

# 基于 GLCM 和深度神经网络特征融合的小样本肺炎诊断算法

朱晓<sup>1</sup>, 徐静<sup>2</sup>, 李新民<sup>1\*</sup>

<sup>1</sup> 青岛大学数学与统计学院, 山东 青岛

<sup>2</sup> 青岛美迪康数字工程有限公司, 山东 青岛

收稿日期: 2024 年 1 月 26 日; 录用日期: 2024 年 2 月 22 日; 发布日期: 2024 年 2 月 29 日

## 摘要

针对图像分类的各种深度神经网络模型发展迅速,但是在训练样本极少的情况下,深度学习模型普遍无法取得良好的样本外表现。纹理是医学影像中图像识别的关键特征,本文使用灰度共生矩阵(Gray Level Co-Occurrence Matrix, GLCM)提取胸部 X 光片的纹理特征,与预训练的 ResNet50 提取的特征进行融合,最后使用机器学习分类模型对胸部 X 光片进行肺炎识别。在本文的 7 种分类算法下,使用逻辑回归分类取得了最好的结果,该模型仅使用灰度共生矩阵提取的特征的分类准确率为 80%,使用预训练的 ResNet50 提取的特征的分类准确率为 90%,融合特征分类准确率为 92.5%。实验结果显示,与仅使用一种方法提取特征的分类结果相比,融合特征再分类的方法使准确率有明显的提高。

## 关键词

图片分类, 小样本, 灰度共生矩阵, ResNet50

# A Small Sample Pneumonia Diagnosis Algorithm Based on Feature Fusion of GLCM and Deep Neural Network

Xiao Zhu<sup>1</sup>, Jing Xu<sup>2</sup>, Xinmin Li<sup>1\*</sup>

<sup>1</sup>School of Mathematics and Statistics, Qingdao University, Qingdao Shandong

<sup>2</sup>Qingdao Medicon Digital Engineering Co., Ltd., Qingdao Shandong

Received: Jan. 26<sup>th</sup>, 2024; accepted: Feb. 22<sup>nd</sup>, 2024; published: Feb. 29<sup>th</sup>, 2024

\*通讯作者。

文章引用: 朱晓, 徐静, 李新民. 基于 GLCM 和深度神经网络特征融合的小样本肺炎诊断算法[J]. 计算机科学与应用, 2024, 14(2): 489-500. DOI: 10.12677/csa.2024.142049

## Abstract

Various deep neural network models for image classification have developed rapidly, but deep learning models generally cannot achieve good out-of-sample performance with very few training samples. Texture is a key feature of medical images in image recognition, we use GLCM to extract texture features from chest X-rays, which are fused with the features extracted from pre-trained ResNet50. Finally, a machine learning classification model is used to recognize pneumonia from chest X-rays. Among the seven classification algorithms in this article, the best results were achieved using Logistic Regression. The classification accuracy of the model is 80% for features extracted using only the GLCM, 90% for features extracted using pre-trained ResNet50, and 92.5% for fused features. The experimental results show that compared to the classification results using only one method to extract features, the fusion feature re-classification method significantly improves the accuracy.

## Keywords

Image Classification, Small Sample, GLCM, ResNet50

Copyright © 2024 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

肺炎是一种可能由细菌、真菌、病毒等引起的肺部炎症。它是呼吸系统的常见病，多发在老人和儿童等免疫系统差的人群中，病况严重时还有可能危及生命。胸腔 X 射线中肺部出现浸润现象是诊断肺炎的黄金标准，在肺炎高发期，医生工作艰巨繁重，因此计算机辅助诊断成为热点研究问题。

对于胸部 X 光片中肺炎的识别，传统方法在解决分类问题之前首先需要进行特征提取，然后利用分类算法，实现正常图像或是肺炎图像的识别。传统特征提取主要包括颜色、纹理、形状三个方面。对于识别肺炎来说，纹理特征尤其重要。早期纹理特征提取方法包括灰度共生矩阵(GLCM) [1]、局部二元模式(LBP) [2]和方向梯度直方图(HOG) [3]等。Thepade 等[4]通过计算胸部 X 射线图像的 GLCM 来提取统计纹理特征，并考虑不同同步幅组合计算矩阵，最后将 GLCM 特征用于训练机器学习分类器和集成器来识别肺部的 COVID-19 感染。Fernandez-Grandon 等[5]通过提取胸部 X 光片的 GLCM 和 HOG 特征，选择最佳特征并训练支持向量机和多层感知器进行 COVID-19 和肺炎分类，得到支持向量机最大准确率为 93.73%。袁茂洲[6]使用 LBP 算法以及灰度共生矩阵来提取图像只含肺部区域的特征，结合支持向量机对肺部图像进行识别。Häfner 等[7]提出了一种类似于 LBP 的新方法用于描述彩色图像局部纹理属性，再使用 k - 最近邻分类算法对放大内镜图像的特征进行分类，从而识别息肉图像。

