

基于 LSTM 神经网络的短期高压负荷电流预测方法

张 洋¹ 姬 波^{1,2} 卢红星^{1,2} 娄铮铮¹

(郑州大学信息工程学院 郑州 450001)¹ (郑州大学产业技术研究院第四代工业研究所 郑州 450001)²

摘 要 传统模型在短期高压负荷电流预测中难以同时解决负荷电流数据的非线性和时间相关性问题。针对此问题,提出一种基于长短期记忆(LSTM)循环神经网络的短期高压负荷电流回归预测方法 SHCP-LSTM。该方法引入自循环权重,使细胞彼此循环连接,可以动态改变累积的时间尺度,使其具有长短期记忆功能;使用遗忘门来控制输入和输出,从而使得门控单元具有 sigmoid 非线性。实验结果验证了该方法的可行性和有效性,与线性逻辑回归算法 LR 和机器学习算法 ANN 神经网络、BPNN 神经网络预测相比,SHCP-LSTM 收敛速度更快,且精确度更高。

关键词 短期负荷电流预测,LSTM,回归预测,SHCP-LSTM

中图分类号 TP183 **文献标识码** A **DOI** 10.11896/j.issn.1002-137X.2019.06.006

Short-term High Voltage Load Current Prediction Method Based on LSTM Neural Network

ZHANG Yang¹ JI Bo^{1,2} LU Hong-xing^{1,2} LOU Zheng-zheng¹

(School of Information Engineering,Zhengzhou University,Zhengzhou 450001,China)¹

(The Fourth Generation of Industry Research Institute,Zhengzhou University,Industrial Technology Research Institute,Zhengzhou 450001,China)²

Abstract In the short-term load current prediction,the traditional model can't solve the problems of nonlinearity and time dependence of load current data simultaneously. To solve this problem,this paper proposed a short-term high voltage load current regression prediction(SHCP) method based on a long short-term memory(LSTM) recurrent neural network,namely SHCP-LSTM. The proposed method introduces the weight of self-circulation,which can make cells connected with each other circularly and dynamically change the cumulative time scale in the prediction,thus having a long short memory function. Meanwhile,the method uses the forgetting gate to control the input and output,so that the gate control unit has the sigmoid nonlinearity. Experiments show that the method is feasible and effective. Compared with linear logistic regression algorithm(LR) and machine learning algorithm artificial neural network(ANN) and back propagation neural network(BPNN) prediction,SHCP-LSTM has fast convergence speed and high accuracy.

Keywords Short-term load current prediction,LSTM,Regression prediction,SHCP-LSTM

随着社会的快速发展,能源供应问题日益凸显,电力供应问题是其中的重要问题之一。针对电能难以大规模存储且需求是实时变化的问题,精准的高压负荷电流预测既保证了高压输电供应的平稳性,也减少了高压输送过程中不必要的电能浪费,从而降低了输送电力的成本,能够较好地满足电力供求。

高压负荷电流的预测则是在历史数据的基础上,通过高压负荷电流数据的变化规律、数据自身的相关性、社会需求量递增以及其他自然状况(如风速、湿度、气温等)间的关联,来探索高压负荷电流的变化规律。在负荷电流预测方法中,一般按照时间长短进行分类,高压负荷电流预测可分为短期、中期和长期预测。本文研究了短期高压负荷电流的预测问题。

传统的短期高压负荷电流预测模型分为两类。一类是以自回归模型(ARIMA)和逻辑线性回归(LR)为代表的时序

列的预测模型,被广泛应用于各个领域。文献[1]报道的研究通过 ARIMA 建立电价预测和误差预测模型,使用加州电力市场的历史数据对日平均电价进行预测。文献[2]通过建立 MARS,SVR 和 ARIMA 模型,对澳大利亚昆士兰州的终端用户对短期电力的总需求数据进行预测。文献[3]通过建立 ARIMAX 模型,对加拿大安大略省东部的一栋三层楼房中的电力需求进行预测。文献[4]通过建立模糊的 LR 模型,使用前 3 年的历史负荷数据进行负荷预测。文献[5]通过建立 LR 和 ANN 模型,对下一时刻的短期负荷进行预测。这类预测较好地突出了高压输送线路负荷电流数据随着时间序列的变化规律以及相关预测的特性,但是在预测中不能较好地表达数据的非线性相关性。另一类是以 ANN 神经网络、BPNN 神经网络为代表的机器学习预测模型。文献[6]通过建立

