



YSA KULLANILARAK MAMOGRAMLARDAN DOKUSAL ÖZİNİTELİK TABANLI MEME KANSERİ İLGİ BÖLGESİ SINIFLANDIRILMASI

Sena Busra YENGEC TASDEMİR^{1*}, Kasım TASDEMİR¹, Zafer AYDIN¹,

¹ Abdullah Gül Üniversitesi, Bilgisayar Mühendisliği Bölümü, Kayseri, Türkiye

Anahtar Kelimeler	Öz
<i>Bilgisayar Yardımlı Kanser Tespiti, Makine Öğrenmesi, Bilgisayarlı Görü, Transfer Öğrenimi ile Derin Öğrenme</i>	Radyoloji uzmanlarının mamografi görüntülerine bakarak yaptığı meme kanseri teşhislerinde tip bir hata oranı yüzde otuzlara kadar çıkmaktadır. Kanser teşhis başarısını artırmak adına bu çalışmada uzmanlara yardımcı olacak yeni bir Bilgisayar Yardımlı Teşhis sistemi, kanserli ve normal dokuyu ayırt etmek için önerilmektedir. Önerilen sistemde kontrast limitli histogram eşitleme (CLAHE) yöntemiyle iyileştirilen görüntülerin iki boyutlu parçacık dönüşümlerinden (2B-DWT) Haralick ve HOG öznitelikleri çıkarılmıştır. Özniteliklerin sayısını azaltması için temel bileşenler analizi (PCA) algoritması kullanılmıştır. Seçilen öznitelikler çok katmanlı algılayıcı (MLP) mimari yapısına sahip yapay sinir ağına (YSA) girdi olarak verilmiştir. Çok katmanlı algılayıcı üzerinde Adam eniyileme yapıldığında %81 tespit doğruluğu yakalanmıştır. Ayrıca, diğer bir çok temel makine öğrenmesi ve derin öğrenme yöntemleri denenerek karşılaştırma sonuçları detaylı olarak sunulmuştur. Sınırlı sayıda veri kümesi kullanıldığında transfer öğrenim kullanılsa dahi derin öğrenme yöntemlerinin tespit başarısı azalmıştır. Buna karşılık doğru ön işleme, öznitelik seçilimi ve makine öğrenmesi yaklaşımları kullanıldığı zaman geleneksel bilgisayarlı görü yöntemleri daha başarılı sonuçlar vermiştir

TEXTURAL FEATURE BASED REGION OF INTEREST CLASSIFICATION USING ANN FROM MAMMOGRAMS

Keywords	Abstract
<i>Computer Aided Cancer Detection, Machine Learning, Computer Vision, Transfer Learning with Deep Learning</i>	Radiologists' Type I error rate of Breast Cancer Detection from mammography images can reach up to thirty percent. In this study to assist radiology experts, a new Computer Aided Detection (CAD) system is proposed in order to increase the detection rate of Breast Cancer. A CAD system distinguishes the cancerous regions from normal tissues. In the proposed system, Haralick and HOG features are extracted from two-dimensional Wavelet transformed images which are enhanced by the CLAHE method. PCA algorithm is employed to select the extracted features. The selected features are given as input to a multi-layer perceptron (MLP) architecture. A detection accuracy of 81% is achieved when Adam optimization is used. In addition, various machine learning and deep learning methods have been implemented for comparison. When limited number of samples are used, the detection success of deep learning methods decreases even if transfer learning is employed. On the contrary, conventional computer vision methods give more successful results when appropriate combination of preprocessing, feature selection and machine learning algorithms are selected.

Alıntı / Cite

YENGEC-TASDEMİR, S.B., TASDEMİR, K., AYDIN, Z., (2020). Textural Feature Based Region of Interest Classification Using ANN from Mammograms, Journal of Engineering Sciences and Design, 8(5), 133-141.

Yazar Kimliği / Author ID (ORCID Number)

S.B. YENGEC-TASDEMİR, 0000-0001-8322-4832
K. TASDEMİR, 0000-0003-4542-2728
Z. AYDIN, 0000-0001-7686-6298

Makale Süreci / Article Process

Başvuru Tarihi / Submission Date	17.11.2020
Revizyon Tarihi / Revision Date	16.12.2020
Kabul Tarihi / Accepted Date	18.12.2020
Yayın Tarihi / Published Date	29.12.2020

* İlgili yazar / Corresponding author: sena.yengec@agu.edu.tr

1. Giriş (Introduction)

Amerikan Kanser Topluluğunun (American Cancer Society) raporuna göre kadınlar arasındaki en yaygın kanser türü olan meme kanseri erken ölüm sebepleri arasında birinci sıradadır (Oeffinger vd., 2015). Hastalığın erken ve doğru teşhisi ölüm oranlarını azaltmakla birlikte, hayati önem taşımaktadır.

Araştırmalar göstermiştir ki radyoloji uzmanları, mamografi görüntülerini görsel olarak inceleyerek kötü huylu kanseri %10-30 arasında bir hata ile gözden kaçırabilmektedirler. Bu oran, böylesine hayati risk taşıyan bir hastalık için oldukça yüksektir. Dolayısıyla, uzmanlara yardımcı olacak bilgisayar yardımı teşhis (CAD) sisteminden hem erken teşhis oranını artırması, hem de teşhis maliyetini azaltması beklenmektedir (Rodriguez-Ruiz vd., 2018).

