

改进残差网络的医学 X 射线影像 分类与加密传输系统

汪兴阳, 戴安邦, 刘艳, 王俊哲, 陈心可

(河海大学 信息科学与工程学院, 江苏 常州 213200)

摘要: 随着 X 射线影像在医疗诊断领域的快速发展, 在大量胸腔 X 射线影像产出的情况下, 医生根据经验进行人为判断分析的方式已不能满足诊断效率与准确率的需求, 高效率、高准确率处理批量 X 射线影像分类的问题亟待解决; 通过改进残差网络对胸腔 X 射线影像进行分类, 并设计一种加密传输系统, 可有效解决上述问题; 利用对 X 射线影像进行基于马尔可夫随机场的图像增强, 再采用深层信息挖掘能力较强的 ResNet50 作为主干网络, 增加自注意力机制并采用 CELU 激活函数优化; 经 Kaggle 整合数据集实验测试结果表明, 在保证分类准确性的前提下, 分类的召回率从 0.432 提升到 0.652; 同时, 系统采用基于 Logistic 混沌序列的图像加密算法, 保证了远程医疗诊断的私密性, 满足实际远程医疗场景的应用需求。

关键词: 胸腔 X 射线影像; ResNet50; 马尔可夫随机场; 自注意力机制; CELU; Logistic 混沌序列

Medical X-ray Image Classification and Encrypted Transmission System Based on Improved Residual Network

WANG Xingyang, DAI Anbang, LIU Yan, WANG Junzhe, CHEN Xinke

(College of Information Science and Engineering, Hohai University, Changzhou 213200, China)

Abstract: With the rapid development of X-ray imaging in the field of medical diagnosis, traditional manual judgment and analysis methods based on the doctor's experience cannot meet the efficiency requirements for diagnosing a large number of chest X-ray images. It is urgent to efficiently and accurately solve the classification of batch X-ray images. The residual network is introduced to classify the batch X-ray images, and an encrypted transmission system is designed to effectively achieve the above problem. The X-ray images are used to enhance the images based on the Markov random field, and then the ResNet50 with strong deep information mining ability is used as the backbone network to add the self-attention mechanism, and the continuously differentiable exponential linear units (CELU) activation function is used to optimize. The experiment is implemented on the Kaggle integrated dataset, the results show that the recall rate of classification is increased from 0.432 to 0.652 while ensuring the classification accuracy. Additionally, the image encryption algorithm based on logistic chaotic sequences is used to ensure the privacy of remote medical diagnosis, meeting the application requirements of actual remote medical scenarios.

Keywords: X-ray images on chest; Resnet50; Markov random field; self-attention; CELU; logistic chaotic sequence

0 引言

人体肺部作为包裹在人体内的器官, 因其无法通过外观察觉到器官异常或病变, 临床上大多数采用个人经验理论或传统方法来观察病人的胸腔 X 射线影像或 CT 影像, 而这种方法不仅对医务工作者的医学水平有较高的要求, 也无法在肺部疾病暴发高峰期及时应对大量出现的病例。与 CT 成像相比, 胸部 X 射线成像技术操作速度快、成本低、易于获得、侵入性小, 且胸部 X 射线影像包含更多的肺部特征, 在疾病的早期诊断和治疗中发挥着不可或缺的作用。尤其在流感季节, 病毒性肺炎高发, 不同地区不同

医疗机构的医疗资源分配不均匀, 胸部 X 射线影像的分析在病人护理中起着关键作用, 传统的医疗诊断方式不仅对医务工作者的专业性和工作效率有较大压力, 而且很难支持远程问诊。此外, 病灶与周围组织存在对比不明显、边缘模糊等问题都会对诊断产生干扰。现在, 人工智能的最新发展为放射诊断应用的快速增长提供了新的潜在机遇, 研究者们已对如何把图像处理技术运用到医学图像的诊断上做了大量的研究, 并且有相当一部分已经投入到实际的医疗当中, 取得了可观的效果。精准快速的医疗辅助诊断设备不仅可以有效地缓解医务工作者的工作压力, 实现远

收稿日期: 2023-12-31; 修回日期: 2024-02-27。

基金项目: 常州市科技项目(CJ20220089); 河海大学大学生创新创业训练计划资助项目(2023102941331)。

作者简介: 汪兴阳(2003-), 男, 大学本科生。

通讯作者: 刘艳(1984-), 女, 博士, 副教授, 研究生导师。

引用格式: 汪兴阳, 戴安邦, 刘艳, 等. 改进残差网络的医学 X 射线影像分类与加密传输系统[J]. 计算机测量与控制, 2024, 32(8): 257-264.

程私人化问诊,也可以有效节省医疗资源与提高医疗诊断效率^[1-4]。

近年来,基于深度学习的医学影像处理技术已在医疗辅助诊断上崭露头角。2017年 Esteva^[5]使用深度学习技术来检测恶性黑色素瘤,此项工作发表在 Nature 期刊上,该团队经过实验得到 AUC (Area Under Curve) 为 0.94 的模型结果,已经达到了专业医师的水平。