到稿日期:2018-06-13 返修日期:2018-08-31 本文受国家自然科学基金(61502434),国家重点研发计划(2018YFB1201403)资助。

张 洋(1991-),男,硕士生,主要研究方向为数据挖掘、深度学习;姬 波(1973-),男,博士,教授,主要研究方向为数据分析、模式识别、工控系统;卢红星(1965-),男,硕士,副教授,CCF 高级会员,主要研究方向为模式识别、工控系统,E-mail:iehxl@zzu.edu.cn(通信作者);娄铮铮(1984-),男,博士,副教授,主要研究方向为机器学习、数据挖掘、模式识别。

ANN神经网络模型来预测负载网侧输入电流的基波成分,控制有源滤波器产生用以抵消非线性负载的谐波电流。文献[7]通过建立 GA-ANN 模型,减少使用的特征数量,对3个不同地理位置的短期负荷数据进行预测。文献[8]通过建立 GA-ANN 模型,对台湾风电公司的实际运营结果进行了测试和分析。文献[9]结合引力搜索算法(GSA)和 ANN 神经网络建立 GSA-ANN 模型,用于预测地下高压线的鞘层电流。文献[10]通过建立交变粒子群优化算法的 BPNN 网络模型,减小了通过神经网络预测模型求解电力短期负荷预测带来的误差。文献[11]通过建立模糊粗糙集理论的 BPNN 网络模型,对电力系统的短期负荷进行预测。这类算法存在的问题在于:时间的逐步增加导致时间之间缺乏相关性,将会逐渐丧失对中期或长期数据的学习能力。

为了解决上述模型在预测中存在的问题,本文提出了基于深度学习 LSTM 神经网络的短期高压负荷电流预测方法 SHCP-LSTM。该方法同时考虑负荷电流时间序列及其非线性相关性;在时间序列方面,SHCP-LSTM 引入自循环权重,使细胞彼此循环连接,以动态改变累积的时间尺度,使其具有长短期记忆功能;在非线性相关性方面,通过 SHCP-LSTM 细胞,由遗忘门控制输入和输出,从而使得门控单元具有 sigmoid 非线性。实验研究表明,本文提出的预测方法是可行和有效的,相比于线性逻辑回归算法 LR 和机器学习算法 ANN 神经网络、BPNN 神经网络预测时间序列预测和机器学习算法预测,收敛速度更快,且精确度更高。

1 LSTM 神经网络

LSTM 神经网络最早是由 Hochreiter 等^[12]于 1997 年通过改进 RNN 循环神经网络而提出的一种具有长短记忆的循环神经网络;Graves 等^[13]对其进行了改进,较好地解决了 RNN 梯度消失的问题。

RNN 神经网络具有循环的结构,具备保持信息的能力,其网络结构如图 1 所示。在每个时间间隔 t ,输入变量为 $i^{(t)}$,隐藏层激活为 $s^{(t)}$,输出量为 $o^{(t)}$,目标函数为 $y^{(t)}$,损失函数为 $L^{(t)}$ 。RNN 输入层到隐藏层的连接由权重矩阵 U 参数化,单元之间隐藏层到另一个隐藏层的双向反馈连接由权重矩阵 W 参数化,最后一个隐藏层到输出层的连接由权重矩阵 V 参数化。该模型相比普通神经网络模型的突出特点是其在处理单元之间既有前馈连接又有反馈连接,形成循环网状。从系统结构上来看,该模型是一个双向循环的动力系统,在计算过程中体现了过程的动态特性,相比机器学习中的神经网络具有较强的动态行为和计算能力。RNN 虽然可以从理论上满足海量数据序列的训练要求,但是随着时间间隔的不断增大,RNN 将会逐渐丧失对中期或长期数据的学习能力,即出现梯度消失的问题。




