



(12) 发明专利

(10) 授权公告号 CN 115018021 B

(45) 授权公告日 2023.01.20

(21) 申请号 202210942327.5

(22) 申请日 2022.08.08

(65) 同一申请的已公布的文献号

申请公布号 CN 115018021 A

(43) 申请公布日 2022.09.06

(73) 专利权人 广东电网有限责任公司肇庆供电局

地址 526000 广东省肇庆市端州区77区信安路88号

(72) 发明人 高宜凡 张杰明 陈展尘 陈显超
梁妍陟 刘洋 陈金成 李波
陈忠颖 陈益哲

(74) 专利代理机构 北京集佳知识产权代理有限公司 11227

专利代理师 任文生

(51) Int.Cl.

G06F 30/27 (2020.01)

(56) 对比文件

CN 114818515 A, 2022.07.29

CN 114065862 A, 2022.02.18

CN 113157771 A, 2021.07.23

审查员 古志春

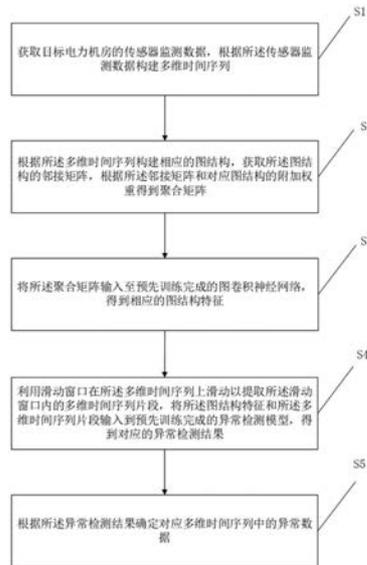
权利要求书3页 说明书15页 附图5页

(54) 发明名称

基于图结构与异常注意力机制的机房异常检测方法及其装置

(57) 摘要

本发明涉及机房检测技术领域,公开了基于图结构与异常注意力机制的机房异常检测方法及其装置。本发明根据目标电力机房的传感器监测数据构建多维时间序列,将序列转换为图结构并获取对应的邻接矩阵,根据邻接矩阵和对应图结构的附加权重得到聚合矩阵,将聚合矩阵输入至预先训练完成的图卷积神经网络,以提取图结构特征;并将多维时间序列片段和图结构特征输入到预先训练完成的异常检测模型,得到对应异常检测结果,进而确定异常数据;其中异常检测模型包括多级编解码模块,每级编解码模块包括基于关联差异的Transformer编码器及解码器,该编码层的注意力模块为带有两分支结构的异常注意力模块。本发明能够有效提高异常检测精度及稳定性。



1. 一种基于图结构与异常注意力机制的机房异常检测方法,其特征在于,包括:
 获取目标电力机房的传感器监测数据,根据所述传感器监测数据构建多维时间序列;
 根据所述多维时间序列构建相应的图结构,获取所述图结构的邻接矩阵,根据所述邻接矩阵和对应图结构的附加权重得到聚合矩阵;
 将所述聚合矩阵输入至预先训练完成的图卷积神经网络,得到相应的图结构特征;
 利用滑动窗口在所述多维时间序列上滑动以提取所述滑动窗口内的多维时间序列片段,将所述图结构特征和所述多维时间序列片段输入到预先训练完成的异常检测模型,得到对应的异常检测结果;
 根据所述异常检测结果确定对应多维时间序列中的异常数据;
 其中,所述异常检测模型包括多级的编解码模块,前一级编解码模块的预测数据与对应真实数据的差值作为后一级编解码模块的输入,每个所述编解码模块包括基于关联差异的Transformer编码器及解码器,所述Transformer编码器是通过将带有两分支结构的异常注意力模块替代Transformer中的注意力模块得到的,所述两分支结构用于同时建模先验关联和序列关联;所述解码器利用多头注意力机制进行解码;所述编解码模块使用附加损失来放大关联差异,相应的损失函数为:

$$L = \min_{\eta, \lambda, w} \left\| h(t) - \hat{h}(t) \right\|^2 + \lambda \left\| \hat{Z}^L - X \right\|^2$$

式中, w 是每个节点附加权重, η 是神经网络的参数, λ 是损失的权衡系数, $h(t)$ 为聚合矩阵通过图卷积神经网络后得到的输出, $\hat{h}(t)$ 为 $h(t)$ 的重建数据, $\left\| \hat{Z}^L - X \right\|^2$ 表示输入序列通过异常检测模型得到的重构损失, \hat{Z}^L 为解码器输出的第L层的隐藏表示, X 为解码器所属编解码模块中的编码器的对应输入序列。

2. 根据权利要求1所述的基于图结构与异常注意力机制的机房异常检测方法,其特征在于,所述根据所述多维时间序列构建相应的图结构,获取所述图结构的邻接矩阵,包括:
 将所述多维时间序列对应的传感器视为图结构中的节点,将传感器之间的相关性视为图结构中节点之间的边,根据图结构中节点与节点之间的相关性构建邻接矩阵。

3. 根据权利要求2所述的基于图结构与异常注意力机制的机房异常检测方法,其特征在于,所述根据图结构中节点与节点之间的相关性构建邻接矩阵,包括:

按照下列相关性度量关系式表示节点与节点之间的相关性:

$$Cor_{ji} = \frac{e_i^T e_j}{\|e_i\| \cdot \|e_j\|} + \log \frac{p(x_i, x_j)}{p(x_i)p(x_j)}, x_j \in C_i$$

式中, Cor_{ji} 表示节点 x_j 与节点 x_i 之间的相关性, e_i 为节点 x_i 与其余节点之间的相关性假设, e_j 为节点 x_j 与其余节点之间的相关性假设, e_i 、 e_j 的取值范围皆为 $0 \sim 1$, $p(x_i, x_j)$ 表示节点 x_j 与节点 x_i 的数据在多维时间序列中一起的数据在多维时间序列中出现的概率, $p(x_i)$ 为节点 x_i 的数据在多维时间序列中出现的概率, $p(x_j)$ 为节点 x_j 的数据在多维时间序列中出现的概率, C_i 为节点 x_i 的相关节点集合。

4. 根据权利要求2所述的基于图结构与异常注意力机制的机房异常检测方法,其特征

在于,所述根据所述邻接矩阵和对应图结构的附加权重得到聚合矩阵,包括:

按照下式得到聚合矩阵:

$$\hat{A} = \alpha A + (1 - \alpha)E$$

式中, \hat{A} 为邻接矩阵A对应的聚合矩阵,E为邻接矩阵A对应图结构的附加权重, α 为预置的图结构复杂性系数, α 的取值范围为0~1。

5.根据权利要求2所述的基于图结构与异常注意力机制的机房异常检测方法,其特征在于,所述图卷积神经网络包括依次连接的卷积层、池化层、全连接层和Sigmoid函数层,所述将所述聚合矩阵输入至预先训练完成的图卷积神经网络,得到相应的图结构特征,包括:

将所述聚合矩阵依次经过卷积层、池化层和全连接层进行处理,得到每个节点的输出特征:

$$G_i^{(t)} = WConv(x_i^{(t)}) + \sum_{j \in N(i)} WConv(x_j^{(t)})$$

式中, $G_i^{(t)}$ 表示节点 x_i 的输出特征, $x_i^{(t)}$ 、 $x_j^{(t)}$ 分别表示聚合矩阵中节点 x_i 、 x_j 的输入特征, $Conv(x_i^{(t)})$ 为 $x_i^{(t)}$ 通过所述卷积层及池化层后得到的结果, $Conv(x_j^{(t)})$ 为 $x_j^{(t)}$ 通过所述卷积层及池化层后得到的结果, $N(i)$ 为由对应邻接矩阵得到的节点 x_i 的邻居节点集合,W为预置的可训练权重矩阵;

将所述每个节点的输出特征经过所述Sigmoid函数层进行处理,得到相应的图结构特征。

6.根据权利要求1所述的基于图结构与异常注意力机制的机房异常检测方法,其特征在于,所述根据所述异常检测结果确定对应多维时间序列中的异常数据,包括:

将所述异常检测结果与对应多维时间序列进行比较以获取异常得分;

若所述异常得分超过预设阈值,将对应数据标记为异常数据。

7.根据权利要求1所述的基于图结构与异常注意力机制的机房异常检测方法,其特征在于,所述方法还包括:

在根据所述多维时间序列构建相应的图结构之前,对所述多维时间序列进行预处理;所述进行预处理包括填充序列缺失数据和/或修正所辨识的异常数据。

8.一种基于图结构与异常注意力机制的机房异常检测系统,其特征在于,包括:

数据获取模块,用于获取目标电力机房的传感器监测数据,根据所述传感器监测数据构建多维时间序列;

数据转换模块,用于根据所述多维时间序列构建相应的图结构,获取所述图结构的邻接矩阵,根据所述邻接矩阵和对应图结构的附加权重得到聚合矩阵;

特征提取模块,用于将所述聚合矩阵输入至预先训练完成的图卷积神经网络,得到相应的图结构特征;

异常检测模块,用于利用滑动窗口在所述多维时间序列上滑动以提取所述滑动窗口内的多维时间序列片段,将所述图结构特征和所述多维时间序列片段输入到预先训练完成的异常检测模型,得到对应的异常检测结果;

