

陈香玉, 陈庆奎, 黄陈. 面向医疗图像 AI 分析的支持模型[J]. 智能计算机与应用, 2025, 15(11):164–169. DOI:10.20169/j.issn.2095-2163.251127

面向医疗图像 AI 分析的支持模型

陈香玉¹, 陈庆奎¹, 黄陈²

(1 上海理工大学 光电信息与计算机工程学院, 上海 200082; 2 上海交通大学附属第一人民医院 胃肠外科, 上海 200082)

摘要: 为解决传统计算机辅助诊断中医疗图像处理存储并未将图像充分利用等问题, 本文设计了一种面向医疗图像 AI 分析的支持模型。该模型专注于医疗图像的特殊性, 通过数据预处理阶段实现图像数据的优化。在存储阶段设计了适应医疗图像特点的存储结构, 并采用云存储方案以提升数据共享的便利性。为解决广域网传输中的安全隐患, 应用加密技术保护图像传输过程中的数据安全性。此外, 通过无监督预训练, 有效地利用未标记图像构建模型参数库, 为模型提供更优的初始化和数据理解能力。实验证明, 本文提出的支持模型在医疗图片存取能力方面优于传统模型, 能够快速响应新需求和变化, 并为 AI 模型训练提供了有力支持。

关键词: 医疗图像; 存储结构; AI 分析; 支持模型

中图分类号: TP391 文献标志码: A 文章编号: 2095-2163(2025)11-0164-06

A support model for AI analysis of medical images

CHEN Xiangyu¹, CHEN Qingkui¹, HUANG Chen²

(1 School of Optical-Electrical and Computer Engineering, University of Shanghai for Science and Technology, Shanghai 200082, China; 2 Department of Gastrointestinal Surgery, Shanghai General Hospital, Shanghai Jiao Tong University, Shanghai 200082, China)

Abstract: A model specifically designed for AI analysis of medical images has been developed to address issues in traditional computer-aided diagnosis, such as underutilization of image data. This model focuses on the unique characteristics of medical images and optimizes the image data during the data preprocessing stage. In the storage phase, a storage structure tailored to medical image characteristics has been designed, and a cloud storage solution is employed to enhance data sharing convenience. To address security risks in wide area network transmission, encryption techniques are applied to ensure the data security during image transmission. Additionally, through unsupervised pretraining, the model effectively utilizes unlabeled images to build a parameter library, providing superior initialization and data understanding capabilities. Experimental results demonstrate that the supporting model outperforms traditional systems in terms of storage and retrieval capabilities, enabling rapid responses to new requirements and changes, while providing robust support for AI model training.

Key words: medical images; storage structure; AI analysis; support model

0 引言

医学图像领域结合人工智能和大数据取得了令人振奋的进展, 提高了诊断准确性和效率, 并为个性化诊疗提供全面支持^[1]。传统的模型缺乏将人工智能与医学图像相结合的能力, 图片采用集中存储方式, 这种存储方式后期的维护和管理比较困难, 不易扩容, 甚至出现数据丢失的情况^[2-3]。医疗图像

单张像素过大, 使得深度学习模型无法直接加载到内存中处理^[4]。文献[5]提出了一种基于多视角知识的协同深度学习模型, 利用有限的胸部 CT 数据来分离恶性结节和良性结节; 文献[6]基于已处理的医疗图像, 提出用于检测肝脏肿瘤及其分类的新型深度学习模型; 文献[7]基于已标注图像, 提出改进的距离正则化水平集模型, 能有效分割医疗图像。以上的方式均是基于部分过程做研究, 未能将问题

基金项目: 国家自然科学基金(61572325); 上海重点科技攻关项目(19DZ1208903)。

作者简介: 陈香玉(1999—), 女, 硕士, 主要研究方向: 医疗图像, 深度学习; 黄陈(1978—), 男, 博士, 教授, 博士生导师, 主要研究方向: 胃肠癌基础临床研究。

通信作者: 陈庆奎(1966—), 男, 博士, 教授, 博士生导师, 主要研究方向: 计算机集群, 并行计算, 人工智能。Email: chenqingkui@usst.edu.cn。

收稿日期: 2024-02-24

结合处理。本文提出了面向医疗图像 AI 分析的支持模型,解决了深度学习算法中忽略数据预处理和清洗的问题,同时解决个人隐私泄漏和数据安全保护问题,充分利用未标记数据。构建预训练参数库,为提高数据利用提供了有力支持。

