

12-21-2022

Anomaly Detection Method of Electrical Power Consumption Based on Deep Autoencoder

Ningke Sun

Engineering Research Center of Internet of Things Technology Applications Ministry of Education, Jiangnan University, Wuxi 214122, China;, 191253041@qq.com

Yan Wang

Engineering Research Center of Internet of Things Technology Applications Ministry of Education, Jiangnan University, Wuxi 214122, China;, wangyan@jiangnan.edu.cn

Zhicheng Ji

Engineering Research Center of Internet of Things Technology Applications Ministry of Education, Jiangnan University, Wuxi 214122, China;

Follow this and additional works at: <https://dc-china-simulation.researchcommons.org/journal>



Part of the [Artificial Intelligence and Robotics Commons](#), [Computer Engineering Commons](#), [Numerical Analysis and Scientific Computing Commons](#), [Operations Research](#), [Systems Engineering and Industrial Engineering Commons](#), and the [Systems Science Commons](#)

This Paper is brought to you for free and open access by Journal of System Simulation. It has been accepted for inclusion in Journal of System Simulation by an authorized editor of Journal of System Simulation.

Anomaly Detection Method of Electrical Power Consumption Based on Deep Autoencoder

Abstract

Abstract: Aiming at the nonlinear and non-stationary characteristics of electrical power consumption data, an abnormal electrical power consumption detection model based on deep autoencoder is proposed. *Gated recurrent unit (GRU) network of the deep learning is combined with autoencoder structure, and the encoder and decoder parts of traditional autoencoder are realized by gated recurrent unit network, which gives full play to the data feature extraction capability of gated recurrent unit and the data reconstruction function of autoencoder structure. Based on the reconstruction error between original data and reconstructed data, abnormal data points of the electrical power consumption are detected.* By applying the proposed method to actual workshop electrical power consumption data set, it is shown that the proposed method can detect the abnormal points of power consumption data, and the detection effect is better.

Keywords

anomaly detection of energy consumption, gated recurrent unit, autoencoder, deep autoencoder, reconstruction error

Recommended Citation

Ningke Sun, Yan Wang, Zhicheng Ji. Anomaly Detection Method of Electrical Power Consumption Based on Deep Autoencoder[J]. *Journal of System Simulation*, 2022, 34(12): 2557-2565.

基于深度自编码器的电力能耗异常检测方法

孙宁可, 王艳*, 纪志成

(江南大学 物联网技术应用教育部工程研究中心, 江苏 无锡 214122)

摘要: 针对电力能耗数据的非线性和不平稳特征, 提出了一种基于深度自编码器的电力能耗异常检测模型。将深度学习的门控循环单元网络和自编码器结构相结合, 通过传统自编码器的编码器和解码器部分采用门控循环单元网络来实现, 充分发挥门控循环单元的数据特征提取能力和自编码器结构的数据重构功能。根据原始数据和重构数据之间的重构误差来检测电力能耗异常数据点。将所提方法应用于实际的车间电力能耗数据集, 结果表明: 所提方法能够对电力能耗数据进行异常点检测, 检测效果良好。

关键词: 能耗异常检测; 门控循环单元; 自编码器; 深度自编码器; 重构误差

中图分类号: TP391.9

文献标志码: A

文章编号: 1004-731X(2022)12-2557-09

DOI: 10.16182/j.issn1004731x.joss.22-FZ0931

Anomaly Detection Method of Electrical Power Consumption Based on Deep Autoencoder

Sun Ningke, Wang Yan*, Ji Zhicheng

(Engineering Research Center of Internet of Things Technology Applications Ministry of Education, Jiangnan University, Wuxi 214122, China)

Abstract: Aiming at the nonlinear and non-stationary characteristics of electrical power consumption data, an abnormal electrical power consumption detection model based on deep autoencoder is proposed. Gated recurrent unit (GRU) network of the deep learning is combined with autoencoder structure, and the encoder and decoder parts of traditional autoencoder are realized by gated recurrent unit network, which gives full play to the data feature extraction capability of gated recurrent unit and the data reconstruction function of autoencoder structure. Based on the reconstruction error between original data and reconstructed data, abnormal data points of the electrical power consumption are detected. By applying the proposed method to actual workshop electrical power consumption data set, it is shown that the proposed method can detect the abnormal points of power consumption data, and the detection effect is better.

