

基于改进 LSTM 的肺结节良恶性预测方法研究

赵 鑫

(山西铁道职业技术学院,山西 太原 030013)

摘要: 目前深度学习计算机辅助诊断技术已经相对成熟,可以实现对肺部医学影像中可疑结节的识别,甚至可以完成对结节大小、类型等信息的精确测量,为医师临床诊断肺结节的良恶性提供有利依据。然而,传统常规的深度学习网络构建过程中使用的均为单独孤立的肺结节影像片段,并没有从时间序列的角度上对特征进行研究和探索。文章提出了一种基于自编码和长短期记忆网络的肺结节良恶性预测算法。首先,利用自编码网络(SAE)自动提取出肺结节影像数据的深度隐藏特征。在此基础上,利用长短期记忆(LSTM)构建了一个双层构时间序列模型,学习了肺结节特征在时间序列上的变化情况。最后,在收集到的 5760 张随诊数据集上进行了对比验证,从实验结果中可以看出,该方法在对肺结节进行良恶性预测的精准度为 91.51%,其识别精度和收敛性能均优于其他比较算法。

关键词: 长短期记忆神经网络;自编码网络;肺结节;门控循环神经网络(GRU)

中图分类号: TP391

文献标识码: A

文章编号: 2096-9759(2023)06-0032-05

Benign and Malignant Prediction of Pulmonary Lesions based on improved Long Short-Term Memory network

ZHAO Xin

(Shanxi Railway Vocational and Technical College, Taiyuan 030013, China)

Abstract: Toady, computer aided diagnosis technology with deep learning has been relatively mature. It can not only realize the automatic marking of suspicious nodules in CT images, but also complete the automatic measurement of nodule size, density and other information, so as to provide a favorable basis for doctors' clinical diagnosis. However, in the traditional deep learning network construction process, only isolated lung nodule image fragments are used. The characteristics are not studied and explored from the perspective of time series. In this paper, an prediction algorithm for pulmonary nodules based on self-coding and long and short term memory network is proposed. Firstly, a auto-coding network (SAE) was used to automatically extract the depth hidden features of pulmonary nodule image data. On this basis, a two-layer time series model was constructed using deep learning to learn the changes of pulmonary nodule features in time series. Finally, we conducted experiments and evaluations on 5760 clinical data sets. The experimental results show that the accuracy of this method is 91.51% which is better than other comparison algorithms.

Key words: Long Short-Term Memory, encoding network, pulmonary lesions, Gate Recurrent Unit(GRU)

0 引言

受环境、生活习惯等多种因素的影响,肺癌已经成为当今发病率和死亡率最高的恶性肿瘤,患癌人数连年增加,单我国患肺癌人数就将达到 100 万之多^[1]。值得人们关注的是,约 3/4 的肺癌病患在临床确诊时已为中晚期,错过最佳治愈的时间和机会,而早期肺癌患者的治愈率可达到 80%以上^[2]。可见肺癌早发现早治疗是有效帮助患者的一个重要手段,在提高治愈率方面起着至关重要的作用^[3]。肺结节作为肺部病灶的一种重要影像表现,对其诊断乃至预测在肺癌的早期筛查过程中意义非凡。

由于肺结节生长与演变相对复杂,同一结节在不同时期状态多为不同的影像表征,其中蕴含的结节从产生、发展到死亡过程中大量时间信息,能很好的表征肺部病灶不同时期的影像学特征^[4]。通过对患者随访数据的长期跟踪、收集和分析,对研究肺结节生长规律及其演化规律,预测早期肺结节良恶性都有重要意义。

近年来,众多学者也对医学上的时间序列问题进行了许多研究。其中,Dan Li 等人^[5]使用 KNN 算法对形式化表示的 ICU 数据学习,以此预测病人病情的严重程度。Thongkam 等人^[6]提

出在随机森林算法的基础上结合 Adaboost 的预测方法,确定乳腺癌患者的存活几率。Chih-wen 等人^[7]设计了一种针对重症患者进行医疗干预的深度学习模型,可对病患状态实时检测。