医学影像通常为 X 射线图像,此类图片容易受到噪声、场偏移效应、局部体效应和人体器官组织复杂性和差异性影响不可避免地具有模糊不均匀性特点。基于此,文献 [6] 提出了一种基于肺部 PET/CT 图像不同纹理特征的 K 最近邻分类器,但该算法在实际 X 射线影像分类任务中,对深度信息的挖掘程度并不够,并且极易受到 X 射线扫描设备产生噪点的干扰。文献 [7] 提出了一种基于图像阈值分割的图像预处理方法,但该方法只能提取出轮廓,而无法对纹理细节进行优化,且基于阈值的方法鲁棒性无法保证。文献 [8] 提出了一种通过卷积神经网络实现乳腺 X 射线影像的有效分类方法,但该模型无法有效应对胸腔 X 射线影像中骨骼和肌肉覆盖的情况,且在训练后期容易出现拟合导致实际应用时效果不佳。文献 [9] 通过 Inception-ResNet 网络实现了胸腔 X 射线图像的高精度分类,但分类结果只针对病毒性肺炎与细菌性肺炎,未考虑其他肺部疾病,缺乏实际应用场景中的普适性。文献 [10] 提出了基于马尔可夫随机场的图像增强方法,该方法与常见的 X 射线影像增强算法相比,可以更好地提高影像的平均对比度,挖掘纹理信息,但因其实时性较传统算法有些不足,鲜有将其应用于实际设计中。

此外,目前大多数的研究针对医学图像的分类而展开,缺少针对远程医疗展开的医学影像远程传输与加密系统设计。文献 [11] 设计了基于 Android 图片 Logistic 映射混沌加密传输,但没有将此算法用于医学影像的加密传输。

综上所述,目前 X 射线影像数据的处理方法存在的问题可概括如下:冗余信息无法有效去除、有效信息的挖掘程度不够、无法有效应对肺部 X 射线影像数据、识别类别不足、未实现远程私密性传输、缺少系统化设计,难以应用于实际医疗场景。针对以上问题,本文设计开发了一种改进残差网络的医学 X 射线影像分类与加密传输系统。为实现医学 X 射线影像的多分类远程自动诊断,将自注意力机制引入改进的 ResNet50 模型,利用自注意力机制在模型中自动学习图像中不同部分的重要性权重,使模型更加关注病变区域与周围正常组织之间的特征差异,并对这些特征进行有效地整合和利用,从而提升分类精度。同时加入基于 MRF (马尔可夫随机场, Markov Random Field) 预处理,能够突出缩小后的肺炎 X 射线图像的重要特征。以实现胸腔 X 射线影像的快速、高精度、安全检测分类。系统的主要创新点包括:

1) 基于结构优化的残差网络对 X 射线影像分类。利用 ResNet50 作为主干网络,基于马尔可夫随机场的图像增强方法作为图像的预处理手段,通过归一化后送入搭载 SA 机

制的改进 ResNet50 网络,为了进一步优化性能,通过 CE-LU (连续可微指数线性单元, Continuously Differentiable Exponential Linear Units) 激活函数优化与一系列网络结构优化,最终得到影像分类结果。

2) 图像加密算法与微内核结构部署。本系统使用 Logistic 混沌序列图像加密算法,以保证影像数据在传输过程中的私密性与安全性;采用 WebSocket 作为网络传输协议以节省网络资源、提高传输性能;利用微内核结构部署,方便统筹协调管理,符合系统实际落地场景。

1 系统结构及原理

基于改进残差网络的医学影像分类与加密传输系统以半自动化的方式运行,能够及时、安全地分析并传输胸腔 X 射线影像图。在假设客户机为一的情况下,系统方案如图 1 所示。




图 1 系统方案示意图

系统主体由基于 WebSocket 协议搭建的微内核结构组成,主要包含加密算法模块、base64 编码模块、base64 解码模块、解密算法模块和胸腔 X 射线影像处理算法组成。当用户希望对某张图片进行解析分类时,系统会先在客户机本地上进行加密与转 base64 编码操作,此时若服务器中存在空闲的 GPU 算力,会自动与客户机端口对接进行数据传输。当服务器接收到客户机传来的数据时,会先进行 base64 解码与解密算法,之后送入胸腔 X 射线影像处理算法中进行解析分类,得到分类结果后将其结果传回客户机,以此为一个完整的服务周期。期间,服务器会一直处于开机状态,当用户短时间内无解析需求时,可以关闭客户机;当用户再次产生图像解析需求时,客户机开机后可以通过预设地址自动与服务器端口进行连接。

胸腔 X 射线影像分类算法由多个处理模块串联组成。当 X 射线影像输入算法模型时,会先对其进行基于马尔可夫随机场的图像增强方法,后加以 Z-score 标准化和影像尺度转换,确保传入网络的数据格式统一。将预处理好的数据传入改进残差网络,采用 ResNet50 作为主干网络,搭载 SA 自注意力机制头和 CELU 激活算法优化结构。经网络计算,可以得到 X 射线影像的分类结果,该优化网络结构提高了分类的准确度和召回率,满足医疗应用场景需要。图 2 为胸腔 X 射线影像多分类算法的总体设计图。

2 胸腔 X 射线影像多分类算法优化

系统核心围绕胸腔 X 射线影像多分类算法展开,相较于以往的医学 X 射线影像分类算法,本系统分别在数据集、




图 2 胸腔 X 射线影像多分类算法的总体设计图

预处理与骨干网络上做出了一系列优化, 旨在提高系统的解析与分类性能。

2.1 数据集扩充

与以往设计中常采用的单一数据集模型训练方式不同, 本系统模型训练采用的数据集来自 Kaggle: Chest X-Ray Images (Pneumonia) 以及 Kaggle: 2027 medical images (chest x-ray) with and without pneumothorax. 通过整合两个数据集, 得到正常、病毒性肺炎、细菌型肺炎、气胸四分类数据集。使实际模型具有更强的泛化能力, 可以适应更多情形下的需求。各分类下具体的数据量如表 1 所示。