Keywords: anomaly detection of energy consumption; gated recurrent unit; autoencoder; deep autoencoder; reconstruction error

引言

“智能制造”和“大数据”等创新理念在我国各类企业中影响深刻, 随着科学技术的进一步发展, 大量的生产数据可以实现采集, 有助于对生产状况进行更详细的分析, 其中电力能耗数据更

是备受关注。2021年, 国务院发布了《完善能源消费强度和总量双控制度方案》, 在国家政策严格要求下, 各企业开始注重能源能耗管理, 以节能减耗、提高能效为发展目标^[1]。在工业生产过程中, 电力能耗异常检测具有十分重要的意义^[2]。对

收稿日期: 2022-08-07

修回日期: 2022-09-26

基金项目: 国家重点研发计划(2018YFB1701903); 国家自然科学基金(61973138)

第一作者: 孙宁可(1998-), 男, 硕士生, 研究方向为工业装备与节能控制。E-mail: 191253041@qq.com

通讯作者: 王艳(1978-), 女, 博士, 教授, 研究方向为制造系统能效优化。E-mail: wangyan@jiangnan.edu.cn

生产设备进行电力能耗异常检测可以及时检测设备异常工作状态,从而提高生产稳定性^[3];对生产车间进行电力能耗异常检测可以帮助企业及时排查能耗异常时间点,从而合理规划能源利用,降低能源不必要的浪费^[4]。

电力能耗异常检测属于时间序列异常检测问题,主要方法包括统计模型、相似度分析模型和偏差分析模型^[5]。统计模型不需要训练,实现简单,但是检测准确度较低;相似度分析模型主要基于聚类、密度、距离等进行建模,准确度较统计模型高,但计算复杂程度高;偏差分析模型主要将数据进行降维再重建,将重构误差作为异常检测依据。自编码器是当前新型的方法,通过结合深度学习网络,异常检测效果较好^[6]。

曩莹等^[7]充分考虑时间序列模式的多样性,提出了基于Seq2Seq深度自编码器的异常检测方法,利用Bi-LSTM网络构建深度自编码器,通过设定重建异常比率来确定误差阈值,实现了对空气质量时间序列数据的异常序列检测。Oleksandr I. Provotar等^[8]为解决异常性质未知的异常检测问题,提出了一种基于LSTM自编码器的时间序列无监督异常检测方法,将LSTM网络应用于自编码器,通过在多样的人工信号数据集和罕见声音异常事件检测数据集中进行测试,验证了该方法的可行性和广泛适用性。陈磊等^[9]将集成思想应用于自编码器结构,基于长短期记忆自编码器提出了集成LSTM-AE,在模型训练阶段中加入预检测阶段,在预检测阶段选择隐层维度不同的检测器,采用多个检测器来共同实现对时间序列的异常检测。Li Yulin等^[10]提出了小波自编码器异常检测方法,将小波变换思想引入自编码器结构,首先将离散小波变换应用与滑动时间窗序列,得到小波变换系数,然后使用自编码器来重构小波变换系数,从而实现对非平稳、非周期单变量时间序列的异常检测。综上所述,自编码器是时间序列异常检测的新型方法,随着深度学习的不断发展,出现了结合深度学习网络和自编码器结构的深度

自编码器异常检测模型,在各类异常检测实验中效果突出,但是在电力能耗异常检测方面还没有得到具体应用,仍有很大的研究空间。

因此,本文将深度学习的门控循环单元(gated recurrent unit, GRU)网络与自编码器结构合理结合,提出了基于GRU深度自编码器的电力能耗异常检测模型。一方面,发挥门控循环单元的数据特征提取能力与长期规律记忆能力;另一方面,利用自编码器结构的数据重构特性,来实现对电力能耗数据的异常检测。

1 方法及原理

1.1 自编码器

自编码器(AE)是一种特定的神经网络结构,用于实现将高维数据简化为低维形式,并使用中心层来重建高维输入向量^[11]。自编码器由编码器和解码器组成。编码器将输入数据转换为一个新的表示形式,解码器将该表示形式重构回原始格式^[12],基本结构如图1所示。




图1 自编码器基本结构图

Fig. 1 Basic structure diagram of autoencoder

其中,编码器用于实现从输入层高维形式到隐藏层低维形式的变换,而解码器则用于实现从隐藏层低维形式到输出层高维形式的数据重构。通过自编码器结构的不断训练,输出近似于原始输入的重构结果。

