

DOI: 10.19783/j.cnki.pspc.180785

一种关联 RNN 模型的非侵入式负荷辨识方法

刘恒勇¹, 史帅彬¹, 徐旭辉¹, 周东国², 闵若琳², 胡文山²

(1. 深圳供电局有限公司, 广东 深圳 518048; 2. 武汉大学动力与机械学院, 湖北 武汉 430072)

摘要: 为了进一步拓展监督学习方法在非侵入式负荷辨识中的应用, 提出了一种关联循环神经网络(Recurrent Neural Networks, RNN)模型的负荷辨识方法。在该方法中, 首先引入了时间窗负荷事件检测方法, 提取谐波分量作为负荷特征, 并将负荷特征作为 RNN 模型的输入。然后根据其对历史输入特征量的记忆建立由输入映射到输出的内在关联, 从而建立面向时间序列输入的 RNN 负荷辨识方法。进一步地, 为了避免“梯度消失”问题, 选择了最佳的激活函数和损失函数。最后, 通过单负荷辨识、多负荷辨识的实测实验, 证实了所提关联 RNN 模型的负荷辨识方法能够有效地实现用户内部负荷设备状态的辨识要求。

关键词: 非侵入式; 负荷辨识; 深度学习; 事件检测; RNN

A non-intrusive load identification method based on RNN model

LIU Hengyong¹, SHI Shuaibin¹, XU Xuhui¹, ZHOU Dongguo², MIN Ruolin², HU Wenshan²

(1. Shenzhen Power Supply Bureau Co., Ltd., Shenzhen 518048, China; 2. School of Power and Mechanical Engineering, Wuhan University, Wuhan 430072, China)

Abstract: In order to extend the application by using supervised learning methods in non-intrusive load identification, a load identification method based on Recurrent Neural Networks (RNN) model is proposed. Firstly, the time window for detecting load event is introduced, and then the harmonic components are taken as the load characteristics to be used as the inputs of the RNN model. According to the memory of its memory history input feature quantity, the internal mapping of the input to the output as well as the RNN load identification method for time series inputs are established. Furthermore, in this model, the suitable activation function and loss function are selected in order to avoid the "gradient disappearance" problem. Finally, the experiment on the single and multi-load identification demonstrates the model can effectively realize the identification of the load status.

This work is supported by Science and Technology Project of China Southern Power Grid Co., Ltd. (No. 090000KK52160049).

Key words: non-intrusive; load identification; deep learning; event detection; RNN

0 引言

随着电力系统的深化改革, 负荷监测技术成为了人们关注的热点^[1]。传统的负荷监测通常是在每种负荷成分或者电器接入处安装一个智能传感器来监测其工作状态。事实上, 这种侵入式测量方法对用户友好性差, 且成本较高。相比之下, 非侵入式电力负荷监测(Non-intrusive electric load monitoring, NILM)是一种经济便利的监测方法^[2], 它以软件程

序来代替传感器网络, 以负荷关口的“软计算”代替近设备“硬测量”, 仅需在配电进线处安装监测设备来监测负荷类型、用电明细等信息, 是一种面向智能电表深化改革的必然趋势^[3]。这不仅能为用户提供用电细节, 也可为电力公司精准预测负荷构成比例等提供数据支持, 对推动电力公司与用户交互等具有重要意义。

近年来, NILM 技术的研究涌现出了多种负荷辨识算法。文献[4]采用 Karhunen Loève 变换将有功功率信号分解成子控件组件, 建立功率负荷特征, 可实现在低采样率情况下的负荷辨识。文献[5]采用基于群体搜索机器学习算法寻找可调参数的最优

基金项目: 中国南方电网有限责任公司科技项目资助 (090000KK52160049)

值, 并对基于 V-I 轨迹的负荷特征做出了改进。文献[6]提出了一种基于倒谱平滑负荷分解的方法, 有效地处理多个电器的同步开/关事件, 并提出了一个可滤除噪声的数据采集系统。文献[7]描述了启发式 NILM 方法和贝叶斯 NILM 方法, 采用电路级能量监测方法测量稳态功率, 克服以往阶跃功率信号测量的限制。文献[8]提出了一种基于减法聚类和最大似然分类器的低采样率负荷检测方法。文献[9]提出了一种基于改进隐马尔科夫模型(Hidden Markov Model, HMM)的负荷辨识算法, 对模型进行四种不同的改进研究。文献[10]采用加性因子 HMM 模型完成建模实验, 使得 FHMM 模型对隐状态的估计不再收敛到局部最优值, 同时提高了辨识准确率。文献[11]采用 S 变换的多分辨率瞬态特征提取方式, 设计了一种基于改进时频分析的 NILM 系统, 利用蚁群优化算法进行组合搜索, 得到一个改进的 0-1 多维背包算法。

在上述的一些算法中, 监督学习算法的研究仍然是目前负荷辨识算法开发的重点。近年来, 深度学习神经网络在图像辨识等领域的突出表现, 为研究者提供了新的解决方法。相比于其他监督模型, 神经网络直接从观测数据中学习, 并可通过训练样本数量的增加, 构建出它自身的解决方案。为此, 本文提出将深度学习模型——RNN 模型应用于解决非侵入式电力负荷的辨识问题, 通过其具有记忆历史输入特征量等特性, 建立输入映射到输出的内在关联, 实现对时间序列输入的负荷辨识。为了进一步提升负荷辨识能力, 本文通过实验探讨了隐含层节点数以及隐含层数。另外, 针对大样本训练过程中 sigmoid 函数的输出容易达到饱和值, 导致梯度消失、辨识效果低下等问题。本文选择了最佳的激活函数和损失函数, 并通过实验对训练效果进行验证, 最终得到了较好的辨识效果。