表 1 整合数据集中各分类项数据量

分类项	数据量/张
正常	1 771
病毒性肺炎	1 345
细菌型肺炎	2 530
气胸	1 597

任选各分类中的一张影像数据展示, 如图 3 所示。




图 3 整合数据集中各分类影像数据展示

将数据经过以上处理后可以得到新的数据集, 该数据集较常见的胸腔 X 射线影像数据集相比, 可以用于更多分类的深度学习模型训练, 也可以实现实际落地场景中一次检测分类就可以挖掘出多种潜在疾病的需求。但值得注意的是, 数据集经过扩充后, 以往用于传统任务的最佳模型就可能不再适配。因此, 本文还对传统模型进行了一些优化修改, 在该数据集上得到了更好的模型表现。

2.2 数据集的预处理优化

文献 [12] 中指出, 医学 X 射线图像通常表现为低对比度、高噪声, 且有骨骼肌肉结构的覆盖, 在肺部 X-ray 图像中, 病灶特征不显著、病变类型多样、形态尺度多变等成为图像分类的难题。若直接输入神经网络进行训练, 会易受到噪点干扰, 且难以挖掘到高覆盖图像中的深层信息。因此, 医学 X 射线影像若想应用于深度学习领域, 就需要添加一些重要的预处理手段。

2.2.1 基于马尔可夫随机场的图像增强

医学图像增强的目的是通过图像增强的方法改善图像的质量、增强图像的特征, 得到优化的医学图像, 以帮助神经网络从图像中获得更多细节信息, 在一定程度上可提高诊断的准确性^[13]。在医学 X 射线影像的处理中, 因为其通常表现为低对比度, 需要采取合适的图像增强方法以提高图片对比度。

马尔可夫随机场 (MRF, Markov random field)^[14]是具有马尔可夫性质的随机场模型, 用于描述随机变量之间的概率关系。在图像中, 每个像素可以看作一个随机变量, 通过建立马尔可夫随机场模型, 可以进行像素间的概率推断, 从而进行图像分割、去噪等任务。在马尔可夫随机场模型中, 重点考虑相邻像素灰度值间的局部相互作用, 受算法实时性要求, 只用其中的一阶邻域系统来构建模型。

在数学模型中, 马尔可夫随机场的一阶邻域被定义为:

$$\eta_i^1 = [(i-1, j), (i, j-1), (i+1, j), (i, j+1)] \quad (1)$$

其中, 上标 1 表示一阶邻域, η_i^1 为最靠近 (i, j) 的二维空间中的 4 个像元, 其空间关系呈现如图 4 所示。




图 4 马尔可夫随机场中各阶邻域的覆盖示意图

将原图中各点的像素值映射到 0 与 1 之间的浮点型数据, 记原图中 (i, j) 点的灰度值为 $g(i, j)$, 则如式 (2):

$$g'(i, j) = \frac{g(i, j)}{255.0} \quad (2)$$

计算每个像素点与其一阶邻域各像素点的能量差异之和, η_i^1 中的各个像素点坐标按 (1) 式中的顺序 $\eta_i^1(1), \eta_i^1(2)$ 依次类推, 则各点能量差异 $D(i, j)$ 的具体公式为:

$$D(i, j) = \sum_{p=1}^4 \beta \times \{g'(i, j) - g'[\eta_i^1(p)]\}^2 \quad (3)$$

其中: β 可以理解为能量差异系数, β 越大会增强图像中的边缘信息或细节信息, β 较小会使图像更模糊平滑。之后, 通过该能量差异来得到增强后 (i, j) 点的像素值 $U(i, j)$:

$$U(i, j) = g'(i, j) - \alpha \times D(i, j) \quad (4)$$

其中: α 可以理解为能量差异所产生的影响的系数, α 越大会使图像更锐化或明亮, α 较小则会减小能量差异对像素更新的影响。

将得到的参数重新映射回 0~255 的整形范围内, 如式 (5):

$$g_{\text{enhanced}}(i, j) = \begin{cases} 0, & \text{if } U(i, j) < 0 \\ \text{round}[255 \times U(i, j)], & \text{if } 0 \leq U(i, j) \leq 1 \\ 1, & \text{if } U(i, j) > 1 \end{cases} \quad (5)$$

式中, $g_{\text{enhanced}}(i, j)$ 组成的图像即为经过基于马尔可夫随机场图像增强算法处理后得到的图像。

2.2.2 数据标准化

图像数据的大小范围通常为 0~255 范围内, 若通过局部信息来看, 取值过大的部分就会对模型造成更大的影响, 即模型会更容易受到该部分数据的扰动。此外, 在模型推理的过程中, 也容易受到噪声或异常值的干扰。

图像数据标准化是一种对图像数据进行预处理的方法, 通过消除图像数据中的偏差和噪声, 使数据更易于理解和分析, 从而表现出提高模型训练效果、加快模型收敛速度等效果。

对于医学 X 射线图像, 通常会因为设备而产生各种噪点干扰。Z-score 标准化方法能够在保留原始图像信息的前提下, 通过减小图像像素值的离散程度来减小异常噪点对图像质量和分析结果的影响, 提高了噪声下的图像诊断准确性。

