DOI:10.20040/j.cnki.1000-7709.2025.20250407

基于 DyGKAN 图神经网络的供水管网泄漏定位模型

汪 淋,李 宁

(安徽建筑大学环境与能源工程学院,安徽 合肥 230000)

摘要:为探究 DyGKAN 图神经网络在供水管网模拟泄漏定位方面的效果,提出了基于 DyGKAN 图神经供水管网泄漏定位模型,该模型在对特征的捕捉过程中优化了注意力机制的计算流程,能够更好地评估邻居节点特征的重要性。同时,在时间维度上,设计了多尺度时间卷积模块(MTCN)捕捉不同周期变化特征,从而实现时间维度上多尺度特征的融合。此外,在解码器部分,采用了 KAN 神经网络,其激活函数动态变化的特点显著提升了模型的非线性捕捉能力和表达能力。进而在案例管网上进行模拟泄漏,利用布置在管网节点上的压力传感器捕捉节点特征,输入模型进行训练,借助对管道的分类和回归指标,验证了 DyGKAN 模型的有效性。最后利用此模型与其他模型对案例管网进行泄漏定位试验,试验证明 DyGKAN 模型的定位效果显著,定位误差小于 5%,定位精度在 90%以上。

关键词:供水管网;泄漏定位;多尺度时间卷积;注意力机制;图神经网络

中图分类号:TV672^{+}.2 **文献标志码**:A **文章编号**:1000-7709(2025)12-0147-05

1 引言

城市供水管网作为城市生存和发展的物质基础,被誉为城市的“生命线”。其正常运行和有效工作不仅是城市保持活力的先决条件之一,而且与市民的生活、工作和工业生产等方面密切相关。然而,随着城市化进程的加快和人口增长,供水管网的压力不断增加,泄漏问题也日益突出。据统计,我国许多地区的供水管网漏损率已经超过15%,远高于相关标准规范中规定的不应超过10%的均值漏损率[1]。如此高的漏损率,既浪费了宝贵的水资源,又降低了水资源利用效率,还增加了供水企业的运维成本,影响了其经济效益。供水管网漏损导致大量水资源浪费,通过减少漏损,可以提高水资源的利用效率,促进水资源的可持续利用,这对于缓解我国水资源紧张的局面具有重要意义。DyGKAN 模型是一个动态图神经网络模型,是由 GATv2(GAT 改进版)图神经网络结合 KAN 神经网络组成的定位模型。在编码器部分,分别对时间和空间进行建模,利用 GATv2 图注意力网络来捕捉图结构信息[2];在时间部分,考虑到时间的多尺度特征,在 MTGNN 中设置了 4 种不同大小的卷积核,这样就能在卷积运算时捕捉到不同尺度的时间变化信息,从而达成时间维度上多尺度特征的融合捕捉;在解码器部分,选用 KAN 神经网络(激活函数在神经元节点上,且每个节点的激活函数随训练动态变化)来提高非线性捕获能力。该模型解决了静态图神经网络(GCN)在供水管网泄漏捕捉时空特征方面的不足[3],特别是对时间多尺度特征和空间结构信息的建模能力有限的问题。鉴此,本文引入了改进版的图注意力网络 GATv2 模块,验证了 DyGKAN 模型在空间和时间 2 个维度上的优越性能,并通过试验分析验证了模型的有效性。

2 研究方法

2.1 结构自注意力机制优化

GATv2 是针对图注意力网络(GAT)的改进版本,其核心优化在于动态注意力计算机制的引入。多头自注意力机制网络结构模块见图 1。GATv2 注意力权重计算函数为:

$$e(\boldsymbol{h}_v,\boldsymbol{h}_u)=\boldsymbol{a}^{\mathrm{T}}\mathrm{LeakyReLU}(\boldsymbol{W}\cdot[\boldsymbol{h}_v\,||\,\boldsymbol{h}_u]) \tag{1}$$

式中,$\boldsymbol{h}_v$、$\boldsymbol{h}_u$ 分别为节点 v、u 的特征向量;$\boldsymbol{a}$ 为可学习的注意力参数向量;$\boldsymbol{W}$ 为可学习的权重矩阵(线变换)。

