

基于改进标签图的图卷积网络管道缺陷检测模型

曾保志, 罗建桥, 熊鹰, 李柏林*

西南交通大学机械工程学院, 四川 成都 610031

摘要 一张排水管道图像中可能同时存在变形、渗漏等多种缺陷。针对现有卷积神经网络(CNN)忽略标签关系,难以准确检测多标签管道图像的问题,引入图卷积网络(GCN)建模不同缺陷标签的关系,提出了一种基于改进标签图的GCN管道缺陷检测模型(ILG-GCN)。首先,ILG-GCN模型在原有CNN模型的基础上引入GCN模块,GCN利用标签图迫使具有共生关系的标签分类器相互接近,获得保持语义拓扑结构的分类器,从而提高预测共生标签的概率。其次,改进GCN模块更新节点信息时使用的标签图,改进后的标签图根据每种缺陷主要相关标签的共生强度计算自适应的标签共生概率,并根据主要相关标签的共生强度为其分配不同的权值。实验结果表明,所提模型的总体平均准确率为95.6%,能够准确检出同时存在的多种管道缺陷。

关键词 图像处理; 管道缺陷检测; 多标签学习; 标签关系; 图卷积网络

中图分类号 TP391 文献标志码 A

DOI: 10.3788/LOP202259.1810004

Graph Convolutional Network Detection Model for Pipeline Defects Based on Improved Label Graph

Zeng Baozhi, Luo Jianqiao, Xiong Ying, Li Bailin*

School of Mechanical Engineering, Southwest Jiaotong University, Chengdu 610031, Sichuan, China

Abstract A drainage pipe image contains many defects, such as deformation and leakage. Considering that existing convolutional neural networks (CNNs) ignore the label relationships and make it difficult to accurately detect multilabel pipeline images, graph convolutional networks (GCNs) were introduced to model the relationships between different defect labels and improved label graph GCN (ILG-GCN) model was proposed. First, the ILG-GCN model introduced the GCN module based on the original CNN model. GCN used label graphs to force classifiers with symbiosis to be close to each other and obtain classifiers that maintain semantic topology, thereby improving the probability of predicting symbiotic labels. Second, the label graph used by the GCN module to update node information was improved. The improved label graph calculated the adaptive label symbiosis probability for each defect based on the symbiosis strength of the main related labels and assigned different weights to the main related labels according to their symbiosis strength. The experimental results show that the mean average precision value of the proposed model is 95.6%, suggesting that the model can accurately detect multiple pipeline defects simultaneously.

Key words image processing; pipeline defect detection; multi-label learning; label relation; graph convolutional network

1 引言

地下市政工程中的日常工作之一是检查排水管道是否存在变形、破裂、渗漏等缺陷。人工方式检测管道缺陷存在效率低、精度低的问题。计算机视觉技术为解决管道缺陷检测问题提供了新方向。目前的管道缺陷检测方法使用CCTV管道机器人采集图像,将图像

输入卷积神经网络(CNN),输出各标签的预测概率,标签预测概率大于预测阈值时则输出该标签。由于一张管道图像中可能同时出现多种缺陷类型,因此管道缺陷检测任务属于多标签学习问题(MLL)^[1]。为了准确检测出管道中同时存在的多种缺陷,应该考虑缺陷间的共生关系。当某标签发生时,如果另一标签发生的条件概率大于人为设定的阈值,则认为两者具有共

收稿日期: 2021-06-07; 修回日期: 2021-07-12; 录用日期: 2021-07-12

基金项目: 四川省科技厅重点研发项目(2021YFN0020)

通信作者: *bli62@263.net

生关系,称这两个标签频繁共生。

对于 MLL 问题,目前流行的 CNN 忽略了标签关系,无法准确预测存在共生关系的多个标签。得益于端到端的特征学习能力,CNN 在不同视觉任务中取得了出色表现^[2-6]。在 CNN 中,每个标签的分类器单独学习,无法建模标签之间的共生关系。具有共生关系的多个标签可以认为具有相似语义,CNN 无法保持分类器的语义拓扑结构^[7],即无法使语义相似的多个分类器彼此接近,语义无关的分类器彼此远离。因此,直接将 CNN 应用于 MLL 任务难以获得满意性能^[8]。近年来,建模标签关系在 MLL 研究中获得了大量关注^[9-11],其中图卷积网络(GCN)采用图结构自动学习标签关系,在 MLL 任务中表现了优异性能^[12]。Chen 等^[13]将 GCN 应用于 X 射线图像分类,使模型自适应地重新校准多标签输出;He 等^[14]基于 GCN 的情感分布学习模型,通过 GCN 捕捉潜在的情感分布;Xie 等^[15]将 GCN 应用于天气识别,通过标签图捕捉不同天气的共生关系;王江安等^[16]将 GCN 应用于点云处理,通过提取节点间的边特征来学习节点间依赖关系。然而,现有 GCN 方法的不足之处在于,标签图为所有标签分配相同的共生概率,忽略了不同标签的差异,对频繁共生标签的关注度低,容易造成标签漏检问题。

针对 CNN 忽略标签关系,无法准确检测排水管道多种缺陷的问题,本文提出了一种基于改进标签图的 GCN 管道缺陷检测模型(ILG-GCN)。一方面,ILG-

GCN 引入 GCN 模块学习高阶标签关系。在 GCN 模块中,标签词向量表示在标签图引导下被映射成分类器,具有共生关系的分类器相互接近,有利于准确检测管道图像中同时存在的多种缺陷。另一方面,为每个标签定义自适应的共生概率,设计了改进标签图。改进标签图能够反映不同标签共生强度的差异,更加关注不同缺陷对应的相关标签,提高缺陷检测能力。

