

团 体 标 准

T/CGSS XXXX—XXXX

乳腺癌 MRI 影像采集和数据处理 技术规范

Technical specification of image collection and data processing on breast
cancer MRI

XXXX-XX-XX 发布

XXXX-XX-XX 实施

中国老年医学会 发 布

目 次

目 次	1
前 言	3
引 言	4
1 范围	5
2 规范性引用文件	5
3 术语和定义	5
3.1 数据集术语	5
3.1.1 数据 data	5
3.1.2 数据采集 data acquisition	5
3.1.3 数据质量 data quality	5
3.1.4 数据脱敏 data masking	5
3.1.5 数据标注 data annotation	6
3.1.6 数据预处理	6
3.1.6 数据集 data set	6
3.1.7 训练集 training set	6
3.1.8 验证集 validation set	6
3.1.9 测试集 testing set	6
3.1.10 标签 label	6
3.2 技术术语	6
3.2.1 特征 features	6
3.2.2 特征提取 feature extraction	7
3.2.3 特征降维 feature reduction	7
3.2.4 影像组学 radiomics	7
3.2.5 人工智能 artificial intelligence	7
3.2.6 深度学习 deep learning	7
3.2.7 神经网络 neural network	7
3.2.8 训练 training	7
3.2.9 监督学习 supervised learning	7
3.2.10 自监督学习 self-supervised learning	7
3.2.11 半监督学习 semi-supervised learning	8
3.2.12 迁移学习 transfer learning	8
3.2.13 前向传播网络 forward-propagation network	8
3.2.14 反向传播网络 back-propagation network	8
3.2.15 过拟合 overfitting	8
3.2.16 交叉验证 cross validation	8
3.3 评价指标	8

3.3.1 混淆矩阵 confusion matrix.....	8
3.3.2 灵敏度 sensitivity.....	9
3.3.3 特异度 specificity.....	9
3.3.4 受试者响应曲线 receiver operating characteristics curve, ROC.....	9
3.3.5 曲线下面积 area under curve, AUC.....	9
3.3.6 准确率 accuracy.....	9
4 影像采集标准.....	9
4.1 采集设备要求.....	9
4.2 数据采集要求.....	9
4.3 数据存储要求.....	10
5 科研数据处理标准.....	10
5.1 数据处理流程.....	10
5.2 数据预处理要求.....	11
5.2.1 数据标注.....	11
5.2.2 数据规范化.....	11
5.2.3 数据集划分.....	11
5.3 人工智能方法处理要求.....	11
5.3.1 传统影像组学特征提取.....	11
5.3.2 传统影像组学特征降维.....	11
5.3.3 深度学习特征提取.....	12
5.3.4 基于传统影像组学特征建模.....	12
5.3.5 基于深度学习特征建模.....	12
5.3.6 深度学习模型训练.....	12
6 数据采集与处理质量评价标准.....	12
6.1 数据采集质量评价.....	12
6.1.1 数据合规性.....	12
6.1.2 数据有效性.....	13
6.2 科研数据处理质量评价.....	13
6.2.1 混淆矩阵.....	13
6.2.2 灵敏度.....	13
6.2.3 特异度.....	13
6.2.4 受试者响应曲线.....	14
6.2.5 准确率.....	14
参 考 文 献	15

前 言

本文件按照 GB/T 1.1—2020《标准化工作导则 第 1 部分：标准化文件的结构和起草规则》的规定起草。

请注意本文件的其他内容可能涉及专利，本文件的发布机构不承担识别这些专利的责任。

本文件由广东省第二人民医院提出。

本文件由中国老年医学学会归口。

本文件起草单位：广东省第二人民医院影像科、解放军总医院第一医学中心放射诊断科、广东省人民医院放射科、广东省医学影像智能分析与应用重点实验室、中山大学计算机学院、湖南省第二人民医院放射科、东部战区总医院放射诊断科、福建医科大学附属协和医院放射科、海南省人民医院放射科。

本文件主要起草人：江桂华，娄昕，刘再毅，陆遥，董婷，张伟，张龙江，薛蕴菁，陈峰，王培军，周俊林，王荣品，吕粟、查云飞，李跃华，李咏梅，邓德茂，高明勇，王宇军，马晓芬，魏新华，苏素联，余晖，丁忠祥，赵艺蕾，刘征华，张建军，李广明，张军，孙继红，刘鹏，黄波涛，刘成环，金科，席一斌，宋建勋，汪文胜，周全，范兵，于小平，符传刚，杨民正，唐飞，王飞，易文忠，邹南安，刘岚，周雁玲，初建平，李福兴，史长征，范伟雄，陈英，赵德利，刘杰，严志汉，汪珍元，胡坚兴，吕晋浩，李晶晶，张帆，王刚，粟海龙，孙艳秋，陈兵，陈彤，梁文宝，邢艳，张林，蒋元文。

