



(12) 发明专利申请

(10) 申请公布号 CN 116879672 A

(43) 申请公布日 2023. 10. 13

(21) 申请号 202310636611.4

G06F 18/24 (2023.01)

(22) 申请日 2023.05.31

G06N 3/045 (2023.01)

(71) 申请人 国网上海市电力公司

G06N 3/0464 (2023.01)

地址 200122 上海市浦东新区中国(上海)
自由贸易试验区源深路1122号

G06N 3/049 (2023.01)

G06N 3/08 (2023.01)

(72) 发明人 丁冬 张立 陈佳瑜 史光宇
陆增洁 张希鹏 李亦言

(74) 专利代理机构 上海三和万国知识产权代理
事务所(普通合伙) 31230
专利代理师 蔡海淳

(51) Int. Cl.

G01R 31/08 (2020.01)

G01R 31/00 (2006.01)

G06F 18/213 (2023.01)

G06F 18/214 (2023.01)

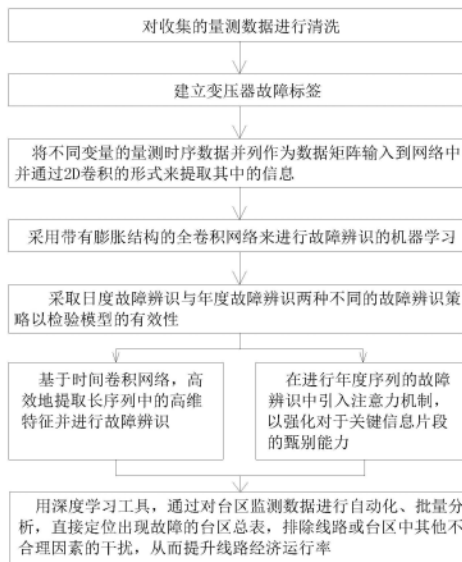
权利要求书2页 说明书8页 附图4页

(54) 发明名称

一种基于时间卷积网络的台区总表故障智能辨识方法

(57) 摘要

一种基于时间卷积网络的台区总表故障智能辨识方法,属电能计量领域。包括通过2D卷积的形式来提取量测时序数据矩阵其中的信息;采用时间卷积网络来进行变压器故障辨识的机器学习;将输入数据矩阵中的高维特征提取并压缩至输出层,进一步用于故障的辨识;采取日度故障辨识与年度故障辨识两种不同的故障辨识策略;用深度学习工具,通过对台区监测数据进行自动化、批量分析,直接定位出现故障的台区总表,排除线路或台区中其他不合理因素的干扰,从而提升线路经济运行率。可以提取每个变量单独包含的时间序列特征,同时可以横向提取变量之间的相关性;在保证信息提取效果的前提下大幅减少网络的参数规模,从而提升计算效率。



1. 一种基于时间卷积网络的台区总表故障智能辨识方法,包括各个变压器台区总表量测数据的收集和清洗,其特征是:

- 1) 建立变压器故障标签;
- 2) 将不同变量的量测时序数据并列作为数据矩阵输入到网络中,并通过2D卷积的形式来提取其中的信息;
- 3) 采用时间卷积网络来进行变压器故障辨识的机器学习;
- 4) 通过增大包括卷积核尺寸、增加堆叠数量、提升膨胀率在内的方式来增大网络的感受野;
- 5) 将输入数据矩阵中的高维特征提取并压缩至输出层,进一步用于故障的辨识;
- 6) 在使用单一注意力函数的基础上,采用多头注意力机制来提升总体表现;
- 7) 采取日度故障辨识与年度故障辨识两种不同的故障辨识策略;
- 8) 基于时间卷积网络,高效地提取长序列中的高维特征并进行故障辨识;
- 9) 在进行年度序列的故障辨识中引入注意力机制,以强化对于关键信息片段的甄别能力
- 10) 用深度学习工具,通过对台区监测数据进行自动化、批量分析,直接定位出现故障的台区总表,排除线路或台区中其他不合理因素的干扰,从而提升线路经济运行率。

2. 按照权利要求1所述的基于时间卷积网络的台区总表故障智能辨识方法,其特征是所述变压器台区总表量测数据表示为:

$$\mathbf{X} = \begin{bmatrix} x_1^1 & x_2^1 & \cdots & x_L^1 \\ x_1^2 & x_2^2 & \cdots & x_L^2 \\ \vdots & \vdots & \ddots & \vdots \\ x_1^E & x_2^E & \cdots & x_L^E \end{bmatrix}$$