Z-score 的计算方法是通过减去均值再除以标准差, 将数据映射到以 0 为均值、1 为标准差的标准正态分布。具体计算公式如下:

$$x'_r{}^{(i)} = \frac{x_r{}^{(i)} - \mu_r}{\sigma_r} \quad (6)$$

其中: r 表示 x 图像中的任意一行或列作为特征, (i) 表示遍历该特征下的每一个像素点, μ_r 为该特征中所有像素值的平均值, σ_r 为该特征中所有像素值的方差。关于 μ_r 和 σ_r 的计算公式如式 (7) (8):

$$\mu_r = \frac{1}{n} \sum_{i=0}^{n-1} x_r{}^{(i)} \quad (7)$$

$$\sigma_r^2 = \frac{1}{n} \sum_{i=0}^{n-1} [x_r{}^{(i)} - \mu_r]^2 \quad (8)$$

在这里采用 Z-score 作为数据标准化方法, 从而实现了数据的归一化。通过对图像的处理和处理前后各像素值的频数统计, 处理前后的 X 射线影像如图 5 所示, 对应的像素值频数统计如图 6 所示。




图 5 Z-score 图像处理前后对比

由图 5、图 6 可见, Z-score 标准化保证图像信息基本不变。此外, 通过将图像像素值映射回 0~255 可以看到, 经过 Z-score 标准化处理后的数据不像原图中数据几乎完全

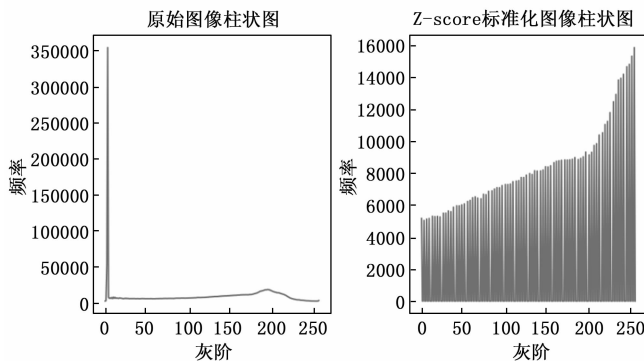


图 6 Z-score 图像处理前后的像素值频数统计图

趋近于 0, 而是会更均匀地分布, 这使得模型训练的效果更好, 也不易受到噪点干扰。

2.3 骨干网络优化

骨干网络 (Backbone Network) 通常由多个堆叠的卷积层组成, 用于逐层提取输入数据的高级特征表示, 是深度学习模型的主要组成部分。

该任务需要实现深度纹理信息的挖掘, 引入更深的网络层次, 带来梯度消失与梯度爆炸问题。ResNet 通过引入残差连接 (Residual Connection), 使得网络能够跳过几个层级的非线性变换, 可有效地缓解该问题。此外, ResNet 的残差连接允许信息直接从前向传播绕过某些层, 在构建较深网络结构的同时减少传播路径的长度。由于梯度可以更容易地传播到早期的层级, 加快了收敛速度, 网络可以更快地进行训练。

文献 [15] 中对常见的 ResNet50、VGG16、EfficientNet 等骨干网络做出了模型参数 (Params) 和计算量 (FLOPs) 的比较, 也对它们在三分类任务下的表现做出评判。综合考量 ResNet50 的高精度表现与低参数量, 对深层信息的挖掘能力更强, 在图像分类问题上具有显著优势, 本文选用了 ResNet50 作为骨干网络, 其网络结构如图 7 所示 [16]。

图 7 中, 卷积块为引入了残差连接结果的卷积层。

为提高 ResNet50 骨干网络在胸腔 X 射线影像分类上的精度, 引入自注意力机制和 CELU 激活函数来进一步提高网络对图像纹理的分析能力。

2.3.1 自注意力机制头

自注意力机制 (SA, self-attention) 是注意力机制的一种改进, 降低了对外部信息的依赖程度, 提高了对数据特征的内部相关性的捕捉能力 [17]。在处理图像问题时, 可以把图像看成输入到模型的很多向量, 这意味着输入样本同时包含了多个元素的信息, 而这些信息之间互为上下文。自注意力机制希望网络不仅仅考虑某一个向量, 而是自己决定感受野的形状和类型。在肺炎图像分类中, 为了让网络可以更加专注地学习感兴趣的区域的特征, 用了自注意力机制的空间注意力, 通过进行上下文感知的整合来捕捉图像中不同位置之间的重要关联信息, 提高分类的准确性。

对于自注意力机制来说, 会有 3 个待训练的参数矩阵:




图 7 ResNet50 的网络结构图

W_q, W_k, W_v , 分别表示查询 (Query) 的权重矩阵, 键 (Key) 的权重矩阵和价值 (Value) 的权重矩阵, 它们分别乘以输入矩阵后得到了 Q, K, V 三个矩阵。将 Query 和每个 Key 进行相似度计算得到权重, 使用一个归一化指数函数 (Softmax) 对这些权重进行归一化, 转换为注意力, 将权重和相应的 Value 进行加权求和得到最后的 Attention, 如式 (9) 所示:

$$Attention(Q, K, V) = Softmax\left(\frac{QK^T}{\sqrt{d_k}}\right)V \quad (9)$$

自注意力机制基于特征图本身的关注而提取的注意力, 其优势就是它的关注是全局的, 它能通过简单的查询与赋值就能获取到特征图的全局空间信息。在 ResNet50 卷积层的第一层和最后一层加入自注意力机制模块后, 可以在不改变原有的网络结构情况下让模型更专注学习感兴趣的区域特征。