1 RNN 模型简介

RNN 是一类用于处理时间序列数据的神经网络, 能够感知某一事物、现象等随时间变化的状态, 且 RNN 拥有类似人类的记忆能力, 能够有效识别序列化信息。图 1 为神经元模型拓扑图, 其拓扑结构主要分为三层——输入层、隐含层和输出层^[12]。

图 1 中 $x_t \in R^{1 \times D}$ 是采样时刻 t 神经元的输入, D 表示输入的维数; W_{sh} 是输入层到隐藏层的权重矩阵, 而权重矩阵 W_{hh} 是隐含层上一次的值作为这一次的输入权重, b_t 为偏移值, f 为激活函数。此时, 当前时刻隐含层输出 h_t 可通过激活函数 f 得

到。隐含层的输出再经权重矩阵 W_{oh} 以及偏移量 b_o , 得到一个输出 o_t , 在激活函数 g 的作用下, 最终得到输出 y_t 。

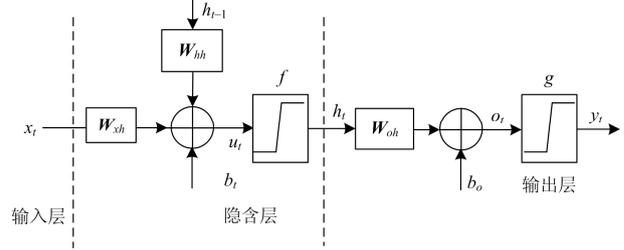


图 1 RNN 拓扑结构

Fig. 1 RNN topology

通常, RNN 模型每一层由多个神经元节点组成。这里假定 N 表示输出量的维数, H 表示隐含层节点数, 则图 1 中隐含层的输出值可表示为 $h_t \in R^{1 \times H}$, 输出层的输出值为 $y_t \in R^{1 \times N}$ 。

具体地, 隐含层的输出可描述为

$$u_t = x_t W_{sh} + h_{t-1} W_{hh} + b_t \quad (1)$$

$$h_t = f(u_t) \quad (2)$$

式中: 输入层到隐含层的权重矩阵为 $W_{sh} = \{\omega_{sh}(i, j)\} \in R^{D \times H}$; 隐含层的自循环权重矩阵为 $W_{hh} = \{\omega_{hh}(i, j)\} \in R^{H \times H}$; 偏置向量为 $b_t \in R^{1 \times H}$ 。

输出层输出为

$$o_t = h_t W_{oh} + b_o \quad (3)$$

$$y_t = g(o_t) \quad (4)$$

式中: 隐含层到输出层的权重矩阵为 $W_{oh} = \{\omega_{oh}(i, j)\} \in R^{H \times N}$; 偏置向量为 $b_o \in R^{1 \times N}$ 。

在 RNN 模型中, 学习算法大多采用通过时间的反向传播算法(Back Propagation Through Time, BPTT)^[13], 将网络中时序输入信号按照层级展开, 进而将静态的网络转化为动态网络, 并在每个层级采用梯度下降算法训练网络的学习能力^[14], 针对其实验结果的评价, RNN 模型通常采用均方误差(Mean-square Error, MSE), 即

$$L(y_t, \hat{y}_t) = \sum_{t=1}^T \frac{1}{2} \|y_t - \hat{y}_t\|_2^2 = \sum_{t=1}^T \sum_{j=1}^N \frac{1}{2} (y_t(j) - \hat{y}_t(j))^2 \quad (5)$$

式中: \hat{y}_t 为输出层期望的输出值; y_t 为真实值; T 表示学习样本数。

根据 BPTT 反向传播机制, 当 $t=T$ 时, 各层梯度为

$$\delta_T^y(j) = -\frac{\partial L}{\partial y_T(j)} \frac{\partial y_T(j)}{\partial o_T(j)} = -\frac{\partial L}{\partial y_T(j)} g'(o_T(j)) \quad (6)$$

$$\delta_T^h(j) = -\sum_{i=1}^H \frac{\partial L}{\partial o_T(i)} \frac{\partial o_T(i)}{\partial h_T(j)} \frac{\partial h_T(j)}{\partial u_T(j)} = \sum_{i=1}^H \delta_T^y(i) \omega_{oh}(i, j) f'(u_T(j)) \quad (7)$$

同理，当 $t = T - 1, T - 2, \dots, 1$ 时各层梯度为

$$\delta_t^y(j) = -\frac{\partial L}{\partial y_t(j)} \frac{\partial y_t(j)}{\partial o_t(j)} = -\frac{\partial L}{\partial y_t(j)} g'(o_t(j)) \quad (8)$$

$$\delta_t^h(j) = \left(\sum_{i=1}^N \delta_t^y(i) \omega_{oh}(i, j) + \sum_{i=1}^H \delta_{t+1}^h(i) \omega_{hh}(i, j) \right) f'(u_t(j)) \quad (9)$$

然后，对各层的权重和偏移量进行修正，权重大小分别修正为

$$\Delta \omega_{oh}(i, j) = \sum_{t=1}^T \delta_t^y(j) h_t(j) \quad (10)$$

$$\Delta \omega_{xh}(i, j) = \sum_{t=1}^T \delta_t^h(j) x_t(j) \quad (11)$$

$$\Delta \omega_{hh}(i, j) = \sum_{t=1}^T \delta_t^h(j) h_{t-1}(j) \quad (12)$$

偏移量修正为

$$\Delta b_o = \sum_{t=1}^T \delta_t^y(j) \quad (13)$$

$$\Delta b_i = \sum_{t=1}^T \delta_t^h(j) \quad (14)$$

2 关联 RNN 模型的负荷辨识方法

在非侵入式负荷监测中，因配电总进线处监测到的电力数据也是一种时间序列数据，因此关联 RNN 模型能够有效地针对电力负荷数据的特征建立内在关联，实现对电力负荷的准确辨识与分解。