收稿日期:2025-03-06,**修回日期**:2025-04-17

作者简介:汪淋(1989-),男,硕士,研究方向为水处理理论与技术,E-mail:626437226@qq.com

中国知网 https://www.cnki.net

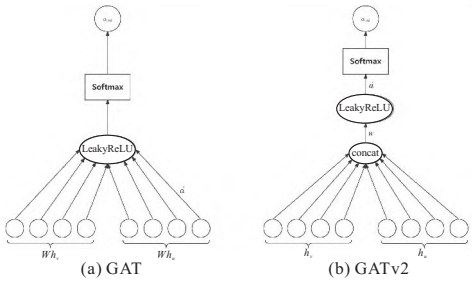

(a) GAT (b) GATv2

图 1 多头自注意力机制

Fig. 1 Multiple self-attention mechanism

其计算过程为先拼接再线性变换，增强对查询节点的动态适应能力，最后通过 LeakyReLU 非线性激活函数与注意力权重矩阵 $\boldsymbol{a}^{\mathrm{T}}$ 计算得到节点 u 的特征向量对节点 v 特征向量的注意力权重。

进行管网模拟泄漏时生成的时间序列压力值为多维度传感器数据[3]，可提取统计特征为 D 维的特征向量，再进行节点特征矩阵构建。所有节点的压力特征向量组合为 $\boldsymbol{X}\in R^{|V|\times D}$，将其输入到 DyGKAN 模型中。

2.2 多尺度时间卷积模块

如图 2 所示，为了进一步捕捉其传感器信息

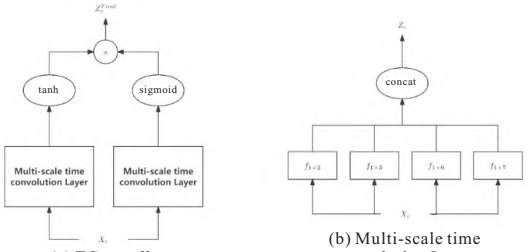

(a) TC moudle (b) Multi-scale time convolution Layer

图 2 多尺度时间卷积模块

Fig. 2 Multiscale time convolution module

随不同时间尺度变化的规律，设置了一个多尺度时间卷积模块，由 2 个并行的扩张一维卷积层，分别使用不同的激活函数。这 2 个扩张初始化一维卷积层中，1 个以 tanh 作为滤波器，用于特征提取；另 1 个是以 sigmoid 作为封闭滤波器，生成范围为[0,1]的权重，充当特征选择器。两分支输出逐元素相乘(Hadamard 积)，公式为：

$$\boldsymbol{O}_{\mathrm{Output}}=\tanh(\boldsymbol{W}_1\cdot\boldsymbol{x}+\boldsymbol{b}_1)\odot \mathrm{sigmoid}(\boldsymbol{W}_2)\cdot\boldsymbol{x}+\boldsymbol{b}_2 \tag{2}$$

式中，$\boldsymbol{O}_{\mathrm{Output}}$ 为输出向量；tanh(·)为双曲正切激活函数，输出范围为(−1,1)；$\boldsymbol{W}_1$、$\boldsymbol{W}_2$ 均为权重矩阵；$\boldsymbol{x}$ 为输入向量(特征向量)；$\boldsymbol{b}_1$、$\boldsymbol{b}_2$ 分别为偏置向量(对应 2 个线性变换的偏置项)；sigmoid(·)为激活函数，输出范围为(0,1)；⊙为逐元素相乘，实现自适应特征加权。

对于 MTGNN 中的 TC 模块设置，由于其时间信号的特殊性，将固有周期 7、12、24、28、60 的卷积核大小分别设置为 1×2、1×3、1×6、1×7。这 4 种不同尺度的卷积核可以捕捉到不同时间尺度的变化规律。

Z^{Final} 是在多尺度卷积处理后的最后一个卷积层输出，这一层的输出通常用于最终的分类或回归任务。作为多尺度卷积处理的最后一环，提供了经过多层卷积和池化后的最终特征表示，这些特征对于后续供水管网泄漏定位中的分类和回归任务至关重要，最终会影响泄漏位置的精准定位。

2.3 KAN 解码模块

结构维度和时间维度的特征表示已经通过前面的编码部分获得。此时，为了配合下游的分类和回归任务，给出 MLP 与 KAN 模块网络图(图 3)。MLP 与 KAN 模块计算公式为：