引 言

乳腺癌的发病率逐年攀升，世界卫生组织国际癌症研究机构(IARC)2020 年全球最新癌症负担数据显示，乳腺癌的全球新发病例高达 226 万，超过肺癌成为全球发病率第一的恶性肿瘤^[1]。此外，2022 年国家癌症中心发布的最新全国癌症统计数据显示，乳腺癌同样位居我国女性新发癌症病例数之首^[2]。乳腺影像学检查在乳腺癌的检出和诊断上具有重要价值。目前，临床最常用的乳腺影像学检查方法包括乳腺 X 线摄影、乳腺超声和乳腺 MRI 检查等。乳腺 X 线摄影能较好显示乳腺内肿块和细小钙化，且诊断费用低、操作简单；乳腺超声具有简便快捷、高效廉价以及适用范围广等特点。因此，乳腺 X 线摄影常与乳腺超声结合作为乳腺疾病筛查和诊断的首选组合方法^[3]。然而，乳腺 X 线摄影对致密型乳腺、近胸壁肿块的显示不佳，且有放射性损害，不作为年轻女性患者的首选检查方法。乳腺超声在评估肿瘤大小等方面优于 X 线摄影，但受操作者经验和水平影响较大^[4]。乳腺 MRI 检查因其多序列、多参数、动态增强扫描等优势，在显示乳腺病变形态、大小、数目、位置、与胸壁关系及腋窝淋巴结转移情况等方面有更大价值，成为乳腺超声和乳腺 X 线摄影的重要后续诊断方法^[4-7]。近年来，人工智能技术的发展，为乳腺癌 MRI 影像数据采集和数据处理带来巨大的促进作用，人工智能技术在病灶自动检出、分割、病灶定性、治疗疗效评估等方面显示出巨大的潜力^[8-16]。

为更好地规范乳腺癌 MRI 影像学检查和影像数据的智能化处理技术，使相关从业和研究人員熟悉和掌握技术要点，广东省医学会放射学分会、分子影像学分会、广东省医学影像智能分析与应用重点实验室的相关专家参考国内外乳腺癌 MRI 影像采集和数据智能化处理步骤，结合近年来乳腺癌 MRI 影像采集和数据处理的应用实际，起草本乳腺癌 MRI 影像采集和数据智能处理技术规范。

乳腺癌 MRI 影像采集和数据处理技术规范

1 范围

本文件给出了乳腺癌 MRI 影像数据采集和处理标准框架，规定了乳腺癌 MRI 影像数据采集标准、数据处理标准、数据采集与处理质量评价标准的具体规范。

本文件适用于乳腺癌高危人群的筛查、乳腺病变的诊断与术前评估、乳腺癌的治疗评价与随访、人工智能应用等场景，需要实施乳腺癌 MRI 影像采集和数据处理质量控制的医疗、企业、高校、科研院所等。

2 规范性引用文件

下列文件中的内容通过文中的规范性引用而构成本文件必不可少的条款。其中，注日期的引用文件，仅该日期对应的版本适用于本文件；不注日期的引用文件，其最新版本（包括所有的修改单）适用于本文件。

YY/T 1833.1-2022 人工智能医疗器械质量要求和评价 第1部分：术语

YY/T 1833.2-2022 人工智能医疗器械质量要求和评价 第2部分：数据集通用要求

YY/T 1833.3-202x 人工智能医疗器械质量要求和评价 第3部分：数据标注通用要求

3 术语和定义

YY/T 1833.1-2022、YY/T 1833.2-2022、YY/T 1833.3-202x 界定的以及下列术语和定义适用于本文件，为了便于使用，以下重复列出了 YY/T 1833.1-2022、YY/T 1833.2-2022、YY/T 1833.3-202x 中的某些术语和定义。

3.1 数据集术语

3.1.1 数据 data

信息的可再解释的形式化表示，以适用于通信、解释或处理。

[YY/T 1833.1-2022，定义 4.1]

3.1.2 数据采集 data acquisition

数据由生成装置按照数据采集规范生成，以数字化格式存储并传输到目标系统的过程。

[YY/T 1833.1-2022，定义 4.1]

3.1.3 数据质量 data quality

在指定条件下使用时，数据的特性满足明确的和隐含的要求的程度。

[YY/T 1833.1-2022，定义 4.2]

3.1.4 数据脱敏 data masking

对敏感信息通过去标识化或匿名化，实现敏感隐私数据的可靠保护。

[YY/T 1833.1-2022，定义 4.3]

3.1.5 数据标注 data annotation

对数据进行分析，建立参考标准的过程。

[YY/T 1833.3-202x，定义 4.3]

3.1.6 数据预处理

数据集文档应明确描述数据集进行预处理的操作步骤和内容。数据集文档应能区分和追溯原始数据和预处理后的数据。

[YY/T 1833.2-2022，定义 4.3]

3.1.6 数据集 data set

具有一定主题，可以标识并可以被计算机化处理的数据集合。

[YY/T 1833.1-2022，定义 4.3]

3.1.7 训练集 training set

用于训练人工智能算法的数据集，类标记对算法来说已知。

[YY/T 1833.1-2022，定义 4.3]