图 2 为整个负荷辨识流程，其中负荷事件检测是 RNN 模型辨识前期处理较为重要的一个环节。

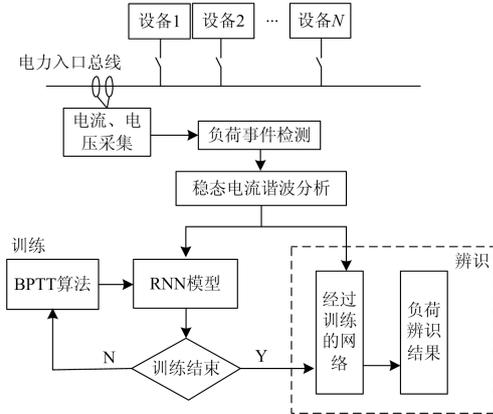


图 2 关联 RNN 模型的负荷辨识架构

Fig. 2 Framework of load identification based on RNN model

2.1 负荷事件检测

负荷事件检测是反映负荷投切的一种标识，是负荷辨识较为关键的一步^[15]。本文采用一种自适应变点寻优算法的负荷事件检测机制，其基本思想为在一定长度的时间窗内以某个时刻点为界划分为两类，该时刻点之前归为一类，之后则认为是一类，使得同类内部的方差和最小，类间方差和最大。此时，如果两类均值距离超过一定阈值，则认为该时刻是变点，存在负荷事件。

为了方便描述，这里假定在某个时刻点 k ，将时间窗内 L 个数据样本 $\{x_i\}$ 分为两类，则 C_0 类 $\{x_1, x_2, \dots, x_k\}$ 和 C_1 类 $\{x_{k+1}, x_{k+2}, \dots, x_L\}$ 的概率分别为

$$\Pr(C_0) = \sum_{i=1}^k p_i = \omega_k \quad (15)$$

$$\Pr(C_1) = \sum_{i=k+1}^L p_i = 1 - \omega_k \quad (16)$$

均值分别为

$$\mu_0 = \sum_{i=1}^k x_i \Pr(x_i | C_0) \quad (17)$$

$$\mu_1 = \sum_{i=k+1}^L x_i \Pr(x_i | C_1) \quad (18)$$

式中， p_i 为 x_i 在数据集 $\{x_i\}$ 中出现的概率，满足 $\sum_{i=1}^L p_i = 1$ 。根据分类规则，可计算某一样本属于 C_0 类和 C_1 类的概率分别为

$$\Pr(x_i | C_0) = p_i / \sum_{i=1}^k p_i = p_i / \omega_k \quad (19)$$

$$\Pr(x_i | C_1) = p_i / \sum_{i=k+1}^L p_i = p_i / (1 - \omega_k) \quad (20)$$

因此，当满足目标函数达到最小，如式(21)所示，便可获得潜在的变点。再结合两类均值的差值，当差值超过某个门限阈值时，就认为存在负荷事件，该点也被称为变点。一般而言，这个门限阈值由功率最小的负荷决定。

$$\min_k \sum_{i=1}^k (x_i - \mu_0)^2 \Pr(x_i | C_0) + \sum_{i=k+1}^L (x_i - \mu_1)^2 \Pr(x_i | C_1) \quad (21)$$

2.2 特征量提取

准确可靠的非侵入式负荷辨识方法通常建立在用电设备负荷特征选择的基础上。通常，电器设备正常运行的稳态电流具有一定的统计特性，具体表现在电流谐波分量上^[14]。

为了方便描述，假定用户家庭中有 N 个用电设备，则在用电设备投切过程中，可建立式(22)所示的方程组。

$$\begin{cases} I_1 = \sum_{i=1}^K \sum_{t=1}^n I_{1t} \cos(i\omega t + \theta_{1i}) \\ I_2 = \sum_{i=1}^K \sum_{t=1}^n I_{2t} \cos(i\omega t + \theta_{2i}) \\ \vdots \\ I_N = \sum_{i=1}^K \sum_{t=1}^n I_{Nt} \cos(i\omega t + \theta_{Ni}) \end{cases} \quad (22)$$

式中, I_{ij} 为支路 i 的电流 I_i 分解到 j 次谐波上的幅值。另外, 对于每个 $\cos(k\omega t + \theta_k)$ 可写成 $\{\cos(k\omega t), \sin(k\omega t)\}, k=1, 2, \dots, K$ 的组合, 即

$$\cos(k\omega t + \theta_k) = s_{ik} \cos(k\omega t) + t_{ik} \sin(k\omega t) \quad (23)$$

式中: ω 为基波角频率; k 表示谐波次数; s_{ik} 和 t_{ik} 分别表示系数。在实际工程项目中, 由于采样频率约束, 通常只取前 K 个谐波分量。