编码器、解码器和损失函数的计算关系式如下。

编码器:

$$h = f(Wx + b) \tag{1}$$

解码器:

$$\hat{x} = f'(W'h + b') \tag{2}$$

损失函数:

$$\Delta = f_1(x, \hat{x}) \tag{3}$$

式中: x 为原始输入数据; f, f' 为非线性函数, 用于编码与解码; f_1 为损失计算函数, 用于计算损失; W, W' 为权重矩阵; b, b' 为偏置向量, 隐藏层神经元通过解码器解码输出重构后的 \hat{x} 。

自编码器用于电力能耗数据异常检测的主要方式为: 首先通过编码器将电力能耗数据变换为低维隐含形式; 然后利用解码器将该隐含形式重构回高维表示形式, 在训练过程中提高数据重构效果, 训练完成后选定重构误差阈值; 最后运用训练完成后的自编码器来实现异常检测。但是在传统的自编码器中, 编码器和解码器不能充分学习数据的深层次特征和长期性特征, 对于非线性数据的重构效果欠佳。而电力能耗数据大多周期性不明显、波动无规律、非线性变化, 因此需要引入深度学习的门控循环单元网络。

1.2 门控循环单元

GRU 是循环神经网络 (recurrent neural networks, RNN) 的一个类型。RNN 是一种深度学习模型, 其特征明显, 网络的输入和输出使用环路, 是前馈神经网络 (feedforward neural network, FNN) 的一个高级版本。FNN 不适合用于时间性数据和递归数据, 而 RNN 可以用于时间性数据和递归数据, 其典型结构如图 2 所示。




图 2 循环神经网络结构

Fig. 2 Architecture of recurrent neural network architecture

RNN 的传递公式为

$$s_t = f(Ux_t + Ws_{t-1} + b_u) \tag{4}$$

$$o_t = g(Vs_t + b_v) \tag{5}$$

式中: x_t 为 t 时刻输入向量; U, V, W 为权重矩阵; b_u, b_v 为偏置向量; s_t, s_{t-1} 分别为 t 和 $t-1$ 时刻隐藏层的输出; o_t 为 t 时刻网络的输出; f, g 为激活函数。

相较于传统的神经网络来说, RNN 能够更好地处理时间序列数据^[13], 然而也存在梯度消失和爆炸问题。

因而基于传统 RNN 提出了长短期记忆 (LSTM) 网络。LSTM 网络可以处理长度可变的序列, 并捕获其中的长期依赖性和非线性关系, 适用于数据深层特征提取。LSTM 网络采用了 LSTM 层替代传统的隐含层, 并且拥有 3 个门结构, 其隐含层内部结构如图 3 所示。

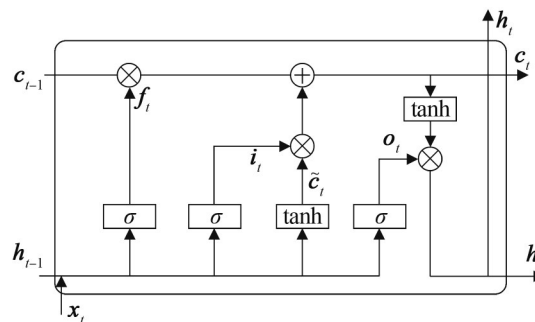


图 3 LSTM 网络隐含层内部记忆单元结构

Fig. 3 Hidden layer internal memory unit structure of LSTM network

图 3 中 x_t 为 t 时刻的输入; h_t 为 t 时刻的隐含层输出; f_t, i_t, c_t, o_t 分别为 t 时刻的遗忘门、输入门、细胞状态和输出门; \tilde{c}_t 为记忆单元的输入状态; σ 为 Sigmoid 函数; \tanh 为双曲正切函数; \otimes 为矩阵元素相乘; c_{t-1}, h_{t-1} 为 $t-1$ 时刻的细胞状态与隐含层输出。