Literatürde CAD destekli meme kanseri tespitine yönelik 300'den fazla çalışma vardır. Sınıflandırmada tanımlayıcılar olarak genellikle ortalama, değişinti, enerji, entropi, çarpıklık (skewness) ve kurtosis gibi istatistiksel öznitelikler sıkça kullanılmıştır (Yassin vd., 2018). Dokusal öznitelik olarak ise, Gray Level Co-occurrence Matris (GLCM) ve Gray Level Run Length Matris (GLRLM), GLCM Optik yoğunluk öznitelikleri gibi pikseller arası ilişkinin istatistiksel özelliklerini inceleyen yöntemler sıklıkla kullanılmıştır. Bunların dışında, Histogram of Gradients (HOG), Local Configure Pattern (LCP), Uniform Directional Pattern (UDP), Local Ternary Pattern (LTP), Local Phase Quantization (LPQ), Local Binary Pattern (LBP), Region Growing ile bölütleme, Generalized Moment Patterns, Zernike momentleri, spikulyasyon indeksi gibi çok çeşitli doku tanımlayıcılar da kullanılmıştır (Yengec-Tasdemir vd., 2020).

Yönlü özniteliklere örnek olarak çoklu çözünürlük ve çoklu yönlendirme çerçevesinde, Wavelet (Yengec-Tasdemir vd., 2018), dual-tree complex Wavelet, Gabor, Contourlet, Shearlet, Ridgelet vs. kullanılmıştır (Gedik, 2016). Bunlara ek olarak Zernike öznitelikleri MIAS verisetinden çıkarılmış, MLP ile iyi huylu-kötü huylu kanser ayrımı 0.97 AUC skoru ile yapılmıştır (Tahmasbi vd., 2011).

Literatürdeki mamografi görüntülerinden kanserli doku tespiti ve sınıflandırması çalışmaları son yıllarda derin öğrenme ile büyük verisetleri üzerinde yapılmaktadır (Becker vd., 2017).


Yukarıda bahsedilen yöntemler arasında 2D-DWT dönüşümü, Haralick gibi algoritmalarından faydalanan çalışmalar mevcuttur. Ancak bu çalışmada; öznitelik seçimi, makine öğrenmesi, regülasyon ve eniyileme yöntemlerinin çeşitli kombinasyonları oluşturularak, az sayıda örnek içeren MIAS veri seti üzerinde test edilmiştir. Ayrıca, oluşturulan sistemin başarısı transfer öğrenimi ile derin öğrenme algoritmaları ile de karşılaştırılmıştır.

Makalenin 2. bölümünde yöntemden, 3. bölümde ise deney sonuçlarından bahsedilmiştir. 4. Bölüm sonuç kısmında ise deney sonuçları ışığında önerilen yöntem değerlendirilmiştir.

2. Yöntem (Methodology)

2.1. Veri Kümesi (Database)

Mamogram görüntüleri mini-MIAS veri kümesinden elde edilmiştir. Mamogramlar ile ilgili detaylı bilgi (<http://peipa.essex.ac.uk/info/mias.html>)'de bulunmaktadır. Veri seti 322 dijital mamogramdan oluşmaktadır, bu görüntülerden 109 adet anormal, 213 adet normal sınıfa aittir. Anormal resimlerin kanser ilgili bölgelerinin (ROI) bilgisi ve koordinatları veri setinin içinde bulunmaktadır. ROI'ler otomatik bir Python kodu ile kesilmiştir. ROI kesim işlemi, ROI olmayan sağlıklı bölgeler için de sağlıklı mamogramlar üzerinde rastgele koordinatlar kullanılarak tekrarlanmıştır. Sonuç olarak kesilmiş resimlerden oluşan bir veri seti (VS1) oluşturulmuştur (Şekil 1). Her görüntünün boyutu farklı olmakla birlikte, ortalama boyut 29x29 piksel olacak şekilde ayarlanmıştır.



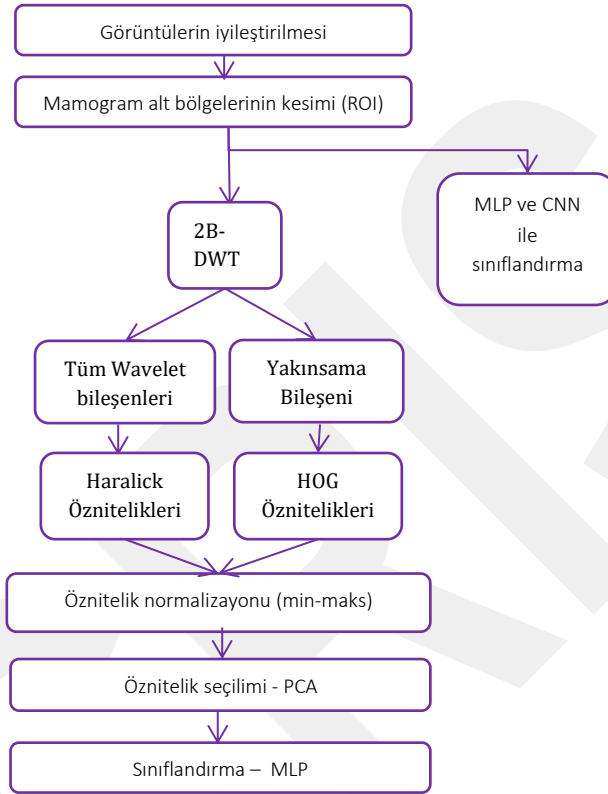
Şekil 1. Mamogram ROI veri seti (a) ROI görüntülerinden üç örnek (b) Sağlıklı görüntülerden üç örnek