随着深度学习在时间序列研究方面也展现出了较好的优越性,循环神经网络因其可特殊的历史信息记忆功能模块,走进了人们的视野^[8]。Dastider 等人^[9]在研究肺部超声帧的时间和空间特征的基础上,使用 LSTM 模型提高了对新冠肺炎严重程度分类的准确率。Islam M Z 等人^[10]研究设计的 CNN 与 LSTM 结合的网络模型,在对多种类型胸部 X 射线图像的识别上取得较好的检测结果。张宇冲提出了一种利用聚合注意力与 LSTM 神经网络的肺炎图像诊断方法,更好地实现了全局信息和局部信息的交互^[11]。Ketu S 等人^[12]提出在 LSTM 网络中使用卷积层特征提取,融入时间序列数据,实验证明使用额外的卷积层对提高检测效果有很大帮助。

因此,本文的主要目的是提出一种基于 LSTM 改进的肺结节生长预测记忆模型,通过对早期病程段图片特征的深度学习,得到中晚期病程段的病灶演化预测结果,实现对肺结节良恶性的预测。其中通过深度自编码进行特征提取,利用 LSTM 网络来对肺结节组织的演化趋势做出预测,进而为医师

收稿日期:2023-03-10

基金项目:山西省自然科学基金(No.201901D111319)。

作者简介:赵鑫(1993-),女,山西太原人,助教,硕士,主要研究方向:图像处理、深度学习。

诊断提供可靠的帮助。

1 数据集处理

1.1 数据采集

早期肺癌大部分多为周围型肺癌,其影像表现为实质内单发的、类圆形阴影、直径最大 30mm 的孤立性肺结节,如图 1 所示。因其肉眼观察上容易和细小的气管、血管相混淆,临床表现无明显的其他病变,导致医师在通过 CT 影像的计算机辅助诊断中很难筛查出原发病。




图 1 早期肺癌影像图

而中晚期肺癌则多表现为中央型肺癌或弥漫型肺癌,肿瘤大多发生于肺段或肺段以上的支气管部分,呈现出沿支气管壁浸润生长的结节状,如图 2 所示。更有肿瘤在肺内弥漫性生长,表现为肺弥漫分布的结节或斑片状病灶,同时伴有阻塞性肺炎或者部分肺不张等其他临床表现。从 CT 影像可以明显看出,但中晚期肺癌治愈率较低,肺癌的检出意义不大。




图 2 中晚期肺癌影像图

针对肺结节以上 CT 影像表征,在对肺结节的良恶性预测进行研究时,实验数据来源于从 2020 年 1 月到 2022 年 1 月期间在合作医院进行肺部检查的相关 CT 肺部影像数据,共计 319 例,这些影像均经主治医师确诊,其中有 120 例患者的 CT 图像中含有肺结节,选取其中的 48 张肺部 CT 图像用于研究。在共 5760 张肺部 CT 图像中共有结节 280 个,其中恶性结节 162 个,良性结节 118 个。

CT 图像是由 PET/CTST 16 系统扫描产生,工作电流 150mA,电压 140Kv,每张切片的扫描厚度为 3.75 毫米,CT 图像的分辨率为 256*256。

1.2 数据集预处理

由于肺部图像中仍存在一定的干扰因素,如伪影、噪声等。因此在进行肺结节特征提取和模型预测之前,首先要对这些图像进行预处理,在排除噪声等因素干扰的同时,将常规的阴影和纹理信息保留到网络学习训练阶段^[13]。为了便于后续的模型使用,将格式转化后的图片数据按照“日期”属性对每个患者的结节进行整理归纳和排列,生成时间序列数据集,例如如图 3 为一名患者间隔相应时间肺结节的变化情况。并从中随机抽取 80% 图片数据和日期数据包划分为训练集,剩余的 20% 则为测试集;然后对训练集和测试集中图片利用线性插值法进行空值补全,便于下一步处理使用。因其融合了全局的结构信息,图像在网络训练中显得具有较强的鲁棒性。




图 3 间隔相同时间的随访肺结节演化图

2 方法介绍

文章提出一种研究肺结节时间影像序列数据的方法,实现对肺结节的良恶性预测。首先通过对预处理后的患者大量随访 CT 影像数据,利用结合极限学习机的自编码网络完成特征提取,然后在长短期记忆模型中对提取的各时段特征深度学习,最终实现对肺结节演化趋势的预测并判断其良恶性。整体网络模型如图 4 所示。