其中E表示量测变量的个数,L表示量测序列的长度。

3. 按照权利要求2所述的基于时间卷积网络的台区总表故障智能辨识方法,其特征是所述的量测变量至少包括压、电流、功率。

4. 按照权利要求1所述的基于时间卷积网络的台区总表故障智能辨识方法,其特征是所述的变压器故障辨识为二分类问题, $Y=0$ 表示正常状态, $Y=1$ 表示故障状态;

则故障辨识的机器学习表示为 $Y=f(X)$,即通过机器学习模型 f ,以量测序列为输入,判别在量测时间内变压器是否存在故障。

5. 按照权利要求1所述的基于时间卷积网络的台区总表故障智能辨识方法,其特征是所述的时间卷积网络为带有膨胀结构的全卷积网络;

令卷积核表示为 $F=[f_0, f_1, \cdots, f_{M-1}]$,其中M为卷积核的数量;

则针对输入矩阵X中元素 x^m 的膨胀卷积运算 $\mathcal{G}(\cdot)$ 表示为:

$$\mathcal{G}(x^m) = \sum_{i=0}^{K-1} f_i \cdot x^{m-d \cdot i}$$

其中d为膨胀率, $m-d \cdot i$ 则为 x^m 之前元素的指针;

当膨胀率 $d=1$ 时,该网络则退化为传统的卷积网络;

而当膨胀率 $d>1$ 时,膨胀卷积运算将跳过前一层中 $(d-1)/d$ 的元素,并只聚焦于剩余的 $1/d$ 个元素;

膨胀率的上述特征可显著地提升网络的感受野,并降低网络的复杂度。

6.按照权利要求5所述的基于时间卷积网络的台区总表故障智能辨识方法,其特征是所述的感受野用下式计算:

$$R_{field} = 1 + 2 \cdot (K - 1) \cdot N_{stack} \cdot \sum_i d_i$$

其中K为卷积核的大小, N_{stack} 为网络的堆叠数量。

7.按照权利要求1所述的基于时间卷积网络的台区总表故障智能辨识方法,其特征是所述基于时间卷积网络的台区总表故障智能辨识方法,在使用单一注意力函数的基础上,并行采用多个注意力函数将有助于提升总体表现,即多头注意力机制;

其所述多头注意力机制的计算如下式所示:

$$\text{MultiHead}(Q, K, V) = \text{concat}(\text{head}_1, \text{head}_2, \dots, \text{head}_n) W^0$$

$$\text{head}_i = \text{Attention}(QW_i^Q, KW_i^K, VW_i^V)$$

其中 W_i^Q, W_i^K, W_i^V 和 W^0 为映射过程中可学习的参数矩阵。

8.按照权利要求1所述的基于时间卷积网络的台区总表故障智能辨识方法,其特征是所述基于时间卷积网络的台区总表故障智能辨识方法,在日度异常辨识中,使用经典的TCN结构;在年度故障辨识中,引入注意力机制,以提升对于关键信息片段的提取能力,从而提升模型的精度。

9.按照权利要求1所述的基于时间卷积网络的台区总表故障智能辨识方法,其特征是所述基于时间卷积网络的台区总表故障智能辨识方法,将不同变量的量测时序数据并列作为数据矩阵输入到网络中,并通过2D卷积的形式来提取其中的信息;提取每个变量单独包含的时间序列特征,同时横向提取变量之间的相关性;在此基础上,利用时间卷积网络其独有的膨胀卷积结构,在保证信息提取效果的前提下,幅减少网络的参数规模,从而提升计算效率。

10.按照权利要求1所述的基于时间卷积网络的台区总表故障智能辨识方法,其特征是所述基于时间卷积网络的台区总表故障智能辨识方法,采用时间卷积网络来高效地提取不同量测变量的相关性,从而提升故障辨识的精度;利用深度学习工具,通过对台区监测数据进行自动化、批量分析,直接定位出现故障的台区总表,排除线路或台区中其他不合理因素的干扰,从而提升线路经济运行率。

一种基于时间卷积网络的台区总表故障智能辨识方法

技术领域

[0001] 本发明属于电能测量领域,尤其涉及一种基于时间卷积网络的台区总表故障智能辨识方法。

背景技术

[0002] 台区总表关联10kV线路售电侧电量及台区供电侧电量,起到了承上启下的作用。

[0003] 台区总表故障导致的电能量异常,会同时对10kV及台区线损的计算产生影响,造成线损合理率下降,影响对台区电量的监测,错估台区的负载率,不利于供电可靠性。对于台区总表故障的有效辨识,是解决以上问题的关键。

[0004] 由于线路关联台区数量多、单一台区电量小、波动不明显、影响因素复杂等原因,台区电量异常在10kV线损治理中是普遍存在的问题,难以精准判别该异常是否由台区总表故障所导致。