2.3.2 CELU 激活函数优化

CELU^[18]采用负数区间为指数计算, 整数区间为线性计算, 这使得在使用 CELU 时, 可以使用任意次数的微分。当 $x < 0$ 时, ReLU 函数的导数为 0, 即 ReLU 在 x 轴右侧饱和^[19], 所以 ReLU 是不连续可微的, 只能使用子导数, 这意味着比起 ReLU, CELU 能够激活更多的神经元, 而 ReLU 可能导致死亡神经元的问题。ReLU 和 CELU 的计算公式如式 (10) (11) 所示, 曲线对照如图 8 所示。

$$ReLU(x) = \max(0, x) \quad (10)$$

$$CELU(x, \alpha) = \max(0, x) + \min\left\{0, \alpha * \left[\exp\left(\frac{x}{\alpha}\right) - 1\right]\right\} \quad (11)$$

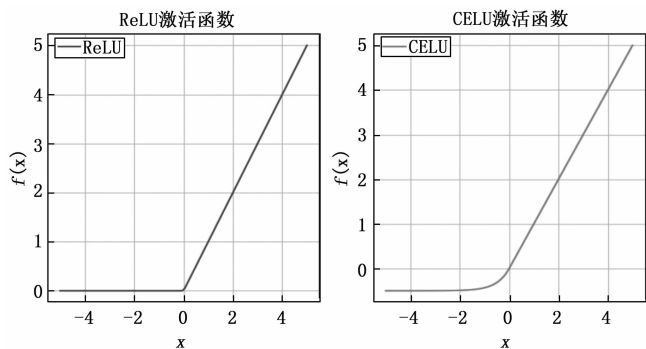


图 8 ReLU 和 CELU 的曲线对照图

本文针对肺部 X 光图像做分类任务, 在肺炎图像分类任务中, 负数特征会更加突出。负数区域的非零输出可能有助于更好地利用网络的容量, 并提升模型的表达能力, 所以选用 CELU 对处理具有较强负数特征的图像有一定的

优势。

3 影像加密与传输策略

为了实现本系统的远程应用和云端部署, 本系统搭载基于 WebSocket 协议的微内核结构部署策略和基于 Logistic 混沌序列图像加密与解密算法来实现目标。

3.1 影像加密策略

文献 [11] 提出了一种基于 Logistic 映射混沌加密的算法, 本系统仿照其思路, 设计一种基于 Logistic 混沌序列图像加密与解密算法, 具体算法如下。

对于密钥获取, 定义初始化参数 u, x_1 。对 u 和 x 通过 Logistic 函数迭代来实现参数的混乱状态。例如在迭代 N 次下, 可以通过式 (12) 得到 x_N :

$$x_N = u \times x_{N-1} \times 1 - x_{N-1}, N > 1 \quad (12)$$

现在, 定义另一个参数 $g(n)$ 来表示密钥。假设图像宽为 W, H , 则有式 (13):

$$g(n) = \begin{cases} u \times g(n-1) * [1 - g(n-1)], & W \times H > n > 1 \\ x_N, & n = 0 \end{cases} \quad (13)$$

将密钥映射回 $0 \sim 255$ 范围内来实现密钥图像的生成, 有式 (14):

$$g'(n) = 255 \times [g(n)] \quad (14)$$

其中: $[g(n)]$ 表示不大于 $g(n)$ 的最大整数。并将 $g'(n)$ 序列整理为 $W \times H$ 的矩阵来对应原图的尺寸。

记原图各像素点为 $r(i, j)$, 加密后图像为 $c(i, j)$, 密钥为 $k(i, j)$, 则加密图像如式 (15):

$$c(i, j) = r(i, j) \oplus k(i, j) + k(W - i, H - j) \quad (15)$$

记解密后图像各像素点为 $q(i, j)$, 解密过程如式 (16) 所示:

$$q(i, j) = [c(i, j) - k(W - i, H - j)] \oplus k(i, j) \quad (16)$$

该算法只需要初始化两个参数 u 与 x_1 , 并设定迭代次数 N , 即可实现大图像的高混乱程度加密, 本系统在此基础上通过翻转密钥的叠加, 再一次提高了加密过程的非线性, 进一步加强了混乱程度与解密难度。本系统选用 $u = 4, x_1 = 0.1, N = 200$, 实现效果如图 9 所示。

可见, 该算法加密混乱程度高, 密钥获取难度高, 密钥保存难度低, 图像还原程度高, 完全符合本系统的高效与安全需求。

3.2 影像加密与传输策略

为了实现本系统在本地或云端的安全、高效部署, 同时打造一个用户友好的 UI 界面, 本文通过以下方案组建服务器传输策略。




图 9 基于 Logistic 混沌序列图像加密与解密算法效果图

3.2.1 base64 编码

Base64^[20]是一种二进制到文本的编码方式，能够解决各系统以及传输协议中二进制不兼容的问题。在传输过程中，将二进制数据安全地表示为 ASCII 字符，以便在各种网络环境以及不同平台中进行传输和存储，使客户端和服务端无需使用额外的传输协议或文件传输方式，并且能够保证数据的完整性和传输的稳定性。

在本系统中，为了实现多种设备的兼容以及保护图像在传输过程中不会产生损坏，同时兼顾传输效率，因此在传输过程中采用了 base64 编码。经实验，胸腔 X 射线图片的平均转 base64 编码时间消耗在 0.001 s 左右，符合系统的实时性要求。

