

基于深度学习的乳腺癌多级诊断系统的设计与实现

郭晓杰¹, 章浩伟¹, 梁 湲², 刘 颖^{1*}

¹上海理工大学健康科学与工程学院, 上海

²浙江深博医疗技术有限公司, 浙江 嘉兴

收稿日期: 2025年3月29日; 录用日期: 2025年4月22日; 发布日期: 2025年4月30日

摘 要

乳腺癌是全球女性发病率最高的恶性肿瘤, 传统筛查方法存在敏感性不足、依赖专业医师等问题。特别是对于偏远地区的女性而言, 由于当地医疗资源条件、经济情况等因素的影响, 从而对乳腺癌的预防和治疗存在一定的延后, 很多患者因未能及时地治疗导致病情的恶化。本研究提出了一种基于深度学习的乳腺癌多级诊断系统, 并通过对比ResNet50、VGGNet、GoogleNet和CNN-ViT模型, 最终选择准确率为93.47%, 精确率为91.35%, 召回率为91.50%, F1分数为91.56%的ResNet50模型作为本系统的诊断模型。将模型诊断结果与医生的实际经验相结合, 最终得到一份相对准确的诊断报告。患者可在微信小程序及时地知道诊断结果, 为下一步治疗提供便利性和快捷性。本系统为乳腺癌的预防和治疗提供了一种可行的方法。

关键词

深度学习, 乳腺癌, 多级诊断, 微信小程序

Design and Implementation of Breast Cancer Multi Level Diagnosis System Based on Deep Learning

Xiaojie Guo¹, Haowei Zhang¹, Zhen Liang², Ying Liu^{1*}

¹School of Health Science and Engineering, University of Shanghai for Science and Technology, Shanghai

²SoftProbe Medical Systems Inc., Jiaxing Zhejiang

*通讯作者。

文章引用: 郭晓杰, 章浩伟, 梁湲, 刘颖. 基于深度学习的乳腺癌多级诊断系统的设计与实现[J]. 建模与仿真, 2025, 14(4): 1168-1179. DOI: 10.12677/mos.2025.144363

Abstract

Breast cancer is the most prevalent malignant tumor among women globally. Traditional screening methods suffer from insufficient sensitivity and reliance on specialized physicians. Particularly for women in remote areas, factors such as limited medical resources, economic constraints, and geographical access delays prevention and treatment, leading to delayed interventions and disease progression for many patients. This study proposes a deep learning-based multi-stage breast cancer diagnosis system. By comparing ResNet50, VGGNet, GoogleNet, and CNN-ViT models, we selected ResNet50 as the optimal model, achieving 93.47% accuracy, 91.35% precision, 91.50% recall, and an F1 score of 91.56%. The system integrates model predictions with clinical expertise to generate comprehensive diagnostic reports. Patients can receive real-time results via a WeChat Mini Program, facilitating prompt decision-making for subsequent treatment. This framework offers a feasible solution to improve breast cancer prevention and management, particularly in resource-limited settings.

Keywords

Deep Learning, Breast Cancer, Multi-Stage Diagnosis, WeChat Mini Program

Copyright © 2025 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

乳腺癌是全球女性中最常见且致死率最高的恶性肿瘤之一[1] [2]。随着生活方式的改变和人口老龄化,乳腺癌的发病率逐年上升,尤其在发展中国家,面临着巨大的公共卫生挑战[3]-[5]。早期筛查与准确诊断对于降低乳腺癌的死亡率至关重要,然而目前的筛查和诊断方法仍存在诸多不足,包括技术手段的局限和资源配置的不均衡[6]-[8]。因此,亟需探索更加高效和可靠的检测系统,以实现早期发现和及时治疗。

近年来,随着人工智能的发展,基于先进的数据处理与分析手段的乳腺癌筛查新模式逐渐受到关注[9]-[12]。通过对乳腺癌影像学数据及病理数据进行深度学习分析,可以提高诊断的准确性和效率,从而改善患者的预后[13] [14]。使用医疗信息管理系统的优势在于可以实现数据的集中管理与共享,使得临床医生能够在多学科协作中快速获取最新的诊疗信息,推动个性化医疗的实现[15]-[18]。

