

基于深度学习的用户异常用电模式检测

赵文清, 沈哲吉, 李 刚

(华北电力大学 控制与计算机工程学院, 河北 保定 071003)

摘要:针对电力用户的异常用电行为,提出一种基于深度学习的用户异常用电模式检测模型。利用 TensorFlow 框架,构建了特征提取网络和多层特征匹配网络。基于长短期记忆(LSTM)的特征提取网络,从大量时间序列中提取出不同的序列特征。基于全连接网络(FCN)的多层特征匹配网络,利用提取出的特征数据,完成对异常用电数据的检测。实例分析表明,与非深度学习检测模型相比,所提模型可更加有效地完成异常用电模式检测。此外,与多层 LSTM 分类模型相比,所提模型具有更好的准确性和鲁棒性。

关键词:智能电网;深度学习;长短期记忆;神经网络;用电模式;异常检测;非技术性损失

中图分类号:TM 715

文献标识码:A

DOI:10.16081/j.issn.1006-6047.2018.09.006

0 引言

配电侧电力用户的窃电、欺诈等一系列欺骗性用电行为所导致的损失统称为非技术性损失 NTL (Non-Technical Loss)。非技术性损失对电网的正常运行会产生严重的影响,扰乱地区电网的正常调度,甚至会由于用户私自改接线路而引发安全事故。非技术性损失在实际运行的电网中普遍存在,在某些国家中,非技术性损失约占用电总量的 12.5%~25%^[1]。在印度、巴西和墨西哥,非技术性损失分别占其全国用电量的 26.2%、16.85%和 15.83%^[2]。我国的非技术性损失相对较低,占全国用电总量的 6.42%^[2]。但由于我国电能需求总体庞大,且近年来用电量不断攀升^[3],在 2016 年由非技术性损失所带来的经济损失高达 190 亿元。因此,研究降低非技术性损失有着非常重要的现实社会意义。

当今电网公司主要通过加强计量设备管理、采用专用计量箱或采用防撬铅封和选择合理电流互感器倍率等方法来降低非技术性损失^[4]。但这些方法需要投入额外的人力物力,且不能及时发现非技术性损失。随着电网的智能化程度不断提高,以及远程用电信息采集系统的使用与推广,电网公司可以通过分析远程用电信息采集系统中的数据来降低非技术性损失^[5]。但是,目前依然存在一些问题。首先,电网公司中用户用电数据非常庞大。文献[6-7]中指出截至 2013 年年底,国家电网公司累计安装智能电表 1.82 亿只,实现用电信息采集 1.91 亿户。如果一个地区以 100 万只智能电表来计算,一年积累的数据量就可高达 3.18 TB。其次,由于某些因素会使得数据出现缺失和错误,甚至在国外存在一些黑客组织专门针对智能电表发动网络攻击^[8]。

为解决非技术性损失检测问题,国内外学者进行了许多研究,提出了各种模型。这些模型可概括性地归为 3 类:基于统计学的模型、基于专家知识的模型和基于数据驱动的模型。文献[9-10]通过带权最小二乘法和高斯核函数分析用户用电数据,从而判断出可疑的交易信息记录。这种方法的误报率较高,不适合电网的大规模实际应用。为提高模型的准确性,文献[11]基于人工经验规则库,实现对于异常交易记录与异常用户的识别工作。这种模型依赖专家知识规则,因此通用性不高。数据驱动模型具有更好的准确性和通用性,文献[12-13]使用历史数据构建 BP 神经网络和用户行为分析模型,以实现异常用电模式的检测。文献[13-16]都是对用户交易记录信息进行数据挖掘,得到用户用电数据的特征,以实现异常用电模式的检测,但这些方法难以从大量高维度数据中提取出数据的特征和特征匹配。

