

文章编号: 1671-7449(2025)03-0354-09

J. Test Measur. Technol., 2025, 39(3): 354-362.

结合水力仿真与神经网络的供热管网阻塞诊断

杨佳霖, 赵鹏翔, 王冰, 李娜, 郭东旭

(国网综合能源服务集团有限公司, 北京 100052)

摘要: 为了准确诊断供热管网阻塞故障, 提升供热系统的运行可靠性, 提出了基于水力仿真与神经网络的阻塞诊断方法。首先, 为了获得大量表征管网阻塞运行特征的数据样本, 基于水力仿真建立了阻塞仿真专家数据库; 其次, 结合表征学习和管网实际数据获得了管网实际水力特征, 并建立了阻塞表征专家数据库; 最后, 基于已建立的数据库训练并测试了卷积神经网络阻塞诊断模型。以某城市实际供热管网为案例进行了研究, 结果表明, 阻塞表征数据可有效表达管网实际水力特征, 以仿真数据和表征数据为样本, 卷积神经网络阻塞诊断准确率大于85%。

关键词: 区域供热管网; 阻塞故障诊断; 表征学习; 卷积神经网络; 水力工况仿真

中图分类号: TU995 **文献标识码:** A **doi:** 10.62756/csjs.1671-7449.2025044

引用格式: 杨佳霖, 赵鹏翔, 王冰, 等. 结合水力仿真与神经网络的供热管网阻塞诊断[J]. 测试技术学报, 2025, 39(3): 354-362.

YANG Jialin, ZHAO Pengxiang, WANG Bing, et al. Blockage diagnosis of heating-networks based on hydraulic simulation and neural-network[J]. Journal of Test and Measurement Technology, 2025, 39(3): 354-362.

Blockage Diagnosis of Heating-Networks Based on Hydraulic Simulation and Neural-Network

YANG Jialin, ZHAO Pengxiang, WANG Bing, LI Na, GUO Dongxu

(State Grid Integrated Energy Service Group Co., Ltd., Beijing 100052, China)

Abstract: To diagnose the blocking fault of the heating network accurately and improve the operation reliability of the heating system, a diagnosis method was proposed based on hydraulic simulation and neural networks. Firstly, to obtain a large number of data samples representing the features of heating-network blockage operation, the blockage simulation expert database was established based on hydraulic simulation. Secondly, the actual hydraulic features of the heating network were obtained by combining representation learning and the heating network's actual data, and the blockage representation expert database was established. Finally, a convolutional neural-network blockage diagnosis model was trained and tested based on the established database. An urban actual heating network was selected as a study case. The results show that the blockage representation data can effectively express the actual hydraulic features of the heating network. The accuracy of diagnosing blockages using simulation data and representation data as samples exceeded 85%.

Key words: district heating network; blockage fault diagnosis; representation learning; convolutional neural-network; hydraulic condition simulation

收稿日期: 2024-07-30

基金项目: 国网综合能源服务集团有限公司科技项目(527899220008)

作者简介: 杨佳霖(1986-), 男, 高级工程师, 博士, 主要从事综合能源系统集成与运行优化、新能源发电智能化管控技术等研究。

E-mail: jjalin1998@126.com。

0 引言

在区域集中供热系统中,随着供热管网运行时长的增加,其阻塞故障发生率不断上升^[1]。管网阻塞会降低管道内部压力和流量,降低系统供热能力并增加系统不必要的能耗;此外,还会引起水温过高、热交换器损坏等问题,将产生一定的安全隐患^[2]。及时准确地诊断管网阻塞对于保证用户的供热需求、减少系统能耗并维持系统安全稳定的运行状态具有重要意义。

近年来,相关学者开展了大量管网故障诊断研究并取得了一系列成果,然而多数故障诊断方法仅针对泄漏故障。由于阻塞故障对管网运行的影响具有高度的潜在性和隐蔽性,一直未受到研究人员的重视,因而对阻塞故障的研究较少。现有阻塞故障诊断方法可概括为两类:基于物理测量的诊断方法和大数据驱动的诊断方法。