针对以上背景,本研究旨在设计一种基于深度学习的乳腺癌多级诊断系统。该系统将整合算法、诊断报告、医生审核修正、数据库和微信小程序,力求提高乳腺癌的筛查效率及准确性,最终为患者提供更为优质的医疗服务。通过对现有技术的优化与创新,本系统将为乳腺癌的早期预防和诊断开辟新途径。

2. 数据集与方法

2.1. 数据集

本文使用的数据集由浙江某医疗公司提供,采集对象为女性体检人员。将数据集分为训练集和测试集,其中 80%用于训练模型,20%用户测试模型,并且在训练集中随机抽取 20%作为模型的验证集。所

有的图像数据都以 dicom 格式保存，共计 1600 张。

2.2. 深度学习算法

在本研究中，通过对比 ResNet50、VGGNet、GoogleNet 和 CNN-ViT 模型的诊断性能，最终选择 ResNet50 模型作为本系统的诊断模型，该模型主要包含了卷积层、池化层、激活函数等。

2.2.1. ResNet50 模型

随着模型层数的增加，模型中的参数数量呈指数级增长，同时梯度消失和梯度爆炸也是困扰深层网络训练的最常见问题之一，并且也会造成网络参数数值的不稳定性，为了解决这些问题，因此微软研究院提出了 ResNet (Residual Neural Network)结构。ResNet 的基本网络结构如下图 1 所示。

layer name	output size	ResNet50
conv1	112×112	7×7,64,stride 2
conv2_x	56×56	3×3 max pool,stride 2
		$\begin{bmatrix} 1 \times 1,64 \\ 3 \times 3,64 \\ 1 \times 1,256 \end{bmatrix} \times 3$
conv3_x	28×28	$\begin{bmatrix} 1 \times 1,128 \\ 3 \times 3,128 \\ 1 \times 1,512 \end{bmatrix} \times 4$
conv4_x	14×14	$\begin{bmatrix} 1 \times 1,256 \\ 3 \times 3,256 \\ 1 \times 1,1024 \end{bmatrix} \times 6$
conv5_x	7×7	$\begin{bmatrix} 1 \times 1,512 \\ 3 \times 3,512 \\ 1 \times 1,2048 \end{bmatrix} \times 3$
	1×1	Average pool,1000-d fc,softmax
FLOPS		3.8×10^9

Figure 1. ResNet network structure

图 1. ResNet 网络结构

ResNet (残差网络)的核心创新在于提出残差学习框架，其本质是通过引入跨层跳跃连接(Shortcut Connection)，使网络能够高效学习输入与期望输出之间的残差映射(Residual Mapping)，如图 2 所示。输入 x 会分为两路，其中 x 表示恒等映射， $F(x)$ 表示残差映射，两者求和进入激活函数，然后输出 $\text{ReLU}(F(x) + x)$ 。




Figure 2. ResNet network

图 2. ResNet 网络

2.2.2. 卷积层

卷积层是卷积神经网络的组成部分，其设计灵感来源于生物视觉系统的局部感知特性。与全连接层相比，卷积层通过局部连接和权重共享两大机制，显著降低参数量并提升模型对位置变化的鲁棒性。局部连接：每个神经元仅与输入图像的局部区域(如 3×3 像素)交互，模拟人脑视觉皮层中神经元的感受野(Receptive Field)。权重共享：同一组卷积核(Filter)被全局应用于整个图像，减少了冗余参数。例如，一个 5×5 的卷积核仅需 25 个权重参数，而全连接层处理同样区域需要 $5 \times 5 \times C_{in}$ 个参数(C_{in} 为输入通道数)。卷积操作的数学公式定义为：

$$y_{i,j} = \sum_{m=0}^{k-1} \sum_{n=0}^{k-1} x_{i+m,j+n} w_{m,n} + b \quad (1)$$

其中 x 表示输入特征图； w 表示可学习卷积核权重(如检测边缘的 3×3 核)； b 表示偏置项； K 表示卷积核尺寸； $y_{i,j}$ 表示输出特征图中的像素值。

2.2.3. 池化层

池化层是通过下采样(Downsampling)减少特征图尺寸，从而减小后续层的参数量和计算复杂度、对输入的小尺度扰动(如噪声、伪影)不敏感和保留最显著的特征(如最大值对应病灶位置)。池化类型主要分为最大池化和平均池化。最大池化是通过在局部窗口中选取最大值，突出纹理和边缘特征，从而增强恶性钙化点的对比度；平均池化是计算局部窗口的平均值，平滑特征并抑制噪声，减少脂肪组织的纹理干扰。