作为目前计算机视觉分类的主流研究方法，深度学习方法表现出强大的竞争力。这一系列方法不仅在普通图像的特征提取和分类方面的效果较好，也在医学图像分析中取得了一定的成果。由于医学图像的相似度非常高，所以相比普通图像，医学图像的特征提取难度更大。但是深度神经网络有着强大的自动内部调节参数的能力，通过大型数据集上训练得到的卷积神经网络也能应用到新的领域，而且具有良好的适应性。此外，通过大规模数据集上预先训练的 CNN 模型学习的特征在图像分类任务中非常有用，并成为提升医学图像分类识别效率的突破口。研究证明 ResNet50 在识别肺炎方面具有较大的潜力，Narin

等[8]建立了 5 个基于卷积神经网络的模型,用于胸片检测冠状病毒肺炎患者,预训练的 ResNet50 模型提供了最高的分类性能。Ayan 等[9]提出一种卷积神经网络(CNN)集成方法用于儿童肺炎的自动诊断,使用 7 个预训练的 CNN 模型进行迁移学习,ResNet50 是 3 个最成功的模型之一。金哲毅等[10]使用 ResNet50 作为预训练模型,通过冻结网络层数、数据增强等方式,实现对新冠肺炎 CT 影像分类。莫琦岚等[11]使用 ResNet50 检测新生儿肺炎,在验证集上的准确率达到 91.18%。

近年来,基于小样本的图像分类大多都首先利用数据增强扩充数据,再进行深度学习,这是因为训练深度神经网络往往会受到数据集大小及样本均衡问题的影响。在医学领域,数据的获取是非常困难的,一方面,输入神经网络的图像往往需要标签信息,这需要资深的影像科医生对图像进行标注,标注成本非常高;另一方面,由于医学图像会涉及到病人隐私等问题,图像获取难度比较大。除此之外,训练神经网络对计算机资源的要求较高,普通计算设备并不能完成网络训练。基于上述问题,如何利用小样本图像数据,在节省算力的同时实现肺炎图像的准确分类成为研究重点。

在肺炎识别中,特征是分类的关键,我们可以使用传统方法与神经网络分别提取特征,再进行特征融合的手段对胸片特征进行充分提取,最后使用机器学习分类算法实现肺炎识别。本文工作从特征提取的不同角度出发,结合分类算法研究了小样本情况下胸部 X 光片是否出现肺炎的分类问题。文章内容结构安排如下,第 2 节介绍了灰度共生矩阵以及利用相关统计量作为特征进行肺炎识别的结果,第 3 节介绍 ResNet50 网络结构及利用该网络提取的抽象特征进行肺炎识别的结果,第 4 节给出融合特征在多种机器学习分类算法下的实验结果,最后在第 5 节给出结论。

## 2. 灰度共生矩阵特征

### 2.1. 灰度共生矩阵

灰度共生矩阵(GLCM)的统计方法是 20 世纪 70 年代初由 R. Haralick 等[1]提出。灰度共生矩阵定义为:在一张图片中,从灰度  $i$  的像素点出发,距离为  $(dx, dy)$  的另一个像素点的灰度为  $j$  的概率。其数学表达式为:

$$P(i, j|d, \theta) = \{(x, y) | f(x, y) = i, f(x + dx, y + dy) = j, x, y = 0, 1, \dots, N - 1\},$$

其中,  $d$  是用像素数量表示的相对距离;  $\theta$  一般考虑四个方向,分别为  $0^\circ, 45^\circ, 90^\circ, 135^\circ$ ;  $\{\}$  表示集合,  $i, j = 0, 1, 2, \dots, L - 1$ ,  $L$  为图像灰度级;  $(x, y)$  为图像中的像素坐标。




Figure 1. Geometric expression of GLCM  
图 1. 灰度共生矩阵几何表达

如图 1 所示:  $x$  方向是图像的列,  $y$  方向是图像的行,  $f(x, y) = i$  为坐标  $(x, y)$  处的像素值, 我们需要统计的是距离  $(dx, dy)$  处  $f(x + dx, y + dy) = j$  的次数, 由于  $(dx, dy)$  的选择不同, 则会导致角度的不同, 一