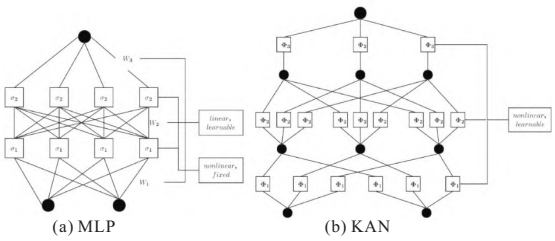

(a) MLP (b) KAN

图 3 MLP 与 KAN 模块

Fig. 3 MLP and KAN module

$$\mathrm{MLP}(\boldsymbol{x})=(\boldsymbol{W}_{L-1}\circ\sigma\circ\boldsymbol{W}_{L-2}\circ\sigma\cdots\circ\boldsymbol{W}_1\circ\sigma\circ\boldsymbol{W}_0)\boldsymbol{x} \tag{3}$$

式中，MLP($\boldsymbol{x}$)为多层感知机(MLP)对输入向量 $\boldsymbol{x}$ 的输出结果；$\boldsymbol{W}_0,\boldsymbol{W}_1,\cdots,\boldsymbol{W}_{L-1}$ 分别为 MLP 每一层的权重矩阵。

KAN 神经网络为每个权重构建了一个独立函数，从而提高了网络的灵活性和表达能力。一个典型的 L 层 KAN 网络处理输入 $\boldsymbol{x}$ 并生成输出的过程为：

$$\mathrm{KAN}(\boldsymbol{x})=(\Phi_{L-1}\circ\Phi_{L-2}\circ\cdots\circ\Phi_1\circ\Phi_0)\boldsymbol{x} \tag{4}$$

式(4)为 KAN 神经网络为权重构建的函数，激活函数位于节点上，Φ_L 为第 1 个 KAN 层的函数矩阵或预激活集，L 为网络总层数，每个 Φ_i 层包含多个可学习的单变量函数，通过层级复合逐步提取特征，层间采用动态可学习的稀疏连接模式。

2.4 损失函数

Z^{Final} 输入 KAN 网络后，分别连接 2 个 KANlinear 线性层，分别得到分类预测值(即对应的故障管道编号)和回归预测值(即具体的管道泄漏点位置)，然后将真实值与预测值进行比较，通过交叉熵损失函数(cross entropy loss)计算分类过程的损失，通过均方误差损失函数(MSE)计算

中国知网 https://www.cnki.net

回归过程的损失,最终合并它们的损失得到混合损失。图 4 为分类和回归的损失计算模型。

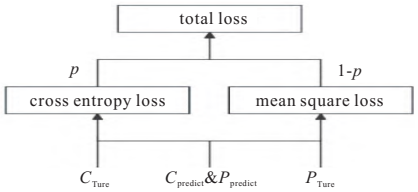

图 4　分类与回归混合损失

Fig. 4　Categorical and regression mixed losses

2.5　基于 DyGKAN 的供水管网泄漏定位模型

选择 python 软件包 WNTR 来模拟泄漏并收集相应数据。首先读取 inp 格式的管网文件,并将管网运行时间设为 48 h。然后将每条管道随机抽取 100 个符合正态分布的泄漏点,将泄漏持续时间随机设置为正态分布,从而获得符合随机泄漏点的标签和持续时间的异常节点传感器信号数据样本,将数据集送入模型中进行训练,并通过 AdamW 自适应学习率的特点,自动调整每个参数的学习率,这对于图神经网络中的不同类型的节点和边的特征学习非常有用。此外,余弦退火学习策略通过动态调整学习率,有助于模型更好地捕捉图结构中的复杂关系,提高预测准确性。DyGKAN 模型结构训练见图 5。