在基于物理测量的诊断方法方面,李宁^[3]采用排水管道液位监测网络研究了管道阻塞前后的液位变化规律,然后根据实验数据建立判别模型以实现阻塞辨识定位;陈卓等^[4]采用高精度的管网供水压力监测仪来查找长距离输水管道的阻塞点。此外,还有管道视频监测技术^[5-6],该技术将搭载摄像头的爬行器注入管道,通过检查井来获取管道内视频及照片资料,从而实现人工识别阻塞故障。基于物理测量的方法虽然取得了一定的故障诊断效果,但其弊端亦逐渐显现:数据监测仪表的布置阵列需根据多样的管段拓扑、地形等情况合理设计,限制了该类方法的适用面;管道管径尺寸及管道内异物的影响会降低视频监测技术识别阻塞的准确性。

在大数据驱动的阻塞诊断方法方面,单文啸^[7]结合管网故障压力数据和BP神经网络建立了诊断模型;王妍等^[8]将管网故障模拟和神经网络相结合对管网故障位置和类型进行诊断;段兰兰等^[9]建立了管网故障模型并生成故障样本数据,而后采用遗传优化的BP神经网络算法定位故障点。然而这类方法存在的问题是:未考虑不同类型数据的特征预处理技术;实际管网缺失大量的阻塞运行数据,导致大数据算法的训练数据样本分布存在严重的不平衡,这使得算法无法全面捕捉管网的故障运行特征。此外,大多数阻塞诊断仅局限于安装有测量仪表的位置,导致阻塞诊断的普遍性不足。

综上所述,基于物理测量的诊断效果易受到测

量精度以及外部安装条件的影响,大数据驱动的方法则存在训练数据过少、数据特征提取效果低下等问题。为了解决上述问题,本文提出了一种新的结合过程机理建模和神经网络表征的管网阻塞诊断方法。该研究弥补了阻塞诊断研究的缺失,相对于传统阻塞诊断研究,所提方法具有以下创新点:1)基于水力仿真和表征学习建立了管网阻塞专家数据库,解决了实际条件下阻塞数据缺失的问题;2)考虑了潜在的阻塞管段,保证了数据库中各个阻塞情况在管网供热范围内的普遍性和典型性,同时阻塞数据样本分布均衡,解决了传统大数据方法中由于样本分布不平衡导致的阻塞特征学习不充分的问题;3)在阻塞诊断数据集中融合了仿真数据与表征数据,弥补了传统仿真过程中因参数理想化假设而导致的数据特征失真的缺陷;4)结合专家数据库和卷积神经网络建立了阻塞诊断模型,该模型能有效提取管网阻塞专家数据库中的阻塞水力特征,同时提高了阻塞诊断的时效性。

1 管网阻塞诊断方法

本文提出了基于水力仿真与神经网络的管网阻塞诊断方法,该法包括特征变量的选择、阻塞专家数据库的建立以及卷积神经网络阻塞诊断。

1.1 特征变量的选择

本文对管网阻塞进行诊断研究,因此,采用的特征变量应能够良好地表达管网阻塞水力运行特征。本文采用压力和流量作为特征变量,因为管网在运行中是一个处于动态平衡的整体,其压力和流量分布在物理和空间层面具有较强的相关性。当某管段发生阻塞时,该管段的流量减少,压力迅速增大,管网水力平衡被打破,会迅速寻找新的平衡状态并重新分配压力和流量。因此,相对于其他变量,二者可以更加有效地表达管网水力运行特征。

1.2 管网阻塞仿真专家数据库的建立

通过管网水力仿真获得了管网在不同阻塞情况下压力和流量的分布情况,以此建立了管网阻塞仿真专家数据库,采用的水力仿真模型如下。

供热管网与供电网络类似,其管段流量、压降和阻力特性系数类似电网中的电流、电压和电阻。根据图论理论并结合表征管路特性的基尔霍夫定律,可推得对于任意供热管网,支路数为 m ,

节点数为 $n+1$ ，其水力工况的基本计算模型为^[10]

$$\begin{aligned} AG &= Q, B_f \Delta H = 0, \\ \Delta H &= S|G|G + Z - DH, \end{aligned} \quad (1)$$

式中： $A_{n \times m}$ 为代表管网拓扑结构的关联矩阵； $B_{f(m-n) \times m}$ 为管网的基本回路矩阵； G 为管段的流量向量， m^3/h ； ΔH 为管段压降向量， kPa ； S 为管段阻力特性系数对角矩阵， $kPa/(m^3/h)^2$ ； Z 为支路中两节点间位差向量， kPa ； DH 为管段水泵扬程向量， kPa 。