[0005] 目前主要通过人为分析加现场核查的方式进行排查,准确率较低且带来显著的人力成本。

[0006] 台区总表中出现的常见故障包括采集异常、现场与档案倍率不一致、表计失压失流、表计电压电流极性错接等。

[0007] 目前对于台区总表故障的直接研究相对较少,主要聚焦于对台区内线损异常的分析。

[0008] 例如,“基于GBDT的电力计量设备故障预测”(刘金硕,刘必为,张密,等.《计算机科学》,2019,46(S1):392-396.)中,公开了基于梯度提升决策树(GBDT)的台区计量设备故障类型辨识方法及其寿命周期的预测方法,并采用实际数据对设计的模型进行了有效性和先进性的验证,但该方法仅考虑故障数据,对于计量设备当前状态运行数据的挖掘不足;“基于多分类融合模型的智能电表故障预测”(陈叶,韩彤,魏龄,等.《电测与仪表》:1-9.)中提出一种多分类器融合的台区电表故障辨识方法,在对故障数据预处理后采用融合算法构建多分类器,其融合策略本质上是一种投票机制,并未考虑不同分类器对于不同故障的识别能力;“基于大数据分析的智能电表故障预测技术研究”(范少华.北京邮电大学,2018.)中分析了智能电表各个属性与故障类型之间的关联关系,提出了一种基于加权列抽样的XGBoost台区计量设备故障预测方法,并在电表故障数据上证实了方法的有效性,但该方法所选用的数据粗糙度较高,所包含的相关属性信息较少。

[0009] 此外,“基于k-means聚类算法的低压台区线损异常辨别方法”(陈洪涛,蔡慧,李熊,王颖,郑恩辉.《南方电网技术》,2019,13(02))中公开了采用k-means聚类等非监督学习方法,对原始线损数据进行聚类,进而分析不同类别所对应的故障原因以及线损异常程度,为检修决策提供支持;“基于深度神经网络的低压台区线损异常识别方法”(王海云,张岩,闫富荣,陈雁,杨莉萍,常乾坤,张再驰,陈茜,袁清芳.《电力需求侧管理》,2018,20(06):31-35.)以及“基于无线通信和大数据技术的低压台区同期线损异常诊断系统”(李建宁,马小丽,颜华敏,蒋晨.《电力与能源》,2019,40(01):36-40.)中公开了采用神经网络等监督学习

算法,对经过标记的线损数据进行分类或回归,进而实现对线损故障的判别。

[0010] 然而,以上现有分析方法对于已有数据的挖掘与利用程度仍有待提升,具体体现在:

[0011] 1) 多个量测变量,如电压、电流、功率、三相不平衡率等之间存在着相关性,传统辨识方法往往针对单个变量进行分析,未能充分利用变量之间的相关关系来提高故障辨识的精度;

[0012] 2) 长序列数据中关键片段的聚焦与提取。台区数据往往保存相对完好,长度可达数年。而在这丰富的历史数据中,异常数据可能只存在于少数短暂的片段。如何从大量正常数据中自动提取出有效的故障相关信息并加以分析利用,并兼顾模型的简洁与效率,目前尚未得到很好的解决。

发明内容

[0013] 本发明所要解决的技术问题是提供一种基于时间卷积网络的台区总表故障智能辨识方法。针对于现有方法不能很好地提取多量测量之间关联性的缺陷,本技术方案采用的时间卷积网络可以高效地提取不同量测变量的相关性,从而提升故障辨识的精度。其利用深度学习工具,通过对台区Ts-run监测数据进行自动化、批量分析,可以直接定位出现故障的台区总表,排除线路或台区中其他不合理因素的干扰,从而提升线路经济运行率。

[0014] 本发明的技术方案是:提供一种基于时间卷积网络的台区总表故障智能辨识方法,包括各个变压器台区总表量测数据的收集和清洗,其特征是:

[0015] 1) 建立变压器故障标签;

[0016] 2) 将不同变量的量测时序数据并列作为数据矩阵输入到网络中,并通过2D卷积的形式来提取其中的信息;

[0017] 3) 采用时间卷积网络来进行变压器故障辨识的机器学习;

[0018] 4) 通过增大包括卷积核尺寸、增加堆叠数量、提升膨胀率在内的方式来增大网络的感受野;

[0019] 5) 将输入数据矩阵中的高维特征提取并压缩至输出层,进一步用于故障的辨识;

[0020] 6) 在使用单一注意力函数的基础上,采用多头注意力机制来提升总体表现;

[0021] 7) 采取日度故障辨识与年度故障辨识两种不同的故障辨识策略;