异常数据确定模块,用于根据所述异常检测结果确定对应多维时间序列中的异常数

据；

其中，所述异常检测模型包括多级的编解码模块，前一级编解码模块的预测数据与对应真实数据的差值作为后一级编解码模块的输入，每个所述编解码模块包括基于关联差异的Transformer编码器及解码器，所述Transformer编码器是通过将带有两分支结构的异常注意力模块替代Transformer中的注意力模块得到的，所述两分支结构用于同时建模先验关联和序列关联；所述解码器利用多头注意力机制进行解码；所述编解码模块使用附加损失来放大关联差异，相应的损失函数为：

$$L = \min_{\eta, \lambda, w} \left\| h(t) - \hat{h}(t) \right\|^2 + \lambda \left\| \hat{Z}^L - X \right\|^2$$

式中，w是每个节点附加权重， η 是神经网络的参数， λ 是损失的权衡系数， $h(t)$ 为聚合矩阵通过图卷积神经网络后得到的输出， $\hat{h}(t)$ 为 $h(t)$ 的重建数据， $\left\| \hat{Z}^L - X \right\|^2$ 表示输入序列通过异常检测模型得到的重构损失， \hat{Z}^L 为解码器输出的第L层的隐藏表示，X为解码器所属编解码模块中的编码器的对应输入序列。

9. 一种基于图结构与异常注意力机制的机房异常检测装置，其特征在于，包括：

存储器，用于存储指令；其中，所述指令用于实现如权利要求1-7任意一项所述的基于图结构与异常注意力机制的机房异常检测方法；

处理器，用于执行所述存储器中的指令。

10. 一种计算机可读存储介质，其特征在于，所述计算机可读存储介质上存储有计算机程序，所述计算机程序被处理器执行时实现如权利要求1-7任意一项所述的基于图结构与异常注意力机制的机房异常检测方法。

基于图结构与异常注意力机制的机房异常检测方法及装置

技术领域

[0001] 本发明涉及机房检测技术领域,尤其涉及基于图结构与异常注意力机制的机房异常检测方法及装置。

背景技术

[0002] 电力机房作为单位用电端与国家电网的一个中转点,内部集成了包括变压器、发电机、电源控制设备、电源管理设备等众多的对电力设备。电力机房的各设备需要在运行时保证安全平稳,否则一旦某台设备出现故障,将会对电力系统的安全运行构成威胁。因此有关电力机房异常检测技术的研究与应用具有重要的现实意义。

[0003] 传统的电力机房异常检测主要依靠人工巡检的方式,基于数据中心基础设施管理系统故障报警,通过人工查找机房和设备铭牌来确定异常设备位置。这种方法不仅效率低下,而且需要耗费大量人力物力。

[0004] 随着人工智能的发展,现有技术中将深度学习算法应用于电力机房的异常检测领域。基于深度学习的异常检测可以被定义为在数据中自动发现偏离正常行为的实例或模型的问题。深度学习算法作为人工智能的重要部分,能够有效解决大部分传统方法稳定性和泛化性有限的问题。应用深度学习算法解决电力机房的异常检测问题时,往往是基于关于电机机房设备的单维数据,通过循环神经网络(RNN)或者长短期记忆网络(LSTM)网络模型学习时序数据点级别的表征,进而依靠重建误差或预测误差进行判定。然而,此类方法基于单维数据进行深度学习,不能有效捕捉设备之间的运行状态的联系和相关性,容易导致模型预测精度有限及稳定性不足的问题,且所学习的点级别表征信息量较小,并且可能被正常模式主导,使得异常点难以区分,导致异常检测精度较低。

发明内容

[0005] 本发明提供了基于图结构与异常注意力机制的机房异常检测方法及装置,解决了目前基于深度学习网络的机房异常检测方法存在异常检测精度和稳定性不足的缺陷的技术问题。

[0006] 本发明第一方面提供一种基于图结构与异常注意力机制的机房异常检测方法,包括:

[0007] 获取目标电力机房的传感器监测数据,根据所述传感器监测数据构建多维时间序列;

[0008] 根据所述多维时间序列构建相应的图结构,获取所述图结构的邻接矩阵,根据所述邻接矩阵和对应图结构的附加权重得到聚合矩阵;

[0009] 将所述聚合矩阵输入至预先训练完成的图卷积神经网络,得到相应的图结构特征;

[0010] 利用滑动窗口在所述多维时间序列上滑动以提取所述滑动窗口内的多维时间序列片段,将所述图结构特征和所述多维时间序列片段输入到预先训练完成的异常检测模

型,得到对应的异常检测结果;

[0011] 根据所述异常检测结果确定对应多维时间序列中的异常数据;

[0012] 其中,所述异常检测模型包括多级的编解码模块,前一级编解码模块的预测数据与对应真实数据的差值作为后一级编解码模块的输入,每个所述编解码模块包括基于关联差异的Transformer编码器及解码器,所述Transformer编码器是通过将带有两分支结构的异常注意力模块替代Transformer中的注意力模块得到的,所述两分支结构用于同时建模先验关联和序列关联;所述解码器利用多头注意力机制进行解码。

[0013] 根据本发明第一方面的一种能够实现的方式,所述根据所述多维时间序列构建相应的图结构,获取所述图结构的邻接矩阵,包括:

[0014] 将所述多维时间序列对应的传感器视为图结构中的节点,将传感器之间的相关性视为图结构中节点之间的边,根据图结构中节点与节点之间的相关性构建邻接矩阵。

[0015] 根据本发明第一方面的一种能够实现的方式,所述根据图结构中节点与节点之间的相关性构建邻接矩阵,包括:

[0016] 按照下列相关性度量关系式表示节点与节点之间的相关性:

$$[0017] \quad Cor_{ji} = \frac{e_i^T e_j}{\|e_i\| \cdot \|e_j\|} + \log \frac{p(x_i, x_j)}{p(x_i)p(x_j)}, x_j \in C_i$$

[0018] 式中, Cor_{ji} 表示节点 x_j 与节点 x_i 之间的相关性, e_i 为节点 x_i 与其余节点之间的相关性假设, e_j 为节点 x_j 与其余节点之间的相关性假设, e_i 、 e_j 的取值范围皆为0~1, $p(x_i, x_j)$ 表示节点 x_j 与节点 x_i 的数据在多维时间序列中一起的数据在多维时间序列中出现的概率, $p(x_i)$ 为节点 x_i 的数据在多维时间序列中出现的概率, $p(x_j)$ 为节点 x_j 的数据在多维时间序列中出现的概率, C_i 为节点 x_i 的相关节点集合。

[0019] 根据本发明第一方面的一种能够实现的方式,所述根据所述邻接矩阵和对应图结构的附加权重得到聚合矩阵,包括:

[0020] 按照下式得到聚合矩阵:

$$[0021] \quad \hat{A} = \alpha A + (1 - \alpha)E$$

[0022] 式中, \hat{A} 为邻接矩阵A对应的聚合矩阵, E 为邻接矩阵A对应图结构的附加权重, α 为预置的图结构复杂性系数, α 的取值范围为0~1。

[0023] 根据本发明第一方面的一种能够实现的方式,所述图卷积神经网络包括依次连接的卷积层、池化层、全连接层和Sigmoid函数层,所述将所述聚合矩阵输入至预先训练完成的图卷积神经网络,得到相应的图结构特征,包括:

[0024] 将所述聚合矩阵依次经过卷积层、池化层和全连接层进行处理,得到每个节点的输出特征:

$$[0025] \quad G_i^{(t)} = WConv(x_i^{(t)}) + \sum_{x_j \in N(i)} WConv(x_j^{(t)})$$

[0026] 式中, $G_i^{(t)}$ 表示节点 x_i 的输出特征, $x_i^{(t)}$ 、 $x_j^{(t)}$ 分别表示聚合矩阵中节点 x_i 、 x_j 的输入特征, $Conv(x_i^{(t)})$ 为 $x_i^{(t)}$ 通过所述卷积层及池化层后得到的结果, $Conv(x_j^{(t)})$ 为 $x_j^{(t)}$ 通过所述卷积层及池化层后得到的结果, $N(i)$ 为由对应邻接矩阵得到的节点 x_i 的邻居节点集合, W 为预置的可训练权重矩阵;

[0027] 将所述每个节点的输出特征经过所述Sigmoid函数层进行处理, 得到相应的图结构特征。

[0028] 根据本发明第一方面的一种能够实现的方式, 所述根据所述异常检测结果确定对应多维时间序列中的异常数据, 包括:

[0029] 将所述异常检测结果与对应多维时间序列进行比较以获取异常得分;

[0030] 若所述异常得分超过预设阈值, 将对应数据标记为异常数据。

[0031] 根据本发明第一方面的一种能够实现的方式, 所述方法还包括:

[0032] 在根据所述多维时间序列构建相应的图结构之前, 对所述多维时间序列进行预处理; 所述进行预处理包括填充序列缺失数据和/或修正所辨识的异常数据。

[0033] 本发明第二方面提供一种基于图结构与异常注意力机制的机房异常检测装置, 包括:

[0034] 数据获取模块, 用于获取目标电力机房的传感器监测数据, 根据所述传感器监测数据构建多维时间序列;

[0035] 数据转换模块, 用于根据所述多维时间序列构建相应的图结构, 获取所述图结构的邻接矩阵, 根据所述邻接矩阵和对应图结构的附加权重得到聚合矩阵;

[0036] 特征提取模块, 用于将所述聚合矩阵输入至预先训练完成的图卷积神经网络, 得到相应的图结构特征;

[0037] 异常检测模块, 用于利用滑动窗口在所述多维时间序列上滑动以提取所述滑动窗口内的多维时间序列片段, 将所述图结构特征和所述多维时间序列片段输入到预先训练完成的异常检测模型, 得到对应的异常检测结果;

