

基于混合 CNN-LSTM 模型的肺癌分割与分类

林明礼

重庆理工大学计算机科学与工程学院, 重庆 400054, 中国

摘要: 癌症是一种致命疾病, 由一系列遗传紊乱与多种代谢异常共同引起。肺癌与结肠癌被认为是导致人群死亡与病残的主要原因。在选择最佳治疗方案时, 对这类肿瘤的诊断通常是最重要的考量。本研究的主要目标是对肺癌及其严重程度进行分类, 并识别恶性肺结节; 所提出的方法还对肺癌的分期进行分类, 以便识别肺结节。本文用卷积神经网络 (CNN) 检测肺结节, 实现结节的准确分割与分类。所提出的方法分为两部分: 首先区分正常与异常, 其次对肺癌的不同分期进行分类; 在分类阶段提取基于纹理与灰度的特征。与嵌套长短期记忆网络 (LSTM)+CNN 等其他方法相比, 混合 CNN-LSTM 在准确率 (99.35%)、特异度 (99.30%)、灵敏度 (99.32%) 与 F1 分数 (99.29%) 方面均取得更优的结果。

关键词: 计算机断层扫描; 卷积神经网络; 肺癌; 结节; 分割

Lung Cancer Segmentation and Classification Using Hybrid CNN-LSTM Model

MingLi Lin

School of Computer Science and Engineering, Chongqing University of Technology, Chongqing 400054, China

Abstract: A collection of genetic disorders and various types of abnormalities in the metabolism lead to cancer, a fatal disease. Lung and colon cancer are found to be main causes of death and infirmity in people. When choosing the best course of treatment, the diagnosis of these tumors is usually the most important consideration. This study's main objectives are to classify lung cancer and its severity, as well as to recognize malignant lung nodules. The suggested approach additionally classifies the stages of lung cancer in order to recognize lung nodules. The convolutional neural network (CNN) is used to detect lung nodules, identifying a nodule which is accurately segmented and classified. The suggested method is separated into dual parts: primarily, it classifies normal and abnormal behavior, and the subsequent one classifies the different stages of lung cancer. Texture and intensity-based features are extracted during the classification stage. When compared to other methods such as nested long short-term memory (LSTM)+CNN, the hybrid CNN-LSTM obtains superior outcomes in terms of accuracy (99.35%), specificity (99.30%), sensitivity (99.32%), and F1-score (99.29%).

Keywords: Computed tomography; Convolutional neural network; Lung cancer; Nodules; Segmentation

一、引言

生化与遗传疾病中多种异常的共同作用引发了危险的肺癌与结肠疾病。要准确地对医学图像进行分割与归

类,理解疾病的本质十分困难 [1]。计算机断层扫描 (CT) 与磁共振 (MR) 图像的自动分割日益普及 [2]。肺癌是一种极其危险的疾病,会导致死亡且预后不佳 [3]。肺癌早期检测阶段可采用多种手段,包括 CT 扫描、磁共振成像 (MRI) 与 X 射线 [4]。卷积神经网络 (CNN) 算法已被证明在提高灵敏度、降低假阳性检出率方面更为高效 [5]。肺癌是肺部细胞的失控增殖,还会引起呼吸困难。非小细胞肺癌与小细胞肺癌是该疾病的几种主要类型。早期发现肺癌对降低死亡率至关重要 [6]。机器学习 (ML) 分类器可从全切片图像 (WSI) 中自动提取图像特征,用以推断肺癌患者的诊断结果,助力精准肿瘤学 [7]。基于深度学习 (DL) 的方法在图像检测、分割与分类方面取得了先进成果 [8]。CT 扫描与正电子发射断层扫描 (PET) 图像是在癌变过程中识别肺组织区域的最佳方式。精细化的模型可解决并改进肺癌检测的整个流程。有研究采用多层亮度保持方法反复分析目标 CT 肺部图像,以提升肺部图像质量。