1 功能概述

医疗影像系统基于一系列的标准规范体系以及安全防护体系建设,在安全防护体系下,系统可与支持模型进行数据和服务的共享与交换。支持模型结构如图 1 所示。

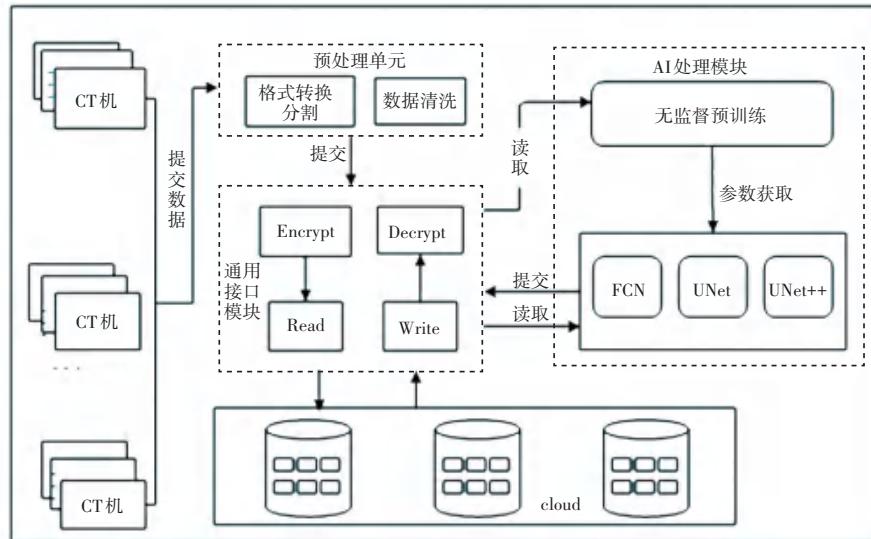


图 1 支持模型结构图

Fig. 1 Supporting model structure diagram

(1) 数据源

数据源可以接入医院医学影像存档与通信系统(PACS),也可以是专业医生挑选的特定病人医疗图像所构建的专业影像库,本文使用的是由上海交通大学附属第一人民医院提供的胃癌患者的 CT 图像。

(2) 数据预处理模块

数据预处理模块需要对图像进行标准化,使其具有统一的尺度。此外,医疗图像通常包含元数据信息,例如患者信息、扫描设备参数等。数据预处理模块需要从医疗图像中提取和解析这些元数据,并将其与图像数据关联起来,以便在模型预测中使用。此外数据预处理模块会对图像进行数据清洗,去除无用数据。

(3) 数据存储模块

数据存储模块采用云存储,提供高度可扩展的存储能力,能够轻松地存储和管理大量的图片数据,该模块根据医疗图像的特点设计适合医疗图像存储的存储结构,采用数据加密方式存储,增加安全性。

(4) AI 模型处理模块

该模块运用无监督预训练技术,针对经有效筛选的未标注图像开展预训练工作。将预训练生成的

模型参数作为初始参数,能够为深度学习模型的后续训练提供支撑。

(5) 通用接口

在支持模型结构中,通用接口包括写接口、读接口、加密接口、解密接口。其中写接口、读接口用于与云存储模块进行数据读写交互;加密接口和解密接口用于存储读取图像时的加解密操作。

2 模型设计

2.1 数据预处理单元

医学数字成像和通信图像(DICOM)将图像的详细信息和患者的详细信息存储在同一图像中^[8]。深度学习模型无法直接将这些图像加载到内存中处理,数据预处理单元会通过图 2 所示的图像转换过程对图像进行处理。

(1) 格式转换归一化

先将 DICOM 图像转换为 bmp 格式,再由 bmp 格式转换成其它通用图像格式。

数据归一化公式:

$$y' = \frac{y - y_{\min}}{y_{\max} - y_{\min}} \quad (1)$$

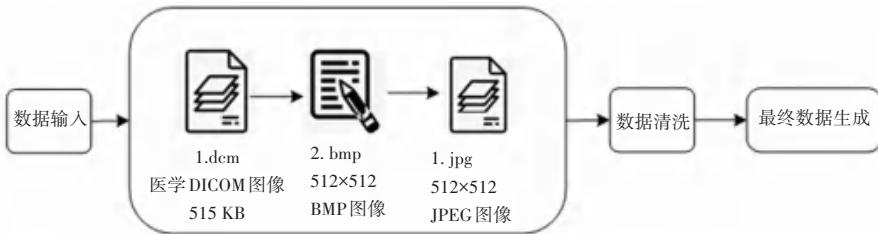


图 2 图像转换过程

Fig. 2 Image conversion process

其中, y 是原始数据的值;而 y_{\min} 是原始数据中最小值; y_{\max} 是原始数据中的最大值。

(2) 数据过滤

转换后的图像中会存在全黑或全白的情况。为了过滤掉这些无用图片,利用主成分分析(PCA)的方式来进行处理,使用 PCA 处理的步骤如下:

