



(12) 发明专利

(10) 授权公告号 CN 112200032 B

(45) 授权公告日 2023.05.30

(21) 申请号 202011041562.2

G01M 13/00 (2019.01)

(22) 申请日 2020.09.28

G01H 17/00 (2006.01)

(65) 同一申请的已公布的文献号
申请公布号 CN 112200032 A

(56) 对比文件

(43) 申请公布日 2021.01.08

CN 103323770 A, 2013.09.25

CN 103487749 A, 2014.01.01

(73) 专利权人 辽宁石油化工大学

CN 107766816 A, 2018.03.06

CN 109272123 A, 2019.01.25

地址 113000 辽宁省抚顺市望花区丹东路
西段一号

CN 110084148 A, 2019.08.02

CN 110398348 A, 2019.11.01

(72) 发明人 罗林 陈文 袁理志 王乔 陈帅

CN 111325112 A, 2020.06.23

CN 111680454 A, 2020.09.18

(74) 专利代理机构 北京君泊知识产权代理有限公司 11496

US 2019339685 A1, 2019.11.07

专利代理师 李丹

张鹏等. “基于 CNN-LSTM 的 QAR 数据特征提取与预测”. 《计算机应用研究》. 2019, 第 36 卷卷 (第 10 期), 第 2958-2961 页.

曹宇鹏等. “基于卷积深度网络的高压真空断路器机械故障诊断方法”. 《电力系统保护与控制》. 2021, 第 49 卷卷 (第 3 期), 第 39-47 页.

审查员 甘宇

(51) Int. Cl.

G06F 18/241 (2023.01)

G06N 3/0442 (2023.01)

G06N 3/045 (2023.01)

G06F 18/213 (2023.01)

G06N 3/0464 (2023.01)

G01R 31/327 (2006.01)

权利要求书 2 页 说明书 9 页 附图 13 页


(54) 发明名称

一种基于注意力机制的高压断路器机械状态在线监测方法

简单、连接方便等优点。

(57) 摘要

本发明公开了一种基于注意力机制的高压断路器机械状态在线监测方法,通过加速度传感器获取高压断路器的振动信号;然后利用 CNN 网络根据振动信号数据按时序窗口创造连续的特征向量,采用注意力机制对局部特征向量进行加权,保留信号局部信息与断路器状态的相关性,从而提取有效的特征向量,然后将提取有效的特征向量输入双向 LSTM 网络;在网络隐含状态中,利用注意力机制提取信号时间敏感状态,实现高压断路器故障类型的分类识别。本发明可以快速而又准确地诊断出高压断路器运行过程中的故障状态,减少定期盲目停机的检修人力、拆卸过程中设备磨损和维修花费,具有容易实现、结构



CN 112200032 B

1. 一种基于注意力机制的高压断路器机械状态在线监测方法,其特征在于,包括以下步骤:

S1、通过加速度传感器获取高压断路器的振动信号;

S2、然后利用CNN网络根据振动信号数据按时序窗口创造连续的特征向量,采用注意力机制对局部特征向量进行加权,保留信号局部信息与断路器状态的相关性,从而提取有效的特征向量,然后将提取有效的特征向量输入双向LSTM网络;

S3、利用LSTM网络实现高压断路器故障类型的分类识别;

所述S3具体步骤为:

S31、利用上位机中存储的振动信号及状态标签作为数据的训练样本,其中高压断路器运行状态包括:正常状态、脱扣闭合电磁铁堵塞、主轴堵塞故障、半轴堵塞;

S32、对训练样本进行预处理,主要包括:缺失信号填补、移除离群值及z-score标准化;

S33、按时间步长对振动信号进行划分,构建出一种张量形式,即传感器数量 \times 样本量 \times 时间步长;

S34、利用网络中的CNN层对这种张量数据进行空间相关性特征提取,并输出为网络的序贯层;

S35、在序贯层之后,设计双向GRU层来处理数据中的时间相关特征;

S36、根据GRU解码器部分的注意力值对双向GRU隐含状态的时间相关性进行加权;

S37、根据网络输出对高压断路器机构卡涩状态进行评价。

2. 根据权利要求1所述的基于注意力机制的高压断路器机械状态在线监测方法,其特征在于,所述S2的具体步骤为:

S21、采集到的实时高压断路器的振动信号数据表达为一种有序实值时间序列:

$\mathbf{X} = (\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_T), \mathbf{x}_t \in \mathbb{R}^{D_0}$, 其中 $t \in [1, T]$ 是时间步长, D_0 表示传感器数量;

S22、假设CNN网络中卷积层的数量为L,使用1D滤波来捕捉振动数据中故障敏感的空间特征,并将卷积层 $l \in \{1, \dots, L\}$ 上的滤波器表示为一种张量形式 $A^{(l)} \in \mathbb{R}^{D_l \times d \times D_{l-1}}$,其中d为滤波器持续时长, D_l 和 D_{l-1} 分别为当前卷积层和前一层上的特征向量长度;前一层的特征图与一个可学习的卷积核进行卷积运算,经过激活函数后的输出形成了这一层的神经元,从而构成了特征提取层,表示为:

$$\begin{aligned} \hat{E}_{i,t}^{(l)} &= f\left(A_{i,t}^{(l)} * E_{i,t+d}^{(l-1)} + b_i^{(l)}\right), \quad \forall t \in [1, T] \\ &= f\left(\sum_{t'=1}^d \langle A_{i,t'}^{(l)}, E_{i,t+d-t'}^{(l-1)} \rangle * E_{i,t+d}^{(l-1)} + b_i^{(l)}\right); \end{aligned}$$

其中, $\hat{E}_i^{(l)} \in \mathbb{R}^{D_l}$ 是当前层上的非规范化激活, $E^{(l-1)} \in \mathbb{R}^{D_{l-1} \times T_{l-1}}$ 为前一层上的规范化激活矩阵,符号*和 $\langle \cdot \rangle$ 分别表示卷积和向量内积运算, $f(\cdot)$ 是一种非线性函数;

S23、为了在一个长周期时间上有效地计算激活值,CNN需要利用池化层对卷积层的输出进行下采样,池化操作,是对滤波器在步长处进行max运算,即:

$$m = \max_i \left\{ \hat{E}_{i,t}^{(l)} \right\};$$

对池化后的激活向量进行规范化:

$$E_t^{(l)} = \frac{1}{m + \varepsilon} \hat{E}_t^{(l)} ;$$

其中, ε 为任意小数;