3.1.8 验证集 validation set

用于调优人工智能算法的超参数，类标记对算法来说未知。

3.1.9 测试集 testing set

用于测试人工智能算法性能的数据集，类标记对算法来说未知。

[YY/T 1833.1-2022，定义 4.3]

3.1.10 标签 label

附加到一组数据元素的标识符。

[YY/T 1833.1-2022，定义 4.3]

3.2 技术术语

3.2.1 特征 features

能表达模式本质的功能或结构特点的可度量属性，如大小、纹理、形状等。好的特征应能使同类模式聚类、不同类模式分离。

[YY/T 1833.1-2022, 定义 5.1]

3.2.2 特征提取 feature extraction

将目标区域的特征转换成具有一定可解释意义的数字矩阵的过程。

3.2.3 特征降维 feature reduction

对特征数目进行一定的限制，避免冗余数据影人工智能模型的精确和稳定性，提升模型泛化能力的手段。

3.2.4 影像组学 radiomics

高通量地从影像图像中提取海量定量特征，从而将图像转化为可挖掘的大数据，并进一步分析其内所含的生物学信息，以达到协助临床决策的目的。

3.2.5 人工智能 artificial intelligence

表现出与人类智能（如推理和学习）相关的各种功能的功能单元的能力。

[YY/T 1833.1-2022, 定义 5.2]

3.2.6 深度学习 deep learning

在神经网络或信念网络的情况下是对基于深层结构或网络表示的输入输出间映射进行机器学习的过程。

[YY/T 1833.1-2022, 定义 5.2]

3.2.7 神经网络 neural network

由加权链路且权值可调整连接的基本处理元素的网络,通过把非线性函数作用到其输入值使每个单元产生一个值,并把它传送给其他单元或把它表示成输出值。

[YY/T 1833.1-2022, 定义 5.2]

3.2.8 训练 training

基于机器学习算法，利用训练数据，建立或改进机器学习模型参数的过程。

[YY/T 1833.1-2022, 定义 5.2]

3.2.9 监督学习 supervised learning

获得的知识的正确性通过来自外部知识源的反馈加以测试的学习策略。

[YY/T 1833.1-2022, 定义 5.2]

3.2.10 自监督学习 self-supervised learning

一种学习策略，通过基于数据本身设计和建立的各种标记信息来对数据本身的特征、特性进行学习，进而把学习到的数据特征网络作为主干网络迁移到对目标任务的学习中。

[YY/T 1833.1-2022，定义 5.2]

3.2.11 半监督学习 semi-supervised learning

一种学习策略，它自行利用少量的具有标记信息的样本和大量没有标记的样本进行学习的框架。

[YY/T 1833.1-2022，定义 5.2]

3.2.12 迁移学习 transfer learning

利用一个学习领域 A 上有关学习问题 T(A)的知识，改进学习领域 B 上相关学习问题 T(B)的学习算法的性能。

[YY/T 1833.1-2022，定义 5.2]

3.2.13 前向传播网络 forward-propagation network

在给定层内的各人工神经元之间既没有反馈路径也没有任何路径的多层网络。

[YY/T 1833.1-2022，定义 5.2]

3.2.14 反向传播网络 back-propagation network

一种多层网络，它使用反向传播，以便学习期间的连接权调整。

[YY/T 1833.1-2022，定义 5.2]

3.2.15 过拟合 overfitting

学习器对训练样本过度学习，导致训练样本中不具有普遍性的模式被学习器当作一般规律，降低了泛化性能；典型表现是训练集上的性能越高，测试集上的性能越低。

[YY/T 1833.1-2022，定义 5.2]

3.2.16 交叉验证 cross validation

一种利用已知数据集获取学习器最有参数，以期在未知数据集上获得最佳泛化性能。常见的有留一法和 K 重交叉验证法。

[YY/T 1833.1-2022，定义 5.2]

3.3 评价指标

3.3.1 混淆矩阵 confusion matrix

一种矩阵，它按一组规则记录试探性实例的正确分类和不正确分类的个数。

注：通常矩阵的列代表人工智能的诊断结果，而矩阵的行代表参考标准的诊断结果。

[YY/T 1833.1-2022, 定义 6.1]

3.3.2 灵敏度 sensitivity

真阳性样本占全体阳性样本的比例。

[YY/T 1833.1-2022, 定义 6.2]

3.3.3 特异度 specificity

真阴性病例占全体阴性病例的比例。

[YY/T 1833.1-2022, 定义 6.3]

3.3.4 受试者响应曲线 receiver operating characteristics curve, ROC

通过在一组预设的阈值下计算人工智能算法在测试集上的灵敏度（Sensitivity）以及特异度（Specificity）从而产生一组（1-Specificity, Sensitivity）操作点，将操作点依次连接形成受试者操作曲线。

[YY/T 1833.1-2022, 定义 6.4]

3.3.5 曲线下面积 area under curve, AUC

受试者操作曲线下的积分面积。

[YY/T 1833.1-2022, 定义 6.4]

3.3.6 准确率 accuracy

算法诊断正确的样本占全体样本的比例。

[YY/T 1833.1-2022, 定义 6.5]

