



Tomosentez Görüntüleri ile Yapılan Derin Öğrenme Çalışmalarında Kullanılan Görüntü Ön İşleme Yöntemleri Üzerine Bir Literatür Araştırması

Elif Aydıngöz^{1*}, Mert Bal²

^{1*} Yıldız Teknik Üniversitesi, Kimya Metalurji Fakültesi, Matematik Mühendisliği Bölümü, İstanbul, Türkiye, (ORCID: 0009-0005-2143-6326), elif.aydingoz@std.yildiz.edu.tr

² Yıldız Teknik Üniversitesi, Kimya Metalurji Fakültesi, Matematik Mühendisliği Bölümü, İstanbul, Türkiye (ORCID: 0000-0001-6250-929X), mertbal@yildiz.edu.tr

(İlk Geliş Tarihi 11 Haziran 2023 ve Kabul Tarihi 6 Temmuz 2023)

(DOI: 10.31590/ejosat.1312965)

ATIF/REFERENCE: Aydıngöz, E. & Bal, M. (2023). Tomosentez Görüntüleri ile Yapılan Derin Öğrenme Çalışmalarında Kullanılan Görüntü Ön İşleme Yöntemleri Üzerine Bir Literatür Araştırması. *Avrupa Bilim ve Teknoloji Dergisi*, (51), 352-367.

Öz

Bu makale, tomosentez görüntülerinin derin öğrenme çalışmalarında kullanılmasına odaklanarak, görüntü ön işleme yöntemleri üzerine bir literatür araştırması sunmaktadır. Tomosentez, meme dokusunun 3 boyutlu, kesitsel olarak taranmasını sağlayan gelişmiş bir tıbbi görüntüleme tekniğidir. Bu teknikle elde edilen görüntüler 2 boyutlu mamografilere oranla daha yüksek boyutlu olduğu gibi daha gürültülü de olabilirler. Bu nedenle bu görüntülerin derin öğrenme modellerine uygun hale getirilmesi için ön işleme yapılması gerekmektedir. Bu literatür araştırması, tomosentez görüntülerinde kullanılan farklı ön işleme yöntemlerini ele almaktadır. Öncelikle Tomosentez görüntülerinin özellikleri ve derin öğrenme yöntemleri hakkında bir giriş yapılacaktır. Daha sonra, kullanılan ön işleme yöntemleri arasında yer alan filtreleme, normalizasyon, segmentasyon ve artırma gibi teknikler hakkında yapılan literatür araştırmasına ait bilgi verilecektir. Ayrıca, bu yöntemlerin bir arada kullanıldığı örnekler de incelenecektir. Sonuç olarak, bu makale ile Tomosentez görüntüleri üzerinde derin öğrenme çalışmaları yapmak isteyen araştırmacılara faydalı bir Türkçe kaynak sunmak hedeflenmektedir. Yapılan araştırma, görüntü ön işleme yöntemlerinin doğru seçiminin, derin öğrenme modellerinin performansını önemli ölçüde artırabileceğini göstermektedir.

Anahtar Kelimeler: Derin Öğrenme, Görüntü Ön İşleme, Tomosentez, Meme Kanseri.

A Literature Review on Image Preprocessing Methods Used in Deep Learning Studies Using Tomosynthesis Images

Abstract

This article presents a literature review on image preprocessing methods, focusing on the use of tomosynthesis images in deep learning studies. Tomosynthesis is an advanced medical imaging technique that provides 3-dimensional, cross-sectional scanning of breast tissue. The images obtained with this technique can be higher dimensional and noisier than 2D mammograms. Therefore, preprocessing is required to make these images suitable for deep learning models. This literature review addresses the different preprocessing methods used in tomosynthesis images. First of all, an introduction will be made about the properties of Tomosynthesis images and deep learning methods. Then, information about the techniques such as filtering, normalization, segmentation and augmentation, which are among the preprocessing methods used, will be given from the literature search. In addition, examples where these methods are used together will also be examined. In conclusion, with this article, it is aimed to present a useful Turkish resource to researchers who want to do deep learning studies on Tomosynthesis images. The research shows that the right choice of image preprocessing methods can significantly improve the performance of deep learning models.

Keywords: Deep Learning, Image Pre-Processing, Tomosynthesis, Breast Cancer.

* Corresponding Author: elif.aydingoz@std.yildiz.edu.tr

1. Giriş

Global Burden of Disease Study 2019 (GBD 2019) verilerine göre, meme kanseri dünya genelinde önemli bir sağlık sorunu olarak karşımıza çıkmaktadır. Meme kanseri, kadınlar arasında en sık görülen kanser türü olup, aynı zamanda kansere bağlı ölümlerde de önemli bir paya sahiptir.

GBD 2019'a göre:

- Meme kanseri, dünya genelinde yaklaşık olarak 2.3 milyon yeni vaka ile en yaygın ikinci kanser türüdür.
- Kadınlarda, meme kanseri vakalarının oranı %24.5 ile en yüksek seviyededir ve bu nedenle kadınlar için büyük bir risk faktörüdür.
- Erkeklerde ise meme kanseri daha az görülse de, erkeklerin yaklaşık %1'inde meme kanserine rastlanmaktadır.

Meme kanseri nedeniyle yaşanan ölümler açısından bakıldığında ise, dünya genelinde yaklaşık 685.000 kişi hayatını kaybetmektedir.

Meme kanserinin erken teşhisi ve etkili tedavisi için tomosentez gibi gelişmiş görüntüleme teknolojileri ve derin öğrenme yöntemleri kullanılması büyük önem taşımaktadır. Bu sayede hastaların yaşam kalitesi artırılabilir ve sağlık hizmetlerinin etkinliği ve verimliliği iyileştirilebilir.

Üç boyutlu bir görüntüleme tekniği olan dijital meme tomosentezi (Digital Breast Tomosynthesis-DBT), daha önce tespit edilmemiş kanserleri yakalamadaki üstün yeteneği nedeniyle dijital mamografi için yeni altın standart olarak ortaya çıkmıştır (Vedantham ve diğerleri, 2015). Farklı açılardan alınan düşük doz X ışınları kullanılarak memenin 3 boyutlu görüntüsünü üreten bir görüntüleme yöntemidir (Hooley ve diğerleri, 2017; Helvie, 2010). DBT, meme kanseri taraması için (mamografide olduğu gibi) projeksiyon görüntüleri yerine her meme için birden çok kesitsel dilim sunduğundan performansı da daha yüksektir.

Taramada DBT ile kanser tespiti açısından denemeler umut verici sonuçlar vermesine rağmen, dijital mamografi'ye (Digital Mammography-DM) kıyasla yorumlama süresinin artması büyük bir dezavantajdır. Gözden geçirilmesi gereken görüntülerin sayısındaki önemli artış nedeniyle, DBT görüntülerinin yorumlanmasının, DM görüntülerini okumak için gereken sürenin yaklaşık iki katına çıktığı tutarlı bir şekilde bildirilmiştir (Skaane ve diğerleri, 2013).

DBT'nin büyük ölçekli tarama programlarına dahil edilmesi, yalnızca klinik sonuçlar üzerindeki etkisine değil, aynı zamanda okuma süresini azaltacak yöntemlerin getirilmesine de bağlı olacaktır. Bu görüntüleri yorumlamaya yönelik otomatik yöntemler, tarama için DBT'nin tanıtılması potansiyelinde kesinlikle bir etkiye sahip olacaktır. Bu etki iki yönlü olabilir; her şeyden önce, DBT görüntü yığınının bilgisayar destekli daha hızlı gezinmesi, radyoloğun şüpheli bulguları görsel olarak aramak için harcadığı süreyi önemli ölçüde azaltabilir. Ek olarak, DBT görüntülerinin yorumlanmasına yardımcı olmak için bilgisayar yöntemlerinin kullanılması, okuyucular arası varyans azaltılırsa, DBT'nin tarama sırasında hatırlama oranı üzerindeki etkisinde çalışmalarda görülen değişkenliği azaltabilir (Sechopoulos ve diğerleri, 2021).

Tomosentez görüntüleri, geleneksel meme görüntüleme yöntemlerine göre daha yüksek çözünürlüğe sahip olduğu için daha ayrıntılı bir görüntüleme sağlar. Derin öğrenme algoritmaları ise, bu ayrıntılı görüntüler üzerinde daha hassas analizler gerçekleştirerek kanserli dokuları tespit etmek için daha uygun bir araç sağlayabilirler. Ayrıca, derin öğrenme algoritmaları sayesinde tomosentez görüntülerindeki çeşitli özellikler (örneğin, kanserli hücrelerin şekilleri ve boyutları) daha iyi analiz edilebilir ve bu da daha doğru bir teşhis imkanı sunar. Bu nedenle, tomosentez görüntüleri üzerinde derin öğrenme kullanımı, meme kanseri teşhisinde ve prognozunda daha etkili bir yaklaşım olabilir.

Tomosentez görüntüleri üzerinde derin öğrenme kullanımı, meme kanseri teşhisi için yeni bir yöntem olarak öne çıkmaktadır. Derin öğrenme algoritmalarının tomosentez görüntülerindeki yüksek çözünürlüklü ayrıntıları analiz edebilme kabiliyeti, meme kanseri tespitinde daha yüksek doğruluk oranları sağlayabilir ve erken teşhis için önemli bir araç olabilir.

Kullanılan algoritmaların en yüksek doğrulukta sonuçlar üretebilmesi görüntüleri en optimal seviyede öğrenmeleri gerekmektedir. Lezyon ve kalsifikasyonların görüntüler üzerinde net olarak çıkarılabilmesi, sınırlarının çizilebilmesi en önemli unsurdur. Aynı zamanda DBT görüntülerinde rastgele dağıtılan X ışını fotonları, bu görüntülerin kalitesini etkiler ve gürültüye sebep olur.

Göğüs pectoral kasları (Pectoral Muscle-PM) bir meme dokusuna çok benzerken, PM bölgelerinin yoğunluğu ortalama değerden daha yüksektir. Kitlesel aday bölgelerin yoğunluğu da normal meme dokularından daha yüksektir ve çoğu aday kitle tanımlama yaklaşımı, prosedürlerinde bunu kullanır. Bu nedenle, PM'lerin tanımlanması ve çıkarılması, DBT'leri analiz ederken kullanılması gereken önemli ön adımlardır (Yousefi ve diğerleri, 2018).