在分割与检测方面,高效的低层矢量量化 (VQ) 被用于检测肺内的初始结节候选 (INC),与现有方法相比计算效率更高。为降低假阳性 (FP) 率,基于特征的支持向量机 (SVM) 与基于规则的滤波相结合。MediNet 是一个仅包含医学图像、面向迁移学习 (TL) 应用的视觉数据集:对于新冠肺炎、糖尿病视网膜病变与胸部数据集,所有学习算法迁移均采用微调方式重新训练,随后利用特征集与权重向量检测疾病。为准确区分结肠癌与肺癌,需要向算法提供包含所有可能癌症情形的大规模数据;为提升癌症分类效率,研究者采用了集成方法。PRIYA 与 VENKATESAN 把双树 M 带小波变换 (DTWT) 应用于 CT 图像,在高频与低频两端产生子带系数,随后把低频分量置零;该方法借助 SVM 取得了更高的预测准确率,从而改善了系统性能,再用高频分量完成重建。遗憾的是,该流程用 SVM 分类器错误地归类了一幅异常图像。MANICKAVASAGAM 与 SELVAN 用朴素贝叶斯结合布谷鸟搜索优化来提升肺癌检测的灵敏度与准确率,其优点是无需大规模试验数据即可获得较好结果与高效训练;但该方法降低了结节识别的灵敏度,使结果变差。

REIS 等实现了 MediNet 与 RdiNet,其中包含称为 MediNet 的 10 类新视觉数据集;RdiNet 深度学习算法被实现并用于 TL 应用中的预训练与分类。所实现的 MediNet 方法在数据集较小的情况下取得了良好结果,并表明在医学领域应用 TL 技术可获得更优结果。为提高 TL 方法的成功率,MediNet 的十个类别与较小的数据样本量都应扩充。TALUKDER 等采用混合分组特征提取方法成功识别了肺癌与结肠癌。CIVIT-MASOT 等开发了用于肺癌诊断的 CNN,加入不同策略会带来有效分类结果的差异;该方法在降低精确率、灵敏度与准确率的同时提高了假阴性。从上述文献综述看,总体局限在于:所引论文使用 SVM 分类器时错误识别了异常图像,布谷鸟搜索优化降低了结节识别的灵敏度;MediNet 所用数据量较小,且单一特征提取器无法给出稳定一致的结果。为克服这些问题,需要一种能把分类成功率提升至 TL 水平的组合策略。本文指出了单一特征提取导致结果一致性不足的局限:既有方法适于对一幅异常图像分类,却降低了结节识别的灵敏度,减小了精确率与灵敏度,同时提高了假阴性。为减少这些局限,本文用新模型来获得良好的分类结果、提升灵敏度与精确率,并在后续工作中降低假阴性。本文的贡献如下:(1) 引入混合 CNN-LSTM 网络,辅助对肺癌患者的自动初筛;(2) 用受试者工作特征 (ROC) 衡量所用技术的性能,并从各项性能指标出发对研究结果作全面评估。

本文结构如下:第二部分说明所提出的方法;第三部分介绍 CNN 与长短期记忆网络 (LSTM) 的处理过程;第四部分给出结果与讨论;第五部分为结论。

二、所提出的方法

肺部疾病的分类及其总体结构如图 1 所示。在所提出的方法中,本文利用肺组织病理数据库与 LC25000 结肠图像数据库,采用特征提取技术与 ML 模型预测肺癌与结肠癌。为改进对指定查询图像的分割与分类,本文

引入所提出的方法，该方法在本装置中展现出最高的灵敏度、准确率、特异度与 F1 分数。所开发系统的理想框图见图 1。

为识别肺癌，所提出的方法包含较多分类环节，如预处理、特征提取、输入 ML、TL、性能评估以及用于基于查询图像进行肺癌分类的高性能滤波器。准确率、特异度与 F1 分数等指标被用于评估 CNN-LSTM 的性能。