基于水力仿真模型，获得了管网在各个阻塞工况下供水压力、回水压力以及流量的分布情况。

1.3 管网阻塞表征专家数据库的建立

本文建立阻塞表征专家数据库的步骤如图1所示。

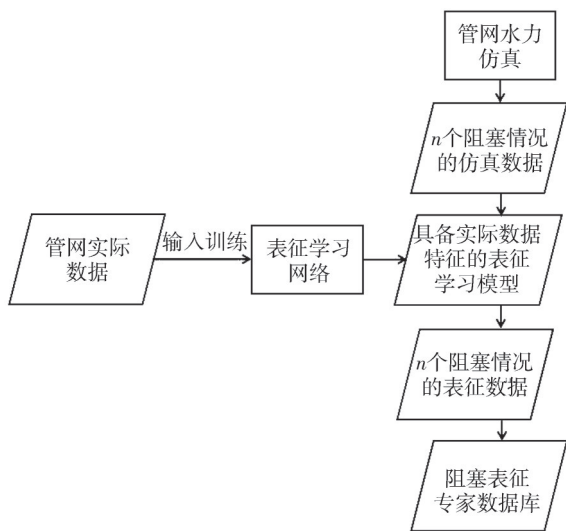


图1 管网阻塞表征专家数据库的建立步骤

Fig. 1 Steps of establishing heating-network blockage representation expert database

图1中的核心方法为表征学习网络。在机器学习领域，由于人工神经网络具有良好的泛化能力和特征学习能力，且能有效反映输入与输出之间的非线性关系，因此被广泛应用于模式识别、语音处理等研究领域^[11]。本文基于人工神经网络的表征学习模型来学习管网实际数据的特征并生成阻塞表征数据(详见2.3节)。该模型包含两部分：编码网络和解码网络，其结构如图2所示。

图2中， x_1, x_2, \dots, x_n 为网络输入特征变量，在本文中代表管网压力和流量， n 为特征变量的个数， y_1, y_2, \dots, y_n 为网络输出特征变量。该网络学习热网水力特征的步骤如下：

输入特征变量经过各个编码层神经元以及连接权重的运算后，其内在特征关系被层层抽取，

最终转化为少量高级变量。而后这些变量会经过各个解码层神经元以及权重的运算，该过程会重构变量的特征关系，并将高级变量转换为与输入变量数量相同的输出变量。基于输出变量与输入变量的误差来调整权重系数，最终获得了可反映热网运行特征的表征学习网络。综合考虑表征学习时间、输入特征变量数量等因素后，本文采用的表征学习网络结构为3个编码层+3个解码层，其训练规则详见文献[12-13]。




图2 表征学习网络结构

Fig. 2 Structure of representation-learning network

1.4 卷积神经网络阻塞诊断方法

所提管网阻塞诊断包含数据预处理和卷积神经网络。诊断步骤如图3所示。

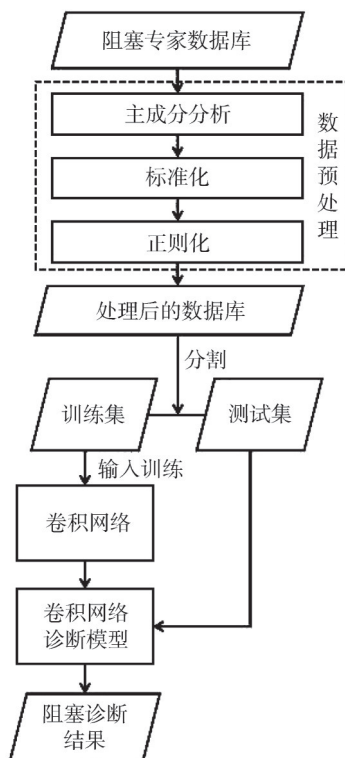


图3 管网阻塞诊断流程

Fig. 3 Steps of heating-network blockage diagnosis

1.4.1 数据预处理

供热管网在运行时,其压力和流量的分布具有较强的物理和空间相关性。此外,压力与流量还具有量纲差异性、数据分布的高维性等特征。

基于上述分析可知,管网压力与流量分布具有高维异构相关的复杂特征。为了保证数据特征的一致性,本文针对压力与流量进行了预处理,首先采用主成分分析方法^[14],通过线性运算将二者映射到统一的特征空间;基于此空间采用标准化^[15]和正则化^[16]重构数据特征分布,将压力与流量转换到统一的特征尺度。

