

Ultrason RF Sinyallerinden Göğüs Kanserinin Derin Öğrenme Tabanlı Yaklaşımlarla Tespit Edilmesi

Fatih DEMİR^{1*}

¹ Teknik Bilimler Meslek Yüksekokulu, Fırat Üniversitesi, Elazığ, Türkiye

*1 fatihdemir@firat.edu.tr

(Geliş/Received: 07/07/2022;

Kabul/Accepted: 24/08/2022)

Öz: Göğüs kanseri kadınların en çok yakalandığı kanser türüdür. Bu hastalıkta erken teşhis çok önemlidir. Erken teşhis için kullanılan en önemli tıbbi teknolojiler arasında Manyetik Rezonans (MR) ve Ultrason (US) yer almaktadır. US ile teşhis MR ile teşhise göre daha az maliyetlidir fakat daha fazla deneyim gerektirir. Gelişen teknoloji ile yapay zekâyı kullanan otomatik karar destek sistemleri son derece popüler hale gelmiştir. Bu noktada bu çalışmada US RF sinyallerini kullanarak derin öğrenme tabanlı bir yaklaşımla göğüs kanseri otomatik teşhis edilmeye çalışılmıştır. Çalışmada kullanılan örnek sayısı fazla olmadığı için önceden eğitilmiş bir ESA modeli olan MobileNetV2 öznelik çıkarmak için kullanılmıştır. Sınıflandırma aşamasında ise bir topluluk sınıflandırıcısı olan ensemble RUSBoosted Tree (ERBT) algoritması tercih edilmiştir.

Anahtar kelimeler: US RF sinyaller, Göğüs Kanseri, Derin Öğrenme, Sınıflandırma.

Detection of Breast Cancer from Ultrasound RF Signals with Deep Learning-Based Approaches

Abstract: Breast cancer is the most common type of cancer in women. Early diagnosis is very important in this disease. Magnetic Resonance (MR) and Ultrasound (US) are among the most important medical technologies used for early diagnosis. Diagnosis with US is less costly than diagnosis with MR but requires more experience. With the developing technology, automatic decision support systems using artificial intelligence have become extremely popular. At this point, in this study, an automatic diagnosis of breast cancer was tried to be made with a deep learning-based approach using US signals. Since the number of samples used in the study was not large, MobileNetV2, a pre-trained ESA model, was used for feature extraction. In the classification phase, the ensemble RUSBoosted Tree (ERBT) algorithm, which is a community classifier, was preferred.

Key words: US signals, Breast Cancer, Deep Learning, Classification.

1. Giriş

Göğüs kanseri, kadınlarda en sık teşhis edilen kanserdir ve dünya çapında kansere bağlı ölümlerin önde gelen nedenidir [1]. Göğüs kanserinin erken teşhisi ve doğru teşhisi, hastaların etkin tedavisi ve hayatta kalması için çok önemlidir. Ultrason (US) görüntüleme, göğüs lezyonu karakterizasyonu için kullanılan popüler bir tıbbi görüntüleme yöntemidir. US düşük maliyetlidir, yaygın olarak bulunur ve göğüs kitlelerini yüksek doğrulukla ayırt etmek için kullanılabilir. Bununla birlikte, US taramalarının, bir US tarayıcısını çalıştırmada ve incelenen göğüs içindeki kitleyi bulmada usta olan yetenekli bir doktor tarafından alınması gerekir. Ayrıca US görüntülerinde göğüs kitlelerinin değerlendirilmesi subjektiftir ve radyoloğun deneyimine bağlıdır.

Sınıflandırma performansını iyileştirmek ve gereksiz biyopsilerden kaçınmak için US'de göğüs kitlelerini objektif olarak değerlendirmede radyologlara yardımcı olmak için çeşitli bilgisayar destekli tanı (CAD) sistemleri geliştirilmiştir [2–5]. CAD sistemleri, malign ve iyi huylu lezyonları ayırt etmek için yaygın olarak US görüntülerini kullanır. Ancak, US görüntülerindeki dokuların görünümü US tarayıcı ayarlarına bağlıdır (ör. tarayıcı kazancı, sıkıştırma). Örneğin, US görüntülerinin dokusu ve nesne kenarlarının görünürlüğü, çeşitli görüntü yeniden oluşturma yöntemleri ve görüntü son işleme algoritmaları kullanılarak değiştirilebilir [6]. Bu tür modifikasyonlar, US görüntülerini kullanan CAD sistemlerinin sınıflandırma performansı üzerinde olumsuz etkiye sahip olabilir [7]. Ayrıca, US görüntüsünün yeniden yapılandırılması işlemi sırasında, ham radyo frekansı (RF) sinyalleri tarafından taşınan doku yapısıyla ilgili bilgiler, ham US verilerini insan gözü için okunabilir kılmak için