Figure 1 Block Diagram for Developed System

图 1 所开发系统的框图

(一) 数据集

本文使用肺癌与结肠的组织病理 (LC25000) 图像数据集对查询图像进行分类，两个数据集共有 25 000 幅图像，其中 15 000 幅来自肺癌数据集、10 000 幅来自结肠癌数据集。肺癌细胞标签有 3 类，即腺癌、良性组织与鳞状细胞癌；结肠细胞标签有 2 类，即良性组织与腺癌。最初有 750 幅肺组织图像，其中鳞状细胞癌 250 幅、腺癌 250 幅、良性 250 幅，这些样本图像经增强后产生 25 000 幅图像。LC25000 数据集为经确认的参考样本且符合 HIPAA 规定。在本系统中，从结肠与肺癌共 25 000 幅图像中仅取 10 000 幅用于肺癌疾病的分类与预测；在这 10 000 幅图像中，肺与结肠组合的图像分别为 4 200 幅与 2 800 幅，另有 5 000 幅为结肠组织图像。

(二) 数据集预处理

对数据集中的图像进行预处理可使其比原图更明亮、更清晰、细节更丰富，从而更适于送入模型并获得更高的图像处理性能。在卷积核矩阵中，卷积滤波器给出每个像素邻域的加权平均；不同的核形状与尺寸会产生

不同的视觉效果。卷积运算的数学表达如下。

设 $I = I(i, j)$, $i = 1, \dots, N$, $j = 1, \dots, M$ 为一幅灰度图像; 卷积核矩阵记为 $M = M(k, l)$, $k = 1, \dots, p$, $l = 1, \dots, q$, 其中 n 与 m 取非负整数, $p = 2n + 1$, $q = 2m + 1$ 。把卷积核 M 作用于查询图像 I , 得到结果 $I' = I'(i, j)$, $i = 1, \dots, N$, $j = 1, \dots, M$, 其中每个 (x_0, y_0) 由式 (1) 给出。

$$I'(x_0, y_0) = \sum_{a=-n..n} \sum_{b=-m..m} M(a, b) I(x_0 + a, y_0 + b) \quad (1)$$

式中, $1 \leq x_0 - n$, $x_0 + n \leq N$, $1 \leq y_0 - m$, $y_0 + m \leq M$ 。

(三) 迁移学习模型

为分析数据集并提取特征, 所提出的方法使用五种 TL 模型, 即 MobileNet、DenseNet169、VGG19、视觉几何组-16 (VGG16) 与 DenseNet201。ML 方法被用于评估 CNN-LSTM 的性能。

(1) VGG16: VGG16 在 AlexNet 的基础上把较大的卷积核替换为多个 3×3 卷积核, 从而减少参数数量并增加网络深度。VGG16 迁移学习由卷积层、全连接层与池化层三部分组成: 卷积层用滤波器提取图像中的信息, 其两项重要特性是步长与核尺寸; 池化层在提升网络空间密度的同时降低维度与计算量; 在全连接层中, 它们以完全连接的方式与低层交互。

(2) VGG19: VGG19 模型共 19 层, 是一种加权基底的特征提取器, 由 3 个全连接层与 16 个卷积层组合而成, 可把图像分为 1 000 个类别。VGG19 基于包含上百万幅图像、分为 1 000 类的 ImageNet 实现。所提出的方法中包含 4 个卷积层加 1 个最大池化层、3 个全连接层以及 2 个卷积层加 1 个最大池化层。由于采用多个 3×3 滤波器的卷积结构, 它在图像预测模型中颇受欢迎。

(3) MobileNet: MobileNet 包含逐点卷积与逐深度卷积两类层。为降低前几层的计算成本, 引入了可分离的逐深度卷积; 逐深度卷积用于为每一类输入分配不同的滤波器, 而 1×1 卷积 (逐点) 作用于逐深度层的输出以形成联合分布。每个卷积之后使用修正线性单元 (ReLU) 与批归一化 (BN)。准确率的折中与延迟共同决定其效率, 可用于图像的识别、分割与归类。