1.4.2 卷积神经网络

在机器学习领域,相较于其他算法,卷积神经网络具有强大的特征提取能力、局部感知能力和高维特征学习能力^[17],因此,本文采用卷积神经网络诊断管网阻塞,该网络包括两个组成部分:卷积层和全连接层。

1) 卷积层

卷积层的输入是数据预处理后的特征变量,其每个神经元节点均连接到输入特征变量的一个子集,子集数量由卷积接受野的大小决定。对于有 a 个卷积接受野的卷积层,每个神经元通过卷积核运算获得节点输出,运算规则为^[18]

$$z_i = b_i + f\left(\sum_{i=1}^a \omega_i y_i\right), \quad (2)$$

式中: ω_i 为第 i 个卷积神经元的权重系数; b_i 为卷积核偏置量。

2) 全连接层

全连接层的输入是从卷积层获得的特征变量,输出是阻塞诊断结果。本文采用的全连接层的基本结构如图 4 所示。




图 4 全连接层结构图
Fig. 4 Structure of fully connection layer

全连接层的节点和连接权重的训练规则与表征学习网络相同,此处不再赘述。

本文采用准确率(Accuracy)来衡量阻塞诊断效果,其计算公式为

$$Accuracy = \frac{n_{correct}}{n_{total}} \times 100\%, \quad (3)$$

式中: $n_{correct}$ 为诊断正确的样本数量; n_{total} 为卷积网络测试集的样本数量。

2 案例分析

2.1 供热管网简介

本文研究案例选自某城市实际供热管网,其管线分布如图 5 所示。




图 5 某城市实际供热管网分布图
Fig. 5 Distribution of an urban actual heating-network

由图5可以看出,该管网是包含8个热用户的单热源双分支网络,在热源侧和所有用户侧安装有供水压力表、回水压力表和流量计,水流自热源流出后,经过供水干管分别流向用户1和用户5两侧。流经用户的水流在经过换热器释放热量后由回水干管收集,并由循环水泵泵回热源,如此往复循环。




图6 管网仿真数据与实际数据分布

Fig. 6 Distributions of heating-network simulation data and actual data

由图6可知,管网仿真压力和实际压力的分布趋势基本一致,仿真流量与实际流量亦有此规律。经计算,管网压力与流量的仿真值和实际值的相对误差绝对值均小于15%。上述结果表明了本文水力仿真的有效性,即仿真数据能够有效地反映实际数据的分布情况。

2.3 管网阻塞专家数据库的建立

在建立阻塞专家数据库时,考虑到当前对于管网干管阻塞诊断的研究较少,且干管阻塞对管网运行的不利影响相对于支路阻塞更大,故设定管网中所有干管为潜在的阻塞管段。为了准确衡量阻塞程度,根据管道管径增加的百分比设定了3个阻塞等级^[19-20],分别为:1%表示轻微阻塞,10%表示中等阻塞,20%表示严重阻塞。此外,为了检验诊断单管段阻塞以及多管段阻塞的效果,阻塞专家库中的阻塞工况包含单管段阻塞、两管段阻塞和三管段阻塞。由于阻塞位置和阻塞程度的自由组合较多,为简化计算,本文选取了100个阻塞情况进行诊断研究,包含45个单管段阻塞+30个两管段阻塞+25个三管段阻塞。

本文分别建立了由仿真数据组成的阻塞仿真专家数据库和由表征学习模型生成的阻塞表征专家数据库。为了选择最佳的表征学习网络运算参数,以最小化表征数据与仿真数据的平均绝对百分比误差为目标^[21],采用adam优化算法^[22]进行了大量的实验与分析。最终采用的各层神经元节点

2.2 管网水力工况仿真

本文依据1.1节中的水力工况仿真模型对管网压力和流量进行仿真。为了验证水力仿真的有效性,将仿真数据与实际数据对比研究,结果如图6所示。

数量和激活函数如表1所示。

表1 表征学习网络各层运算参数

Tab. 1 Operation parameters of representation-learning network layers

表征学习网络层	神经元节点数量	激活函数
编码层1	200	relu
编码层2	100	selu
编码层3	20	selu
解码层1	20	selu
解码层2	100	relu
解码层3	200	relu

为了获得100个阻塞情况对应的仿真数据,采用2.2节的水力仿真对管网在每个阻塞情况下压力和流量的分布进行仿真。每一个数据样本为一个序列,自前向后依次为用户供水压力、用户回水压力和用户流量,故样本的特征变量个数为24(8×3)。