2 理论基础

2.1 模型整体框架

ILG-GCN 模型由 CNN 和 GCN 模块组成,如图 1 所示。CNN 和 GCN 的结构如图 2 所示。训练阶段,输入样本图像,样本真实标签表示为 $\mathbf{y} \in \mathbb{R}^C$,所有标签的词向量表示为 $\mathbf{H}^0 \in \mathbb{R}^{C \times D_0}$,标签图表示为 $\mathbf{B} \in \mathbb{R}^{C \times C}$,其中 C, D_0 分别是标签总数和标签词向量长度。CNN 模块提取图像特征 $\mathbf{x} \in \mathbb{R}^{D_L}$,可记为 $\mathbf{x} = f_{\text{CNN}}(\mathbf{I} | \boldsymbol{\Theta})$, D_L 为特征长度。GCN 模块通过 L 层在标签图 \mathbf{B} 上的图卷积,将 \mathbf{H}^0 映射成每个标签的分类器 $\mathbf{H}^L \in \mathbb{R}^{C \times D_L}$,可记为 $\mathbf{H}^L = f_{\text{GCN}}(\mathbf{H}^0, \mathbf{B} | \mathbf{W})$, \mathbf{W} 是图卷积参数。分类器 \mathbf{H}^L 和特征 \mathbf{x} 的维度均为 D_L ,预测结果 $\hat{\mathbf{y}} \in \mathbb{R}^C$ 由 \mathbf{H}^L 和 \mathbf{x} 的乘积获得。由预测结果和真实标签计算损失函数,通过反向传播损失函数的梯度完成 CNN 和 GCN 模块中参数 $\boldsymbol{\Theta}, \mathbf{W}$ 的训练。测试阶段,由图像特征 \mathbf{x} 与 \mathbf{H}^L 的乘积预测样本标签。