S24、为了进一步捕捉特征序列中的时间相关性,将池化层中提取到的空间特征向量输入到序列层sequential layer中,并为序列层引入双向RNN模型来进行向量合成,在双向RNN模型上放置了门控迭代单元GRU,利用门控器对遗忘门和输入门进行控制:

$$g_t^z = \sigma(W^z h_{t-1} + U^z E_t)$$

$$g_t^r = \sigma(W^r h_{t-1} + U^r E_t)$$

$$\tilde{h}_t = \tanh(W^h (g_t^r h_{t-1}) + U^h E_t)$$

$$h_t = g_t^z h_{t-1} + (1 - g_t^z) \tilde{h}_t ;$$

其中, g_t^z 和 g_t^r 分别表示更新门和复位门; W^z, W^r 和 W^h 分别表示前一时刻的加权矩阵; U^z, U^r 和 U^h 是对应输入向量的加权矩阵;

S25、在门控迭代单元GRU的解码器部分引入了一种注意力机制,该机制能够在所有时刻上自适应地确定GRU编码器对应隐含状态的相关性,第t时刻隐含状态的注意力计算为:

$$p_t^k = V^k \tanh(W^k h_{t-1} + U^k h_{t-T+k})$$

$$\beta_t^k = \frac{|p_t^k|}{\sum_{m=1}^T |p_t^m|}, 1 \leq k \leq T$$

其中 V^k, E^k 和 U^k 是窗体中第k个样本所对应的参数; p_t^k 是第k个编码隐含状态的注意力值; T是子窗大小。

3. 根据权利要求1所述的基于注意力机制的高压断路器机械状态在线监测方法,其特征在于:所述加速度传感器固定在高压断路器的壳体上。

4. 根据权利要求1所述的基于注意力机制的高压断路器机械状态在线监测方法,其特征在于:所述加速度传感器的信号输出端连接有A/D转换模块,A/D转换模块的信号输出端连接到内置有注意力机制的卷积神经网络和长短时记忆网络相结合的混合模型CNN-LSTM的处理器。

5. 根据权利要求3所述的基于注意力机制的高压断路器机械状态在线监测方法,其特征在于:所述加速度传感器的底座用螺钉安装在高压断路器的壳体上,将螺钉旋入加速度传感器的底座安装孔的一半长度,在加速度传感器的底座和高压断路器的壳体接合面上涂一层油脂,加速度传感器的底座安装孔的垂直度小于0.10mm。

一种基于注意力机制的高压断路器机械状态在线监测方法

技术领域

[0001] 本发明涉及高压断路器的机械故障状态诊断技术领域,特别是一种基于注意力机制的高压断路器机械状态在线监测方法。

背景技术

[0002] 高压断路器是电力系统中重要的控制和保护设备,也是应用状态检修技术的主要设备之一。根据国内外统计分析表明,高压断路器所发生60%-70%的故障是由其机械性能差所引起的,主要包括:弹簧老化、机构卡涩、油脂凝固、连杆传动轴断裂等。这些与断路器机械特性相关的故障大部分都可以反映到执行机构所产生的振动信号上。

[0003] 随着机械振动信号处理方法和人工智能故障诊断方法的日益精进,高压断路器正常运行的标准也随之提高。通过传感器对高压断路器的机械振动信号进行提取,进而提取故障信号中的特征向量,通过类比分析对高压断路器的工作状态进行及时诊断。利用高压断路器机械状态的诊断方法能大大提高电力系统的可靠性,也避免了断路器停电检修所带来的额外经济损失。国外所研发的断路器机械状态研究系统虽然具有成熟的操作体系及完善的软硬件设施,但型号与我国电力系统不匹配,并且引进这样的系统需要花费大量的财力,因此,对高压断路器操作机构的机械状态诊断进行研究具有重大的实际意义。

[0004] 高压断路器的机械故障状态需要用到分类器进行诊断。通过将采集到的振动信号特征向量与已有故障的特征向量进行对比,从而确认断路器是否发生故障及故障类型。目前常用的断路器机械状态诊断方法是神经网络。传统神经网络法存在着参数依赖性过高的问题,参数的选定会降低断路器特征信号提取的准确性、无法提取局部特征、收敛速度慢等问题。深度神经网络可以有效的避免参数、样本数量对诊断结果的影响。深度神经网络通过控制隐藏层的数目达到对输入的样本信息进行递进抽取的目的,可以更加快速、精确找到发生故障时的特征向量。基于深度学习的故障诊断与之前描述的故障诊断流程不同,特定的参数无需诊断前人为设定,基于深度模型的机械状态诊断方式将信号提取模型与故障诊断模型合二为一,避免信号在传输过程中受损、丢失的现象发生。这种端到端的模型在工业实践运行时中更有优势。

发明内容

[0005] 本发明的目的是要解决现有技术中存在的不足,提供一种基于注意力机制的高压断路器机械状态在线监测方法。

[0006] 为达到上述目的,本发明是按照以下技术方案实施的:

[0007] 一种基于注意力机制的高压断路器机械状态在线监测方法,包括以下步骤:

[0008] S1、通过加速度传感器获取高压断路器的振动信号;

[0009] S2、然后利用CNN网络根据振动信号数据按时序窗口创造连续的特征向量,采用注意力机制对局部特征向量进行加权,保留信号局部信息与断路器状态的相关性,从而提取有效的特征向量,然后将提取有效的特征向量输入LSTM网络;

[0010] S3、利用LSTM网络实现高压断路器故障类型的分类识别。

[0011] 进一步地,所述S2的具体步骤为:

[0012] S21、采集到的实时高压断路器的振动信号数据表达为一种有序实值时间序列:

$\mathbf{X} = (\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_T), \mathbf{x}_t \in \mathbb{R}^{D_0}$, 其中 $t \in [1, T]$ 是时间步长, D_0 表示传感器数量;

[0013] S22、假设CNN网络中卷积层的数量为L,使用1D滤波来捕捉振动数据中故障敏感的空间特征,并将卷积层 $l \in \{1, \dots, L\}$ 上的滤波器表示为一种张量形式 $\mathbf{A}^{(l)} \in \mathbb{R}^{D_l \times d \times D_{l-1}}$, 其中 d 为滤波器持续时长, D_l 和 D_{l-1} 分别为当前卷积层和前一层上的特征向量长度;前一层的特征图与一个可学习的卷积核进行卷积运算,经过激活函数后的输出形成了这一层的神经元,从而构成了特征提取层,表示为:

$$\begin{aligned} \hat{E}_{i,t}^{(l)} &= f\left(\mathbf{A}_{i,t}^{(l)} * \mathbf{E}_{i,t-d}^{(l-1)} + \mathbf{b}_i^{(l)}\right), \quad \forall t \in [1, T] \\ [0014] \quad &= f\left(\sum_{\tau=1}^d \langle \mathbf{A}_{i,t,\tau}^{(l)}, \mathbf{E}_{i,t-d+\tau}^{(l-1)} \rangle * \mathbf{E}_{i,t-d}^{(l-1)} + \mathbf{b}_i^{(l)}\right); \end{aligned}$$