2.2.4. 激活函数

激活函数为神经网络引入非线性映射，使其能够学习复杂模式(如肿瘤的异质性)。常用的函数主要有 ReLU、Swish、Sigmoid、Tanh、Leaky ReLU 等。本研究使用 ReLU 函数，其函数公式定义为：

$$f(x) = \max(0, x) \quad (2)$$

其中 x 表示输入值， $f(x)$ 表示经映射得到的输出值。

2.3. 数据预处理

2.3.1. 统一数据大小

图像尺寸过小会导致细节丢失，过大则会增加计算开销，因此使用 cv2 库将图像调整为 ResNet50 模型的输入要求 $224 \times 224 \times 3$ 。

2.3.2. 层归一化

由于超声图像具有低对比度、局部纹理复杂的特点，同时当模型试图拟合真实数据分布时，中间层的微小扰动会通过多层传播被指数级放大(即“蝴蝶效应”)，这种现象在深度网络中尤为显著。为了解决因数据分布的动态变化和梯度不稳定引起的不确定性，本研究选取层归一化(Layer Normalization, LN)方法，其数学公式为：

$$Y = \gamma \times \frac{X - \mu}{\sqrt{\sigma^2 + \epsilon}} + \beta \quad (3)$$

其中 X 表示输入张量； γ 表示可学习缩放因子，初始值为 1； β 表示可学习偏移量，初始值为 0； μ 表示每个特征的均值； σ 表示每个特征的方差； ϵ 是个小常数，用于数值稳定性。通过参数调优和训练模型，发现 γ 在 $[1.0, 1.2]$ 、 β 在 $[0, 0.1]$ 范围内时可以得到符合要求的图像，因此最终将 γ 设置为 1.2， β 设置为 0.1。

2.3.3. 数据增强

在选择的图像中，存在图像质量相对较差和类别不平衡的情形，将会给图像识别任务带来较大困难，

进一步提高了训练成本和降低了准确性。同时为了进一步提高模型的泛化能力和鲁棒性,因此需通过对原始影像进行平移、旋转操作,这样就可以模拟真实场景中的 variations (如患者体位变化、设备误差、组织形变等),从而提高训练效率和准确性。

为了模拟扫描时的轻微偏移和患者的呼吸运动,因此需通过 OpenCV 的 warpAffine 方法来实现平移,其数学公式定义为:

$$x' = (x + t_x) \bmod W \quad (4)$$

$$y' = (y + t_y) \bmod H \quad (5)$$

其中 t_x , t_y 表示平移量, W , H 分别表示图像宽度和高度。

若平移量过大可能导致图像中的病灶移出视野,影响模型学习。在训练中发现横向和纵向平移不超过 8% 的图像宽度或高度可以模拟患者的轻微偏移和呼吸运动,因此选择的平移范围为 $\pm 8\% W/H$ 。

为了模拟患者体位的变化,如乳房位置偏移,因此需对数据进行旋转处理,其数学公式定义为:

$$\begin{bmatrix} x' \\ y' \end{bmatrix} = \begin{bmatrix} \cos \theta & -\sin \theta \\ \sin \theta & \cos \theta \end{bmatrix} \begin{bmatrix} x - c_x \\ y - c_y \end{bmatrix} + \begin{bmatrix} c_x \\ c_y \end{bmatrix} \quad (6)$$

其中 (c_x, c_y) 为中心点坐标, θ 为旋转角度。

为了避免旋转角度过大导致解剖结构严重扭曲,通过训练发现在与图像中心对齐的情况下,选择旋转角度 $\pm 7^\circ$ 模拟乳房位置的偏移。

2.4. 评价指标

在医学影像分类任务中,为了尽可能在类别不平衡的情况下,比如良性样本远多于恶性,进一步提高对恶性的识别能力。本文选取了准确率(Accuracy)、精确率(Precision)、召回率(Recall)和 F1 分数作为评价指标。

准确率(Accuracy)来表示模型的性能,即正确预测样本数占总样本数的比例。其数学公式为:

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN} \quad (7)$$

精确率(Precision)是预测为恶性且实际为恶性的比例。其数学公式为:

$$\text{Precision} = \frac{TP}{TP + FP} \quad (8)$$

召回率(Recall)表示模型实际为恶性且预测为恶性的比例。一般情况,召回率越高,说明更多的正类样本被预测正确,模型效果越好。其数学公式为:。

$$\text{Recall} = \frac{TP}{TP + FN} \quad (9)$$

F1 分数表示精确率和召回率的调和平均数,可以减少误诊和漏诊。其数学公式为:

$$F1 = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (10)$$

2.5. 特征分类

为了更好地区分乳腺癌所处的不同阶段,目前对于乳腺癌诊断会用不同特征进行区分,本文所选取的每种特征的类型见表 1。


Table 1. Characteristic types and types of breast cancer**表 1.** 乳腺癌特征种类和类型

特征	形状	方位	边缘	病灶界限	钙化
类型	椭圆形	平行	完整	锐利	大钙化灶
	圆形	不平行	模糊	回声晕	病变外微小钙化
	不规则形		成角		病变内微小钙化
			微小分叶		导管内微小钙化
			毛刺		

3. 乳腺癌多级诊断系统设计

3.1. 系统总体设计

本系统基于 Qt5.2、C++语言、Python 语言和微信开发者工具进行开发，总体分为表现层、逻辑层、数据层和微信小程序，如图 3 所示，四层交互工作，方便用户使用，并提高了系统的整体性能。

**Figure 3.** The multi level diagnostic architecture**图 3.** 多级诊断架构

3.2. 系统主要模块

3.2.1. 微信小程序模块

患者可以在微信小程序注册登录，在注册完成后患者的个人信息会传递给系统内部，并且当每次诊断结果出来后，系统会生成对应的诊断报告并传给微信小程序，这样患者就可以及时地查看到每次检查的诊断报告，在报告中会根据患者的病灶等级为患者提供相关建议。然后患者可以根据自己的时间安排和当地医疗资源等情况来决定是否到上一级医院进一步诊断治疗。

3.2.2. 诊断模块

在对 ResNet50 模型进行大量数据训练后，会将该模型集成到系统中。在将医学图像传入训练好的深度学习模型中后，经模型推理后生成一份诊断报告，在该报告中会说明病灶特征以及对应的类型，同时会记录对应的病灶图像。

3.2.3. 医生审核修正模块

医生审核修改模块是医生与系统的重要交互模块，该模块主要负责当诊断模块生成诊断报告后，由医生查看诊断报告的内容，依据自身的临床经验对诊断结果与病灶图像进行对比，确认诊断结果是否与临床经验一致，若存在差异，医生可手动修改报告中的病灶信息并且会根据自身经验对这份报告提出后续的治疗建议，然后再生成报告。从而使报告的准确性得到提升，同时在将报告提供给患者之前，经过

了临床医生的审核修正，这也使得系统的安全性得到提高。

3.2.4. 隐私保护模块

为确保患者隐私安全，系统在数据全生命周期中嵌入多层次防护机制：生成报告时，通过脱敏技术仅展示患者姓名(首字 + *)、年龄、性别及诊断结果，敏感字段(如身份证号)默认隐藏，诊断内容按风险分级管控；基于角色分级授权，医生仅可看到脱敏后的必要信息，敏感数据加密存储，采用 AES-256 加密，实现数据可用不可见的闭环管理。

3.2.5. 数据库模块

数据库模块致力于安全、高效地保存患者的每次检查报告数据，采用加密技术确保信息存储的安全性，仅授权的患者和医护人员可访问相应数据，从而有效保护患者隐私。通过追踪病情变化趋势，它不仅支持医生做出更精准的诊断与治疗计划，也让患者能够方便地管理自己的健康信息，同时遵循 HIPAA、GDPR 等相关法律法规，确保数据处理的合规性与透明度，增强医患之间的信任关系。

4. 乳腺癌多级诊断系统实现

4.1. 前端实现

前端主要用于患者与系统的交互，本研究采用 Qt 工具链(Qt Creator + C++)构建核心界面框架，结合 QML 实现动态组件渲染与数据绑定，形成“厚客户端”架构。开发过程严格遵循测试驱动开发(TDD)原则，利用 Google Test 框架编写 C++单元测试用例。界面交互层采用 Qt 信号槽机制与 Vue 的响应式数据流深度融合，实现跨语言状态同步。之后通过微信开发者工具根据用户需求设计相应的功能组件，个人信息注册界面如图 4 所示，该界面包含了姓名、性别、年龄和身份证号等信息。查看报告的效果如图 5 所示，在该界面患者会看到自己检查的信息和建议，如建议复查或到上一级医院进行治疗等。