3.2.2 利用 WebSocket 协议的微内核结构

WebSocket 是 HTML5 新提出的一个协议^[21]，它是一种在客户端和服务端之间实现全双工通信的网络协议。WebSocket 建立在 HTTP 协议之上，通过建立一次连接，实现了持久化的双向通信，在较低的延迟下进行高效的数据传输，并且减少了每次传输的网络开销，提高了传输效率，减少了网络带宽的使用，有利于实时传输 X 光图片。

系统的 WebSocket 通信流程如图 10 所示。

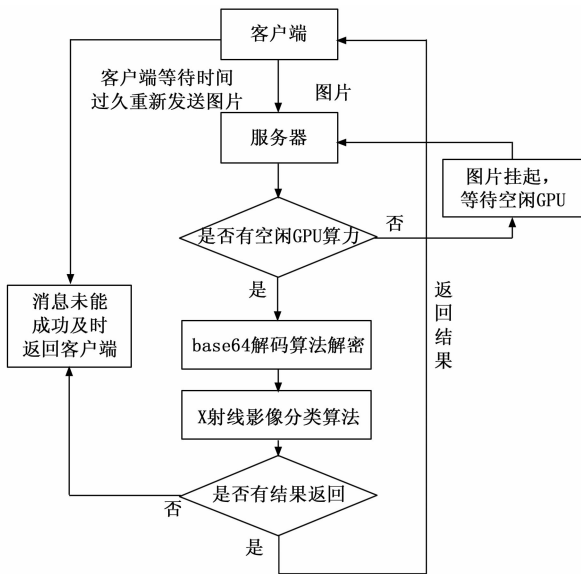


图 10 系统的 WebSocket 通信流程图

4 系统测试结果与分析

4.1 图像增强结果分析

截取出胸腔 X 射线影像中的肺部区域，分别经过直方

图均衡化、自适应直方图均衡化、基于马尔可夫随机场图像增强算法的处理，得到的效果如图 11 所示。




图 11 各图像增强算法在肺部区域的表现效果图

从图 11 可以看出，直方图均值化过滤了背景中的复杂重影，将注意力集中在肺部与肋骨上，但过度的均值化使得一些重要的信息变暗；在自适应直方图中，缓解了局部区域变暗的问题，但整体较原图仍没有太多的纹理信息变化；在基于马尔可夫随机场图像增强算法中，集中关注了图片中的细节纹理，对于轮廓和边缘区域加上了高对比度灰度差，并对冗杂的其他覆盖区域做了模糊处理，更利于深度学习网络对纹理信息的把握。

从主观评价上看，系统采用的基于马尔可夫随机场图像增强改善了模型的学习能力。下面通过量化指标来衡量这些算法的优劣。本文采用文献 [22] 中基于像素边缘均值和局部对比度的细节图像平均对比度来衡量图像中的对比度差异，使用一种简化的平均对比度来衡量所述图像增强算法的差异。

计算图像中的所有像素点周围点的灰度均值，设该点为 (i, j) ，记其灰度值为 $g(i, j)$ ，则灰度均值 $a(i, j)$ 为：

$$a(i, j) = \frac{\sum_{y=j-[A/2]}^{j+[A/2]+1} \sum_{x=i-[A/2]}^{i+[A/2]+1} g(x, y)}{A \times A} \quad (17)$$

其中： A 为可以自定义的所考虑正方形范围的边长， A 越大，则考虑的范围越大， $[A]$ 表示不大于 A 的最小整数。此外，当 (i, j) 位于边缘或该范围包含边缘外的位置时，则认为这些位置上的灰度值为 0，且每有一个外位置，分母上则减 1。

将对比度衡量因子 $C(i, j)$ 用于衡量 (i, j) 点的对比度指标定义为：

$$C(i, j) = \frac{[g(i, j) - a(i, j)]^2}{A \times W \times H} \quad (18)$$

其中: W, H 分别为该图像的宽和高, 该对比度衡量因子描述了该点与周围点灰度均值的差异。为了防止累加后数值过大, 将图像面积也加入分母。

通过累加所有像素点的对比度衡量因子, 可得到整图的平均对比度 T :

$$T = \frac{1}{W \times H} \sum_{y=0}^H \sum_{x=0}^W C(x, y) \quad (19)$$

对 4.1 中所得到的多种结果进行平均对比度以及其他常见评价指标的测算, 得到结果如表 2 所示。

表 2 多种图像增强算法结果的评价指标

算法名称	原图	直方图均衡化	自适应直方图均衡化	基于马尔可夫随机场图像增强算法
平均对比度得分	1.367 13	4.556 62	6.267 97	24.771 48
PSNR	—	27.619 135 74	28.393 165 87	28.455 608 33
MSE	—	109.001 85	91.207 563 89	89.905 572 22
MAE	—	80.667 633 33	96.824 041 67	81.811 572 22

从表 2 可以看出, 平均对比度得分用于衡量图像的对比度, 数值越高表示图像的对比度越强, 特征对比也就越明显; PSNR (Peak Signal-to-Noise Ratio) 为峰值信噪比, 数值越高表示图像重建的质量越好; MSE (Mean Squared Error) 为均方误差; MAE (Mean Absolute Error) 为平均绝对误差, 此二者数值越小表示图像的质量越好。因为 PSNR、MSE、MAE 都是需要对比得到结果的指标, 所以不讨论原图的得分。基于马尔可夫随机场的图像增强预处理结果通过全局对比度衡量因子验证, 其肺部部分截取图像对比度得分有显著提升由 1.367 上涨至 24.771。