[0015] 其中, $\hat{E}_t^{(l)} \in \mathbb{R}^{D_l}$ 是当前层上的非规范化激活, $E^{(l-1)} \in \mathbb{R}^{D_{l-1} \times T_{l-1}}$ 为前一层上的规范化激活矩阵,符号*和 $\langle \cdot \rangle$ 分别表示卷积和向量内积运算, $f(\cdot)$ 是一种非线性函数;

[0016] S23、为了在一个长周期时间上有效地计算激活值,CNN需要利用池化层对卷积层的输出进行下采样,池化操作,是对滤波器在步长处进行max运算,即:

$$[0017] \quad m = \max_i \left\{ \hat{E}_{i,t}^{(l)} \right\};$$

[0018] 对池化后的激活向量进行规范化:

$$[0019] \quad E_t^{(l)} = \frac{1}{m + \varepsilon} \hat{E}_t^{(l)};$$

[0020] 其中, ε 为任意小数;

[0021] S24、为了进一步捕捉特征序列中的时间相关性,将池化层中提取到的空间特征向量输入到序列层sequential layer中,并为序列层引入双向RNN模型来进行向量合成,在双向RNN模型上放置了门控迭代单元GRU,利用门控器对遗忘门和输入门进行控制:

$$[0022] \quad \mathbf{g}_t^z = \sigma\left(\mathbf{W}^z \mathbf{h}_{t-1} + \mathbf{U}^z \mathbf{E}_t\right)$$

$$[0023] \quad \mathbf{g}_t^r = \sigma\left(\mathbf{W}^r \mathbf{h}_{t-1} + \mathbf{U}^r \mathbf{E}_t\right)$$

$$[0024] \quad \tilde{\mathbf{h}}_t = \tanh\left(\mathbf{W}^h \left(\mathbf{g}_t^r \mathbf{h}_{t-1}\right) + \mathbf{U}^h \mathbf{E}_t\right)$$

$$[0025] \quad \mathbf{h}_t = \mathbf{g}_t^z \mathbf{h}_{t-1} + (1 - \mathbf{g}_t^z) \tilde{\mathbf{h}}_t;$$

[0026] 其中, \mathbf{g}_t^z 和 \mathbf{g}_t^r 分别表示更新门和复位门; \mathbf{W}^z , \mathbf{W}^r 和 \mathbf{W}^h 分别表示前一时刻的加权矩阵; \mathbf{U}^z , \mathbf{U}^r 和 \mathbf{U}^h 是对应输入向量的加权矩阵;

[0027] S25、在门控迭代单元GRU的解码器部分引入了一种注意力机制,该机制能够在所有时刻上自适应地确定GRU编码器对应隐含状态的相关性,第t时刻隐含状态的注意力计算为:

$$[0028] \quad \rho_t^k = V^k \tanh(W^k h_{t-1} + U^k h_{t-T+k})$$

$$[0029] \quad \beta_t^k = \frac{|\rho_t^k|}{\sum_{m=1}^T |\rho_t^m|}, 1 \leq k \leq T$$

[0030] 其中 V^k , W^k 和 U^k 是窗体中第 k 个样本所对应的参数; ρ_t^k 是第 k 个编码隐含状态的注意力值; T 是子窗大小。

[0031] 具体地, 所述S3具体步骤为:

[0032] S31、利用上位机中存储的振动信号及状态标签作为数据的训练样本, 其中高压断路器运行状态包括: 正常状态、脱扣闭合电磁铁堵塞、主轴堵塞故障、半轴堵塞;

[0033] S32、对训练样本进行预处理, 主要包括: 缺失信号填补、移除离群值及z-score标准化;

[0034] S33、按时间步长对振动信号进行划分, 构建出一种张量形式, 即传感器数量 \times 样本量 \times 时间步长;

[0035] S34、利用网络中的CNN层对这种张量数据进行空间相关性特征提取, 并输出为网络的序贯层;

[0036] S35、在序贯层之后, 设计双向GRU层来处理数据中的时间相关特征;

[0037] S36、根据GRU解码器部分的注意力值对双向GRU隐含状态的时间相关性进行加权;

[0038] S37、根据网络输出对高压断路器机构卡涩状态进行评价。

[0039] 作为本发明的优选方案, 所述加速度传感器固定在高压断路器的壳体上。

[0040] 作为本发明的优选方案, 所述加速度传感器的信号输出端连接有A/D转换模块, A/D转换模块的信号输出端连接到内置有注意力机制的卷积神经网络和长短时记忆网络相结合的混合模型CNN-LSTM的处理器。

[0041] 作为本发明的优选方案, 所述加速度传感器的底座用螺钉安装在高压断路器的壳体上, 将螺钉旋入加速度传感器的底座安装孔的一半长度, 在加速度传感器的底座和高压断路器的壳体接合面上涂一层油脂, 加速度传感器的底座安装孔的垂直度小于0.10mm。

[0042] 与现有技术相比, 本发明通过采用加速度传感器获取高压断路器的振动信号数据, 经A/D转换模块转换成数字信号输入到处理器中, 在处理器内由注意力机制的卷积神经网络和长短时记忆网络相结合的混合模型CNN-LSTM诊断出高压断路器可能出现的如: 机构卡涩、油脂固化凝结、分合闸线圈烧毁、辅助接点失效故障, 还能判断高压断路器需重点检修的部位, 有效指导检修策略。

[0043] 本发明可以快速而又准确地诊断出高压断路器运行过程中的故障状态, 减少定期盲目停机的检修人力、拆卸过程中设备磨损和维修花费, 具有容易实现、结构简单、连接方便等优点。据粗略估计可避免50%以上的断路器“无病也修”现象, 节省50%以上检修成本(人工、耗材、工具等); 节约80%的检修时间, 应用于高电压等级断路器效益更加明显。

