kullandılar. Özneliklerin indirgenmesi işleminde yapay balık okulu optimizasyon yöntemini kullandılar. Sınıflandırma sürecinde elde ettikleri en iyi genel doğruluk başarıları %98,66’ydı.


Bu çalışmada meme kanseri görüntülerinden oluşan veri kümesini kullanarak türlerine göre sınıflandırabilen, derin öğrenme tabanlı bir model önerilmiştir. Önerilen yaklaşım;

- Uzmanların daha kolay karar verebilme,
- Zamandan kazanç ve performanstan artış sağlayabilme
- Eş zamanlı birçok girdi verisini karar destek sistemi tabanlı sonuçlandırabilme, vb. katkılar sağlamıştır.

Makalenin diğer bölümleri şu şekilde özetlenir; veri kümesi hakkında detaylı bilgiler ikinci bölümde verilmiştir. Önerilen yaklaşım ve bu yaklaşımda kullanılan yöntem ve modeller üçüncü bölümde detaylandırılmıştır. Deneysel analizler, analiz sonuçları ve tartışma dördüncü bölümde yer almıştır. Sonuç bölümü en son bölüm başlığı olarak bu makalede yer almıştır.

2. Veri Kümesi

Veri kümesi, erişime açık meme kanseri görüntülerinden oluşmaktadır. Görüntüler, 2018 yılında toplanmıştır ve 25 ile 75 yaş aralığındaki kadın hastalardan elde edilen ultrason tabanlı imgelerden oluşmaktadır. Görüntülerin oluşturulmasında kullanılan hasta sayısı 600’dür. Görüntüler PNG formatında olup, görüntü çözünürlükleri ortalama 500×500 pikseldir [10]. Veri kümesi iyi huylu, kötü huylu ve normal olmak üzere üç sınıf türünden oluşmaktadır [11]. Veri kümesinin sınıflarını temsil eden örnek görüntüler Şekil 1’de gösterilmiştir.



Şekil 1. Veri kümesi sınıflarına ait örnek görüntüler; a) İyi huylu, b) Kötü huylu, c) Normal.

Veri kümesi hakkında istatistiksel bilgiler Tablo 1’de verilmiştir. Toplam 780 görüntüden oluşmaktadır. İyi huylu kanser türüne ait görüntü sayısı 437, kötü huylu kanser türüne ait görüntü sayısı 210 ve normal türlü görüntü sayısı 133’tür. Bu çalışmanın deneysel analizlerinde veri kümesindeki eğitim verisi oranı 0.7 ve test verisi oranı 0.3 olarak ayarlanmıştır.


Tablo 1. Veri kümesinin sınıflarına ait görüntü sayısı.

Sınıf	Görüntü Sayısı
İyi huylu	437
Kötü huylu	210
Normal	133
Toplam	780

3. Yapay Zekâ Yaklaşımları

3.1. Derin öğrenme modelleri

Derin öğrenme, girdi verilerini otomatik bir şekilde işleyebilen, öznitelikler çıkartabilen, mimari yapısında gizli katmanlar bulunduran; sınıflandırma, bölütleme, regresyon, vb. işlemleri gerçekleştirebilen yapay zekânın alt dalıdır. Kullanım amaçlarına göre derin öğrenme modelleri bulunmaktadır ve sınıflandırma süreçlerinde genellikle evrişimsel sinir ağı (ESA) modelleri tercih edilmektedir [12]. ESA modellerinin genel yapısı; evrişimsel katmanlar, havuzlama katmanları ve tam bağlantılı katmanlardan oluşur [13]. Bir ESA modeli genel olarak giriş katmanı, gizli katmanlar ve çıkış katmanlarından oluşur. ESA modellerini makine öğrenme yöntemlerinden ayırt eden en önemli özelliği girdi verilerinde öznitelikleri otomatik olarak çıkartabilmesi ve gizli katmanlardan öznitelikleri işleyebilmesidir [4,14]. ESA modelinin genel yapısı Şekil 2’de gösterilmiştir.