般会选择  $0^\circ$ ,  $45^\circ$ ,  $90^\circ$ ,  $135^\circ$ , 并且方向是双向的。

由于灰度共生矩阵的维度较大, 一般不会直接作为区分纹理的特征, 而是基于它构建一些统计量作为纹理分类特征。在这里使用到如下六个统计量:

### 1) 对比度(Contrast)

$$\text{Contrast} = \sum_i \sum_j (i - j)^2 P(i, j)。$$

对比度直接反映了某个像素值及其领域像素值亮度的对比情况, 即图像的清晰度和纹理沟纹深浅的程度。如果灰度共生矩阵偏离对角线的元素有较大值, 即灰度差大的像素对越多, 说明图像亮度值变化很快, 则 Contrast 会有较大取值。具体地, 纹理沟纹越深, 其对比度越大, 视觉效果越清晰; 反之, 对比度小, 则沟纹浅, 效果模糊。

### 2) 相异性(Dissimilarity)

$$\text{Dissimilarity} = \sum_i \sum_j |i - j| P(i, j)。$$

计算对比度时, 权重随矩阵元素与对角线的距离以指数方式增长, 如果改为线性增长, 则得到相异性。

### 3) 角二阶矩(Angular Second Moment, ASM)

$$\text{ASM} = \sum_i \sum_j P(i, j)^2。$$

角二阶矩即为灰度共生矩阵元素的平方和, 反映了图像灰度分布均匀程度和纹理粗细度。当图像纹理比较规则时, 灰度共生矩阵的值集中在某一块(例如, 连续灰度值图像, 值集中在对角线附近; 结构化的图像, 值集中在偏离对角线的位置), 此时 ASM 有较大值, 若灰度共生矩阵中的值分布较均匀(如噪声严重的图像), 则 ASM 有较小的值。

### 4) 能量(Energy)

$$\text{Energy} = \sqrt{\text{ASM}}。$$

### 5) 自相关(Correlation)

$$\text{Correlation} = \frac{\sum_i \sum_j \left( P(i, j)^2 (i - \text{Mean})(j - \text{Mean}) \right)}{\text{Variance}}。$$

其中,  $\text{Mean} = \sum_i \sum_j (iP(i, j)) / L^2$ ,  $\text{Variance} = \sum_i \sum_j (i - \text{Mean})^2 P(i, j)$ 。

自相关反应了图像纹理的一致性。如果图像中有水平方向纹理, 则水平方向矩阵的 Correlation 大于其余矩阵的 Correlation 值。它度量空间灰度共生矩阵元素在行或列方向上的相似程度, 因此, 相关值大小反映了图像中局部灰度相关性。当矩阵元素值均匀相等时, 相关值就大; 相反, 如果矩阵元素值相差很大, 则相关值小。

### 6) 逆方差(Homogeneity)

$$\text{Homogeneity} = \sum_i \sum_j P(i, j) / \left( 1 + (i - j)^2 \right)。$$

逆方差反映了图像纹理局部变化的大小, 若图像纹理的不同区域间较均匀, 变化缓慢, 逆方差会较大, 反之非均匀图像的逆方差值较小。与对比度相反, 逆方差的权重随着元素值与对角线的距离变大而减小, 并且是以指数形式减小。

## 2.2. 分类结果

本文图片来自 kaggle 网站的一个数据集，其中包括正常肺图片和肺炎图像两类。随机选择正常肺图片和肺炎图像各 100 张，按照 8:2 划分为训练集和测试集，即训练集 160 张，测试集 40 张，并将不同尺寸的图片缩放至  $256 \times 256$ 。以下实验使用相同的训练集与测试集。

首先对缩放至  $256 \times 256$  的图片使用 Skimage Feature 中的 Graycomatrix 函数，在距离为 2 的情况下，计算  $0^\circ$ ， $45^\circ$ ， $90^\circ$ ， $135^\circ$  四个方向上的灰度共生矩阵，再利用 Graycoprops 函数，计算对比度(Contrast)、相异性(Dissimilarity)、角二阶矩(Angular Second Moment, ASM)、能量(Energy)、自相关(Correlation)、逆方差(Homogeneity)六个统计量。最终每张图片统计量的结果取四个方向上的平均值，由此根据灰度共生矩阵得到每张图片关于纹理的六个特征。在这里，我们不关心特征之间的共线性，只关心所有特征的预测结果。基于上述提取的特征，使用 KNN、逻辑回归、决策树、支持向量机、随机森林、XGBoost、LightGBM 分类模型进行训练和测试，实验结果如表 1 所示。