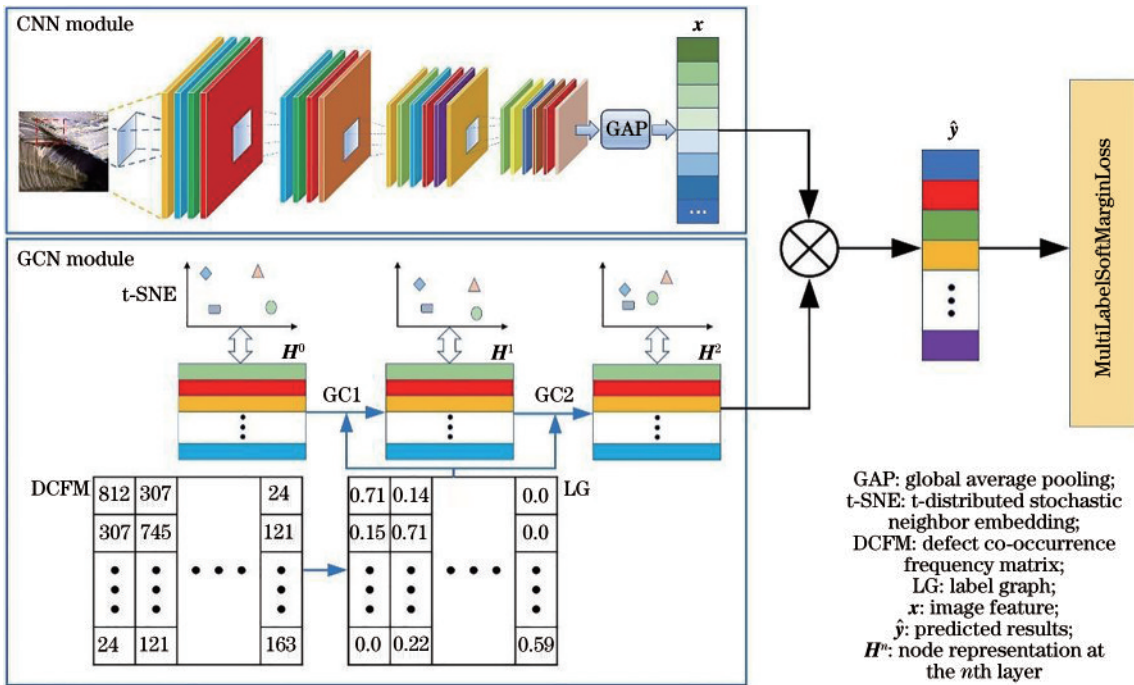


图 1 ILG-GCN 模型框架

Fig. 1 ILG-GCN model framework

图 1 中的 label graph(LG)为改进后的标签图,改进后的标签图根据共生频次矩阵(DCFM)中每类缺陷

发生次数及每类缺陷与其他缺陷共生次数得到每类标签的自适应共生概率,同时根据共生次数得到主要标

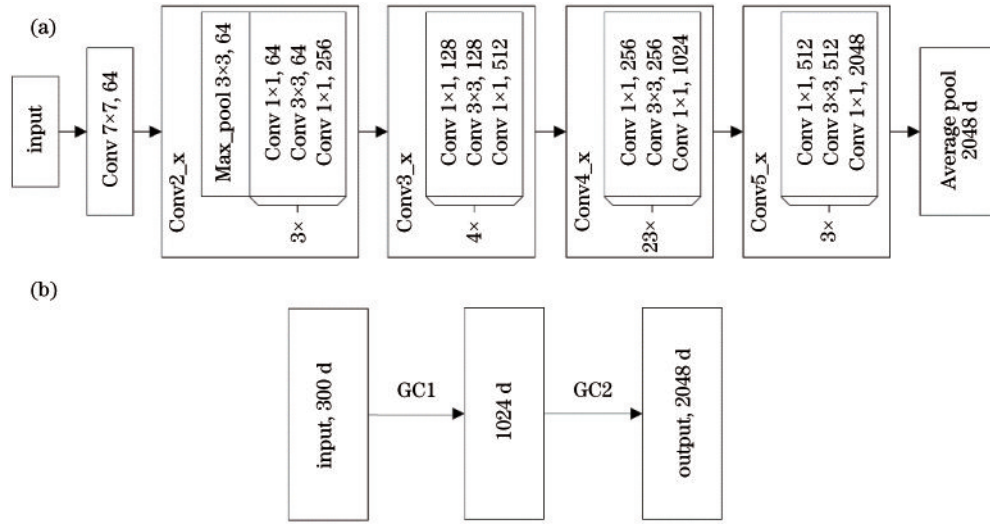


图2 网络结构。(a) CNN网络结构;(b) GCN网络结构

Fig. 2 Network structure. (a) CNN network structure; (b) GCN network structure

签与共生标签的共生强度,从而为共生标签在更新节点时分配不同权重。

2.2 GCN 模块

MLL任务中的标签间存在关联,挖掘标签间的高阶关系能够提升模型检测标签的性能,而CNN模型无法建模标签关系,因此引入GCN模块。

在MLL任务中,数据标签可以转化为以标签词向量为节点、标签图为边的图结构。图卷积神经网络是一种多层神经网络,利用谱聚类思想,将传统离散卷积应用于图结构数据,学习特征时综合考虑相邻特征。GCN学习方式遵循逐层学习,所有节点同步更新,每层学习过程可分解为聚合和合并两个步骤,其本质是在节点间传播信息来更新节点表示。因此,GCN能够在标签图引导下建模标签之间的共生关系。

假设训练集中的标签共生关系由标签图 $\mathbf{B} \in \mathbb{R}^{C \times C}$ 表达。对于一个由 L 层图卷积组成的 GCN,第 l 层卷积根据 \mathbf{B} 将原节点表示 $\mathbf{H}^l \in \mathbb{R}^{C \times D_l}$ 更新成 $\mathbf{H}^{l+1} \in \mathbb{R}^{C \times D_{l+1}}$ 。 \mathbf{H}^{l+1} 中第 n_0 个节点、第 d_0 维可以表示为

$$\mathbf{H}_{n_0 d_0}^{l+1} = h \left(\sum_{d=1}^{D_l} \sum_{n=1}^C \hat{B}_{n_0 n} \mathbf{H}_{nd}^l \mathbf{W}_{dd_0}^l \right), \quad (1)$$

式中: $\mathbf{W}^l \in \mathbb{R}^{D_l \times D_{l+1}}$ 是待学习的卷积核,用于合并 \mathbf{H}^l 中的 D_l 维信息;激活函数 $h(\cdot)$ 一般采用 Leaky ReLU; $\hat{\mathbf{B}}$ 是归一化后的标签图,用于聚合与 n_0 相邻的节点表示。式(1)以矩阵形式表示为

$$\begin{cases} \mathbf{H}^{l+1} = h(\hat{\mathbf{B}} \mathbf{H}^l \mathbf{W}) \\ \hat{\mathbf{B}} = \mathbf{D}^{-\frac{1}{2}} \mathbf{B} \mathbf{D}^{-\frac{1}{2}} \\ D_{ii} = \sum_j B_{ij} \end{cases} \quad (2)$$

在第 1 层图卷积 ($l=0$) 中, \mathbf{H}^0 由标签词向量构成,之后,每个图卷积层都以上一层节点 \mathbf{H}^l 作为输入,

输出新节点 \mathbf{H}^{l+1} , 参数 \mathbf{W}^l 通过训练获得。最后一层节点表示 \mathbf{H}^L 的维度 D_L 被设置成与图像 CNN 特征 \mathbf{x} 的维度一致。样本标签预测值 $\hat{\mathbf{y}} \in \mathbb{R}^C$ 可以表示为

$$\hat{\mathbf{y}} = \text{Sigmoid}(\mathbf{H}_n^L \mathbf{x}). \quad (3)$$

式(3)说明,标签 n 节点的最终表示 \mathbf{H}_n^L 被作为标签 n 的分类器。由于标签图 \mathbf{B} 描述了标签之间的共生关系,在 \mathbf{B} 基础上学习得到的 \mathbf{H}^L 能够体现标签关系。具体来说,若管道缺陷标签 m 和 n 在训练集中频繁共现,则分类器 \mathbf{H}_m^L 和 \mathbf{H}_n^L 相似。此时,当模型输出较高的 n 类缺陷概率时,同时也会输出较高的 m 类缺陷概率,这样就达到了预测共生管道缺陷的目的。因此,GCN 可以保持标签语义的拓扑结构。

2.3 改进标签图

由式(1)可知,标签图 \mathbf{B} 在图卷积运算中控制不同节点之间信息传播的强度,是决定分类器拓扑结构的关键因素。 B_{nm} 反映标签 m 和 n 的共生关系,较大的 B_{nm} 迫使标签 m 显著影响标签 n , 引导分类器 \mathbf{H}_m^L 和 \mathbf{H}_n^L 相互接近。现有 GCN 方法中标签图 \mathbf{B} 的计算公式为

$$B_{nm} = \begin{cases} \frac{\rho \sigma[p(m|n) > \tau]}{\sum_{m \neq n} \sigma[p(m|n) > \tau] + \epsilon}, & m \neq n \\ 1 - \rho, & m = n \\ p(m|n) = N_{n,m}/N_n \end{cases}, \quad (4)$$

式中: $N_{n,m}$ 和 N_n 分别表示训练集中标签 m 、 n 同时出现的样本数量及标签 n 的样本数量; $p(m|n)$ 表示标签 n 存在时,标签 m 发生的条件概率;当条件 \cdot 为真时, $\sigma(\cdot) = 1$, 否则为 0;人工设定的阈值 τ 用于筛选条件概率 $p(m|n)$, 当 $p(m|n) > \tau$ 时, B_{nm} 为整数, 否则为 0; ϵ 是较小常数, $\epsilon = 1 \times 10^{-6}$; ρ 表示一个标签与其他标签的共生概率, ρ 较大表示标签 n 与其他标签 m ($m \neq n$) 的共生概率大, 其他标签 m 的分类器将显著影响标签 n

的分类器。

现有标签图中的共生概率 ρ 采用人工定义的常数,所有标签的共生概率相同。人工定义的常数 ρ 忽略了标签共生强度的差异,容易造成漏检。例如,管道变形容易诱发破裂、渗漏等缺陷。相对其他标签,当变形标签存在时,更容易存在其他缺陷标签。因此,为了准确预测其他缺陷,应该赋予变形标签更大的共生概率 ρ ,而不是为所有标签分配固定的 ρ 。