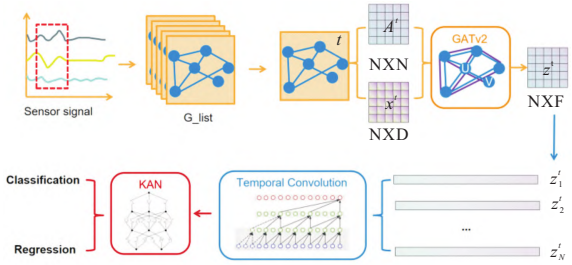

图 5　DyGKAN 模型结构训练

Fig. 5　DyGKAN model structure training

3　试验结果与分析

在案例管网节点 50、109、217、259 布置传感器(图 6),并进行数据模拟。

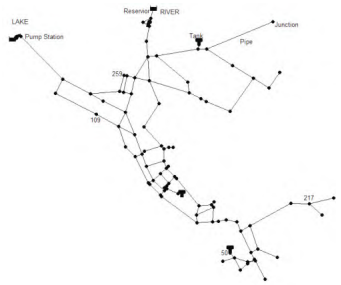

图 6　试验管网

Fig. 6　Experimental pipeline network

3.1　模型框架比较

模型框架比较的目的是比较 RNN、TCN、Transformer 这 3 个传统的框架[4],并用 KAN 代替这 3 个模型框架中的解码器部分进行比较。在案例管网上的模型框架比较结果见表 1。表 1 中,A_{ACC} 为准确率;R^2 为决定系数。

表 1　模型框架比较

Tab. 1　Comparison of modeling frameworks

模型	指标	数值	模型	指标	数值
LSTM	A_{ACC}	0.826 5	Transformer	A_{ACC}	0.860 9
	R^2	0.805 1		R^2	0.807 2
LSTM+KAN	A_{ACC}	0.859 7	Transformer+KAN	A_{ACC}	0.883 5
	R^2	0.793 3		R^2	0.817 8
TCN	A_{ACC}	0.792 2	DyGKAN+KAN	A_{ACC}	0.911 9
	R^2	0.784 3		R^2	0.902 6
TCN+KAN	A_{ACC}	0.882 6			
	R^2	0.826 9			

由表 1 可看出,DyGKAN 模型框架对案例管网产生的泄漏数据进行训练时,在分类和回归方面比其他模型表现更好。为了全面比较结构和时间 2 个独立建模模块在模型架构中的有效性,还进行了结构模块和时间模块的对比试验。

3.2　结构模块比较

在结构模块中,选择 GCN、GAT、Graphsage 这 3 种经典图神经网络算法进行比较[5]。在保留原有 DyGKAN 多尺度时间模块的基础上,将其 DyGKAN 替换为 3 个结构模块,试验结果见表 2。

表 2　结构模块比较

Tab. 2　Comparison of structural modules

模型	GCN+MTCN		GAT+MTCN		Graphsage+MTCN		DyGKAN+MTCN	
	A_{ACC}	R^2	A_{ACC}	R^2	A_{ACC}	R^2	A_{ACC}	R^2
数值	0.895 7	0.877 6	0.903 3	0.897 8	0.905 7	0.901 7	0.911 9	0.902 6

由表 2 可知,DyGKAN 模块为最好的模块,其效果在各方面均优于 GCN。但值得注意的是,Graphsage 的“先采样后聚合”模式可以使其在大规模图上的性能超过 GAT 模块,因为它使用的信息是多跳邻居,这可以捕捉到多阶邻居的特征。

3.3　时序模块比较

对于时间模块的比较,选择了 LSTM、TCN(非多尺度)和 Transformer 来替代多尺度时间卷积。

试验结果见表 3。由表 3 可知,多尺度时间卷积模块(MTCN)性能是最好的。

表 3　时序模块比较

Tab. 3　Comparison of timing module

模型	DyGKAN+LSTM		DyGKAN+TCN		DyGKAN+Transformer		DyGKAN+MTCN	
	A_{ACC}	R^2	A_{ACC}	R^2	A_{ACC}	R^2	A_{ACC}	R^2
数值	0.865 2	0.815 8	0.896 0	0.849 9	0.900 4	0.897 2	0.911 9	0.902 6

中国知网　https://www.cnki.net

在模型框架比较中(表 1),DyGKAN 在分类和回归任务上的准确率 A_{ACC} 和决定系数 R^2 值均优于传统的 LSTM、TCN、Transformer 模型框架,此模型在大中型且复杂管网的泄漏定位表现更为突出。进一步的对比试验显示(表 2),GATv2 模块在结构信息捕捉方面优于 GCN 和 Graphsage,在时序模块比较中(表 3),多尺度时间卷积模块在时间特征捕捉方面也显著优于 LSTM、Transformer 和非多尺度 TCN。这验证了 DyGKAN 模型在空间、时间 2 个维度上的优越性能。