(4) DenseNet: DenseNet 把每一层前向馈送并影响后续每一层的行为, 属于 CNN。DenseNet 块共有五层, 其中前 4 层为稠密层、最后一层为过渡层; k 为每层的增长率。当增长率为 4 时, 过渡层的平均池化为步长 2 的 2×2 池化并配以 1×1 卷积, 而四个稠密层中为步长 1 的 1×1 与 3×3 卷积。DenseNet169、DenseNet 网络与 DenseNet201 被用于 CNN-LSTM 模型的性能评估。

(四) 深度特征提取

由于所提出的深度学习方法受到更多关注, 本实验对多种现有模型加以使用与改造以满足需求。为提取数据集中的特定属性, 本文只分离出少数几层并在冻结层中使用已训练权重, 而不训练整个模型。图像中的显著特征对图像的有效识别起着重要作用。

特征提取: 该过程用于从全连接层最后一个块的最大池化中提取特征。输入图像尺寸为 $128 \times 128 \times 3$, 特征提取过程中使用提取前后的特征形状。特征提取完成后, 特征的最终尺寸为 16 384。此处 n 表示输入图像的数量; 进一步可计算结肠、肺及其他癌症的输入 / 输出特征尺寸。所提取的特征被送入 ML 算法, 用以评估各 ML 模型的有效性。所有 TL 模型均采用该方法。

三、卷积神经网络与长短期记忆网络

(一) 卷积神经网络

在所提出的方法中, 本文用 CNN 在不同阶段以多种滤波器训练图像, 以识别图像的不同属性。CNN 的主

要目标是从高层提取局部特征并处理至低层。每一层的输出作为下一层的输入，从边缘、亮度等简单属性开始，在对具体目标逐一分类时难度逐渐加大。CNN 由 SoftMax 层、ReLU、卷积层、池化层、稠密层与全连接层（FC）构成。卷积层的卷积核用于刻画特征图的规模，它以“步长”对整个输入做卷积，使输出值的尺度为整数。用零填充可在输入周围补零，从而沿用低层特征的维度。卷积层的运算如式（2）所示。

$$F(i, j) = (I * K)(i, j) = \sum \sum I(i + m, j + n) K(m, n) \quad (2)$$

式（2）中，F 表示输出特征图，I 表示输入矩阵， $I * K$ 表示卷积层运算，K 表示尺寸为 $m * n$ 的二维滤波器。把输入阈值取为零即可计算 ReLU 激活，其数学表达如式（3）：

$$f(x) = \max(0, x) \quad (3)$$

（二）长短期记忆网络

LSTM 具有单一输入点，其中的反馈线路用于管理完整的数据序列。LSTM 包含输入门、输出门与遗忘门三个门；其中 x_t 表示当前输入， h_{t-1} 与 h_t 分别表示上一时刻与当前时刻的输出，细胞的先前状态与新状态分别记为 C_{t-1} 与 $\tilde{C}_t$ 。LSTM 输入门由式（4）—式（6）给出。

$$it = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (4)$$

$$\tilde{C}_t = \tanh(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (5)$$

$$C_t = it C_{t-1} + \tilde{C}_t \quad (6)$$

式（4）中用 Sigmoid 层依据 h_{t-1} 与 x_t 确定哪部分数据被采纳。为增强数据， h_{t-1} 与 x_t 需按式（5）经过 tanh 层。式（6）表示当前时刻的 $\tilde{C}_t$ 与数据中的长期记忆，其中 W_i 由 Sigmoid 的输出确定，tanh 的输出记为 $\tilde{C}_t$ ，且 $\tilde{C}_t$ 由 C_{t-1} 转换而来。LSTM 输入门偏置记为 b_i ，权重矩阵记为 W_f 。遗忘门允许 LSTM 借助 Sigmoid 层与点积实现数据的选择性传递。式（7）中，偏移量记为 b_f ，权重矩阵记为 W_f ， σ 表示 Sigmoid 函数，用于判定是否按特定概率遗忘来自前一阶段的数据。