附图说明

[0044] 图1为本发明的流程图。

- [0045] 图2为A/D转换模块的AD7606芯片引脚图。
- [0046] 图3为A/D转换模块的模拟信号输入电路。
- [0047] 图4为A/D转换模块的稳压芯片电路。
- [0048] 图5为A/D转换模块的总电路。
- [0049] 图6为基于注意力机制的高压断路器机械状态评估图。
- [0050] 图7为加速度传感器实时采集的四种机械状态振动信号：(a) 正常状态；(b) 脱扣闭合电磁铁堵塞；(c) 主轴堵塞；(d) 半轴堵塞。
- [0051] 图8为脱扣闭合电磁铁堵塞状态下注意力机制的高压断路器机械状态在线监测方法和常规SVM所对应的ROC曲线：(a) 注意力机制的高压断路器机械状态在线监测方法；(b) 常规SVM。
- [0052] 图9为脱扣闭合电磁铁堵塞状态下注意力机制的高压断路器机械状态在线监测方法和常规SVM所对应的PRC曲线：(a) 注意力机制的高压断路器机械状态在线监测方法；(b) 常规SVM。
- [0053] 图10为主轴堵塞状态下注意力机制的高压断路器机械状态在线监测方法和常规SVM所对应的ROC曲线：(a) 注意力机制的高压断路器机械状态在线监测方法；(b) 常规SVM。
- [0054] 图11为主轴堵塞状态下注意力机制的高压断路器机械状态在线监测方法和常规SVM所对应的PRC曲线：(a) 注意力机制的高压断路器机械状态在线监测方法；(b) 常规SVM。
- [0055] 图12为半轴堵塞状态下注意力机制的高压断路器机械状态在线监测方法和常规SVM所对应的ROC曲线：(a) 注意力机制的高压断路器机械状态在线监测方法；(b) 常规SVM。
- [0056] 图13为半轴堵塞状态下注意力机制的高压断路器机械状态在线监测方法和常规SVM所对应的PRC曲线：(a) 注意力机制的高压断路器机械状态在线监测方法；(b) 常规SVM。

具体实施方式

[0057] 为使本发明的目的、技术方案及优点更加清楚明白，以下结合实施例，对本发明进行进一步的详细说明。此处所描述的具体实施例仅用于解释本发明，并不用于限定发明。

[0058] 如图1所示，本发明提供了一种基于注意力机制的高压断路器机械状态在线监测方法，包括以下步骤：

[0059] S1、将加速度传感器的底座用螺钉安装在高压断路器的壳体上，本实施例中选取的是D0005型加速度传感器，将螺钉旋入加速度传感器的底座安装孔的一半长度，在加速度传感器的底座和高压断路器的壳体接合面上涂一层油脂，能够保证整个加速度传感器的底座能很好地与被测试物的钢性接触；加速度传感器的底座安装孔的垂直度小于0.10mm，，这样加速度传感器在使用过程中频率响应才能与原标定的频率响应相同；通过加速度传感器获取高压断路器的振动信号；加速度传感器的信号输出端连接有A/D转换模块，A/D转换模块的信号输出端连接到内置有注意力机制的卷积神经网络和长短时记忆网络相结合的混合模型CNN-LSTM的处理器；

[0060] 由于传感器采集的信息为模拟信号，多不能直接传输给CPU，因此需要将传感器输出的模拟信息通过A/D转换模块转换成数字信息。本专利采用AD7606芯片实现A/D转换，AD7606的优点是应用广、性能十分优异、价格低廉。拥有着8/6/4路的同步采样输入，它的双极性的模拟输入范围在 $\pm 10V$ 和 $\pm 5V$ ，可用5V的模拟单电源供电，2.3V至+5V VDRIVE，完全

集成的数据采集就解决了方案模拟输入的嵌位保护,1M Ω 的模拟输入阻抗的输入缓冲器,二阶抗混叠的模拟滤波器,片内精密的基准电压及基准电压缓冲器,精度高达16位、200KSPS ADC,通过数字滤波器提供过采样功能。

[0061] A/D转换公式如下:

$$[0062] \quad \text{Data} = \frac{U_o \times 2^{15}}{U};$$

[0063] 其中, U_o 为传感器经信号放大电路后输出电压; U 为采样电压量程,这里取 $U=10V$;Data为A/D转换结果。

[0064] A/D转换电路输入的模拟信号是传感器发出的信号经放大电路调整后接入的,所有的芯片上模拟信号输入GND引脚均要接入VGND中即模拟地。未被使用的模拟信号输入引脚也要接入VGND,为了减少干扰信号的产生。A/D转换电路输入的模拟信号是传感器发出的信号经放大电路调整后接入的,所有的芯片上模拟信号输入GND引脚均要接入VGND中即模拟地。未被使用的模拟信号输入引脚也要接入VGND,为了减少干扰信号的产生。

[0065] 为了提高A/D转换芯片工作的稳定与精准性,这里设计了稳压电路,芯片稳压电路如图4所示。图4中Vin引脚接入的是VDD5V0。详细的A/D转换模块电路如图5所示。

[0066] S2、然后利用CNN网络根据振动信号数据按时序窗口创造连续的特征向量,采用注意力机制对局部特征向量进行加权,保留信号局部信息与断路器状态的相关性,从而提取有效的特征向量,然后将提取有效的特征向量输入LSTM网络;所述S2具体步骤为:

[0067] S21、采集到的实时高压断路器的振动信号数据表达为一种有序实值时间序列:

$$\mathbf{X} = (\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_T), \mathbf{x}_t \in \mathbb{R}^{D_0}, \text{其中 } t \in [1, T] \text{ 是时间步长, } D_0 \text{ 表示传感器数量;}$$

[0068] S22、假设CNN网络中卷积层的数量为L,使用1D滤波来捕捉振动数据中故障敏感的空间特征,并将卷积层 $l \in \{1, \dots, L\}$ 上的滤波器表示为一种张量形式 $\mathbf{A}^{(l)} \in \mathbb{R}^{D_l \times d \times D_{l-1}}$,其中d为滤波器持续时长, D_l 和 D_{l-1} 分别为当前卷积层和前一层上的特征向量长度;前一层的特征图与一个可学习的卷积核进行卷积运算,经过激活函数后的输出形成了这一层的神经元,从而构成了特征提取层,表示为:

$$[0069] \quad \begin{aligned} \hat{E}_{i,t}^{(l)} &= f\left(\mathbf{A}_{i,t}^{(l)} * \mathbf{E}_{:,t-d}^{(l-1)} + \mathbf{b}_i^{(l)}\right), \quad \forall t \in [1, T] \\ &= f\left(\sum_{t=1}^d \langle \mathbf{A}_{i,t}^{(l)}, \mathbf{E}_{:,t-d-t}^{(l-1)} \rangle * \mathbf{E}_{:,t-d}^{(l-1)} + \mathbf{b}_i^{(l)}\right); \end{aligned}$$