* Sorumlu yazar: fatihdemir@firat.edu.tr. Yazarların ORCID Numarası: ¹ 0000-0003-3210-3664

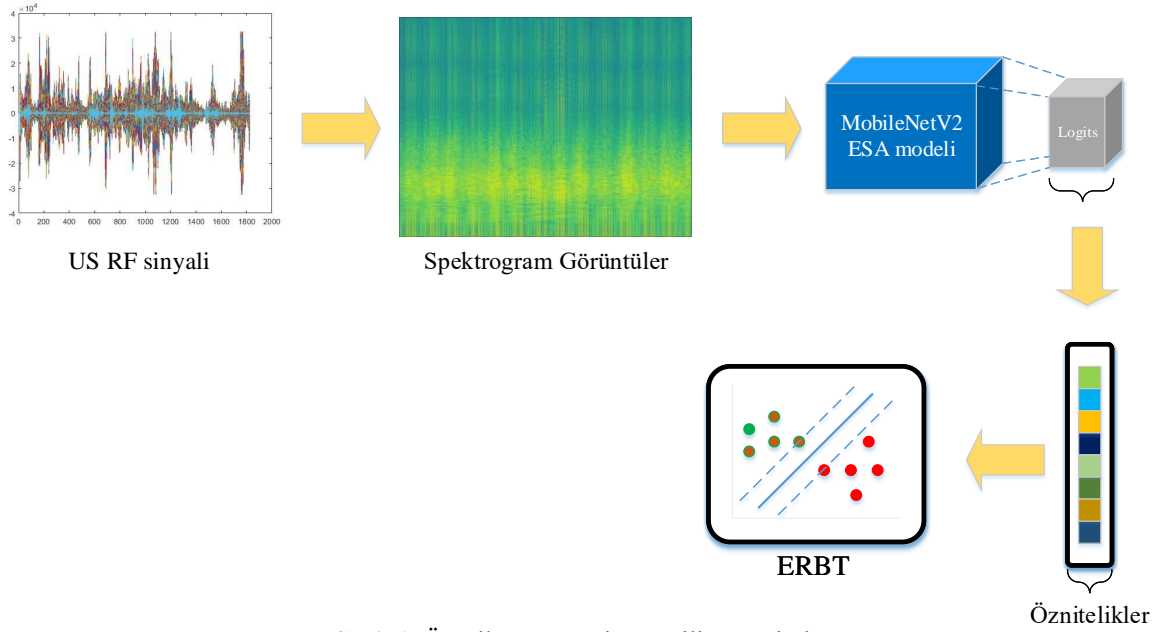
gerekli olan geri döndürülemez sıkıştırma nedeniyle kısmen kaybolur. Bir çare olarak, özellikleri doğrudan RF verilerinden çıkarmak için nicel US (NUS) yöntemleri geliştirilmiştir. NUS teknikleri, dokunun çeşitli yerel fiziksel özellikleriyle ilgili özellikleri tahmin etmek için genellikle küçük 2B RF verisi yamaları kullanır [8]. Örneğin, doku mikro yapılarının yerel uzaysal dağılımı, RF sinyal genliklerine dayalı olarak değerlendirilebilir [9]. Yaygın olarak, Nakagami ve homodinlenmiş K dağılımları, RF sinyal genliği istatistiklerini modellemek için kullanılır. Göğüs kitle sınıflandırması durumunda, Nakagami ve homodinli K dağılımlarının şekil parametreleri, birkaç makalede malign ve iyi huylu göğüs kitlelerini ayırt etmek için kullanılmıştır [10–13]. QUS teknikleri belirli doku modellerine dayalıyken, Uniyal ve ark. küçük 2 boyutlu RF verilerinden ve US görüntülerinden elde edilen genel el yapımı özelliklere dayanan bir göğüs kitle sınıflandırma yöntemi geliştirdi [14]. Bu durumda, RF verilerine dayalı olarak çeşitli spektral özellikler hesaplanmıştır. Ayrıca, gri seviyeli birlikte oluşum matrisi ile ilgili özellikler, US görüntülerine dayalı olarak tahmin edildi. Ayrıca, Ouyang ve ark. malign ve iyi huylu göğüs kitlelerini ayırt etmek için H-scan yöntemiyle US saçılımlarının göreceli boyutunu değerlendirdi [15].