Farklı boyutlarda kesilmiş görüntülerden oluşan veri seti öznitelik çıkarımında kullanılmıştır. Ancak ilerleyen deneylerde kullanılmış olan yöntemlerin aynı boyutlarda olan görüntülere ihtiyaç duyması sebebiyle VS1'in görüntüleri eşit boyutlara getirilerek ikinci bir veri seti (VS2) daha oluşturulmuştur. VS2'nin tüm görüntülerini boyutu 29x29 piksel olacak şekilde ayarlanmıştır. Her iki veri setinde de 208 normal, 114 anormal görüntü

bulunmaktadır.

2.2. ROI Algılanması (ROI Detection)


Önerilen yöntem üç ana görevi içermektedir: görüntü iyileştirilmesi, öznelik çıkarımı ve sınıflandırma. Mamogramların düşük görüntü kalitesini iyileştirmek ve belirsiz tümör bölgelerini daha belirgin yapmak için, orijinal mamogram görüntüleri üzerinde görüntü iyileştirme teknikleri kullanılmıştır. Öznelik çıkarımı, iyileştirilmiş mamogram görüntülerinden elde edilen görüntülere uygulanmıştır. Bir sonraki adımda, bir sınıflandırıcı, seçilen bölgeyi temsil eden özneliklerin bir ROI'ye veya sağlıklı bir dokuya ait olup olmadığına karar vermiştir. Önerilen yöntemin adımlarını özetleyen bir akış diyagramı Şekil 2'de gösterilmiştir.



Şekil 2. Önerilen ROI algılama yönteminin akış diyagramı

2.3. Görüntü İyileştirilmesi (Image Enhancement)

Mamogramdaki tümör bölgelerini vurgulamak için bir takım görüntü geliştirme teknikleri denenmiştir. Bu teknikler: histogram denkleştirme, genişleme süzgeci (dilation) ve CLAHE işlemleridir (Şekil 3). Görüntü iyileştirme işlemlerini uygulamak için Python'un OpenCV kütüphanesi kullanılmıştır (Bradski vd., 2008).



Şekil 3. Orijinal mamogram ve görüntü iyileştirme teknikleri uygulanmış mamogramlar (a) orijinal mamogram (b) histogram denkleştirme uygulanmış mamogram (c) genişleme süzgeci uygulanmış mamogram (d) CLAHE uygulanmış mamogram


2.3.1 Histogram Denkleştirme (Histogram Equalization)

Evrensel karşıtlığı ayarlamak için histogram eşitleme kullanılmıştır. Histogram denkleştirme için, öncelikle histogramdan yararlanılarak aşağıdaki gibi birikimli histogramlar çıkarılmaktadır:

$$s_k = T(r_k) = \frac{L-1}{MN} \sum_{i=0}^k n_i \quad (1)$$

Denklem 1’de histogram işlemi olan $T(\cdot)$ dönüşüm fonksiyonu verilmiştir. Burada piksel değeri k , girdi ve çıktı piksel değerleri r_k ve s_k , en büyük piksel değeri $L - 1$, resmin en ve boyu olan M ve N , i piksel değerine sahip toplam piksel sayısı n_i ile gösterilmiştir.

Bu adımı düzgeleme adımı takip etmektedir. Birikimli histogramın düzgelmesi, histogramın toplam piksel sayısına bölünmesi ile yapılmaktadır. Düzgeleme adımını ters dönüşüm takip etmektedir. Bu işlemten sonra yoğunlukların daha eşit olduğu gözlenmiştir. (Şekil 4)



Şekil 4. Histogram Denkleştirme Öncesi (a) ve Sonrası (b)

2.3.2 Genleşme Süzgeci (Dilation)

Genleşme süzgeci, bir nesnenin sınırına pikseller ekleyerek ve bir yapılandırma öğesi kullanarak, delikleri doldurmaktadır. Genleşme işlemi ikili resme uygulandığı gibi gri ölçekli resimlere de uygulanabilir. Bu çalışmada bahsedilen genleşme süzgeci \oplus , gri ölçekli düz yapılandırma elemanı b ile aşağıdaki denklemde verildiği gibi uygulanmıştır.

$$f \oplus b(x, y) = \max_{(s,t) \in b} \{f(x - s, y - t)\} \quad (2)$$

Denklem (2)’de verilen x ve y pikselin resim içerisindeki pozisyonunu, f girdi resmini, b yapılandırma elemanını, (s, t) yapılandırma elemanı içerisindeki piksel konumunu vermektedir. Bu işlem, b yapılandırma elemanı bütün resim üzerinde kaydırılarak her pozisyonda tekrarlanır.