[0038] 异常数据确定模块, 用于根据所述异常检测结果确定对应多维时间序列中的异常数据;

[0039] 其中, 所述异常检测模型包括多级的编解码模块, 前一级编解码模块的预测数据与对应真实数据的差值作为后一级编解码模块的输入, 每个所述编解码模块包括基于关联差异的Transformer编码器及解码器, 所述Transformer编码器是通过将带有两分支结构的异常注意力模块替代Transformer中的注意力模块得到的, 所述两分支结构用于同时建模先验关联和序列关联; 所述解码器利用多头注意力机制进行解码。

[0040] 根据本发明第二方面的一种能够实现的方式, 所述数据转换模块包括:

[0041] 第一数据转换单元, 用于将所述多维时间序列对应的传感器视为图结构中的节点, 将传感器之间的相关性视为图结构中节点之间的边, 根据图结构中节点与节点之间的相关性构建邻接矩阵。

[0042] 根据本发明第二方面的一种能够实现的方式, 所述第一数据转换单元具体用于:

[0043] 按照下列相关性度量关系式表示节点与节点之间的相关性:

$$[0044] \quad Cor_{ji} = \frac{e_i^T e_j}{\|e_i\| \cdot \|e_j\|} + \log \frac{p(x_i, x_j)}{p(x_i)p(x_j)}, x_j \in C_i$$

[0045] 式中, Cor_{ji} 表示节点 x_j 与节点 x_i 之间的相关性, e_i 为节点 x_i 与其余节点之间的相关性假设, e_j 为节点 x_j 与其余节点之间的相关性假设, e_i 、 e_j 的取值范围皆为 0~1, $p(x_i, x_j)$ 表示节点 x_j 与节点 x_i 的数据在多维时间序列中一起的数据在多维时间序列中出现的概率, $p(x_i)$ 为节点 x_i 的数据在多维时间序列中出现的概率, $p(x_j)$ 为节点 x_j 的数据在多维时间序列中出现的概率, C_i 为节点 x_i 的相关节点集合。

[0046] 根据本发明第二方面的一种能够实现的方式, 所述数据转换模块还包括:

[0047] 第二数据转换单元, 用于按照下式得到聚合矩阵:

$$[0048] \quad \hat{A} = \alpha A + (1 - \alpha)E$$

[0049] 式中, \hat{A} 为邻接矩阵 A 对应的聚合矩阵, E 为邻接矩阵 A 对应图结构的附加权重, α 为预置的图结构复杂性系数, α 的取值范围为 0~1。

[0050] 根据本发明第二方面的一种能够实现的方式, 所述图卷积神经网络包括依次连接的卷积层、池化层、全连接层和 Sigmoid 函数层, 所述特征提取模块包括:

[0051] 第一特征提取单元, 用于将所述聚合矩阵依次经过卷积层、池化层和全连接层进行处理, 得到每个节点的输出特征:

$$[0052] \quad G_i^{(t)} = WConv(x_i^{(t)}) + \sum_{x_j \in N(i)} WConv(x_j^{(t)})$$

[0053] 式中, $G_i^{(t)}$ 表示节点 x_i 的输出特征, $x_i^{(t)}$ 、 $x_j^{(t)}$ 分别表示聚合矩阵中节点 x_i 、 x_j 的输入特征, $Conv(x_i^{(t)})$ 为 $x_i^{(t)}$ 通过所述卷积层及池化层后得到的结果, $Conv(x_j^{(t)})$ 为 $x_j^{(t)}$

通过所述卷积层及池化层后得到的结果, $N(i)$ 为由对应邻接矩阵得到的节点 x_i 的邻居节点集合, W 为预置的可训练权重矩阵;

[0054] 第二特征提取单元, 用于将所述每个节点的输出特征经过所述 Sigmoid 函数层进行处理, 得到相应的图结构特征。

[0055] 根据本发明第二方面的一种能够实现的方式, 所述异常数据确定模块包括:

[0056] 异常得分计算单元, 用于将所述异常检测结果与对应多维时间序列进行比较以获取异常得分;

[0057] 异常数据确定单元, 用于若所述异常得分超过预设阈值, 将对应数据标记为异常数据。

[0058] 根据本发明第二方面的一种能够实现的方式, 所述装置还包括:

[0059] 数据预处理模块, 用于在根据所述多维时间序列构建相应的图结构之前, 对所述多维时间序列进行预处理; 所述进行预处理包括填充序列缺失数据和/或修正所辨识的异

常数据。

[0060] 本发明第三方面提供了一种基于图结构与异常注意力机制的机房异常检测装置，包括：

[0061] 存储器，用于存储指令；其中，所述指令用于实现如上任意一项能够实现的方式所述的基于图结构与异常注意力机制的机房异常检测方法；

[0062] 处理器，用于执行所述存储器中的指令。

[0063] 本发明第四方面一种计算机可读存储介质，所述计算机可读存储介质上存储有计算机程序，所述计算机程序被处理器执行时实现如上任意一项能够实现的方式所述的基于图结构与异常注意力机制的机房异常检测方法。

[0064] 从以上技术方案可以看出，本发明具有以下优点：

[0065] 本发明根据目标电力机房的传感器监测数据构建多维时间序列，并将多维时间序列转换为图结构并获取对应的邻接矩阵，根据邻接矩阵和对应图结构的附加权重得到聚合矩阵，将聚合矩阵输入至预先训练完成的图卷积神经网络，以提取图结构特征；并将多维时间序列片段和图结构特征输入到预先训练完成的异常检测模型，得到对应的异常检测结果，进而确定异常数据；其中异常检测模型包括多级编解码模块，每级编解码模块包括基于关联差异的Transformer编码器及解码器；本发明基于多维度输入变量进行异常检测，多维变量能够有效捕捉机房设备之间的运行状态联系和相关性，避免了采用单维数据进行异常检测导致的模型预测精度有限以及稳定性不足的问题；通过建立图结构，将多维时间序列利用有向图表示，使模型能够更有效地学习多维时间数据之间的依赖程度；采用多级编解码模块，能够减少数据过拟合现象，提高模型检测性能的稳定性，其中编码层采用基于关联差异的Transformer编码器，能够提高模型区分正常数据与异常数据的能力，进一步提高模型检测精度。

附图说明

[0066] 为了更清楚地说明本发明实施例或现有技术中的技术方案，下面将对实施例或现有技术描述中所需要使用的附图作简单地介绍，显而易见地，下面描述中的附图仅仅是本发明的一些实施例，对于本领域普通技术人员来讲，在不付出创造性劳动性的前提下，还可以根据这些附图获得其它的附图。

[0067] 图1为本发明一个可选实施例提供的一种基于图结构与异常注意力机制的机房异常检测方法的流程图；

[0068] 图2为本发明一个可选实施例提供的Transformer编码器的结构示意图；

[0069] 图3为本发明一个可选实施例提供的解码器的结构示意图；

[0070] 图4为本发明一个可选实施例提供的一种基于图结构与异常注意力机制的机房异常检测方法的异常检测逻辑示意图。

[0071] 图5为本发明一个可选实施例提供的一种基于图结构与异常注意力机制的机房异常检测装置的结构连接框图。

[0072] 附图标记：

[0073] 1-数据获取模块；2-数据转换模块；3-特征提取模块；4-异常检测模块；5-异常数据确定模块。

具体实施方式

[0074] 本发明实施例提供了基于图结构与异常注意力机制的机房异常检测方法及装置，用于解决目前基于深度学习网络的机房异常检测方法存在异常检测精度和稳定性不足的缺陷的技术问题。

[0075] 为使得本发明的发明目的、特征、优点能够更加的明显和易懂，下面将结合本发明实施例中的附图，对本发明实施例中的技术方案进行清楚、完整地描述，显然，下面所描述的实施例仅仅是本发明一部分实施例，而非全部的实施例。基于本发明中的实施例，本领域普通技术人员在没有做出创造性劳动前提下所获得的所有其它实施例，都属于本发明保护的范围。

[0076] 为了更好地对本申请实施例中的技术方案进行描述，下面对相关知识进行介绍。

[0077] (1)图卷积神经网络(Graph Convolutional Network,GCN):

[0078] 是一类采用图形结构进行卷积的神经网络，本质上是一个特征提取器。由于图的结构一般是不规则的，可以看作是无限维的一种数据，不具有平移不变性，因此无法用CNN或RNN神经网络进行特征提取。图结构中的节点因为相邻和更远的点的影响，而改变着自己的状态直到最终的平衡，且关系越亲近的邻居节点影响越大。GCN利用这一点完成对图结构特征的提取。

[0079] (2)重构误差(Reconstruction error):

[0080] 指的是模型输出值与原始输入之间的均方误差。

[0081] (3)邻接矩阵(Adjacency Matrix):

[0082] 是表示顶点之间相邻关系的矩阵，是n阶方阵。即当节点 x_j 与节点 x_i 相连时，对应的邻接矩阵 $A_{i,j} = 1$ ，表示两节点之间的连接关系。

[0083] (4)多维时间序列:

[0084] 多维时间序列可以表示为 $X = (x_1, x_2, \dots, x_N)^T \in R^{N \times V}$ ，其中， $x_i \in R^V$ 是长度为V的信号，N是信号总数，即传感器的个数。

[0085] (5)先验关联:

[0086] 异常数据总是集中出现，因此异常数据的相关性集中在相邻的时间点，由于连续性，这些时间点包含类似的异常模式，我们把这种相邻的异常模式以先验关联进行表征。因此异常关联为采用可学习的高斯核函数表示的对应时间点的数据与邻接数据的偏差。

[0087] (6)序列关联:

[0088] 从原始时间序列中学习关联权重大小，可以自适应地找到最有效的关联，基于此可得到序列关联。序列关联为从所述多维时间序列中学习的对应时间点的自我注意权重。

[0089] (7)关联差异:

[0090] 通过时间点的先验关联与序列关联之间的距离来量化，称为关联差异。通常利用KL散度来表征关联差异。KL散度又被称为相对熵(relative entropy)，是两个概率分布间差异的非对称性度量。在信息理论中，相对熵等价于两个概率分布的信息熵的差值。当参与计算的一个概率分布为真实分布，另一个为理论(拟合)分布，相对熵表示使用理论分布拟合真实分布时产生的信息损耗。

[0091] 本发明提供了一种基于图结构与异常注意力机制的机房异常检测方法。

[0092] 请参阅图1,图1示出了本发明实施例提供的一种基于图结构与异常注意力机制的机房异常检测方法的流程图。

[0093] 本发明实施例提供的一种基于图结构与异常注意力机制的机房异常检测方法,包括:

[0094] 步骤S1,获取目标电力机房的传感器监测数据,根据所述传感器监测数据构建多维时间序列。

[0095] 其中,传感器监测数据为用于监测目标电力机房故障的传感器所采集的数据。例如,主轴承温度、风扇转速、CPU温度、电源电压等数据。

[0096] 步骤S2,根据所述多维时间序列构建相应的图结构,获取所述图结构的邻接矩阵,根据所述邻接矩阵和对应图结构的附加权重得到聚合矩阵。

[0097] 在一种能够实现的方式中,所述根据所述多维时间序列构建相应的图结构,获取所述图结构的邻接矩阵,包括:

[0098] 将所述多维时间序列对应的传感器视为图结构中的节点,将传感器之间的相关性视为图结构中节点之间的边,根据图结构中节点与节点之间的相关性构建邻接矩阵。

[0099] 具体地,对于图的定义为 $G = (v, \bar{E})$,其中 v 表示节点的集合, \bar{E} 表示为边的集合。

$v = \{x_1, x_2, \dots, x_N\}$, N 表示传感器的个数。

[0100] 计算图结构中节点与节点之间的相关性时,需要为每一个传感器即节点选择相关节点,以构建相关节点集合。同时,对于每个节点,设置节点与其余节点之间的相关性假设:

[0101] $e_i \in R^{N-1}, i \in \{1, 2, \dots, N\}$

[0102] 式中, e_i 为节点 x_i 与其余节点之间的相关性假设。

[0103] 在一种能够实现的方式中,按照下列相关性度量关系式表示节点与节点之间的相关性:

[0104]
$$Cor_{ji} = \frac{e_i^T e_j}{\|e_i\| \cdot \|e_j\|} + \log \frac{p(x_i, x_j)}{p(x_i)p(x_j)}, x_j \in C_i$$

[0105] 式中, Cor_{ji} 表示节点 x_j 与节点 x_i 之间的相关性, e_i 为节点 x_i 与其余节点之间的相关性假设, e_j 为节点 x_j 与其余节点之间的相关性假设, e_i 、 e_j 的取值范围皆为0~1, $p(x_i, x_j)$ 表示节点 x_j 与节点 x_i 的数据在多维时间序列中一起的数据在多维时间序列中出现的概率, $p(x_i)$ 为节点 x_i 的数据在多维时间序列中出现的概率, $p(x_j)$ 为节点 x_j 的数据在多维时间序列中出现的概率, C_i 为节点 x_i 的相关节点集合。

[0106] 这里,前部分为余弦相关,用来度量节点之间在空间中的相关性,后部分为P概率相关,用来度量节点 x_j 和节点 x_i 在时间上的相关性。结合时空两个维度,可以更有效地表示节点之间的依赖程度,将节点的拓扑结构精细化。 Cor_{ji} 的结果越大,表示两个节点越相似。

[0107] 其中,假设n维时间数据服从正太分布,其中n是传感器的个数,节点 x_j 和节点 x_i 的数据分别为 X_i 、 X_j 则:

$$[0108] \quad p(x_i) = \frac{1}{\sqrt{2\pi\sigma}} \exp\left(-\frac{(X_i - \mu)^2}{2\sigma^2}\right)$$

$$[0109] \quad p(x_i, x_j) = \frac{1}{\sqrt{2\pi\sigma}} \exp\left(-\frac{(X_i X_j - \mu)}{2\sigma^2}\right)$$

[0110] 其中, μ , σ 分别表示均值和方差,可以通过观测数据计算得到。

[0111] 其中,邻接矩阵的元素 A_{ji} 为:

$$[0112] \quad A_{ji} = 1, \{j \in \text{TopK}(\{Cor_{ki} : k \in C_i\})\}$$

[0113] 即,首先利用相关性度量关系式计算与节点 x_i 与各相关节点之间的相关性,然后选择前K个值,其中 $\frac{N}{3} < K < N$,这里K值可以根据用户预计的图结构的复杂性来选择,并且将K个值对应的邻接矩阵元素设为1,其余为0。

[0114] 本发明实施例中,提出用图结构建立多维数据之间的相关性。传统的图神经网络使用相同的模型为每个节点建立图结构,限制了模型的灵活性,传统的图卷积神经网络使用相同的模型为每个节点建立图结构,限制了模型的灵活性。本实施例中,基于模型的复杂度选择前K个值进行邻接矩阵的构建,以用于后续的网络训练,可以准确地学习传感器之间的相互依赖程度;

[0115] 在一种能够实现的方式中,所述根据所述邻接矩阵和对应图结构的附加权重得到聚合矩阵,包括:

[0116] 按照下式得到聚合矩阵:

$$[0117] \quad \hat{A} = \alpha A + (1 - \alpha)E$$

[0118] 式中, \hat{A} 为邻接矩阵A对应的聚合矩阵, E 为邻接矩阵A对应图结构的附加权重, α 为预置的图结构复杂性系数, α 的取值范围为0~1。

[0119] 传统的异常检测方法都是基于二维空间进行处理,容易忽略传感器之间的相互关系,为此本发明上述实施例中,引入图结构,来表示多维时间序列的拓扑结构,从二维空间转换到多维空间。在进行图结构的表示上,引入聚合矩阵,即由邻接矩阵和初始化时的预测权重矩阵组合而成,加入的预测权重一开始是随机初始化,然后与邻接矩阵一起输入到图结构的特征学习网络(即图卷积神经网络)进行调参,这使得时间序列的拓扑结构更具有灵活性。

[0120] 步骤S3,将所述聚合矩阵输入至预先训练完成的图卷积神经网络,得到相应的图结构特征。

[0121] 在一种能够实现的方式中,所述图卷积神经网络包括依次连接的卷积层、池化层、全连接层和Sigmoid函数层,所述将所述聚合矩阵输入至预先训练完成的图卷积神经网络,

得到相应的图结构特征,包括:

[0122] 将所述聚合矩阵依次经过卷积层、池化层和全连接层进行处理,得到每个节点的输出特征:

$$[0123] \quad G_i^{(t)} = W \text{Conv}(x_i^{(t)}) + \sum_{x_j \in N(i)} W \text{Conv}(x_j^{(t)})$$

[0124] 式中, $G_i^{(t)}$ 表示节点 x_i 的输出特征, $x_i^{(t)}$ 、 $x_j^{(t)}$ 分别表示聚合矩阵中节点 x_i 、 x_j 的输入特征, $\text{Conv}(x_i^{(t)})$ 为 $x_i^{(t)}$ 通过所述卷积层及池化层后得到的结果, $\text{Conv}(x_j^{(t)})$ 为 $x_j^{(t)}$ 通过所述卷积层及池化层后得到的结果, $N(i)$ 为由对应邻接矩阵得到的节点 x_i 的邻居节点集合, W 为预置的可训练权重矩阵;

[0125] 将所述每个节点的输出特征经过所述Sigmoid函数层进行处理,得到相应的图结构特征。

[0126] 具体地,输入聚合矩阵为 \hat{A} ,其维度是 $N \times N \times T$, N 是传感器的个数, T 是信号通过滑动窗口截取的时间序列的长度,卷积核的参数为 3×3 ,加入池化层后,通过下采样,对特征进行压缩,减少全连接层的参数,降低模型的复杂度,最后通过全连接层,将邻接矩阵的每个节点表示为相关节点的加权求和,即该输出特征。

[0127] 现有技术中,通常对图结构进行特征提取的网络是单层全连接网络。本发明实施例中,对现有的图结构的特征提取网络进行改进,加入了卷积层与池化层。由于对图结构的特征提取,是基于聚合矩阵进行处理,利用该矩阵的方阵特性,添加卷积网络可以扩大感受野的范围,提高模型的精细度。

[0128] 本发明实施例中,通过搭建一个轻量级的图卷积神经网络对图结构进行特征提取,这里卷积核的参数设置为 3×3 ,网络的输入为聚合矩阵,是 N 阶方阵,其中 N 表示传感器的个数,即多维时间序列的维度。由于卷积网络的轻量特点,使得该网络便于移植处理与嵌入操作。

[0129] 其中,将所述每个节点的输出特征经过所述Sigmoid函数层进行处理,具体为:

[0130] 对于每个节点进行共享线性变换:

$$[0131] \quad g_i^{(t)} = e_i \oplus G_i^{(t)}$$

$$[0132] \quad Z_i = \frac{\exp(g_i^{(t)})}{\sum_{j \in C_i} \exp(g_j^{(t)})}$$

[0133] 式中, \oplus 表示串联, $g_i^{(t)}$ 为将传感器相关性假设 e_i 与相应变换后的特征 $G_i^{(t)}$ 连接起来的结果;

[0134] 使用Sigmoid函数对 $g_i^{(t)}$ 进行激活。

[0135] 本发明实施例中,将输入的聚合矩阵映射为每个值属于 $0 \sim 1$ 且所有值之和为1的结

果。图卷积神经网络的输出为 N 个节点的表示,即 $\{z_1^{(t)}, \dots, z_N^{(t)}\}$ 。

[0136] 步骤S4,利用滑动窗口在所述多维时间序列上滑动以提取所述滑动窗口内的多维时间序列片段,将所述图结构特征和所述多维时间序列片段输入到预先训练完成的异常检测模型,得到对应的异常检测结果。

[0137] 其中,如图2所示,所述异常检测模型包括多级的编解码模块,前一级编解码模块的预测数据与对应真实数据的差值作为后一级编解码模块的输入。每个所述编解码模块包括基于关联差异的Transformer编码器及解码器,所述Transformer编码器是通过将带有两分支结构的异常注意力模块替代Transformer中的注意力模块得到的,所述两分支结构用于同时建模先验关联和序列关联;所述解码器利用多头注意力机制进行解码。

[0138] 本发明实施例中,借鉴现有的基于关联差异的时间序列异常检测方法,采用具有二分支结构的Transformer编码器,该二分支结构可以计算时间序列的先验相关和序列相关。相比于单分支,可以增加正常数据与异常数据之间的区别。在此基础上,本申请对异常检测模型进行改进。由于模型有时会对异常的数据进行拟合,即产生“过拟合”现象,异常数据会通过与周围其他正常节点建立“假性”关联,使得异常数据的损失函数值较低,隐藏自己的异常性。为了使模型在异常数据上表现为异常的数据和预测的数据差异较大,本申请将多个具有该Transformer编码器的编解码模块进行串联,将第一个编解码模块输出的预测值与真实值的差值作为第二个编解码模块的输入,以此希望第二个编解码模块能学习到差值中所剩余的信息。

[0139] 本发明实施例中,Transformer编码器是通过将带有两分支结构的异常注意力模块替代Transformer中的注意力模块得到的。对于先验相关,可以采用一个可学习的高斯核来计算相对时间距离的先验相关。由于高斯核函数只有一个峰值,并且距离中心点的距离越近,相似度越接近1,反之越接近于0。利用此特性,引入高斯核函数的注意力机制会更加关注邻近的节点特征。这里,为高斯核函数嵌入一个可学习的参数,使得先验相关适应各种时间序列模式,例如不同长度的异常段。序列相关分支是从原始序列中学习关联,可以自适应地找到最有效的关联。

[0140] Transformer编码器的结构示意图可如图3所示。其中,第 L 层参数为 Q, K, V, r 。

[0141] Transformer编码器的第 l 层输出为:

$$[0142] \quad Z^l = \text{Layer - Norm}(\text{Multi - attention}(X^{l-1}) + X^{l-1})$$

$$[0143] \quad X^l = \text{Layer - Norm}(\text{feed - forward}(Z^l) + Z^l)$$

[0144] 其中, $X^l \in R^{N \times d}$, $l \in \{1, \dots, L\}$, 表示第 L 层与 d_{model} 通道的输出。初始输入 $X^0 = \text{Embedding}(X)$, 表示嵌入的原始序列。 $Z^l \in R^{N \times d_{\text{model}}}$ 表示第 L 层的隐藏表示。

[0145] QKV的初始值为:

$$[0146] \quad Q, K, V, r = X^{l-1}W_Q^l, X^{l-1}W_K^l, X^{l-1}W_V^l, X^{l-1}W_r^l$$

[0147] 式中, Q, K, V, r 分别表示查询、关键字、自我注意值和学习量, $Q, K, V \in R^{N \times d_{\text{model}}}$, $r \in R^{N \times 1}$, $W_Q^l, W_K^l, W_V^l, W_r^l$ 分别表示第 L 层中 Q, K, V, r 的参数矩阵,

$W_Q^l, W_K^l, W_V^l \in R^{d \times d}, W_r^l \in R^{d \times 1}$ 。

[0148] 计算序列相关所采用的计算公式为：

$$[0149] \quad S^l = \text{Softmax}\left(\frac{QK^T}{\sqrt{d_{\text{model}}}}\right)$$

[0150] 可以基于学习到的高斯核参数 $\tilde{r} \in R^{N \times 1}$ 生成异常关联 $P^l \in R^{N \times N}$ ，并且第 i 个元素 \tilde{r}_i 对应于第 i 个时间点。先验相关的计算公式可以为：

$$[0151] \quad P_i^l = \text{Rescale}\left(\left[\frac{1}{\sqrt{2\pi}\tilde{r}_i} \exp\left(-\frac{|j-i|^2}{2\tilde{r}_i^2}\right)\right]_{i,j \in \{1, \dots, \tilde{N}\}}\right)$$

[0152] 式中， \tilde{N} 为参与计算时间序列的长度， i, j 对应不同时间点，即第 i 个时间点到第

j 个时间点的关联权重由高斯核 $G(|j-i|; \tilde{r}_i) = \frac{1}{\sqrt{2\pi}\tilde{r}_i} \exp\left(-\frac{|j-i|^2}{2\tilde{r}_i^2}\right)$ 计算。Rescale

(.) 表示除以行和操作，用于将关联权重转变为离散分布。

[0153] 解码器的结构示意图可如图4所示。

[0154] 解码器输出的第 l 层的隐藏表示为：

$$[0155] \quad \hat{Z}^l = S^l V$$

[0156] 作为一项无监督的任务，可以采用重建损失优化异常检测模型。重建损失将引导序列关联找到最有信息的关联。为了进一步放大正常和异常时间点之间的差异，可以进一步使用附加损失来放大关联差异。相应的损失函数为：

$$[0157] \quad L = \min_{\eta, \lambda, w} \left\| h(t) - \hat{h}(t) \right\|^2 + \lambda \left\| \hat{Z}^L - X \right\|^2$$

[0158] 式中， w 是每个节点附加权重， η 是神经网络的参数， λ 是损失的权衡系数， $h(t)$ 为聚合矩阵通过图卷积神经网络后得到的输出， $\hat{h}(t)$ 为 $h(t)$ 的重建数据， $\left\| \hat{Z}^L - X \right\|^2$ 表示输入序列通过异常检测模型得到的重构损失。

[0159] 步骤S5，根据所述异常检测结果确定对应多维时间序列中的异常数据。

[0160] 在一种能够实现的方式中，所述根据所述异常检测结果确定对应多维时间序列中的异常数据，包括：

[0161] 将所述异常检测结果与对应多维时间序列进行比较以获取异常得分；

[0162] 若所述异常得分超过预设阈值，将对应数据标记为异常数据。

[0163] 获取异常得分时，可以将异常检测结果与观测的时间序列进行比较，计算出 t 时刻的传感器 i 的错误值：

$$[0164] \quad Err_i(t) = \left| h_i^{(t)} - \hat{h}_i^{(t)} \right| + \left\| Z_i^t - x_i^{(t)} \right\|^2$$

[0165] 式中, $Err_i(t)$ 表示 t 时刻的传感器 i 的错误值, $h_i^{(t)}$ 表示第 i 个节点在 t 时刻由其他节点通过边的连接进行的加权集合表示, $h_i^{(t)} = x_1 e_{1,i} + x_2 e_{2,i} + \dots + x_j e_{j,i}$, $e_{j,i}$ 表示节点 x_i 与节点 x_j 之间边的值, $\hat{h}_i^{(t)}$ 表示 $h_i^{(t)}$ 通过图卷积神经网络后得到的结果, $\hat{h}_i^{(t)} = x_1 \hat{e}_{1,i} + x_2 \hat{e}_{2,i} + \dots + x_j \hat{e}_{j,i}$, $\hat{e}_{j,i}$ 表示通过图卷积神经网络处理后节点 x_i 与节点 x_j 之间边的值, Z_i^t 表示异常检测结果中第 i 个传感器在 t 时刻的值, $x_i^{(t)}$ 表示第 i 个传感器在 t 时刻的观测值;

[0166] 对所述进行归一化处理, 得到对应的异常得分:

$$[0167] \quad a_i(t) = \frac{Err_i(t) - \hat{\mu}_i}{\hat{\sigma}_i}$$

[0168] 式中, $a_i(t)$ 表示第 i 个传感器在 t 时刻的数据的异常得分, $\hat{\mu}_i, \hat{\sigma}_i$ 分别表示在预置时间间隔内第 i 个传感器的错误值的均值和方差。

[0169] 其中, 可以使用当前时刻的前数天数据进行训练建模, 然后以当天的数据作为测试集得到异常分数, 将预设阈值设置为所得异常分数的最大值。

[0170] 进一步地, 可以使用 \max 函数对传感器的异常得分进行聚合, 即 $A(t) = \max_i a_i(t)$ 。

如果 $A(t)$ 超过预设阈值, 则将时间点对应的数据标记为异常数据。

[0171] 在一种能够实现的方式中, 所述方法还包括:

[0172] 在根据所述多维时间序列构建相应的图结构之前, 对所述多维时间序列进行预处理; 所述进行预处理包括填充序列缺失数据和/或修正所辨识的异常数据。

[0173] 具体地, 可以利用滑动窗口截取到的时间序列进行平均值计算, 将得到的结果作为缺失数据的填充。对于感知数据中出现明显反常的数据进行修改, 以保证进行模型训练的样本为正确样本。

[0174] 本发明还提供了一种基于图结构与异常注意力机制的机房异常检测装置。

[0175] 请参阅图5, 图5示出了本发明实施例提供的一种基于图结构与异常注意力机制的机房异常检测装置的结构连接框图。

[0176] 本发明实施例提供的一种基于图结构与异常注意力机制的机房异常检测装置, 包括:

[0177] 数据获取模块1, 用于获取目标电力机房的传感器监测数据, 根据所述传感器监测数据构建多维时间序列;

[0178] 数据转换模块2, 用于根据所述多维时间序列构建相应的图结构, 获取所述图结构的邻接矩阵, 根据所述邻接矩阵和对应图结构的附加权重得到聚合矩阵;

[0179] 特征提取模块3, 用于将所述聚合矩阵输入至预先训练完成的图卷积神经网络, 得

到相应的图结构特征；

[0180] 异常检测模块4,用于利用滑动窗口在所述多维时间序列上滑动以提取所述滑动窗口内的多维时间序列片段,将所述图结构特征和所述多维时间序列片段输入到预先训练完成的异常检测模型,得到对应的异常检测结果；

[0181] 异常数据确定模块5,用于根据所述异常检测结果确定对应多维时间序列中的异常数据；

[0182] 其中,所述异常检测模型包括多级的编解码模块,前一级编解码模块的预测数据与对应真实数据的差值作为后一级编解码模块的输入,每个所述编解码模块包括基于关联差异的Transformer编码器及解码器,所述Transformer编码器是通过将带有两分支结构的异常注意力模块替代Transformer中的注意力模块得到的,所述两分支结构用于同时建模先验关联和序列关联;所述解码器利用多头注意力机制进行解码。

[0183] 在一种能够实现的方式中,所述数据转换模块2包括:

[0184] 第一数据转换单元,用于将所述多维时间序列对应的传感器视为图结构中的节点,将传感器之间的相关性视为图结构中节点之间的边,根据图结构中节点与节点之间的相关性构建邻接矩阵。

[0185] 在一种能够实现的方式中,所述第一数据转换单元具体用于:

[0186] 按照下列相关性度量关系式表示节点与节点之间的相关性:

$$[0187] \quad Cor_{ji} = \frac{e_i^T e_j}{\|e_i\| \cdot \|e_j\|} + \log \frac{p(x_i, x_j)}{p(x_i)p(x_j)}, x_j \in C_i$$

[0188] 式中, Cor_{ji} 表示节点 x_j 与节点 x_i 之间的相关性, e_i 为节点 x_i 与其余节点之间的相关性假设, e_j 为节点 x_j 与其余节点之间的相关性假设, e_i 、 e_j 的取值范围皆为0~1, $p(x_i, x_j)$ 表示节点 x_j 与节点 x_i 的数据在多维时间序列中一起的数据在多维时间序列中出现的概率, $p(x_i)$ 为节点 x_i 的数据在多维时间序列中出现的概率, $p(x_j)$ 为节点 x_j 的数据在多维时间序列中出现的概率, C_i 为节点 x_i 的相关节点集合。

[0189] 在一种能够实现的方式中,所述数据转换模块2还包括:

[0190] 第二数据转换单元,用于按照下式得到聚合矩阵:

$$[0191] \quad \hat{A} = \alpha A + (1 - \alpha)E$$

[0192] 式中, \hat{A} 为邻接矩阵A对应的聚合矩阵, E 为邻接矩阵A对应图结构的附加权重, α 为预置的图结构复杂性系数, α 的取值范围为0~1。

[0193] 在一种能够实现的方式中,所述图卷积神经网络包括依次连接的卷积层、池化层、全连接层和Sigmoid函数层,所述特征提取模块3包括:

[0194] 第一特征提取单元,用于将所述聚合矩阵依次经过卷积层、池化层和全连接层进行处理,得到每个节点的输出特征:

$$[0195] \quad G_i^{(t)} = W \text{Conv}(x_i^{(t)}) + \sum_{x_j \in N(i)} W \text{Conv}(x_j^{(t)})$$

[0196] 式中, $G_i^{(t)}$ 表示节点 x_i 的输出特征, $x_i^{(t)}$ 、 $x_j^{(t)}$ 分别表示聚合矩阵中节点 x_i 、 x_j 的输入特征, $\text{Conv}(x_i^{(t)})$ 为 $x_i^{(t)}$ 通过所述卷积层及池化层后得到的结果, $\text{Conv}(x_j^{(t)})$ 为 $x_j^{(t)}$ 通过所述卷积层及池化层后得到的结果, $N(i)$ 为由对应邻接矩阵得到的节点 x_i 的邻居节点集合, W 为预置的可训练权重矩阵;

[0197] 第二特征提取单元, 用于将所述每个节点的输出特征经过所述Sigmoid函数层进行处理, 得到相应的图结构特征。

[0198] 在一种能够实现的方式中, 所述异常数据确定模块5包括:

[0199] 异常得分计算单元, 用于将所述异常检测结果与对应多维时间序列进行比较以获取异常得分;

[0200] 异常数据确定单元, 用于若所述异常得分超过预设阈值, 将对应数据标记为异常数据。

[0201] 在一种能够实现的方式中, 所述装置还包括:

[0202] 数据预处理模块, 用于在根据所述多维时间序列构建相应的图结构之前, 对所述多维时间序列进行预处理; 所述进行预处理包括填充序列缺失数据和/或修正所辨识的异常数据。

[0203] 本发明还提供了一种基于图结构与异常注意力机制的机房异常检测装置, 包括:

[0204] 存储器, 用于存储指令; 其中, 所述指令用于实现如上任意一项实施例所述的基于图结构与异常注意力机制的机房异常检测方法;

[0205] 处理器, 用于执行所述存储器中的指令。

[0206] 本发明还提供了一种计算机可读存储介质, 所述计算机可读存储介质上存储有计算机程序, 所述计算机程序被处理器执行时实现如上任意一项实施例所述的基于图结构与异常注意力机制的机房异常检测方法。

[0207] 所属领域的技术人员可以清楚地了解到, 为描述的方便和简洁, 上述描述的装置和模块的具体工作过程, 可以参考前述方法实施例中的对应过程, 上述描述的装置和模块的具体有益效果, 可以参考前述方法实施例中的对应有益效果, 在此不再赘述。

[0208] 在本申请所提供的几个实施例中, 应该理解到, 所揭露的装置和方法, 可以通过其它的方式实现。例如, 以上所描述的装置实施例仅仅是示意性的, 例如, 所述模块的划分, 仅仅为一种逻辑功能划分, 实际实现时可以有另外的划分方式, 例如多个模块或组件可以结合或者可以集成到另一个系统, 或一些特征可以忽略, 或不执行。另一点, 所显示或讨论的相互之间的耦合或直接耦合或通信连接可以是通过一些接口, 装置或模块的间接耦合或通信连接, 可以是电性, 机械或其它的形式。

[0209] 所述作为分离部件说明的模块可以是或者也可以不是物理上分开的, 作为模块显示的部件可以是或者也可以不是物理模块, 即可以位于一个地方, 或者也可以分布到多个网络模块上。可以根据实际的需要选择其中的部分或者全部模块来实现本实施例方案的目的。

的。

[0210] 另外,在本发明各个实施例中的各功能模块可以集成在一个处理模块中,也可以是各个模块单独物理存在,也可以两个或两个以上模块集成在一个模块中。上述集成的模块既可以采用硬件的形式实现,也可以采用软件功能模块的形式实现。

[0211] 所述集成的模块如果以软件功能模块的形式实现并作为独立的产品销售或使用时,可以存储在一个计算机可读取存储介质中。基于这样的理解,本发明的技术方案本质上或者说对现有技术做出贡献的部分或者该技术方案的全部或部分可以以软件产品的形式体现出来,该计算机软件产品存储在一个存储介质中,包括若干指令用以使得一台计算机设备(可以是个人计算机,服务器,或者网络设备等)执行本发明各个实施例所述方法的全部或部分步骤。而前述的存储介质包括:U盘、移动硬盘、只读存储器(ROM,Read-Only Memory)、随机存取存储器(RAM,Random Access Memory)、磁碟或者光盘等各种可以存储程序代码的介质。

[0212] 以上所述,以上实施例仅用以说明本发明的技术方案,而非对其限制;尽管参照前述实施例对本发明进行了详细的说明,本领域的普通技术人员应当理解:其依然可以对前述各实施例所记载的技术方案进行修改,或者对其中部分技术特征进行等同替换;而这些修改或者替换,并不使相应技术方案的本质脱离本发明各实施例技术方案的精神和范围。