[0022] 8) 基于时间卷积网络,高效地提取长序列中的高维特征并进行故障辨识;

[0023] 9) 在进行年度序列的故障辨识中引入注意力机制,以强化对于关键信息片段的甄别能力

[0024] 10) 用深度学习工具,通过对台区监测数据进行自动化、批量分析,直接定位出现故障的台区总表,排除线路或台区中其他不合理因素的干扰,从而提升线路经济运行率。

[0025] 具体的,所述变压器台区总表量测数据表示为:

$$[0026] \quad \mathbf{X} = \begin{bmatrix} x_1^1 & x_2^1 & \cdots & x_L^1 \\ x_1^2 & x_2^2 & \cdots & x_L^2 \\ \vdots & \vdots & \ddots & \vdots \\ x_1^E & x_2^E & \cdots & x_L^E \end{bmatrix}$$

[0027] 其中E表示量测变量的个数,L表示量测序列的长度。

[0028] 进一步的,所述的量测变量至少包括压、电流、功率。

[0029] 具体的,所述的变压器故障辨识为二分类问题, $Y=0$ 表示正常状态, $Y=1$ 表示故障状态;

[0030] 则故障辨识的机器学习表示为 $Y=f(X)$,即通过机器学习模型 f ,以量测序列为输入,判别在量测时间内变压器是否存在故障。

[0031] 具体的,所述的时间卷积网络为带有膨胀结构的全卷积网络;

[0032] 令卷积核表示为 $F=[f_0, f_1, \dots, f_{M-1}]$,其中 M 为卷积核的数量;

[0033] 则针对输入矩阵 X 中元素 x^m 的膨胀卷积运算 $\mathcal{G}(\cdot)$ 表示为:

$$[0034] \quad \mathcal{G}(x^m) = \sum_{i=0}^{K-1} f_i \cdot x^{m-d \cdot i}$$

[0035] 其中 d 为膨胀率, $m-d \cdot i$ 则为 x^m 之前元素的指针;

[0036] 当膨胀率 $d=1$ 时,该网络则退化为传统的卷积网络;

[0037] 而当膨胀率 $d>1$ 时,膨胀卷积运算将跳过前一层中 $(d-1)/d$ 的元素,并只聚焦于剩余的 $1/d$ 个元素;

[0038] 膨胀率的上述特征可显著地提升网络的感受野,并降低网络的复杂度。

[0039] 进一步的,所述的感受野用下式计算:

$$[0040] \quad R_{field} = 1 + 2 \cdot (K - 1) \cdot N_{stack} \cdot \sum_i d_i$$

[0041] 其中 K 为卷积核的大小, N_{stack} 为网络的堆叠数量。

[0042] 具体的,所述基于时间卷积网络的台区总表故障智能辨识方法,在使用单一注意力函数的基础上,并行采用多个注意力函数将有助于提升总体表现,即多头注意力机制;

[0043] 其所述多头注意力机制的计算如下式所示:

$$[0044] \quad \text{MultiHead}(Q, K, V) = \text{concat}(\text{head}_1, \text{head}_2, \dots, \text{head}_n) W^o$$

$$[0045] \quad \text{head}_i = \text{Attention}(QW_i^Q, KW_i^K, VW_i^V)$$

[0046] 其中 W_i^Q, W_i^K, W_i^V 和 W^o 为映射过程中可学习的参数矩阵。

[0047] 具体的,所述基于时间卷积网络的台区总表故障智能辨识方法,在日度异常辨识中,使用经典的TCN结构;在年度故障辨识中,引入注意力机制,以提升对于关键信息片段的提取能力,从而提升模型的精度。

[0048] 本发明所述基于时间卷积网络的台区总表故障智能辨识方法,将不同变量的量测时序数据并列作为数据矩阵输入到网络中,并通过2D卷积的形式来提取其中的信息;提取每个变量单独包含的时间序列特征,同时横向提取变量之间的相关性;在此基础上,利用时间卷积网络其独有的膨胀卷积结构,在保证信息提取效果的前提下,幅减少网络的参数规模,从而提升计算效率。

[0049] 本发明所述基于时间卷积网络的台区总表故障智能辨识方法,采用时间卷积网络来高效地提取不同量测变量的相关性,从而提升故障辨识的精度;利用深度学习工具,通过对台区监测数据进行自动化、批量分析,直接定位出现故障的台区总表,排除线路或台区中其他不合理因素的干扰,从而提升线路经济运行率。

[0050] 与现有技术比较,本发明的优点是:

[0051] 1.本发明的技术方案,采取两种不同的故障辨识策略以检验模型的有效性,即日

度故障辨识与年度故障辨识；日度故障辨识通过读入日度量测值以判定变压器在当日是否存在异常；年度故障辨识则读入整年的量测值，以判定在该年度中变压器是否存在故障；

[0052] 2. 本发明的技术方案，将不同变量的量测时序数据并列作为数据矩阵输入到网络中，并通过2D卷积的形式来提取其中的信息；不仅可以提取每个变量单独包含的时间序列特征，同时可以横向提取变量之间的相关性；在此基础上，考虑传统深度卷积网络具有较高的模型复杂度和计算时间成本，本专利的技术方案采用的时间卷积网络具有稀疏特征，其独有的膨胀卷积结构可以在保证信息提取效果的前提下大幅减少网络的参数规模，从而提升计算效率；

[0053] 3. 本发明的技术方案，提出了基于时间卷积网络(Temporal Convolutional Nets, TCN)的台区总表故障辨识算法；TCN具有膨胀卷积结构，可高效地提取长序列中的高维特征并进行故障辨识；进一步地，在进行年度序列的故障辨识中引入注意力机制(Attention)，以强化对于关键信息片段的甄别能力；

[0054] 4. 本发明的技术方案，通过提取台区量测值时间序列中的高维特征，实现对故障的辨识；进一步地，在年度序列故障辨识中引入注意力机制，以甄别出关键的信息片段，提升辨识的准确率；其所提出的故障辨识算法，可实现93.1%的日度故障辨识精度以及85.3%的年度故障辨识精度，且相比传统深度学习模型具有更高的计算效率。

附图说明

[0055] 图1是时间卷积网络结构示意图；

[0056] 图2是多头注意力机制示意图；

[0057] 图3a至图3d是电量异常或故障变压器量测值示例图；

[0058] 图4是TCN与CNN-LSTM模型训练过程示意图；

[0059] 图5是TCN模型测试结果示意图；

[0060] 图6a是引入注意力机制前的年度序列故障辨识混淆矩阵示意图；

[0061] 图6b是引入注意力机制后的年度序列故障辨识混淆矩阵示意图；

[0062] 图7是本发明台区总表故障智能辨识方法的流程方框示意图。

具体实施方式

[0063] 下面结合附图和实施例对本发明做进一步说明。

[0064] 一、模型方法：

[0065] 变压器台区总表的量测数据可表示为

$$[0066] \quad \mathbf{X} = \begin{bmatrix} x_1^1 & x_2^1 & \cdots & x_L^1 \\ x_1^2 & x_2^2 & \cdots & x_L^2 \\ \vdots & \vdots & \ddots & \vdots \\ x_1^E & x_2^E & \cdots & x_L^E \end{bmatrix}$$

[0067] 其中E表示量测变量的个数(如电压、电流、功率等)，L表示量测序列的长度。变压器故障标签用Y表示。

[0068] 在本技术方案中，变压器故障辨识本质为二分类问题，Y=0表示正常状态，Y=1表示故障状态。则故障辨识的机器学习表示为 $Y=f(X)$ ，即通过机器学习模型f，以量测序列为

输入,判别在量测时间内变压器是否存在故障。

[0069] 1.1时间卷积网络:

[0070] 时间卷积网络结构如图1所示,其本质为带有膨胀结构的全卷积网络。

[0071] 令卷积核表示为 $F = [f_0, f_1, \dots, f_{M-1}]$,其中M为卷积核的数量。

[0072] 则针对输入矩阵X中元素 x^m 的膨胀卷积运算 $\mathcal{G}(\cdot)$ 可表示为:

$$[0073] \quad \mathcal{G}(x^m) = \sum_{i=0}^{K-1} f_i \cdot x^{m-d \cdot i}$$

[0074] 其中d为膨胀率, $m-d \cdot i$ 则为 x^m 之前元素的指针。

[0075] 当 $d=1$ 时,该网络则退化为传统的卷积网络。

[0076] 而当 $d>1$ 时,膨胀卷积运算将跳过前一层中 $(d-1)/d$ 的元素,并只聚焦于剩余的 $1/d$ 个元素。

[0077] 该特征可显著地提升网络的感受野,并降低网络的复杂度。

[0078] 模型的感受野可用下式计算

$$[0079] \quad R_{field} = 1 + 2 \cdot (K-1) \cdot N_{stack} \cdot \sum_i d_i$$

[0080] 其中K为卷积核的大小, N_{stack} 为网络的堆叠数量。

[0081] 根据上述模型的感受野的计算公式,可通过增大卷积核尺寸、增加堆叠数量、提升膨胀率等方式来增大网络的感受野。

[0082] 通过该网络,可将输入数据矩阵中的高维特征提取并压缩至输出层,并进一步用于故障的辨识。

[0083] 1.2注意力机制:

[0084] 注意力机制是从输入序列中提取关键信息片段的技术。

[0085] 注意力函数可描述为从查询(Query,Q)以及键值(Key,K)-值项(Value,V)数据对到输出之间的映射,如下式所示:

$$[0086] \quad Attention(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = softmax\left(\frac{\mathbf{QK}^T}{\alpha}\right)\mathbf{V}$$

[0087] 其中Q,K,V均为向量且包含了可训练的参数, α 为比例系数。

[0088] 在使用单一注意力函数的基础上,并行采用多个注意力函数将有助于提升总体表现,即多头注意力机制(Multi-head attention),如图2所示。

[0089] 多头注意力机制的计算方法如下式所示:

$$[0090] \quad MultiHead(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = \text{concat}(\text{head}_1, \text{head}_2, \dots, \text{head}_n) W^0$$

$$[0091] \quad \text{head}_i = Attention(\mathbf{Q}W_i^Q, \mathbf{K}W_i^K, \mathbf{V}W_i^V)$$

[0092] 其中 W_i^Q, W_i^K, W_i^V 和 W^0 为映射过程中可学习的参数矩阵。

[0093] 基于注意力机制,输入序列中的关键信息片段可以被有效甄别出来,且不受信息片段相互之间距离的影响。

[0094] 综上,如图7中所示,本发明的技术方案,提供一种基于时间卷积网络的台区总表故障智能辨识方法,包括各个变压器台区总表量测数据的收集和清洗,其特征是:

[0095] 1) 建立变压器故障标签;

[0096] 2) 将不同变量的量测时序数据并列作为数据矩阵输入到网络中,并通过2D卷积的形式来提取其中的信息;

- [0097] 3) 采用时间卷积网络来进行变压器故障辨识的机器学习;
- [0098] 4) 通过增大包括卷积核尺寸、增加堆叠数量、提升膨胀率在内的方式来增大网络的感受野;
- [0099] 5) 将输入数据矩阵中的高维特征提取并压缩至输出层,进一步用于故障的辨识;
- [0100] 6) 在使用单一注意力函数的基础上,采用多头注意力机制来提升总体表现;
- [0101] 7) 采取日度故障辨识与年度故障辨识两种不同的故障辨识策略;
- [0102] 8) 基于时间卷积网络,高效地提取长序列中的高维特征并进行故障辨识;
- [0103] 9) 在进行年度序列的故障辨识中引入注意力机制,以强化对于关键信息片段的甄别能力
- [0104] 10) 用深度学习工具,通过对台区监测数据进行自动化、批量分析,直接定位出现故障的台区总表,排除线路或台区中其他不合理因素的干扰,从而提升线路经济运行率。
- [0105] 具体的,本发明所述基于时间卷积网络的台区总表故障智能辨识方法,将不同变量的量测时序数据并列作为数据矩阵输入到网络中,并通过2D卷积的形式来提取其中的信息;提取每个变量单独包含的时间序列特征,同时横向提取变量之间的相关性;在此基础上,利用时间卷积网络其独有的膨胀卷积结构,在保证信息提取效果的前提下,幅减少网络的参数规模,从而提升计算效率。
- [0106] 进一步的,本发明所述基于时间卷积网络的台区总表故障智能辨识方法,采用时间卷积网络来高效地提取不同量测变量的相关性,从而提升故障辨识的精度;利用深度学习工具,通过对台区监测数据进行自动化、批量分析,直接定位出现故障的台区总表,排除线路或台区中其他不合理因素的干扰,从而提升线路经济运行率。
- [0107] 二、算例分析:
- [0108] 本发明技术方案所使用的算例数据为某市2920个10kV变压器的台区量测数据。数据长度为2019.7.1至2020.8.1共计13个月,分辨率为15分钟。
- [0109] 每个变压器台区量测值包括三相电压、三相电流、三相有功功率、总功率、无功功率、功率因数、电压不平衡率、电流不平衡率、负载率共计15个变量。
- [0110] 在这2920个变压器中,部分变压器具有明确的电量异常标签与现场故障检测标签。
- [0111] 图3a至图3d中,选取了4个具有电量异常或故障标签的变压器作为示例。
- [0112] 其中,台区#1自2020年3月16日起电量出现异常偏小,且存在部分缺失数据,但并无具体故障标签,表明该现象可能由故障导致,也可能由于用户用电行为改变导致的正常现象。
- [0113] 台区#2的三相电压存在显著的跌落现象,且有较多的缺失数据。根据故障标签,显示为接线盒C相短接。
- [0114] 台区#3标记为电量异常,故障为ABC三相短接。从量测数据来看,可用量测数据非常有限。
- [0115] 台区#4电流存在负值,故障标记为表上C像电流头尾接反。
- [0116] 以上异常或故障标签可用来作为台区故障辨识的标签。
- [0117] 本发明的技术方案,采取两种不同的故障辨识策略以检验模型的有效性,即日度故障辨识与年度故障辨识。