步骤 1 设 X 是 PCA 的输入矩阵;

步骤 2 使用下式计算每个维度的均值 (\bar{X}):

$$\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i \quad (2)$$

其中, n 为样本数, X_i 为观测数据。

步骤 3 使用下式计算协方差矩阵 C_x :

$$C_x = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})(X_i - \bar{X})^T \quad (3)$$

其中, \bar{X} 为平均数。

步骤 4 使用下式计算协方差矩阵的特征向量 ν_m 和特征值 λ_m :

$$C_x \nu_m = \lambda_m \nu_m \quad (4)$$

步骤 5 每个主成分(特征向量)的方差比例(PPV)由下式描述:

$$PPV = \frac{\lambda_i}{\sum \lambda_i} \times 100\% \quad (5)$$

其中, λ_i 为特征值。

步骤 6 通过将阈值与累积方差比例进行比较来确定特征向量的数量。

步骤 7 将测试数据 Y 乘以主成分矩阵 PC ,从而将 Y 映射到由主成分构成的低维子空间中,完成维度降低的操作。

$$y' = Y \times PC \quad (6)$$

2.2 数据存储单元

2.2.1 云存结构设计

在临床诊断过程中,患者做一次 CT 检查,一般会产生几百个医学影像文件。因此,医学影像文件将影像信息按层级划分为 4 个级,分别为:患者(Patient)、检查(Study)、序列(Series)、图像

(Image)^[9]。不同的层次都对应一个唯一标识 UID。通过这 4 个层级的 UID,可以快速精确地找到想要的医学影像文件。

构造数据存储核心内部结构如图 3 所示,经预处理后会生成待存储的图像和一份原图像描述,包括患者 UID、检查 UID、序列 UID、图像 UID。存储核心以医院为一级对象,病人为二级对象。每个病人对应其一系列的检查,每个检查下对应多个序列,每个序列中包括多张图像,每个图像目录有描述文件、原图文件、输出文件 3 个文件,其中描述文件记录了病人及图像的描述信息;原图文件存放未处理的图像;输出文件存放的是对应经处理后的图像。

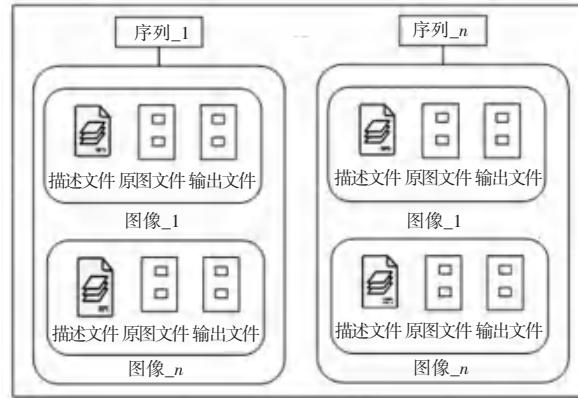


图 3 数据存储核心内部结构

Fig. 3 Internal structure of data storage core

2.2.2 加密存储

健康记录是敏感数据,应保护避免未经授权的使用、暴露和访问^[10]。本文用 AES-128 算法对数据进行加密。AES-128 算法使用 128 位(16 字节)的密钥对数据进行加密,使用相同的密钥和 AES-128 算法对加密后的数据块进行解密,然后将解密后的数据重新组合成原始图像数据^[11-12]。

2.2.3 数据存取交互

数据读取和数据写入是数据交互的两个过程,客户端与云端之间的数据通信是以流的形式进行的^[13-14]。客户端先与云端建立连接,并逐层获取目标文件列表及数据块信息,再执行数据块交互读写

数据。读取数据的步骤:客户端发起读请求,接口解析客户端读请求,解析后的查询条件为医院编号、病人编号、病例编号、序列编号、图形编号,以此得到定位输入流;定位输入流用于定位文件位置和读取数据;根据解析后的参数,依次按照医院编号、病人编号、病例编号、序列编号、图形编号的顺序进行查询,如果后续参数条件为空,则批量返回对应文件下的所有内容,直到目标文件读取完毕,客户端关闭与云端的连接。