Evrişimli sinir ağlarına (ESA'lar) dayalı derin öğrenme yöntemleri, tıbbi görüntü analizi alanında önem kazanmaktadır. ESA, evrişim benzeri işlemler gerçekleştiren en az bir katman içeren bir yapay sinir ağıdır [16]. ESA'lar sıklıkla zaman alanını ve mekansal verileri işlemek için kullanılmıştır [17,18]. Bunlar, öncelikle çevrimsel denklik, parametre paylaşımı ve seyrek bağlantı gibi evrişimsel katmanların özelliklerinden dolayı, tamamen bağlı sinir ağlarına oldukça başarılı bir alternatif olarak kabul edilirler [19–23]. US görüntüleme, derin ESA'lar birçok çalışmada göğüs kitle sınıflandırmasına başarıyla uygulanmıştır [24–30]. Nispeten küçük veri kümeleri nedeniyle, yukarıda bahsedilen çalışmaların yazarları, US görüntülerine dayalı sınıflandırıcılar geliştirmek için ImageNet veri seti üzerinde önceden eğitilmiş derin ESA'larla farklı transfer öğrenme teknikleri uygulamışlardır [31]. Örneğin, [24]'da yazarlar, destek vektör makine sınıflandırıcılarını eğitmek için VGG19 ESA'dan çıkarılan özellikleri kullandılar. Bu arada, [25], [30]'te önceden eğitilmiş ESA'lar malign ve iyi huylu göğüs kitlelerini ayırt etmek için ince ayar yapıldı.

Bu çalışmada US sinyalleri kullanılarak göğüs kanseri otomatik olarak teşhis edilmeye çalışılmıştır. Bunun için ilk önce US sinyalleri spektrogram görüntüleri dönüştürülmüştür. Bu görüntüler MobilenetV2 derin öğrenme modeline iletilmiştir. Bu modelde derin öznetelikler çıkarılmıştır. Bu öznetelikler kullanılarak ERBT algoritması ile sınıflandırma yapılmıştır.


2. Materyal ve Metodoloji

Bu çalışmada US RF sinyallerinden göğüs kanserini otomatik olarak saptamak için derin öğrenme temelli bir yaklaşım önermiştir. Önerilen yaklaşım 3 safhadan oluşmaktadır. İlk safhada US RF sinyallerinin spektrogram görüntüleri elde edilmiştir. Spektrogram görüntülerin elde edilmesinin amacı sinyallerin hem frekans hem de zaman bölgesine göre temsillerinin oluşturulmasıdır. Ayrıca farklı sinyal türlerinden (EMG, EEG gibi) elde edilen spektrogram görüntüler birçok sınıflandırma probleminde iyi bir performans elde edilmesini sağlamıştır. Dahası spektrogram görüntüler ile farklı boydaki sinyaller standart giriş boyutlarına getirilmektedir. Yapılan çalışmada da spektrogram görüntüler 875×656 boyutunda oluşturulmuştur. Daha sonra hem donanım gereksinimi azaltmak hem de kullanılacak olan MobileNetV2 modelinin standart boyutunu elde etmek için tüm spektrogram görüntüler 224×224 olarak yeniden boyutlandırılmıştır. Daha sonraki aşamada derin öznetelikler çıkarmak için bir önceden eğitilmiş ESA olan MobileNetV2 modelinin ağırlıkları kullanılmıştır. Spektrogram girişlerle MobileNetV2 modelinin Logits isimli katmanının ağırlık değeri aktive edilerek öznetelikler çıkarılmıştır. Son safhada sınıflandırma için makine öğrenmesinde popüler olan DVM, K-EYK, Karar Ağacı (KA), Lineer Ayırtaç (LA), Saf Bayes (SB), Torbalama Ağaçları Topluluğu (TAT), Güçlendirilmiş Ağaçlar Topluluğu (GAT) ve ERBT algoritmaları kullanılmıştır. En iyi performans ERBT algoritması ile elde edilmiştir. Önerilen yaklaşımın temsili gösterimi Şekil -1'de verilmiştir.