图 1 简单的 RNN 模型单元图

Fig. 1 Cell diagram of simple RNN model

LSTM 神经网络能较好地克服梯度消失的问题,该模型由专门的记忆存储单元组成,通过精心设计的遗忘门、输入门和输出门来控制各个记忆存储单元的状态,通过门的控制保证了随着隐藏层在新的时间状态下不断叠加输入序列,前面的信息能够继续向后传播而不消失,使其具有较好的长短期记忆能力和非线性特性,更好地适应于长时间序列的海量数据处理。LSTM 神经网络的结构如图 2 所示。

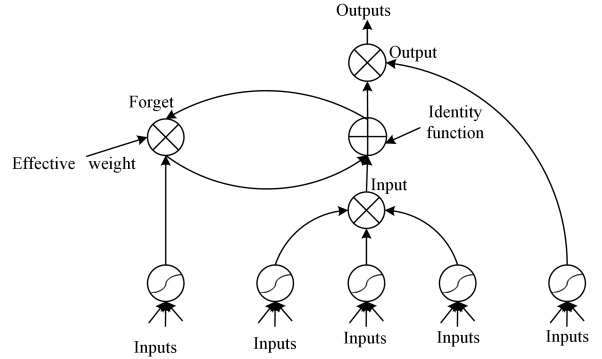


图 2 LSTM 循环网络“细胞”的框图

Fig. 2 Block diagram of “cell” of LSTM circulating network

LSTM 循环神经网络由 input(输入门)、forget(遗忘门)、output(输出门)和 cell(细胞核)等单元组成。其中,输入门则是用来控制需要计算序列的输入过程;遗忘门用来控制前一个过程中状态信息的保存;输出门用来控制输入信息在计算后的输出;细胞核为整个计算节点中的核心单元,用来记录当前时刻 LSTM 神经网络的状态。其计算如下:

1) 输入门是由使用了 sigmoid 激活函数控制输出的 $e^{(t)}$ 和使用 tanh 激活函数控制输出的 $a^{(t)}$ 组成的。计算公式为:

$$e^{(t)} = \sigma(W_i s^{(t-1)} + U_i i^{(t)} + p_i) \quad (1)$$

$$a^{(t)} = \tanh(W_a s^{(t-1)} + U_a i^{(t)} + p_a) \quad (2)$$

其中, W_i 和 W_a 是遗忘门的循环过程的权重; U_i 和 U_a 是输入权重; p_i 和 p_a 是偏置; $s^{(t-1)}$ 和 $i^{(t)}$ 分别为隐藏层激活、输入。

2) 遗忘门 $f^{(t)}$ 控制自循环权重,更好地突出了 LSTM 神经网络的核心长短期记忆,且还控制输入和输出,使其具有非线性。计算公式为:

$$f^{(t)} = \sigma(W_f s^{(t-1)} + U_f i^{(t)} + p_f) \quad (3)$$

其中, W_f 和 U_f 为遗忘门和输入权重, p_f 为偏置。

3) 细胞核状态的更新。细胞状态 $C^{(t)}$ 由两部分组成,第一部分是 $C^{(t-1)}$ 和遗忘门输出 $f^{(t)}$ 的乘积,第二部分是输入门的 $e^{(t)}$ 和 $a^{(t)}$ 的乘积, \odot 为 Hadamard 积。计算公式为:

$$C^{(t)} = C^{(t-1)} \odot f^{(t)} + e^{(t)} \odot a^{(t)} \quad (4)$$

4) 输出门将输入的数据经过隐藏层再通过激活函数压缩到 $[0, 1]$ 进行输出。计算公式为:

$$o^{(t)} = \sigma(W_o s^{(t-1)} + U_o i^{(t)} + p_o) \quad (5)$$

$$s^{(t)} = o^{(t)} \odot \tanh(C^{(t)}) \quad (6)$$

其中, p_o 为偏置, W_o 和 U_o 为权重。

5) prediction(预测)。预测用 $\hat{y}^{(t)}$ 表示,计算公式为:

$$\hat{y}^{(t)} = \sigma(V s^{(t)} + c) \quad (7)$$

其中, V 和 c 分别为权重和偏置。

2 基于 LSTM 神经网络的负荷电流预测方法

2.1 SHCP-LSTM 神经网络模型

本文在时间序列下以输电线路温度、环境温度、环境风速、环境湿度、输电线路弧垂、负荷电流作为输入量,来进行下一个时间序列负荷电流的预测。本文构建的 SHCP-LSTM 模型的整体结构如图 3 所示,由输入层、隐藏层、输出层、网络训练以及网络预测 5 个功能模块组成。

(1) 输入层

输入层负责对输入的时间序列数据进行相应的处理以满足网络输入要求。

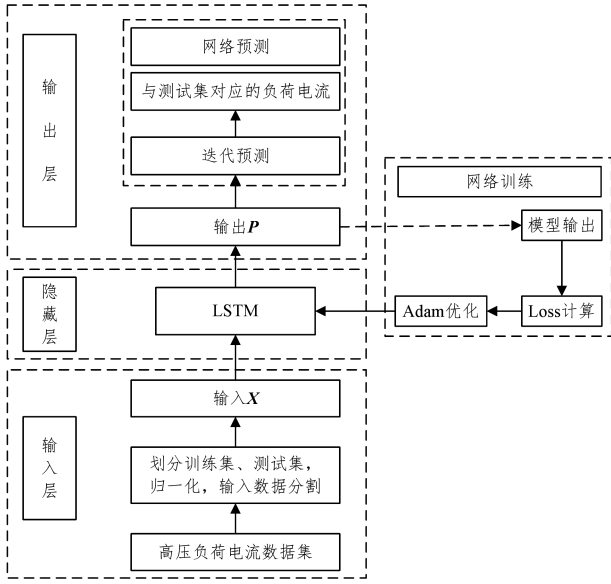


图 3 SHCP-LSTM 神经网络模型

Fig. 3 SHCP-LSTM neural network model

1) 数据输入之前,首先要定义在时间序列下的原始的高压输电线路数据 \mathbf{N} ,如式(8)所示:

$$\mathbf{N} = \{N_1, N_2, N_3, N_4, \dots, N_n\} \quad (8)$$

2) 将数据集划分为训练集 N_{train} 和测试集 N_{test} , 满足约束条件 $m < n$ 和 $m, n \in \mathbf{N}^+$, 如式(9)和式(10)所示:

$$N_{\text{train}} = \{N_1, N_2, N_3, N_4, \dots, N_m\}, m \in (0, n) \quad (9)$$

$$N_{\text{test}} = \{N_{m+1}, N_{m+2}, N_{m+3}, N_{m+4}, \dots, N_n\} \quad (10)$$

3) 将划分好的训练集数据和测试集数据进行归一化处理,如式(11)和式(12)所示:

$$N'_{\text{train}} = \{N'_1, N'_2, N'_3, N'_4, \dots, N'_m\} \quad (11)$$

$$N'_{\text{test}} = \{N'_{m+1}, N'_{m+2}, N'_{m+3}, \dots, N'_n\} \quad (12)$$

4) 为了适应隐藏层输入的特点,应用数据分割的方法对训练数据进行处理。设定分割窗口的长度取值为 L , 则分割后的模型输入为:

$$\mathbf{X} = \{X_1, X_2, X_3, X_4, \dots, X_L\} \quad (13)$$

$$\mathbf{X}_p = \{X'_p, X'_{p+1}, X'_{p+2}, X'_{p+3}, \dots, X'_{m-L+p-1}\} \quad (14)$$

$$1 \leq p \leq L; p, L \in \mathbf{N}^+ \quad (14)$$

(2) 隐藏层

隐藏层采用 LSTM 细胞构建带有多隐藏层的长短期记忆神经网络,将输入层数据输入到隐藏层,隐藏层经过理论输

出,计算相对损失,然后将算法进行相应的优化,经过多个隐藏层损失计算和优化,隐藏层对最终结果进行输出,输出到输出层进行相应的预测。其过程如下:

1) 将 \mathbf{X} 输入隐藏层。

2) 隐藏层包含 L 个按时间序列顺序连接的同构 LSTM 细胞。 \mathbf{X} 经过隐藏层后的输出可以表为:

$$\mathbf{P} = \{P_1, P_2, P_3, P_4, \dots, P_L\} \quad (15)$$

$$P_p = \text{LSTM}_{\text{forward}}(\mathbf{X}_p, \mathbf{C}_{p-1}, \mathbf{H}_{p-1}) \quad (16)$$

其中, \mathbf{C}_{p-1} 和 \mathbf{H}_{p-1} 分别为前一个 LSTM 细胞的状态和输出; $\text{LSTM}_{\text{forward}}$ 表示第 1 节提到的 LSTM 细胞的前向传播计算方式(式(1)~式(6))。

3) 将输出的数据进行相应的 $loss$ 损失计算,从而得到误差。本文选用均方误差(RMSE)和平均绝对百分误差(MAPE)作为 $loss$ 的误差标准。

4) 优化。基于梯度的优化算法比较多,如 SGD, AdaGrad 和 RMSProp 等优化算法,本文选用适应性动量估计算法(Adam),该算法融合了 AdaGrad 和 RMSProp 算法的优势,能够对不同参数计算适应性学习率,并且占用的存储资源较少。相比于其他随机优化方法,Adam 算法在实际应用中的整体表现更优。

(3) 输出层

输出层是将隐藏层经过优化降低损失的结果进行输出 $\{P_1, P_2, P_3, P_4, \dots, P_L\}$ 。然后将输出的 m 时刻的结果提供给预测模块,对高压负荷电流进行预测。来预测 $m+1$ 时刻的负荷电流大小。最终将得到预测结果进行输出。

(4) 网络训练

网络训练其训练的部分主要为隐藏层部分。使用 RMSE 和 MAPE 进行损失计算。最后采用 Adam 优化算法进行优化,经过多次训练最终进行验证预测。其处理过程如下:

1) 将分割后的训练集数据 $N_1, N_2, N_3, N_4, \dots, N_m$ 进行输入隐藏层。

2) 通过隐藏层进行理论输出,并计算 $loss$ 损失,本文给定误差评判标准为 RMSE 和 MAPE。

3) 采用 Adam 优化算法不断更新网络权重进行优化。

4) 最后将经过多个隐藏层 $loss$ 计算与 Adam 优化的结果 $\{P_1, P_2, P_3, P_4, \dots, P_L\}$ 进行输出。

(5) 网络预测

网络预测则是采用训练好的 LSTM 循环神经网络模型进行预测,采用多次迭代逐点预测的方法。

1) 理论上,输出 \mathbf{P} 的最后一行数据为:

$$\mathbf{Y}_f = \{Y'_{m-L+1}, Y'_{m-L+2}, Y'_{m-L+3}, Y'_{m-L+4}, \dots, Y'_m\} \quad (17)$$

2) 将 \mathbf{Y}_f 输入 $\text{LSTM}_{\text{net}}^*$, 得到 $m+1$ 时刻的预测值为 P_{m+1} , 输出结果可以表示为:

$$\mathbf{P}_f = \text{LSTM}_{\text{net}}^*(\mathbf{Y}_f) = \{P_{m-L+2}, P_{m-L+3}, P_{m-L+4}, P_{m-L+5}, \dots, P_{m+1}\} \quad (18)$$

3) 然后将 \mathbf{Y}_{f+1} 输入 $\text{LSTM}_{\text{net}}^*$ 得到 $m+2$ 时刻的预测值。依次执行该操作,最终得到 $n+1$ 时刻的预测值。

4) 预测输出与测试集对应的负荷电流数据。最后通过计算训练集和训练预测数据,以及测试集和测试预测数据的偏

差,定量地给出模型的拟合和预测精度。

2.2 SHCP-LSTM 神经网络算法

2.2.1 算法伪代码

SHCP-LSTM 神经网络算法的伪代码如算法 1 所示。

算法 1 SHCP-LSTM 预测输电线路负荷电流算法

输入:训练集 Train_set,测试集 Test_set,属性(时间、负荷电流、温度、弧垂、气温、湿度、风速)