2.3.3 Kontrast Limitli Histogram Denkleştirme (Contrast Limited Adaptive Histogram Equalization)

Karşıtlığı uyarlamalı olarak artırmak için CLAHE yöntemi kullanılmıştır. CLAHE operasyonun temeli uyarlanabilir Histogram Eşitleme’dir (AHE). Görüntü, karo adı verilen küçük bloklara bölünmüştür. AHE, her bir karo için histogramı Denklem 1’deki gibi eşitlemektedir. Döşemede biraz gürültü varsa, AHE gürültüyü artırmaktadır. Bu nedenle, bu sorunu önlemek için kontrast sınırlama kullanılmaktadır. Kontrast sınırının üzerinde herhangi bir histogram bölmesi varsa, bu pikseller kesilip eşit olarak dağıtılmaktadır. Eşitlemeden sonra, karo sınırlarının yapaylığını düzeltmek için doğrusal enterpolasyon uygulanmaktadır.

2.4. Öznitelik Çıkarımı (Feature Extraction)

Daha önceki çalışmamızda (Yengec-Tasdemir vd., 2018) mamogram görüntülerinden oluşan yarışma veri setinde iyi sonuç veren metodoloji MIAS veri seti için de takip edilmiştir: CLAHE işlemi uygulanıp kesilen resimlere bir kademeli, iki boyutlu kesikli dalgacık dönüşümü (2B-DWT) uygulanmıştır. 2B-DWT hesaplanması için Python’un PyWavelet kütüphanesi kullanılmıştır (Lee vd., 2018). 2B-DWT sonucu 4 farklı bileşen elde edilmiştir, bu bileşenler; düşük-düşük (LL), düşük-yüksek (LH), yüksek-düşük (HL), yüksek-yüksek (HH)’tir. Haralick’in dokusal öznitelikleri tüm bileşenlerden ayrı ayrı çıkartılmıştır. Bu işlem için de Python’un Mahotas kütüphanesi kullanılmıştır (Coelho, 2012). Yakınsama bileşeni olan LL’den ise HOG öznitelikleri çıkartılmıştır. Toplamda 72 tane öznitelik elde edilmiştir. Tablo 1, çıkarılan öznitelikleri ve hangi bileşenden çıkarıldığını göstermektedir.

Tablo 1. Özniteliklerin Çıkarıldığı Bileşenler ve Sayıları (Numbers and Components of Features)

Görüntü/Öznitelik Sayısı	Haralick	HOG
2B-DWT Tüm Bileşenler (LL, LH, HL, HH)	56	0
2B-DWT Yakınsama Bileşeni (LL)	0	16

3. Deneysel Sonuçları (Experimental Results)

Çıkarılan öznitelikler ile aşırı modellemeye dayanıklı olan Rastgele Orman algoritması kullanılarak, Histogram Denkleştirme, Genleşme Süzgeci ve CLAHE yöntemlerinin performansları kontrol edilmiştir. Sınıflandırma 10 katlı çapraz doğrulama (ÇD) ile VS1 üzerinde yapılmıştır. Tablo 2, bu deneylerin doğruluk ölçütlerini göstermektedir. Tablodan da görüldüğü üzere CLAHE işlemi sistemin başarısını arttırmıştır. Bu nedenle takip eden deneyler CLAHE işlemi uygulanmış görüntüler üzerinden yapılmıştır.

Tablo 2. Görüntü İyileştirme Yöntemlerinin Performansları (Performance of Image Enhancement Techniques)

Görüntü/Doğruluk Ölçüleri	F-Değerlendirme (Anormal Sınıf)	ROC Alanı (Anormal Sınıf)	Doğruluk (Genel)
Orijinal Görüntüler	%34	%54.2	%52
Histogram Denkleştirme	%42.6	%44	%43.5
Genleşme Süzgeci	%42	%44	%46.8
CLAHE uygulanmış Görüntüler	%42.1	%62.4	%58.8

ROI resimlerinden öznitelikler, öznitelik çıkarımı bölümünde anlatıldığı gibi çıkartılmıştır. Öznitelikler kullanılarak temel makine öğrenmesi yöntemleri ve 10 katlamalı ÇD ile VS1 üzerinde sınıflandırma yapılmıştır. Bu deneyin sonuçları Tablo 3'de gösterilmiştir. Tabloya göre en iyi doğruluk oranları Rastgele Orman ve Bagging kullanıldığında elde edilmiştir.

Tablo 3. Temel Makine Öğrenmesi Yöntemlerinin Performansı (Performance of Different Machine Learning Approaches)

Sınıflandırıcı/ Doğruluk Ölçüleri	Toplam Doğruluk (%)
Rastgele Orman	58.75
Lojistik Regresyon	58.02
KNN	57.66
Naïve Bayes	53.28
Karar Ağacı	54.01
Deste Vektör Makinesi	56.00
RBF Ağı	56.20
AdaBoost	55.47
Bagging	59.00

Çıkarılan öznitelik sayısının fazla olması modellerin karmaşıklaşmasına sebep olmaktadır. Bu nedenle bir başka deney olarak VS1 üzerinde özniteliklerin boyutunu küçültme algoritmaları bir önceki deneyde daha iyi sonuç veren Rastgele Orman algoritması ve 10 katlamalı ÇD kullanılarak değerlendirilmiş ve Tablo 4'de sonuçlar sunulmuştur. Denenen metotları arasında en iyi sonucu PCA vermiştir. PCA 82 olan öznitelik sayısını 5'e düşürmüştür. Temel makine öğrenmesi ve boyut küçültme algoritmaları WEKA yazılımı ile çalıştırılmıştır (Hall vd., 2009).