个人信息

姓名

性别 ☐ 男 ☐ 女

年龄

身份证号

手机号码

是否做过乳腺相关手术？ ☐ 无 ☐ 有

Figure 4. The registration interface
图 4. 注册界面

诊断报告

姓名: XX 性别: XX 年龄: XX

方位: NA

形状: NA

边缘: NA

病灶界限: NA

钙化: NA

建议: NA

Figure 5. Diagnostic report interface
图 5. 诊断报告界面

4.2. 后端实现

后端主要用于处理请求，并根据实际需求对数据进行处理，并将处理后的结果返回给前端和保存到数据库保存。同时卷积神经网络算法在通过训练后，集成到该系统中。当接收到患者的个人信息后，首先会将该患者的图像传给诊断模块，经过诊断模块的分类，会得到对应的特征并将结果保存到数据库中。医生还可以通过结合自己的经验与模型诊断结果，通过数据处理模块将生成诊断报告，然后传给微信小程序数据库。最后在微信小程序中，会根据数据库中记录的数据生成报告并通知给患者，患者可以在微信小程序上及时地看到诊断报告。

5. 结果与分析

5.1. 实验环境

本文的实验环境在 python 环境下运行，CPU 为 AMD Ryzen 7 5800H，8 核；核心频率：3.20 GHz；内存：16 GB DDR4；显卡：RTX 3060；64 位 Windows10 操作系统。

5.2. 模型参数

在本实验中，使用二元交叉熵损失函数(Binary Crossentropy)来判断模型预测结果与实际值之间的差异，损失函数的表达式为：

$$L = -\frac{1}{N} \sum_{i=1}^N (y_i \log p_i + (1 - y_i) \log (1 - p_i)) \quad (11)$$

其中， y_i 表示样本的真实标签， p_i 表示对样本的预测值， n 表示样本数量。

本文使用一种广泛应用于深度学习的自适应优化算法 Adam (Adaptive Moment Estimation)，该算法结合了动量法(Momentum)和 RMSProp 的优点，能够自动调整每个参数的学习率，其更新步骤如下：

首先计算动量估计，其公式为：

$$m_t = \beta_1 m_{t-1} + (1 - \beta_1) g_t \quad (12)$$

其中， m_t 表示梯度的动量估计， g_t 是当前梯度， β_1 是动量超参数，一般取值为 0.9。

其次计算梯度平方的动量估计，其公式为：

$$v_t = \beta_2 v_{t-1} + (1 - \beta_2) g_t^2 \quad (13)$$

其中， v_t 表示梯度平方的动量估计， β_2 是 RMSProp 超参数，一般取值为 0.999。

然后由于动量估计和梯度平方的动量估计在初始时刻可能偏向于零，因此需要偏差修正(Bias Correction)，其公式为：

$$\hat{m}_t = \frac{m_t}{1 - \beta_1^t} \quad (14)$$

$$\hat{v}_t = \frac{v_t}{1 - \beta_2^t} \quad (15)$$

最后更新参数，其公式为：

$$\theta_t = \theta_{t-1} - \alpha \frac{\hat{m}_t}{\sqrt{\hat{v}_t} + \epsilon} \quad (16)$$

其中， θ_t 表示第 t 次迭代的参数， α 是学习率， ϵ 是一个小常数，一般取值 10^{-8} 。

在实验中，通过冻结卷积层和池化层保留预训练模型的基础特征提取能力，调整全连接层以适配新任务；针对目标数据集特性调整参数，结合数据增强和训练策略以提升泛化能力。经调试后具体参数如表 2 所示。

Table 2. Model parameters
表 2. 模型参数

参数	数值
Epoch	30
image_size	224
batch_size	32
损失函数	Binary Crossentropy
优化器	Adam
learning rate	0.0001

5.3. 结果分析

本文评估和比较了 ResNet50、VGGNeT、GoogleNet 和 CNN-ViT 模型在乳腺诊断上的分类性能。为了保持公平性，所有的模型均使用相同的数据集进行训练，为了进一步确保精确性，训练集和测试机来源于相同的数据集并且使用参数也保持相同。