可见, 基于马尔可夫随机场图像增强算法极大地提高了图像的对比度, 且在图像的质量上也较其他算法有所提升。综合其对纹理信息的高对比度标注以及冗余覆盖问题的模糊优化, 再次验证了该算法的实用性与高效性。

4.2 影像分类算法实验结果与分析

通过多次优化的模型前后的实验, 以及多个典型分类模型的对比测试, 得到的分类结果如表 3 所示。

表 3 不同分类算法的分类效果比较

分类算法	正确率/%	召回率/%
ResNet50	77.3	43.2
ResNet101	68.9	44.2
MoblieNetv3	50.3	56.5
MRF+ResNet50	77.1	59.3
SA+ResNet50+CELU	74.3	56.8
MRF+SA+ResNet50+CELU(Ours)	76.1	65.2

表 3 中, 各项策略依次为: MRF (基于马尔可夫随机场的图像增强算法)、SA (自注意力机制 Self-Attention)、ResNet50 (残差网络模型)、CELU (激活函数优化)。

MRF 通过建模像素之间的相关性来提升图像的质量,

对图像进行增强, 使得肺部病变的特征更加突出, 由于病变与周围正常组织的灰度值差异较大, MRF 可以通过提高病变区域与周围区域的对比度, 从而使病变更容易被识别和分类。SA 能够在模型中自动学习图像中不同部分的重要性权重, 使得模型能够更加关注重要的特征, 可以帮助模型更加关注病变区域与周围正常组织之间的特征差异, 并对这些特征进行有效地整合和利用, 从而提升分类精度。CELU 能够有效地提高模型的非线性表示能力和鲁棒性, 帮助模型更好地学习和表示图像中的特征, 提高模型对不同病变类型的识别能力和表现效果。在 ResNet50 模型中, 通过 SA 机制与 CELU 激活函数优化, 其肺炎四分类正确率由 77.3% 降至 76.1%, 但召回率由 43.2% 上涨至 65.2%, 在准确率没有降低太多的前提下, 实现了召回率的大幅上升, 增强了系统在实际医疗场景中的应用可能。虽然本文所采用的算法优化策略虽正确率下降 1.2%, 但在召回率上实现了 22% 的上升, 更符合现实医疗落地场景的应用需求。

4.3 模型部署与系统测试

在经过影像预处理、分类模型训练与测试后, 将模型部署在 Window 10 系统上搭载 NVIDIA GeForce RTX 3060 Laptop GPU 与 16 核 AMD Ryzen 7 5800H with Radeon Graphics。通过 Pycharm 编译器与 Python 3.10 语言搭建 WebSocket 服务器; Python3.8 与 PyQt5 搭建 UI 界面。系统的 UI 交互界面设计如图 12、13 所示。

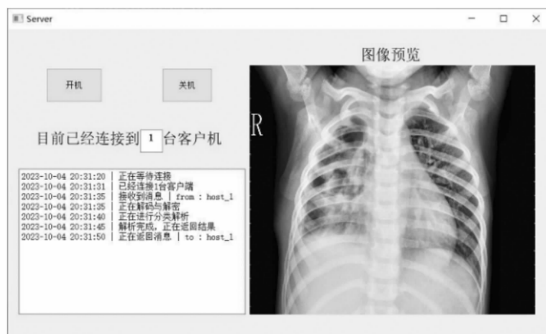


图 12 服务器的交互界面展示

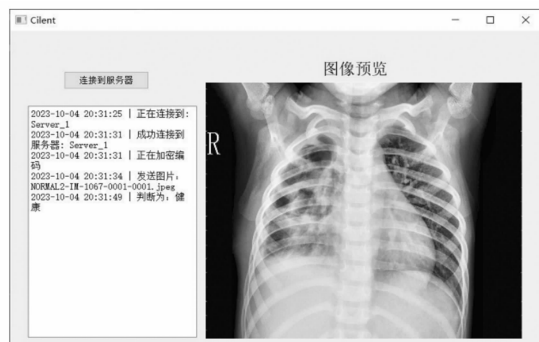


图 13 客户机的交互界面展示

系统的测试步骤如下:

1) 配置 Python 环境与调试。在系统运行前需要先安装 OpenCV 图像处理库、Pytorch 深度学习框架、PyQt5 交互界面设计库、WebSockets 数据传输库以及包含在内的 NumPy、Matplotlib 等数据与图像处理库。调试至胸腔 X 射线图像分类模型可以正常进行, 服务器可以进入等待连接状态。

2) 利用另一台设备连接 WebSocket 端口, 通过将图像传入系统客户端, 检测服务器的接收、解密和模型运行情况。实际测试中, 一百张图片解析与传输的平均时间可以维持在 350 s 左右。测试效果如图 14 所示。

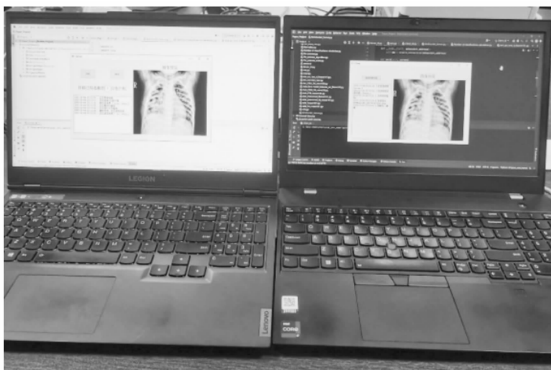


图 14 系统运行效果图

经过测试, 本系统具有高效率、高精度的胸腔 X 射线图像分类算法与高实时性的部署, 符合医疗行业的实际需求, 可有效避免实际应用中出现病例样片外流或盗取的负面影响, 符合软件工程设计需求, 具有较高的应用价值。