Tablo 4. Farklı Boyut Küçültme Algoritmalarının Performansı (Performance of Different Feature Selection Algorithms)

Algoritma/ Doğruluk Ölçüleri	Toplam Doğruluk (%)	F-değerlendirme (Anormal sınıf)(%)
CFS	58.39	58.0
İlinti Öznitelik Değerlendirme (Correlation Attribute Evaluation)	56.20	55.2
Kazanım Oranı (Gain Ratio)	58.02	57.3
Bilgi Kazanımı (Info Gain)	60.94	60.2
PCA	61.31	60.1
Relief Ranking	56.56	55.5
Simetrik Belirsizlik (Symmetrical Uncertainty)	58.75	58.2
Tek Kural Öznitelik (One Rule Attribute)	60.58	60.6

Bir başka deneyde literatürde görüntü sınıflandırma görevlerinde daha fazla tercih edilen çok katmanlı algılayıcı (MLP) VS2 üzerinde uygulanmıştır. Kullanılan MLP'nin girdi katmanı, bir adet gizli katmanı ve çıktı katmanı bulunmaktadır. Gizli katmanın 25 adet gizli birimi (M) bulunmaktadır. Gizli katman ve çıktı katmanının aktivasyon fonksiyonu hiperbolik tanjant ve maliyet fonksiyonu çapraz entropidir. Ağırlıklar $[-1,1]$ aralığında düzgün dağılım kullanarak rastgele başlatılmıştır. Başlangıçta sabit bir öğrenme oranı olan $\eta = 0.1$ kullanılmıştır. Optimum epok ve yineleme sayısını bulmak için erken durdurma kriteri kullanılmıştır. Bu kriterin çalışma prensibi takip eden adımlardan oluşmaktadır; veri setinin %80'i eğitim seti, %10'u doğrulama ve gerisi test seti olarak kullanılmıştır. En fazla 20 epok gerçekleştirilerek optimum sayıda epok ve yineleme, doğrulama veri seti kullanılarak bulunmuştur. Optimum sayıda yineleme ve epok bulunduğu, sınıflandırma eğitim ve test setleri kullanılarak optimum değerler ile yapılmıştır. Bu deney için sınıflandırıcının kodu TensorFlow kullanılarak yazılmıştır (Abadi vd., 2016).

MLP ağı eğitilirken veri setinde ağda belli bir öznitelik grubuna ağırlık verilmemesi için minimum-maksimum normalizasyonu yapılmıştır. Ayrıca önceki deneylerde iyi sonuç veren boyut küçültme algoritması MLP için de denenmiştir. Tablo 5'de normalizasyonu yapılan, boyut küçültme olan ve olmayan veri setleri kullanılarak MLP sınıflandırma ile 10 katlı ÇD sonuçları sunulmuştur. Tablodan da görüldüğü üzere boyut küçültme doğruluk sonuçlarını arttırmıştır.

Tablo 5. MLP ile 10-Katlı Çapraz Doğrulama Sonuçları (MLP Results for 10 Fold CV)

Görüntü/Doğruluk Ölçüleri	Doğruluk (Genel)
Normalizasyon yapılmış, boyut küçültme yapılmamış	%70.35
Normalizasyon yapılmış, boyut küçültülmüş	%72.5

MLP ağını optimum duruma getirmek için takip eden deneyler yapılmıştır: MLP üzerinde çevrimiçi öğrenme, toplu öğrenme yöntemi ve kısa-toplu öğrenme yöntemi kullanılarak birbiri ile bağlantılı olan iki deney yapılmıştır. Bu iki deneyde optimum öğrenme oranına yakınsamak için; ilk olarak farklı öğrenme oranları, ara-sonra-yakınsa öğrenme yaklaşımı kullanılarak (Denklemler 4) uygulanmıştır. İkincisinde momentum katsayısı kullanılarak optimum değere yakınsanmaya çalışılmıştır. Denklem 4'de n yineleme sayısını göstermektedir ve 1, 10, ..., 100.000 arasındaki değerleri, $\eta_0=0.1$ ve $\tau=10000$ değerlerini almıştır.

$$\eta(n) = \frac{\eta_0}{1 + \frac{n}{\tau}} \quad (4)$$

Deneyler 10-katlı ÇD kullanılarak VS2 üzerinde gerçekleştirilmiştir. Bu deneylerin sonuçları Tablo 6'da gösterilmiştir. 10 katlı çapraz doğrulama için sabit bir öğrenme oranı olan $\eta = 0.01$ kullanılmıştır.