4 影像采集标准

4.1 采集设备要求

设备方面推荐采用高场(1.5 T 及以上)扫描设备,以便获得较好的信噪比和脂肪抑制效果。采用专门的乳腺线圈,推荐采用相控阵线圈及并行采集技术,双乳同时成像,获得较好的时间分辨率和空间分辨率。影像采集过程使用的设备应当在有效期内,并符合《中国抗癌协会乳腺癌诊治指南与规范(2021 版)》要求。

4.2 数据采集要求

数据采集具有标准 DICOM 格式的真实、原始临床数据。从操作层面来说,以下表技术规范进行选择。

扫描体位	俯卧位，双侧乳房自然悬垂，双侧乳头位于线圈中心并在同一水平线上。摆位时，受检者两臂上举支撑于软垫上，力求体位舒适，保证全部乳腺组织位于线圈内，皮肤与乳腺无褶皱，双侧乳腺对称，乳头与地面垂直，胸骨中线位于线圈中线上。
成像方位	一般行横断面、矢状面、冠状面定位扫描，至少包括两个体位(尤其是横断面与矢状面相结合)。先行三平面定位像扫描，利用获得的横断面、矢状面、冠状面三平面定位像进行单侧或双侧乳腺矢状面、横断面或冠状面成像。
扫描序列	推荐 T1 WI 非脂肪抑制序列、T2WI 脂肪抑制序列、动态增强 T1WI(DCE-T1WI) 脂肪抑制序列、扩散加权成像(diffusion weighted imaging, DWI) (b 值为 0 和 1000 s/mm ²)。
层厚与分辨率	扫描层厚应≤3 mm，层面内的分辨率应<1.5 mm，单次扫描时间<2 min。
增强扫描	对比剂选用 Gd-DTPA，注射剂量 0.1~0.2 mmol / kg，采用压力注射器以 2 ml/s 的速率经肘静脉注入，注射完对比剂后以相同速率注入 20 mL 生理盐水冲管。轴位 DCE-T1WI 脂肪抑制序列扫描 6 期，注射对比剂前先采集第 1 期平扫图像；注射完对比剂并用盐水冲完管后，连续采集 5 期增强图像，采集时间 60 s/期；随后扫描冠状位 DCE-T1WI 脂肪抑制序列。


4.3 数据存储要求

符合 DICOM 3.0 协议的标准数据。

5 科研数据处理标准

5.1 数据处理流程

数据处理流程如以下流程图所示。



5.2 数据预处理要求

5.2.1 数据标注

依据 MRI 乳腺癌的病灶特点，目前有研究机构研发可用于自动或半自动分割肿瘤病灶的方法。乳腺癌病灶的标注需要精确，以《人工智能医疗器械质量要求和评价 第3部分：数据标注通用要求》为执行准则。

5.2.2 数据规范化

乳腺癌 MRI 图像规范处理技术一般包含以下几个方面。

(1)影像配准：为了减小影像采集过程中患者身体移动等原因产生的影像形变和噪声需对图像进行影像配准，可使用刚性配准^[56]。

(2)影像增强：为提升图像清晰度和视觉效果，以达到精确的诊断，可应用多种处理技术，对图像进行增强。

(3)影像标准化：不同数据源图像存在尺寸、层间距等差别，可应用图像重采样，图像归一化（Z-score 归一化）等方法对图像进行标准化^[57]。

(4)图像增广：由于深度学习的训练需要大量数据，为减轻模型过拟合，可对数据集进行增广，常用的图像增广方法包括对图像进行翻转、旋转、平移等刚性变化、以及随机裁剪、色彩抖动、对比度变换等方法。图像增广处理目前独用于深度学习处理技术中。

5.2.3 数据集划分

将数据集划分为训练集、验证集、测试集。常见划分方法有留出法，K 折交叉验证法等。

5.3 人工智能方法处理要求

5.3.1 传统影像组学特征提取

基于乳腺癌 MRI 影像和肿瘤病灶区域可提取影像组学图像特征合集，包含一阶梯度特征（如灰度均值、最大值、最小值、方差等）、形状特征（如形态学参数、圆形度等）、纹理特征（灰度共生矩阵、灰度区域大小矩阵、灰度游程矩阵、邻域灰度差矩阵、灰度依赖矩阵等），也包含了各种图形滤波变换后的特征，比如高斯-拉普拉斯变换、小波变换、平方根滤波等。影像组学图像特征合集将在医学图像分析中有过较为成功应用的特征聚集在一起。

5.3.2 传统影像组学特征降维

影像组学特征集包含成百上千的高维特征，将包含着一定的噪声和冗余信息，当特征维度达到一定级别的时候，再增加特征对最终的结果影响已经降到很低，反而严重增加了完成组学流程的时间和空间复杂度。倘若直接将大量特征纳入模型将会产生过拟合问题，因此推荐采用一些特征降维的手段来对特征数目进行一定的限制，避免冗余数据影响机器学习模型的精确和稳定性，提升模型泛化能力。常见推荐使用的降维方法有相关性分析、主成分分析、独立分量分析、基于 LASSO 回归模型^[60,61]等方法。