2.3 AI 处理单元

2.3.1 预训练

从医院设备获取大量的原始胃癌医学图像后,通过预处理创建一个专门针对胃癌的图片库。利用无监督训练来构造模型参数库,使用卷积神经网络的倒数第二层的向量作为特征或表示,表示为 f_θ 。通过学习参数 θ ,最终得到一个能够生成有效通用视觉特征的函数。

假设有一组 N 个图像 $\{x_1, \dots, x_n\}$,并且为每个输入 x_n 分配一个伪标签 y_n ,伪标签 y_n 在优化期间是固定的通过学习卷积神经网络的参数 θ 和线性分类器 v ,以预测这些伪标签,预测公式如下:

$$y_n = \min_{\theta, v} \frac{1}{N} \sum_{n=1}^N \zeta(y_n, v f_\theta(x_n)) \quad (7)$$

其中, ζ 代表一个损失函数。

为每个图像 n 定义在 z 中的潜在伪标签 z_n 以及相应的线性分类器 W 。学习参数 θ 和 W 在更新伪标签 z_n 之间交替。通过求解 θ 来优化参数和分类器,如下式:

$$\theta = \min_{\theta, v} \frac{1}{N} \sum_{n=1}^N \zeta(z_n, W f_\theta(x_n)) \quad (8)$$

然后,可以通过最小化辅助损失函数来重新分配伪标签 z_n 。通过 k-means 聚类激活值来获得潜在目标,即通过解决下式优化问题来更新目标 z_n :

$$z_n = \min_{C \in R^{d \times k}} \sum_{n=1}^N \left[\min_{z_n \in \{0, 1\}^k} z_n^T z_n = 1 \right] \| C z_n - f_\theta(x_n) \|_2^2 \quad (9)$$

其中, C 是一个矩阵,其中每列对应一个质心, k 是质心的数量,而 z_n 是一个二进制向量,只有一个非零元素。

这种方法假设聚类的数量 k 是事先已知的,在随机梯度下降的 T 个轮次中,潜在目标会每隔 T 个轮次进行更新。

使用无监督任务来捕获图片中的信息。通过无监督预训练模块,可在筛选后的数据上开展预训练,进而学习通用的特征表示,预训练生成的模型参数库能够作为后续任务的基础参数^[15-16]。

2.3.2 AI 模型处理模块

AI 分析模块利用人工智能技术,对存储的医学图像进行智能化的分析和判别。该模块引入 3 种神经网络模型(FCN、U-net、Unet++),并将预训练模块的参数导入这些 AI 模型中,使系统能够自动识别和分类医疗图像,从而减少人工判断的成本。AI 模型处理流程如图 4 所示,首先加载图片列表,加载成功后可选择模型处理图片,经过处理后图片会标注出病灶区域,帮助医生进行诊断。

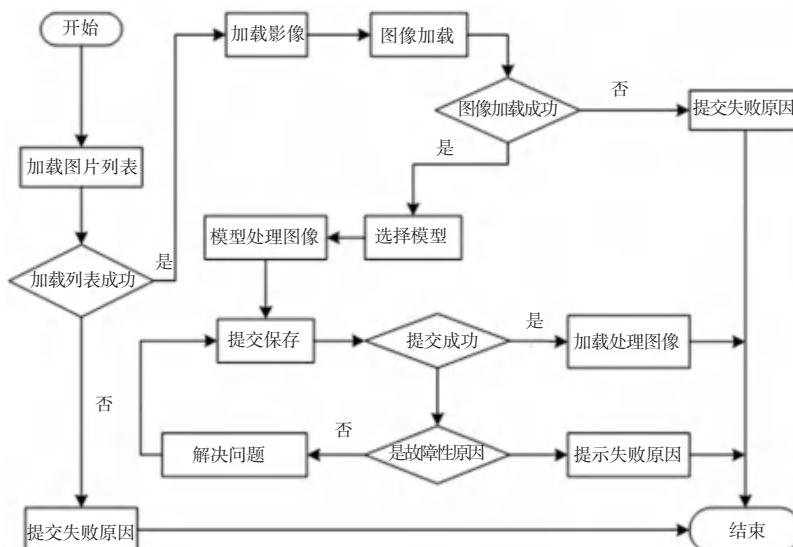


图 4 AI 模型处理流程图

Fig. 4 AI model processing flowchart

3 实验与分析

3.1 实验环境

本实验操作系统为 CentOS 7.9.2009 (Core), CPU 型号为 Intel Xeon E5-2690, 2.60 GHz, 16 cores, GPU 为 NVIDIA GeForce RTX 2080。在软件环境方面,采用 Python 3.9.5 版本, AI 模型部分基于深度学习框架 Pytorch 和 Tensorflow 开发,存储使用阿里云的分布式存储服务。