针对现有标签图的不足,本实验组设计了一种改进标签图,为每个标签 n 计算自适应的共生概率 ρ_n 来表达标签共生强度的差异。自适应共生概率 ρ_n 的表达式为

$$\rho_n = \frac{\sum_{m \in N_{n,k}} \rho(m|n)/k}{\sum_{m \in N_{n,k}} \rho(m|n)/k + 1}, \quad (5)$$

式中: $N_{n,k}$ 是一个集合,包含标签 n 的前 k 个主要相关标签, k 由人工确定。若标签 $m_0 \in N_{n,k}$, 则 $\rho(m_0|n)$ 属于集合 $\{\rho(m|n) | m \in N_{n,C-1}\}$ 中的前 k 个最大的元素之一。

对于某一特定标签,其各个共生标签的共生程度也互不相同,因此标签图 \mathbf{B} 的计算方式可重写为

$$B_{nm} = \begin{cases} \frac{\rho\sigma[\rho(m|n) > \tau]N_{n,m}}{\sum_{m \neq n} \{\sigma[\rho(m|n) > \tau]N_{n,m}\} + \epsilon}, & m \neq n \\ 1 - \rho, & m = n \\ \rho(m|n) = N_{n,m}/N_n \end{cases}. \quad (6)$$

根据式(5),共生概率 ρ_n 随着 k 的增大而减小,当 $k=1$ 时 ρ_n 取最大值。任一标签与其共生强度最大的主要标签的共生次数小于等于该标签发生次数,当两者相等且 $k=1$ 时, ρ_n 最大,此时 $\rho_n=0.5$, B_{nm} 取最小值 0.5,因此不论 k 值大小以及共生次数多少,都保证了 GCN 更新该标签自身节点时的权重不会小于其相关标签的权重。GCN 更新标签节点时,若主要相关标签的权重大,则聚合该相关标签节点表示的程度高。共生次数越高的标签,其分类器应该越相似,在更新节点信息时聚合程度应该越高,因此对于某一特定的标签,它与主要相关标签的共生次数越多,分配给该主要相关标签的权重就应该越大。式(6)将共生概率 ρ_n 按照标签与其主要相关标签的共生次数分配给不同标签,对于某一标签的其中一个主要相关标签,其更新权重为共生概率 ρ_n 乘以该标签与该主要相关标签的共生次数占该标签与所有主要相关标签的共生次数的比重,该标签与该主要相关标签的共生次数越多,该主要标签的更新权重越大,GCN 更新该标签节点信息时聚合该主要相关标签节点信息程度越高,则两者分类器越相似。

一方面,式(5)根据主要相关标签 ($m \in N_{n,k}$) 的共生强度 $\sum_{m \in N_{n,k}} \rho(m|n)/k$ 计算共生概率 ρ_n 。共生强度

$\sum_{m \in N_{n,k}} \rho(m|n)/k$ 越大, ρ_n 越大,表示标签 n 更容易与其

他标签共生。此时,根据式(6), $B_{nm} = 1 - \rho_n$ 较小,图卷积更新时[式(1)]节点本身权重小,更新后的节点更多地关注其他相邻节点,分类器 \mathbf{H}_n^L 与其他分类器更加靠近。这意味着对于预测结果为缺陷 n 的样本,更容易输出其他缺陷。另一方面,式(6)根据共生标签的共生程度不同构造标签图 \mathbf{B} , 标签 m 和 n 共生程度较高时, B_{nm} 较大。因此,改进的标签图能够更加合理地引导分类器 \mathbf{H}^L 捕捉标签之间的共生关系。

2.4 损失函数

所提模型使用二值交叉熵损失函数,每个样本的损失函数为

$$\begin{cases} L = \sum_{n=1}^C y_n \ln \hat{y}_n + (1 - y_n) \ln(1 - \hat{y}_n) \\ \hat{y} = \sigma(\mathbf{H}^L \mathbf{x}) = \sigma[f_{\text{GCN}}(\mathbf{H}^0, \mathbf{B} | \mathbf{W}) f_{\text{CNN}}(\mathbf{I} | \boldsymbol{\Theta})] \end{cases}, \quad (7)$$

式中: \hat{y} 代表网络预测值。

通过最小化损失函数优化 CNN 模块 $f_{\text{CNN}}(\cdot)$ 的参数 $\boldsymbol{\Theta}$ 和 GCN 模块 $f_{\text{GCN}}(\cdot)$ 的参数 \mathbf{W} , 优化过程可以表示为

$$(\boldsymbol{\Theta}^*, \mathbf{W}^*) = \arg \min_{\boldsymbol{\Theta}, \mathbf{W}} L. \quad (8)$$

式(8)引导模型同时学习样本的特征表达和每个标签的分类器。通过优化 $\boldsymbol{\Theta}$, CNN 模块学习样本特征表达;通过优化 \mathbf{W} , GCN 模块学习将标签图映射成保持标签语义拓扑结构的分类器。

3 实验与分析

3.1 实验设置

实验数据来自本实验组采集的排水管道 CCTV 检测视频。从视频中截取无缺陷的正常样本图像 4000 张,缺陷样本 1557 张。缺陷标签包括变形、破裂、渗漏、异物穿入、障碍物、树根障碍及混凝土结块 7 种。数据增强方面^[17],采用随机水平、垂直翻转将数据集扩大 2 倍,扩充后的数据集按照 6:2:2 的比例划分为训练集、验证集、测试集,数据集样本和标签数量如表 1 所示。

表 1 数据集划分
Table 1 Dataset partition

Item	Training set	Validation set	Testing set
Picture number	6668	2223	2223
Label number	3154	1067	1055

所提 ILG-GCN 模型包括 CNN 和 GCN 模块。CNN 模块采用 ImageNet 数据集上预训练的 ResNet-101^[18] 作为主干网络,输出 2048 维特征。参考文献[19]的设置,GCN 模块中的图卷积层数 L 取 2。 L 过大容