5.3.3 深度学习特征提取

深度学习特征主要是通过卷积神经网络提取的，大致可以分为三部分：通道内特征、通道间特征以及通道信息融合。

(1)通道内特征：卷积神经网络通过单个卷积层提取的特征。

(2)通道间特征：卷积神经网络各卷积层之间通过共享参数，调整单个卷积层提取的特征。

(3)通道信息融合：不同卷积层提取的特征进行融合，得到最具表达力的特征向量。

5.3.4 基于传统影像组学特征建模

根据应用目标的不同可能选择的模型也不同，包含常用的分类、回归、聚类等模型。常用的分类器包括了决策树、逻辑回归、随机森林、支持向量机（SVM）等，在建模过程中，为了减少过拟合和选择偏差、保证更好的模型性能，也需要对模型进行参数调优，并加入交叉验证方法。

5.3.5 基于深度学习特征建模

选择基础的网络模型、设计损失函数、选择优化器，设计适合目标任务的神经网络模型。根据应用目标和解决策略的不同，深度学习模型方法可分为多种不同类型的模型。如：常见的模型包括基于卷积神经网络的乳腺癌检测模型，基于候选区域的乳腺癌检测模型等。

①基于卷积神经网络的乳腺癌检测模型：卷积神经网络可提取输入数据的局部特征并逐层组合抽象生成高层特征，可用于图像识别、图像分类、图像分割等。搭建基于卷积神经网络的模型可实现端到端的类别预测或者肿瘤病灶区域的分割。常用的用于类别预测的网络结构有 AlexNet、VGG、ResNet 等网络，常用的用于病灶分割的网络结构有 FCN、U-Net 等网络。

②基于候选区域的乳腺癌检测模型：基于候选区域的乳腺癌检测模型通常包括以下三步：首先，利用选择性搜索、区域生成网络（Region proposal network, RPN）、ROI 池化层等方法从输入图像中预测乳腺肿瘤可能出现的位置，生成若干个候选区域；然后利用卷积神经网络从候选区域中提取特征；最后利用分类器对特征进行分类。常用的基于候选区域的网络包含 R-CNN 系列深度学习模型、YOLO 系列模型等。

5.3.6 深度学习模型训练

循环调用训练过程进行模型训练，直至网络收敛，网络是否收敛可根据每一轮验证集的结果变化判断。每轮训练都包括前向计算、优化目标和后向传播等步骤。根据实际目标应用，训练过程除了采用自监督学习，还可采用迁移学习、半监督学习等数据量较少的策略。

6 数据采集与处理质量评价标准

6.1 数据采集质量评价

6.1.1 数据合规性

伦理批件或其他官方批件应当真实合规。从志愿者、体检中心、社区筛查项目、科研项目等其他途径获取的图像应当通过同等效力的批准程序保证数据脱敏、患者隐私安全和受检者利益。

数据脱敏是保护受检者隐私的技术手段。图像本身、头文件、附属文件，以及数据集的元数据中均不应包含与受检者隐私有关的任何信息。

受检者个人信息、医保信息、活动轨迹、经济状况、家庭情况、财务信息、社会信息等个人隐私不得搜集和显示；图像头文件中涉及受检者隐私的字段必须进行脱敏处理。

6.1.2 数据有效性

数据集制造责任方应确保脱敏后的原始数据的准确性，避免有损压缩、图像篡改等操作。每个病例的图像应当保持连续完整，不得出现缺层、错层等情况。不同医院的数据质量、成像参数配置应保持一致。最后，需对采集数据进行检查和确认，去除数据缺层、错层、序列缺失、超范围扫描、伪影遮挡等不合格数据，筛选满足质量要求的数据。

6.2 科研数据处理质量评价

6.2.1 混淆矩阵

对于 N 分类问题，混淆矩阵的一般形式如表 6.2.1 所示：

表 6.2.1 N 分类混淆矩阵

分类	Pred_1	Pred_2	...	...	Pred_N
True_1	$M_{1,1}$	$M_{1,2}$	...	...	$M_{1,N}$
True_2	$M_{2,1}$	$M_{2,2}$	...	...	$M_{2,N}$
...	...	...	...	...	...
...	...	...	...	...	...
True_N	$M_{N,1}$	$M_{N,2}$	...	...	$M_{N,N}$

注：Pred_x (x=1~N) 为人工智能诊断为 N 类的类别；True_x (x=1~N) 为参考标准诊断为 x 类的类别； M_{ij} (i=1~N, j=1~N) 为参考标准的诊断结果为 i 类，被人工智能诊断为 j 类的个数；N 为分类类型个数。

6.2.2 灵敏度

灵敏度用 Sen 表示，表达式见式（6.2.2）：

$$Sen = \frac{M_{i,i}}{M_{i,i} + \sum_{j=1, j \neq i}^N M_{j,i}} \times 100\% \tag{6.2.2}$$