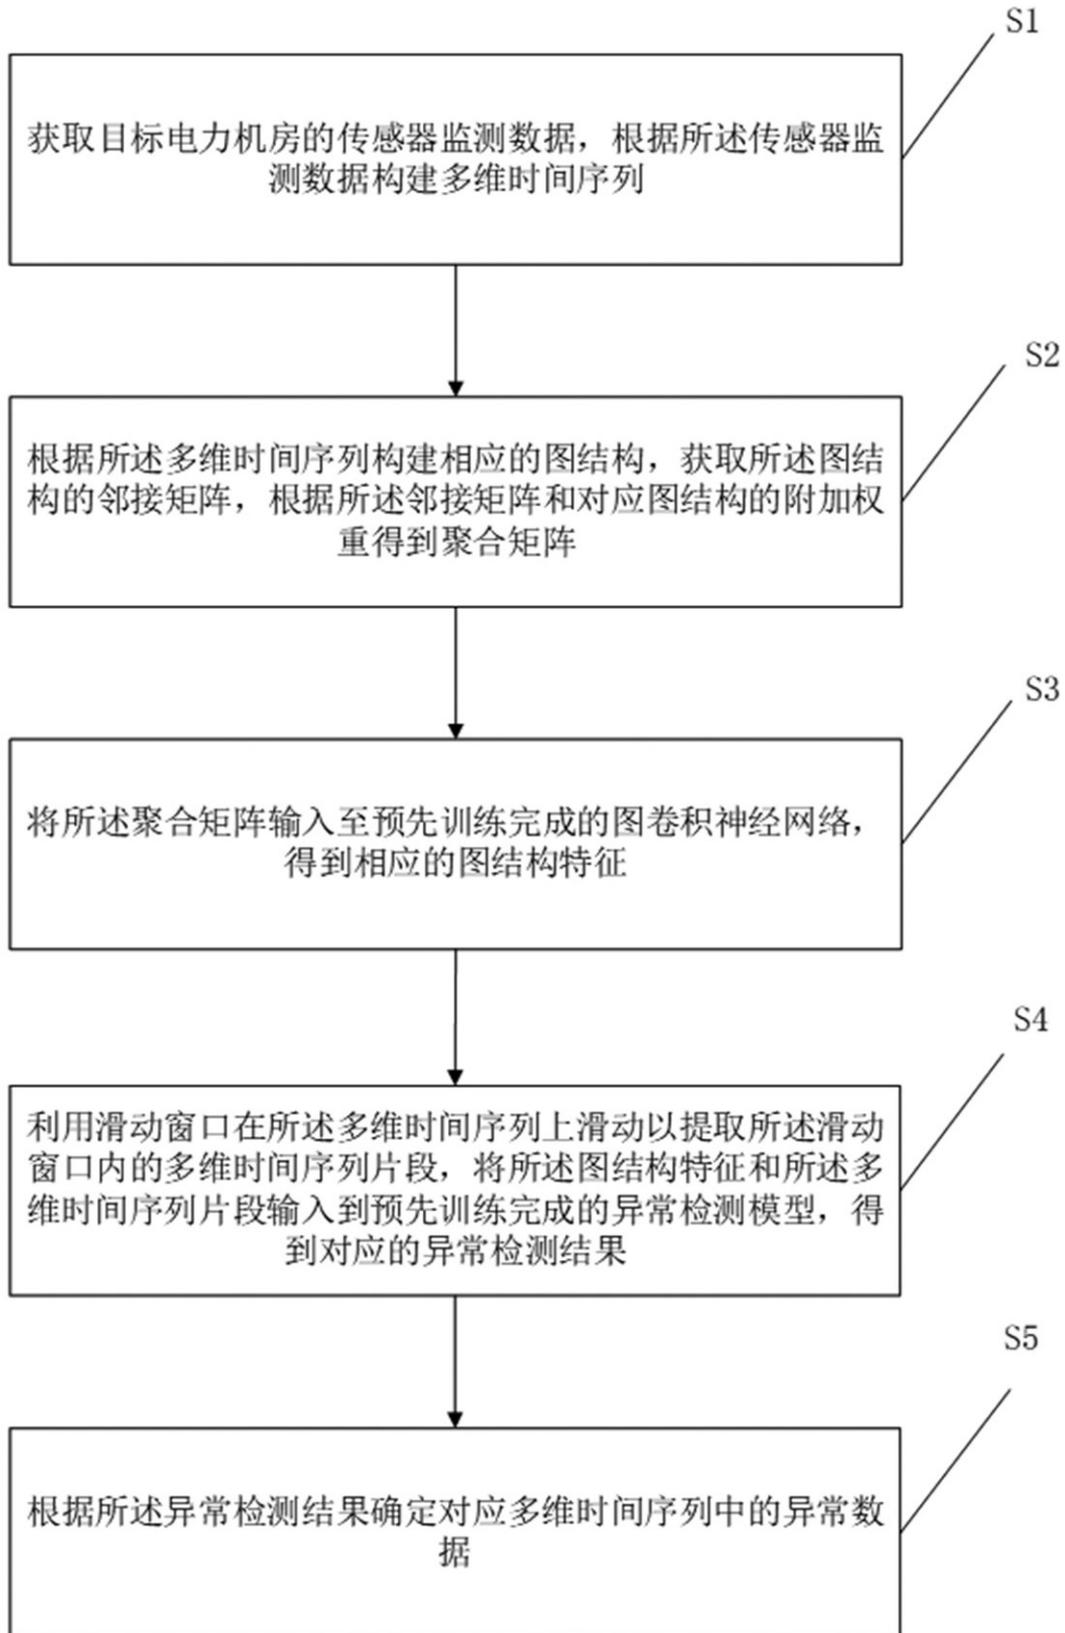


图1

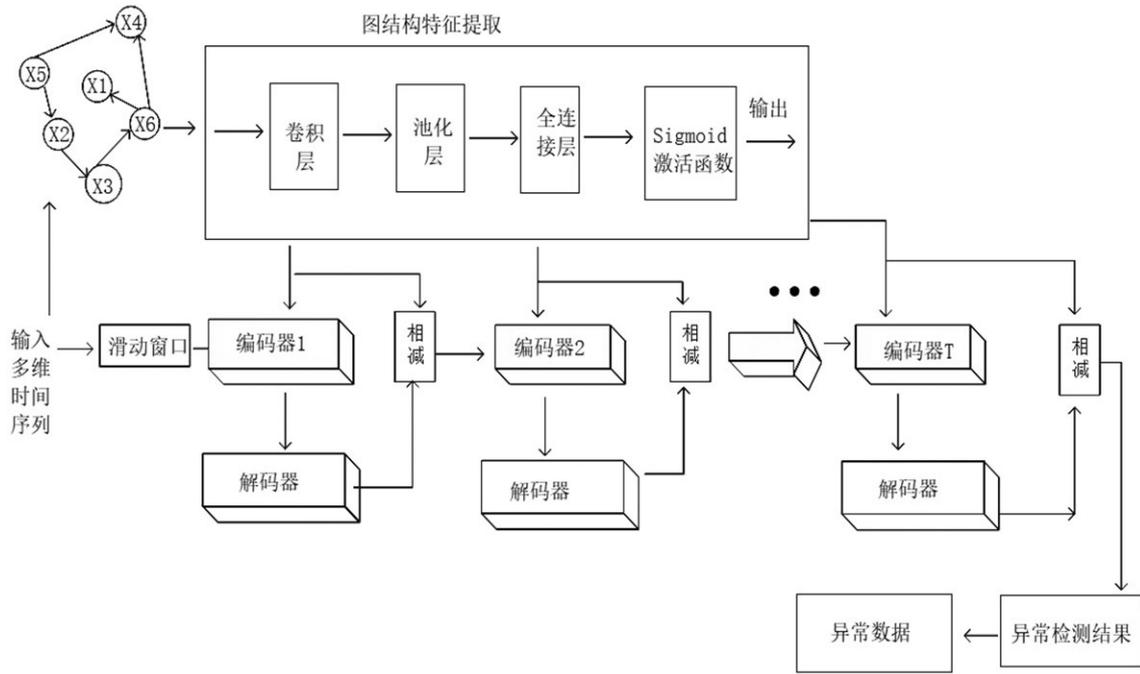


图2

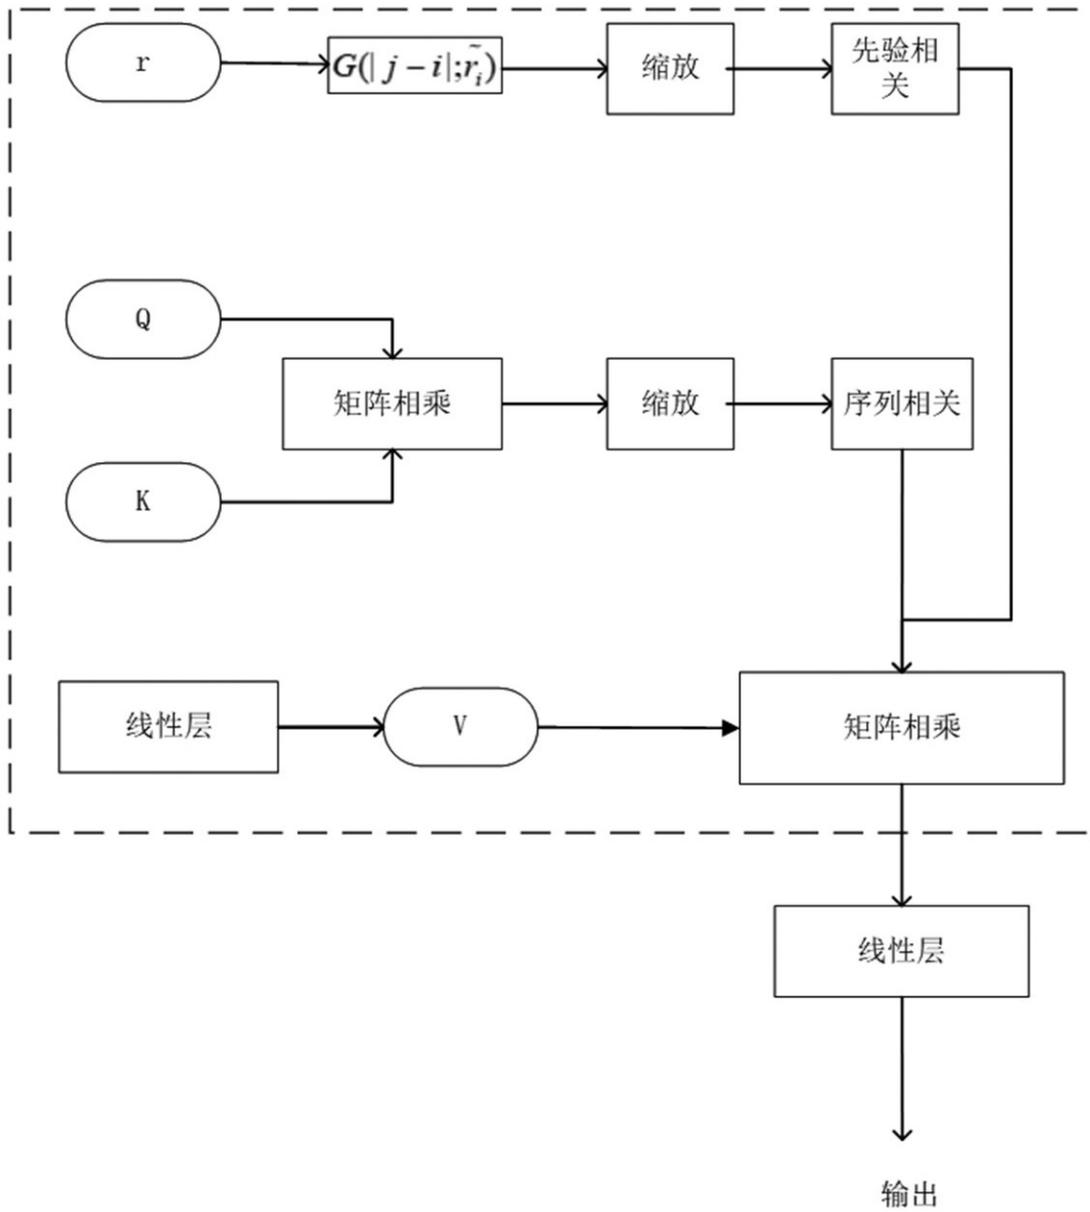