Bu çalışmada, derin öğrenme yöntemleri ve tomosentez görüntülerinin derin öğrenme algoritmaları ile birlikte en optimal sonucu verebilmeleri için uygulanması gereken görüntü ön işleme yöntemleri detaylı olarak incelenecektir.

2. Derin Öğrenme

Derin öğrenme, 2006 yılında makine öğrenimi araştırmasının bir alt dalı olarak ortaya çıkmıştır. Derin yapılandırılmış öğrenme veya hiyerarşik öğrenme olarak da adlandırılmaktadır.

DL'nin radyoloji pratiğindeki en önemli uygulamalarından biri, doku-iskelet anormalliklerinin tespiti ve hastalıkların sınıflandırılmasıdır. Evrişimli sinir ağının en önemli DL algoritmalarından biri olduğu ve göğüs radyografilerindeki anormallikleri ve patolojileri tespit etmede en etkili teknik olduğu kanıtlanmıştır (Lu ve diğerleri, 2019).

2.1. Tanım

Derin Öğrenme, makine öğreniminin bir alt kümesi ve yapay zekanın büyük bir alt kümesidir ve makinelerin belirli bilgi türlerini elde etmede ve durumsal bilgi geliştirmede insanları nasıl taklit ettiğini yansıtır (Zhao ve diğerleri, 2020; Usuga Cadavid ve diğerleri, 2022).

İnsanların göreve özel yazılım programları geliştirmesini gerektirmek yerine DL, yapılandırılmamış meta verileri alır ve sağlanan bilgilere dayalı olarak artan ve öngörülebilir eylemler gerçekleştirmek için kendini eğitir (Usuga Cadavid ve diğerleri, 2022; Schwenzow ve diğerleri, 2021).

ML'nin bir alt kümesi olan DL, insan beyninde bulunan bilgi işleme modellerinden esinlenmiştir. DL'nin çalışması için insanlar tarafından tasarlanmış herhangi bir kural gerekmez; bunun yerine, verilen girdiyi belirli etiketlere eşlemek için büyük miktarda veri kullanır. DL, her biri kendilerine beslenen verilerin farklı bir yorumunu sağlayan çok sayıda algoritma katmanı kullanılarak tasarlanmıştır. Geleneksel makine öğrenimi tekniklerini kullanarak sınıflandırma görevini gerçekleştirmek, özellikle ön işleme, özellik çıkarma, akıllı özellik seçimi, öğrenme ve sınıflandırma gibi birkaç sıralı adım gerektirir. Ayrıca, özellik seçiminin ML tekniklerinin performansı üzerinde büyük etkisi vardır. Taraflı özellik seçimi, sınıflar arasında yanlış ayırım yapılmasına neden olabilir. Tersine, DL, geleneksel ML yöntemlerinin aksine, çeşitli görevler için özellik kümelerinin öğrenimini otomatikleştirme yeteneğine sahiptir. DL, öğrenme ve sınıflandırmanın tek seferde gerçekleştirilmesini sağlar. (LeCun ve diğerleri., 2015).

2.2. Derin Öğrenme Mimarileri

Derin öğrenme yöntemleri için birçok farklı mimari ve model bulunmaktadır. Bu bölümde sık kullanılan derin öğrenme mimarilerinden bahsedilecektir.

2.2.1. Evrişimsel Sinir Ağları

Evrişimsel Sinir Ağları (Convolutional Neural Network-CNN veya ConvNet), insan özelliği çıkarımına ihtiyaç duymadan doğrudan girdiden öğrenen popüler bir ayırmacı derin öğrenme mimarisidir. CNN, geleneksel YSA benzeri düzenlenmiş MLP ağlarının tasarımını geliştirir. CNN'deki her katman, model karmaşıklığını azaltmanın yanı sıra anlamlı bir çıktı için optimum parametreleri dikkate alır. CNN ayrıca, geleneksel bir ağda ortaya çıkabilen aşırı uydurma sorunuyla başa çıkabilen bir "bırakma" kullanır.

CNN'ler, özellikle çeşitli 2B şekillerle başa çıkmak için tasarlanmıştır. Bu nedenle en yaygın kullanıldığı alanlarından başında görsel tanıma, tıbbi görüntü analizi, görüntü bölümlenme ve doğal dil işleme gelmektedir. İnsan müdahalesine ihtiyaç duymadan verilen girdi ile temel özellikleri otomatik olarak keşfedebilme yeteneği, onu geleneksel ağlardan daha güçlü kılmaktadır. Öğrenme yeteneklerine göre çeşitli uygulama alanlarında kullanılacak CNN'nin çeşitli varyantları mevcuttur; VGG, AlexNet, Xception, Inception, ResNet vb. (Sarker, 2021).

2.2.2. Tekrarlayan Sinir Ağları

Tekrarlayan Sinir Ağı (Recurrent Neural Network-RNN), giriş verilerindeki zaman veya sıra bağımlılıklarını modellemek için tasarlanmıştır. Verileri sırayla işleyebilen ve önceki adımlardaki bilgileri hatırlayabilen özel bir yapıya sahip popüler bir sinir ağıdır.

İleri besleme ve CNN'e benzer şekilde, RNN'ler de eğitim girdisinden öğrenir. Fakat önceki aşamaların bilgilerini kullanarak mevcut girdiyi ve çıktığı pekiştirmelerine izin veren "bellekleri" ile farklılaşırlar. Girdilerin ve çıktılarının bağımsız olduğunu kabul eden DNN'lerden farklı olarak, RNN'nin çıktısı dizideki önceki veriler ile ilişkilidir. (Sarker, 2021).

RNN'ler, uzun veri dizilerinde bazı zorluklarla karşılaşabilir ve etkinliği azalabilir. Bunun nedeni, RNN'lerin uzun vadeli bağımlılıkları koruma yeteneklerinin sınırlı olması ve "gradyan kaybolması" veya "gradyan patlaması" gibi sorunlarla karşılaşabilmesidir.

Gradyan kaybolması, RNN'lerin geriye doğru yayılım sırasında çok küçük veya sıfıra yakın gradyanlara sahip olması anlamına gelir. Bu durum, uzun vadeli bağımlılıkları korumayı zorlaştırır, çünkü uzak geçmişteki bilgilerin güncellemeye çok az katkısı olur. Gradyan patlaması ise tam tersine, gradyanların hızla büyümesi ve ağıstikarsız hale gelmesi anlamına gelir.

2.2.3. Uzun Kısa Süreli Hafıza Ağları

Uzun Kısa Süreli Hafıza Ağları (Long Short-Term Memory Networks-LSTM), ilk olarak 1997'de Hochreiter ve Schmidhuber tarafından tanıtılmıştır. LSTM'nin birincil hedefleri, uzun vadeli bağımlılıkları modellemek ve zaman serisi problemleri için en uygun zaman gecikmesini belirlemektir. (Hochreiter & Schmidhuber, 1997).

Bir LSTM, bir girdi katmanı, bir yinelenen gizli katman ve bir çıktı katmanı olmak üzere üç kapı tarafından yönetilir.

Geleneksel sinir ağlarından farklı olarak gizli katmanın temel birimi bellek bloğudur. Bellek bloğu, geçici durumu ezberleyen kendi kendine bağlantılara sahip bellek hücrelerini ve bloktaki bilgi akışını kontrol etmek için bir çift uyarlanabilir, çoğaltıcı kapılama birimini içerir. Sırasıyla giriş kapısı ve çıkış kapısı olarak adlandırılan iki ek kapı, bloğa giriş ve çıkış aktivasyonlarını kontrol eder. Bellek

hücresinin çekirdeği, Sabit Hata Karuseli (Constant Error Carousel-CEC) olarak adlandırılan, tekrar tekrar kendi kendine bağlanan doğrusal bir birimdir. CEC'nin aktivasyonu hücre durumunu temsil eder. CEC'nin varlığı nedeniyle, çarpımsal kapılar açılıp kapanmayı öğrenebilir ve böylece LSTM, ağ hatasını sabit tutarak yok olan hata problemini çözebilir. (Alguliyev ve diğerleri, 2019)

2.2.4. Kısıtlanmış (Derin) Boltzmann Makineleri

Kısıtlı Boltzmann makinesi (RBM), görünür bir değişken katmanının dağılımını modellemek için bir gizli ikili değişkenler veya birimler katmanı kullanan olasılıksal bir modeldir. Simetrik olarak birleştirilmiş stokastik ikili birimlerden oluşur. Basit bir derin Boltzmann makinesi, bir sıra halinde bir dizi görünür birim ve çok sayıda gizli birim katmanı içerir. Görünürden gizliye (alt katman) ve gizliden gizliye katmanlar arasındaki bağlantılar yönsüzdür (Salakhutdinov & Hinton, 2009).

Bu bağlamda genellikle iki yaklaşım izlenir. İlk olarak, bir RBM, girdilerin dağılımını modellemek için denetimsiz bir şekilde eğitilir (muhtemelen birden fazla RBM eğitilebilir ve bunları üst üste istifleyebilir (Hinton ve diğerleri, 2006)). Ardından, RBM iki yoldan biriyle kullanılır: ya gizli katmanı, girdi verilerini gizli katman tarafından verilen temsille değiştirerek önceden işlemek için kullanılır ya da RBM'nin parametreleri, bir ileri beslemeli sinir ağını başlatmak için kullanılır. Her iki durumda da, eldeki denetimli öğrenme problemini çözmek için RBM başka bir öğrenme algoritmasıyla (önceden işlenmiş girdileri kullanan sınıflandırıcı veya sinir ağı) eşleştirilir. Bu yaklaşım ne yazık ki aynı anda her iki hiper parametre setinin (RBM ve diğer öğrenme algoritmasınkiler) ayarlanmasını gerektirir. Ayrıca, RBM denetimsiz bir şekilde eğitildiğinden, denetlenen görevin çözülmesi gereken doğasına karşı kördür ve gizli katmanı tarafından çıkarılan bilgilerin faydalı olacağına dair hiçbir garanti vermez. (Salakhutdinov & Larochelle, 2009).