为克服上述缺点,本文提出一种基于深度学习的用户异常用电模式检测的模型。利用 TensorFlow 框架构建深度学习模型,主要由两部分组成,分别是基于长短期记忆(LSTM)的特征提取网络和基于全连接网络(FCN)的多层特征匹配网络。由于用户用电数据主要为时间序列数据,而 LSTM 网络相对于其他网络(卷积神经网络和自编码网络)更适合处理时间序列数据^[17]。在特征提取网络中,通过多个特征提取模块,以实现输入数据的特征提取。在多层特征匹配网络中,通过 FCN 处理特征序列,以实现用户用电模式的特征匹配,完成用户用电模式的异常检测。

1 相关技术介绍

1.1 TensorFlow 框架

TensorFlow 框架是谷歌基于 DistBelief 研发的人工智能学习系统,具有高度的灵活性和可移植性。目前,TensorFlow 框架是主要的深度学习框架之一。

收稿日期:2018-02-11;修回日期:2018-07-12

基金项目:国家自然科学基金资助项目(51407076)

Project supported by the National Natural Science Foundation of China(51407076)

本文通过 TensorFlow 框架建立基于深度学习的用户异常用电模式检测的模型,实现对用户用电数据的异常模式的检测。

1.2 LSTM 结构和结构递归神经网络

LSTM 结构通常由一个或者多个长短期记忆块 (LSTM block) 组成。长短期记忆块结构由四部分组成,分别为输入门、输出门、遗忘门和长短期记忆单元 (LSTM cell)。长短期记忆块组成结构如附录中图 A1 所示。

结构递归神经网络 RNN (Recursive Neural Network) 是利用多个相似的神经网络结构递归构造更为复杂的深度网络,其结构在 2 维平面上类似于树结构。附录中图 A2 为一种结构递归神经网络的示意图。

通常情况下,在递归过程中易发生权重指数级爆炸或消失的问题,使结构递归神经网络难以捕捉数据之间的关联。而基于 LSTM 的结构递归神经网络能较好地避免上述问题,并且在基因分类和机器翻译等领域取得了不错的成绩^[18-19]。

2 基于深度学习的用户异常用电模式检测模型

为了更好地完成异常用电模式检测,本文提出一种基于深度学习的用户异常用电模式检测的模型,如图 1 所示。该模型通过深度学习找出用电数据与用户用电模式之间的关系,分析出异常的用电数据。




图 1 基于深度学习的用户异常用电模式检测模型

Fig.1 Anomaly power consumption detection model based on deep learning

2.1 数据源与数据集

本文使用的数据源来自于某防窃电公司采集的用户电表数据,数据采集的时间间隔为 15 min,数据样本为数据源部分数据。取某电表一天的三相电流

数据构成一条样本数据,数据维度为 288 维。标签数据来自于该公司专家分析与现场稽查的结果。为保证数据的安全性,数据集均经过脱敏处理;为能更接近实际情况,在训练集中降低异常用电数据比例;为测试模型学习异常用电数据特征的能力,在测试集中适当增加异常数据。

2.2 数据预处理

由于数据可能出现重复、缺失甚至错误等问题,因此对数据进行预处理。本文所用的预处理方法主要为数据的清洗与归一化处理。数据清洗主要是删除重复信息、填补缺失信息和纠正错误信息等。数据归一化处理如式(1)所示。

$$\mathbf{x}'_i = \frac{\mathbf{x}_i - \text{mean}(\mathbf{x})}{\max(\mathbf{x}) - \min(\mathbf{x})} \quad (1)$$

其中, $\mathbf{x}$ 为样本数据, $\mathbf{x} = [x_1, x_2, \dots, x_n]$, n 为样本数; $\text{mean}(\mathbf{x})$ 表示计算样本平均值; $\max(\mathbf{x})$ 表示计算样本最大值; $\min(\mathbf{x})$ 表示计算样本最小值; $\mathbf{x}'_i$ 为归一化处理后的数据。