图 4 基于 CAE-LSTM 的肺结节良恶性预测网络架构

2.1 肺结节深度特征提取

自编码网络在视觉感知信息的提取方面有明显的优势。众所周知,人类在看到图像的同时,会自动提取其中的关键信息,忽略掉其他认为不重要的东西。深度自编码网络在与常规卷积网络相比之下,可以保存更多的位置信息,提取出有更少冗余信息的代表性的特征图像^[14]。从另一方面来讲,自编码网络可以作为一种无监督的分层特征提取器,在获得更鲁棒和更具判别性的视觉特征表示的同时,为网络训练提供更优输入特征。

自编码深度学习网络是通过编码方式对网络的原始输入数据 $X \in R^d$ 进行重构原始的神经网络,如图 5 所示。理想状态下,自编码网络的输出 $Y \in R^d$ 要等同于输入,也就是 $Y=X$ 。因此,理论上讲,在多层 S 网络学习框架中,自编码函数可以实现特征提取的功能。从数学表达上看,自编码就是将输入数据 X 映射为高层表示 Z ,详见公式 1。

$$Z = H(X) = g(A \cdot X + b) \quad (1)$$

其中 $g(\cdot)$ 是激励函数, A 是 $d' \times d$ 维的权值矩阵, b 是偏差向量。之后,将产生的隐藏表示 Z 重新映射到输入空间重构向量 Y 中,详见公式 2。

$$Y = H(Z) = g(A' \cdot Z + b') \quad (2)$$

其中, Z 作为随机映射输出的中间表示,可以很容易地构建基于极限学习机 ELM (Extreme Learning Machine) 的自编码网络,然后得到 Y 的过程,也就是对于输入数据的重构的过程,可以看作是 ELM 学习过程,公式中的 A' 可以通过计算最小均方优化得到。




图 5 单隐含层自编码网络结构

文中设计使用的自编码特征提取充分利用 ELM 的通用

逼近能力并在其中加入稀疏约束, 以此保证输出的高层特征更加紧凑, 如图 6 所示。从图中我们可以看出, 不同于传统深度学习中的自编码网络, ELM 稀疏编码的输入权重是通过在随机空间反向搜索路径得到的。在极限学习机理论中指出使用随机映射输入权重来训练网络可以有效地逼近输入数据, 也就是说, 如果我们根据 ELM 的思想来训练自动编码, 一旦初始化后就不再需要调优了^[15]。另外, 为了能够得到输入数据的紧凑特征, 我们采用稀疏约束来构建 ELM 编码, 如公式 3 所示。

$$O_{\beta} = \arg \min_{\beta} \{\|H\beta - X\|^2 + \|\beta\|\} \quad (3)$$

其中 X 代表输入数据, H 表示随机映射的输出, β 是得到的隐含层的权重。在深度学习算法中, Z 是基于 β 的编码输出, 它在迭代中不断调整, 而本文的方法中由于使用的是随机映射表示隐含层特征表示, Z 是原始输入数据, H 是随机初始化的输出, 不需要再进行调整。




图 6 ELM 稀疏编码特征提取

2.2 基于 LSTM 时间序列的肺结节预测

在对肺结节建立时间序列上的神经网络学习模型时, 单纯依靠传统深度学习搭建的网络进行训练是具有一定的局限性。其既不能挖掘出肺结节影像图片中隐含的信息, 同时还存在遗漏重要提取特征的可能性。随着深度学习网络的不段发展, 学者们发现新型神经网络中的循环卷积网络 (RNN) 可以有效对图像中隐含的时间序列上的特征信息进行存储与运用, 以此在提高肺部结节随时间演化的良恶性趋势预测的准确率上, 可以发挥出重要的作用。

长短期记忆模型 (LSTM) 作为一种特殊的卷积神经网络, 通过将单元状态添加进循环神经网络中, 对已有网络的输入、输出及反馈流程起到了一个时间上的滞后作用^[16]。记忆模型会在特定记忆单元中的内部状态保持一个持续误差流, 从而保证梯度稳定的存在。LSTM 的核心在于对循环神经网络中的记忆模块进行了重构, 添加了三个门控单元, 分别为输入门、输出门与遗忘门, 实现对输入信息选择性的产生相应长度的记忆, 如下图 7 所示。