2.1. Veri seti


Deneyleri gerçekleştirmek için 52 kötü huylu ve 48 iyi huylu lezyondan kaydedilen US RF sinyal çerçevelerini içeren halka açık OASBUD veri setini kullandık . Malign kitleler biyopsi ile, iyi huylu kitleler ise biyopsi veya 2 yıllık takip ile değerlendirildi. Her kütle için, 10 MHz'lik bir nominal merkezi iletim frekansında çalışan L14-5/38 lineer dizi dönüştürücü ile donatılmış Ultrasonix SonixTouch Research US tarayıcısı (Ultrasonix Inc., Kanada) kullanılarak iki ortogonal tarama (enine ve boyuna) elde edildi. Her durumda, odak bölgesi lezyon derinliğine ayarlanmış olarak tek odaklı hüzmleme uygulandı. Her bir RF sinyal çerçevesi için, örnekleme frekansı 40 MHz'e eşit olan 512 tarama çizgisi toplanmıştır. US görüntüleri, RF verilerine dayanarak yeniden oluşturuldu ve deneyimli bir radyolog tarafından her bir göğüs kitle alanını gösteren ilgi bölgelerini (ROI'ler) belirlemek için kullanıldı. Veri seti hakkında daha fazla bilgi orijinal belgede bulunabilir [32]. Şekil 1, bir göğüs kütlelerinin yeniden yapılandırılmış ve tarama çizgilerinden birine karşılık gelen tek bir US RF sinyalini göstermektedir.



2.2. Metodoloji Tanımlamaları

MobileNetV1 [33], Google çalışanlarının 2017 yılında önerdiği, mobil veya gömülü cihazlar için uyumlu hafif-ağırlıklı bir ESA mimarisidir. MobileNetV1, klasik evrişimin iki safhasını, başka bir deyişle derinleme evrişim ve noktasal evrişim işlemini katmalar derinleştikçe ayıran evrişim işlemini kullanmaktadır. MobileNetV1 yapısında bit çarpımı hesabı kanallar temel alınarak yapılır ve kanal sayısı sabit kalır. Sonrasında, 1×1 evrişim çekirdeği kanal adedi değişmesinde sakınca yoktur. MobileNetV1 hiperparametre seçimi ile hız ve güvenilirlik arasındaki optimizasyon yapılabilir.

MobileNetV2 [34], MobileNetV1 modelinin güncellenmiş bir versiyonudur. MobileNetV2 modelinde ters yapıli artık bloklar ve lineer darboğazlar eklenmiştir. Derinlemesine evrişim stratejisinde, kanal sayısının değiştirilmemesi öznetelik çıkarımında giriş kanal sayısının sınırlı kalmasına neden olmaktadır. Tersine yapıli artık bloklar ile bu sorun ortadan kalkar. Genel olarak bir artık blok, 1×1 boyutlu evrişim filtresi, 3×3 boyutlu evrişim filtresi ve 1×1 boyutlu artan evrişim filtresi düzeninde olan yapı tersine çevrilmiş artık yapıda 1×1 boyutlu artan evrişim filtresi, 3×3 boyutlu derinlemesine evrişim filtresi ve 1×1 boyutlu evrişim filtresi düzenindedir. Tersine yapıli artık bloktaki aktive işlevi, öğrenme işlemini hızlandırır, gradyan dağılımını ise dengeler ve modelin kararlılık performansını artırır. MobileNetV2 mimarisinin blok düzeni Şekil 3'te verilmiştir.




Şekil 3. MobileNetV2 modelinin blok şeması.