2.3 特征提取网络

2.3.1 特征提取模块

为提取数据中的特征数据,本文采用特征提取模块 FEM (Feature Extracting Module) 进行特征提取。特征提取模块由多个长短期记忆块垂直连接组成,即上一个长短期记忆块的输出作为下一个长短期记忆块的输入,其结构如附录中图 A3 所示。图中, $\mathbf{x}_{in}^{(t)}$ 为时刻 t 的输入数据; $\mathbf{x}_{feature}^{(t)}$ 为时刻 t 提取得到的特征数据; $\mathbf{x}_{outm}$ 为第 m 个长短期记忆块的输出; M 为长短期记忆块数。本文采用 3 个长短期记忆块构成的特征提取模块。

2.3.2 特征提取网络的结构

在许多实际问题中,模型需要处理高维度数据。一般地,有多种不同的特征以及特征之间的关系隐含在高维度数据中,这些特征和关系能有效地反映数据的特性。从数据中提取的特征以及特征之间的关系越多,将越有利于模型做出准确的判断。而在很多情况下,单一的特征提取模块难以从高维度数据中提取多种特征以及特征之间的关系。

为解决上述问题,本文将输入的高维度数据 $\mathbf{x}$ 划分成为 3 个大小相同的子数据: $\mathbf{x}_1$, $\mathbf{x}_2$ 和 $\mathbf{x}_3$ ($\mathbf{x}_a \cap \mathbf{x}_b = \emptyset$; $\mathbf{x}_1 \cup \mathbf{x}_2 \cup \mathbf{x}_3 = \mathbf{x}$ 。其中 $\forall (a, b), a \neq b; a = 1, 2, 3; b = 1, 2, 3$)。针对子数据,利用由 10 个特征提取模块所构建的结构递归神经网络,实现输入的高维度数据 $\mathbf{x}$ 的特征提取。特征提取网络结构如附录中图 A4 所示。图中, $\mathbf{x}^{(t)}$ 为时刻 t 输入的数据, $\mathbf{x}^{(t)}$ 被分解为 3 个子数据 $\mathbf{x}_1$, $\mathbf{x}_2$ 和 $\mathbf{x}_3$; $\text{FEM}_{i,j}$ 表示第 j 层的第 i 个特征提取模块; $\mathbf{h}_{i,j}$ 表示 $\text{FEM}_{i,j}$ 的输出数据; $\mathbf{s}^{(t)}$ 表示 $\text{FEM}_{4,1}$ 的输出数据,也表示从 $\mathbf{x}^{(t)}$ 中提取得

到的特征数据。本文中, $\mathbf{h}_{1,j}(j=1,2,3)$ 均为 64 维输出数据, $\mathbf{h}_{2,j}(j=1,2,3)$ 均为 48 维输出数据, $\mathbf{h}_{3,j}(j=1,2,3)$ 均为 32 维输出数据, $\text{FEM}_{4,1}$ 输出 96 维特征数据。

通过如附录中图 A4 所示的特征提取网络结构, 实现从高维度(如 2.1 节所述, 288 维)数据 $\mathbf{x}$ 中提取出特征数据。首先, 从输入数据 $\mathbf{x}$ 的子集数据($\mathbf{x}_1$ 、 $\mathbf{x}_2$ 和 $\mathbf{x}_3$) 中提取特征; 然后, 通过多层结构递归的特征提取, 逐渐压缩特征数据的维度并维持特征间关系, 从而使提取的特征数据具有整体性, 能较为完整地反映输入数据特性; 最后, $\text{FEM}_{4,1}$ 输出 96 维数据 $\mathbf{s}=[s_1, s_2, \dots, s_{96}]$, 该 96 维数据就是所需要的特征数据, 从而完成了高维度数据的特征提取。