输出:与测试集对应预测的负荷电流数据,以及模型标准误差和平均绝对百分误差

Step1 将时间序列数据转化为有监督数据:

If $i > n_{in}$ and $i < 0$

input sequence($t-n, \dots, t-1$)

Else if $i > 0$ and $i < n_{out}$

forecast sequence($t, t+1, \dots, t+n$)

Step2 Max-Min 特征变换:

Return (Train_set)

Return (Test_set)

Step3 Train_set Train SHCP-LSTM

Test_set Test SHCP-LSTM

Return (标准误差 RMSE)

Return (平均绝对百分误差 MAPE)

Return (预测高压线路负荷电流值)

END

2.2.2 时间复杂度分析

SHCP-LSTM 算法 Step1 中数据转化为时间序列有监督数据的时间复杂度为 $O(|n||m|)$, Step2 中 Max-Min 特征变换的时间复杂度为 $O(|n||m|)$, Step3 中计算标准误差 RMSE 的时间复杂度为 $O(|n||m||i|)$, 计算平均绝对百分误差 MAPE 的时间复杂度 $O(|n||m||i|)$ 。其中, $|n|$ 是数据对象的个数, $|m|$ 是属性值的个数, $|i|$ 是隐藏层节点的个数。因此, SHCP-LSTM 算法的时间复杂度为 $O(|n||m||i|)$ 。

3 实验

3.1 实验数据集

实验数据集取自某电力公司高压输电线路 22 号传感器的数据,传感器按照 1 次/min 的频率采集了 2016 年 12 月 3 日至 2016 年 12 月 23 日的记录,共 13980 条记录,每条数据记录包含 6 个属性:输电线路温度、环境温度、环境风速、环境湿度、负荷电流、输电线路弧垂。如何选择合适的输入量及标签来使用回归算法进行训练,是建立短期高压负荷电流预测模型中较为关键的一步。本实验在时间序列条件下以输电线路温度、环境温度、环境风速、环境湿度、弧垂、负荷电流作为 SHCP-LSTM 神经网络的输入属性,来预测下一时刻的高压负荷电流。

3.2 数据质量的分析

在数据采集的过程中,环境因素的干扰、采集数据的不正当操作以及设备本身的问题等将导致采集的数据中会出现一些异常数据。为了使实验预测更加精准,在进行训练之前先对数据进行处理,本文中利用样本的统计指标与设定阈值判断是否存在非正常数据。通过计算 $Mean$ (均值)、 Std (标准

差)、 $Range$ (极差)、 Var (变异系数)、 max (最大值)、 min (最小值)及 1/4、1/2、3/4 分位数(25%, 50%, 75%)来对数据质量进行分析,结果如表 1 所列。

表 1 数据分析表

Table 1 Data analysis table

	温度	弧垂	电流	气温	湿度	风速
count	13980	13980	13980	13980	13980	13980
mean	7.527515	1.488405	58.782025	5.824249	0.643924	9.184378
std	3.938374	0.158559	17.701630	3.889205	0.230690	5.511776
min	0.642384	1.183500	30.100000	-4.000000	0.080000	0.000000
25%	4.468780	1.365300	49.397700	4.000000	0.490000	3.600000
50%	6.906130	1.453425	58.344400	5.000000	0.650000	7.200000
75%	9.631875	1.576313	68.537900	8.000000	0.870000	10.800000
max	21.37310	2.125090	837.22100	21.000000	1.000000	28.800000
range	20.73071	0.941590	807.12100	25.000000	0.920000	28.800000
var	0.523197	0.106530	0.301140	0.667761	0.358256	0.600125
dis	5.163095	0.211013	19.140200	4.000000	0.380000	7.200000