Sınıflandırma aşamasında ERBT algoritması kullanılmıştır. ERBT algoritmasındaki Rastgele yetersiz örnekleme artırma (RUSBoost), dengesiz verileri sınıflandırmada özellikle etkilidir, yani eğitim verilerindeki bazı sınıfların diğerlerine göre çok daha az üyesi vardır [35]. RUS, Rastgele Düşük Örnekleme anlamına gelir. Algoritma, örnekleme için temel birim olarak eğitim verilerinde en az üyeye sahip sınıftaki üye sayısı olan N'yi alır. Daha fazla üyeye sahip sınıflar, her sınıfın yalnızca N gözlemi alınarak örneklenir. Başka bir deyişle, eğer K sınıfı varsa, topluluktaki her zayıf öğrenen için RUSBoost, K sınıfının her birinden N gözlemi olan bir veri alt kümesini alır. Güçlendirme prosedürü, topluluğu yeniden ağırlıklandırmak ve oluşturmak için Çok Sınıflı Sınıflandırma için Uyarlamalı Yükseltme'deki prosedürü takip eder.

3. Deneysel Çalışma ve Sonuçlar

Gerçekleştirilen çalışmadaki tüm kodlamalar Intel marka i7 işlemcili (5500U), 8GB DDR3 bellekli, 512 SD depo kapasiteli bir dizüstüne kurulu MATLAB 2020a simülasyon programında gerçekleştirilmiştir. Kodlamada ilk adım olarak US RF sinyalleri spektrogram görüntülere çevrilmiştir. Bu adımda pencereleme, çakışma boyutu, örnekleme frekansı ve Fourier serisi boyutu sırasıyla 1000, 100, 500 ve 1000 olarak seçilmiştir. Pencereleme için "Hamming" kullanılmıştır. Öznetelik çıkarmak için MobileNetV2 modelinin Logits isimli tamamen bağlı katmanının ağırlıkları kullanılmıştır. Bu katmanda 1000 adet düğüm bulunmaktadır. Dolayısıyla 1000 adet öznetelik çıkarılmıştır. 1. ve 2. özneteliklere göre iyi huylu ve kötü huylu örneklerin saçılımı Şekil 4'te verilmiştir. Mavi renk kötü huylu örnekleri kırmızı renk kötü huylu örnekleri temsil etmektedir. Şekil 4'ten de görüldüğü gibi sınıflar arasında lineer bir dağılım yoktur. Dolayısıyla lineer bir sınıflandırıcı ile iyi bir başarımlı elde etmek mümkün değildir. Sınıflandırma aşamasında KA, LA, SB, DVM, K-EYK, TAT, YAT ve ERBT algoritmaları kullanılmıştır. Bu sınıflandırıcılar ile elde edilen sınıflandırma doğrulukları Tablo 1'de verilmiştir. Tüm sınıflandırıcılar için 10-kat çapraz doğrulama tekniği kullanılmıştır. Tablo 1'den de görüldüğü gibi en iyi sınıflandırma doğruluğu (%71) ERBT algoritması ile elde edilirken en kötü sınıflandırma doğruluğu YAT algoritması ile edilmiştir.

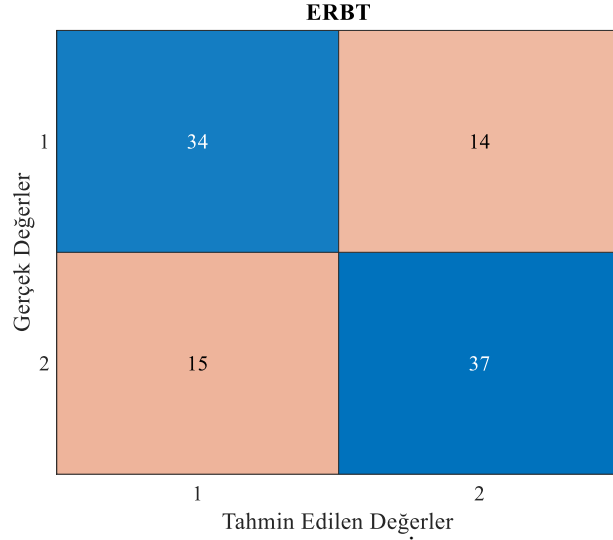


Şekil 4. Özniteliklerin saçılım düzeni için örnek gösterim.