Şekil 2. ESA modelinin genel mimari yapısı.

Evrişimsel katman, girdi görüntüleri üzerinde $n \times n$ boyutunda filtre dolaştırarak aktivasyon haritalarının oluşturulmasını sağlar. Girdi boyutu küçültülerek modelin daha kolay eğitim görmesine yardımcı olur. Havuzlama katmanı, genellikle evrişimsel katmanlardan sonra kullanılır ve girdi verisinin boyutunu küçültür. Havuzlama katmanı bunu gerçekleştirirken (2×2 , 3×3 , vs.) boyutlu filtreler kullanır. Tam bağlantılı katman, önceki katmanlardan elde edilmiş öznitelikleri tek bir boyutta toplayarak düzleştirir (flatten) ve girdi verilerinin olasılıklı değerlerinin oluşmasına yardımcı olur [15–17]. ESA’ya örnek olarak; AlexNet, VGG-16, GoogLeNet, DarkNet, ResNet, Inception gibi modeller verilebilir. Bu çalışmada AlexNet, DarkNet-19, ResNet-18 modelleri kullanıldı.

AlexNet, yaklaşık 650 bin nörondan oluşan, toplam 60 milyon parametreden oluşan ve 2012 yılında ImageNet görüntü sınıflandırması yarışmasında üstün başarı gösteren bir derin öğrenme modelidir. AlexNet 8 katmanlı bir

ESA'dır. Bu mimari 5 evrişim katmanı ve 3 tam bağlantı katmanından oluşur. Maksimum havuzlama katmanı ile gerçekleşen işlemler, evrişim katmanlarından sonra gerçekleşir. Önceki sinir ağlarından farklı olarak, AlexNet, geleneksel sigmoid ve tanh işlevleri yerine etkinleştirme işlevi olarak ReLU'yu kullanır. ReLU, yalnızca modelin eğitim hızını etkili bir şekilde geliştirmekle kalmayıp aynı zamanda gradyandan meydana gelebilecek problemi daha iyi kontrol edebilen, doymamış bir aktivasyon fonksiyonudur. Bu modelin genel mimari yapısı 8 katmanlı bir ESA'dır. Evrişimsel katman sayısı 5 ve tam bağlantılı katman sayısı 3'tür. Evrişimsel katmanlardan sonra havuzlama katmanını da kullanılmıştır. Aktivasyon fonksiyonu olarak ReLU tercih edilmiştir. ReLU, AlexNet modelini hızlandırmakla kalmayıp, oluşabilecek gradyan problemlerinin de önüne geçmiştir [18]. AlexNet modelinin girdi boyutu 227×227 çözünürlüktedir. Tam bağlantılı katmanları arasında en son sırada yer alan FC-8 katmanı girdi verisinden toplam 1000 öznitelik çıkartır ve bir sonraki katmana aktarır [19].

DarkNet, mimarisinde ESA model yapısını kullanan bir derin öğrenme yaklaşımıdır. Bu model esas olarak gerçek zamanlı görüntülerde/videolarda nesnelere algılamak için tasarlanmıştır. DarkNet modeli, YOLO modelini temel alıp geliştirilmiş bir mimariye sahiptir. DarkNet-19 modelinin giriş çözünürlüğü 256×256 pikseldir. Bu model, YOLO-v2'nin özellik çıkarımı işlevini mimari yapısında tutar ve 19 katmanlı derin ağ yapısına sahiptir [20,21].


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-34, ResNet-50, 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 bu modelin girdi boyutu 224×224 'tür. Artık ağlar, normal yapay sinir ağından daha derin ve daha derin olan ağı eğitimi kolaylaştırmaya yardımcı olur [22].