为了更加直观地展示高压数据的属性分布,本文还引入了箱线图分析来进行异常检测。箱线图提供了识别异常数据的准则:异常数据通常被定义为不在 $[Q_L - 1.5IQR, Q_U + 1.5IQR]$ 区间内的值,将异常数据使用均值进行替换。 Q_L 为下四分位数, Q_U 为上四分位数, IQR 为四分位数间距。异常检测的箱线图如图 4 所示。




图 4 异常检测箱线图

Fig. 4 Abnormal detection box line drawing

3.3 归一化处理

数据处理完后,再把数据进行归一化处理,使其值处于 $[0, 1]$ 之间,以更好地进行直观比较(否则数据差值太大,图像不能看得更直观)。本文采用最小-最大规范化是对原始数据的线性变换,变换公式如式(19)所示。

$$X_i' = \frac{X_i - Minvalue}{Maxvalue - Minvalue} \quad (19)$$

其中, $Maxvalue$ 为数据中的最大值, $Minvalue$ 为数据中的最小值, $Maxvalue - Minvalue$ 为极差, X_i 为在数据集中所取的数据, X_i' 为归一化后数据的大小。

3.4 实验性能评估方法

采用 10 次十折交叉验证进行实验评估,将实验结果的标准差(RMSE)、平均绝对百分误差(MAPE)作为 SHCP-LSTM 神经网络预测短期高压负荷电流方法的评测指标。十折交叉验证法是将处理好的数据平均划分为 10 份,依次轮流选择 9 份作为训练集,另一份作为实验的验证集,进行短期高压负荷电流的预测。其中, RMSE 和 MAPE 的计算公式如式(20)、式(21)所示。

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^n w_i (y_i - \hat{y}_i)^2} \quad (20)$$

$$MAPE = \frac{1}{N} \sum_{i=1}^N \left| \frac{y_i - \hat{y}_i}{y_i} \right| * 100 \quad (21)$$


其中, y_i 是指从 12 月 3 号到 12 月 23 号传感器按照 1 次/min 的频率在第 i 分钟所取的数据, \hat{y}_i 第 i 分钟所取数据的预测值, w_i 为自由度。

3.5 实验结果

本文采用了 SHCP-LSTM 算法模型进行短期高压负荷电流的预测,同时采用传统的回归预测方法进行对照实验。为了更好地突出 SHCP-LSTM 神经网络相对更好的效果,本文分别通过时间相关性和非线性来进行验证。在时间相关性方面,本文采用了 LR 线性逻辑回归预测;在非线性方面,本文分别采用了一个三层的 ANN 神经网络和四层的 BPNN 神经网络进行回归预测。


3.5.1 收敛性实验

图 5 分别给出 ANN 神经网络、BPNN 神经网络和 SHCP-LSTM 神经网络的训练误差下降曲线。以同样训练迭代 500 次为分界点,可以看出对于同样的数据集,SHCP-LSTM 神经网络在迭代 150 次左右时,训练误差就已经降低至 0.04,而且网络已经收敛;而 ANN 神经网络和 BPNN 神经网络在迭代 500 次后训练的误差分别处于 0.6 和 0.3 左右,未达到收敛状态。由此可见,SHCP-LSTM 神经网络的学习率较传统的神经网络要好得多。



(a) ANN 神经网络训练误差下降曲线

(b) BPNN 神经网络训练误差下降曲线




(c) SHCP-LSTM 神经网络训练误差下降曲线

图 5 ANN, BPNN 和 SHCP-LSTM 算法的训练误差下降曲线


Fig. 5 Training error fall curve of ANN, BPNN and SHCP-LSTM algorithms

3.5.2 预测结果的分析


采用训练好的模型进行预测,选取 12 月 3 号到 12 月 23 号按照 1 次/min 的频率所取的 1398 条数据进行预测。图 6 分别给出 LR、ANN 神经网络、BPNN 神经网络、SHCP-LSTM 神经网络训练集在训练中预测的结果与真实数据的比较。其中,黑色虚线点代表真实数据,灰色实线代表预测的数据。与 LR、ANN 神经网络、BPNN 神经网络相比,SHCP-LSTM 神经网络的预测精度更高。