3.4 管网泄漏定位试验

将 DyGKAN 供水管网泄漏定位模型与 TCN、Transformer(GCN 改进版)模型作对比,从这 3 种模型训练得到的分类以及回归相关指标可以看出,DyGKAN 模型在管网的定位性能上表现出色,显示出 DyGKAN 模型在定位精度上的优势。

为了验证 DyGKAN 模型的定位效果,在案例管网中选择 5 条管道开展了泄漏模拟,并与 Transformer、TCN 模型框架进行对比。对于分类效果,用混淆矩阵表示,见图 7(a)~(c)。由图 7(a)~(c)可知,DyGKAN 的效果明显优于 2 种传统方法。对于回归效果,使用散点图表示,见图 7(d)。由图 7(d)可知,DyGKAN 的点更多地集中在完美曲线上,因此具有更好的回归定位效果。

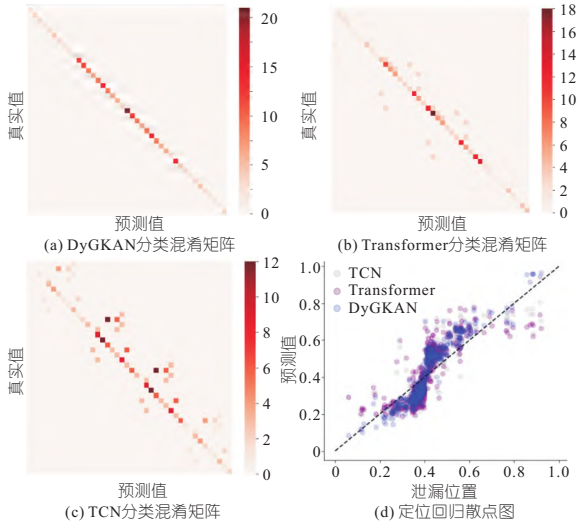

图 7 DyGKAN、Transformer、TCN 分类混淆矩阵及其定位回归散点图

Fig. 7 DyGKAN, Transformer and TCN classification confusion matrix and scatterplot of the three model localization regressions

泄漏点位置的确定方式就是将泄漏点所在管段两端节点中数值较小的节点视为管段左端点,将数值较大的节点看作管段右端点,距离左端点的长度与管段总长度的比值用来表示泄漏点的位置。为了科学地评估模型定位的准确度,模型引入了绝对值误差百分比(E_{Error})概念,表示预测泄漏点与实际泄漏点的误差比[6]。其公式为:

$$E_{Error}=\frac{\left|p_{predict_value}-p_{position_value}\right|}{p_{pipe_length}}\times 100 \quad (5)$$

式中,$p_{predicted_value}$ 为预测的泄漏位置;$p_{position_value}$ 为真实的泄漏位置;p_{pipe_length} 为发生泄漏的管道总长度。

表 4 为不同模型对管网 Large 泄漏定位误差。由表 4 可知,DyGKAN 模型的定位效果优于 Transformer、TCN 模型。

表 4 不同模型对管网 Large 泄漏定位误差

Tab. 4 Leak localization errors of different models for Large pipe networks

管道 ID	管长/m	泄漏位置/m	Transformer		TCN		DyGKAN	
			预测位置/m	误差/%	预测位置/m	误差/%	预测位置/m	误差/%
60	375.21	96.18	113.38	4.58	116.65	5.46	106.72	2.81
109	1 200.91	388.51	374.94	1.13	349.42	3.26	364.39	2.01
121	569.98	175.79	192.90	3.00	195.04	3.38	190.61	2.60
131	987.55	511.03	535.48	2.47	539.30	2.86	527.58	1.68
175	886.97	435.27	461.41	2.95	472.03	4.14	455.23	2.25

4 结论

a. DyGKAN 模型在模拟供水管网泄漏定位中表现出色,实现了对供水管网泄漏压力数据的时间和空间特征的精细提取,此模型为实际供水管网泄漏定位提供了一种创新且有效的解决方案。

b. 在定位效果方面,传感器的布置位置与泄漏点的时空距离也会最终影响定位误差,因此未来应尝试将此模型与传感器布置情况相结合来综合研究定位效果。管网泄漏模拟时,数据提取只有压力值,结合流速等数据多维度输入模型展开试验,为进一步的研究方向。另外,本文的泄漏为单泄漏,还可展开多点泄漏试验。并建立类似于 fourierGNN 的超变量图来同步建模,在更多更大的管网中进行试验。

参考文献:

[1] 陈健勋. 城市供水管网漏失特性模拟及评价[D]. 哈尔滨:哈尔滨工业大学, 2020.