3.2. Softmax sınıflandırıcı

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 olasılıksal $[0, 1]$ değerlere dönüştürür. Ardından girdi verisini olasılıksal değerlere göre karşılaştırarak ilgili sınıfa aktarılmasını sağlar. Kısacası softmax, genellikle iki ve çok tipli veri setlerini sınıflandırmak için ESA modellerinde tercih edilir [23].

3.3. Önerilen yaklaşım

Önerilen yaklaşım, ultrason görüntülerini kullanarak meme kanseri tanı sistemine katkı sunan ve kanser tümörü türleri arasında başarılı bir şekilde sınıflandırmayı amaçlayan derin öğrenme tabanlı bir modeldir. Önerilen yaklaşımın literatüre katkısı, tür tabanlı yeni bir tam bağlantılı katman ESA modellerine ekleyerek modellerin daha verimli ve başarılı sınıflandırma yapabilmelerini sağlamıştır. Bu çalışmada transfer öğrenme tabanlı ESA modellerinin son katmanından önce yeni bir tam bağlantılı katman modellere eklendi. Böylece softmax öncesi, sınıf tipi sayısı kadar aktivasyon setleri tam bağlantılı katmandan elde edildi. Örneğin 3 sınıflı bir veri setinin transfer öğrenme tabanlı ESA modeli ile eğitiminden sonra tam bağlantılı katmanlardan işlenmekte, yine sınıflandırma işlemi öncesi oluşturulmuş yeni tam bağlantılı katman sayesinde; ($3 \times$ girdi veri sayısı) kadar aktivasyon setleri oluşturulmaktadır. Toplam 3 ESA modeli bu çalışmanın deneysel kısmında kullanıldı ve $3 \times$ ($3 \times$ girdi veri sayısı) kadar birleştirilmiş bir aktivasyon seti elde edildi. Ardından ($9 \times$ girdi veri sayısı) boyutundaki birleştirilmiş aktivasyon seti yeniden softmax yöntemine girdi olarak verilerek sınıflandırma işlemi gerçekleştirildi. Tür sayısı kadar aktivasyon seti verebilen tam bağlantılı katmanlar (FC tür sayısı) ESA modellerin iş yükünü (zaman, hız maliyeti) azaltmayı sağladı. FC tür sayısı katmanlarının birleştirilerek yeni bir özellik setinin oluşturulması ve yeniden sınıflandırılması işlemi de önerilen yaklaşımın performansını pozitif yönde artırdı. Bu yaklaşımın genel mimarisi Şekil 3'te gösterilmiştir.



Şekil 3. Önerilen yaklaşımın mimari tasarımı.

4. Deneysel Analizler ve Tartışma

Bu çalışmanın deneysel analizleri MATLAB 2020 programı kullanılarak gerçekleştirildi. Deneysel analizler için gereksinim duyulan donanım bilgileri şunlardır; 8 GB geçici hafıza birimi, Intel® Xeon® CPU @3.20 GHz işlemci birimi ve 4 GB GPU destekli ekran kartı kullanıldı. MATLAB yazılımında derlenen ESA modelleri için tercih edilen parametreler ve değerleri Tablo 2’de verilmiştir.

Tablo 2. ESA modellerinin eğitimi sürecinde tercih edilmiş parametre değerleri.

Parametre	Tercih / Değer
İterasyon sayısı	194
Dönem/Devir sayısı	2
Öğrenme oranı	0,0001
Optimizasyon	SGD
Donanım kaynağı	Tekli GPU
Mini – topluluk (mini-batch)	4
Eğitim oranı: test oranı	0.7:0.3

Deneysel analizlerin ölçüm işlemleri için birçok makalenin deneysel analizlerinde tercih edilen karmaşıklık matrisi kullanıldı. Karmaşıklık matrisini oluşturan metriklerin (f-skor, kesinlik, geri çağırma, vb.) hesaplanmasında aşağıda verilen denklemler kullanıldı. Denklem 1-4 arasında kullanılan kısaltmaların anlamları şunlardır; (D): doğru, (Y): yanlış, (N): negatif, (P): pozitifdir [24-26].