网络输出计算过程如下。

计算遗忘门的输出值:

$$f_t = \sigma(W_{hf}h_{t-1} + W_{xf}x_t + b_f) \tag{6}$$

计算输入门的值:

$$i_t = \sigma(W_{hi}h_{t-1} + W_{xi}x_t + b_i) \tag{7}$$

计算记忆单元的输入状态:

$$\tilde{c}_t = \tanh(W_{hc}h_{t-1} + W_{xc}x_t + b_c) \quad (8)$$

更新细胞状态:

$$c_t = f_t \circ c_{t-1} + i_t \circ \tilde{c}_t \quad (9)$$

计算输出门的值:

$$o_t = \sigma(W_{ho}h_{t-1} + W_{xo}x_t + b_o) \quad (10)$$

计算 t 时刻的隐藏层输出:

$$h_t = o_t \circ \tanh(c_t) \quad (11)$$

式中: W_{hf} 、 W_{xf} 、 W_{hi} 、 W_{xi} 、 W_{hc} 、 W_{xc} 、 W_{ho} 、 W_{xo} 为权重矩阵; b_f 、 b_i 、 b_c 、 b_o 为偏置向量。

3个门结构的相互配合使得LSTM网络具有了一定时期内的记忆能力,并且可以遗忘和删除部分信息,能够更好地处理时间序列数据^[14]。

但是LSTM网络具有极其复杂的形式,往往会导致模型训练时间变长等一些问题,2014年Kyunghyun Cho提出了门控循环单元(GRU)网络。

GRU神经网络对LSTM网络进行了简化并对模型中出现的问题进行了完善^[15]。LSTM神经网络由遗忘门、输入门和输出门组成,而GRU模型正是对这三个门进行了处理,将其简化为更新门(update gate)和重置门(reset gate)2个门,其中更新门能够实现LSTM中遗忘门和输入门的功能。这样的结构改变使得GRU网络比标准的LSTM网络更加简洁,加快了训练速度^[16]。对于电力能耗数据而言,异常检测方法一方面要尽可能提高检测精度,有助于发现微小的异常隐患;另一方面也要缩短检测时间,这对于异常检测的实时性至关重要,GRU网络则可以同时满足这2个方面的要求,其神经网络内部结构如图4所示。




图4 门控循环单元结构图

Fig. 4 Structure diagram of gated recurrent unit

与LSTM网络的不同之处在于, \tilde{h}_t 为候选隐藏层状态; h_{t-1} 为 $t-1$ 时刻传递给 t 时刻的隐藏层输出。

GRU网络的具体结构与运算过程如下:

重置门 r_t : 确定 $t-1$ 时刻的隐状态 h_{t-1} 有多大程度更新到 t 时刻的候选隐状态 \tilde{h}_t 。 r_t 值越小,代表 $t-1$ 时刻的隐状态信息被写入的越少,计算公式为

$$r_t = \sigma(W_{hr}h_{t-1} + W_{xr}x_t + b_r) \quad (12)$$

式中: W_{hr} 、 W_{xr} 为重置门的权重矩阵; b_r 为重置门的偏置向量。

更新门 z_t : 确定 $t-1$ 时刻的隐状态 h_{t-1} 有多大程度更新到 t 时刻的隐状态 h_t 。 z_t 值越大,代表 $t-1$ 时刻的隐状态信息被写入的越少^[17],计算公式为

$$z_t = \sigma(W_{hz}h_{t-1} + W_{xz}x_t + b_z) \quad (13)$$

其中: W_{hz} 、 W_{xz} 为更新门的权重矩阵; b_z 为更新门的偏置向量。

更新候选隐藏层状态:

$$\tilde{h}_t = \tanh(r_t \circ W_{hh}h_{t-1} + W_{xh}x_t + b_h) \quad (14)$$

式中: W_{hh} 、 W_{xh} 为候选隐藏层状态的权重矩阵; b_h 为候选隐藏层状态的偏置向量。

输出 h_t 的计算式为

$$h_t = z_t \circ \tilde{h}_t + (1 - z_t) \circ h_{t-1} \quad (15)$$

相较于传统循环神经网络和LSTM网络,GRU模型有2个优点: ①改善了RNN神经网络使用中出现的梯度异常问题^[18]; ②GRU的参数量少,减少过拟合的风险,训练速度比LSTM更快。

因此,对于具有时间性特征的电力能耗数据,传统的RNN虽然处理效果较FNN更好,但是其内部结构特征存在梯度异常问题。LSTM网络在循环神经网络的基础上缓解了梯度异常问题,但是结构较为复杂,运算成本较高。GRU网络既保留了传统循环神经网络处理时间性数据的基本能力,又缓解了梯度异常问题,同时运算复杂度较LSTM网络有所降低,最适合处理具有非线性、不平稳特征的电力能耗数据。