易造成标签过平滑问题; L 太小则节点聚合作用不够, 导致相关缺陷的分类器相似度不高^[20]。设置第 1 层图卷积输出维度 $D_1 = 1024$, 第 2 层图卷积输出维度 $D_L = D_2 = 2048$ 。标签词向量选择 GloVe. 6B, 构造词向量时, 采用词向量叠加的方式。例如“管道变形”的词向量为“管道”的词向量加“变形”的词向量。概率阈值 τ 取 0.3, 主要相关标签数量 k 取 2。模型训练阶段, 随机初始化 GCN 参数 \mathbf{W} , 学习率和数据集迭代次数分别取 0.001, 100。测试和验证阶段, 当 $\hat{y}_n > 0.5$ 时, 认为图像具有标签 n 。所提模型采用 Python 3.6 语言和 Pytorch1.8 深度学习库实现, 在配备 GTX1080 GPU 的工作站上运行。

参考现有 MLL 研究^[21], 模型评价指标采用每个标签类别的平均准确率 (AP) 和所有标签的总体平均准确率 (mAP)。一个标签类别的 AP 值越高表示模型检测这个标签的性能越强。mAP 反映模型检测所有标签的平均性能, mAP 越大代表模型综合性能越好。为获得稳定实验结果, 每次实验重复 5 次, 汇报 5 次结果的均值。

3.2 实验 1: 参数寻优

式(6)中的 τ 用于判断两个标签是否相关, 是影响模型检测性能的重要参数。设置不同的 τ 将得到不同的标签图, 从而影响分类器 \mathbf{H}^L 。若 τ 较大, 标签图 \mathbf{B} 仅保留较强的标签共生关系 [即 $p(m|n)$ 较大时], 标签关系无法得到充分利用, 容易造成缺陷漏检。若 τ 较小, 标签图 \mathbf{B} 中表达了大量较弱的标签共生关系 [即 $p(m|n)$ 较小时], 造成每个标签的分类器考虑多个其他标签, 容易导致标签过平滑。用于评价标签条件概率 $p(m|n)$ 的 $\tau \in (0, 1]$, 不同 τ 值条件下的验证集 mAP 值如图 3 所示。




图 3 不同 τ 值的精度比较

Fig. 3 Accuracy comparison of different τ values

从图 3 可以看出, $\tau = 1$ 时模型 mAP 值较低。这是因为 τ 为 1 时 $B_{nm} = 0$, 模型忽略了全部标签关系, 无法准确预测共生标签。随着 τ 减小, 模型 mAP 值逐步提高, 说明考虑标签关系能够提高模型的缺陷检测性能。当 $\tau < 0.3$ 时, 模型 mAP 值降低, 说明过度考虑较弱的标签关系将引起标签过平滑问题, 造成管道缺陷检测性能。因此, 模型取 $\tau = 0.3$ 。

式(5)中的主要相关标签数量 k 是计算自适应共生概率 ρ_n 的关键参数, 对标签图有重要影响。如果 k 值较大, 模型同时考虑多个条件概率 $p(m|n)$ 较低的弱相关标签 m , 造成 ρ_n 较小, 容易降低对重要相关标签的关注程度。如果 k 值较小, 模型仅关注条件概率 $p(m|n)$ 较高的相关标签 m , 造成 ρ_n 较大, 容易导致标签过平滑问题。由于管道缺陷标签数量为 7, $k \in [1, 6]$ 。不同 k 值条件下的验证集 mAP 值如图 4 所示。




图 4 不同 k 值的精度比较

Fig. 4 Accuracy comparison of different k values

从图 4 可以看出, $k = 2$ 时模型获得最佳 mAP 值, 说明考虑两个主要相关标签定义共生概率能够合理捕捉管道缺陷的标签关系, 获得较高检测性能。因此, 模型取 $k = 2$ 。当 $k = 2$ 时, 表示标签的共生概率考虑前两个主要相关标签。假如一个标签有三个主要相关标签, 该标签根据式(5)由前两个共生强度更大的主要相关标签计算共生概率, 得到共生概率后, 根据每个主要相关标签的共生强度分配 GCN 更新节点时的权重, 共生强度更小的标签虽然不会参与共生概率的计算, 但也会分配到权重, 其权重小于共生强度更大的标签的权重。

3.3 实验 2: 管道缺陷检测性能

为验证所提 ILG-GCN 模型的管道缺陷检测性能, 采用下列 MLL 方法进行对比实验:

1) CNN 模型。去除所提模型中的 GCN 模块, 仅用 CNN 实现多标签学习, 通过 Sigmoid 函数输出标签预测概率。

2) 结合递归神经网络 (RNN) 的模型, 包括 CNN-RNN^[22]、递归显著性增强模型 (RAR)^[23]。递归网络仅考虑低阶标签关系。

3) 现有 GCN 模型^[24]。现有 GCN 模型使用流行的 ML-GCN 模型, ML-GCN 提取图像特征部分使用 CNN 模块, CNN 模块使用预训练的 ResNet-101 模型, GCN 更新节点时, 采用人工定义的常数共生概率计算标签图。相比 RNN, GCN 能够捕提高阶标签关系。

4) CNN-GCN 模型。文献[15]提出一种经典的 CNN-GCN 模型, 该模型 CNN 部分使用预训练的 DenseNet-169 模型, GCN 部分使用两层 GCN, 最后输出维度为 1664 维。

5) VGG-Sewer 模型^[25]。VGG-Sewer 是针对排水

管道缺陷检测问题提出的一种深度学习模型,以 VGG-16 为基础,在最后两个全连接层之间加入一个全连接层,该全连接层具有 1024 个神经元。

6) 所提 IGL-GCN 模型。采用设计的自适应共生概率计算标签图。

表 2 列出了不同模型对每种标签的 AP 值及对所有标签的 mAP 值。从表 2 可以看出: CNN 模型对于各类缺陷的 AP 值及 mAP 值 (87.3%) 均较低,说明忽略标签关系难以准确预测管道中同时存在的多种缺陷。考虑标签关系的 CNN-RNN、RAR 及 ML-GCN 模型均提高了缺陷检测性能。CNN-RNN 使用 RNN 对 CNN 输出进行序列预测,考虑了缺陷间的二阶关系, CNN-RNN 模型检测准确率优于 ResNet-101,说明利用缺陷标签关系可以提高模型检测准确率。相比 CNN-