由基尔霍夫定律可知, 一个入口节点的电流由流经各个支路上的电流线性叠加得到。因此, 在负荷辨识过程中, 变点前后谐波分量的变化信息是表现负荷投切的重要特征。

2.3 RNN 模型负荷辨识

负荷事件检测以及特征提取之后, 本文根据负荷数据时间序列特性, 设计了面向非侵入式负荷分解模型的 RNN 网络, 其主要分为 6 个阶段。

(1) 准备训练和测试样本数据

在准备训练样本时, 采样装置以 2 s 为间隔获取谐波数据, 设备的开关按表 1 所对应的状态, 其中 N 表示负荷设备种类。在不同组合情况下, 原则上不考虑设备的顺序; 其次, 两个设备不存在同时开的情况, 即一个设备开了之后, 如果需要开下一个设备, 则需要间隔 1 min 或等待其运行到稳态。数据均保存在 MySQL 数据库上。

(2) 各层神经元个数的选取

将 RNN 神经网络应用于负荷辨识, 其神经网络节点和网络层数决定了辨识结果的好坏。本文由输入负荷特征向量的维数决定输入层节点的个数, 而相应期望负荷标签向量的维数则决定输出节点的个数。隐含层神经元个数的选择通常与工程实际有关, 一般而言, 神经元个数越少, 对混叠特征下的辨识效果越差, 而随着神经元个数增多, 辨识效果会逐步提升, 但是超过一定个数辨识效果则会趋于稳定。据实际经验, 一般选择 2 倍的输入神经元个数或更多^[17]。

根据电器工作状态的组合, 选取输入层神经元个数为 16, 输入的时序变量为 $\{x_1, x_2, \dots, x_T\}$, 其中在采样时刻 t 神经元的输入时间序列为 $x_t = [I'_L(1), I'_L(2), \dots, I'_L(16)]$ 。

(3) 定义输出层变量

实验对具有代表性的 7 类电器进行实验, 则选取输出层神经元的个数为 7, 输出变量按照表 1 进行定义。其中 0 表示电器处于停止状态, 1 表示电器处于运行状态。

表 1 输出层变量意义

Table 1 Meaning of output layer variables

工作状态组合	输出变量的意义						
	电暖器	电冰箱	电视机	空调	电饭煲	消毒柜	热水壶
S_1	0	0	0	0	0	0	1
S_2	0	0	0	0	0	1	0
S_3	0	0	0	0	0	1	1
\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots
$S_{2^{N-1}}$	1	1	1	1	1	1	1

(4) 网络层数

对于每个负荷标签对应的负荷特征输入信号, 每个采样时间点的输入数据对应一层网络。隐含层在神经网络学习过程中具有对细节认知的功能, 能够更好地区分类别。因此相对来说, 层数越多其辨识准确度越高, 但训练过程也越复杂^[18]。通常, 隐含层的层数与输入的特征类别有关, 单一特征情况下一般设置一层隐含层。

(5) 各层激活函数的确定

在神经网络中, 激活函数表示网络中节点针对给定输入产生相应输出的映射关系。由于二进制函数和线性函数构建的网络模型具有非常不稳定的收敛特性, 因此, 通常使用规范的 S 形激活函数来解决, 例如 softsign 函数^[19-20], 其函数表达式为

$$f(x) = \frac{1}{1 + \exp\{-\lambda(x - b)\}} \quad (24)$$

其中, 参数通常设置为 $\lambda=1, b=0$ 。

(6) 损失函数的选取

在神经网络中, 损失函数是描述并评估该差值的函数, 将模型预测输出与相关联类标签的偏离程度进行量化。在分类模型中, 监督式学习机制以损失函数为标准, 对训练效果进行评估, 其目的在于使预测值与实际值之间的差值最小化。

损失函数直接关系到网络对权重的修正作用, 从而决定 RNN 网络的学习能力。由式(6)—式(9)可知, 当 $g'(\cdot)$ 和 $f'(\cdot)$ 出现饱和时, 权重等修正就会减弱, 导致学习速率大幅下降, 出现梯度消失等问题。为此, 本文选择交叉熵损失函数能够使训练样本集的输出与期望值偏差最小化, 其具体表达式为

$$L(y_t, \hat{y}_t) = -\frac{1}{N} \sum_{t=1}^T \sum_{j=1}^N \left[\hat{y}_t(j) \ln y_t(j) + (1 - \hat{y}_t(j)) \ln(1 - y_t(j)) \right] \quad (25)$$

3 关联 RNN 模型负荷辨识实例验证

3.1 负荷事件检测

本文以在某能源研究中心采集到的输配电总进线处的电压信号和电流信号作为实验数据，图 3 为某段时间内电流有效值的变化，其中包括了用电设备的投切。进一步可以发现，实际负荷事件发生时刻点为 20, 38, 48, 78, 100, 140, 170, 210, 232, 260, 290, 310, 350, 380 共 14 个变点。表 2 给出在不同时间窗下得到的检测结果。从表中可以看出，本文方法在较短长度时间窗下能够较好地获取负荷事件发生点。通常，窗口大小设置为 10。

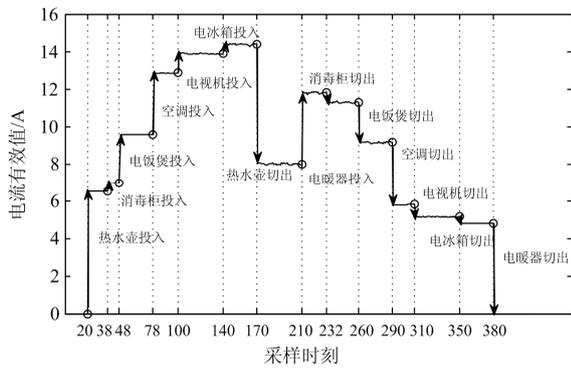


图 3 电流有效值时间序列
Fig. 3 Current RMS time series

表 2 变点检测结果

Table 2 Change point detection result

窗口大小	检测结果	漏检或误检
4~28	20, 38, 48, 78, 100, 140, 170, 210, 232, 260, 290, 310, 350, 380	0
29~50	20, 48, 78, 100, 140, 170, 210, 232, 260, 290, 310, 350, 380	1
51~52	20, 48, 78, 100, 140, 170, 210, 260, 290, 310, 350, 380	2
53~70	20, 48, 78, 100, 140, 170, 210, 260, 290, 310, 380	3