Tablo 1. Sınıflandırıcılara göre doğruluk sonuçları

Sınıflandırıcılar	Doğruluk (%)
KA	65
LA	61
Saf Bayes (SB)	67
Lineer DVM	61
Fine K-EYK	60
TAT	62
YAT	52
EnsembleRUSBoosted Tree (ERBT)	71

En iyi başarımın elde edildiği ERBT algoritması için karmaşıklık matrisi Şekil 5’te verilmiştir. Şekil 5’teki “1” iyi huylu sınıfları, “2” ise kötü huylu sınıfları temsil etmektedir. Şekil 5’ten de görüldüğü gibi iyi huylu sınıfta 48 örnekten 14 adedi yanlış tahmin edilmiştir, kötü huylu sınıfta 52 örnekten 15 adedi yanlış tahmin edilmiştir. Karmaşıklık matrisindeki doğru pozitif, doğru negatif, yanlış pozitif ve yanlış negatif değerleri kullanılarak duyarlılık, özgüllük, kesinlik ve F-skor performans metrikleri hesaplanmıştır. Bu değerler Tablo 2’de verilmiştir.



Şekil 5. Karmaşıklık matrisi sonuçları: 1: İyi huylu, 2: Kötü huylu.

Tablo 2’den de görüldüğü gibi iyi huylu sınıf için duyarlılık, özgüllük, kesinlik ve F-skor metriklerinde sırasıyla 0.708, 0.712, 0.694 ve 0.701 değerleri, kötü huylu sınıf için 0.712, 0.708, 0.725 ve 0.718 değerleri elde edilmiştir.

Tablo 2. Diğer performans metriklerinin sonuçları

Sınıflar	Duyarlılık	Özgüllük	Kesinlik	F-Skor
İyi huylu	0.708	0.712	0.694	0.701
Kötü huylu	0.712	0.708	0.725	0.718

Tablo 3’te aynı veri setini kullanan Larrue ve diğerleri [10] Nakagami parametresine dayanan istatistiksel analiz yöntemi ile sınıflandırma yapmıştır. Bu yöntem ile %61.1 sınıflandırma doğruluğu ve 0.64 AUC değerleri elde edilmiştir.

Tablo 3. Aynı veri setini kullanan yöntem ile karşılaştırma

Metot	Model	Doğruluk (%)	AUC
Larrue ve diğerleri [10]	Nakagami parametre temelli sınıflandırıcı	61.10	0.64
Önerilen metot	Spektrogram Görüntüler+MobileNetV2+ERBT	71.00	0.71

4. Sonuçlar

Bu çalışmada, US RF sinyallerinden kötü huylu göğüs kanserini saptamak için derin öğrenme temelli bir yaklaşım kullanılmıştır. Bu yaklaşımda 2 boyutlu güçlü temsiller elde etmek için spektrogram görüntüleri oluşturulmuştur. Bu temsiller MobileNetV2 modelinde kullanılmıştır. Bu modelden öznetelikler çıkarılmıştır. Çıkarılan özneteliklerde en iyi sınıflandırma performansını ERBT algoritması (%71) sağlamıştır. Önerilen yaklaşım aynı veri setini kullanan başka bir yöntemin performansına göre geliştirilmiştir. Sınıflandırma doğruluğu yaklaşık %10 kadar AUC değeri 0.7 kadar artırılmıştır. Buna rağmen alınan sonuç karar destek uygulamasında kullanılmak için yeterli başarı düzeyinde değildir. Bunun için veri setinin boyutunun artırılması gerekmektedir. Ayrıca daha büyük veri seti ile sıfırdan oluşturulmuş ESA modelleri ile de başarı artırılabilir.

Kaynaklar

- [1] H. Sung, J. Ferlay, R.L. Siegel, M. Laversanne, I. Soerjomataram, A. Jemal, F. Bray, Global Cancer Statistics 2020: GLOBOCAN Estimates of Incidence and Mortality Worldwide for 36 Cancers in 185 Countries, CA. Cancer J. Clin. 71 (2021) 209–249. <https://doi.org/10.3322/caac.21660>.
- [2] H.-D. Cheng, J. Shan, W. Ju, Y. Guo, L. Zhang, Automated breast cancer detection and classification using ultrasound images: A survey, Pattern Recognit. 43 (2010) 299–317.
- [3] J. Virmani, R. Agarwal, Assessment of despeckle filtering algorithms for segmentation of breast tumours from