[0118] 日度故障辨识通过读入日度量测值以判定变压器在当日是否存在异常;年度故障辨识则读入整年的量测值,以判定在该年度中变压器是否存在故障。

[0119] 2.1、日度异常辨识:

[0120] 在日度辨识中,首先建立训练样本集,包含正常样本(标记为0)及异常样本(标记为1),每个样本均为 96×15 的数据矩阵。

[0121] 经过统计分析,某市10kV变压器台区数据的完整度约为80%,存在20%的数据缺失。

[0122] 因此,首先对原始数据进行预处理,删除每个变压器中缺失数据超过10%的天数,并对缺失数据小于10%的天数进行基于时序外推、相关性分析的数据补全。

[0123] 在此基础上,进一步筛选出具有明确异常标签的日度样本共计364个。同时,在正常运行的台区中随机选取500个日度样本共同构成训练集。

[0124] 将以上共计864个训练样本切分为训练集(70%,605个),测试集(20%,173个)与验证集(10%,65个)。采用训练集与验证集对模型进行训练,最终在测试集上测试模型的表现。

[0125] 需要注意的是,在日度异常辨识中由于序列长度较短,因此不采用注意力机制,只使用经典的TCN结构。TCN的模型参数设置如表1所示,其感受野为161大于日度序列的长度96,可完备地提取日度序列所包含的信息。

[0126] 表1TCN日度故障辨识模型参数设置

序号	参数名	取值
1	卷积核大小	3
2	模型堆叠层数	1
[0127]	膨胀系数	[1, 3, 9, 27]
4	卷积核数量	64
5	感受野大小	161
	总参数规模	64K

[0128] 图4展示了TCN模型与具有相似总参数规模的卷积-长短期记忆网络模型(CNN-LSTM)训练过程中的损失函数变化。可以看出,TCN模型相比CNN-LSTM模型具有更快的收敛速度与测试精度。

[0129] TCN模型训练耗时约3分钟,经过40次迭代后基本趋于稳定。

[0130] 将训练完成的TCN模型应用于测试集,其分类结果混淆矩阵如图5所示,其综合辨识精度为93.1%。

[0131] 2.1、年度故障辨识:

[0132] 在年度故障辨识中,模型输入为年度量测数据矩阵,尺寸为 $[396 \times 96, 15]$,是典型的长时间序列。

[0133] 与日度异常辨识类似,首先筛选出70个在目标年份具有明确故障标记的变压器台区,并将其标记为1。

[0134] 同时,随机在正常台区中选取100个标记为0,共同构成训练集。

[0135] 对于其中的缺失数据,将其统一填充为0。

[0136] 同样地,将170个样本的数据集切分为训练集(70%,119个),测试集(20%,34个)与验证集(10%,17个)。对于长序列辨识,需要甄别出其中关键的故障信息片段,因此引入

注意力机制。模型参数如表2所示。

[0137] 表2TCN年度故障辨识模型参数设置

	序号	参数名	取值
[0138]	1	卷积核大小	3
	2	模型堆叠层数	1
	3	膨胀系数	[1, 3, 9, 27]
	4	卷积核数量	64
	5	感受野大小	161
注意力 层	6	编码规模	16
	7	注意力头数	10
		总参数规模	243K

[0139] 模型训练完成后,将其应用于测试集以检验其辨识效果。

[0140] 为对比注意力机制的作用,同时给出引入注意力机制前后的模型结果如图6所示。

[0141] 引入前综合辨识精度为67.6%,引入后为85.3%,精度得到明显提升,尤其是对于故障样本的辨识精度提升显著。

[0142] 本发明的技术方案,提出了一种基于时间卷积网络的台区总表故障智能辨识方法。该算法的膨胀卷积结构可明显提升模型的效率,尤其适用于长时间序列的特征提取。进一步地,在年度故障辨识中引入注意力机制,可提升对于关键信息片段的提取能力,从而提升模型的精度。通过对某市10kV台区的真实算例结果表明,所提出的算法可实现93.1%的日度故障辨识精度,以及85.3%的年度故障辨识精度。本发明可广泛用于供电公司各台区总表的电能计量管理以及故障智能识领域。