当检测到突变点时，表明电器设备发生投入或切除操作。此时，提取稳态区段的负荷特征^[21]，利用训练好的 RNN 神经网络模型对负荷进行辨识。整个过程包含训练和测试两个环节。

3.2 离线训练

本方法针对 7 个用电设备，共采集了 2⁷ 组数据，采样时刻点以 2 s 为一个间隔，并记录到 MySQL 数据库，其中每一组分别与表 1 的工作态组合相对应，选取每一组中的 40 个时刻点作为训练样本，训练模型示例如图 4 所示。

这种以谐波分量为特征的训练模型使得每组训练样本相对独立，因此在训练时只需考虑本类别的样本，从而提高学习速度^[22]。

整个 RNN 模型的具体训练过程如下。

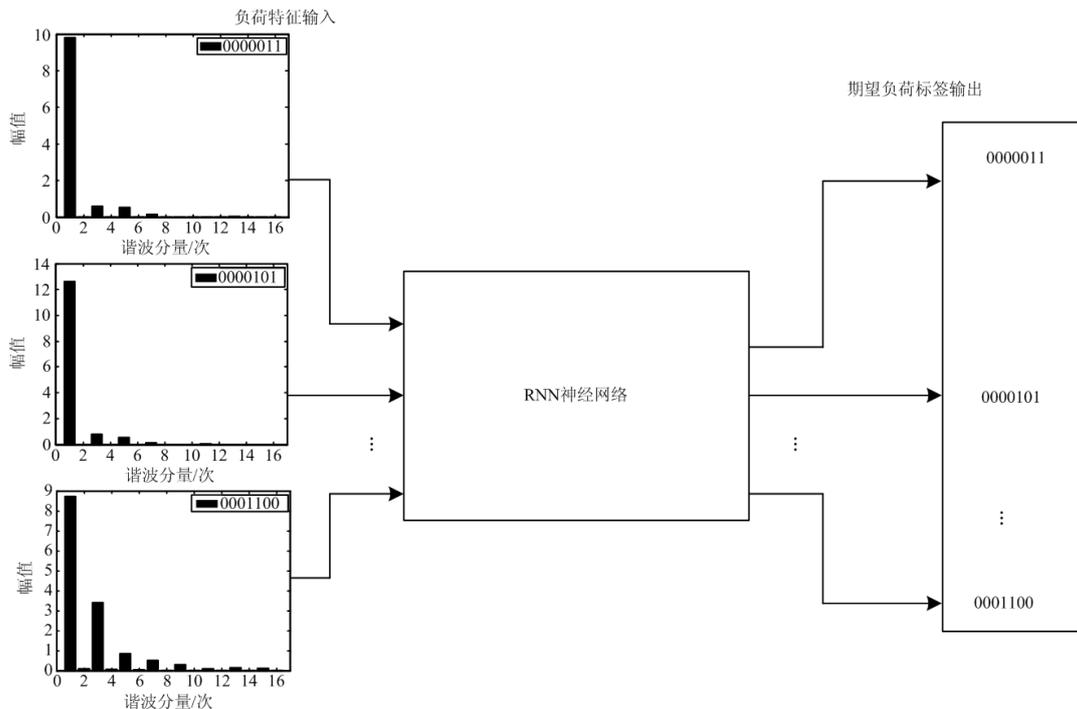


图 4 以谐波分量为特征的训练框架
Fig. 4 Training framework using harmonic components

初始化参数: 学习步长初始化为 0.01, 输入维度为 16, 隐含层节点个数为 32, 输出层节点个数为 7, 权重参数矩阵所有元素初始化为(-1,1)的数值, 误差限值 error_gate 设置为 1×10^{-4} 。

训练: RNN 训练过程是以网络输出的实际值与期望值之间的方差作为评判依据。

$$error = \sum_{i=1}^T \sum_{j=1}^N (y_i(j) - \hat{y}_i(j))^2 \quad (26)$$

迭代次数最大设置为 1 000 次时, 误差平均值最终达到 2.3308×10^{-4} , 训练过程结束。

图 5 给出了损失函数随训练过程迭代次数的变化曲线。可以看出使用 sigmoid 函数作为激活函数时, 输出很快就饱和, 使得 RNN 出现梯度消失现象, 并且收敛速度较慢。

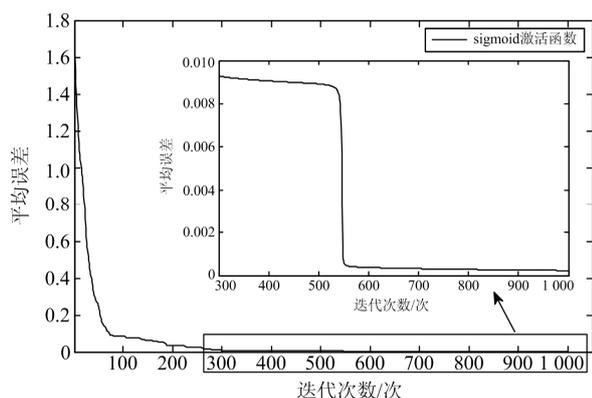


图 5 平均误差曲线

Fig. 5 Average error curve

图 6 给出了当采用 softsign 函数作为激活函数时 RNN 的收敛过程, 相比之下收敛速度较快, 且没有出现梯度消失问题。特别地, 采用交叉熵误差 (Cross Entropy Error, CEE) 作为损失函数下的平均误差曲线, 从图 7 中不难看出, CEE 函数可以有效解决 RNN 在训练过程中出现的“梯度消失”问