RNN, ML-GCN 将 mAP 提高了 2.6 个百分点。这是因为 GCN 能够表达高阶标签关系,保持分类器的语义拓扑结构,具有更强的管道缺陷检测性能。相比 ML-GCN, 所提模型 mAP 值提升了 1.7 个百分点,达到了最佳性能。这是因为所提模型设计的改进的标签图为每类缺陷分配自适应共生概率,能够反映不同标签共生概率的差异,更加合理表达缺陷标签的关系。实验结果表明,改进的标签图能够提高管道缺陷检测能力。相比 CNN-GCN, ILG-GCN 模型 mAP 值提升了 1.5 个百分点,这是因为虽然 CNN-GCN 使用不同的预训练模型提取图像特征,但挖掘标签关系时,依然使用人工定义的常数共生概率计算标签图,不能准确反映标签之间的关联。即,所提模型可以更加充分利用标签关系,捕捉不同标签间存在的关联以及其关联的程度。

表 2 各模型的 AP 与 mAP
Table 2 AP and mAP of each model

unit: %

Model	Deformation	Fracture	Leakage	Penetration	Obstacle	Root	Concrete	mAP
CNN	91.1	91.5	83.3	75.4	90.7	89.1	90.2	87.3
CNN-RNN	94.0	95.8	85.3	80.8	94.5	94.2	94.4	91.3
RAR	94.5	96.9	89.5	85.3	96.6	93.8	95.6	93.2
ML-GCN	94.1	95.8	90.9	86.6	96.8	97.5	95.8	93.9
CNN-GCN	93.9	96.0	91.1	87.0	97.1	97.9	95.9	94.1
VGG-Sewer	91.3	92.2	82.7	74.9	91.7	89.4	90.9	87.6
ILG-GCN	95.7	98.4	93.7	89.8	96.5	97.3	97.9	95.6

与 VGG-Sewer 相比, ILG-GCN 模型 mAP 值提升了 8 个百分点,且检测每类缺陷的 AP 值均有所提升,其中检测异物穿入的 AP 值提高了 14.9 个百分点。实验结果表明,针对管道缺陷检测问题,所提方法有效提高了检测精度。

3.4 实验 3: 分类器与标签图可视化

ILG-GCN 模型使用 GCN 学习保持标签语义拓扑结构的分类器,使具有共生关系的标签的分类器相似。为验证模型保持分类器语义结构的能力,通过 t 分布随机领域嵌入算法 (t-SNE) 展示模型学习到的分类器,结果如图 5 所示。[图 5(a)] 中的分类器来自 CNN

网络中最后一个全连接层的参数。数据集中变形与破裂标签共生频次较高,变形与障碍物共生频次较低。[图 5(b)] 中变形与破裂标签的分类器距离较近,变形与障碍物标签的分类器距离较远。相比而言, CNN 模型分类器则无法保持分类器的语义拓扑结构。实验结果表明, ILG-GCN 能够保持分类器语义结构,迫使频繁共现的标签具有相似分类器,这有利于准确检测管道中同时存在的多种缺陷。

所提模型为每个标签计算自适应共生概率 ρ , 设计了一种改进的标签图,图 6 展示了改进前后的标签

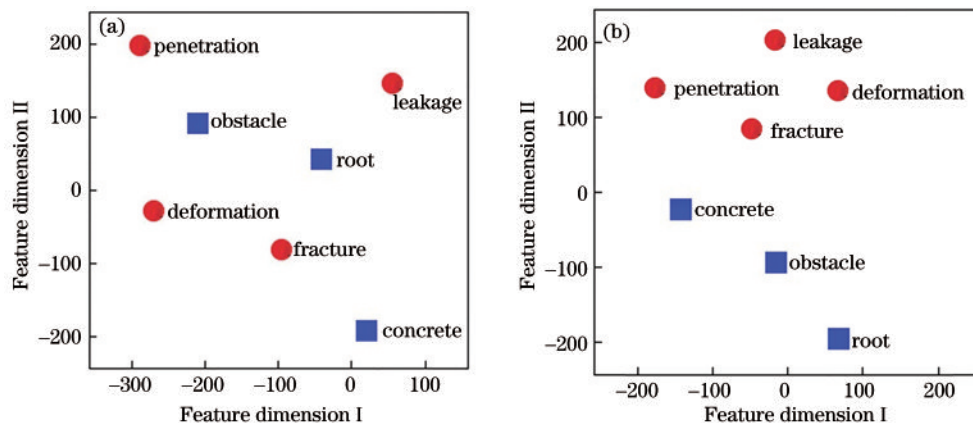


图 5 分类器可视化对比。(a) CNN 模型学习到的分类器; (b) ILG-GCN 模型学习到的分类器

Fig. 5 Classifier visual comparison. (a) Classifiers learned from CNN model; (b) classifiers learned from ILG-GCN model

图。在[图 6(a)]中,人工设置的共生概率 $\rho = 0.25$, 对角线元素 B_{mm} 均为 0.75(1-0.25)。ML-GCN 模型对所有标签赋予相同的共生概率,忽略了标签共生强度的差异。[图 6(b)]中,变形、渗漏、破裂标签的共生概率分别为 0.286(1-0.714)、0.292(1-0.708)、0.346(1-0.654),这些标签的共生概率被提高。渗漏标签和破裂标签是变形标签的共生标签,ILG-GCN 模型根据其共生程度不同,赋予了不同的 B_{mm} , 分别为 0.135、0.152。因此,对于具有共生关系的变形、渗漏、破裂等