2.4 多层特征匹配网络

使用 2.3 节中特征提取网络所得到的特征数据, 实现用户用电模式的特征匹配, 进而完成数据类型的标注。为实现该目的, 本文利用一个由 3 层全连接的隐含层组成的神经网络实现用户特征数据的匹配工作。多层特征匹配网络结构如附录中图 A5 所示。图中, $\mathbf{s}=[s_1, s_2, \dots, s_{96}]$ 表示特征提取网络所得到的 96 维特征数据; λ_k 表示第 k 层网络到第 $k+1$ 层网络的偏置; $L_{k,n}$ 表示第 k 层隐含层的第 n 个节点; Output 表示输出层。

该特征匹配模型中, 输入层输入数据为 96 维, 第 1 层隐含层输出数据为 64 维, 第 2 层隐含层输出数据为 32 维, 第 3 层隐含层输出数据为 16 维, 输出层输出数据为 2 维, 该 2 维数据为不同标注类型的权值, 最终完成分类。

2.5 损失计算与梯度优化

本文使用损失函数来计算当前模型的损失偏差程度。通过损失函数的计算, 进行反馈调节, 调整各个神经网络的参数设置。本文中所用损失函数如式(2)所示。

$$f_{\text{Loss}} = -\text{mean}[\mathbf{y}_{\text{real}} \ln(\mathbf{y}_{\text{class}})] \quad (2)$$

其中, $\mathbf{y}_{\text{real}}$ 表示实际的分类标签; $\mathbf{y}_{\text{class}}$ 表示分类结果。

对于上述损失函数, 本文使用适应性矩阵估计进行优化, 得到最小化损失函数值。反馈调节部分由 TensorFlow 框架完成。

2.6 模型评价方法

本文使用混淆矩阵^[20]对模型的结果进行评价。定义异常用电数据为负类, 正常用电数据为正类。分类结果用混淆矩阵表示, 如附录中表 A1 所示, 行(Positive/Negative)对应实际所属的类别, 列(True/False)表示分类器预测的类别。在混淆矩阵的基础上, 可以产生多种模型评价指标。本文使用准确率 f_{Metric1} 和漏警率 f_{Metric2} 进行评价, 具体定义如下:

$$f_{\text{Metric1}} = \frac{n_{\text{TP}} + n_{\text{TN}}}{n_{\text{TP}} + n_{\text{TN}} + n_{\text{FP}} + n_{\text{FN}}} \quad (3)$$

$$f_{\text{Metric2}} = \frac{n_{\text{FN}}}{n_{\text{TN}} + n_{\text{FN}}} \quad (4)$$

其中, n_{TP} 为将正常数据分类为正常的数目; n_{TN} 为将异常数据分类为异常的数目; n_{FP} 为将正常数据分类为异常的数目; n_{FN} 为将异常数据分类为正常的数目。

准确率是正确识别数目占测试样本的比率, 这个指标越高, 反映出模型错误识别用电模式为异常的可能性越低。漏警率是模型错误识别异常用电数据占总的异常数据的比率, 这个指标越低, 反映出模型错误识别用电模式为正常的可能性越低。

3 实验分析

为了验证本文所提模型的有效性, 与其他非深度学习模型(支持向量机和 BP 神经网络)进行对比实验。该实验进行 5 次, 取平均值。此外, 该模型也与常规的多层 LSTM 所构成的深度学习模型进行对比实验。该实验进行 5 次, 2 个模型运行周期均为 15 000。

3.1 实验数据与实验环境

本文采用的数据集为 2.1 节中所介绍的数据样本。数据样本包含若干电力用户 2 个月内的三相电流数据, 总计 3 863 条数据。训练集中异常用电数据有 309 条, 正常数据有 3 422 条, 异常数据占训练集的 8.28%。测试集中异常用电数据有 51 条, 正常数据有 81 条, 异常数据占测试集的 38.64%。算法运行平台为已经搭建好的 TensorFlow 深度学习平台。实验平台为一台 PC, 其中央处理器(CPU)为 Intel E3 4 核, 内存(RAM)为 8 G, 显卡(GPU)为 NVIDIA GTX 960。