1.3 GRU深度自编码器异常检测模型

深度自编码器(deep autoencoder, DAE)是一种无监督或自监督算法,其本质是一种数据压缩算法^[19]。其结构也分为编码器和解码器2部分,编码器和解码器都采用深度学习的神经网络。

相较于传统自编码器的单层编码器和单层解码器,深度编码器和深度解码器有很多的优势:深度结构可以有效地简化数据压缩或重构过程的计算,降低成本;深度结构可以更高效地学习数据压缩或重构过程的隐含表示,只需更少的训练数据即可达到合适的隐含表示;深度自编码器比浅层或线性自动编码器的数据压缩和重建效果更好。

因此,本文选择采用深度自编码器结构,选取GRU深度学习网络来构建深度编码器和深度解码器,提出一种基于GRU深度自编码器的电力能耗异常检测模型,目的是发挥GRU网络的数据长期特征记忆能力,充分提取电力能耗数据的非线性和不平稳特征,用于实现对电力能耗数据的异常检测,GRU深度自编码器基本结构如图5所示。



图5 GRU深度自编码基本结构图

Fig. 5 GRU deep autoencoder basic structure diagram

其作用流程为:

step 1: 输入原始电力能耗数据并进行数据缺失值处理、预处理和标准化;

step 2: 将预处理后的数据输入GRU编码器进行编码,得到数据隐含状态;

step 3: 将数据隐含状态输入GRU解码器进行解码,得到重构后的数据;

step 4: 重构数据反标准化,得到重构后的电力能耗数据。

其中,GRU编码器和GRU解码器均选择深度

结构,前者起到数据降维作用,将高维输入转换为低维隐含表示;后者起到数据重建作用,重建结果与原始输入维数相同。

GRU深度自编码器异常检测模型主要分为2个阶段:模型训练阶段和异常检测阶段。对于异常检测问题,通常假设正常数据点在数据集中占主导地位。在模型训练阶段,GRU深度自编码器异常检测模型针对训练集数据进行模型训练,通过若干次迭代训练,学习正常点与异常点在模型重构结果上的差异性,寻找到合适的重构异常阈值,将训练阶段得到的阈值作为异常检测阶段的异常点判断阈值,以此实现由训练集到测试集的阈值传递。对于正常点来说,模型的重构效果较好,重构误差较小;对于异常点来说,模型的重构效果较差,重构误差较大。在异常检测阶段,以模型训练阶段获得的重构异常阈值为依据,将重构误差大于该重构异常阈值的数据点视为异常点,从而进行电力能耗数据的异常检测。GRU深度自编码器异常检测模型异常检测流程如图6所示。

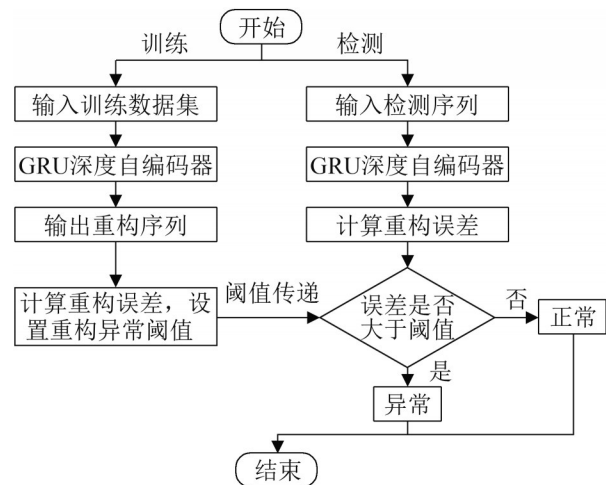


图6 GRU深度自编码器异常检测流程图

Fig. 6 Anomaly detection flow chart of GRU deep autoencoder

2 实验结果与分析

2.1 实验数据集

实验所用的电力能耗数据来自江苏某药企中

药生产车间，为每小时的电力能耗数据，时间范围2021-11-01—12-30，共1440个样本，其中包含对应的车间工作日或休息日的标注信息和车间工作时间区的标注信息。数据集中的缺失点采用当天其余时间点的数据平均值替换，处理后的原始电力能耗数据序列如图7所示。其中选取70%作为训练数据集，30%作为检测验证数据集，为在对比实验中定量分析算法性能，提前对验证集数据的异常点进行了分析和标注。