3.2 数据集描述

研究中使用的数据集是上海交通大学附属第一人民医院胃肠外科提供的数据集,该数据集包含 2015 年 1 月至 2019 年 12 月期间经术后病理证实的 I, II 期胃癌患者的术后病理图像共 3 049 幅。

选取 4 种不同分辨率的图片 (128×128 、 256×256 、 512×512 、 1024×1024) 开展存储实验, 分别采用传统存储方式和本文提出的支持模型结构存储方式记录存储时间, 数据存储对比结果见表 1。对比发现, 与传统方式存储未经处理的各类分辨率图像相比, 支持模型结构存储方式存储各类图片的时间开销更多。但支持模型结构存储会考虑后续图像数据与 AI 模型的适配性, 对数据进行预处理, 且采用松散耦合的模块化架构, 能够灵活动态调整, 通用性更强。从数据支持模型处理不同分辨率图像的表现来看, 其更适配 512×512 分辨率图像, 存储 512×512 分辨率的时间比 256×256 增加 30%, 存储 1024×1024 分辨率图比存储 512×512 分辨率图形增加 74%, 并且 512×512 分辨率的图像能为后续 AI 模型提供更丰富信息, 提升处理准确性, 综上 512×512 分辨率为本文支持模型结构的最佳选择。

表 1 数据存储对比表

Table 1 Data storage comparison table

读取方式	执行时间/ms			
	分辨率/dpi			
	128×128	256×256	512×512	1024×1024
支持模型结构存储	72	118	153	235
传统存储	52	84	133	225

对比“Pytorch+传统方式”和“Pytorch+支持模型”读取 4 种分辨率图像 (128×128 、 256×256 、 512×512 、 1024×1024) 的时间, “Pytorch+支持模型”在读取不同分辨率图像时速度更快; 对比“Tensorflow+传统方式”和“Tensorflow+支持模型”的读取时间, “Tensorflow+支持模型”的读取速度也更快, 具体图

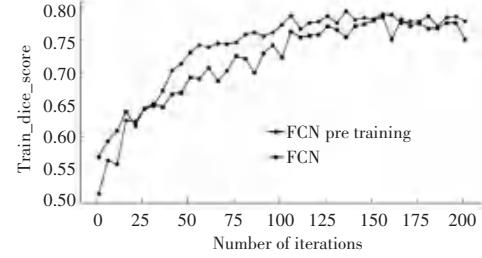
像读取时间对比见表 2。

表 2 图像读取时间对比表

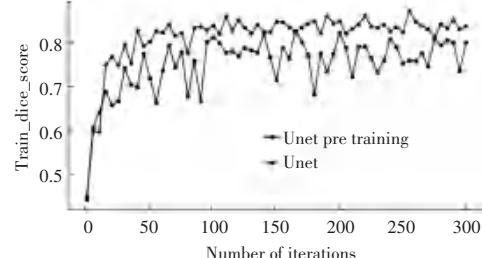
Table 2 Image reading time comparison table

读取方式	执行时间/ms			
	分辨率/dpi			
	128×128	256×256	512×512	1024×1024
Pytorch+支持模型	48	67	103	175
Pytorch+传统方式	67	93	143	246
Tensorflow+支持模型	52	74	112	135
Tensorflow+传统方式	76	104	152	275

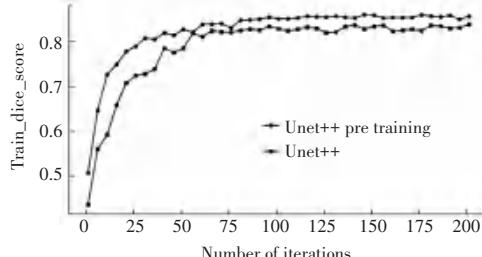
在相同数据集上, 分别对 FCN(全卷积网络)、Unet 和 Unet++ 3 种模型采用预训练参数与未采用预训练参数的情况进行实验, 3 种模型在迭代 0~200 轮过程中模型相似系数指标 (Dice Similarity Coefficient) 的对比变化情况如图 5 所示。