Deep Boltzmann'ın makineleri, belirsiz girdileri ele almak için daha iyi bir yol sağlayan yukarıdan aşağıya bir geri bildirim oluşturmak için kullanılabilen yönlendirilmemiş mimarisi nedeniyle oldukça popülerdir (Salakhutdinov & Larochelle, 2009).

2.2.5. Derin İnanç Ağları

Derin inanç ağları (Deep Belief Network-DBN), çok sayıda gizli birim katmanına sahip olasılıksal üretken grafik modellerdir. Derin bir inanç ağının temel yapı taşı, kısıtlı Boltzmann makinesi (RBM) olarak bilinen yönlendirilmemiş iki parçalı bir grafik modeldir (Salakhutdinov & Murray, 2008). Derin inanç ağının inşası, sigmoidal inanç ağına benzer (Bengio, 2009).

Derin inanç ağı için öğrenme farklıdır çünkü ağırlıklı katman katman eğitim tekniğini kullanır. Katman katman eğitimde, alt katmanlar eğitilirken üst katmanların olmadığı varsayılır. 2006 yılında, bu üst katmanların göz ardı edilmediği, ancak bağlı ağırlıkların kullanıldığı yeni bir yaklaşım getirilmiştir (Hinton, Osindero, & The, 2006). Mevcut katmandaki ağırlıkları daha yüksek katman ağırlıklarından aşamalı olarak çözerek tamamlayıcı bir önceki oluşturmak için bağlı ağırlık kullanımı eski tekniklerden çok daha etkilidir (Zorzi, Testolin ve Stoianov, 2013).

Özetle, üretken öğrenme teknikleri, tipik olarak keşif analizi yoluyla verilerin yeni bir temsili oluşturmamıza izin verir. Sonuç olarak, bu derin üretken ağlar, denetimli veya ayırıcı öğrenme görevleri için ön işleme olarak kullanılabilir ve ayrıca denetimsiz temsili öğrenmenin gelişmiş sınıflandırıcı genellemeye izin verebileceği model doğruluğunu sağlar (Sarker, 2021).

2.2.6. Derin Oto-Kodlayıcılar

Oto-kodlayıcılar (Autoencoders-AE), esas olarak girdiyi sıkıştırılmış ve anlamlı bir temsile kodlamak ve ardından yeniden oluşturulan girdinin orijinaline mümkün olduğunca benzer olacak şekilde kodunu çözmek için tasarlanmış belirli bir sinir ağı türüdür. Otomatik kodlayıcılar girdisini yeniden yapılandırmak için eğitilmiş bir sinir ağı olarak tanıtılmıştır. Ana amaçları, denetimsiz bir şekilde, kümeleme gibi çeşitli çıkarımlar için kullanılabilir verilerin bilgilendirici bir temsili öğrenmektir.

Otomatik kodlayıcılar genel olarak veri boyutunu azaltmak, veri sıkıştırma, veri temsili öğrenimi, görüntü restorasyonu, jeneratif modeller ve anormallik tespiti gibi uygulamalarda yaygın olarak kullanılır.

Devasa veri setlerinin boyutsallığını azaltmak için de kullanılan temel bileşen analizi, esasen doğrusal aktivasyon fonksiyonuna sahip tek katmanlı bir AE'ye benzer. Seyrek, gürültü giderici ve büzülmeli gibi düzenli otomatik kodlayıcılar daha sonraki sınıflandırma görevleri için öğrenme temsilleri için yararlıdır, varyasyonel otomatik kodlayıcılar ise aşağıda tartışılan üretici modeller olarak kullanılabilir (Sarker, 2021).

3. Literatür Araştırması

Zhang ve diğerleri (2019), önceden eğitilmiş 2D Evrişimli Sinir Ağları (Convolutional Neural Network-CNN) kullanmamızı sağlayan tam hacimli DBT sınıflandırması için yeni bir yaklaşım önermeyi amaçladıkları çalışmalarında özel bir klinik veri seti kullanmışlardır. Bu veri seti 3018 negatif ve 272 malign örnek içermektedir. Her biri 1024 × 1024'lük orijinal DBT dilimleri kullanılmıştır. Veri setinde genelliğe yardımcı olmak için rastgele yatay çevirmeler ve 0, 90, 180 veya 270 derecelik döndürmeler ile veri artırma işlemi gerçekleştirilmiştir. Bu sayede eğitim veri seti boyutu 8 kat artırılmıştır. Hazırlanan veri seti ile AlexNet, ResNet50 ve Xception olmak üzere üç yaygın sınıflandırma ağı test edilmiştir. (Zhang ve diğerleri, 2019)


Amit ve diğerleri (2017), meme görüntülerini iyi huylu ve kötü huylu olarak sınıflandıran iki Derin Evrişimli Sinir Ağı (Deep Convolutional Neural Network-DCNN) tekniğini tanıtmıştır. Açıklamalı görüntüler, açıklamalı sınırların çevresinde bir kare sınırlayıcı kutu kullanılarak kırılmış ve 891 malign (Breast Imaging-Reporting and Data Systems, BI-RADS 5) ve 365 benign (BI-RADS 2)

görüntü elde edilmiştir. Bu görüntüler döndürme (90° , 180° , 270°) ve kaydırma (sağ-sol, aşağı-yukarı) kullanılarak büyütülmüştür. (Amit ve diğerleri, 2017)

Buda ve diğerleri (2021), meme kanseri taraması için yapay zeka algoritmalarının geliştirilmesini ve değerlendirilmesini kolaylaştırmak için dijital göğüs tomosentezi (DBT) görüntülerinin büyük ölçekli bir veri setini düzenlemek, açıklama eklemek ve kamuya açık hale getirmek; meme kanseri tespiti için temel bir derin öğrenme modeli geliştirmek ve gelecekteki araştırmalar için bir temel olarak hizmet edecek bir veri setini kullanarak bu modeli test etmek amacıyla yaptığı çalışmada 16802 DBT görüntüsü kullanmıştır. İlk olarak, DICOM (Digital Imaging and Communications in Medicine) dosya başlığındaki bilgilere dayalı olarak görüntüleri pencere seviyelendirmesiyle temel bir ön işleme uygulanmıştır. Daha sonra, hesaplama ve bellek ayak izini azaltmak için 2×2 yerel ortalama filtresi kullanılarak her bir dilim 2 faktörü ile küçültülmüştür. Bundan sonra, sıfır olmayan görüntü piksellerini, dış yüzey kaldırma için 5 piksel yarıçaplı bir filtreyle aşındırmışlardır. Son olarak, göğüs bölgesini bölümlere ayırmak için sıfır olmayan piksellerin en büyük bağlı bileşenini çıkarmışlardır. (Buda ve diğerleri, 2021)

Ricciardi ve diğerleri (2021), derin evrişimli sinir ağına (DCNN) dayalı, dijital meme tomosentezi (DBT) açıklamalı muayenelerinde kitle lezyonlarının varlığı/yokluğunun otomatik olarak sınıflandırılması için bilgisayarlı bir algılama sistemi geliştirmek amacıyla bir çalışma yapmıştır. Görüntü düzeyinde (DBT dilimi) çalışan AlexNet ve VGG19 DCNN mimarileri karşılaştırılmıştır. Bu çalışmada kullanılan DBT veri seti iki farklı hastaneden (H1 ve H2) temin edilen verilerden oluşmuştur. DBT muayene seti, sırasıyla H1 ve H2 için yinelemeli ve filtrelenmiş geri projeksiyon (Filtered Back Projection-FBP) yeniden yapılandırma teknikleri kullanılarak yeniden yapılandırılmış düzlemler için 1 mm dilim aralığına ve $90 \times 90 \mu\text{m}^2$ 'lik bir düzlem içi çözünürlüğe göre yeniden yapılandırılmıştır. Yeniden yapılandırılmış dilimler 16 bit/ piksel çözünürlüğe sahiptir. Beyaz gürültüyü azaltmak için tüm görüntüleri ImageJ yazılımı kullanılarak geliştirilen bir gürültü giderme algoritması ile işlenmişlerdir. Algoritma, görüntüdeki 300×300 piksellik seçili bir ilgi alanı (Region of Interest Coding-ROI) içindeki gürültüyü değerlendirilmiş ve ölçülen gürültü değeri tüm görüntüden çıkarılmıştır. Burada, ROI'nin boyutu temel bir seçimdir, çünkü algoritmayı çok büyük bir matrise uygulamak, ağ öğrenimiyle ilgili bilgileri çıkarmak için çok bulanık olan son bir görüntü anlamına gelir. Şekil 1, bu algoritmanın uygulanmasının bir örneğini göstermektedir: burada gösterildiği gibi, önemli bir gürültü azaltma ve daha iyi bir kenar keskinliği elde edilebilir. Son adım olarak, bitişik piksellerin ortalamasını alan yeniden boyutlandırma algoritması kullanılarak dilimlerin boyutları başlangıç boyutlarından (H1 veri seti için 1072×2356 piksel ve H2 veri seti için 1996×2457 piksel) 300×300 piksele düşürülmüştür. Görüntüyü bindirme gerekliliği, mevcut GPU mimarisindeki bir donanım sınırlamasından kaynaklanmaktadır. 300×300 piksellik maksimum boyut, deneme yanılma sonrasında ve aramayı donanımın desteklediği maksimum değerle sınırlayarak belirlenmiştir. Bu verilerden 242 dilim (1996×2457 piksel), ImageJ yazılımındaki bir makro prosedür kullanılarak özel olarak geliştirilen otomatik bir prosedürle kraniyokaudal görünümde elde edilmiştir. Bu görüntüler, ilk veri setinde kullanılan benzer bir arka plan normalleştirme ve düzeltme prosedürü izlenerek işlenmiştir. Bu veri kümesinin sınırlı sayıda görüntüsü nedeniyle bir veri artırma prosedürü uygulanmıştır. Görüntüler, birincisi dilimin dikey eksenine göre ve ikincisi merkezi yatay eksene göre olmak üzere iki yansıma ve ardından $[-35^\circ, +35^\circ]$ aralığında 10° ile döndürülmüştür. Tüm bu prosedürler ile orijinal veri setindeki 242 DBT diliminden 3024 dilim elde edilmiştir. (Ricciardi ve diğerleri, 2021)

Şekil 1. Derin CNN'yi beslemek için a) ön işlemeden önce ve b) ön işlemeden sonra aynı vakaya ait iki tomosentez görüntüsünün karşılaştırılması. Sonradan işlenmiş görüntüde (b), kuantum gürültüsünde bir azalma ve meme içindeki yapıların kenarlarının vurgulandığını görebiliriz.