[0070] 其中, $\hat{E}_t^{(l)} \in \mathbb{R}^{D_l}$ 是当前层上的非规范化激活, $\mathbf{E}^{(l-1)} \in \mathbb{R}^{D_{l-1} \times T_{l-1}}$ 为前一层上的规范化激活矩阵,符号*和 $\langle \cdot \rangle$ 分别表示卷积和向量内积运算, $f(\cdot)$ 是一种非线性函数;

[0071] S23、为了在一个长周期时间上有效地计算激活值,CNN需要利用池化层对卷积层的输出进行下采样,池化操作,是对滤波器在步长处进行max运算,即:

$$[0072] \quad m = \max_i \left\{ \hat{E}_{i,t}^{(l)} \right\};$$

[0073] 对池化后的激活向量进行规范化:

$$[0074] \quad E_t^{(l)} = \frac{1}{m + \varepsilon} \hat{E}_t^{(l)};$$

[0075] 其中, ε 为任意小数;

[0076] S24、为了进一步捕捉特征序列中的时间相关性,将池化层中提取到的空间特征向量输入到序列层 sequential layer 中,并为序列层引入双向RNN模型来进行向量合成,在双向RNN模型上放置了门控迭代单元GRU,利用门控器对遗忘门和输入门进行控制:

$$[0077] \quad g_t^z = \sigma(W^z h_{t-1} + U^z E_t)$$

$$[0078] \quad g_t^r = \sigma(W^r h_{t-1} + U^r E_t)$$

$$[0079] \quad \tilde{h}_t = \tanh(W^h (g_t^r h_{t-1}) + U^h E_t)$$

$$[0080] \quad h_t = g_t^z h_{t-1} + (1 - g_t^z) \tilde{h}_t,$$

[0081] 其中, g_t^z 和 g_t^r 分别表示更新门和复位门; W^z, W^r 和 W^h 分别表示前一时刻的加权矩阵; U^z, U^r 和 U^h 是对应输入向量的加权矩阵;

[0082] S25、在门控迭代单元GRU的解码器部分引入了一种注意力机制,该机制能够在所有时刻上自适应地确定GRU编码器对应隐含状态的相关性,第t时刻隐含状态的注意力计算为:

$$[0083] \quad \rho_t^k = V^k \tanh(W^k h_{t-1} + U^k h_{t-T+k})$$

$$[0084] \quad \beta_t^k = \frac{|\rho_t^k|}{\sum_{m=1}^T |\rho_t^m|}, 1 \leq k \leq T$$

[0085] 其中 V^k, W^k 和 U^k 是窗体中第k个样本所对应的参数; ρ_t^k 是第k个编码隐含状态的注意力值; T是子窗大小;

[0086] S3、利用LSTM网络实现高压断路器故障类型的分类识别:

[0087] 具体地,所述S3具体步骤为:

[0088] S31、利用上位机中存储的振动信号及状态标签作为数据的训练样本,其中高压断路器运行状态包括:正常状态、脱扣闭合电磁铁堵塞、主轴堵塞故障、半轴堵塞;

[0089] S32、对训练样本进行预处理,主要包括:缺失信号填补、移除离群值及z-score标准化;

[0090] S33、按时间步长对振动信号进行划分,构建出一种张量形式,即传感器数量×样本量×时间步长;

[0091] S34、利用网络中的CNN层对这种张量数据进行空间相关性特征提取,并输出为网络的序贯层;

[0092] S35、在序贯层之后,设计双向GRU层来处理数据中的时间相关特征;

[0093] S36、根据GRU解码器部分的注意力值对双向GRU隐含状态的时间相关性进行加权;

[0094] S37、根据网络输出对高压断路器机构卡涩状态进行评价。

[0095] 为了验证本发明的诊断效果,采用现有技术支持向量机模型作为对比方法来确定本发明方法对高压断路器故障诊断效果,具体试验如下:

[0096] 1、数据的采集

[0097] 以一台ZW32-12FG/630-20型真空断路器的机械性能测试系统,并基于yd-39型加速度传感器测量开/关过程中的振动加速度参数,得到相应的电压。采用NI9234数据采集卡对电压进行数字化处理。传感器的测量范围为0-5000m/s²,数据采集卡采样频率为10kHz。加速度传感器的位置在真空断路器的壳体上,在壳体上采集垂直振动信号,比较各种监测方法。

[0098] 实验模拟了四种实验类型:正常状态;脱扣闭合电磁铁堵塞;主轴堵塞;半轴堵塞。在每种情况下进行了7次实验,真空断路器正常和故障状态的典型信号如图7。在这7个数据集中,选择其中3个作为训练数据集,选择其余的作为每个状态的测试数据集。

[0099] 2、参数设置

[0100] 注意力深度网络模型中,设计的CNN有1个卷积层和1个池化层,卷积滤波器的个数为64。将卷积核大小设为1,步长为1。在池化层中MaxPooling1D的大小为1。CNN网络中的激活函数采用Relu函数。通过卷积操作和池化操作来减小振动信号的输出维度,然后经过扁平操作对样本进行处理,作为全整个网络的特征提取。LSTM模型采用的网络层节点数目为100,激活函数采用sigmoid函数。本实验采用SVM模型与CNN-LSTM模型对比的方法。输入相同的机械振动信号的样本进行故障诊断,两种模型在ROC和PRC曲线中的诊断结果进行评估,表1为故障类型及其标签。

[0101] 表1

	故障类型	故障标签
	正常状态	0
[0102]	脱扣闭合电磁铁堵塞	1
	主轴堵塞	2
	半轴堵塞	3

[0103] 3、实验结果对比

[0104] 实验1脱扣闭合电磁铁堵塞情况下振动信号的诊断比较

[0105] 首先,图8(a)采用注意力机制深度网络模型的脱扣闭合电磁铁堵塞的ROC曲线完全将正常状态的ROC曲线包络住,从而可以将故障信号与正常信号进行准确分类。其次,图8(a)中的正常状态和脱扣闭合电磁铁堵塞故障状态的曲线随着阈值变化保持平稳变化,而图8(b)中采用SVM的正常状态曲线在此期间出现大幅度波动变化。最后,由图8(a)和(b)可知,采用注意力机制深度网络模型的正常状态和脱扣闭合电磁铁堵塞故障AUC的值均为0.99,而采用SVM模型相对应的AUC的值为0.52和0.52。采用注意力机制深度网络模型的AUC值远远大于采用SVM模型的AUC值,AUC的数值越大,诊断效果越好。综上,从ROC曲线中可以看出,采用注意力机制深度网络模型对高压断路器的脱扣闭合电磁铁堵塞振动信号与正常状态的振动信号排序更精确,对断路器机械振动信号状态诊断效果更好。