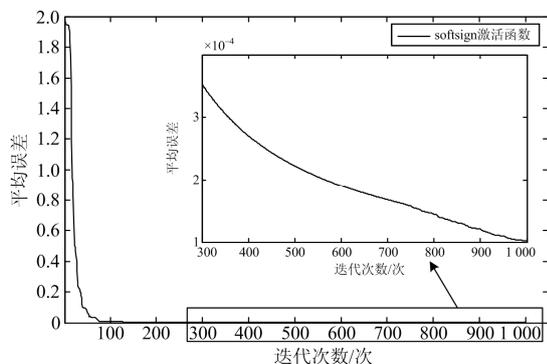


图 6 平均误差曲线

Fig. 6 Average error curve

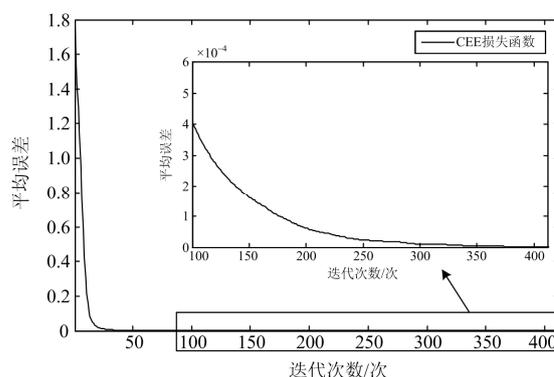


图 7 平均误差曲线

Fig. 7 Average error curve

题, 并能快速收敛, 从而验证本文方法可以有效解决对训练过程中出现梯度消失的问题。

3.3 在线辨识

为了能够较好地统计辨识准确率, 在实际负荷辨识测试过程中, 先将负荷数据记录到 MySQL 数据库中, 其中采样时刻点以 2 s 为一个间隔, 每个设备状态组合中为 1 的用电设备依次以 1 min 间隔开启, 确保负荷事件能够被检测到。当设备状态组合中为 1 的用电设备全开启超过 20 s 时, 依次关闭用电设备。从中获取用电设备全开情况下 10 个时刻点的数据并对其进行辨识。最终得到测试样本集的辨识准确率, 如表 3 所示。可以发现, 当用电设备组合较少时准确率较高, 而当设备较多时, 则出现了一些辨识错误的结果。其主要原因是用电设备谐波特征叠加后的相似性, 使得特征产生了混叠, 造成 RNN 模型辨识错误。

表 3 辨识准确率($H=32$)Table 3 Recognition accuracy ($H=32$)

设备状态组合	样本容量	测试样本	正确辨识样本	辨识准确率/%
1 个设备	$C_7^1 = 7$	70	70	100
2 个设备	$C_7^2 = 21$	210	210	100
3 个设备	$C_7^3 = 35$	350	328	93.14
4 个设备	$C_7^4 = 35$	350	251	71.71
5 个设备	$C_7^5 = 21$	210	149	70.95
6 个设备	$C_7^6 = 7$	70	53	75.71
7 个设备	$C_7^7 = 1$	10	10	100
总计		1 270	1 071	84.33

为此, 本文通过增加不同隐含层节点数进行负荷辨识。图 8 给节点数分别为 32、80、100 时的辨识结果。可以发现, 当隐含层节点增加时, 负荷辨识准确度会有一定程度的提升, 但是当节点数增大到一定程度, 便出现了饱和, 即准确率不再有大

增加。因此,在实际情况下,需根据实验进一步调整这个隐含层节点数。

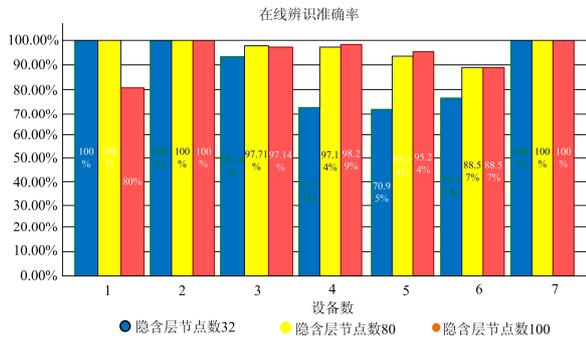


图 8 不同隐含层节点数的比较

Fig. 8 Comparison of the identification effect of different number of nodes in hidden layers

另外,隐含层的增加一定程度上可以提升 RNN 模型的负荷辨识能力。表 4 给出了两层隐含层、32 个节点下不同样本容量的负荷辨识准确率。相比于单层隐含层,在多个设备混合的情况下,能够得到有效的区分,使得负荷辨识准确性提升了 10%。从理论上讲,多层隐含层能够学习样本的细节信息,

因此能够获得较高的负荷辨识能力。

表 4 辨识准确率($H_1=32, H_2=32$)

Table 4 Recognition accuracy ($H_1=32, H_2=32$)

设备状态组合	样本容量	测试样本	正确辨识样本	辨识准确率/%
1 个设备	$C_7^1 = 7$	70	70	100
2 个设备	$C_7^2 = 21$	210	210	100
3 个设备	$C_7^3 = 35$	350	336	96
4 个设备	$C_7^4 = 35$	350	304	86.86
5 个设备	$C_7^5 = 21$	210	194	92.38
6 个设备	$C_7^6 = 7$	70	62	88.57
7 个设备	$C_7^7 = 1$	10	10	100
总计		1 270	1 186	93.39