- ultrasound images, *Biocybern. Biomed. Eng.* 39 (2019) 100–121.
- [4] G.-G. Wu, L.-Q. Zhou, J.-W. Xu, J.-Y. Wang, Q. Wei, Y.-B. Deng, X.-W. Cui, C.F. Dietrich, Artificial intelligence in breast ultrasound, *World J. Radiol.* 11 (2019) 19.
- [5] W.G. Flores, W.C. de Albuquerque Pereira, A.F.C. Infantosi, Improving classification performance of breast lesions on ultrasonography, *Pattern Recognit.* 48 (2015) 1125–1136.
- [6] M.L. Oelze, J. Mamou, Review of quantitative ultrasound: Envelope statistics and backscatter coefficient imaging and contributions to diagnostic ultrasound, *IEEE Trans. Ultrason. Ferroelectr. Freq. Control.* 63 (2016) 336–351.
- [7] P.-H. Tsui, C.-C. Chang, Imaging local scatterer concentrations by the Nakagami statistical model, *Ultrasound Med. Biol.* 33 (2007) 608–619.
- [8] X. Yu, Y. Guo, S.-M. Huang, M.-L. Li, W.-N. Lee, Beamforming effects on generalized Nakagami imaging, *Phys. Med. Biol.* 60 (2015) 7513.
- [9] J. Virmani, R. Agarwal, Effect of despeckle filtering on classification of breast tumors using ultrasound images, *Biocybern. Biomed. Eng.* 39 (2019) 536–560.
- [10] A. Larrue, J.A. Noble, Modeling of errors in nakagami imaging: Illustration on breast mass characterization, *Ultrasound Med. Biol.* 40 (2014) 917–930. <https://doi.org/10.1016/j.ultrasmedbio.2013.11.018>.
- [11] M. Byra, A. Nowicki, H. Wróblewska-Piotrkowska, K. Dobruch-Sobczak, Classification of breast lesions using segmented quantitative ultrasound maps of homodyned K distribution parameters, *Med. Phys.* 43 (2016) 5561–5569.
- [12] N. Uniyal, H. Eskandari, P. Abolmaesumi, S. Sojoudi, P. Gordon, L. Warren, R.N. Rohling, S.E. Salcudean, M. Moradi, Ultrasound RF time series for classification of breast lesions, *IEEE Trans. Med. Imaging.* 34 (2014) 652–661.
- [13] Y. Ouyang, P.-H. Tsui, S. Wu, W. Wu, Z. Zhou, Classification of benign and malignant breast tumors using h-scan ultrasound imaging, *Diagnostics.* 9 (2019) 182.
- [14] Y. Liao, P. Tsui, C. Li, K. Chang, W. Kuo, C. Chang, C. Yeh, Classification of scattering media within benign and malignant breast tumors based on ultrasound texture-feature-based and Nakagami-parameter images, *Med. Phys.* 38 (2011) 2198–2207.
- [15] I. Trop, F. Destrepes, M. El Khoury, A. Robidoux, L. Gaboury, L. Allard, B. Chayer, G. Cloutier, The added value of statistical modeling of backscatter properties in the management of breast lesions at US, *Radiology.* 275 (2015) 666–674.
- [16] I. Goodfellow, Y. Bengio, A. Courville, *Deep learning*, MIT press, 2016.
- [17] K.J. Lang, A.H. Waibel, G.E. Hinton, A time-delay neural network architecture for isolated word recognition, *Neural Networks.* 3 (1990) 23–43.
- [18] Y. LeCun, B. Boser, J.S. Denker, D. Henderson, R.E. Howard, W. Hubbard, L.D. Jackel, Backpropagation applied to handwritten zip code recognition, *Neural Comput.* 1 (1989) 541–551.
- [19] F. Demir, B. Taşçı, An Effective and Robust Approach Based on R-CNN+LSTM Model and NCAR Feature Selection for Ophthalmological Disease Detection from Fundus Images, *J. Pers. Med.* 11 (2021) 1276. <https://doi.org/10.3390/jpm11121276>.
- [20] F. Demir, K. Demir, A. Şengür, DeepCov19Net: Automated COVID-19 Disease Detection with a Robust and Effective Technique Deep Learning Approach, *New Gener. Comput.* (2022) 1–23. <https://doi.org/10.1007/s00354-021-00152-0>.
- [21] F. Demir, K. Siddique, M. Alswaitti, K. Demir, A. Sengur, A Simple and Effective Approach Based on a Multi-Level Feature Selection for Automated Parkinson’s Disease Detection, *J. Pers. Med.* 12 (2022) 55. <https://doi.org/10.3390/jpm12010055>.
- [22] F. Demir, Deep autoencoder-based automated brain tumor detection from MRI data, in: *Artif. Intell. Brain-Computer Interface*, Elsevier, 2022: pp. 317–351. <https://doi.org/10.1016/b978-0-323-91197-9.00013-8>.
- [23] F. Demir, DeepBreastNet: A novel and robust approach for automated breast cancer detection from histopathological images, *Biocybern. Biomed. Eng.* 41 (2021) 1123–1139. <https://doi.org/10.1016/j.bbe.2021.07.004>.
- [24] N. Antropova, B.Q. Huynh, M.L. Giger, A deep feature fusion methodology for breast cancer diagnosis demonstrated on three imaging modality datasets, *Med. Phys.* 44 (2017) 5162–5171.
- [25] S. Han, H.-K. Kang, J.-Y. Jeong, M.-H. Park, W. Kim, W.-C. Bang, Y.-K. Seong, A deep learning framework for supporting the classification of breast lesions in ultrasound images, *Phys. Med. Biol.* 62 (2017) 7714.
- [26] M. Byra, Discriminant analysis of neural style representations for breast lesion classification in ultrasound, *Biocybern. Biomed. Eng.* 38 (2018) 684–690.
- [27] M.H. Yap, G. Pons, J. Marti, S. Ganau, M. Sentis, R. Zwigelaar, A.K. Davison, R. Marti, Automated breast ultrasound lesions detection using convolutional neural networks, *IEEE J. Biomed. Heal. Informatics.* 22 (2017) 1218–1226.
- [28] M.H. Yap, M. Goyal, F.M. Osman, R. Martí, E. Denton, A. Juette, R. Zwigelaar, Breast ultrasound lesions recognition: end-to-end deep learning approaches, *J. Med. Imaging.* 6 (2018) 11007.
- [29] M. Byra, M. Galperin, H. Ojeda-Fournier, L. Olson, M. O’Boyle, C. Comstock, M. Andre, Breast mass classification in sonography with transfer learning using a deep convolutional neural network and color conversion, *Med. Phys.* 46 (2019) 746–755.
- [30] X. Qi, L. Zhang, Y. Chen, Y. Pi, Y. Chen, Q. Lv, Z. Yi, Automated diagnosis of breast ultrasonography images using deep neural networks, *Med. Image Anal.* 52 (2019) 185–198.
- [31] O. Russakovsky, J. Deng, H. Su, J. Krause, S. Satheesh, S. Ma, Z. Huang, A. Karpathy, A. Khosla, M. Bernstein,