为了保证数据样本的均衡性,每个阻塞情况仿真了5000组总流量相同、总压力不同的运行数据。将500000组(100×5000组)阻塞仿真数据导入具备管网实际数据特征的表征学习模型,生成了500000组对应的阻塞表征数据。该表征数据具备了管网实际数据特征,这是因为:表征学习网络内部的神经元和连接权重系数的运算规则会在管网实际数据特征学习过程中不断调整,最终实际特征便体现在这些运算规则中,当阻塞仿真数据样本被输入训练好的表征学习网络中,仿真数据会经过神经元和连接权重的一系列运算,实际特征便会被赋予到仿真数据。

为了进一步验证阻塞表征数据表征管网实际阻塞数据的能力,分别选取了单管段阻塞、两管段阻

塞和三管段阻塞各一个,将仿真数据和对应的表征数据对比研究,结果如图 7~图 9 所示。




图 7 单管段阻塞仿真数据和表征数据分布图

Fig. 7 Distributions of simulation data and representation data for single-pipeline blockage




图 8 两管段阻塞仿真数据和表征数据分布图

Fig. 8 Distributions of simulation data and representation data for double-pipeline blockage




图 9 三管段阻塞仿真数据和表征数据分布图

Fig. 9 Distributions of simulation data and representation data for triple-pipeline blockage

由图 7~图 9 可知,无论是单管段阻塞、两管段阻塞还是三管段阻塞,实际压力与表征压力的分布趋势基本一致,实际流量与表征流量基本接近。此结果说明由表征学习模型生成的表征数据不仅符合水力仿真的分布趋势,而且具有管网实际数据特征,因而可以代表管网实际阻塞数据。

2.4 管网阻塞诊断结果与分析

为了探究仿真数据和表征数据对于卷积网络

训练效果和测试结果的影响,分别以阻塞表征专家数据库和二者的混合数据库为数据集建立了管网阻塞诊断方法并对诊断结果进行分析。

2.4.1 以表征专家数据库训练和测试的管网阻塞诊断方法

根据图 3 的诊断步骤,利用阻塞表征专家数据库训练并测试了提出的管网阻塞诊断方法。

为了寻找最佳的卷积网络结构和运算参数,以阻塞诊断准确率最高为目标,采用 nadam 参数

优化算法^[23]进行了大量实验与分析,最终确定卷积网络的结构为5层卷积层+3层全连接层。其中卷积核大小、卷积核个数和激活函数如表2所示。


表2 卷积层运算参数

Tab. 2 Operation parameters of convolutional layers


卷积层名称	卷积核大小	卷积核个数	激活函数
卷积层1	4	16	tanh
卷积层2	4	16	tanh
卷积层3	4	64	tanh
卷积层4	4	64	tanh
卷积层5	4	64	tanh

每层全连接层的神经元节点个数为500,激活函数为simnoid函数。设定卷积网络的损失函数为交叉熵函数^[24],其训练迭代次数为30。

卷积网络阻塞诊断效果的优劣程度取决于训练过程是否稳定以及测试准确率大小。为了探究上述问题,本文选取了9组“训练集:测试集”比例,并计算了9组数据集比例下卷积网络的训练损失函数、训练准确率和测试准确率,结果如图10~图11所示。



(a) 训练损失函数



(b) 训练准确率

图10 卷积网络训练结果

Fig. 10 Training results of convolutional neural network

由图10可知,随着训练集比例与迭代次数的增加,训练损失函数逐渐减小,训练准确率逐渐增加。原因是训练样本的增多使卷积网络能更加充分地学习数据特征。然而,图11中的测试准确率较低,且随着数据集比例的变化有较大波动,卷积网络出现了轻微的过拟合现象。




图11 卷积网络测试准确率

Fig. 11 Testing accuracy of convolutional neural network


综上所述,采用阻塞表征专家数据库时,卷积网络虽然能够稳定地进行训练,但无法以较高的准确率诊断阻塞。该结果说明虽然表征数据具备管网实际数据特征,然而,其在卷积网络中的特征表达能力较差,这是因为在管网运行过程中,其实际数据会受到各种扰动的影响,如机械振动、水力冲击以及第三方干扰等等。因此,在实际条件下,当管网水力工况发生变化时,实际数据并不会完全根据工况变化而改变,所以,实际数据特征表达能力相对较差。