图3

残差连接

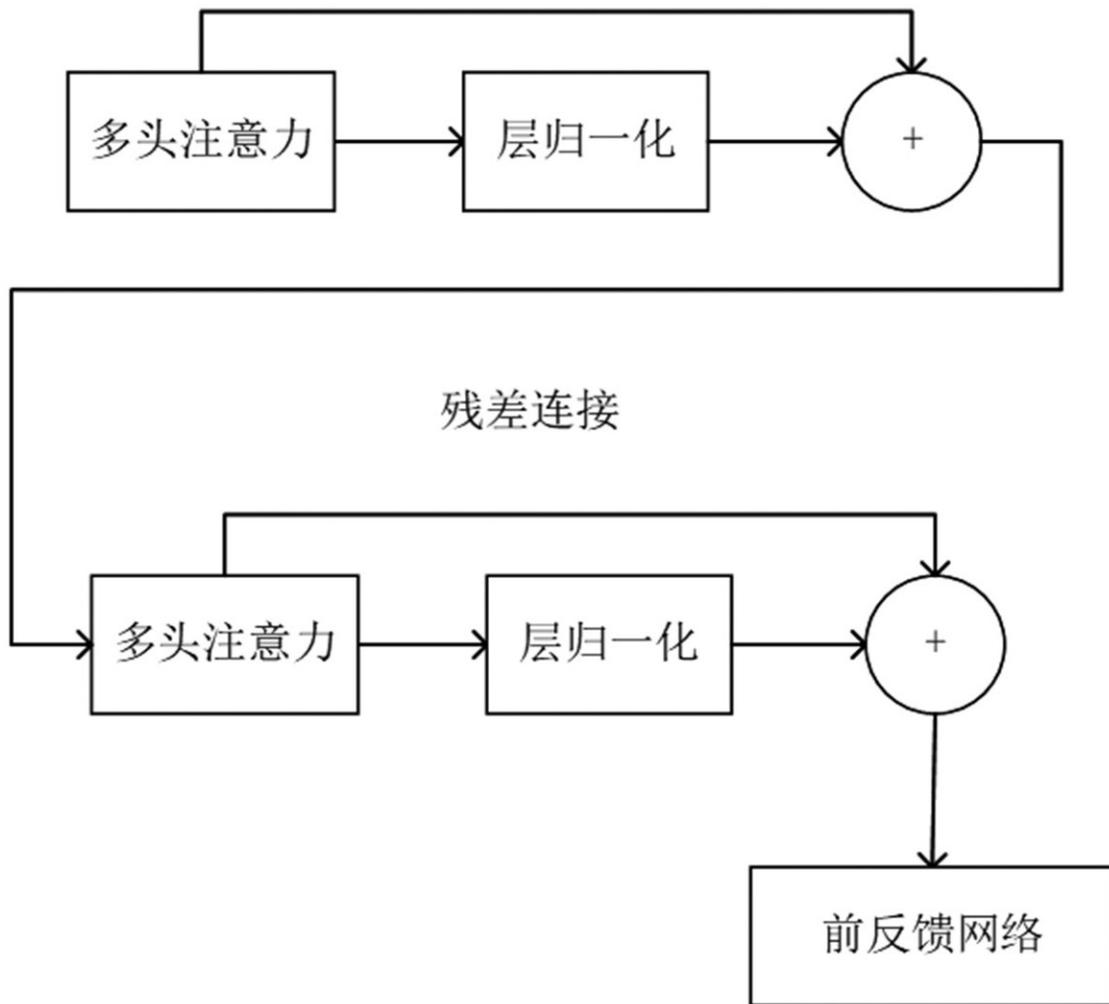


图4

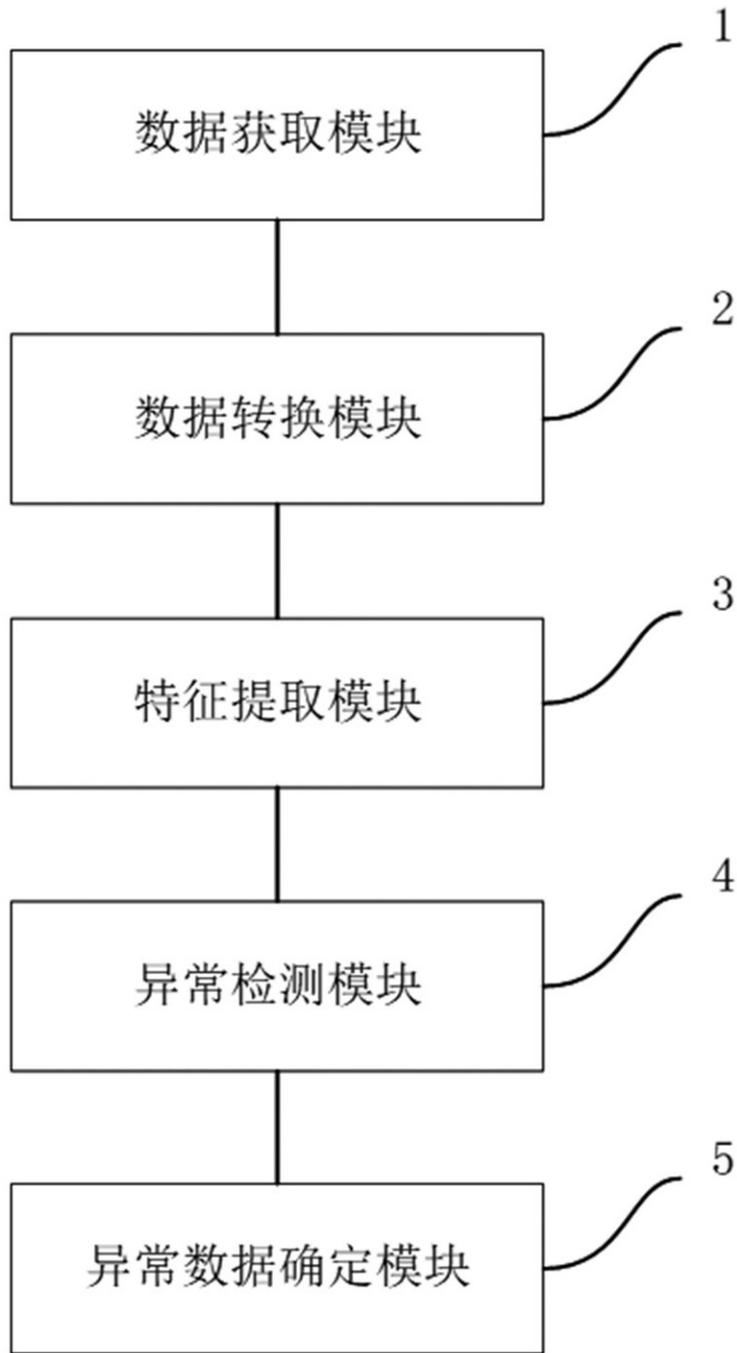


图5