- others, Imagenet large scale visual recognition challenge, *Int. J. Comput. Vis.* 115 (2015) 211–252.
- [32] H. Piotrkowska-Wróblewska, K. Dobruch-Sobczak, M. Byra, A. Nowicki, Open access database of raw ultrasonic signals acquired from malignant and benign breast lesions, *Med. Phys.* 44 (2017) 6105–6109. <https://doi.org/10.1002/mp.12538>.
- [33] A.G. Howard, M. Zhu, B. Chen, D. Kalenichenko, W. Wang, T. Weyand, M. Andreetto, H. Adam, Mobilenets: Efficient convolutional neural networks for mobile vision applications, *ArXiv Prepr. ArXiv1704.04861*. (2017).
- [34] M. Sandler, A. Howard, M. Zhu, A. Zhmoginov, L.-C. Chen, Mobilenetv2: Inverted residuals and linear bottlenecks, in: *Proc. IEEE Conf. Comput. Vis. Pattern Recognit.*, 2018: pp. 4510–4520.
- [35] C. Seiffert, T.M. Khoshgoftaar, J. Van Hulse, A. Napolitano, RUSBoost: Improving classification performance when training data is skewed, in: *2008 19th Int. Conf. Pattern Recognit.*, IEEE, 2008: pp. 1–4.