2.4.2 以混合数据集训练和测试的管网阻塞诊断方法


基于表征数据较差的特征表达能力,同时为了探究在阻塞诊断过程中仿真数据对表征数据特征表达力的影响,结合两种阻塞专家数据库组成混合数据集来训练和测试提出的管网阻塞诊断方法。仍采用9组数据集比例,训练迭代次数为30,计算了卷积网络的训练损失函数、训练准确率和测试准确率,结果如图12~图13所示。

由图12可知,随着迭代次数和训练集比例的增加,损失函数呈现下降趋势,同时训练准确率呈上升趋势。由图13可知,在9组数据集比例下,阻塞诊断的测试准确率均高于85%,且分布较稳定。该结果表明将仿真数据和表征数据混合后,仿真数据优化了数据集整体的特征表达效果。

原因在于阻塞仿真数据源于水力仿真，其分布完全符合管网水力运行的过程机理且不会受到任何非稳定因素的影响，因此，其表达管网水力特征的能力更强，卷积网络能够有效捕捉并学习该特征。



(a) 训练损失函数



(b) 训练准确率

图 12 卷积网络训练结果

Fig. 12 Training results of convolutional neural-network




图 13 卷积网络测试准确率

Fig. 13 Testing accuracy of convolutional neural-network

3 结 论

管网阻塞会增加供热系统能耗以及系统运行的安全风险。为了高效诊断阻塞，本文提出了一个新的诊断理论架构，即基于水力仿真和神经网络的阻塞诊断。结合案例分析，可得出以下结论：

- 1) 所提出的管网阻塞诊断方法能以较高的准确率诊断管网阻塞故障；
- 2) 管网阻塞专家数据库的建立解决了阻塞数据缺乏以及数据样本分布不平衡的问题；
- 3) 阻塞表征专家数据库不仅符合管网水力仿真的规律，同时具备管网实际数据特征；
- 4) 仿真数据和表征数据的特征分布差异较大，且仿真数据的特征表达能力优于表征数据；
- 5) 本文设置了覆盖整个管网的潜在干管阻塞管段，使得阻塞诊断不再依赖于安装测量仪表的干管实际测量点。

参考文献：

[1] ZHOU S, LIU C, ZHAO Y, et al. Leakage diagnosis of heating pipe-network based on BP neural network [J]. Sustainable Energy, Grids and Networks, 2022, 32: 100869.

[2] 陈贤敏. 浅谈城市集中供热中易发生的故障及应对措施[J]. 城市地理, 2016(7X): 250.
CHEN Xianmin. Discussion on the common faults in urban central heating and the countermeasures [J]. City Geography, 2016(7X): 250. (in Chinese)

[3] 李宁. 村镇污水管道阻塞辨识定位技术研究及应用 [D]. 青岛: 青岛理工大学, 2023.

[4] 陈卓, 王晴, 王轶凡, 等. 长距离输水管线堵塞点查找与分析[J]. 供水技术, 2011, 5(2): 60-61.
CHEN Zhuo, WANG Qing, WANG Yifan, et al. Searching and analysis of blocking point in long distance distribution pipeline [J]. Water Technology, 2011, 5(2): 60-61. (in Chinese)

[5] 李顺安, 李婷, 温慧锋, 等. 南方某市排水管道 CCTV 检测结果分析[J]. 城市勘测, 2022(5): 169-172.
LI Shun'an, LI Ting, WEN Huifeng, et al. Analysis of CCTV detection results of drainage pipelines in a city of Southern China[J]. Urban Geotechnical Investigation & Surveying, 2022(5): 169-172. (in Chinese)

[6] WANG J, LIU G H, WANG J, et al. Current status, existent problems, and coping strategy of urban drainage pipeline network in China[J]. Environmental