Tablo 6. MLP'nin Farklı Optimizasyon Algoritmaları ile Kullanıldığında Gösterdiği Performans (Performance of different Optimization Algorithms on MLP)

Algoritma/ Doğruluk Ölçüleri	Çevrimiçi Öğrenme	Toplu öğrenme yöntemi	Kısa-Toplu öğrenme yöntemi
Sabit öğrenme oranı	%70.35	%55	%54
Ara-sonra-yakınsa	%64.28	%55	%55

Bir sonraki deneyde kısa-toplu öğrenme yöntemi için parametre optimizasyonu VS2 üzerinde, momentum katsayısı ve erken durdurma kriteri kullanılarak yapılmıştır. Bu optimizasyonun amacı ise objektif fonksiyonun gradyanını momentum kullanarak optimize ederek daha önce de belirtildiği gibi MLP ağının öğrenme başarısını arttırmaktır. Optimize edilen parameteler: epok sayısı (N_e), gizli katmandaki gizli birim sayısı (M), öğrenme oranı (η), kısa-toplu öğrenme boyutu (B_s) ve momentum katsayısı (α). Her bir parametre için kullanılan aralıklar aşağıdaki gibidir:

$$1 \leq N_e \leq 20$$

$$M = 50, 100, 150, 200, 250$$

$$B_s = 25, 50, 75, 100$$

$$\eta = 0.5, 0.1, 0.05, 0.01, 0.005, 0.001, 0.0005$$

$$\alpha = 0.5, 0.1, 0.05, 0.01, 0.005, 0.001, 0.0005$$

Parametre optimizasyonunun en iyi olan %75 doğruluk sonucu, $N_e=1$, $M=25$, $\alpha =0.5$ ve $\eta = 0.01$ olduğu kombinasyonda 10 katlı ÇD kullanıldığında elde edilmiştir. Parametre optimizasyonu kısa-toplu öğrenme yöntemi için momentum katsayısının doğruluk sonucu ile yaklaşık aynı sonucu vermiştir.

Önceki deneylerde yapılan optimizasyonlar MLP ağını veri setine istenilenden daha fazla uyumlu hale getirerek aşırı uyuma yol açabilir. Aşırı uyum ise MLP'nin performansını test verisi üzerinde düşürme ihtimalini ortaya çıkarmaktadır. Bundan kaçınmak için: L2-norm regülasyonu kullanılmıştır. Parametre optimizasyonunun yapıldığı deneyde kullanılan parametreler ile L2-norm regülasyonu gerçekleştirilmiştir. L2-norm regülasyonunda ise regülasyon katsayısı olan lambda (λ) değeri optimize edilmiştir. Lambda değer aralığı olarak [0.0001, 0.001, 0.01, 0.1, 1.0, 10, 100] kullanılmıştır. Bu deneyde elde edilen maksimum doğruluk olan %70, $M = 50$, $\lambda = 0.001$, $B_s = 50$, $\eta = 0.1$ olduğunda elde edilmiştir.

Tablo 6'da objektif fonksiyonunun gradyanını optimize etmek için Stokastik Eğim İnişi, Toplu Eğim İnişi ve Kısa Toplu Eğim İnişi kullanılmıştır. Bu yöntemlerin birbirlerinden farkı, ağı girdi olarak verilen veri miktarına bağlı olarak, ağı eğitmek için parametrelerin güncellenme sıklığının farklı olmasıdır. Sıralanan optimizasyonlara ek olarak öğrenme oranını parametrelere uyarlayan; Adam, Adagrad, AdaDelta ve RMSprop algoritmaları gerçekleştirilmiştir. Tablo 7'de de belirtildiği üzere bu deneyde en iyi sonucu %81.4 doğruluk oranı ile Adam optimizasyon algoritması %81.4 ile vermiştir (Tablo 7).

Tablo 7. Farklı Optimizasyon Teknikleri (Different Optimizations of MLP)

Sınıflandırıcı/ Doğruluk Ölçüleri	Ham Piksel Verisinde Toplam Doğruluk (%)
Hiper-parametre Optimizasyonu (En iyi sonuç)	%75
L2-norm	%70
ADAM	%81.4
Adagrad	%70.3
AdaDelta	%57
RMS Prop	%74

MLP ağını derinleştirerek daha kompleks bir hale getirip veri seti üzerindeki performansını değerlendirmek için iki ve üç gizli katmanlı MLP gerçekleştirilmiştir. Bu yeni gerçekleştirilen MLP'lerin yapısı daha önceki deneylerde kullanılan MLP'nin yapısı ile benzer bir şekilde oluşturulmuştur. Daha fazla gizli katman, daha fazla zaman alacağı için, kısa-toplu öğrenme kullanılmıştır. Gizli katmandaki gizli birim sayıları ve ara-sonra-yakınsa yöntemi'nin öğrenme oranı, gizli katmandaki gizli birim sayısı (M) ve kısa-toplu öğrenme boyutu (B_s) optimize edilmiştir. 2 gizli katman için en iyi sonuç olan %74 değeri $M = 50$, $B_s=25$ ve $\eta_0 = 0.001$ iken elde edilmiştir. 3 gizli katman

için, bir önceki deney tekrarlanmış ve en iyi sonuç olan %74 değeri $M = 50$, $B_s = 75$ ve $\eta_0 = 0.005$ iken elde edilmiştir (Tablo 8).