图 7 LSTM 结构图

从图中我们可以看出, LSTM 网络使用记忆单元中的状态来对历史信息进行存储。在整个网络中, 输入数据负责状态的更替和内容输出。而在输入门关闭期间, 历史信息将被保留下来。在输出门打开时, 记忆单元中的历史信息才被重新启用。同时, 在进入到 LSTM 时会根据已有的规则来判断该信息是否对有用, 只有符合条件的信息可以留下。因此, 使用 LSTM 模型对时序数据处理具有很好的效果。在 LSTM 网络

门机制的基础上, GRU (Gate Recurrent Unit) 结构, 作为 LSTM 的一个变种, 合并记忆信息和隐含状态, 用一个单独的更新门取代了 LSTM 结构中的输入门和遗忘门。因此, GRU 模型较长期记忆模型在结构上更简单, 也在越来越多领域得到应用。

基于上述理论思想, 针对肺部结节特征学习, 本文提出一种双层长短期记忆模型网络, 如下图 8 所示。整个模型采用了两层反复迭代的 GRU 结构作为基本单元模块, 底层编码特征经过隐含层高维变量输入的学习得到预估的较早期结节病灶, 顶层解码隐含层的高维特征学习得到相应的预测肺结节病灶, 两层的 GRU 模型较单层网络而言更加灵活。




图 8 双层 GRU 肺结节预测模型

重置门 r_t 允许 GRU 单元记住或删除不相关的特征信息, 用来确定是否忽略之前输入的肺结节特征信息, 如公式 4 中所示。当 r_t 接近于 0 时, 则强制丢弃该特征信息, GRU 单元将只关注当前的输入特征。

$$r_t = \sigma(W_{rh}h_{t-1} + W_{rx}x_t + b_r) \quad (4)$$

其中 σ 表示 sigmoid 函数 $[W_{rh}, W_{rx}]$ 表示权重矩阵, $[b_r]$, 表示学习偏差项。

更新门 z_t 用来控制前一个状态传输到当前肺结节特征信息的数量。更新门的工作原理就像输入门和遗忘门一样, 但它并不是像 LSTM 那样分别计算遗忘门和输入门的值, 而是通过 z_t 和 $1-z_t$ 一起计算它们, 如公式 5 所示。这一设置意味着 GRU 单元只有在忘记前面的特征后才能接受新的特征输入。更新门的作用则类似于 LSTM 中的内存单元。

$$z_t = \sigma(W_{zh}h_{t-1} + W_{zx}x_t + b_z) \quad (5)$$

重置门中的候选隐藏层状态 C_t 表示通过 tanh 层创建出的要添加到当前特征上的新特征。将该隐藏层状态与之前的特征图像信息相融合, 在更新门设置的权重作用下形成最终隐藏状态 h_t 。

$$c_t = \tanh(W_{ch}r_th_{t-1} + W_{cx}x_t + b_c) \quad (6)$$

$$h_t = (1 - z_t) \odot h_{t-1} + z_t \odot c_t \quad (7)$$

当重置门一直处于激活状态时, 它不会保留之前的特征, 整个模型仅可以保留图像的短时期特征记忆。但如果更新门长期处于未激活状态的话, 网络模型可以保留较长时间的特征记忆, 所有之前的特征也可以被保留下来。

在整个肺结节预测网络框架中, 长短期记忆模型作为一个不断学习预测的过程, 将早期肺结节图像特征慢慢地学习转变为对应的中晚期肺结节特征。在训练模型中, 拟设置每个基本单元重复 3 次。输入的序列 $[X_1, \dots, X_n]$ 是对早期肺部

病灶的重现。每次迭代后计算损失。通过网络模型的学习,时间在图像上的显示是逐渐变化的。换句话说,在每次迭代之后,都应该更接近目标图像。因此,在训练过程中,在合成的特征图像和目标图像之间的损失也应该逐渐变小。为了满足这一要求,损失函数设置了一系列的权重,得到以下损失函数:

$$J = \sum_{t=1}^T w_t \|x_{k+1} - \hat{h}_t\|_F^2 \quad w = [0.1, 1, 10] \quad (8)$$