- Science and Pollution Research International, 2021, 28 (32): 43035-43049.
- [7] 单文嘯. 基于数据驱动的供热二级管网故障诊断研究[D]. 哈尔滨: 哈尔滨工业大学, 2023.
- [8] 王妍, 卢淑文, 李杰, 等. 基于SDE-BP网络的油田注水管网故障诊断方法研究[J]. 化工机械, 2023, 50 (5): 749-757.
WANG Yan, LU Shuwen, LI Jie, et al. Research on fault diagnosis of oilfield water injection pipeline network based on SDE-BP method [J]. Chemical Engineering Machinery, 2023, 50 (5): 749-757. (in Chinese)
- [9] 段兰兰, 田琦, 段鹏飞, 等. 基于遗传优化BP神经网络的供热管网故障诊断模型[J]. 中北大学学报(自然科学版), 2014, 35(3): 303-308.
DUAN Lanlan, TIAN Qi, DUAN Pengfei, et al. Fault diagnosis model of heating networks based on BP neural network optimized by genetic algorithm [J]. Journal of North University of China (Natural Science Edition), 2014, 35(3): 303-308. (in Chinese)
- [10] ZHOU S, LI H, GONG P, et al. Hydraulic modeling of double-source and ring-shaped heating networks [J]. Applied Thermal Engineering, 2017, 119: 215-221.
- [11] 李沁琳. 人工神经网络综述[J]. 科学与信息化, 2021 (7): 181-182.
LI Qinlin. Review of artificial neural networks [J]. Science and informatization, 2021 (7): 181-182. (in Chinese)
- [12] 周丽华, 王家龙, 王丽珍, 等. 异质信息网络表征学习综述[J]. 计算机学报, 2022, 45(1): 160-189.
ZHOU Lihua, WANG Jialong, WANG Lizhen, et al. Heterogeneous information network representation learning: a survey [J]. Chinese Journal of Computers, 2022, 45(1): 160-189. (in Chinese)
- [13] LI R, ZHANG H, ZHUANG Q, et al. BP neural network and improved differential evolution for transient electromagnetic inversion [J]. Computers Geosciences, 2020, 137: 104434.
- [14] 刘鸿涛, 王皓, 汪金礼, 等. 基于PCA的第二代Curvelet变换域图像降噪研究[J]. 测试技术学报, 2014, 28(2): 143-148.
LIU Hongtao, WANG Hao, WANG Jinli, et al. Image denoising in second generation curvelet transform domain based on PCA [J]. Journal of Test and Measurement Technology, 2014, 28 (2): 143-148. (in Chinese)
- [15] 谭建鑫, 谢前, 井延伟, 等. 风电数据标准化技术及风电大数据应用方法[J]. 微型电脑应用, 2023, 39 (2): 89-92.
TAN Jianxin, XIE Qian, JING Yanwei, et al. Wind power data standardization technology and wind power big data application method [J]. Microcomputer Applications, 2023, 39(2): 89-92. (in Chinese)
- [16] 程万里, 王守东, 孟中钰, 等. 基于 L_1 范数正则化约束的叠前数据衰减补偿方法[J]. 石油地球物理勘探, 2023, 58(3): 567-579.
CHENG Wanli, WANG Shoudong, MENG Jinyu, et al. Prestack data attenuation compensation based on L_1 -norm regularization constraint [J]. Oil Geophysical Prospecting, 2023, 58(3): 567-579. (in Chinese)
- [17] 王建荣, 邓黎明, 程伟, 等. 基于CNN-LSTM-SE的心电图分类算法研究[J]. 测试技术学报, 2024, 38 (3): 264-273.
WANG Jianrong, DENG Liming, CHENG Wei, et al. Study on ECG classification algorithm based on CNN-LSTM-SE [J]. Journal of Test and Measurement Technology, 2024, 38 (3): 264-273. (in Chinese)
- [18] APICELLA A, ISGRÒ F, POLLASTRO A, et al. Adaptive filters in graph convolutional neural networks [J]. Pattern Recognition, 2023, 144: 109867.
- [19] 邢鼎皇, 王海, 杨光. 环状空间供热管网的堵塞故障分析[C]//2022供热工程建设与高效运行研讨会论文集, 2022: 196-205.
- [20] 蒋卫威, 鱼京善, 陈基培, 等. 排水管网系统堵塞与拍门对城市水动力过程的影响研究[J]. 水资源与水工程学报, 2021, 32(1): 143-150.
JIANG Weiwei, YU Jingshan, CHEN Jipei, et al. Impact of discharge pipe system clogging and flap gate on urban hydrodynamic process [J]. Journal of Water Resources and Water Engineering, 2021, 32(1): 143-150. (in Chinese)
- [21] 周云浩, 杨宝杰, 刘丹, 等. 基于随机森林算法的电力工程数据预测分析建模与仿真[J]. 电子设计工程, 2024, 32(4): 103-106.
ZHOU Yunhao, YANG Baojie, LIU Dan, et al. Modeling and simulation of power engineering data prediction and analysis based on Random Forest algorithm [J]. Electronic Design Engineering, 2024, 32 (4): 103-106. (in Chinese)