$$ft = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (7)$$

对于输入 h_{t-1} 与 x_t ，LSTM 所需的状态由式（8）与式（9）计算。 C_t 是决策向量所携带的新信息，为生成最终输出需取 tanh 函数并相乘。

$$O_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (8)$$

$$h_t = O_t \tanh(C_t) \quad (9)$$

式中， b_o 与 W_o 分别表示偏置与权重矩阵。

（三）混合 CNN-LSTM

CNN-LSTM 是一种专为含图像或视频等视觉输入的过程预测问题而设计的 LSTM 架构。为自动识别肺癌病例，该组合系统使用了三类 X 射线图像。该架构通过融合 LSTM 与 CNN 网络构建，其中 CNN 作为分类器用于从 LSTM 与图像函数中剥离复杂细节。

所提出的混合网络用于检测肺癌疾病。该网络共 20 层：5 个池化层、12 个卷积层、1 个 LSTM 层、1 个输出层，以及 1 个带 SoftMax 函数的全连接层。两到三个二维 CNN、一个池化层与一个卷积层组合起来，使每个丢弃层与卷积块的丢弃率为 25%。卷积层用 ReLU 函数激活，特征提取的卷积核尺寸为 3×3 ；最大池化层的尺寸为 2×2 ，用于缩小输入图像的尺寸。特征图函数被送入架构最佳位置处的 LSTM 层以提取时序数据。卷积块之后得到的输出形状为 $(\text{none}, 7, 7, 512)$ ，再用 reshape 方法把 LSTM 输入尺寸调整为 $(49, 512)$ 。该设计在分析时序特征后，经全连接层把 X 射线图像归入三个类别（正常、肺癌与肺炎）之一。对于困难的分类问题，采用 CNN-LSTM 组合方法。

（四）高性能滤波器

排名前三的 ML 算法通过称为高性能滤波（HPF）的机制把输入送入集成学习流程。该 HPF 流程的作用是找出向集成学习方法提供输入、进而得到最终输出的估计器。HPF 与集成学习相结合，用于评估所实现模型的表现。本分析采用的性能指标包括特异度、灵敏度、F1 分数、混淆矩阵与准确率。所提出框架的分类算法对结肠癌与肺癌的检测准确率超过 99%。

四、结果与讨论

本部分考察各类 TL 方法的性能，随后考察融合了分类器投票模型与高性能 TL 模型的混合方法。研究表明，MobileNet 模型的表现优于其他各 TL 模型。

（一）肺癌分析

表 1 列出了若干 TL 模型在软投票与硬投票分类器下的结果。从结果看，MobileNet 在准确率均值上优于其他模型；此外，MobileNet 的指标高于其余模型，因此所提出的模型在肺癌数据集上采用 MobileNet。

Table 1 Evaluation of Accuracy Using TL (Lung Cancer)

表 1 用 TL 评估准确率（肺癌）

TL	VGG16 (%)	VGG19 (%)	MobileNet (%)	DenseNet169 (%)	DenseNet201 (%)
硬投票	98.7	98.89	99.89	98.77	99.66
软投票	98.99	99.24	99.78	99.19	99.91
平均	98.83	98.89	99.84	98.96	99.77

（二）结肠分析

此外，表 2 给出了用 TL 评估准确率的结果。这些良好结果得益于有效的特征提取、集成软投票分类器与恰当的预处理。MobileNet 模型的准确率达到历史最佳水平，因为它比其他 TL 模型提供了更强的特征提取能力。相较仅采纳单一模型，从多个模型获得预测的模型更强健、更有效，因此本文采用集成方法以获得高性能结果。

Table 2 Evaluation of Accuracy Using TL (Colon)