[0106] 若正常状态信号样本与故障状态信号样本比例悬殊时可以采用查准率-查全率曲线(Precision-recall curve,PRC)进一步来判定模型分类性能。首先,如图9(a)所示,采用注意力机制深度网络模型的PRC曲线相对于图9(b)所示的基于SVM的PRC曲线更接近坐标轴的右上角,在PRC曲线中越接近右上角诊断效果越好。其次,图9(a)中的正常状态和发生脱扣闭合电磁铁堵塞故障状态曲线在诊断过程中随着阈值的变化始终保持平滑,在查全率不断提高的过程中,查准率依旧保持平稳变化。最后,由图9(a)可知采用注意力机制深度网络

模型的正常状态曲线和断路器发生脱扣闭合电磁铁堵塞故障曲线的AUC的值分别为0.996和0.977,而采用SVM模型所对应的AUC的值为0.575和0.629,AUC的值越大诊断越精确。综上可以得出在PRC曲线中,采用注意力机制深度网络模型对断路器正常工作时和发生脱扣闭合电磁铁堵塞时的状态诊断均有更高的灵敏性和准确性。

[0107] 实验2发生主轴堵塞故障情况下振动信号的诊断对比

[0108] 如图10(a)所示,采用注意力机制深度网络的正常状态和发生主轴堵塞的故障状态的曲线随着阈值变化保持平稳变化,而图10(b)采用SVM模型的正常状态曲线及主轴堵塞故障曲线在整个诊断期间出现大幅度波动变化,不利于振动信号的机械诊断。采用注意力机制深度网络模型的ROC曲线接近左上角,ROC曲线越接近左上角,诊断精度越高。由图10可知,采用注意力机制深度网络模型的正常状态和发生主轴堵塞时AUC的值均为0.99,而采用SVM模型的相对应的AUC的值为0.54,AUC的值越大诊断效果越好。在ROC曲线中可以得出,采用注意力机制深度网络模型对断路器发生主轴堵塞与正常状态的信号的实时监测效果更好。

[0109] 如图11(a)所示,采用注意力机制深度网络模型的正常状态和发生主轴堵塞时的故障状态曲线在诊断过程中随着阈值的变化始终保持平滑,在查全率不断提高的过程中,查准率依旧保持平稳变化,而采用SVM模型的PRC曲线随着查全率的增加查准率出现剧烈的变化,如图11(b)。最后,由图11(a)可知,采用注意力机制深度网络模型的正常状态曲线和发生主轴堵塞故障曲线的AUC的值分别为0.996和0.96,而采用SVM模型相对应的AUC的值为0.585和0.647,如图11(b)所示。在PRC曲线中,采用注意力机制深度网络模型的AUC值更高一些。在对主轴堵塞故障和正常状态进行监测时,采用注意力机制深度网络高压断路器机械状态监测的模型对发生主轴堵塞故障和正常状态的分类效果都要强于SVM模型,因此更有利于对高压断路器的机械状态进行监测。

[0110] 实验3半轴堵塞情况下振动信号的诊断对比

[0111] 首先由图12(a)可以明显的看出,采用注意力机制深度网络的模型的正常状态和发生半轴堵塞故障时的ROC曲线更接近坐标的左上角。其次,采用注意力机制深度网络模型在断路器发生半轴堵塞时,TPR值随着阈值的增加稳定的接近于1,而图12(b)中采用SVM模型对于故障诊断的TPR值随着阈值的增加,维持在0.4-0.6之间。根据两种模型对同一种故障的TPR值进行对比,采用注意力机制深度网络对于发生半轴堵塞故障的诊断具有更高的准确性及更精准的趋势诊断。最后,由图12可知,注意力机制深度网络模型在正常状态和发生半轴堵塞故障的AUC值分别为1.00和1.00,而采用SVM模型相对应的AUC值为0.53和0.53,采用注意力机制深度网络模型的AUC值远远大于SVM模型对应的值。综上,在ROC曲线中无论是对断路器正常状态诊断或者发生半轴堵塞的故障状态诊断,采用注意力机制深度网络模型相较于采用SVM模型都具有更高的准确性。

[0112] 首先图13(a)中采用注意力机制深度网络模型的PRC曲线相对于图13(b)中采用SVM的PRC曲线更接近坐标轴的右上角,在PRC曲线中,曲线越接近右上角,诊断效果越好。其次,图13(a)中的正常状态和发生半轴堵塞的曲线保持平滑,在查全率不断提高的过程中,查准率依旧保持平稳变化。采用注意力机制深度网络模型的正常状态和发生半轴堵塞故障的AUC值分别为0.996和0.994,而采用SVM的相对应的AUC值为0.583和0.642,AUC的数值越高诊断精度越高。无论是对正常状态还是半轴堵塞状态进行诊断,采用注意力机制深度网

络模型都比传统采用SVM模型都有更高的精度。

[0113] 通过三组实验的对比结果表明,注意力机制深度网络模型对比SVM模型能更快速、准确的提取有效特征向量。更加精确地对特征向量进行诊断。所以,采用注意力机制深度网络模型相较于现有技术支持向量机模型能更加准确的对高压断路器的机械故障进行诊断。