其中, X_{k+1} 表示第 $K+1$ 组中的目标图像, \hat{h}_t 表示循环训练过程中预测的中间状态, w_t 为循环的第 t 个步骤的权重。

3 实验与结果分析

3.1 参数设置

为了验证本文所提方法的有效性,我们使用该方法进行肺结节的诊断。在进行特征学习之前,所有的肺结节图像的大小都被调整为 240×240 像素,并且进行直方图均衡化,增强图像的对比度。在特征学习阶段,特征学习的层数设置为 4,隐含层激励函数采用高斯函数。在特征预测阶段,采用双层 GRU 对特征学习后的高层信息进行预测学习,隐含层的节点个数设置为 15,隐含层的激励函数选用 sigmoid 函数。

3.2 对肺结节良恶性预测定量评估

在实验过程中,为保证输入数据的统一性,我们将候选结节设置预处理为相同大小的区域。然后,对 280 个预训练结节使用十折交叉验证方式进行诊断预测,通过预测良恶性的准确度情况分为以下 4 种:

- 真阳性 (TP), 代表检测出真有疾病;
- 假阳性 (FP), 代表检测出有疾病实际上没有;
- 真阴性 (TN), 代表没有疾病;
- 假阴性 (FN), 代表检测出没有疾病, 实际上存在。

表 1 肺结节良恶性预测的准确率

| 恶性结节 | | 良性结节 | | 总计 |
|------|-----|------|-----|-----|
| 真阳性 | 156 | 真阴性 | 114 | 270 |
| 假阴性 | 6 | 假阳性 | 4 | 10 |
| 总计 | 162 | | 118 | 280 |

从表 1 中可以看出,在 200 多个待测试样本中有 6 个恶性结节被判断成良性,4 个良性结节被预测为恶性结节,并通过以下公式分别计算得到预测的敏感度为 96.3% (156/162),特异性为 96.6% (114/118) 准确度可达 96.4% (270/280)。

$$specificity = \frac{TN}{TN + FP} \quad (9)$$

$$sensitivity = \frac{TP}{TP + FN} \quad (10)$$

$$accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (11)$$

3.3 不同肺结节良恶性预测方法的对比

为了更好地验证本文方法的预测诊断性能,使用相同的数据对其他不同肺结节良恶性预测方法进行评估。我们使用相同的测试集并且将本文方法的实验结果和文献中提到的方法进行比较。本文方法的预测结果在肺结节诊断列表中排第二。Polat^[17]等提出的将主成分分析、模糊加权预处理和人工免疫识别系统结合起来的方法获得最好的准确率,但是他们的系统过于复杂,时间消耗大于本文方法,而本文的方法同样获得理想的分类准确率。

接下来,我们通过计算各种预测方法的受试者工作特征曲线 (receiver operating characteristic curve, ROC) 来对方法的预测性能进行评估。ROC 曲线是一种普遍用来评估二值回归分析的有力工具,是以真阳性率为纵坐标,假阳性率为横坐标绘制的曲线。在对不同肺结节预测方法进行比对分析时,将不同方法的 ROC 曲线绘制到同一坐标中,曲线越靠近左上角代表对应方法预测越精确,如图 9 所示,我们的方法具有较好的预测性能。与 Polat 的方法相比,虽然他们方法在整体准确率上优于我们的方法,但是他们方法的假阳性率 (6.8%) 高于我们方法假阳性率 (3.4%),我们方法的诊断性能优于 Polat 的方法。




图 9 不同方法对比的 ROC 曲线

根据模型 ROC 曲线求出曲线面积 AUC (the area under curve), 面积越接近于 1, 说明该方法效果越好。我们的方法获得最高的 AUC 值 0.9515, 具有很好的预测效果, 如表 2 所示。