标签,改进标签图能够自适应增强对相关标签的关注程度,达到准确预测多个标签的效果。

图 7 展示了部分管道缺陷检测例子。从图 7 可以看出,ML-GCN 模型漏检了部分管道缺陷,改进标签图的 ILG-GCN 模型完整检出了多个缺陷。这是因为式(5)根据标签与其主要相关标签共生的次数计算该标签的自适应共生概率。如果标签与其他标签频繁共现,在 GCN 更新节点信息时,相比现有标签图,ILG-GCN 增加该节点聚合相邻节点信息的程度,使其分类

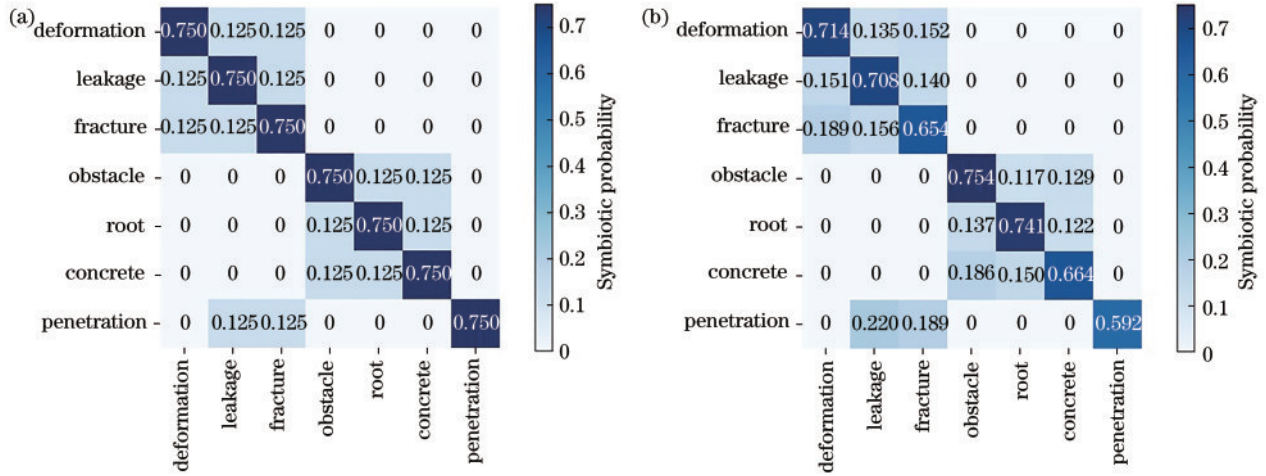


图 6 标签图对比。(a)ML-GCN 模型采用的标签图;(b)ILG-GCN 采用的改进标签图

Fig. 6 Label graph comparison. (a) Label graph adopted by existing GCN model; (b) improved label graph adopted by ILG-GCN model




图 7 模型预测结果对比。(a)样本真实标签;(b)ML-GCN 模型预测结果;(c)ILG-GCN 模型预测结果

Fig. 7 Comparison of model prediction results. (a) True label of sample; (b) prediction results of ML-GCN model; (c) prediction results of ILG-GCN model

器更加相似,从而提高预测共生标签的概率。式(6)根据标签与其共生标签的共生次数为每个共生标签分配不同的权重值,使 GCN 在更新节点信息时,根据标签与其共生标签的共生次数来决定该标签节点聚合某一特定共生标签节点信息的程度。如果两标签频繁共现,则标签节点聚合该共生标签节点信息的程度高,反之,则聚合程度低,改进的标签图使各个标签的分类器根据共现程度决定相似度,从而提高检测准确率。实验结果表明,ILG-GCN 模型设计的改进标签图能够自适应地关注相关标签,减少缺陷漏检。

4 结 论

针对 CNN 模型忽略标签关系,难以准确检测排水管道多种缺陷的问题,提出了一种基于改进标签图的 GCN 管道缺陷检测模型。所提模型构造 GCN 模块保持分类器的语义拓扑结构,同时定义自适应共生概率计算标签图。实验结果表明,GCN 模块能够迫使具有共生关系的缺陷标签分类器互相接近,准确检测管道中同时存在的多种缺陷。改进的标签图通过为每个标签定义自适应的共生概率,提高了模型关注相关标签的能力,有利于减少缺陷漏检。下一步拟研究标签缺失条件下的 MLL 问题^[26],降低人工标注管道图像的劳动强度。