Singh ve diğerleri (2020), çalışmalarında, orijinal olarak Tam Alan Dijital Mammografi (Full Field Digital Mammography- FFDM) incelemeleri için geliştirilen DL malignite modellerini, mevcut DBT veri miktarının oldukça sınırlı olduğu durumlarda DBT incelemelerine uyarlama yöntemlerine odaklanmışlardır. 3D DBT görüntülerinin büyük boyutunun üstesinden gelmek için, bunun yerine bu 3D hacimlerin maksimum yoğunluk projeksiyonunu (Maximal Intensity Projection-MIP) dikkate almışlardır. FFDM görüntülerinin yamaları üzerinde eğitilmiş bir modeli MIP görüntülerinin yamalarına uyarlamanın çeşitli yöntemleri değerlendirilmiş ve karşılaştırmışlardır. Bu sayede histogram eşleştirmenin etki alanı kaymasını azaltma ve uyarlama problemini basitleştirme üzerindeki etkisini de vurgulamışlardır. Çalışmada kullanılan DL modeli, 29 katman ve yaklaşık 6 milyon parametre içeren ResNet12 tabanlı modeldir. Bir FFDM veya MIP görüntüsünden 512×512 görüntü yamasını kabul eder ve yamanın kötü huylu veya yüksek riskli bulgu

içerme olasılığını tahmin eder. Orijinal görüntüler, FFDM görüntüleri için 4096×3328 veya 3328×2560 piksele veya MIP görüntüleri için 2457×1996 veya 2457×1890 piksele sahiptir. Modele girdi elde etmek için, görüntüden 1024×1024 piksellik bir ilk yama çıkarılmış ve çift doğrusal enterpolasyon ile 512×512 piksele altörneklenmiş ve orijinal görüntünün yarı çözünürlüğünde bir yama elde edilmiştir. Ortaya çıkan yama, orijinal görüntünün alanının %7,7-12,3'ünü kaplamıştır. Görüntüler, eğitim sırasında rastgele yatay ve dikey çevirme, 1 standart sapmalı toplam Gauss beyaz gürültüsü, 20 piksel standart sapmalı bir Gauss dağılımından alınan rastgele çeviri, -30 dereceden +30 dereceye tekdüze bir dağılımdan çizilen rastgele döndürme ile artırılmıştır.

Bir alandaki kümülatif histogramı başka bir alanın ortalama kümülatif histogram değerine dönüştürmek için doğrusal olmayan bir dönüşüm kullanılır, buna histogram eşleştirme (Histogram Matching-HM) denir. Bu çalışmada özellikle, modeli eğitmek için orijinal olarak kullanılan FFDM görüntüleriyle daha iyi eşleşmesi için MIP görüntülerini dönüştürmek için HM kullanılmıştır. HM için prosedür, Algoritma 1'de özetlenmiştir.

FFDM verilerinin ortalama kümülatif histogramı, eşit miktarda normal, iyi huylu ve kötü huylu sınıflardan oluşan rastgele seçilmiş 1200 eğitim örneği üzerinden hesaplanmıştır. Benzer şekilde, MIP verilerinin ortalama kümülatif histogramı, eşit miktarda normal, iyi huylu ve kötü huylu sınıflardan oluşan rastgele seçilmiş 600 eğitim örneği üzerinden hesaplanmıştır. Histogram eşleştirme uygulaması Şekil 2'de niteliksel olarak görselleştirilebilir. (Singh ve diğerleri, 2020)

Algoritma 1: Histogram eşleştirme

Algoritma, iki alandan görüntüleri eşleştirme histogram prosedürünü açıklar. Burada $X[i]$, X görüntüsünün i 'inci piksel değerini temsil eder. Referans alanındaki bir piksel değerine ters eşleme, lineer enterpolasyon ile gerçekleştirilir.

Input: Kaynak görüntü $X_S \in [0, K - 1]^N$,

Kaynak kümülatif histogram $F_S \in \mathbb{N}_0^K$,

Referans kümülatif histogram $F_R \in \mathbb{N}_0^L$

Output: Histogram eşleştirilmiş görüntü $X'_S \in [0, L - 1]^N$

for i in 0 to $N-1$ **do**

$$\rho_S = X_S[i]$$


$$\rho'_S = F_R^{-1}(F_S(\rho_S))$$

$$X'_S[i] = \rho'_S$$

end

return X'_S

Şekil 2. Normal, Benign ve Malign olmak üzere farklı malignite sınıfları için her alandan örnek görüntüler. Kırmızı kutu, radyolog açıklamalı bir bulgunun yerini gösterir.



Harron ve diğerleri (2022), bir derin öğrenme modeli kullanarak DBT görüntülerini gürültüden arındırmak için bir teknik önermektedir. Düşük doz tam alanlı projeksiyon görüntüleri, meme boyunca çeşitli yönlerde ilerleyen x-ışınları ile çeşitli açılardan elde edilir. Radyasyon dozu azaltıldıkça DBT görüntüsünün gürültü seviyesi artar. Ayrıca, toplanan projeksiyon verilerinden yeniden yapılandırılmış DBT görüntülerinin görüntü performansı, dedektör hassasiyet çözünürlüğü ve x-ışını tüpünün sonlu odaklama noktası gibi doğal görüntüleme sistemi özelliklerinden kaynaklanan gürültü ve bulanıklık artefaktları nedeniyle sıklıkla sınırlıdır. Bulanıklaştırmanın lezyonların saptanabilirliği üzerindeki etkisi net bir şekilde görülebilir. Sonuç olarak, görüntüde parazit giderme veya bozulmuş projeksiyon görüntülerinin geri kazanılması, elde edilen DBT görüntülerinin görüntü özelliklerini iyileştirmek için kritik öneme sahiptir. Eşzamanlı cebirsel yeniden yapılandırma ve toplam varyasyon gibi bir yeniden oluşturma yaklaşımı, yinelemeli bir optimizasyon prosedürü sırasında örtülü olarak gürültü yumuşatma tekniklerini sıklıkla uygular. Filtrelenmiş geri projeksiyon (FBP), DBT rekonstrüksiyonu için popüler ve yaygın olarak kullanılan bir yöntemdir. FBP yöntemi, arka projeksiyondan önce genel yüksek frekanslı gürültüyü azaltmak için bir pencereleme tekniğiyle birlikte rampa filtresi gibi bir yüksek geçiren filtre kullanılarak geliştirilmiştir. Ancak, bir rampa filtresi kullanmak görüntünün gürültü seviyesini artıracaktır. Projeksiyonlarda Poisson veya Poisson-Gaussian gürültüsüyle veya DBT'deki görüntü alanı için özel olarak başa çıkmak için yalnızca birkaç yaklaşım önerilmiştir. Son zamanlarda görüntü parazit giderme sorununu çözmek için derin öğrenmeye dayalı birçok gürültü giderme yöntemi önerilmiştir.

Bu çalışmada eğitim verileri, açık kaynaklı bir klinik deneme DBT görüntülerini barındıran web sitesi kullanılarak elde edilmiştir. Web sitesinde Monte Carlo röntgeni kullanılarak DBT yöntemiyle taranan ve kalınlıkları 3,5 ile 6 cm arasında değişen toplam 2986 hasta bulunmaktadır. Matlab'de bulunan bilateralFilterDataset yardımcı işlevi kullanılarak eğitim veri setinin ön işleme yapılmış ve filtrelenen görüntü bir diskte saklanmıştır. Ağ, amaçlanan ağ yanıtı olarak filtrelenmiş resmi ve ağ girişi olarak bozulmamış görüntü beslemesini alır. randomPatchExtractionDatastore işlevi kullanılarak yama çıkarma işlemi, ağ girişi olan iki görüntü tabanlı veri deposundan rastgele konumlandırılmış yamaları çıkarmak için gerçekleştirilmiştir. Yama boyutu 256 x 256 pikseldir. (Harron ve diğerleri, 2022)

Bevilacqua ve diğerleri (2019), meme tomosentez görüntülerini sınıflandırmada radyologları desteklemek için iki farklı çerçeve tartışılmış ve kantitatif olarak karşılaştırılmıştır. İlk çerçeve özellik tabanlıdır ve optimize edilmiş Yapay Sinir Ağı (YSA) sınıflandırıcılarına girdi olarak her bir ROI'den çıkarılan morfolojik ve dokusal el yapımı özellikleri dikkate alır. İkinci çerçeve, bunun yerine, farklı Evrişimsel Sinir Ağı modelleri kullanarak birkaç özellik kümesini ayıklayan sınıflandırma performansını değerlendiren otomatik olarak hesaplanan özelliklere dayalı sinirsel olmayan sınıflandırıcıları dikkate alır. Bu çalışmada 16 hastaya meme tomosentez incelemesi yapılmıştır. Tüm hastalar 35-65 yaş arası (ortalama yaş 49.8 ± 9.2) kadınlardır. Özellikle bazı kadınlara birden fazla tomosentez muayenesi yapılarak 39 meme muayenesinden oluşan bir veri setine ulaşılmıştır. Ön işleme prosedürünün ilk adımı, DICOM görüntülerinin kontrastını Algoritma 2'de bildirilen algoritma izlenerek pencerelemeye ve geliştirmeye başlanmıştır. Önerilen algoritma, Pencere Genişliği (w) ve Pencere Merkezini (c) göz önünde bulundurarak görüntüleri doğrusal bir dönüşümle dönüştürdü; burada x , giriş DICOM görüntüsündeki bir pikselin değeri, y , çıktı görüntüsündeki karşılık gelen pikselin değeri, y_{min} ve y_{max} , son görüntüdeki piksel değeri aralığının sınırlarıdır (ör. [0-255]).