表 2 不同的预测方法 ROC 面积 AUC 对比

| 不同的肺结节良恶性预测方法 | ROC 曲线面积 AUC |
|---------------------------------------|--------------|
| ANN ^[18] | 0.8746 |
| SVM ^[19] | 0.8021 |
| Rule-based+SVM ^[20] | 0.8060 |
| PCA+Fuzzy Weight+AIRS ^[17] | 0.9034 |
| AdaBoost ^[21] | 0.8663 |
| Our method | 0.9515 |

4 结语

本文中提出了一种基于自编码和长短期记忆网络的肺结节良恶性诊断算法。该框架将患者随访产生的临床数据制定为对应的一个时间序列。研究利用深度自编码网络对特征进行学习后,通过双层 LSTM 网络学习特征在时间序列上的隐藏信息,从而实现对肺结节良恶性的预测。该方法在分析深度学习方法的基础上,结合从 CT 成像和实验室检测中获得的特征来预测进展。使用选出的 280 个肺结节进行特征提取和特征训练,产生了较好的诊断准确率。在今后的研究过程中,还需要进一步利用深度学习技术、海量图像处理与识别技术来研究肺部病灶不同维度下的特征表达,对分析早期肺癌超微特征、继而预测早期肺癌的演化规律和良恶性程度有非常重要的价值。

参考文献:

- [1] National Lung Screening Trial Research Team, Aberle DR, Adams AM, et al. Reduced lung-cancer mortality with low-