[0114] 本发明的技术方案不限于上述具体实施例的限制,凡是根据本发明的技术方案做出的技术变形,均落入本发明的保护范围之内。

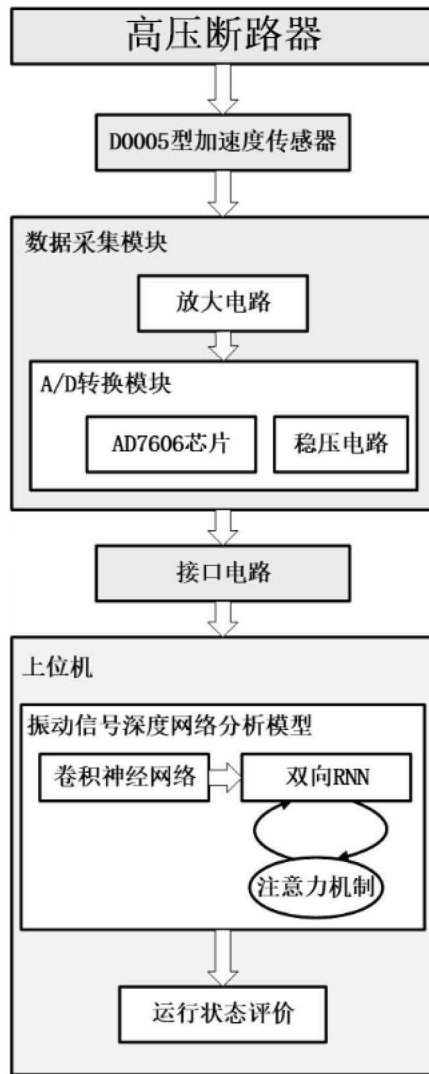


图1

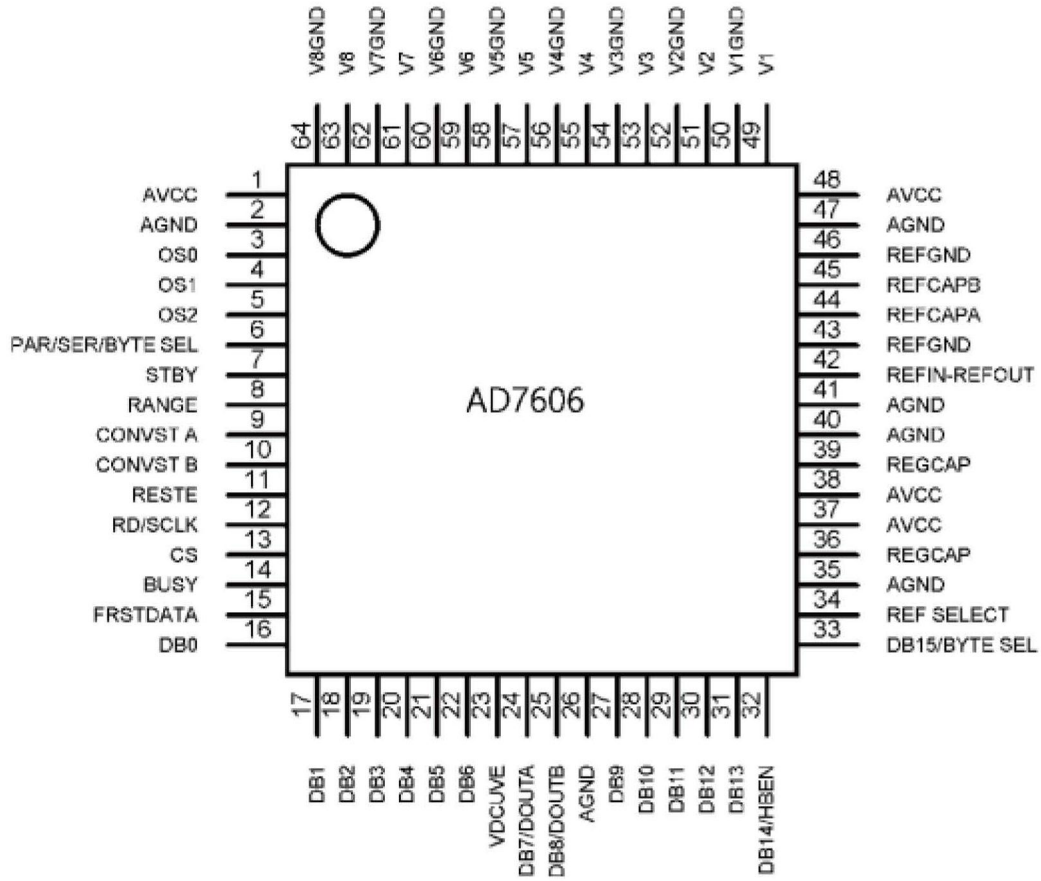


图2




图3




图4

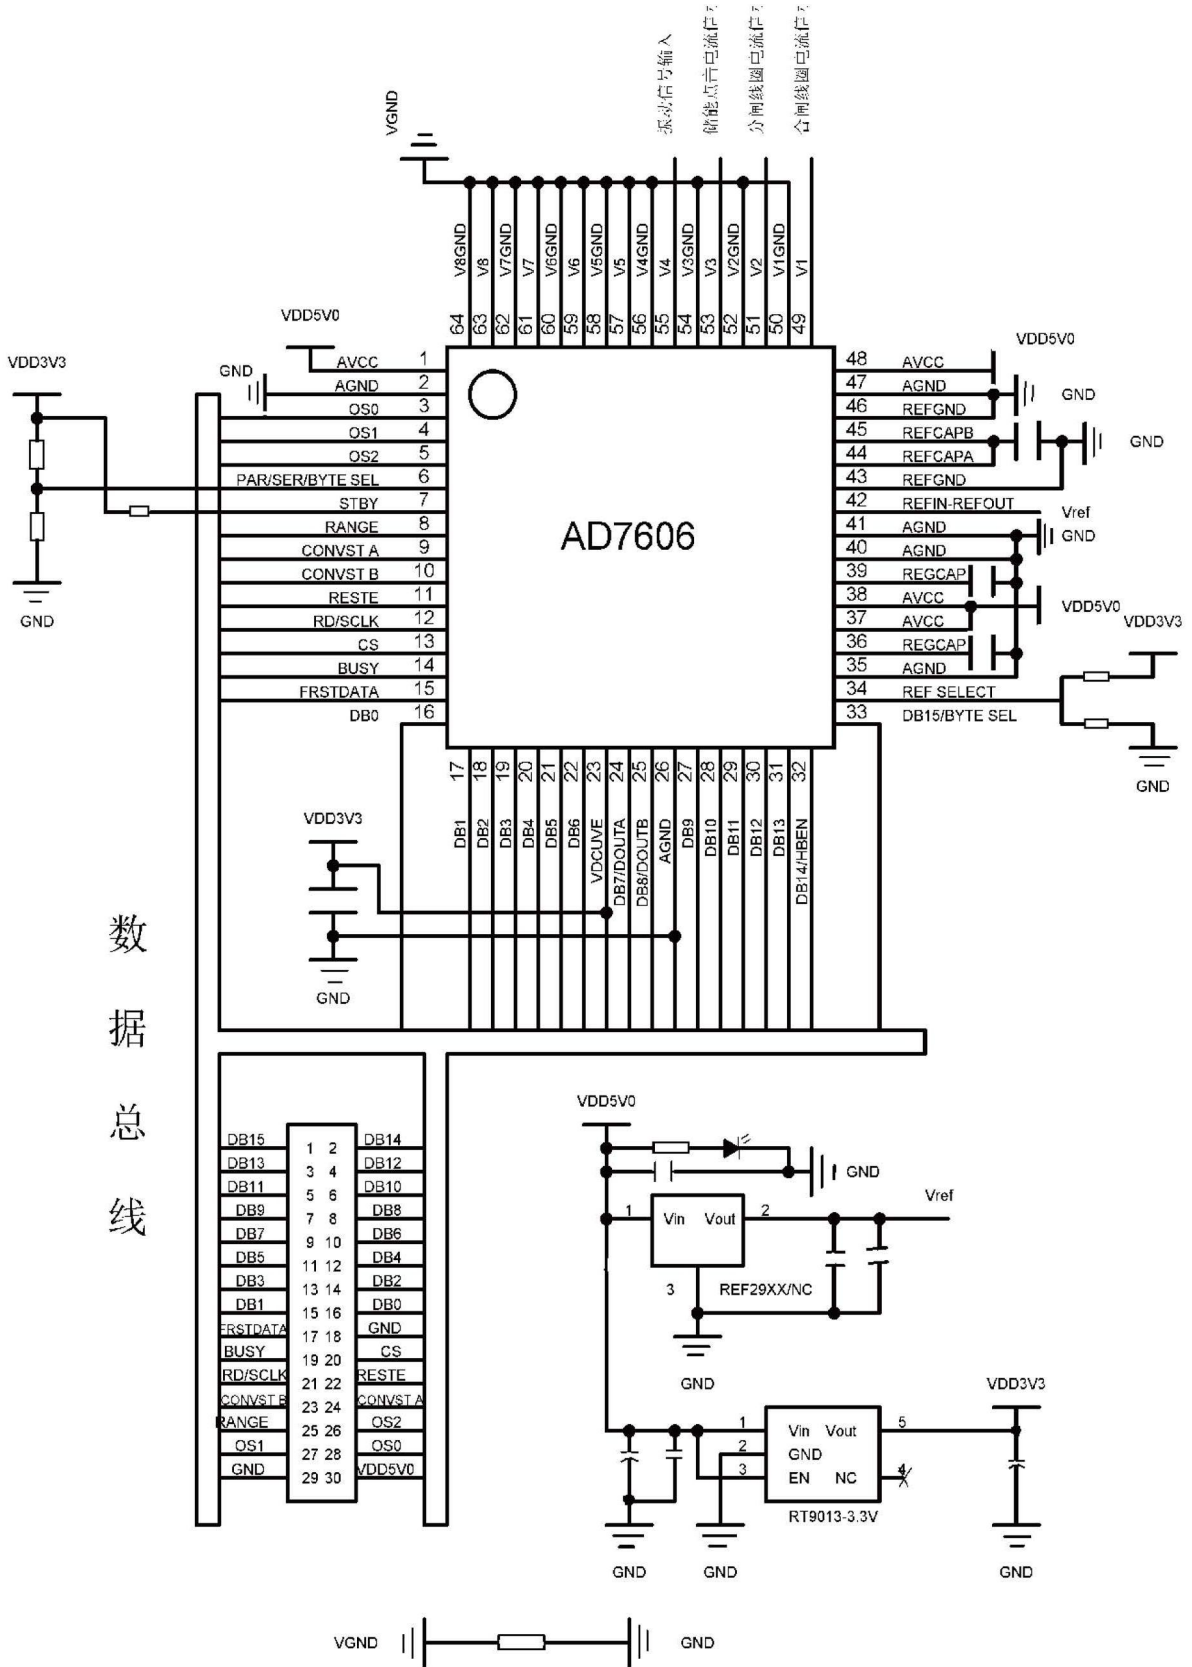