表 5 给出了图 4 所对应的 RNN 模型的实际输出,可以发现,在变点时刻本文方法能够有效辨识电气设备的工作状态组合,因此在后续的稳态运行阶段,辨识得到的负荷类别与真实的负荷投切类别就会保持一致,从而可以潜在提升负荷辨识的准确率。

表 5 实例辨识结果

Table 5 Recognition results of examples

采样时刻		电暖器	电冰箱	电视机	空调	电饭煲	消毒柜	热水壶
20	\hat{y}	0	0	0	0	0	0	1
	y	0.001 205	0.000 307	0.005 265	0.001 126	0.004 223	0.001 209	0.994 531
38	\hat{y}	0	0	0	0	0	1	1
	y	0.001 416	0.000 253	0.001 616	0.001 297	0.003 271	0.994 45	0.991 556
48	\hat{y}	0	0	0	0	1	1	1
	y	0.001 932	0.000 477	0.005 411	0.001 589	0.996 882	0.994 933	0.970 042
78	\hat{y}	0	0	0	1	1	1	1
	y	7e-05	0.000 31	0.003 88	0.996 877	0.997 934	0.996 294	0.958 413
100	\hat{y}	0	0	1	1	1	1	1
	y	0.000 194	8.15e-05	0.999 652	0.977 76	0.994 974	0.991 156	0.941 979
140	\hat{y}	0	1	1	1	1	1	0
	y	7.69e-06	0.999 668	0.999 027	0.997 537	0.998 723	0.995 403	0.003 218
170	\hat{y}	0	1	1	1	1	1	0
	y	1.08e-05	0.999 201	0.999 158	0.998 681	0.994 986	0.992 415	0.002 015
210	\hat{y}	1	1	1	1	1	1	0
	y	0.998 472	0.997506	0.998 669	0.983 888	0.992 722	0.994 078	0.000 243
232	\hat{y}	1	1	1	1	1	0	0
	y	0.998 298	0.997 474	0.998 63	0.982 728	0.991 827	0.007 128	0.000 276
260	\hat{y}	1	1	1	1	0	0	0
	y	0.999 035	0.999 102	0.997 474	0.969 623	0.007 883	0.009 447	0.000 718
290	\hat{y}	1	1	1	0	0	0	0
	y	0.999 69	0.999 44	0.993 365	0.001 224	0.001 135	0.006 765	1.01e-05
310	\hat{y}	1	1	0	0	0	0	0
	y	0.999 883	0.991 761	0.001 574	0.006 279	0.002 373	0.004 967	0.000 137
350	\hat{y}	1	0	0	0	0	0	0
	y	0.997 849	0.006 3	0.001 874	0.008 075	0.000 951	0.006 455	0.002 796

为了进一步验证本文方法的有效性, 本文与文献[21]的方法进行比较, 其结果如表 6 所示。可以发现, 多个设备开启状态的辨识容易出现辨识设备数与实际的辨识设备数不一致, 导致辨识效果低下。而本文采用 RNN 神经网络训练学习的方法, 能够在一定程度上避免因目标函数的最优解约束而产生偏离实际负荷投切情况。而且, 负荷事件检测方法的引入也可以降低负荷辨识类别与真实情况负荷数类别投切的不一致性。

表 6 辨识准确率

Table 6 Recognition accuracy

设备状态 组合	样本 容量	测试 样本	正确辨识 样本	辨识 准确率/%
1 个设备	$C_7^1 = 7$	70	70	100
2 个设备	$C_7^2 = 21$	210	203	96.67
3 个设备	$C_7^3 = 35$	350	298	85.14
4 个设备	$C_7^4 = 35$	350	268	76.57
5 个设备	$C_7^5 = 21$	210	129	61.42
6 个设备	$C_7^6 = 7$	70	58	72.5
7 个设备	$C_7^7 = 1$	10	10	100
总计		1 270		93.39

4 结论

本文将深度学习 RNN 模型应用于对非侵入式电力负荷的辨识, 对历史输入特征量进行记忆, 建立输入映射到输出的内在联系, 实现对负荷特征标签量的可靠辨识。针对 RNN 模型在大样本数据训练过程出现的“梯度消失”现象, 通过合理选取 softsign 函数作为激活函数, 选取交叉熵损失函数进行实验, 有效地解决了该问题, 并在实验中探讨了隐含层神经元个数的增加及两层隐含层的辨识准确性。相比之下, 隐含层数的增加和隐含层节点数的增加都有助于提升 RNN 模型的负荷辨识能力。由于本文所采用的监督学习方法要求对所辨识的用电设备具有一定的先验知识, 因此后续研究应完善并优化非侵入式负荷辨识方法, 或结合自学习模型, 提升模型在多种用电设备投切情况下的负荷辨识能力, 同时, 在稳定、快速性上做出进一步改进, 为市场推广奠定基础。

参考文献

[1] 汤庆峰, 刘念, 张建华. 计及广义需求侧资源的用户侧自动响应机理与关键问题[J]. 电力系统保护与控制, 2014, 42(24): 138-147.
TANG Qingfeng, LIU Nian, ZHANG Jianhua. Theory and key problems for automated demand response of user

side considering generalized demand side resources[J]. Power System Protection and Control, 2014, 42(24): 138-147.

[2] 阳小丹, 李扬. 家庭用电响应模式研究[J]. 电力系统保护与控制, 2014, 42(12): 51-56.
YANG Xiaodan, LI Yang. Research on household electricity response mode[J]. Power System Protection and Control, 2014, 42(12): 51-56.