参 考 文 献

- [1] Yang K H, She C W, Zhang W, et al. Multi-label learning based on transfer learning and label correlation [J]. Computers, Materials & Continua, 2019, 61(1): 155-169.
- [2] 张爱武, 刘路路, 张希珍. 道路三维点云多特征卷积神经网络语义分割方法 [J]. 中国激光, 2020, 47(4): 0410001.
Zhang A W, Liu L L, Zhang X Z. Multi-Feature 3D Road Point Cloud Semantic Segmentation Method Based on Convolutional Neural Network [J]. Chinese Journal of Lasers, 2020, 47(4): 0410001(in chinese)
- [3] 李文健, 盖绍彦, 俞健, 达飞鹏. 基于卷积神经网络的单帧复合图像绝对相位恢复 [J]. 光学学报, 2021, 41(23): 2312001.
Li W J, Gai S Y, Yu J, Da F P. Absolute Phase Recovery of Single Frame Composite Image Based on Convolutional Neural Network [J]. Acta Optica Sinica, 2021, 41(23): 2312001.
- [4] 陈永, 郭红光, 艾亚鹏. 基于多尺度卷积神经网络的单幅图像去雾方法 [J]. 光学学报, 2019, 39(10): 1010001.
Chen Y, Guo H G, Ai Y P. Single image dehazing method based on multi-scale convolution neural network [J]. Acta Optica Sinica, 2019, 39(10): 1010001.
- [5] 袁坤, 霍力. 用于视网膜 OCT 图像分层的多尺度补全卷积神经网络 [J]. 中国激光, 2021, 48(15): 1507004.
Yuan K, Huo L. Multiple-Scale Inpainting Convolutional Neural Network for Retinal OCT Image Segmentation [J]. Chinese Journal of Lasers, 2021, 48(15): 1507004.
- [6] 王洪斌, 肖嵩, 曲家慧, 等. 基于多分支 CNN 的高光谱与全色影像融合处理 [J]. 光学学报, 2021, 41(7): 0710001.
Wang H B, Xiao S, Qu J H, et al. Pansharpening based on multi-branch CNN [J]. Acta Optica Sinica, 2021, 41(7): 0710001.
- [7] 李冉. 基于语义图模型的跨语言网络信息检索方法研究 [J]. 周口师范学院学报, 2020, 37(2): 100-103.
Li R. Research on cross language web information retrieval method based on semantic graph model [J]. Journal of Zhoukou Normal University, 2020, 37(2): 100-103.
- [8] 刘晓玲, 刘柏嵩, 王洋洋, 等. 基于深度学习的多标签生成研究进展 [J]. 计算机科学, 2020, 47(3): 192-199.
Liu X L, Liu B S, Wang Y Y, et al. Research and development of multi-label generation based on deep learning [J]. Computer Science, 2020, 47(3): 192-199.
- [9] 李锋, 杨有龙. 基于标签特征和相关性的多标签分类算法 [J]. 计算机工程与应用, 2019, 55(4): 48-55.
Li F, Yang Y L. Multi-label classification algorithm based on label-specific features and label correlation [J]. Computer Engineering and Applications, 2019, 55(4): 48-55.
- [10] 黄友文, 万超伦, 冯恒. 基于卷积神经网络与长短期记忆神经网络的多特征融合人体行为识别算法 [J]. 激光与光电子学进展, 2019, 56(7): 071505.
Huang Y W, Wan C L, Feng H. Multi-feature fusion human behavior recognition algorithm based on convolutional neural network and long short term memory neural network [J]. Laser & Optoelectronics Progress, 2019, 56(7): 071505.
- [11] Luo J Q, He B, Ou Y, et al. Topic-based label distribution learning to exploit label ambiguity for scene classification [J]. Neural Computing and Applications, 2021, 33: 16181-16196.
- [12] Liu Y S, Chen W Y, Qu H, et al. Weakly supervised image classification and pointwise localization with graph convolutional networks [J]. Pattern Recognition, 2021, 109: 107596.
- [13] Chen B Z, Li J X, Lu G M, et al. Label co-occurrence learning with graph convolutional networks for multi-label chest X-ray image classification [J]. IEEE Journal of Biomedical and Health Informatics, 2020, 24(8): 2292-2302.
- [14] He T, Jin X M. Image emotion distribution learning with graph convolutional networks [C] // Proceedings of the 2019 on International Conference on Multimedia Retrieval, June 10-13, 2019, Ottawa, ON, Canada. New York: ACM Press, 2019: 382-390.
- [15] Xie K Z, Wei Z Q, Huang L, et al. Graph convolutional networks with attention for multi-label weather recognition [J]. Neural Computing and Applications, 2021, 33: 11107-11123.
- [16] 王江安, 何娇, 庞大为. 基于动态图卷积网络的点云分类和分割网络 [J]. 激光与光电子学进展, 2021, 58(12): 1215008.
Wang J G, He J, Pang D W. Point cloud classification

- and segmentation network based on dynamic graph convolutional network[J]. *Laser & Optoelectronics Progress*, 2021, 58(12): 1215008.
- [17] 员娇娇, 胡永利, 孙艳丰, 等. 基于深度学习的小目标检测方法综述[J]. *北京工业大学学报*, 2021, 47(3): 293-302.
- Yun J J, Hu Y L, Sun Y F, et al. Survey of small object detection methods based on deep learning[J]. *Journal of Beijing University of Technology*, 2021, 47(3): 293-302.
- [18] 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, June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE Press, 2016: 770-778.
- [19] Ou G J, Yu G X, Domeniconi C, et al. Multi-label zero-shot learning with graph convolutional networks[J]. *Neural Networks*, 2020, 132: 333-341.
- [20] 廖文龙, 于贇, 王煜森, 等. 基于图卷积网络的配电网无功优化[J]. *电网技术*, 2021, 45(6): 2150-2160.
- Liao W L, Yu Y, Wang Y S, et al. Reactive power optimization of distribution network based on graph convolutional network[J]. *Power System Technology*, 2021, 45(6): 2150-2160.
- [21] 牟甲鹏, 蔡剑, 余孟池, 等. 基于标签相关性的类属属性多标签分类算法[J]. *计算机应用研究*, 2020, 37(9): 2656-2658, 2673.
- Mu J P, Cai J, Yu M C, et al. Label-correlation based multi-label classification algorithm with label-specific features[J]. *Application Research of Computers*, 2020, 37(9): 2656-2658, 2673.
- [22] Wang J, Yang Y, Mao J H, et al. CNN-RNN: a unified framework for multi-label image classification[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition, June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE Press, 2016: 2285-2294.
- [23] Chen T S, Wang Z X, Li G B, et al. Recurrent attentional reinforcement learning for multi-label image recognition[EB/OL]. (2017-12-20)[2021-02-03]. <https://arxiv.org/abs/1712.07465>.
- [24] Chen Z M, Wei X S, Wang P, et al. Multi-label image recognition with graph convolutional networks[C]//2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 15-20, 2019, Long Beach, CA, USA. New York: IEEE Press, 2019: 5172-5181.
- [25] 吕兵, 刘玉贤, 叶绍泽, 等. 基于卷积神经网络的 CCTV 视频中排水管道缺陷的智能检测[J]. *测绘通报*, 2019 (11): 103-108.
- Lü B, Liu Y X, Ye S Z, et al. Convolutional-neural-network-based sewer defect detection in videos captured by CCTV[J]. *Bulletin of Surveying and Mapping*, 2019 (11): 103-108.
- [26] Ma Z C, Chen S C. Expand globally, shrink locally: discriminant multi-label learning with missing labels[J]. *Pattern Recognition*, 2021, 111: 107675.