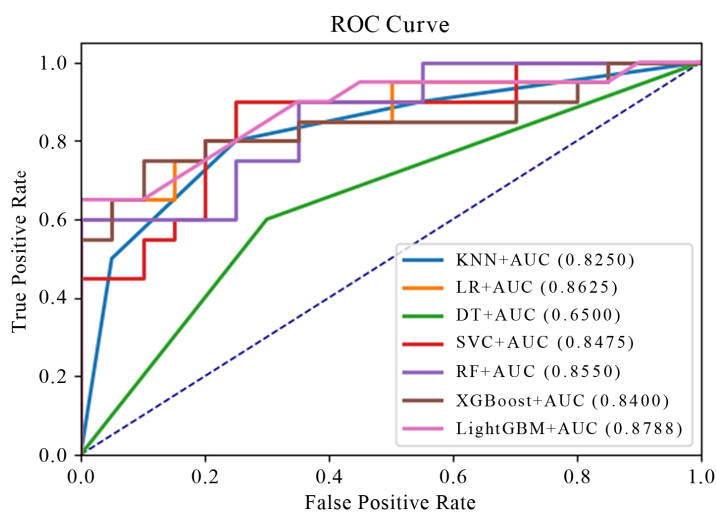


Figure 2. ROC curve under features extracted using GLCM

图 2. 灰度共生矩阵提取特征下的 ROC 曲线




Figure 3. P-R curve under features extracted using GLCM

图 3. 灰度共生矩阵提取特征下的 P-R 曲线

**Table 1.** Classification results of features extracted using GLCM**表 1.** 灰度共生矩阵提取的特征分类结果

	KNN	逻辑回归	决策树	支持向量机	随机森林	XGBoost	LightGBM
ACC	0.750	0.800	0.625	0.800	0.700	0.775	0.775
P	0.813	0.833	0.632	0.800	0.722	0.789	0.824
R	0.650	0.750	0.600	0.800	0.650	0.750	0.700
F1	0.722	0.789	0.615	0.800	0.684	0.769	0.757

注: ACC 表示准确率(accuracy), P 表示精确率(precision), R 表示召回率(recall), F1 表示 F1 分数(F1 score), P、R、F1 均是肺炎图像为正例情况下的结果。

从表 1 中可以看到, 在仅使用灰度共生矩阵提取特征的情况下, 使用逻辑回归和支持向量机分类在七种算法中取得了最高的准确率, 结果为 80%。

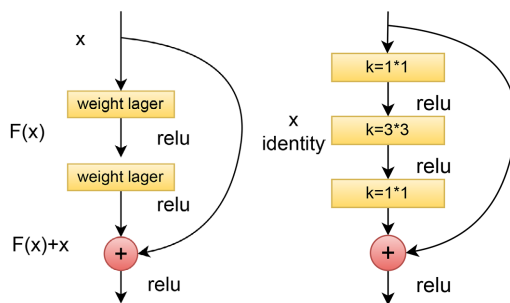
准确率虽然最直观, 但存在明显的缺陷。ROC 曲线(Receiver Operating Characteristic Curve)能够更清晰地描述分类器的性能, 它显示了在不同阈值下分类器的真阳性率(True Positive Rate, TPR)和假阳性率(False Positive Rate, FPR)之间的关系。图 2 为灰度共生矩阵提取特征下的 ROC 曲线, 其中 ROC 曲线的横坐标为 FPR, 在本文中表示正常图片中被判定为肺炎图像的比例; 纵坐标为 TPR, 表示所有肺炎图像中被识别出来的比例。

由图 2 中可以看出, ROC 曲线中的线均高于对角线, 它们交叉在一起, 不能很好的判断分类器的性能, 但是从 AUC 结果上可以看出, LightGBM 模型的 AUC 最大, 据此判断其分类性能最好。图 3 为灰度共生矩阵提取特征下的 P-R 曲线, 可以用于寻找分类器在精确率与召回率之间的权衡。由图 3 可以看出, 召回率在 0.9 以上时, LightGBM 模型在精确率上的表现都优于其他模型。

### 3. ResNet50 特征

#### 3.1. ResNet50 网络结构

ResNet [12]通过引入残差学习框架来解决深度神经网络训练退化的问题, 残差学习模块如图 4 所示。假设最初期望拟合映射为  $H(x)$ , 那么想让这些新加的层去拟合另外一个映射, 此映射可以表示为  $F(x) = H(x) - x$ , 那么最初期望拟合的映射  $H(x) = F(x) + x$ 。这种残差映射相对于原始的映射是更容易进行优化的, 让残差变为 0 要容易的多。