6.2.3 特异度

特异度用 Spe 表示，表达式见式（6.2.3）：

$$Spe = \frac{\sum_{j=1, j \neq i}^N \sum_{l=1, l \neq i}^N M_{j,l}}{\sum_{j=1, j \neq i}^N M_{i,j} + \sum_{j=1, j \neq i}^N \sum_{l=1, l \neq i}^N M_{j,l}} \times 100\% \quad (6.2.3)$$

6.2.4 受试者响应曲线

示例如图 6.2.4 所示：




图 6.2.4

横坐标和纵坐标值均 0-1 之间，曲线下面积 AUC 最大值为 1。

6.2.5 准确率

准确率用 Acc 表示，表达式见式（6.2.5）

$$Acc = \frac{\sum_{i=1}^N M_{i,i}}{\sum_{j=1}^N \sum_{l=1}^N M_{j,l}} \times 100\% \quad (6.2.5)$$

参 考 文 献

- [1] Sung H, Ferlay J, Siegel R L, et al. Global cancer statistics 2020: GLOBOCAN estimates of incidence and mortality worldwide for 36 cancers in 185 countries[J]. CA Cancer J Clin, 2021, 71(3): 209- 249. <https://doi.org/10.3322/caac.21660>
- [2] Zheng R S, Zhang S W, Zeng H M, et al. Cancer incidence and mortality in China, 2016[J]. JNCC, 2022, 2(1): 1-9. DOI: <https://doi.org/10.1016/j.jncc.2022.02.002>.
- [3] 王思敏, 顾雅佳. 对比增强乳腺 X 线摄影的应用,挑战与前景[J]. 中华放射学杂志, 2021, 55(12):6. DOI: 10.3760/cma.j.cn112149-20210216-00122.
- [4] Dialani V, Chadashvili T, Slanetz P J. Role of imaging in neoadjuvant therapy for breast cancer[J]. Ann Surg Oncol, 2015, 22(5):1416-24.
- [5] 《中国癌症杂志》编辑部. 《中国抗癌协会乳腺癌诊治指南与规范(2021 版)》2022 年指南主席团巡讲活动[J]. 中国癌症杂志, 2022, 32(5):1.
- [6] Expert Panel on Breast I, Slanetz P J, Moy L, et al. ACR Appropriateness Criteria((R)) Monitoring Response to Neoadjuvant Systemic Therapy for Breast Cancer[J]. J Am Coll Radiol, 2017, 14(11S): S462-S75.
- [7] Morrow M, Waters J, Morris E. MRI for breast cancer screening, diagnosis, and treatment[J]. Lancet, 2011,378(9805):1804-11.
- [8] Wang S, Zhou M, Liu Z, et al. Central focused convolutional neural networks: Developing a data-driven model for lung nodule segmentation[J]. Med Image Anal,2017,40:172-183.
- [9] Yasaka K, Akai H, Abe O, et al. Deep Learning with Convolutional Neural Network for Differentiation of Liver Masses at Dynamic Contrast-enhanced CT: A Preliminary Study[J]. Radiology, 2017:170706.
- [10] Li S, Dong M, Du G, et al. Attention Dense-U-Net for Automatic Breast Mass Segmentation in Digital Mammogram[J]. IEEE Access,2019, (99):1-1.
- [11] Zhang Z, Zhang X, Li X, et al. Ultrasonic Diagnosis of Breast Nodules Using Modified Faster R-CNN[J]. Ultrasonic imaging, 2019, 41(6):353-367.
- [12] Ming F, Yuanzhe L, Shuo Z, et al. Computer-aided detection of mass in digital breast tomosynthesis using a faster region-based convolutional neural network[J]. Methods, 2019, (166):103-111.

- [13] Aly G H, Marey Mo, Sayed S A, et al. YOLO Based Breast Masses Detection and Classification in Full-Field Digital Mammograms[J]. Computer Methods and Programs in Biomedicine,2020,(4):105823-105823.
- [14] Yi W, Qin C, Chuan L.3D Inception U-net with Asymmetric Loss for Cancer Detection in Automated Breast Ultrasound[J]. Medical Physics, 2020, 47(11):5582-5591.
- [15] Wu N, Phang J, Park J, et al. Deep Neural Networks Improve Radiologists' Performance in Breast Cancer Screening[J]. IEEE transactions on medical imaging.2020,39(4):1184-1194.
- [16] McKinney S M, Sieniek M, Godbole V, et al. Addendum: International evaluation of an AI system for breast cancer screening[J]. Nature. 2020,586(7829):E19-E19.
- [17] Lambin P, Rios-Veazquez E, Leijennar R, et al. Radionics: extracting more information from medical images using advanced feature analysis[J]. Ann Surg, 2021, 273(4):694-700.
- [18] Gillies R J, Kinahan P E, Hriak H. Radiomics: Images Are More than Pictures, They Are Data[J]. Radiology, 2016, 278(2):563-77.
- [19] Zhang Q, Peng Y, Liu W, et al. Radiomics Based on Multimodal MRI for the Differential Diagnosis of Benign And Malignant Breast Lesions [J]. J Magn Reson Imaging 2020, 52(2): 596-607.
- [20] Dalmis M U, Gubem-Merida A, Vreemann S, et al. Artificial Intelligence-Based Classification of Breast Lesions Imaged With a Multiparametric Breast MRI Protocol With Ultrafast DCE-MRI, T2, and DWI[J]. Invest Radiol, 2019, 54(6):325-32.
- [21] Li H, Mendel KR, Lan L, et al. Digital Mammography in Breast Cancer. Additive Value of Radiomics of Breast Parenchyma [J]. Radiology, 2019, 291(1): 15-20.
- [22] Tagliafico AS, Valdora F, Mariscotti G, et al. An exploratory radiomics analysis on digital breast tomosynthesis in women with mammographically negative dense breasts[J]. Breast, 2018, 40:92-6.
- [23] Zhang Q, Xiao Y, Suo J. et al. Sonoelastomics for Breast Tumor Classification: A Radiomics Approach with snoelastography [J]. Ultrasound Med Biol, 2017, 43(5):1058-69.
- [24] Li C, Song L, Yin J. Intratumoral and Peritumoral Radiomics Based on Functional Parametric Maps from Breast DCE-MRI for Prediction of HER-2 and Ki-67 Stats[J]. J Magn Reson Imaging 2021,54(3):703-14.