Algoritma 2: Görüntü pencereleme için önerilen algoritma

$$K \leftarrow \frac{c - 0.5 - (w - 1)}{2}$$

if $x \leq K$ **then**

$y \leftarrow y_{min}$

else

if $x > K$ **then**

$y \leftarrow y_{max}$

else


$y \leftarrow \frac{x - (c - 0.5)}{(w - 1) + 0.5} * (y_{max} - y_{min}) + y_{min}$

end if

end if

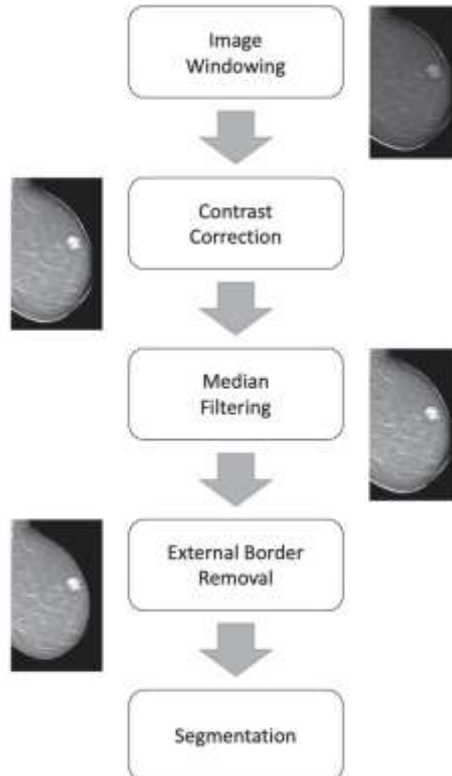
Şekil 3, pencereleme işleminin sonucunu göstermektedir. c ve w değerleri, belirli giriş cihazı tarafından elde edilen görüntüleri dayalı olarak ampirik olarak elde edilmiştir.

Şekil 3. Pencereleme sonucu; (a) orijinal DICOM görüntüsünü gösterir ve (b) değiştirilmiş görüntüyü gösterir (Pencere Merkezi 3477, Pencere Geniliği 844'tür).



Bu ön işlemden sonra, Şekil 4'te gösterildiği gibi sonraki adımlarda işlenecek ROI'leri geliştirmek için sırayla kontrastın artırılması, medyan filtreleme ve kenarlık giderme gerçekleştirildi. Verilerin %1'i hem düşük hem de yüksek yoğunluklarda doymuş olacak şekilde piksellerin yoğunluk değerini yeni değerlerle eşlemek için önceki pencereleme işleminden kaynaklanan görüntüye kontrast geliştirme uygulanmıştır. Daha sonra, 33 kare çekirdek kullanılarak görüntüden "tuz ve biber" olarak da bilinen tanecikli gürültüyü gidermek için bir ortanca filtre uygulanmıştır. Son olarak meme dış sınırının kaldırılması işlemi gerçekleştirilmiştir. Bu son adım, ön işleme aşamasında temel bir öneme sahiptir çünkü meme, sonraki segmentasyon aşamasına müdahale edebilecek beyaz bir kenar göstermiştir. Bu son işlem, 16 piksel yarıçaplı bir disk kullanılarak arka planı (görüntünün siyah kısmı) genişleterek gerçekleştirilmiştir. (Bevilacqua ve diğerleri, 2019)

Şekil 4. Girdi görüntülerinin geliştirilmesine yol açan görüntü ön işleme aşamasında ihtiyaç duyulan adımların şematik bir gösterimi.



Samala ve diğerleri (2019), dijital meme tomosentezinde (DBT) kötü huylu ve iyi huylu kitlelerin sınıflandırılması için, ara aşama ince ayar için benzer yardımcı alanlardan gelen verileri kullanan çok aşamalı bir transfer öğrenme yaklaşımı kullanarak derin bir evrişimli sinir ağı (CNN) geliştirmişlerdir. Toplam 4039 benzersiz ilgi bölgesi (1797 malign ve 2242 benign) olmak üzere DBT, dijital ekran-film mamografi ve dijital mamografiden meme görüntüleme verileri toplanmıştır. Çalışmada kullanılan tüm meme görüntüleri, her bitişik $k \times k$ pikselin ortalaması alınarak $200 \mu m \times 200 \mu m$ piksel boyutuna düşürülmüştür; burada k , görüntünün orijinal piksel boyutuna bağlıdır. Kitle merkezli 128×128 piksellik bir ROI meme görüntüsünden çıkarılmış ve bir arka plan düzeltme yöntemi kullanılarak normalleştirilmiştir. (Samala ve diğerleri, 2019)

Zhang ve diğerleri (2018), CNN'lere dayalı bir mamogram ve tomosentez sınıflandırması yaklaşımı önermişlerdir. Hem 2D mamogramları hem de 3D tomosentezi sınıflandırmak için farklı CNN modelleri oluşturulmuştur ve her sınıflandırıcı, biyopsi ve uzman radyologlar tarafından onaylanan iki yıllık negatif mamogram takibinden elde edilen histoloji sonuçları tarafından üretilen doğruluk değerlerine göre değerlendirilmiştir. Sonuçlar, transfer öğrenimi ve veri artırımı kullanarak oluşturdukları ve optimize ettikleri CNN tabanlı modellerin, mamogramlar ve tomosentez verilerine dayalı olarak otomatik meme kanseri tespiti için iyi bir potansiyele sahip olduğunu göstermiştir. Biyomedikal veri kümeleri, sınırlı hasta hacmi nedeniyle nispeten az sayıda örnek içerir. Orijinal girdi verilerinden yeni veriler üreterek, veri artırma, eğitim veri boyutunu artırabilir. Görüntü verilerini büyütme için birçok strateji mevcuttur. Bu çalışmada, yansıma ve döndürmenin bir kombinasyonunu kullanmışlardır. Her bir tomosentez numunesi için, bir bütün olarak 3D tomosentez görüntü dizileri ya yatay olarak döndürülmüştür ya da çevrilmiştir ve ardından rastgele 0, 90, 180 veya 270 derece döndürülmüştür. Bu tür veri artırma, ilgili eğitim örnekleri üretir, çünkü tümörler kendilerini çeşitli yönlerde gösterebilir. (Zhang ve diğerleri, 2018)

Shimokawa ve diğerleri (2022), bilateral meme dokusunun asimetrisini dikkate alan bir teşhis algoritması yerleştirerek meme kanserinin sınıflandırma tahminini iyileştirmek için bir derin öğrenme modeli geliştirmeyi amaçlamışlardır. CNN modelindeki asimetrik farklılıkları araştırmak için iki veri seti oluşturulmuştur; malign bir tümörün (meme kanseri) görüntüsünden ve kontralateral normal memenin görüntüsünden (M/N eşleştirilmiş veri kümesi) oluşan eşleştirilmiş bir veri kümesi ve kanserli olmayan normal meme dokusunun görüntüsünden ve kontralateral normal memenin görüntüsünden oluşan eşleştirilmiş bir veri kümesi (N/N eşleştirilmiş veri kümesi). Bu çalışmaya dahil edilen 173 hastanın her birinden iki görüntü çifti (E/N ve N/N) oluşturulmuş ve toplam 346 çift bilateral meme DBT görüntüsü üretilmiştir. Bu 346 görüntü çifti, eğitim ve doğrulama veri setlerinden oluşturulmuştur. 173 M/N görüntü çifti aşağıdaki gibi üretilmiştir. 173 hacimsel görüntü setinin her biri için, tümörün merkez DBT dilimi seçilmiş ve benzersiz meme kanseri lezyonlarının 173 görüntüsü elde edilmiştir. Bu lezyonlar, meme görüntüleme 5 yıldan fazla deneyime sahip radyologlar tarafından kırılmış ve not edilmiştir. Görüntülerin kırılma boyutu, lezyonun boyutuna göre belirlenmiştir. Kontrol görüntüsü için, kanserli memenin kontralateral tarafına karşılık gelen kanserli olmayan meme dokusu kullanılmış ve orijinal koordinatları yansıtılarak karşılık gelen konumda aynı boyutta kırılmıştır. Sonuç olarak, bir tümörün kırılmış görüntüsünün 173 çifti ve kontralateral meme dokusundan meme dokusunun kontrol görüntüsü M/N eşleştirilmiş veri setini oluşturmak için üretilmiştir.

173 N/N veri seti aşağıdaki gibi oluşturulmuştur. Hastanın tümörle aynı boyuttaki meme dokusunun rastgele bir kanserli olmayan normal görüntüsü, tümörün aynı merkez DBT diliminden kırılmış ve tümör ek açıklamasıyla örtüşme olmayacaktır. Karşı meme görüntüsü için, karşılık gelen konumdaki aynı boyuttaki görüntü de orijinal koordinatları yansıtılarak kırılmıştır. Sonuç olarak, N/N eşleştirilmiş veri setini oluşturmak için 173 çift çift taraflı karşılık gelen kanserli olmayan görüntü üretilmiştir.