**Figure 4.** Residual block**图 4.** 残差学习模块

ResNet 提出了五个不同深度的模型分别为 ResNet18、ResNet34、ResNet50、ResNet101、ResNet152。在本文中我们选择 ResNet50 作为特征提取器, 图 5 为 ResNet50 网络结构。

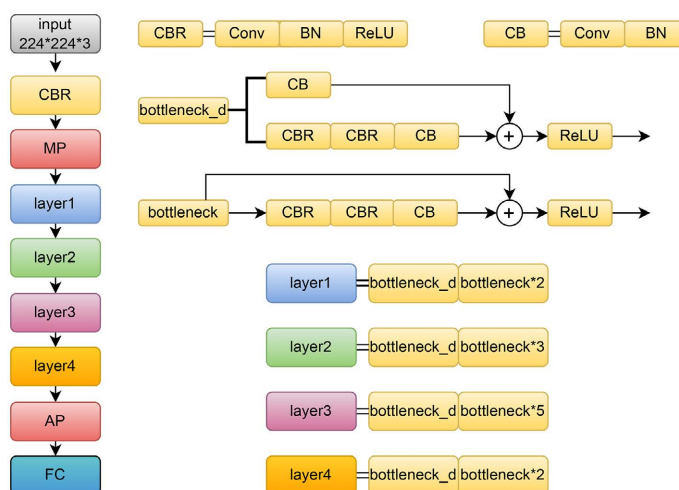


Figure 5. ResNet50 network structure

图 5. ResNet50 网络结构

ResNet50 输入维度是  $224 \times 224 \times 3$ ，即尺寸为  $224 \times 224$  的三通道图片。首先是 layer0，这部分在各个网络中都相同，由一个  $7 \times 7$ ，步长为 2 的卷积层、批归一化层(Batch Normalization, 简记为 BN)、ReLU 激活函数和  $3 \times 3$ ，步长为 2 的最大值池化层组成，在图 5 ResNet50 网络结构中表示为 CBR 和 MP (Maximum pooling)。layer0 输出大小为  $56 \times 56 \times 64$  的特征图。

其次依顺序是 layer1、layer2、layer3、layer4，分别由 3，4，6，3 个 bottleneck (即残差模块)构成，bottleneck 如图 2 所示。略有差异的是，layer1 第一个 bottleneck 的恒等连接通过 CB 结构改变通道数；layer2、layer3、layer4 第一个 bottleneck 的恒等连接通过 CB 结构改变通道数并进行下采样操作。最终 layer4 输出  $7 \times 7 \times 2048$  的特征图。

接着是平均池化层(Average Pooling, AP)，最后是全连接层输出维度为 1000，本文在使用预训练的 ResNet50 提取特征时将全连接层的输出改为 2048 维。

### 3.2. 分类结果

由于胸部 X 光片特征差异小，使用灰度共生矩阵方法提取特征数量较少，而通过大规模数据集上预先训练的 CNN 模型学习的特征在图像分类任务中非常有用，因而以此为突破口，选取预先训练的 ResNet50 作为特征提取器，并修改最后的全连接层，对每张图片输出一个 2048 维的特征向量。我们使用文献[13]中提出的类激活映射(Class Activation Mapping, CAM)技术，将使用预先训练的 ResNet50 提取到的特征图可视化，如图 6 所示。



Figure 6. ResNet50 class activation mapping

图 6. ResNet50 热力图

从图 6 中可以看到, 预训练的 ResNet50 特征提取在原图中虽然有少量关注点在颈部, 但是可以看出主要关注点在肺部区域, 能够比较充分的提取到肺部的细微特征。由于提取特征数量太多, 会因为特征维数大使模型无法训练或者效果不好, 所以使用 lasso 方法对特征进行筛选, 最终筛选得到 124 个特征。利用提取的 124 个抽象特征结合上述机器学习分类算法进行图片分类, 结果如表 2 所示。




Figure 7. ROC curve under features extracted from ResNet50

图 7. ResNet50 提取特征下的 ROC 曲线




Figure 8. P-R curve under features extracted from ResNet50

图 8. ResNet50 提取特征下的 P-R 曲线

从表 2 中可以看到, 在仅使用预训练 ResNet50 提取特征的情况下, 使用逻辑回归分类器在七种算法中取得了最高的准确率, 结果为 90%。图 7 为 ResNet50 提取特征下的 ROC 曲线, 由图 7 ROC 曲线中可以看出, 相比其余五种模型, 表示决策树模型和 LightGBM 模型的曲线偏离对角线程度较小, 曲线下的面积(即 AUC)较小, 分类效果较差; 图 8 为 ResNet50 提取特征下的 P-R 曲线, 在图 8 P-R 曲线中可以看到上述两种模型在精确率和召回率上的表现也较差。结合准确率和 AUC 结果可以判断逻辑回归模型在七