- [25] Zhou J, Tan H, Li W, et al. Radiomics Signatures Based on Multiparametric MRI for the Preoperative Prediction of the HFR2 Status of Patients with Breast Cancer[J]. Acad Radiol,2021,28(10):1352-60.
- [26] Kayadibi Y, Kocak B, Ucar N, et al Radioproteomics in Breast Cancer. Prediction of Ki-67 Expression With MRI-based Radiomic Models [J]. Acad Radiol, 2022, 29 Suppl I:S116-S25.
- [27] Leithner D, Horvat J V, Marino M A, et al. Radiomic signatures with contrast-enhanced magnetic resonance imaging for the assessment of breast cancer receptor status and molecular subtypes: initial results [J]. Breast Cancer Res, 2019,21(1): 106.
- [28] Ma W, Zhao Y, Ji Y, e al. Breast Cancer Molecular Subtype Prediction by Mammographic Radiomic Features [J]. Acad Radiol,2019,26(2): 196-201.
- [29] Li H, Zhu Y, Bumside E S, et al. Quantitative MRI radiomics in the prediction of molecular classifications of breast cancer subtypes in the TCGA/TCIA data set [J]. NPJ Breast Cancer,2016,2.
- [30] Yu Y, He Z, Ouyang J, et al Magnetic resonance imaging radiomics predicts preoperative axillary lymph node metastasis to support surgical decisions and is associated with tumor microenvironment in invasive breast cancer A machine learning, multicenter study[J]. EBioMedicine,2021,69:103460.
- [31] Mao N, Dai Y, Lin F, et al. Radiomics Nomogram of DCE-MRI for the Prediction of Axillary Lymph Node Metastasis in Breast Cancer [J]. Front Oncol, 2020, 10:541849.
- [32] Chai R, Ma H, Xu M, et al. Differentiating axillary lymph node metastasis in invasive breast cancer patients: A comparison of radiomic signatures from multiparametric breast MR sequences[J]. J Magn Reson Imaging,2019, 50(4):1125-32.
- [33] Liu C, Ding J, Spuhler K, et al. Preoperative prediction of sentinel lymph node metastasis in breast cancer by radiomic signatures from dynamic contrast-enhanced MRI[J]. J Magn Reson Imaging, 2019,49(1):131-40.
- [34] Yu Y, Tan Y, Xie C, et al. Development and Validation of a Preoperative Magnetic Resonance Imaging Radiomics-Based Signature to Predict Axillary Lymph Node Metastasis and Disease-Free Survival in Patients With Early-Stage Breast Cancer[J]. JAMA Netw Open,2020,3(12):e2028086.