图7 原始电力能耗数据

Fig. 7 Original electrical power consumption data

根据图7中的电力能耗数据变化曲线可以分析得出：一方面，电力能耗数据随时间变化，具有时间序列特性；另一方面，电力能耗数据的变化是非线性、不平稳的，传统的统计模型不能够准确分析数据特征。

因此，本文选取GRU深度自编码器来实现对电力能耗数据的异常检测，通过GRU深度学习网络来提取电力能耗数据的深层特征和长期特征，配合自编码器更好地实现对电力能耗数据的异常检测。

2.2 GRU深度自编码器构建

本文采用Python环境下的TensorFlow 2深度学习库来构建GRU深度自编码器模型。实验环境为Windows 10，64位，CPU为i5-11400H，显卡

为RTX3050，内存为16 GB。

首先，对电力能耗数据进行标准化，所用方法为Z-score；然后构建编码器和解码器，编码器采用2层GRU网络，解码器采用同样采用2层GRU网络；接着构建dropout层，dropout比率为0.2；最后构建全连接层，激活函数为线性整流函数(relu)。模型的训练损失函数选择均方误差(MSE)，优化器选择adam，学习率为0.001，训练轮数(epoch)为200，完整参数设置如表1所示。

表1 实验参数设置

Table 1 Experimental parameter setting

参数名称	参数设置
optimizer	Adam
dropout rate	0.2
learning rate	0.001
epoch	200
batch size	24

损失函数的计算公式为

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (16)$$

式中： y_i 为原始电力能耗数据； \hat{y}_i 为训练时的重构结果。

2.3 实验结果

为了进行电力能耗数据的异常检测，需要定义重构误差的计算方式，本文主要对电力能耗数据进行重构，因此采用重构结果与原始电力能耗数据之间差值的绝对值作为数据重构误差：

$$error_i = |m_i - \hat{m}_i| \quad (17)$$

式中： m_i 为原始电力能耗数据； \hat{m}_i 为GRU深度自编码器模型的重构结果。

模型训练阶段结束后，训练集数据的重构结果如图8所示，其结果进行了反标准化，并与原始数据进行对比。在实验中，为了选取合适的重构异常阈值，需要直观地观察数据重构结果与原始电力能耗数据之间的重构误差分布情况，因此将其以分布直方图的形式呈现，如图9所示。对于无监督异常检测问题，重构异常阈值的选取主要通过设定数据

的异常百分比, 本文选取重构误差大于95%的数据点为异常点, 重构异常阈值为2.04。




图8 训练集重构结果

Fig. 8 Reconstruction results of training set




图9 重构误差分布情况

Fig. 9 Distribution of reconstruction errors

在本文提出的检测模型中, 选取的重构异常阈值在训练数据集和检测验证数据集中的异常点识别方式如图10所示。重构误差高于临界线的数据点被识别为异常点, 重构误差低于临界线的数据点则为正常点, 从而实现对电力能耗数据的异常点检测功能。

GRU深度自编码器模型训练完成, 并完成重构异常阈值确定后, 即可对检测验证数据集进行异常数据点检测。检测验证数据集不参与模型训练过程, 只用于模型异常检测阶段, 防止出现数据泄露。




图10 重构异常阈值作用分析图

Fig. 10 Reconstruction function analysis diagram of abnormal threshold

在仿真实验中, 为了对比本文提出方法和传统检测方法的异常检测效果, 选取了基于RNN的自编码器和LSTM深度自编码器来对本文使用的电力能耗数据集进行异常检测。为更好地对比本文提出模型与2种对比方法的异常检测性能, 选择准确率 P 、召回率 R 、 P 和 R 的调和平均值 F_1 作为判断指标, 3个指标值越大, 代表检测效果越好。计算公式为

$$P = T_p / (T_p + F_p) \quad (18)$$

$$R = T_p / (T_p + F_n) \quad (19)$$

$$F_1 = 2PR / (P + R) \quad (20)$$

式中: T_p 为检测正常且实际正常的样本数; F_p 为检测正常但实际异常的样本数; F_n 为检测异常但实际正常的样本数。

分别使用训练完成的传统RNN自编码器模型、LSTM深度自编码器模型和GRU深度自编码器模型对验证集数据进行异常检测, 具体检测指标如表2所示。从表2中可以看出, 2种深度自编码器模型的 P 指标、 R 指标和 F_1 指标均明显高于传统RNN自编码器模型, 说明深度结构能够提高异常检测的效果。LSTM深度自编码器模型与GRU深度自编码器模型的3项指标相差不大, 从检测效果来看表现相近。