3.2 实验结果与分析

3.2.1 本文所提模型实验结果

文本所提模型在测试集上的分类结果如下: TP 类平均为 80.6 条, FP 类平均为 0.4 条, TN 类平均为 46 条, FN 类平均为 5 条。由此可得本文所提模型的准确率和漏警率指标如下: 模型准确率为 95.90%, 漏警率为 9.80%。

3.2.2 与非深度学习模型的对比

为验证本文所提模型的有效性, 与非深度学习模型(支持向量机模型和 BP 神经网络模型)进行了对比实验。非深度学习模型在测试集上的分类结果如下: 非深度学习模型能正确识别 TP 类数据 81 条; 而对于异常数据, 支持向量机模型识别 TP 类 25 条, FN 类 26 条, BP 神经网络模型识别 TP 类 17 条, FN 类 34 条。

计算各模型的准确率和漏警率, 得到评价指标结果如下: 本文所提模型的准确率为 95.90%, 高于支持向量机和 BP 神经网络的 81.06% 和 87.12%; 本

文所提模型漏警率为 9.80%, 低于支持向量机和 BP 神经网络的 50.98% 和 66.67%。由此说明, 本文所提模型相对于支持向量机和 BP 神经网络具有更好的性能。

3.2.3 与多层 LSTM 深度学习模型的对比

本文所提模型与常规的多层 LSTM 模型^[17]进行了对比实验。其相应的混淆矩阵对比结果如下: 多层 LSTM 模型识别 TP 类平均为 75.4 条, FP 类平均为 5.6 条, TN 类平均为 45.2 条, FN 类平均为 5.8 条; 而本文所提模型识别 TP 类平均为 80.6 条, FP 类平均为 0.4 条, TN 类平均为 46 条, FN 类平均为 5 条。

计算各模型的准确率和漏警率, 得到评价指标结果对比如下: 本文所提模型准确率为 95.90%, 高于多层 LSTM 模型的 91.36%; 本文所提模型的漏警率为 9.80%, 低于多层 LSTM 模型的 11.37%。由此可知, 本文所提模型相对于多层 LSTM 模型具有更好的性能。此外, 为了能够体现模型的鲁棒性, 记录了 2 个模型在 15 000 个训练周期中, 在测试集上的准确率, 如图 2 所示。




图 2 2 个模型的准确率对比

Fig.2 Comparison of accuracy between two models

从图 2 可以看出, 本文模型和多层 LSTM 模型在大约 5 000 个周期后, 2 个模型准确率变化程度变小, 可认为 2 个模型生成趋于稳定; 在大约 5 000 个周期后, 本文所提模型的准确率比多层 LSTM 模型高; 本文所提模型在大约 5 000 个周期后, 模型准确率变化幅度比多层长短期 LSTM 小。

综上所述, 本文所提模型相对于多层 LSTM 模型, 具有更好的准确性和鲁棒性。

4 结论

本文提出了一种基于深度学习的用户异常用电模式检测的模型。该模型能从实际的用户数据中检测得到用电模式存在异常的数据。所做工作如下: 利用 TensorFlow 框架, 成功构建了一个基于深度学习的用户异常用电模式检测模型; 利用多个特征提取模块构建了基于结构递归神经网络的特征提取网络; 利用 3 层全连接神经网络构建了一个数据特征匹配的神经网络。

将本文所提模型与支持向量机和 BP 神经网络进行对比实验。实验结果说明, 本文提出的模型相对于非深度学习模型有更好的性能, 能够发现用电

模式存在异常的数据, 具有更高的准确性。此外, 本文所提模型相对于多层 LSTM 模型具有更好的准确性和鲁棒性。

在后续工作中, 将研究如何加快深度学习模型的学习速度, 缩减模型生成所需要的时间, 更为有效地提取用户用电模式特征和优化特征匹配, 以满足实际需求。

致 谢

本文中实验方案的制定和实验数据的测量记录工作是在保定市新源绿网电力科技有限公司的工作人员的大力支持下完成的, 在此向他们表示衷心的感谢。

附录见本刊网络版 (<http://www.epae.cn>)。

参考文献:

- [1] GASTALDELLO D, SOUZA A, FORTI T, et al. Study of proposed identification of non-technical losses of electricity in Brazil [C] // Electricity Consumption Analysis and Energy Efficiency. Portolm, Portugal: ELECO, 2013: 50-56.
- [2] ANGELOS E W S, SAAVEDRA O R, CORTÉS O A C, et al. Detection and identification of abnormalities in customer consumptions in power distribution systems [J]. IEEE Transactions on Power Delivery, 2011, 26(4): 2436-2442.
- [3] 杨漾. 2016 年中国全社会用电量同比增长 5% 上年仅 0.5% [EB/OL]. (2017-01-17) [2017-12-23]. <http://finance.qq.com/a/20170117/012249.htm>.
- [4] 梁毅涵. 供电企业反窃电管理综合评价研究 [D]. 北京: 华北电力大学, 2016.
LIANG Yihan. Research on comprehensive evaluation of anti power theft management in power supply company [D]. Beijing: North China Electric Power University, 2016.
- [5] 刘利平, 蔡广林, 陈旭, 等. 考虑用电可靠性的客户用电信息管理系统 [J]. 电力自动化设备, 2018, 38(4): 204-209.
LIU Liping, CAI Guanglin, CHEN Xu, et al. Electricity information management system considering power utilization reliability [J]. Electric Power Automation Equipment, 2018, 38(4): 204-209.
- [6] 王德文, 孙志伟. 电力用户侧大数据分析与并行负荷预测 [J]. 中国电机工程学报, 2015, 35(3): 527-537.
WANG Dewen, SUN Zhiwei. Big data analysis and parallel load forecasting of electric power user side [J]. Proceedings of the CSEE, 2015, 35(3): 527-537.
- [7] 王桂兰, 周国亮, 赵洪山, 等. 大规模用电数据流的快速聚类 and 异常检测技术 [J]. 电力系统自动化, 2016, 40(24): 27-33.
WANG Guilan, ZHOU Guoliang, ZHAO Hongshan, et al. Fast clustering and anomaly detection techniques for large scale power data streams [J]. Automation of Electric Power Systems, 2016, 40(24): 27-33.
- [8] LEITE J B, MANTOVANI J R S. Detecting and locating non-technical losses in modern distribution networks [J]. IEEE Transactions on Smart Grid, 2016, 9(2): 1023-1032.
- [9] LO Y L, HUANG S C, LU C N. Non-technical loss detection using smart distribution network measurement data [C] // IEEE PES Innovative Smart Grid Technologies. Tianjin, China: IEEE, 2012: 1-5.