种分类器中的性能最好。

**Table 2.** Classification results of features extracted using pre trained ResNet50

**表 2.** 预训练 ResNet50 提取的特征分类结果

	KNN	逻辑回归	决策树	支持向量机	随机森林	XGBoost	LightGBM
ACC	0.850	0.900	0.625	0.850	0.850	0.850	0.725
P	0.850	0.900	0.632	0.818	0.889	0.889	0.696
R	0.850	0.900	0.600	0.900	0.800	0.800	0.800
F1	0.850	0.900	0.615	0.857	0.842	0.842	0.744

## 4. 基于融合特征的小样本肺炎图像分类

### 4.1. 评价指标


为了验证提出的特征融合方法对于小样本肺炎图像分类的效果，我们使用准确率、精确率、召回率、F1 分数对结果进行测评，其公式如下。

$$\text{accuracy} = \frac{TP + TN}{TP + FP + TN + FN}, \quad \text{precision} = \frac{TP}{TP + FP}, \quad \text{recall} = \frac{TP}{TP + FN}, \quad f1 = 2 \frac{\text{precision} \times \text{recall}}{\text{precision} + \text{recall}}.$$

其中，TP (True Positive)表示预测正确的正样本的数量；FP (False Positive)表示真实为负样本，被错误预测成正样本的数量；TN (True Negative)表示预测正确的负样本的数量；FN (False Positive)表示真实为正样本，被错误预测成负样本的数量，在这里，肺炎图像为正样本，正常图片为负样本。

### 4.2. 分类结果

将使用预训练的 ResNet50 提取的 124 个特征与灰度共生矩阵得到的 6 个特征统计量合并，得到肺炎分类的 130 个特征。再使用上述相同分类算法进行训练和测试，实验结果如表 3 所示。



**Figure 9.** ROC curve under fused features

**图 9.** 融合特征下的 ROC 曲线

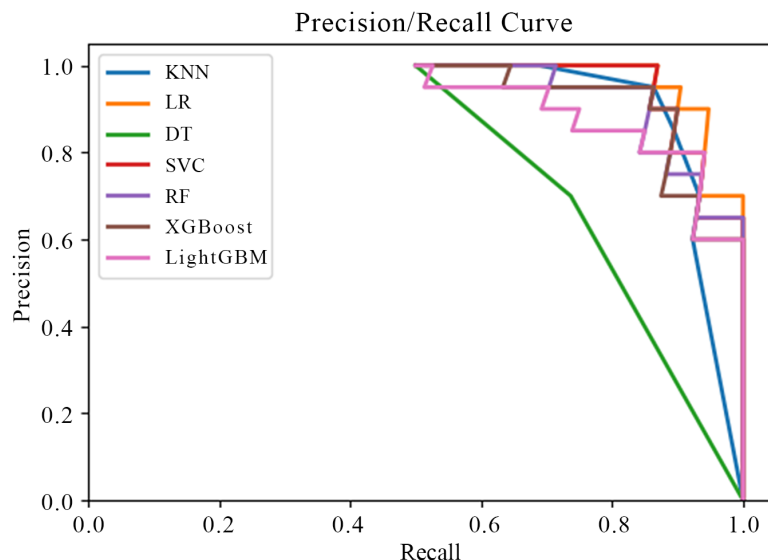


Figure 10. P-R curve under fused features

图 10. 融合特征下的 P-R 曲线

Table 3. Classification results using fused features

表 3. 融合特征的分类结果

	KNN	逻辑回归	决策树	支持向量机	随机森林	XGBoost	LightGBM
ACC	0.875	0.925	0.725	0.875	0.850	0.850	0.825
P	0.895	0.947	0.737	0.895	0.889	0.889	0.933
R	0.850	0.900	0.700	0.850	0.800	0.800	0.700
F1	0.872	0.923	0.718	0.872	0.842	0.842	0.800