本研究所使用的四个模型的精确度、召回率和 F1 分数都显示在表 3 中。结果表明，在四种模型中 ResNet50 模型的效果最优。由表 3 可知，ResNet50 模型的精确率为 0.9135，召回率为 0.9150，F1 分数为 0.9156。

Table 3. Model training results table
表 3. 模型训练结果表

模型	训练集 Accuracy	验证集 Accuracy	测试集			
			Accuracy	Precision	Recall	F1 分数
ResNet50	0.9515	0.9261	0.9347	0.9135	0.9150	0.9156
VGGNeT	0.8689	0.7656	0.7563	0.7436	0.7419	0.7427
GoogleNet	0.8676	0.7196	0.7063	0.6828	0.6571	0.6697
CNN-ViT	0.8941	0.7121	0.7188	0.7233	0.7143	0.7187

本文还通过混淆矩阵来评估不同模型对乳腺癌的识别能力。可以根据混淆矩阵很直观地看到每个模型的预测准确率，颜色越深代表准确率越高，图 6 表示不同模型对乳腺识别数量结果混淆矩阵。

通过对比四个模型的 Accuracy，由图 7 可知，ResNet50 模型的准确率达到 0.9347，远高于另外三个模型。

为了进一步说明 ResNet50 模型在乳腺癌诊断的准确性，本文还应用了迁移学习方法。对于 ResNet50 模型是否使用迁移学习方法的实验结果如表 4 所示。

由表 4 中的结果所示，使用迁移学习，实验结果相对于未使用迁移学习准确率提高了 4.9%。

结合表 3、图 6，ResNet50 模型无论是精确率、召回率、F1 分数或准确率都远高于另外三个模型，

并且使用了迁移学习的 ResNet50 模型的准确率也高于未使用的, 因此本系统选取 ResNet50 模型用于乳腺癌预测诊断。




Figure 6. Confusion matrix of breast recognition quantity results by different models: (a) ResNet50; (b) VGGNet; (c) GoogLeNet; (d) CNN-ViT

图 6. 不同模型对乳腺识别数量结果混淆矩阵: (a) ResNet50; (b) VGGNet; (c) GoogLeNet; (d) CNN-ViT




Figure 7. Accuracy of each model

图 7. 各模型的准确率

Table 4. Whether to use transfer learning results comparison
表 4. 是否使用迁移学习结果对比

方法	Accuracy	Precision	Recall	F1 分数
使用迁移	0.9347	0.9135	0.9150	0.9156
不使用迁移	0.8910	0.8707	0.8724	0.8758

6. 总结

当前在我国女性人群中乳腺癌仍是癌症中比较常见的类型，对于偏远地区而言，由于经济水平、医疗资源、医生技术水平等多方向的因素，人们对于乳腺癌的认知仍有一定缺乏或不太重视。本文使用深度学习、Qt 工具、C++等和微信小程序建立了一个乳腺癌多级诊断系统。在本文对比的四种模型中，发现 ResNet50 模型对乳腺癌的诊断准确率达到 93.47%，再结合医生的临床经验，可以为患者生成一份比较可靠的诊断报告，并且患者可以及时地在微信小程序中看到自己每次的诊断报告，患者可以根据诊断报告来决定是否到上一级医院接受治疗。通过本系统可以为患者提供更加有效、快捷的治疗手段，本系统对于乳腺疾病的预防、治疗有着良好的前景。