- [10] 孙毅,李世豪,崔灿,等. 基于高斯核函数改进的电力用户用电数据离群点检测方法[J]. 电网技术,2018,42(5):1595-1606.
SUN Yi, LI Shihao, CUI Can, et al. Improved outlier detection method of power consumer data based on Gaussian kernel function[J]. Power System Technology, 2018, 42(5):1595-1606.
- [11] SONG D H, KO Y J, SHIN J T. A study on the development of real-time Intrusion Detection Expert System (IDES) [J]. Technical Report of Ieicelsec, 1993, 93(296):7-17.
- [12] ÍÑIGO M, BISCARRI F, LEÓN C, et al. MIDAS: detection of non-technical losses in electrical consumption using neural networks and statistical techniques [M]. Berlin Heidelberg, Germany: Springer, 2006:725-734.
- [13] 陈碧云,丁晋,陈绍南. 基于关联规则挖掘的电力生产安全事故事件关键诱因筛选[J]. 电力自动化设备,2018,38(4):68-74.
CHEN Biyun, DING Jin, CHEN Shaonan. Selection of key incentives for power production safety accidents based on association rule mining[J]. Electric Power Automation Equipment, 2018, 38(4):68-74.
- [14] 苏适,李康平,严玉廷,等. 基于密度空间聚类和引力搜索算法的居民负荷用电模式分类模型[J]. 电力自动化设备,2018,38(1):129-136.
SU Shi, LI Kangping, YAN Yuting, et al. Classification model of residential power consumption mode based on DBSCAN and gravitational search algorithm[J]. Electric Power Automation Equipment, 2018, 38(1):129-136.
- [15] 郝然,艾芊,肖斐. 基于多元大数据平台的用电行为分析构架研究[J]. 电力自动化设备,2017,37(8):20-27.
HAO Ran, AI Qian, XIAO Fei. Architecture based on multivariate big data platform for analyzing electricity consumption behavior[J]. Electric Power Automation Equipment, 2017, 37(8):20-27.
- [16] 庄池杰,张斌,胡军,等. 基于无监督学习的电力用户异常用电模式检测[J]. 中国电机工程学报,2016,36(2):379-387.
ZHUANG Chijie, ZHANG Bin, HU Jun, et al. Anomaly detection for power consumption patterns based on unsupervised learning[J]. Proceedings of the CSEE, 2016, 36(2):379-387.
- [17] GRAVES A. Supervised sequence labelling with recurrent neural networks [M]. Berlin Heidelberg, Germany: Springer, 2012:37-45.
- [18] DITZLER G, POLIKAR R, ROSEN G. Multi-layer and recursive neural networks for metagenomic classification[J]. IEEE Transactions on Nanobioscience, 2015, 14(6):608-616.
- [19] LUONG M T, SUTSKEVER I, LE Q V, et al. Addressing the rare word problem in neural machine translation[J]. Bulletin of University of Agricultural Sciences and Veterinary Medicine Cluj-Napoca. Veterinary Medicine, 2014, 27(2):82-86.
- [20] STEHMAN S V. Selecting and interpreting measures of thematic classification accuracy[J]. Remote Sensing of Environment, 1997, 62(1):77-89.

作者简介:



赵文清(1973—),女,山西朔州人,教授,博士,主要研究方向为人工智能与数据挖掘(E-mail:jibzwq@126.com)。

Anomaly detection for power consumption pattern based on deep learning

ZHAO Wenqing, SHEN Zheji, LI Gang

(Department of Control and Computer, North China Electric Power University, Baoding 071003, China)

Abstract: To deal with the anomalous power consumption behavior of users, a model of anomaly detection for power consumption pattern based on deep learning is proposed, in which the TensorFlow framework is employed to establish a feature extracting network and a multi-layer feature matching network. The feature extracting network based on LSTM(Long Short Term Memory) extracts different sequence features from large-scale time series data. The multi-layer feature matching network, which is based on FCN(Fully Connected Network), uses the extracted different sequence features to detect the anomalous electrical power consumptions. Case studies show that the proposed model can detect the anomalous power consumption mode with higher efficiency compared to non-deep learning models. Compared to the multi-layer LSTM classification model, the proposed model is more precise and robust.

Key words: smart grid; deep learning; long short term memory; neural networks; power consumption patterns; anomaly detection; non-technical loss

附录




图 A1 长短期记忆块

Fig.A1 Long short term memory block




图 A2 一种结构递归神经网络

Fig.A2 A type of recursive neural network




图 A3 特征提取模块

Fig.A3 Architecture of feature extracting modular




图 A4 特征提取网络结构

Fig.A4 Architecture of feature extracting network




图 A5 多层特征匹配结构

Fig.A5 Architecture of multiple feature matching network

表 A1 混淆矩阵
Table A1 Confusion matrix

数据	分类结果 Positive/Negative	
实际	True Positive(TP)	True Negative(TN)
True/False	False Positive(FP)	False Negative(FN)