表 2 用 TL 评估准确率（结肠）

TL	VGG16 (%)	VGG19 (%)	MobileNet (%)	DenseNet169 (%)	DenseNet201 (%)
硬投票	99.80	99.61	99.78	99.69	99.79
软投票	99.80	99.61	99.78	99.69	99.79
平均	99.80	99.61	99.78	99.69	99.79

（三）肺与结肠的综合分析

表 3 给出了各 TL 模型的性能，表明 MobileNet 的 TL 模型在不同均值排序的 TL 模型中表现更优。在肺与结肠数据上，VGG19、VGG16、MobileNet、DenseNet201 与 DenseNet169 的准确率分别约为 98.81%、99.35%、99.32%、99.31%与 99.12%。

Table 3 Evaluation of Accuracy Using TL Models (Lung and Colon)

表 3 用各 TL 模型评估准确率（肺与结肠）

TL	VGG16 (%)	VGG19 (%)	MobileNet (%)	DenseNet169 (%)	DenseNet201 (%)
硬投票	99.3	98.52	99.3	98.75	99.27
软投票	99.4	99.1	99.35	99.5	99.35
平均	99.35	98.81	99.32	99.12	99.31

（四）CNN-LSTM 分类的性能分析

用于肺癌分类的 CNN 对照架构与所实现的 LSTM 架构的混淆矩阵如图 2 所示。CNN 架构在 915 幅图像中错误识别了 14 幅，其中 3 幅为肺癌；而所提出的 LSTM 模型仅错误归类了 8 幅，其中 2 幅为肺癌。可见所实现的 LSTM 网络优于对照的 CNN 网络，因为它具有更高的真阴性与真阳性值以及更少的假阳性与假阴性值。由此，所实现的方法能够有效地对肺癌病例进行分类。

正常	306 (33.4%)	0 (0.0%)	0 (0.0%)
肺癌	0 (0.0%)	305 (33.3%)	0 (0.0%)
肺炎	1 (0.%)	3 (0.3%)	300 (32.7%)
	正常	肺癌	肺炎

Figure 2 Confusion Matrix of the Proposed Lung Cancer Detection System**图 2** 所提出肺癌检测系统的混淆矩阵

此外，本文还给出了 CNN 分类器在验证与训练阶段的交叉熵（损失）与准确率评估。在第 125 轮迭代时，验证与训练准确率分别为 94.4%与 96.7%；相应地，CNN 架构的验证损失为 0.26、训练损失为 0.09。同样，本文也给出了 LSTM 分类器在训练与验证阶段的交叉熵（损失）与准确率的可视化表现：在第 125 轮迭代时，验证与训练准确率分别为 97.0%与 98.3%，LSTM 架构的验证损失与训练损失分别为 0.07 与 0.05。与 CNN 架构相比，LSTM 架构给出了更高的训练与验证准确率。各 CNN 的性能指标以图表形式见表 4。

Table 4 Assessment of CNN Model**表 4** CNN 模型的评估

类别	准确率 (%)	特异度 (%)	灵敏度 (%)	F1 分数 (%)
正常	99.9	98.9	100	98.6
肺炎	98.6	99.9	97.8	98.7
肺癌	98.5	98.7	99.5	98.9

表 5 给出了 CNN+LSTM 流程中各类别的运行特性。灵敏度 99.6%说明假阴性很少，特异度 99.5%说明真阴

性总数很高。对于肺炎，其灵敏度为 98.4%、F1 分数为 99.2%、特异度为 99.8%；对于正常病例，其灵敏度为 100%、特异度为 99.8%、F1 分数为 99.8%。

Table 5 Assessment of CNN-LSTM Network

表 5 CNN-LSTM 网络的评估

类别	准确率 (%)	特异度 (%)	灵敏度 (%)	F1 分数 (%)
正常	99.3	99.8	100	99.8
肺炎	99.5	99.8	98.4	99.2
肺癌	99.9	99.5	99.6	98.9