M/N ve N/N eşleştirilmiş veri kümelerinin tüm kırılmış görüntüleri 256×256 olarak yeniden boyutlandırılmıştır. Sonuç olarak, meme kanseri/normal meme dokusu (M/N eşleştirilmiş veri seti) içeren 173 görüntü seti ve iki taraflı normal meme dokusu çifti (N/N eşleştirilmiş veri seti) içeren 173 görüntü seti oluşturulmuştur. (Shimokawa ve diğerleri, 2022)

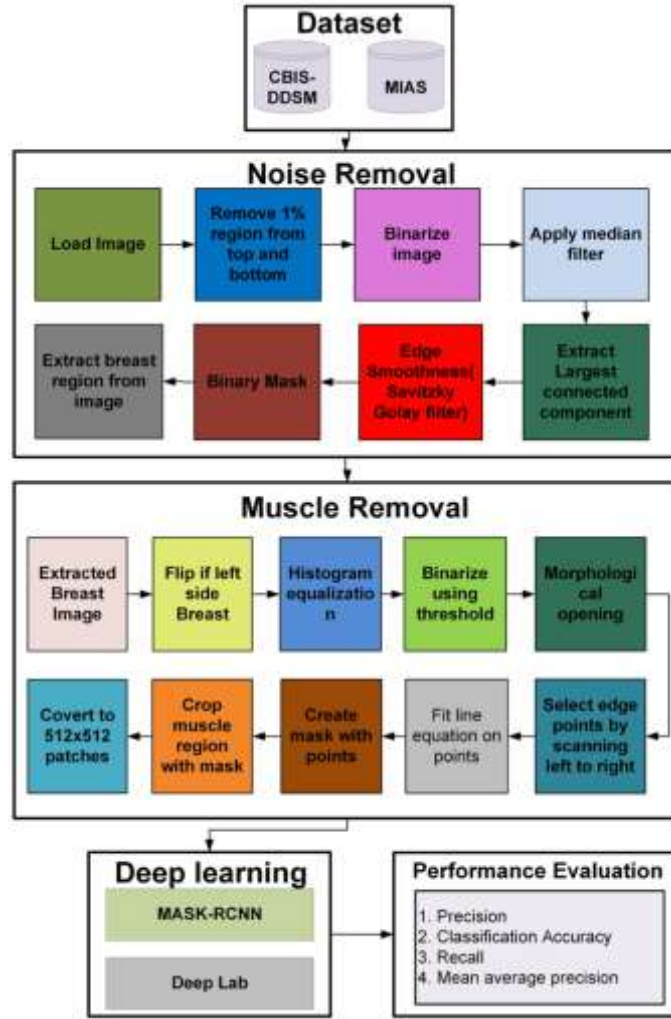
Shimokawa ve diğerleri (2022), dijital meme tomosentezinde (DBT) meme kanserinin stromal invazyonunun varlığını tahmin etmek için derin öğrenme tabanlı bir algoritma geliştirmeyi amaçlamışlardır. Çalışmaya 499 hasta (ortalama yaş 50,5, 29 ile 90 yıl) dahil edilmiştir. 499 hasta arasından meme kanseri tanısıyla ameliyat edilen 140 hasta seçilmiştir. Patolojik raporlara göre 140 hasta, invaziv olmayan kanserli 20 hasta ve invaziv kanserli 120 hasta olarak kategorize edilecek şekilde ayrılmıştır. DL modeli için Xception mimarisi kullanılmak üzere tüm lezyonlar kırılmış ve 16 bit derinlikte kalan 256×256 piksel gri tonlamalı görüntüye yeniden boyutlandırılmıştır. (Shimokawa ve diğerleri, 2022)

Ahmed ve diğerleri (2020), mamogramlarda kanserli bölgeyi tespit etmek, sınıflandırmak ve segmentlere ayırmak için derin öğrenme tabanlı bilgisayar destekli bir sistemin geliştirilmesine odaklanmışlardır. Ayrıca, yüksek yanlış pozitif oranına neden olabilecek görüntüyü, artefaktları ve kas bölgesini ortadan kaldıran ön işleme mekanizması önerilmişlerdir.

Şekil 5 metodolojisinde önerilen sistem, toplamda üç hedefi gerçekleştirmek üzere tasarlanmıştır: (1) radyologların yapılandırılmamış verilerini (ham görüntüleri) yapıya ve hesaplanabilir temsile ayırtmak için sistematik bir bilgi çıkarma yöntemi tasarlamak ve uygulamak, (2) işlem süresini ve hastalara yapılan inceleme ve protokol atamasında yanlış negatif oran tanımlamasını

azaltmak ve (3) kanserli bölgenin sınıflandırılmasının yanı sıra segmentasyonunu kullanarak klinisyenlerin hastaların yaşamsal belirtilerine ilişkin karar vermelerine yardımcı olacak derin öğrenmeye dayalı bir model sunmak.

Şekil 5. Meme Kanseri Segmentasyonu Metodolojisi



Bu çalışmada halka açık iki meme kitle veri seti kullanılmıştır, yani mamografik görüntü analizi derneği dijital mamogram veri tabanı (MIAS) ve (Digital Database for Screening Mammography) DDSM'nin (CBIS-DDSM) Küratörlü Meme Görüntüleme Alt Kümesi. MIAS veri tabanı, toplam 322 görüntüye (sol ve sağ meme) sahip 161 hasta verisinden oluşur. Her 322 görüntü 1024×1024 piksel boyutundadır ve 200 mikron çözünürlük içerir. İkinci veri seti (CBIS-DDSM) toplam 2.620 taranmış mamogram içerir. 870 iyi huylu, 914 kötü huylu ve 830 normal olarak teşhis edilmiştir. Mamogramlar, ilgi alanı segmentasyonu, sınırlayıcı kutular ve tanıya ilişkin patolojik zemin gerçeği ile Tıpta Dijital Görüntüleme ve İletişim (DICOM) formatındadır. Her iki veri seti de normalleştirilir ve tek bir veri seti oluşturmak için birleştirilmiştir.

Ham görüntüler ön işleme algoritmasına sunulmuştur. Önerilen ön işleme algoritmasının iki ana modülü vardır, yani i) artefakt ve gürültü giderme, ii) kas giderme. Veri setinin analizinden sonra, bazı görüntülerin üstte ve altta görüntünün bazı bölgelerinde beyaz şeritler içerdiği ortaya çıkmıştır. Bozulmuş bölge, segmentasyonda sorun yaratır. Bölge seçilir ve pikselin değeri üstten ve alttan yaklaşık yüzde 1'lik bölge sıfır değerleri ile değiştirilir. Her iki veri seti de memenin sol ve sağ taraf görüntülerini içerir. Kas bölgesini kaldırmak için sol ve sağ taraf görüntüleri için farklı yaklaşımlara ihtiyaç vardır. Görüntülerin farklı taraflarını dengelemek için, algoritma yalnızca sağ taraftaki görüntüler için geliştirilmiştir. Sol taraftaki görüntü, piksel oranıyla algılanır ve sağ tarafa benzer hale getirmek için yatay olarak bükülür. Kas kaldırıldıktan sonra, görüntü sol tarafa geri döndürülür. Ortaya çıkan görüntü, yalnızca parlak bölgenin sunulduğu histogram eşitlemesinden sonra ikili hale getirilir. Parlak bölge, morfolojik işlemler kullanılarak geliştirilir. Veri setinin analizi sonucunda kas bölgesinin üst bölgede yer aldığı (çoğunlukla üçgen şeklinde) ortaya çıkmıştır. İşlenen görüntü daha sonra sol taraftan sağ tarafa doğru beyaz piksele kadar yatay olarak taranmıştır. Her beyaz piksel konumu (x, y) koordinatları olarak saklanmıştır. Algoritma, hangisi önce gelirse görüntünün üçte bir yüksekliği veya beyaz kısım bitene kadar taramaya devam eder. Ayrıca, dikey olarak görüntü ardışık olarak taranmaz. Algoritma, her yatay döngüden sonra dikey olarak on piksel atlar. Noktalar kas bölgesinin yönünü verir. Çizgiyi her iki yanda uzatmak için çizgi denklemi seçilen noktalara yerleştirilmiştir. Nokta sağ alt ve sol üste doğru uzatılmıştır.

Çizgi denklemi bir üst ve sağ alt piksel konumu verir ve sağ üst konumu biliniyordur. Üç nokta, kas bölgesini kırpma için kullanılan üçgen bir maske oluşturmak için kullanılır. Algoritma 4 "Görüntüden Kas Kaldırma" kodunu verir. Gürültüyü gidermek için medyan filtresi uygulandıktan sonra görüntü ikili hale getirilir. Meme bölgesi en büyük bağlı bileşenler kullanılarak çıkarılır. Bir sonraki adım, pürüzlü kenarlar içerdiğinden meme kenarlarını düzeltmektir.

Algoritma 3: Artefakt ve Gürültü Giderme

Input: Ham Görüntüler,

Output: Önceden İşlenmiş Görüntü (Çıkarılmış Göğüs)

```
    I ← Load Image()
for i ← 0 do height(I)/10
    for j ← 0 do width(I)
        I(i,j) ← 0
    end for
end for
for i ← ( $\frac{height(I)}{10}$ ) – height(I) do height(I)
    for j ← 0 do width(I)
        I(i,j) ← 0
    end for
end for

    J ← ImBinarize(I)
    J ← Median(J)
    Blob ← ELCC(J)
    Blob ← SGF(Blob)

    Binary(mask) ← Convert(mask)(Blob)
    extracted breast ← Crop image(I, Binary(mask))

    Return extracted breast
```

Pürüzsüzleştirme için, pürüzlü kenarları yumuşatan Savitsky Golay algoritması kullanılır. Pürüzsüz kenarlar sınırı, ikili maskeler oluşturmaya yardımcı olur. Bu ikili maske, göğüs bölgesini orijinal görüntüden çıkarmak için kullanılır. Ortaya çıkan görüntü, göğüs bölgesi çıkarılır. Algoritma 3 "Artefakt ve Gürültü Giderme" kodunu verir. (Ahmed ve diğerleri, 2020)

Algoritma 4: Görüntüden Kas Kaldırma

Input: Önceden İşlenmiş Görüntü (Çıkarılmış Göğüs),

Output: Kassız meme görüntüsü

```
    I ← Load_Proprocessed_Image()
if image_side(I) == LEFT then
    I ← Flip Horizontal(I)
end if

    J ← HistogramEqualize(I)
    J ← Binarize(J)
    J ← MorphologicalOpening(J)

    XPoints ← []
    YPoints ← []
```

```

for  $i \leftarrow 0$  do  $\frac{height(I)}{3}$ 
  for  $j \leftarrow 0$  do  $width(I)$ 
    if  $J(i, j) == 1$  then
      XPoints.append(i)
      YPoints.append(j)
      break
    end if
  end for
   $i \leftarrow i + 20$ 
end for


   $P \leftarrow Polyfit(XPoints, YPoints)$ 
   $P \leftarrow ExtendLine(P, width(I))$ 
   $Binary_{(mask)} \leftarrow PolyToMask(P, Size(I))$ 
   $Binary_{(mask)} \leftarrow Invert(Binary_{(mask)})$ 
   $BreastRegion \leftarrow CropImage(I, Binary_{(mask)})$ 
if image_side(I) == LEFT then
   $BreastRegion$ 
   $\leftarrow FlipHorizontal(BreastRegion)$ 
end if
Return  $BreastRegion$ 

```

El-Shazli ve diğerleri (2022), DBT artırma ve renkli öznelik haritasını değiştirilmiş bir derin öğrenme mimarisi (Mod_AlexNet) ile bütünleştiren yeni bir bilgisayar destekli çok sınıflı teşhis sistemi önermişlerdir. Önerilen değiştirilmiş derin öğrenme mimarisine (Mod AlexNet), çeşitli optimizasyon teknikleri kullanılarak değerlendirilebilmesi ve optimize edilebilmesi için birden fazla yüksek performanslı optimize ediciye sahip bir optimizasyon katmanı dahil edilmiştir. Önerilen model, DBT dilimlerini normal, iyi huylu veya kötü huylu olarak sınıflandırmak için uygulanmıştır. Modeli oluşturmak için çeşitli görüntü işleme algoritmaları uygulanmıştır.