(a) FCN 相似系数指标对比图



(b) Unet 相似系数指标对比图



(c) Unet++相似系数指标对比图

图 5 模型相似系数指标对比图

Fig. 5 Comparison chart of model similarity coefficient metrics

由图 5 可见, 在迭代 0~200 轮中, FCN、Unet 和 Unet++ 3 种模型使用预训练参数的 Dice 指标约 90% 以上, 高于未使用预训练参数的 Dice 指标, 表明使用预训练参数的模型在 Dice 指标上表现更

出色。

4 结束语

本文提出了一种面向医疗图像 AI 分析的支持模型, 通过数据预处理、适配医疗图像特性的存储结构、安全的数据传输机制及无监督预训练等技术手段, 有效解决了传统计算机辅助诊断中数据预处理存在的问题。实验结果表明, 该模型在优化数据处理流程、保障数据安全性以及提升数据共享便利性等方面优势显著, 大幅提高了数据访问效率与共享便捷性。无监督预训练方法则成功构建了模型参数库, 为模型提供了更优的初始化条件和数据理解能力。但该支持模型仍存在一定局限性, 随着医疗图像数据量的持续增长, 后续的数据检索问题将逐渐凸显, 后续将针对这一方向展开深入研究。

参考文献

- [1] 陈冲, 陈俊, 夏黎明. 人工智能促进医学影像临床应用与研究 [J]. 放射学实践, 2024, 39(1): 12–16.
- [2] 王小瑜, 曾永康, 向明飞, 等. PACS 数据管理中的问题与解决方案 [J]. 中国医学装备, 2021, 18(8): 221–223.
- [3] 陈伟哲. 面向海量图数据存储与检索系统的设计与实现 [D]. 北京: 北京邮电大学, 2021.
- [4] XIE Y T, XIA Y, ZHANG J P, et al. Knowledge-based collaborative deep learning for Benign–Malignant lung nodule classification on chest CT [J]. IEEE Transactions on Medical Imaging, 2018, 38(4): 991–1004.
- [5] POIROT M G, VEPAKOMMA P, CHANG K, et al. Split learning for collaborative deep learning in healthcare [J]. arXiv, 1912.12115, 2019.
- [6] MANJUNATH R V, GHANSHALA A, KWADIKI K. Deep learning algorithm performance evaluation in detection and classification of liver disease using CT images [J]. Multimedia Tools and Applications, 2024, 83(1): 2773–2790.
- [7] 岳晴, 关雪, 王生生. 基于改进的距离正则化水平集模型的医疗图像分割 [J]. 东北师范大学学报(自然科学版), 2023, 55(4): 52–58.
- [8] TRIEU P D Y, BARRON M, LEWIS S J. Use of full-quality DICOM images compared to minimally compressed mammograms in jpeg format for radiology training: A study from radiologist and radiographer perspectives [J]. Academic Radiology, 2023, 30(8): 1748–1755.
- [9] 钟良志. 基于 DICOM 标准的医学图像解析与处理系统的设计与实现 [D]. 成都: 电子科技大学, 2018.
- [10] KIRKPATRICK J N, MITCHELL C, TAUB C, et al. ASE statement on protection of patients and echocardiography service providers during the 2019 novel coronavirus outbreak: Endorsed by the American College of Cardiology [J]. Journal of the American College of Cardiology, 2020, 75(24): 3078–3084.
- [11] JOHRI A M, GALEN B, KIRKPATRICK J N, et al. ASE statement on point – of – care ultrasound during the 2019 novel coronavirus pandemic [J]. Journal of the American Society of Echocardiography, 2020, 33(6): 670–673.
- [12] AL-JUMAILI A H A, MUNIYANDI R C, HASAN M K, et al. Big data analytics using cloud computing based frameworks for power management systems: Status, constraints, and future recommendations [J]. Sensors, 2023, 23(6): 2952.
- [13] 李亚鹏. 医学影像云存储系统的设计与实现 [D]. 郑州: 郑州大学, 2019.
- [14] CARON M, BOJANOWSKI P, JOULIN A, et al. Deep clustering for unsupervised learning of visual features [C]// Proceedings of the European Conference on Computer Vision (ECCV). Cham: Springer, 2018: 132–149.
- [15] CHEN X, DING M, WANG X, et al. Context autoencoder for self-supervised representation learning [J]. International Journal of Computer Vision, 2024, 132(1): 208–223.
- [16] ABULIBDEH A, ZAIDAN E, ABULIBDEH R. Navigating the confluence of artificial intelligence and education for sustainable development in the era of industry 4.0: Challenges, opportunities, and ethical dimensions [J]. Journal of Cleaner Production, 2024, 437: 140527.