5 结束语

本文设计并开发了一种改进残差网络的医学 X 射线影像分类与加密传输系统。为实现医学 X 射线影像的多分类远程自动诊断, 将自注意力机制引入改进的 ResNet50 模型, 利用自注意力机制在模型中自动学习图像中不同部分的重要性权重, 使模型更加关注病变区域与周围正常组织之间的特征差异, 并对这些特征进行有效地整合和利用, 从而提升分类精度。同时加入 MRF 预处理, 能够突出缩小后的肺炎 X 射线图像的重要特征。多次对比实验的结果表明了本文方法在医学 X 射线影像分类上具有较高的准确性和召回率; 通过 Logistic 混沌加密算法与 PyQt5、Python-Websocket 前后端搭建与测试, 展示了部署在服务器上的实时加密传输与分类结果具有良好的有效性和安全性。

系统为大批量高速诊断 X 射线影像处理任务提供一种优化模型结构的方法与思路。在后续工作中, 将进一步添加分类训练数据集, 以改进模型结构提高系统面对复杂 X 射线图像时的鲁棒性, 增强更多疾病的诊断能力。

参考文献:

- [1] 曹春萍, 李哲. 基于 ResNet101 多特征融合的新型冠状病毒感染图像分类方法 [J/OL]. 小型微型计算机系统: 1-7.
- [2] 周涛, 刘赞璨, 侯森宝, 等. REC-ResNet: 面向 COVID-19

- 辅助诊断的特征增强模型 [J]. 光学精密工程, 2023, 31 (14): 2093-2110.
- [3] WANG G, LIU X, SHEN J, et al. A deep-learning pipeline for the diagnosis and discrimination of viral, non-viral and COVID-19 pneumonia from chest X-ray images [J]. Nat. Biomed. Eng., 2021, 5: 509-521.
- [4] 周涛, 叶鑫宇, 陆惠玲, 等. 基于多分辨率注意密集网络的肺炎分类识别方法 [J]. 模式识别与人工智能, 2023, 36 (6): 544-555.
- [5] ESTEVA A, KUPREL B, NOVOA R A, et al. Dermatologist-level classification of skin cancer with deep neural networks [J]. Nature, 2017, 542: 115-118.
- [6] 马圆, 田思佳, 冯巍, 等. 基于肺部 PET/CT 图像不同纹理特征的 K 最近邻分类器 [J]. 北京生物医学工程, 2018, 37 (1): 57-61.
- [7] 刘长征, 相文波. 基于改进卷积神经网络的肺炎影像判别 [J]. 计算机测量与控制, 2017, 25 (4): 185-188.
- [8] 孙利雷, 徐勇. 基于深度学习的乳腺 X 射线影像分类方法研究 [J]. 计算机工程与应用, 2018, 54 (21): 13-19.
- [9] 吴云峰, 吴春敏. 基于 Inception-ResNet 的肺部 CT 图像分类 [J]. 电子技术与软件工程, 2021 (6): 196-197.
- [10] 刘芳. 医学 X 射线图像增强算法研究 [D]. 太原: 中北大学, 2011.
- [11] 贺道翔. 基于 Android 的图片 Logistic 映射混沌加密传输的设计与实现 [J]. 工业控制计算机, 2018, 31 (1): 57-58.
- [12] 刘冰. 基于深度学习的肺部 X-ray 图像分类模型研究 [D]. 西宁: 青海师范大学, 2023.
- [13] 上官泓廷, 刘玉红. 医学图像增强方法综述 [J]. 中国医学物理学杂志, 2023, 40 (4): 410-415.
- [14] 郑玮. 基于模糊马尔科夫随机场的遥感图像分割算法研究 [D]. 成都: 电子科技大学, 2007.
- [15] 宋佳航, 刘静, 王青松, 等. 融合局部与全局特征的肺炎医学影像分类 [J]. 计算机系统应用, 2023, 32 (11): 159-166.
- [16] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition [C] //2016 IEEE Conference on Computer Vision and Pattern Recognition; CVPR 2016, Las Vegas, Nevada, USA, 2016: 770-778.
- [17] 胡艳丽, 童谭骞, 张啸宇, 等. 融入自注意力机制的深度学习情感分析方法 [J]. 计算机科学, 2022, 49 (1): 252-258.
- [18] BARRON J T. Continuously differentiable exponential linear units [J]. ArXiv Preprint ArXiv: 1704.07483, 2017: 1-2.
- [19] 周畅, 米红娟. 深度学习中 3 种常用激活函数的性能对比研究 [J]. 北京电子科技学院学报, 2017, 25 (4): 27-32.
- [20] 陈禹航. 私有 base64 编码转化分析及其 Python 实现 [J]. 电脑与电信, 2022 (12): 87-92.
- [21] PILGRIM M. HTML5: up and running [M]. O' Reilly Media, Inc., 2010: 200-212.
- [22] 段慧东. X 线胸片图像分割、特征提取与分类方法研究 [D]. 沈阳: 东北大学, 2017.