表2 检测指标对比
Table 2 Comparison of detection indexes

检测模型	P	R	F_1
传统RNN自编码器	0.948	0.891	0.918
LSTM深度自编码器	0.970	0.951	0.961
GRU深度自编码器	0.973	0.953	0.963

为了研究传统RNN自编码器模型、LSTM深度自编码器模型和GRU深度自编码器模型在异常检测时间上的差异性，分别采用3种方式对本文所用数据集进行了20次异常检测，平均运行时间如表3所示。从表中数据可知，LSTM深度自编码器由于模型深度的增加，平均运行时间约为传统RNN自编码器模型的3倍；而GRU深度自编码器模型采用了结构简化的GRU网络，平均运行时间相较于LSTM深度自编码器模型降低了56.8%。

表3 平均运行时间
Table 3 Average running time s

检测模型	平均运行时间
传统RNN自编码器	157.63
LSTM深度自编码器	474.66
GRU深度自编码器	204.95

综上所述，本文提出的GRU深度自编码器异常检测模型能够实现对实际电力能耗数据的异常检测。采用GRU深度学习网络来处理原始电力能耗数据，提取数据特征并且保留电力能耗数据的长期性信息，完成对电力能耗数据的编码降维与解码重构。根据直观的重构误差分布直方图和设定异常数据百分比来选定重构异常阈值，最后在检测阶段完成对电力能耗数据的异常检测。同时，提出模型的算法平均运行时间约为3'25"，对于每小时的电力能耗数据，能够满足异常检测的时间要求。

3 结论

本文提出了一种结合GRU深度学习网络和自编码器结构的GRU深度自编码器模型，用于实现对电力能耗数据的异常检测。针对传统自编码器的编码器和解码器处理非线性、不平稳的电力能

耗数据的效果不佳问题，选择GRU深度学习网络来替代传统的编码器和解码器。通过GRU深度学习网络来处理电力能耗数据，挖掘数据深层特征，提高自编码器结构对数据的重构效果。通过在实际电力能耗数据集上的实验和方法对比分析，验证了该方法的可行性，实现了对电力能耗数据的异常检测，达到了良好的检测效果。

参考文献:

- [1] 江航, 卢瞰, 顾寒苏, 等. 一种动态实时高校建筑能耗异常检测方法[J]. 计算机工程, 2017, 43(4): 15-20, 27.
Jiang Hang, Lu Tun, Gu Hansu, et al. A Dynamic and Real-time Outlier Detection Method for Energy Consumption of Campus Building[J]. Computer Engineering, 2017, 43(4): 15-20, 27.
- [2] 代德宇, 何江涛, 吴中元. 基于PSO-BP算法的铜管生产过程能耗异常检测模型[J]. 机电工程技术, 2016, 45(9): 128-132.
Dai Deyu, He Jiangtao, Wu Zhongyuan. Copper Tube Production Process Energy Consumption of Anomaly Detection Model Based on PSO-BP Algorithm[J]. Mechanical & Electrical Engineering Technology, 2016, 45(9): 128-132.
- [3] 杨海东, 江海昌, 方华, 等. 基于GA-SVR的挤压机能耗异常检测模型研究[J]. 机床与液压, 2019, 47(5): 163-168.
Yang Haidong, Jiang Haichang, Fang Hua, et al. Study on Abnormal Energy Consumption Model of Extruder Based on GA-SVR[J]. Machine Tool & Hydraulics, 2019, 47(5): 163-168.
- [4] 段中兴, 梅思雨. 基于数据挖掘的建筑能耗异常检测研究[J]. 计算机测量与控制, 2020, 28(7): 253-259.
Duan Zhongxing, Mei Siyu. Research on Abnormal Detection of Building Energy Consumption Based on Data Mining[J]. Computer Measurement & Control, 2020, 28(7): 253-259.
- [5] Zhao Z, Zhang Y, Zhu X, et al. Research on Time Series Anomaly Detection Algorithm and Application[C]//2019 IEEE 4th Advanced Information Technology, Electronic and Automation Control Conference (IAEAC). Chengdu, China: IEEE, 2019: 16-20.
- [6] El-Fiqi H, Wang M, Kasmarik K, et al. Weighted Gate Layer Autoencoders[J]. IEEE Transactions on Cybernetics(S2168-2275), 2022, 52(8): 7242-7253.
- [7] 樊莹, 吴越. 基于Seq2Seq深度自编码器的时间序列异常检测方法研究[J]. 现代电子技术, 2022, 45(2): 26-30.