[2] VELIČKOVIĆP, CUCURULL G, CASANOVA A, et al. Graph attention networks[EB/OL]. 2017: arXiv: 1710.10903. https://arxiv.org/abs/1710.10903.

[3] KIPF T N, WELLING M. Semi-supervised classi-

中国知网 https://www.cnki.net

fication with graph convolutional networks[EB/OL]. 2016:arXiv:1609.02907. https://arxiv.org/abs/1609.02907.

[4] ZHOU X,TANG Z H,XU W R,et al. Deep learning identifies accurate burst locations in water distribution networks[J]. Water research,2019,166:115058.

[5] HAMILTON W L, YING R, LESKOVEC J. Inductive representation learning on large graphs[EB/OL]. 2017:arXiv:1706.02216. https://arxiv.org/abs/1706.02216.

[6] 张杰. 基于深度学习的城市供水管网泄漏定位技术的研究[D]. 长春: 吉林大学, 2023.

Leakage Localization Model for Water Supply Network Based on DyGKAN Graph Neural Network

WANG Lin,LI Ning

(School of Environmental and Energy Engineering, Anhui Jianzhu University, Hefei 230000, China)

Abstract: In order to explore the effect of the DyGKAN graph neural network in simulating leakage localization in water supply pipe network, a leakage localization model of water supply pipe network based on DyGKAN graph neural is proposed. The computational process of attention mechanism was optimized in the process of DyGKAN's feature capture, which is capable of better assessing the importance of the features of neighboring nodes. Meanwhile, in the time dimension, a multi-scale time convolution module (MTCN) was designed to capture different period-varying features, so as to realize the fusion of multi-scale features in the time dimension. In addition, in the decoder part, the KAN neural network was adopted, whose dynamic change of activation function significantly improves the nonlinear capturing ability and expression ability of the model. By simulating leakage on the case pipe network, the node features were captured using pressure sensors arranged on the nodes of the pipe network and input into the model for training, with the help of classification and regression metrics on the pipes in order to verify the effectiveness of the DyGKAN model. Finally, leakage localization experiments were carried out on the case pipe network using this model and other models, and the experiments proved that the DyGKAN model is effective in localization, with a localization error of less than 5% and a localization accuracy of more than 90%.

Key words: water supply network; leak localization; multi-scale time convolution; attention mechanisms; graph neural network

(上接第 185 页)

Photogrammetric Deformation Monitoring and Residual Effects Analysis of Steel Bifurcated Pipes Under Multi-Cycle Hydraulic Pressure Loading Tests

FAN Qin-hong[1,2], WU Wei-ping[3]

(1. Zhengzhou Chenwei Science and Technology Co., Ltd., Zhengzhou 450001, China; 2. College of Surveying and Geo-Informatics, North China University of Water Resources and Electric Power, Zhengzhou 450046, China; 3. National Center of Quality Inspection & Testing for Hydraulic Steel Structure Ministry of Water Resources, Zhengzhou 450044, China)

Abstract: To investigate the deformation characteristics and residual effects of high-strength steel bifurcated pipes under multi-cycle loading, photogrammetric technology was employed for high-precision deformation monitoring. By analyzing the magnitude of deformation of each monitoring point under different internal water pressures, residual deformation, residual deformation rate, and deformation linear coefficient , the plastic deformation of the structure and the effectiveness of residual stress elimination were systematically evaluated. These findings were further corroborated by residual stress measurements in the weld zones obtained using X-ray diffraction (XRD). The results demonstrate that photogrammetry can effectively capture the deformation process of the steel bifurcated pipe, with the maximum deformation not exceeding 3.6 mm. Following the second loading cycle, the linear relationship between deformation and water pressure became more pronounced, and the residual deformation rate decreased significantly, indicating that multiple loading cycles effectively promoted the homogenization of residual stresses.

Key words: steel bifurcated pipe; hydraulic test; photogrammetry; deformation monitoring; residual effects; residual deformation; residual stress

中国知网　https://www.cnki.net