$$\text{Geri çağırma} = \frac{DP}{DP+YN} \quad (1)$$

$$\text{Kesinlik} = \frac{DP}{DP+YP} \quad (2)$$

$$\text{F-skor} = \frac{2 \times DP}{2 \times DP + YP + YN} \quad (3)$$

$$\text{Doğruluk} = \frac{DP+DN}{DP+DN+YP+YN} \quad (4)$$

DeneySEL analizler iki aşamadan oluşmuştur. Birinci aşamada veri kümesi sırasıyla AlexNet, DarkNet-19 ve ResNet-18 modelleri ile eğitildi. Bu modeller tarafından elde edilmiş eğitim-test başarı grafikleri Şekil 4'te gösterildi. Modellerden elde edilmiş karmaşıklık matrisleri Şekil 5'te gösterilmiştir.



Şekil 4. ESA modellerinin eğitim-test doğruluk grafikleri; a) AlexNet, b) DarkNet-19, c) ResNet-18.

		Tahmini Sınıf						
		İyi huylu	Kötü huylu	Normal				
Gerçek Sınıf	İyi huylu	128	1	2	İyi huylu	129	2	
	Kötü huylu	8	55		Kötü huylu		63	
	Normal			40	Normal	1		39
		İyi huylu	Kötü huylu	Normal				

(a)

		Tahmini Sınıf						
		İyi huylu	Kötü huylu	Normal				
Gerçek Sınıf	İyi huylu	124	6	1	İyi huylu	124	6	1
	Kötü huylu	3	60		Kötü huylu	3	60	
	Normal	2	1	37	Normal	2	1	37
		İyi huylu	Kötü huylu	Normal				

(b)

		Tahmini Sınıf						
		İyi huylu	Kötü huylu	Normal				
Gerçek Sınıf	İyi huylu	124	6	1	İyi huylu	124	6	1
	Kötü huylu	3	60		Kötü huylu	3	60	
	Normal	2	1	37	Normal	2	1	37
		İyi huylu	Kötü huylu	Normal				

(c)

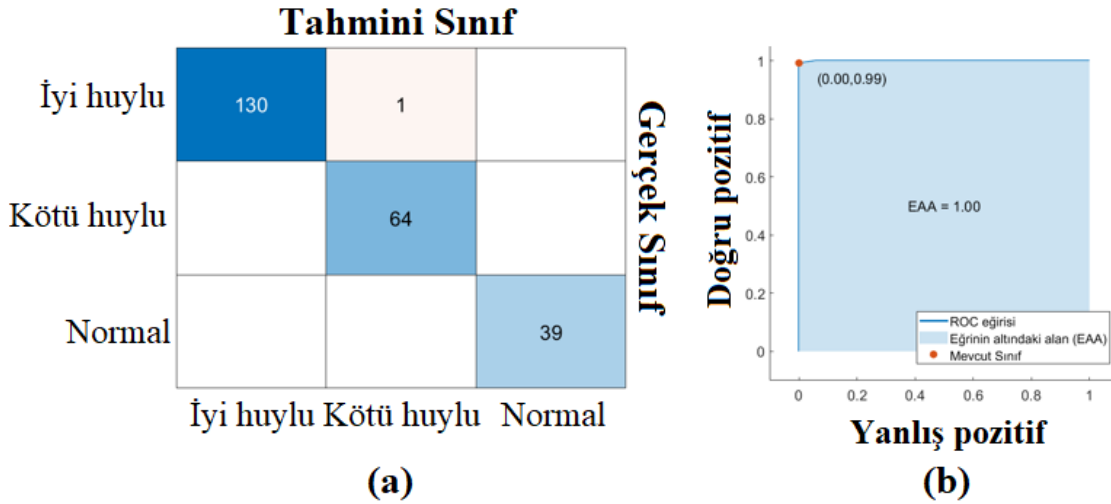
Şekil 5. ESA modellerinden elde edilmiş karmaşıklık matrisleri; a) AlexNet, b) DarkNet-19, c) ResNet-18.