图5

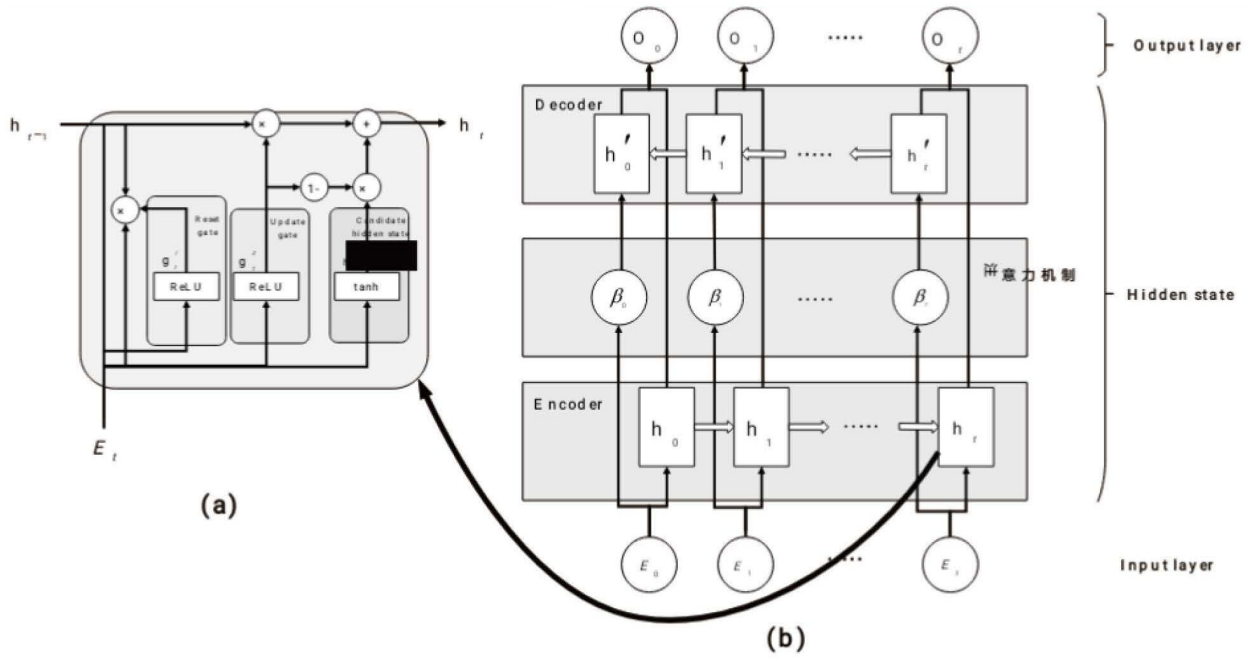





图6




(a)



(b)




(c)




(d)

图7




(a)




(b)

图8




(a)




(b)

图9




(a)




(b)

图10




(a)




(b)

图11




(a)




(b)

图12



(a)



(b)

图13