从表 3 中可以看到, 在融合灰度共生矩阵提取的特征与预训练的 ResNet50 提取的特征的情况下, 使用逻辑回归分类在七种算法中取得了最高的准确率, 结果为 92.5%, 与仅使用灰度共生矩阵提取的特征相比, 准确率提高了 12.5%; 与仅使用预训练的 ResNet50 提取的特征相比, 准确率提高了 2.5%。另外, KNN、决策树、支持向量机、LightGBM 在融合特征下的准确率相对于单独使用一种特征提取方法的结果都有明显的提高。我们也可以从精确率(precision), 召回率(recall), F1 分数(F1 score)三个指标看出, 在融合特征下使用逻辑回归分类器比其他分类器更有优势, 使用融合特征后分类效果明显改善。该结果可以从 ROC 曲线和 P-R 曲线中得到验证:

图 9 为融合特征下的 ROC 曲线, 从图 9 中可以清晰地看到在七种分类器下, 橙线偏离对角线的程度最大, 其代表的逻辑回归模型的 AUC 在七种分类器下达到最大值 0.9775; 图 10 为融合特征下的 P-R 曲线, 从图 10 中也能够看出橙色曲线将其他曲线完全包住, 逻辑回归模型的分类性能最优。

仅使用灰度共生矩阵提取的特征数量较少, 对胸部 X 光片肺部区域的特征提取不够充分; 而仅使用 ResNet50 提取的是抽象特征, 虽然特征数量较多, 但是缺少具体可描述性特征, 二者都存在特征不充分的问题。实验证明融合特征表现出较好的结果。图 11 为本文提出的肺炎诊断算法。肺炎图像经过灰度共生矩阵提取可描述的六个统计纹理特征, 同时输入预训练的 ResNet50 提取图像中肺部区域的细微特征, 并使用 lasso 方法对高维抽象特征进行降维, 然后进行特征融合, 最后基于融合特征使用逻辑回归分类器进行分类, 提出的算法对小样本的分类效果较好。

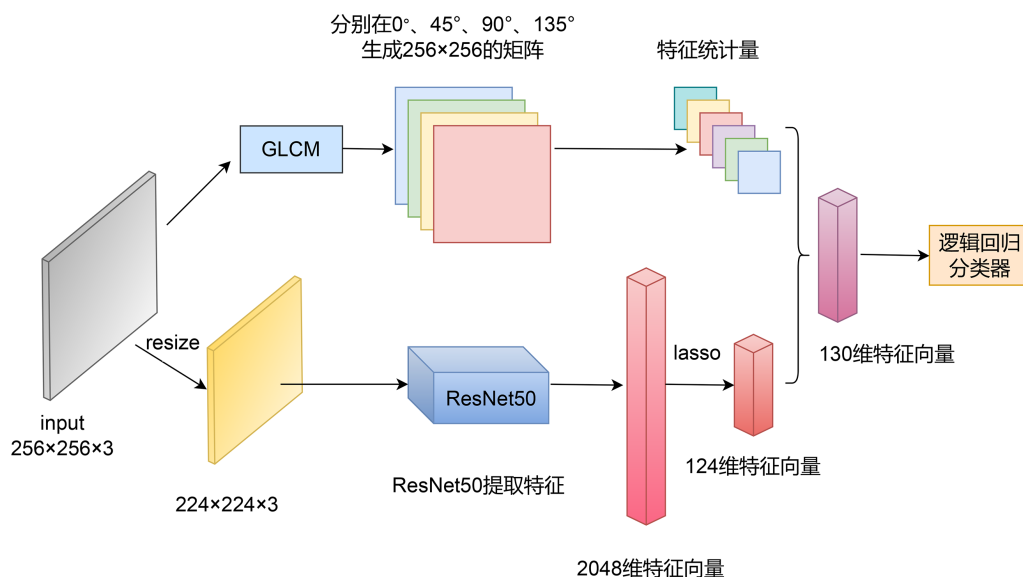


Figure 11. Pneumonia diagnosis algorithm

图 11. 肺炎诊断算法

## 5. 结论

医学影像数据集获取难度大，深度学习模型要求海量的数据且计算成本非常高。本文提出了一种基于灰度共生矩阵和深度神经网络特征融合的小样本肺炎诊断算法。根据本文的实验结果，融合灰度共生矩阵提取的特征与 ResNet50 提取的特征再进行图片分类有较高的准确率。在逻辑回归模型中，使用这种融合特征的分类准确率达到 92.5%，AUC 值为 0.9775，与仅使用灰度共生矩阵提取特征相比，准确率提高了 12.5%，AUC 提高了 0.115；与仅使用预训练的 ResNet50 提取的特征相比，准确率提高了 2.5%，AUC 提高了 0.015。在实际中 ResNet50 也可以替换为其他深度神经网络的特征提取，比如 VGG [14]、clip [15] 的 Image Encoder 等结构。本文方法既避免了深度学习模型对海量数据和计算机算力的要求，又能够打破传统方法提取特征不充分的局限。在实际应用中，在小样本图像分类问题上，这种传统方法与深度学习相结合的模式仍有进一步探究的意义，也将应用于更多计算机视觉问题。