Şekil 5'te gösterilen karmaşıklık matrislerin metrik sonuçları Tablo 3'de verilmiştir. Tablo 3 incelendiğinde AlexNet model ile %95.30, DarkNet-19 model ile %98.72 ve ResNet-18 model ile %94.44 genel doğruluk başarıları elde edilmiştir. En iyi performansı modeller arasında DarkNet-19 vermiştir. Üç modelinde sınıflandırma sürecinde softmax yöntemi kullanıldı ve bu modellerin tam bağlantılı son katmanından elde edilmiş 1000 özellik seti softmax yöntemine girdi verisi olarak verildi. Sonuç olarak ESA modellerinden Tablo 3'teki skorlar elde edildi.

Tablo 3. ESA modellerinin karmaşıklık matris metrik sonuçları.

ESA model	Sınıf	Kesinlik	Geri çağırma	F1-skor	Doğruluk (%)	Genel Doğruluk (%)
AlexNet	İyi huylu	0,98	0,94	0,96	95,30	95,30
	Kötü huylu	0,87	0,98	0,92	96,15	
	Normal	1,0	0,95	0,98	99,15	
DarkNet-19	İyi huylu	0,98	0,99	0,99	98,72	98,72
	Kötü huylu	1,0	0,97	0,98	99,15	
	Normal	0,97	1,0	0,99	99,57	
ResNet-18	İyi huylu	0,95	0,96	0,95	94,87	94,44
	Kötü huylu	0,95	0,90	0,92	95,73	
	Normal	0,93	0,97	0,95	98,29	

DeneySEL analizlerin ikinci aşamasında ESA modellerin tam bağlantılı katmanlarının yer aldığı bloka yeni bir tam bağlantılı katman / FC_{tür sayısı} eklendi. FC_{tür sayısı} sayesinde ESA modellerinden girdi türü sayısı kadar (3 sınıf türü var) öznitelik setleri elde edildi. Her bir modele ait öznitelik setleri tür sayısı × girdi sayısı boyutunda iki boyutlu matris değerler içermektedir. Üç modelinde öznitelik setleri birleştirilerek yeni bir öznitelik seti oluşturuldu. Yani, “ $3 \times [\text{tür sayısı} (3\text{tür}) \times \text{girdi sayısı}] = 9 \times \text{girdi sayısı}$ ” boyutlarında yeni bir öznitelik seti oluşturuldu. Oluşturulmuş öznitelik seti yeniden softmax yöntemi ile sınıflandırıldı ve sınıflandırma sürecinde elde edilmiş karmaşıklık matrisi ve ROC eğrisi Şekil 6'de gösterildi. Önerilen yaklaşımın analiz sonuçları Tablo 4'te verildi. Sonuç olarak önerilen yaklaşım ile %99,57 genel doğruluk başarıları elde edildi. DeneySEL analizlerin iki aşamasından elde edilmiş sonuçlar bize önerilen yaklaşımın ESA modellerinden daha başarılı olduğunu göstermiştir.



Şekil 6. Birleştirilmiş öznitelik setinin softmax yöntemi ile gerçekleştirilen analiz sonucu; a) karmaşıklık matrisi, b) ROC eğrisi.

Tablo 4. Önerilen yaklaşımın analiz sonuçları.