- dose computed tomographic screening [J]. *N Engl J Med*, 2011, 306(5):395-332.
- [2] International Early Lung Cancer Action Program Investigators, Henschke CI, Yankelevitz DF, et al. Survival of patients with stage I lung cancer detected on CT screening[J]. *N Engl J Med*, 2006, 355(17):1763-1771.
- [3] Siegel, R., D. Naishadham, and A. Jemal, Cancer statistics, 2013. *CA Cancer J Clin*, 2013, 63(1):p.11-30.
- [4] Natbna Lung screening Trial Research Team, Aberle DR, Adams AM, et al. Reduced lung-cancer mortality with low-dose computed tomographic screening [J]. *N Engl J Med*, 2011, 365(5):395-409.
- [5] Li, D., A. Djulovic, and J. Xu, A Study of k NN using ICU Multivariate Time Series Data [C], in *The 9th International Conference on Data Mining (DMIN'13)*. 2013, CSREA: Las Vegas. 211~217.
- [6] Thongkam J, Xu G, Zhang Y. Ada Boost algorithm with random forests for predicting breast cancer survivability [C]// *Neural Networks*, 2008. *IJCNN 2008*. (IEEE World Congress on Computational Intelligence). IEEE International Joint Conference on. IEEE, 2008: 3062~3069.
- [7] Cheng C W, Chanani N, Maher K, et al. icu ARM-II: improving the reliability of personalized risk prediction in pediatric intensive care units [C]// *Proceedings of the 5th ACM Conference on Bioinformatics, Computational Biology, and Health Informatics*. ACM, 2014: 211-219.
- [8] Nakhaei, Fardis, Irannajad, et al. Application and comparison of RNN, RBFNN and MNLR approaches on prediction of flotation column performance[J]. *International Journal of Mining Science and Technology*, 2015, 25(6):983-990.
- [9] Dastider A G, Sadik F, Fattah S A. An integrated autoencoder-based hybrid CNN-LSTM model for COVID-19 severity prediction from lung ultrasound[J]. *Computers in Biology and Medicine*, 2021, 132(2):104296.
- [10] Islam M Z, Islam M M, Asraf A. A combined deep CNN-LSTM network for the detection of novel coronavirus (COVID-19) using X-ray images[J]. *Informatics in Medicine Unlocked*, 2020, 20:100412.
- [11] 张宇冲.基于深度学习预测 CT 图像中肺结节的病理亚型[D].中国医科大学,2022.
- [12] Ketu S, Mishra P K. India perspective: CNN-LSTM hybrid deep learning model-based COVID-19 prediction and current status of medical resource availability[J]. *Soft Computing*, 2022, 26(2): 645-664.
- [13] Qiang Y, Zhang X, Ji G, et al. Automated Lung Nodule Segmentation Using an Active Contour Model Based on PET/CT Images [J]. *Journal of Computational and Theoretical Nanoscience*, 2015, 12(8): 1972-1976.
- [14] Kasun L L C, Zhou H, Huang G B, et al. Representational learning with ELMs for big data[J]. *IEEE Intelligent Systems*, 2013, 28(6): 31-34.
- [15] 赵鑫,强彦,葛磊.基于双模态深度自编码的孤立性肺结节诊断方法[J].*计算机科学*,2017,44(08):312-317.
- [16] HOCHREITER S, SCHMIDHUBER J. Long short-term memory[J]. *Neural Computation*, 1997, 9(8):1735-1780.
- [17] Polat, K., and Gunes, S., Principles component analysis, fuzzy weighting pre-processing and artificial immune recognition system based diagnostic system for diagnosis of lungcancer. *Expert Syst. Appl.* 34:214-221,2008.
- [18] Suzuki K, Armato III S G, Li F, et al. Massive training artificial neural network (MTANN) for reduction of false positives in computerized detection of lung nodules in low-dose computed tomography[J].*Medical Physics*,2003, 30(7): 1602-1617.
- [19] Keshani M, Azimifar Z, Tajeripour F, Boostani R. Lung nodule segmentation and recognition using SVM classifier and active contour modeling: a complete intelligent system. *Comput Biol Med.* 2013;43:287-300.
- [20] Jing Z, Bin L, Lianfang T. Lung nodule classification combining rule-based and SVM. In: Edited by Li K, *Proceedings of the IEEE Fifth International Conference on Bio-Inspired Computing: Theories and Applications: 23-26 September 2010; Changsha, China*. Piscataway, NJ: IEEE Computer Society;2010. p.1033-36
- [21] Dolejsi, M., Kybic, J., Polovincak, M., Tuma, S., 2009. The Lung TIME: annotated lung nodule dataset and nodule detection framework, vol. 7260, SPIE, 72601U, doi: <http://dx.doi.org/10.1117/12.811645>, URL <<http://link.aip.org/link/PSI/7260/72601U/1>>.
- +++++
- (上接第 31 页)
- [8] 王彤,李琦.基于残差网络与特征融合的改进 YOLO 目标检测算法研究[J].*河北工业大学学报*,2023,52(01):41-49. DOI:10.14081/j.cnki.hgdxb.2023.01.006.
- [9] 陈锋军,朱学岩,周文静,郑一力,顾梦梦,赵燕东.利用无人机航拍视频结合 YOLOv3 模型和 SORT 算法统计云杉数量[J].*农业工程学报*,2021,37(20):81-89.
- [10] 罗茜,赵睿,庄慧珊,罗宏刚.YOLOv5 与 Deep-SORT 联合优化的无人机多目标跟踪算法[J].*信号处理*,2022,38(12):2628-2638.DOI:10.16798/j.issn.1003-0530.2022.12.017.
- [11] 石博雅,董学峰.融合 GhostNet 的 YOLOv4 轻量化网络设计与实现 [J/OL]. *小型微型计算机系统*: 1-9 [2023-03-13]. DOI:10.20009/j.cnki.21-1106/TP.2021-0516.
- [12] 曾凯,李响,陈宏君,文继锋.引入注意力机制的改进型 YOLOv5 网络研究[J].*软件工程*,2023,26(01):55-58+54.
- [13] 徐翔,蔡茂国,唐剑兰.基于改进的 YOLOv4 的目标识别研究[J].*信息技术*,2022,46(12):107-111+117. DOI: 10.13274/j.cnki.hdzj.2022.12.019.
- [14] 陈翠琴,范亚臣,王林.基于改进 Mosaic 数据增强和特征融合的 Logo 检测[J].*计算机测量与控制*,2022,30(10):188-194+201. DOI:10.16526/j.cnki.11-4762/tp.2022.10.029.
- [15] 沈皓,常军.基于改进卡尔曼滤波的结构损伤识别方法研究[J].*苏州科技大学学报(工程技术版)*,2022,35(04):14-19.
- [16] 郭春学,贺欣欣.基于改进匈牙利算法对多人人体关键点匹配的研究[J].*信息技术与网络安全*,2022,41(05):45-50+58. DOI:10.19358/j.issn.2096-5133.2022.05.007