## 参考文献

- [1] Haralick, R.M., Shanmugam, K. and Dinstein, I.H. (1973) Textural Features for Image Classification. *IEEE Transactions on Systems, Man, and Cybernetics*, **SMC-3**, 610-621. <https://doi.org/10.1109/TSMC.1973.4309314>
- [2] Ojala, T., Pietikainen, M. and Maenpaa, T. (2002) Multiresolution Gray-Scale and Rotation Invariant Texture Classification with Local Binary Patterns. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, **24**, 971-987. <https://doi.org/10.1109/TPAMI.2002.1017623>
- [3] Dalal, N. and Triggs, B. (2005) Histograms of Oriented Gradients for Human Detection. 2005 *IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'05)*, Vol. 1, 886-893. <https://doi.org/10.1109/CVPR.2005.177>
- [4] Thepade, S.D., Bang, S.V., Chaudhari, P.R. and Dindorkar, M.R. (2020) Covid19 Identification from Chest X-Ray Images Using Machine Learning Classifiers with GLCM Features. *ELCVIA Electronic Letters on Computer Vision and Image Analysis*, **19**, 85-97. <https://doi.org/10.5565/rev/elcvia.1277>
- [5] Fernandez-Grandon, C., Soto, I., Zabala-Blanco, D., Alavia, W. and Garcia, V. (2021) SVM and ANN Classification Using GLCM and HOG Features for COVID-19 and Pneumonia Detection from Chest X-Rays. 2021 *3rd South American Colloquium on Visible Light Communications (SACVLC)*, 11-12 November 2021, 1-6. <https://doi.org/10.1109/SACVLC53127.2021.9652248>
- [6] 袁茂洲. X 线肺部图像的特征提取与分类方法研究[D]: [硕士学位论文]. 大连: 大连理工大学, 2019.

- 
- [7] Häfner, M., Liedlgruber, M., Uhl, A., Vécsei, A. and Wrba, F. (2012) Color Treatment in Endoscopic Image Classification Using Multi-Scale Local Color Vector Patterns. *Medical Image Analysis*, **16**, 75-86. <https://doi.org/10.1016/j.media.2011.05.006>
- [8] Narin, A., Kaya, C. and Pamuk, Z. (2021) Automatic Detection of Coronavirus Disease (Covid-19) Using X-Ray Images and Deep Convolutional Neural Networks. *Pattern Analysis and Applications*, **24**, 1207-1220. <https://doi.org/10.1007/s10044-021-00984-y>
- [9] Ayan, E., Karabulut, B. and Ünver, H.M. (2022) Diagnosis of Pediatric Pneumonia with Ensemble of Deep Convolutional Neural Networks in Chest X-Ray Images. *Arabian Journal for Science and Engineering*, **47**, 1-17. <https://doi.org/10.1007/s13369-021-06127-z>
- [10] 金哲毅, 杨晓玲. 基于深度残差网络的新冠肺炎 CT 影像分类系统[J]. 信息技术与信息化, 2021(10): 114-116.
- [11] 莫琦岚, 张水兴. 深度学习在 X 线诊断新生儿肺炎中的应用[J]. 暨南大学学报(自然科学与医学版), 2022, 43(2): 199-204.
- [12] He, K., Zhang, X., Ren, S. and Sun, J. (2016) Deep Residual Learning for Image Recognition. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, Las Vegas, 27-30 June 2016, 770-778. <https://doi.org/10.1109/CVPR.2016.90>
- [13] Zhou, B., Khosla, A., Lapedriza, A., Oliva, A. and Torralba, A. (2016) Learning Deep Features for Discriminative Localization. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, Las Vegas, 27-30 June 2016, 2921-2929. <https://doi.org/10.1109/CVPR.2016.319>
- [14] Simonyan, K. and Zisserman, A. (2014) Very Deep Convolutional Networks for Large-Scale Image Recognition.
- [15] Radford, A., Kim, J.W., et al. (2021) Learning Transferable Visual Models from Natural Language Supervision. *International Conference on Machine Learning*, 18-24 July 2021, 8748-8763. <http://proceedings.mlr.press/v139/radford21a/radford21a.pdf>