ESA model	Sınıf	Kesinlik	Geri çağırma	F1-skor	Doğruluk (%)	Genel Doğruluk (%)
Önerilen yaklaşım	İyi huylu	0,99	1,0	1,0	99,57	99,57
	Kötü huylu	1,0	0,98	0,99	99,57	
	Normal	1,0	1,0	1,0	100	

5. Sonuç

Meme kanseri dünya genelinde kadınlar arasında sıkça rastlanılan ve ölümcül neticeler ile sonuçlanabilen bir hastalık türüdür. Erken tanı, bu hastalığın sağ kalım oranını artırmaktadır. Bu sebeplerden dolayı erken tanı üzerine kurgulanan birçok çalışma literatürde yer almıştır ve son zamanlarda bu çalışmalar arasında yapay zekâ tabanlı yaklaşımlar da mevcuttur. Bu makalede meme kanseri türleri arasında (iyi huylu-kötü huylu) ve normal/sağlıklı görüntüleri de dâhil ederek üç tür üzerinde sınıflandırma gerçekleştirilmiştir. Önerilen yaklaşımın literatüre katkısı, tür tabanlı yeni bir tam bağlantılı katman ESA modellerinin son aşamasına ekletilerek daha az öznelikte fakat daha başarılı analizler elde edebilmesini sağlamıştır. Ayrıca önerilen yaklaşım da ESA modellerinden elde edilmiş özneliklerin birleştirilmesi, sınıflandırma başarısını artırmıştır. Sonuç olarak bu çalışmanın deneysel analizlerinde %99,57 oranında genel doğruluk başarısı elde edilmiştir.

Gelecek çalışmada farklı türden veri setleri kullanarak meme kanserinin tanı sürecinde derin öğrenme tabanlı yeni yaklaşımlar tasarlanacaktır. Ayrıca öznelik seçiminde daha verimli özelliklerin ön plana çıkartılabilmesi için meta-sezgisel yöntemler de tasarlanacak 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. ve M.T., makaleyi yazdı.

Kaynaklar

- [1] S. Ortega-Martorell, P. Riley, I. Olier, R.G. Raidou, R. Casana-Eslava, M. Rea, L. Shen, P.J.G. Lisboa, C. Palmieri, Breast cancer patient characterisation and visualisation using deep learning and fisher information networks, *Sci. Rep.* 12 (2022) 14004. doi:10.1038/s41598-022-17894-6.
- [2] Y. Gao, B. Reig, L. Heacock, D.L. Bennett, S.L. Heller, L. Moy, Magnetic Resonance Imaging in Screening of Breast Cancer, *Radiol. Clin. North Am.* 59 (2021) 85–98. doi:10.1016/j.rcl.2020.09.004.
- [3] L. Balkenende, J. Teuwen, R.M. Mann, Application of Deep Learning in Breast Cancer Imaging, *Semin. Nucl. Med.* 52 (2022) 584–596. doi:10.1053/j.semnuclmed.2022.02.003.
- [4] C. Janiesch, P. Zschech, K. Heinrich, Machine learning and deep learning, *Electron. Mark.* 31 (2021) 685–695. doi:10.1007/s12525-021-00475-2.
- [5] F. Emmert-Streib, Z. Yang, H. Feng, S. Tripathi, M. Dehmer, An Introductory Review of Deep Learning for Prediction Models With Big Data, *Front. Artif. Intell.* 3 (2020). doi:10.3389/frai.2020.00004.
- [6] H. Aljuaid, N. Alturki, N. Alsubaie, L. Cavallaro, A. Liotta, Computer-aided diagnosis for breast cancer classification using deep neural networks and transfer learning, *Comput. Methods Programs Biomed.* 223 (2022) 106951. doi:https://doi.org/10.1016/j.cmpb.2022.106951.
- [7] S. Zahoor, U. Shoaib, I.U. Lali, Breast Cancer Mammograms Classification Using Deep Neural Network and Entropy-Controlled Whale Optimization Algorithm, *Diagnostics.* 12 (2022) 557. doi:10.3390/diagnostics12020557.
- [8] E.H. Houssein, M.M. Emam, A.A. Ali, An optimized deep learning architecture for breast cancer diagnosis based on improved marine predators algorithm, *Neural Comput. Appl.* (2022). doi:10.1007/s00521-022-07445-5.