[3] 程祥, 李林芝, 吴浩, 等. 非侵入式负荷监测与分解研究综述[J]. 电网技术, 2016, 40(10): 3108-3117.
CHENG Xiang, LI Linzhi, WU Hao, et al. A survey of the research on non-intrusive load monitoring and disaggregation[J]. Power System Technology, 2016, 40(10): 3108-3117.

[4] DINESH C, GODALIYADDA R I, EKANAYAKE M P B, et al. Non-intrusive load monitoring based on low frequency active power measurements[J]. AIMS Energy, 2016, 4(3): 414-443.

[5] HASSAN T, JAVED F, ARSHAD N. An empirical investigation of V-I trajectory based load signatures for non-intrusive load monitoring[J]. IEEE Transactions on Smart Grid, 2013, 5(2): 870-878.

[6] KONG S, KIM Y, KO R, et al. Home appliance load disaggregation using cepstrum-smoothing-based method[J]. IEEE Transactions on Consumer Electronics, 2015, 61(1): 24-30.

[7] MARCHIORI A, HAKKARINEN D, HAN Q, et al. Circuit-level load monitoring for household energy management[J]. IEEE Pervasive Computing, 2011, 10(1): 40-48.

[8] HENAO N, AGBOSSOU K, KELOUWANI S, et al. Approach in nonintrusive type I load monitoring using subtractive clustering[J]. IEEE Transactions on Smart Grid, 2015, 8(2): 812-821.

[9] KIM H S. Unsupervised disaggregation of low frequency power measurements[C] // Eleventh Siam International Conference on Data Mining, 2011, Mesa, Arizona, USA: 747-758.

[10] KOLTER J Z, JAAKKOLA T. Approximate inference in additive factorial HMMs with application to energy disaggregation[C] // Proceedings of the International Conference on Artificial Intelligence and Statistics, 2012, AISTATS: 1472-1482.

[11] LIN Y H, TSAI M S. Development of an improved time-frequency analysis-based nonintrusive load monitor for load demand identification[J]. IEEE Transactions on

Instrumentation & Measurement, 2014, 63(63): 1470-1483.

[12] CONNOR J T, MARTIN R D, ATLAS L E. Recurrent neural networks and robust time series prediction[J]. IEEE Transactions on Neural Networks, 1994, 5(2): 240-254.

[13] JAEGER H. Tutorial on training recurrent neural networks, covering BPPT, RTRL, EKF and the echo state network approach[J]. Encyclopedia of Systems Biology, 2002.

[14] WILLIAMS R J, PENG J. An efficient gradient-based algorithm for on-line training of recurrent network trajectories[J]. Neural Computation, 1990, 2(4): 490-501.

[15] HUANG L, YANG Y, ZHAO H, et al. Time series modeling and filtering method of electric power load stochastic noise[J]. Protection and Control of Modern Power Systems, 2017, 2(2): 269-275. DOI: 10.1186/s41601-017-0059-8.

[16] 王晓换, 李如意, 周东国, 等. 基于决策融合的非侵入式电力负荷辨识方法及应用[J]. 电力系统保护与控制, 2016, 44(7): 115-121.
WANG Xiaohuan, LI Ruyi, ZHOU Dongguo, et al. Non-intrusive power load disaggregation method based on decision fusion and its applications[J]. Power System Protection and Control, 2016, 44(7): 115-121.

[17] 李如意, 王晓换, 胡美璇, 等. RPROP 神经网络在非侵入式负荷分解中的应用[J]. 电力系统保护与控制, 2016, 44(7): 55-61.
LI Ruyi, WANG Xiaohuan, HU Meixuan, et al. Application of RPROP neural network in nonintrusive load decomposition[J]. Power System Protection and Control, 2016, 44(7): 55-61.

[18] 丛爽. 面向 MATLAB 工具箱的神经网络理论与应用[M]. 北京: 中国科学技术大学出版社, 2009.

[19] BERGSTRÄ J, BENGIO Y, LOURADOUR J. Suitability of V1 energy models for object classification[J]. Neural Computation, 2011, 23(3): 774-790.

[20] BORDES A, GLOROT X, WESTON J, et al. A semantic matching energy function for learning with multi-relational data[J]. Machine Learning, 2014, 94(2): 233-259.

[21] 李如意, 黄明山, 周东国, 等. 基于粒子群算法搜索的非侵入式电力负荷分解方法[J]. 电力系统保护与控制, 2016, 44(8): 30-36.
LI Ruyi, HUANG Mingshan, ZHOU Dongguo, et al. Optimized nonintrusive load disaggregation method using particle swarm optimization algorithm[J]. Power System Protection and Control, 2016, 44(8): 30-36.

[22] 郑小霞, 刘庆强, 林顺富, 等. 面向非干预式负荷监测的居民负荷微观特性研究[J]. 电力系统保护与控制, 2014, 42(10): 62-70.
ZHENG Xiaoxia, LIU Qingqiang, LIN Shunfu, et al. Research of the microscopic signatures of residential loads for NILM[J]. Power System Protection and Control, 2014, 42(10): 62-70.

收稿日期: 2018-06-29; 修回日期: 2018-08-31

作者简介:

刘恒勇(1984—), 男, 硕士, 工程师, 研究方向为供电可靠性、电能质量及指标管理;

周东国(1985—), 男, 通信作者, 博士, 讲师, 研究方向为智能电网、模式识别。E-mail: dgzhou1985@whu.edu.cn

(编辑 许威)