- [35] Sun Q, Lin X, Zhao Y, et al. Deep Learning vs Radiomics for Predicting Axillary Lymph Node Metastasis of Breast Cancer Using Ultrasound Images: Don't Forget the Peritumoral Region[J]. *Front Oncol*,2020,10:53.
- [36] Zheng X, Yao Z, Huang Y, et al. Deep learning radiomics can predict axillary lymph node status in early-stage breast cancer[J]. *Nat Commun*,2020, 11(1):1236.
- [37] Braman N, Prasanna P Whitney J, et al. Association of Peritumoral Radiomics With Tumor Biology and Pathologic Response to Preoperative Targeted Therapy for HER2(ERBB2)-Positive Breast Cancer [J]. *JAMA Netw Open*, 2019, (4): e192561.
- [38] Liu Z, Li Z, Qu J, et al Radiomics of Multiparametric MRI for Pretreatment Prediction of Pathologic Complete Response to Neoadjuvant Chemotherapy in Breast Cancer. A Multicenter Study [J]. *Clin Cancer Res*,2019, 25(12):3538-47.
- [39] Cain E H, Saha A, Harowicz M R, et al. Multivariate machine learning models for prediction of pathologic response to neoadjuvant therapy in breast cancer using MRI features: a study using an independent validation set[J].*Breast Cancer Res Treat*, 2019,173(2): 455-63.
- [40] Braman N M, Etesami M, Prasanna P, et al. Intratumoral and peritumoral radiomics for the pretreatment prediction of pathological complete response to neoadjuvant chemotherapy based on breast DCE-MRI[J]. *Breast Cancer Res*,2017, 19(1):57.
- [41] Fan M, Wu G, Cheng H, et al. Radiomic analysis of DCE-MRI for prediction of response to neoadjuvant chemotherapy in breast cancer patients[J]. *Eur J Radiol*,2017,94:140-7.
- [42] Pesapane F, Rotl A, Bota F, et al Radiomics of MRI for the Prediction of the Pathological Response to Neoadjuvant Chemotherapy in Breast Cancer Patients: A Single Referral Centre Analysis[J]. *Cancers (Basel)*, 2021, 13(17).
- [43] Li H, Zhu Y, Bumside E S, et al. MR Imaging Radiomics Signatures for Predicting the Risk of Breast Cancer Recurrence as Given by Research Versions of MammaPrint, Oncotype DX, and PAM50 Gene Assays [J]. *Radiology*, 2016,281(2): 382-91.
- [44] Huang S Y, Frnc B L, Hamish R J, et al. Exploration of PET and MRI radiomic features for decoding breast cancer phenotypes and prognosis [J]. *NPJ Breast Cancer*,2018,4:24.
- [45] Park H, Lim Y, Ko E S, et al. Radiomics Signature on Magnetic Resonance Imaging: Association with Disease-Free Survival in Patients with Invasive Breast Cancer[J]. *Clin*

Cancer Res,2018,24(19):4705-14.

- [46] Chitalia R D, Rowland J, McDonald E S, et al. Imaging Phenotypes of Breast Cancer Heterogeneity in Preoperative Breast Dynamic Contrast Enhanced Magnetic Resonance Imaging(DCE-MRI)Scans Predict 10-Year Recurrence [J]. Clin Cancer Res,2020,26(4):862-9.
- [47] Tagliafico A S, Piana M, Schenone D, et al. Overview of radiomics in breast cancer diagnosis and prognostication [J]. Breast,2020, 49:74-80.
- [48] Sheth D, Giger M L. Artificial intelligence in the interpretation of breast cancer on MRI[J]. J Magn Reson Imaging, 2020,51(5): 1310-24.
- [49] Pesapane F, Rotili A, Agazi GM, et al. Recent Radiomics Advancements in Breast Cancer. Lessons and Pifalls for the Next Future[J]. Cur Oncol,2021,28(4):2351-72.
- [50] Conti A, Duggento A, Indovinal, et al. Radiomics in breast cancer classification and prediction[J]. Semin Cancer Biol, 2021,72:238-50.
- [51] Valdora F, Houssami N, Rossi F, et al. Rapid review: radiomics and breast cancer[J]. Breast Cancer Res Treat, 2018, 169(2):217-29.
- [52] Satake H, Ishigaki S, Ito R, et al. Radiomics in breast MRI: current progress toward clinical application in the era of artificial intelligence [J]. Radiol Med, 2022,127(1): 39-56.
- [53] Yang X, Wu L, Ye W, et al. Deep Learning Signature Based on Staging CT for Preoperative Prediction of Sentinel Lymph Node Metastasis in Breast Cancer[J]. Acad Radiol,2020,27(9): 1226-33.
- [54] Arimura H, Soufi M, Kamezawa H, et al. Radiomics with artificial intelligence for precision medicine in radiation therapy[J]. Journal of Radiation Research, 2019, 60(1): 150-157.
- [55] Kontos D, Summers M M D R, Giger M L. Special Section Guest Editorial: Radiomics and Deep Learning[J]. Journal of medical imaging, 2018, 4(4): 041301.
- [56] Stelmo N, Aristó fanes C S, Rodolfo A N, et al. Voxel-based comparative analysis of lung lesions in CT for therapeutic purposes[J]. Medical & Biological Engineering & Computing, 2017,55(2): 295-314.
- [57] Zhao X, Wu Y, Song G, et al. 3D Brain Tumor Segmentation Through Integrating Multiple 2D FCNNs[C]// Crimi A, Bakas , Kuijf H et al. International MICCAI Brainlesion Workshop. Springer: Cham, 2017:191-203.
- [58] Prastawa M, Bullitt E, Moon N, et al. Automatic brain tumor segmentation by subject specific modification of atlas priors[J]. Acad Radiol, 2003, 10(12): 1341-1348.
- [59] Corso J J, Sharon E, Dube S, et al. Efficient multilevel brain tumor segmentation with integrated Bayesian model classification[J]. IEEE Trans Med Imaging, 2008, 27(5): 629-640.

- [60] Friedman J, Hastie T, Tibshirani R. Regularization paths for generalized linear models via coordinate descent[J]. Journal of statistical software, 2010, 33(1): 1.
- [61] Tibshirani R. Regression shrinkage and selection via the lasso[J]. Journal of the Royal Statistical Society: Series B (Methodological), 1996, 58(1): 267-288.
-