- Cuan Ying, Wu Yue. Method of Time Series anomaly Detection Based on Seq2Seq Depth Autoencoder[J]. Modern Electronics Technique, 2022, 45(2): 26-30.
- [8] Provotar O I, Linder Y M, Veres M M. Unsupervised Anomaly Detection in Time Series Using LSTM-Based Autoencoders[C]//2019 IEEE International Conference on Advanced Trends in Information Theory (ATIT). Kyiv, Ukraine: IEEE, 2019: 513-517.
- [9] 陈磊, 秦凯, 郝矿荣. 基于集成LSTM-AE的时间序列异常检测方法[J]. 华中科技大学学报(自然科学版), 2021, 49(11): 35-40.
- Chen Lei, Qin Kai, Hao Kuangrong. Time Series Anomaly Detection Method Based on Integrated LSTM-AE[J]. Journal of Huazhong University of Science and Technology(Natural Science Edition), 2021, 49(11): 35-40.
- [10] Li Y L, Jiang J R. Anomaly Detection for Non-Stationary and Non-Periodic Univariate Time Series[C]//2020 IEEE Eurasia Conference on IOT, Communication and Engineering (ECICE). Yunlin, Taiwan: IEEE, 2020: 177-179.
- [11] Mansouri N, Lachiri Z. Laughter Synthesis: A Comparison between Variational Autoencoder and Autoencoder[C]//2020 5th International Conference on Advanced Technologies for Signal and Image Processing (ATSIP). Sousse, Tunisia: IEEE, 2020: 1-6.
- [12] Barreto F, Yadav S, Patnaik S, et al. SIFT Features for Deep and Variational Autoencoders: A Performance Comparison[C]//2020 2nd International Conference on Advances in Computing, Communication Control and Networking (ICACCCN). Greater Noida, India: IEEE, 2020: 652-655.
- [13] Xu X, Zhao H, Liu H, et al. LSTM-GAN-XGBOOST Based Anomaly Detection Algorithm for Time Series Data[C]//2020 11th International Conference on Prognostics and System Health Management (PHM-2020 Jinan). Jinan, China: IEEE, 2020: 334-339.
- [14] Zhu G, Zhao H, Liu H, et al. A Novel LSTM-GAN Algorithm for Time Series Anomaly Detection[C]//2019 Prognostics and System Health Management Conference (PHM-Qingdao). Qingdao, China: IEEE, 2019: 1-6.
- [15] Zhai N, Yao P, Zhou X. Multivariate Time Series Forecast in Industrial Process Based on XGBoost and GRU[C]//2020 IEEE 9th Joint International Information Technology and Artificial Intelligence Conference (ITAIC). Chongqing, China: IEEE, 2020: 1397-1400.
- [16] Yang S, Yu X, Zhou Y. LSTM and GRU Neural Network Performance Comparison Study: Taking Yelp Review Dataset as an Example[C]//2020 International Workshop on Electronic Communication and Artificial Intelligence (IWEC AI). Shanghai, China: IEEE, 2020: 98-101.
- [17] 高德亮. 基于AdamW算法的WT-GRU模型在高频股指预测中的应用[D]. 济南: 山东大学, 2021.
- Gao Deliang. Application of WT-GRU Model Based on AdamW Algorithm in High Frequency Stock Index Forecasting[D]. Ji'nan: Shandong University, 2021.
- [18] Yu K, Long Z. A TCP Friendly Rate Control Algorithm Based on GRU Prediction Model[C]//2021 Asia-Pacific Conference on Communications Technology and Computer Science (ACCTCS). Shenyang, China: IEEE, 2021: 21-24.
- [19] Xu Q, Wu Z, Yang Y, et al. The Difference Learning of Hidden Layer Between Autoencoder and Variational Autoencoder[C]//2017 29th Chinese Control and Decision Conference (CCDC). Chongqing, China: IEEE, 2017: 4801-4804.