此外，本文把假阳性率（FPR）与真阳性率（TPR）的 ROC 曲线结合起来评估总体性能。可以看出，所提出的网络优于 CNN 架构：CNN 设计的 ROC 曲线下面积（AUC）为 99.8%，而 CNN-LSTM 架构为 99.9%。研究结果表明，对于肺癌患者，CNN 取得 98.2%的特异度、95.3%的 AUC 与 97.7%的 F1 分数；结果评估显示，CNN+LSTM 取得 99.2%的平均特异度、99.9%的 AUC、98.9%的 F1 分数与 99.3%的灵敏度。最后，本文用热力图借助目标概念的梯度来呈现实验结果，即梯度加权类激活映射（Grad-CAM）：经过最后一层后，粗略的定位图可指出图像中用于预测的关键区域。

所提出方法与现有方法的比较见表 6。所推荐的方法优于此前包括 CNN、混合模型与嵌套 LSTM+CNN 在内的各种方案；与上述模型相比，所提出的 CNN+LSTM 准确率最高。

Table 6 The Implemented System Comparison with Extant Systems

表 6 所实现系统与现有系统的比较

模型	准确率 (%)	特异度 (%)	灵敏度 (%)	F1 分数 (%)
嵌套 LSTM+CNN[18]	80	74	81	77
定制 CNN 混合模型[19]	99.30	99.27	99.27	99.26
CNN[20]	97.11	97.15	97.13	97.14
CNN+LSTM（本文）	99.35	99.30	99.32	99.29

五、结论

本研究提出了一种用于诊断肺癌与结肠癌的混合模型，它结合分组学习模型、k 折交叉验证、多种 TL 模型、专用 ML 模型与 HPF 来选出最佳方案。此外，本文用 MobileNet、DenseNet201、DenseNet169、VGG19 与 VGG16 等 TL 模型进行特征提取，并采用广泛使用的深度学习模型 CNN+LSTM 作为混合系统评估性能。本研究表明，在应用于肺与结肠图像的 LC25000 数据集时，该混合方法在识别上是高效的：CNN-LSTM 在准确率、特异度、灵敏度与 F1 分数方面分别取得约 99.35%、99.30%、99.32%与 99.29%的更优结果。未来临床机构可采用所提出的模型实现肺癌的自动识别。为提升肺癌与结肠癌检测的有效性，今后应采用高效的深度学习技术对这两类癌症的数据集进行联合研究。

参考文献

[1] Cao Y, Liu Y, Yang J, et al. Segmentation of lung cancer-caused metastatic lesions in bone scan images using self-defined model with deep supervision. Biomedical Signal Processing and Control, 2023, 79(1): 104068.

-
- [2] Yang H, Chen H, Wang F, et al. Deep learning-based six-type classifier for lung cancer and mimics from histopathological whole slide images: a retrospective study BMC Medicine, 2021, 19(1).
- [3] 田娟秀, 刘国才, 谷珊珊, 等. 医学图像分析深度学习研究方法研究与挑战. 自动化学报, 2018, 44(3): 401-424.
- [4] 石军, 王天同, 朱子琦, 等. 基于深度学习的医学图像分割方法综述. 中国图象图形学, 2025, 30(6): 2161-2186.
- [5] Gu D, Liu G, Xue Z. On the performance of lung nodule detection, segmentation and classification. Computerized Medical Imaging and Graphics, 2021, 89: 101886.
- [6] Zabin M, Choi H J, Uddin J. Hybrid deep transfer learning architecture for industrial fault diagnosis using Hilbert transform and DCNN-LSTM. The Journal of Supercomputing, 2023, 79(5): 5181-5200.
- [7] 马婷婷, 许志高. 影像学在肺结节良恶性诊断中的研究进展: 从传统成像到人工智能融合. 齐齐哈尔医学院学报, 2025, 46(24).
- [8] 张震, 杨世锡, 何俊, 等. 深度学习驱动故障诊断方法研究进展. 振动与冲击, 2026, 45(9): 222-232.