参考文献

- [1] Sung, H., Ferlay, J., Siegel, R.L., Laversanne, M., Soerjomataram, I., Jemal, A., et al. (2021) Global Cancer Statistics 2020: GLOBOCAN Estimates of Incidence and Mortality Worldwide for 36 Cancers in 185 Countries. *CA: A Cancer Journal for Clinicians*, **71**, 209-249. <https://doi.org/10.3322/caac.21660>
- [2] Park-Simon, T.W., Müller, V., Jackisch, C., et al. (2023) Arbeitsgemeinschaft Gynäkologische Onkologie Recommendations for the Diagnosis and Treatment of Patients with Early Breast Cancer: Update 2023. *Breast Care (Basel)*, **18**, 289-305.
- [3] Bleyer, A. and Welch, H.G. (2012) Effect of Three Decades of Screening Mammography on Breast-Cancer Incidence. *New England Journal of Medicine*, **367**, 1998-2005. <https://doi.org/10.1056/nejmoa1206809>
- [4] Dembrower, K., Wittenberg, T. and Lång, K. (2020) Artificial Intelligence in Breast Imaging: Potentials and Limitations. *The Breast*, **49**, 44-48.
- [5] Elmore, J.G. (2005) Screening for Breast Cancer. *JAMA*, **293**, 1245-1256. <https://doi.org/10.1001/jama.293.10.1245>
- [6] Kuhl, C.K. (2007) The Role of MRI in Breast Cancer Screening. *Radiology*, **244**, 656-684.
- [7] McKinney, S.M., Sieniek, M., Godbole, V., Godwin, J., Antropova, N., Ashrafiyan, H., et al. (2020) International Evaluation of an AI System for Breast Cancer Screening. *Nature*, **577**, 89-94. <https://doi.org/10.1038/s41586-019-1799-6>
- [8] Pisano, E.D. and Yaffe, M.J. (2005) Digital Mammography: A Review of Technical Developments and Clinical Applications. *Radiology*, **234**, 353-362. <https://doi.org/10.1148/radiol.2342030897>
- [9] Schnitt, S.J. (2010) Molecular Pathology of Breast Cancer: The Merging of Molecular and Traditional Pathology. *The American Journal of Surgical Pathology*, **34**, e19-e24.
- [10] Shen, D., Wu, G. and Suk, H. (2017) Deep Learning in Medical Image Analysis. *Annual Review of Biomedical Engineering*, **19**, 221-248. <https://doi.org/10.1146/annurev-bioeng-071516-044442>
- [11] Smith, R.A., Andrews, K.S., Brooks, D., Fedewa, S.A., Manassaram-Baptiste, D., Saslow, D., et al. (2019) Cancer Screening in the United States, 2019: A Review of Current American Cancer Society Guidelines and Current Issues in Cancer Screening. *CA: A Cancer Journal for Clinicians*, **69**, 184-210. <https://doi.org/10.3322/caac.21557>
- [12] Sood, R., Rositch, A.F., Shakoor, D., Ambinder, E., Pool, K., Pollack, E., et al. (2019) Ultrasound for Breast Cancer Detection Globally: A Systematic Review and Meta-Analysis. *Journal of Global Oncology*, **5**, 1-17. <https://doi.org/10.1200/jgo.19.00127>
- [13] Yau, C. and Esserman, L. (2015) The Future of Breast Cancer Screening. *The New England Journal of Medicine*, **372**, 2353-2358.
- [14] Yedjou, C.G., Sims, J.N., Miele, L., Noubissi, F., Lowe, L., Fonseca, D.D., et al. (2019) Health and Racial Disparity in Breast Cancer. In: Ahmad, A., Ed., *Breast Cancer Metastasis and Drug Resistance*, Springer, 31-49. https://doi.org/10.1007/978-3-030-20301-6_3

-
- [15] Duffy, S.W., Tabár, L., Yen, A.M., Dean, P.B., Smith, R.A., Jonsson, H., *et al.* (2020) Mammography Screening Reduces Rates of Advanced and Fatal Breast Cancers: Results in 549,091 Women. *Cancer*, **126**, 2971-2979.
<https://doi.org/10.1002/cncr.32859>
 - [16] Margolies, L.R., Rosenkrantz, A.B., Ayoola, A. and Khalil, H. (2016) Breast MRI for Cancer Detection and Characterization: A Review of Evidence-Based Clinical Applications. *Academic Radiology*, **23**, 362-371.
 - [17] Román, M., Sala, M., Domingo, L. and Ascunce, N. (2017) Effect of False-Positives and Women's Characteristics on Long-Term Adherence to Breast Cancer Screening: A Retrospective Cohort Study. *BMC Cancer*, **17**, Article ID: 764.
 - [18] Teixeira, S.C., Leithner, D., Mayerhoefer, M.E., Martinez, D.F., Morris, E.A. and Jochelson, M.S. (2021) Imaging Algorithms for the Diagnosis, Staging, and Response Assessment of Breast Cancer: A Literature Review and Narrative Review of the Current Guidelines. *Cancer Imaging*, **21**, 1-12.