图1

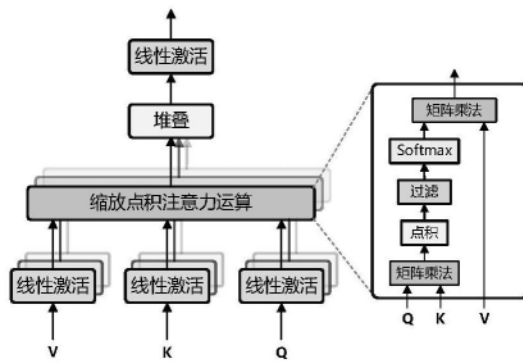


图2




图3a




图3b




图3c




图3d




图4

	预测正常	预测异常
正常样本	89	7
异常样本	11	66

图5

	预测正常	预测异常
正常样本	15	6
异常样本	5	8

图6a

	预测正常	预测异常
正常样本	17	4
异常样本	1	12

图6b

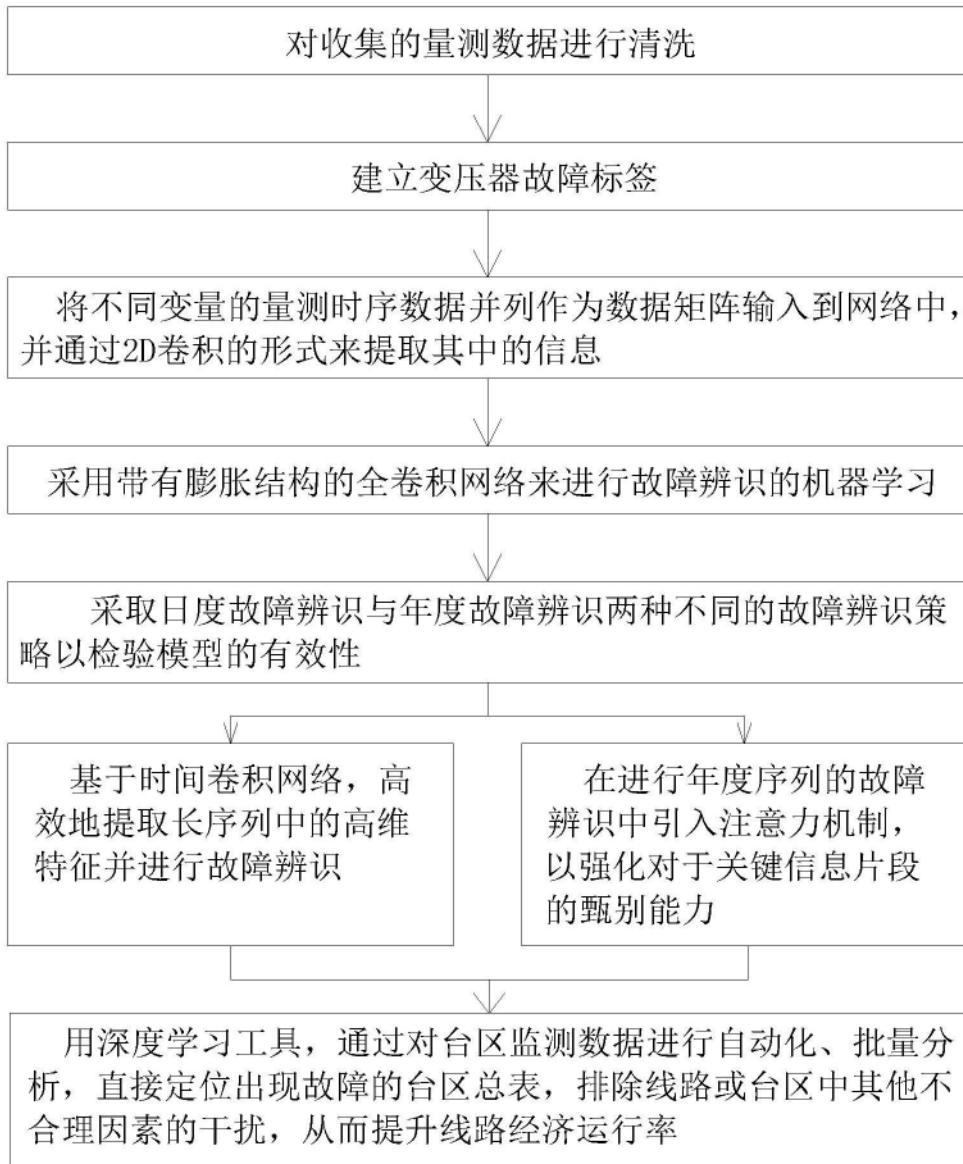


图7