Önerilen modelde, önce görüntüler ters çevrilmiş, daha sonra $[-0.3, -0.1]$ aralığında parlaklık, $[-0.4, 0.2]$ aralığında doygunluk ve $[0.05, 0.25]$ aralığında ton için rastgele seçilen değerler uygulanmıştır. Şekil 6, uygulanan farklı büyütme tekniklerinin bir görselleştirmesini göstermektedir. Orijinal görüntü Aug1 ve Aug2'de ters çevrildi ve Aug1'de rastgele doygunluk ve ton değerleri uygulanmıştır. Parlaklık ve ton değerleri Aug2 için rastgele seçilmiştir. Aug3 ve Aug4, orijinal görüntüye rastgele seçilen doygunluk ve parlaklık değerlerini uygularken, Aug4 ek olarak renk tonu değerlerinin rastgele seçimi uygulanmıştır.

Şekil 6. Uygulanan farklı büyütme tekniklerinin örnekleri (a) orijinal görüntü, (b) Aug1 çıktısı, (c) Aug2 çıktısı, (d) Aug3 çıktısı, (e) Aug4 çıktısı.



Bu çalışmada, her bir tomosentez dilimi dört artırılmış görüntü üretmiştir. İki resim ters çevrilmiş, diğer ikisi çevrilmemiştir. Bunu takiben, rastgele parlaklık, doygunluk ve ton değerleri ile birlikte görüntünün yerel kontrastını iyileştirmek için kontrast sınırlı uyarlanabilir histogram eşitleme (CLAHE) uygulanmıştır. Eğitim setinde 400 normal hasta (toplam 96.862 dilim), benign (iyi huylu) bulgusu olan 50 hasta (toplam 7034 dilim) ve malign(kötü huylu) bulgusu olan 30 hasta (toplam 4242 dilim) olmak üzere 480 hastadan alınan taramalar yer almıştır. Büyütme, eğitim seti için dilim hazırlamanın ilk aşaması olarak gerçekleştirilmiştir. Büyütme sonrası eğitim dilimlerinin toplam sayısı 387.448 normal dilim, 28.136 iyi huylu dilim ve 16.968 kötü huylu dilimdir.

Ön işleme aşaması birden fazla aşamadan oluşmuştur. İlk aşama, DBT hacmini 2B dilimlere dilimlemektir. İkinci aşama, farklı filtreler ve morfolojik işlemler kullanarak gürültü bastırma, kenar geliştirme ve kontrast geliştirme yoluyla DBT dilimlerini geliştirmeyi amaçlar.

Görüntünün kontrastını ve kenarlarını iyileştirdikten sonra, mevcut olabilecek herhangi bir arka plan gürültüsünü ortadan kaldırmak için ek değişiklikler gerekmektedir.

Adımlar aşağıdaki gibidir:

a. Arka Plan Eserini Kaldırma

Arka plan kusurları ve etiketler, görüntüden özellikler çıkarılırken yanlış göstergeler verebileceğinden modelin doğruluğunu etkiler. Düşük seviyeli eserler, etiketler, yüksek seviyeli eserler ve arka plan sesleri, arka plan eserlerine örnektir. Ön planı arka plandan ayırtmak için, görüntü önce gri tonlamadan ikili biçime dönüştürülmüştür. İkinci olarak, görüntüdeki tuz gürültüsünü ortadan kaldırmak için bir açılış morfolojik tekniği kullanılmıştır. Son olarak, küçük beyaz yamalar silinmiş, ikili maskenin en büyük alanı seçilmiş ve mamografide tespit edilen tüm artefaktlar ve etiketler bastırılmıştır.

b. Renk Haritası Uygulaması

Görüntüdeki farklı bölümleri ayırt etmek için renk haritası HSV (Hue, Saturation, Value) (Ton, Doymunluk, Değer) renklerinde uygulanmıştır. Farklı konumlardaki renklerin farklı tonları, doymunlukları ve değerleri vardır. Son olarak dilimler, her bir DL modeli için girdi boyutuna uyacak şekilde yeniden boyutlandırılır. (El-Shazli ve diğerleri, 2022)

4. Araştırma Sonuçları

Bu literatür araştırması, tomosentez görüntülerinde derin öğrenme yöntemlerinin kullanımının artmasıyla birlikte, görüntüler üzerinde kullanılan görüntü ön işleme yöntemlerine odaklanmıştır. Bu çalışmanın amacı, tomosentez görüntülerini iyileştirmek, görüntü kalitesini artırmak ve derin öğrenme algoritmalarının performansını optimize etmek ve veri setini artırmak için kullanılan ön işleme yöntemlerini derlemek ve analiz etmektir.

Araştırma sonuçları, tomosentez görüntülerinde ön işleme yöntemlerinin yaygın bir şekilde kullanıldığını ve derin öğrenme algoritmalarının performansını iyileştirmede etkili olduğunu göstermiştir. Literatürde bulunan ön işleme yöntemleri arasında filtreleme, normalizasyon, keskinleştirme, düzeltme, segmentasyon ve artırma gibi farklı teknikler bulunmaktadır. Bu yöntemlerin her biri,

tomosentez görüntülerinin analiz edilmesi ve sınıflandırılması gibi derin öğrenme tabanlı uygulamalar için uygun olabilecek özelliklere sahiptir.

Araştırmalar, tomosentez görüntülerinin önceden işlenmesinin derin öğrenme algoritmalarının performansını artırabileceğini ve doğruluk oranlarını iyileştirebileceğini göstermiştir. Ön işleme yöntemlerinin seçimi, uygulanacak derin öğrenme modeline, veri setinin özelliklerine ve spesifik uygulamaya bağlı olmalıdır. Farklı yöntemlerin kombinasyonu ve optimizasyonu, daha iyi sonuçlar elde etmek için üzerinde çalışılması gereken alanlardır.

Bu araştırma, tomosentez görüntülerinde derin öğrenme kullanımının önemini vurgulamış ve tomosentez görüntülerindeki ön işleme yöntemlerinin derin öğrenme tabanlı uygulamalarda başarılı sonuçlar elde etmede önemli bir rol oynadığını göstermiştir. Gelecekte, daha gelişmiş ve optimize edilmiş ön işleme yöntemlerinin geliştirilmesi, tomosentez görüntülerinin analizinde ve teşhis süreçlerinde daha kesin ve güvenilir sonuçlar elde etmek için büyük bir potansiyel sunmaktadır.

Sonuç olarak, tomosentez görüntüleri üzerinde yapılan derin öğrenme çalışmalarında kullanılan görüntü ön işleme yöntemleri, veri setini artırmak, görüntü kalitesini artırmak, gürültüyü azaltmak, yapıları daha belirgin hale getirmek ve derin öğrenme algoritmalarının performansını iyileştirmek için etkili bir araç olarak kullanılmaktadır. Bu çalışma, bu alandaki mevcut çalışmaları derlemiş ve araştırmacılara, gelecekteki çalışmalarda bu yöntemleri daha etkin bir şekilde kullanma imkanı sunmuştur.