- [9] M. Thilagaraj, N. Arunkumar, P. Govindan, Classification of Breast Cancer Images by Implementing Improved DCNN with Artificial Fish School Model, *Comput. Intell. Neurosci.* 2022 (2022) 6785707. doi:10.1155/2022/6785707.
- [10] W. Al-Dhabyani, M. Gomaa, H. Khaled, A. Fahmy, Dataset of breast ultrasound images, *Data Br.* 28 (2020) 104863. doi:10.1016/j.dib.2019.104863.
- [11] A. Shah, Breast Ultrasound Images Dataset, Kaggle Web. (2021). <https://www.kaggle.com/datasets/aryashah2k/breast-ultrasound-images-dataset?resource=download>.
- [12] I.H. Sarker, Deep Learning: A Comprehensive Overview on Techniques, Taxonomy, Applications and Research Directions, *SN Comput. Sci.* 2 (2021) 420. doi:10.1007/s42979-021-00815-1.
- [13] B. Ait Skourt, A. El Hassani, A. Majda, Mixed-pooling-dropout for convolutional neural network regularization, *J. King Saud Univ. - Comput. Inf. Sci.* 34 (2022) 4756–4762. doi:https://doi.org/10.1016/j.jksuci.2021.05.001.
- [14] N. Sharma, R. Sharma, N. Jindal, Machine Learning and Deep Learning Applications-A Vision, *Glob. Transitions Proc.* 2 (2021) 24–28. doi:10.1016/j.gltp.2021.01.004.
- [15] W. Alsaggaf, Z. Cömert, M. Nour, K. Polat, H. Brdesec, M. Toğaçar, Predicting fetal hypoxia using common spatial pattern and machine learning from cardiocotography signals, *Appl. Acoust.* 167 (2020) 107429. doi:10.1016/j.apacoust.2020.107429.
- [16] 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.
- [17] 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.
- [18] C. Banerjee, T. Mukherjee, E. Pasilio, An Empirical Study on Generalizations of the ReLU Activation Function, in: Proc. 2019 ACM Southeast Conf., Association for Computing Machinery, New York, NY, USA, 2019: pp. 164–167. doi:10.1145/3299815.3314450.
- [19] S. Li, L. Wang, J. Li, Y. Yao, Image Classification Algorithm Based on Improved AlexNet, *J. Phys. Conf. Ser.* 1813 (2021). doi:10.1088/1742-6596/1813/1/012051.
- [20] J. Redmon, A. Farhadi, YOLO9000: Better, faster, stronger, Proc. - 30th IEEE Conf. Comput. Vis. Pattern Recognition, CVPR 2017. 2017-Janua (2017) 6517–6525. doi:10.1109/cvpr.2017.690.
- [21] P. Sowa, J. Izydorczyk, Darknet on OpenCL: a multi-platform tool for object detection and classification, (2020) 1–22. doi:10.20944/preprints202007.0506.v1.
- [22] A. Venkata, S. Abhishek, Resnet18 Model With Sequential Layer For Computing Accuracy On Image Classification Dataset, *10* (2022) 176–181.
- [23] M. El, A. Seddik, C. Louart, R. Couillet, M. Tamaazousti, The Unexpected Deterministic and Universal Behavior of Large Softmax Classifiers, *Int. Conf. Artif. Intell. Stat.* (2021). <https://melaseddik.github>.
- [24] M. Toğaçar, Z. Cömert, B. Ergen, Enhancing of dataset using DeepDream, fuzzy color image enhancement and hypercolumn techniques to detection of the Alzheimer’s disease stages by deep learning model, *Neural Comput. Appl.* 33 (2021) 9877–9889. doi:10.1007/s00521-021-05758-5.
- [25] 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.
- [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