Tablo 8. Derin MLP Deney Sonuçları (Results of Deep MLP)

Sınıflandırıcı/ Doğruluk Ölçüleri	Ham Piksel Verisinde Toplam Doğruluk (%)
2-Katlı MLP (En iyi sonuç)	%74
3-Katlı MLP (En iyi sonuç)	%74

Yapılan tüm deneyler göz önüne alındığında en iyi doğruluk oranını Adam optimizasyon yöntemi vermiştir. Bu nedenle, farklı bir deney olarak, Adam daha derin olan 2 ve 3 gizli katmanlı MLP'lerde de kullanılmıştır. Adam optimizasyon yönteminin 1 gizli katmanlı MLP'de verdiği sonuç ile 2 ve 3 gizli katmanlı MLP'de verdiği sonuç aynı çıkmıştır.

Yapılan deneylere ek olarak, öznelik çıkarımı yapılmış veri seti yerine, literatürde büyük veri setlerinde kullanılan bir yöntem olan, görüntülerin ham piksel verisi kullanılarak MLP, Evrişimli Sinir Ağı (CNN), Transfer Öğrenim ile Derin Öğrenme Yöntemleri olan AlexNet, SqueezeNet, ResNet, VGGNet ile VS2 üzerinde eğitim yapılmıştır. Bir gizli katmanı olan MLP ($M = 50$, $B_s = 75$ ve $\eta_0 = 0.01$), bir konvolusyon, bir pooling ve bir tamamı bağlantılı katmanı bulunan basit bir CNN (kernel pencere boyutu= 5×5 , pooling pencere boyutu= 2×2 , stride= $[1,2,2,1]$) kullanılmıştır. Transfer öğrenimi ile derin öğrenme yöntemlerinin ise OpenAI kütüphanesinde bulunan varsayılan parametreleri kullanılmıştır. Eğitim tamamen bağlı katman üzerinde yapılmıştır. Sonuçlar Tablo 9'da gösterilmiştir. CNN'in verdiği doğruluk performansı SqueezeNet, ResNet ve AlexNet'ten daha iyi olduğu gözlenmektedir. Ancak özneliği çıkarılmış veri setinin gösterdiği performansın (%81) çok altında kalmıştır.

Tablo 9. Ham Görüntüler İle Eğitimin Performansı (Performance on raw pixel data)

Sınıflandırıcı/ Doğruluk Ölçüleri	Ham Piksel Verisinde Toplam Doğruluk (%)
MLP	%56
CNN	%68.9
Transfer Öğrenim ile AlexNet	%56.41
Transfer Öğrenim ile SqueezeNet	%66.7
Transfer Öğrenim ile ResNet18	%64.10
Transfer Öğrenim ile VGGNet	%52.56

4. Sonuç ve Tartışma (Results and Discussions)

Düşük görüntü kalitesi ve belirsiz tümör bölgeleri nedeniyle, görüntü iyileştirme teknikleri kullanılarak tespit doğruluğu %6.8 artırılmıştır. Deney sonuçları kısmındaki bulgular ışığında, tespit doğruluğunda oluşan bu artışın temelinde mamogram görüntülerinin ön işlemeden geçmeden önce düz ve silik renklerde olması, histogramları incelendiğinde de görüldüğü gibi ara renklerde dengesiz birikmelerin olduğu fark edilmiştir. Birikmelerden kaynaklanan bozuklukların ise önerilen çalışmadaki histogramın karşıtlık sınırlı ve uyarlamalı olarak dengelenmesi işlemleri ile düzeldiği görülmüştür.

Uygulanan temel sınıflandırma yöntemleri arasında, MLP etkin bir şekilde çalışmıştır ve model Adam optimizasyon algoritması kullanılarak eğitildiğinde %81.4'lük bir doğruluk vermiştir. Birden fazla gizli katmana sahip derin MLP modelleri de uygulanmıştır. Ancak diğer çalışmalardaki bulgulara paralel olarak (Serifovic-Trbalic vd. (2014), Jiao vd. (2017)) bunun, doğruluğa önemli bir katkı yapmadığı gözlenmiştir.

Bu çalışmada, MLP modellerine alternatif olarak, öznelikler yerine ham görüntüler MLP, CNN ve Transfer Öğrenim ile Derin Öğrenme Yöntemleri olan AlexNet, SqueezeNet, ResNet, VGGNet yapılarına da girdi olarak kullanılmıştır. Ancak bu deneyler daha iyi performans göstermemiştir. Yukarıda adı geçen yöntemlerden Transfer Öğrenimi yönteminin tespit doğruluğuna olumlu etki yapmadığı bu çalışmada olduğu gibi (Raghu vd. 2019) tarafından da gösterilmiştir. Transfer öğreniminin, RGB kamera görüntüleri gibi doğal görüntüler üzerinde etkin bir şekilde çalışsa bile, mamogram gibi doğal görüntülere benzemeyen, farklı renk dağılımları, şekiller ve nesnelere

içeren özel imgeler üzerinde çalışmaması beklenen bir durumdur. Çünkü ham piksel verisi ile eğitilen yapay sinir ağlarının ilk katmanlarında oluşan süzgeçler, doğal görüntülerin özneliklerini vurgulamak için özelleştirilmiş ve bu süzgeçler doğal olmayan mamogram gibi farklı dağılıma sahip görüntülerde etkin çalışmamaktadır.