Kaynakça

- Ahmed, L., Iqbal, M. M., Aldabbas, H., Khalid, S., Saleem, Y., & Saeed, S. (2020). Images data practices for semantic segmentation of breast cancer using Deep Neural Network. *Journal of Ambient Intelligence and Humanized Computing*. <https://doi.org/10.1007/s12652-020-01680-1>
- Alguliyev, R. M., Aliguliyev, R. M., & Abdullayeva, F. J. (2019). The improved LSTM and CNN models for ddos attacks prediction in social media. *International Journal of Cyber Warfare and Terrorism*, 9(1), 1–18. <https://doi.org/10.4018/ijcwt.2019010101>
- Amit, G., Ben-Ari, R., Hadad, O., Monovich, E., Granot, N., & Hashoul, S. (2017). Classification of breast MRI lesions using small-size training sets: Comparison of Deep Learning Approaches. *SPIE Proceedings*. <https://doi.org/10.1117/12.2249981>
- Bengio, Y. (2009). Learning deep architectures for AI. *Foundations and Trends® in Machine Learning*, 2(1), 1–127. <https://doi.org/10.1561/2200000006>
- Bevilacqua, V., Brunetti, A., Guerriero, A., Trotta, G. F., Telegrafo, M., & Moschetta, M. (2019). A performance comparison between shallow and deeper neural networks supervised classification of tomosynthesis breast lesions images. *Cognitive Systems Research*, 53, 3–19. <https://doi.org/10.1016/j.cogsys.2018.04.011>
- Boser, B., LeCun, Y., Denker, J. S. (1989). Handwritten Digit Recognition with a Back-Propagation Network.
- Buda, M., Saha, A., Walsh, R., Ghate, S., Li, N., Swiecicki, A., Lo, J. Y., & Mazurowski, M. A. (2021). A data set and deep learning algorithm for the detection of masses and architectural distortions in digital breast tomosynthesis images. *JAMA Network Open*, 4(8). <https://doi.org/10.1001/jamanetworkopen.2021.19100>
- Ciresan, D. C., Meier, U., Gambardella, L. M., & Schmidhuber, J. (2011). Convolutional neural network committees for handwritten character classification. 2011 International Conference on Document Analysis and Recognition. <https://doi.org/10.1109/icdar.2011.229>
- El-Shazli, A. M., Youssef, S. M., & Soliman, A. H. (2022). Intelligent Computer-aided model for efficient diagnosis of digital breast tomosynthesis 3D imaging using Deep Learning. *Applied Sciences*, 12(11), 5736. <https://doi.org/10.3390/app12115736>
- Elman, J. L. (1990). Finding structure in time. *Cognitive Science*, 14(2), 179–211. https://doi.org/10.1207/s15516709cog1402_1
- Graves, A., & Schmidhuber, J. (2005). Framewise phoneme classification with bidirectional LSTM and other neural network architectures. *Neural Networks*, 18(5–6), 602–610. <https://doi.org/10.1016/j.neunet.2005.06.042>
- Harron, N. A., Osman, N. F., Sulaiman, S. N., Karim, N. K., Ismail, A. P., & Soh, Z. H. (2022). An image denoising model using deep learning for Digital Breast Tomosynthesis Images. 2022 IEEE 13th Control and System Graduate Research Colloquium (ICSGRC). <https://doi.org/10.1109/icsgrc55096.2022.9845152>
- Helvie, M. A. (2010). Digital Mammography Imaging: Breast Tomosynthesis and Advanced Applications. *Radiologic Clinics of North America*, 48(5), 917–929. <https://doi.org/10.1016/j.rcl.2010.06.009>
- Hinton, G. E., Osindero, S., & The, Y. (2006). A fast learning algorithm for deep belief nets. *Neural Computation*, 18(7), 1527–1554. <https://doi.org/10.1162/neco.2006.18.7.1527>
- Hinton, G. E., Srivastava, N., Krizhevsky, A., Sutskever, I. & Salakhutdinov, R. R. (2012). Improving neural networks by preventing co-adaptation of feature detectors. *CoRR*, abs/1207.0580.
- Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural Computation*, 9(8), 1735–1780. <https://doi.org/10.1162/neco.1997.9.8.1735>
- Hooley, R. J., Durand, M. A., & Philpotts, L. E. (2017). Advances in Digital Breast Tomosynthesis. *American Journal of Roentgenology*, 208(2), 256–266. <https://doi.org/10.2214/ajr.16.17127>
- Liu, W., Wang, Z., Liu, X., Zeng, N., Liu, Y., & Alsaadi, F. E. (2017). A survey of deep neural network architectures and their applications. *Neurocomputing*, 234, 11–26. <https://doi.org/10.1016/j.neucom.2016.12.038>
- Lu, M. T., Ivanov, A., Mayrhofer, T., Hosny, A., Aerts, H. J., & Hoffmann, U. (2019). Deep learning to assess long-term mortality from chest radiographs. *JAMA Network Open*, 2(7). <https://doi.org/10.1001/jamanetworkopen.2019.7416>
- Memisevic, R., & Hinton, G. E. (2010). Learning to represent spatial transformations with factored higher-order Boltzmann machines. *Neural Computation*, 22(6), 1473–1492. <https://doi.org/10.1162/neco.2010.01-09-953>

- Ren, J., Green, M., & Huang, X. (2021). From traditional to deep learning: Fault diagnosis for Autonomous Vehicles. *Learning Control*, 205–219. <https://doi.org/10.1016/b978-0-12-822314-7.00013-4>
- Ricciardi, R., Mettievier, G., Staffa, M., Sarno, A., Acampora, G., Minelli, S., Santoro, A., Antignani, E., Orientale, A., Pilotti, I. A. M., Santangelo, V., D'Andria, P., & Russo, P. (2021). A deep learning classifier for digital breast tomosynthesis. *Physica Medica*, 83, 184–193. <https://doi.org/10.1016/j.ejmp.2021.03.021>
- Salakhutdinov, R. & Larochelle, H. (2009). Efficient learning of deep Boltzmann machines, in *Proceedings of the Twelfth International Conference on Artificial Intelligence and Statistics*, 16–18 April, Florida, USA, 693–700.
- Salakhutdinov, R., & Hinton, G. (2009). Deep Boltzmann machines, in *Proceedings of the Twelfth International Conference on Artificial Intelligence and Statistics*, 16–18 April, Florida, USA, 448–455.
- Salakhutdinov, R., & Murray, I. (2008). On the quantitative analysis of deep belief networks, *Proceedings of the 25th international conference on Machine learning - ICML '08*, USA, 10–20.
- Samala, R. K., Chan, H.-P., Hadjiiski, L., Helvie, M. A., Richter, C. D., & Cha, K. H. (2019). Breast cancer diagnosis in digital breast tomosynthesis: Effects of training sample size on multi-stage transfer learning using deep neural nets. *IEEE Transactions on Medical Imaging*, 38(3), 686–696. <https://doi.org/10.1109/tmi.2018.2870343>
- Sarker, I. H. (2021). Deep learning: A comprehensive overview on techniques, taxonomy, applications and Research Directions. *SN Computer Science*, 2(6). <https://doi.org/10.1007/s42979-021-00815-1>
- Schwenzow, J., Hartmann, J., Schikowsky, A. and Heitmann, M. (2021), “Understanding videos at scale: how to extract insights for business research”, *Journal of Business Research*, Vol. 123, pp. 367-379, doi: 10.1016/j.jbusres.2020.09.059.
- Sechopoulos, I., Teuwen, J., & Mann, R. (2021). Artificial Intelligence for Breast Cancer Detection in mammography and Digital Breast Tomosynthesis: State of the art. *Seminars in Cancer Biology*, 72, 214–225. <https://doi.org/10.1016/j.semcancer.2020.06.002>
- Shimokawa, D., Takahashi, K., Kurosawa, D., Takaya, E., Oba, K., Yagishita, K., Fukuda, T., Tsunoda, H., & Ueda, T. (2022). Deep learning model for breast cancer diagnosis based on bilateral asymmetrical detection (Bilad) in digital breast tomosynthesis images. *Radiological Physics and Technology*, 16(1), 20–27. <https://doi.org/10.1007/s12194-022-00686-y>
- Shimokawa, D., Takahashi, K., Oba, K., Takaya, E., Usuzaki, T., Kadowaki, M., Kawaguchi, K., Adachi, M., Kaneno, T., Fukuda, T., Yagishita, K., Tsunoda, H., & Ueda, T. (2022). Deep Learning Model for Predicting the Presence of Stromal Invasion of Breast Cancer on Digital Breast Tomosynthesis. <https://doi.org/10.21203/rs.3.rs-1807556/v1>
- Singh, S., Matthews, T. P., Shah, M., Mombourquette, B., Tsue, T., Long, A., Almohsen, R., Pedemonte, S., & Su, J. (2020). Adaptation of a deep learning malignancy model from full-field digital mammography to Digital Breast Tomosynthesis. *Medical Imaging 2020: Computer-Aided Diagnosis*. <https://doi.org/10.1117/12.2549923>
- Skaane, P., Bandos, A. I., Gullien, R., Eben, E. B., Ekseth, U., Haakenaasen, U., Izadi, M., Jepsen, I. N., Jahr, G., Krager, M., Niklason, L. T., Hofvind, S., & Gur, D. (2013). Comparison of Digital Mammography alone and Digital Mammography Plus Tomosynthesis in a population-based screening program. *Radiology*, 267(1), 47–56. <https://doi.org/10.1148/radiol.12121373>
- Usuga Cadavid, J.P., Grabot, B., Lamouri, S., Pellerin, R. and Fortin, A. (2022), “Valuing free-form text data from maintenance logs through transfer learning with CamemBERT”, *Enterprise Information Systems*, Vol. 16 No. 6, pp. 1-29, 1790043, doi: 10.1080/17517575.2020.1790043.
- Usuga-Cadavid, J.P., Lamouri, S., Grabot, B. and Fortin, A. (2022), “Using deep learning to value freeform text data for predictive maintenance”, *International Journal of Production Research*, Vol. 60 No. 14, pp. 4548-4575, doi: 10.1080/00207543.2021.1951868.
- Vedantham, S., Karellas, A., Vijayaraghavan, G. R., & Kopans, D. B. (2015). Digital Breast Tomosynthesis: State of the art. *Radiology*, 277(3), 663–684. <https://doi.org/10.1148/radiol.2015141303>
- Yousefi, M., Krzyżak, A., & Suen, C. Y. (2018). Mass detection in digital breast tomosynthesis data using convolutional neural networks and multiple instance learning. *Computers in Biology and Medicine*, 96, 283–293. <https://doi.org/10.1016/j.combiomed.2018.04.004>
- Zhang, X., Zhang, Y., Han, E. Y., Jacobs, N., Han, Q., Wang, X., & Liu, J. (2018). Classification of whole mammogram and tomosynthesis images using deep convolutional neural networks. *IEEE Transactions on NanoBioscience*, 17(3), 237–242. <https://doi.org/10.1109/tnb.2018.2845103>
- Zhang, Y., Wang, X., Blanton, H., Liang, G., Xing, X., & Jacobs, N. (2019). 2d Convolutional Neural Networks for 3D Digital Breast Tomosynthesis Classification. 2019 *IEEE International Conference on Bioinformatics and Biomedicine (BIBM)*. <https://doi.org/10.1109/bibm47256.2019.8983097>
- Zhao, B., Zhang, X., Li, H. and Yang, Z. (2020), “Intelligent fault diagnosis of rolling bearings based on normalized CNN considering data imbalance and variable working conditions”, *KnowledgeBased Systems*, Vol. 199, 105971, doi: 10.1016/j.knsys.2020.105971.
- Zorzi, M., Testolin, A., & Stoianov, I. P. (2013). Modeling language and cognition with deep unsupervised learning: A tutorial overview. *Frontiers in Psychology*, 4(1), 515–527.