Bununla birlikte, deney sonuçları göstermektedir ki CNN ve diğer transfer öğrenme ile derin modelleri çok küçük veri kümeleri üzerinde eğitildiklerinde geleneksel yöntemlerden daha iyi sonuçlar vermeyebilmektedir. Bu da Transfer Öğrenme kullanılmadığı zaman derin öğrenme yöntemlerinin verimli bir şekilde eğitilmesi için gereken büyük veri kümesinin yokluğunda oluşması beklenen bir durumdur.

Teşekkür (Acknowledgment)

Yazarlardan Sena Büşra YENGEC TAŞDEMİR, Yüksek Öğretim Kurumu tarafından, YÖK 100-2000 bursu ile desteklenmektedir.

Çıkar Çatışması (Conflict of Interest)

Yazarların herhangi bir çıkar çatışması yoktur.

Kaynaklar (References)

- "The mini-MIAS database of mammograms." [Online]. Available: <http://peipa.essex.ac.uk/info/mias.html>. [Accessed: 10-Feb-2019].
- Abadi, M., Barham, P., Chen, J., Chen, Z., Davis, A., Dean, J., ... & Kudlur, M. (2016). Tensorflow: A system for large-scale machine learning. In 12th {USENIX} symposium on operating systems design and implementation ({OSDI} 16) (pp. 265-283).
- Becker, A. S., Marcon, M., Ghafoor, S., Wurnig, M. C., Frauenfelder, T., & Boss, A. (2017). Deep learning in mammography: diagnostic accuracy of a multipurpose image analysis software in the detection of breast cancer. *Investigative radiology*, 52(7), 434-440.
- Coelho, L. P. (2012). Mahotas: Open source software for scriptable computer vision. arXiv preprint arXiv:1211.4907.
- Gedik, N. (2016). A new feature extraction method based on multi-resolution representations of mammograms. *Applied Soft Computing*, 44, 128-133.
- G. R. Lee et al., "PyWavelets/pywt: PyWavelets v1.0.0," Aug. 2018.
- Hall, M., Frank, E., Holmes, G., Pfahringer, B., Reutemann, P., & Witten, I. H. (2009). The WEKA data mining software: an update. *ACM SIGKDD explorations newsletter*, 11(1), 10-18.
- Jiao, Z., Gao, X., Wang, Y., & Li, J. (2018). A parasitic metric learning net for breast mass classification based on mammography. *Pattern Recognition*, 75, 292-301.
- Oeffinger, K. C., Fontham, E. T., Etzioni, R., Herzig, A., Michaelson, J. S., Shih, Y. C. T., ... & Wolf, A. M. (2015). Breast cancer screening for women at average risk: 2015 guideline update from the American Cancer Society. *Jama*, 314(15), 1599-1614.
- Pedro, R. W. D., Machado-Lima, A., & Nunes, F. L. (2019). Is mass classification in mammograms a solved problem?-a critical review over the last 20 years. *Expert Systems with Applications*, 119, 90-103.
- Raghu, M., Zhang, C., Kleinberg, J., & Bengio, S. (2019). Transfusion: Understanding transfer learning for medical imaging. In *Advances in neural information processing systems* (pp. 3347-3357).
- Rodriguez-Ruiz, A., Mordang, J. J., Karssemeijer, N., Sechopoulos, I., & Mann, R. M. (2018, July). Can radiologists improve their breast cancer detection in mammography when using a deep learning based computer system as decision support?. In 14th International Workshop on Breast Imaging (IWBI 2018) (Vol. 10718, p. 1071803). International Society for Optics and Photonics.
- Saki, F., Tahmasbi, A., Soltanian-Zadeh, H., & Shokouhi, S. B. (2013). Fast opposite weight learning rules with application in breast cancer diagnosis. *Computers in biology and medicine*, 43(1), 32-41.
- Šerifović-Trbalić, A., Trbalić, A., Demirović, D., Prljača, N., & Cattin, P. C. (2014, May). Classification of benign and malignant masses in breast mammograms. In 2014 37th International Convention on Information and Communication Technology, Electronics and Microelectronics (MIPRO) (pp. 228-233). IEEE.
- Tahmasbi, A., Saki, F. and Shokouhi, S. B. (2011) "Classification of benign and malignant masses based on Zernike moments", *Computers in Biology and Medicine*, 41, 726-735.
- Tasdemir, S. B. Y., Tasdemir, K., & Aydin, Z. (2018, December). ROI Detection in Mammogram Images using Wavelet-Based Haralick and HOG Features. In 2018 17th IEEE International Conference on Machine Learning and Applications (ICMLA) (pp. 105-109). IEEE.
- Yassin, N. I., Omran, S., El Houby, E. M., & Allam, H. (2018). Machine learning techniques for breast cancer computer aided diagnosis using different image modalities: A systematic review. *Computer methods and programs in biomedicine*, 156, 25-45.
- Yengec-Tasdemir, S. B., Tasdemir, K., & Aydin, Z. (2020). A review of mammographic region of interest classification. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, e1357.