(a) LR 预测值与真实值的比较



(b) ANN 网络预测值与真实值的比较



(c) BPNN 神经网络预测值与真实值的比较



(d) SHCP-LSTM 神经网络预测值与真实值的比较

图 6 LR、ANN 神经网络、BPNN 神经网络和 SHCP-LSTM 神经网络的预测值与真实值的比较

Fig. 6 Comparison of predicted and real values of LR, ANN, BPNN and SHCP-LSTM algorithms

3.5.3 时间相关性和非线性误差的对比分析

(1) 本文在时间相关性上,采用 LR 线性逻辑回归方法进行预测。通过 10 次训练和验证得到 10 次训练的平均 RMSE 为 13.194,平均 MAPE 为 20.5762;10 次验证的平均 RMSE 为 9.182,平均 MAPE 为 14.4963。其实验结果如图 7 所示。

(2) 在非线性方面,本文采用了 ANN 神经网络和 BPNN 神经网络的预测方法对短期高压负荷电流进行了预测。ANN 神经网络采用三层网状结构,实验设置如下:5 个输入节点,100 个隐藏节点,1 个输出节点,随机种子数 $seed=1$,训练步数 $steps=500$,学习率 $\eta=0.001$,批处理大小 $batch_size=1$ 。ANN 神经网络通过 500 次迭代得到 10 次训练的平均 RMSE 为 7.922,平均 MAPE 为 11.2588;10 次验证的平均 RMSE 为 4.732,平均 MAPE 为 6.6036。结果如图 7 所示。BPNN 神经网络采用四层网状结构,实验设置如下:5 个输入节点,第一隐藏层和第二隐藏层都是 100 个隐藏层节点,1 个输出节点,随机种子数 $seed=1$,训练步数 $steps=500$,学习率 $\eta=0.001$,批处理大小 $batch_size=1$ 。BPNN 神经网络同样

使用 500 次迭代得到 10 次训练的平均 RMSE 为 5.017, 平均 MAPE 为 7.0248; 验证的平均 RMSE 为 3.851, 平均 MAPE 为 5.1538。实验结果如图 7 所示。




图 7 LR, ANN, BPNN 和 SHCP-LSTM 算法的 RMSE 和 MAPE 对比

Fig. 7 Comparison of RMSE and MAPE of LR, ANN, BPNN and SHCP-LSTM algorithms

(3) 为了更好地突出时间序列的相关性和非线性, 本文采用同时兼具时间相关性和非线性的 SHCP-LSTM 神经网络方法进行了短期高压负荷电流的预测。在时间序列下, 实验设置如下: 6 个输入节点, 50 个隐藏节点, 1 个输出节点。随机种子数 $seed=1$, 训练步数 $steps=500$, 学习率 $\eta=0.001$, 批处理大小 $batch_size=1$ 。通过 500 次迭代最终得到 10 次训练的平均 RMSE 为 3.997, 平均 MAPE 为 5.0788; 10 次验证得到的平均 RMSE 为 3.185, 平均 MAPE 为 4.1346。实验结果如图 7 所示。

由实验结果可以看出, SHCP-LSTM 神经网络在训练时较 ANN 神经网络、BPNN 神经网络收敛得更快, 预测的精度也更高, 且标准差 RMSE 和平均绝对百分误差 MAPE 远远小于 LR、ANN 神经网络、BPNN 神经网络, 证明该预测方法在使用效果上优于传统的线性回归 LR 和非线性的 ANN 神经网络、BPNN 神经网络的预测方法。

结束语 本文针对目前已有短期高压负荷电流预测方法难以同时解决高压负荷电流数据的非线性和时间相关性问题, 提出了一种基于深度学习 LSTM 神经网络的短期高压负荷电流预测方法 SHCP-LSTM。该算法在预测过程中同时兼具时间相关性和非线性的特征。基于国家电网某电力公司真实的高压数据进行实验, 并采用 10 次十折验证方法进行评价, 结果表明了 SHCP-LSTM 具有更高的精确性和更好的适用性。

在今后的工作中一方面可以扩大数据集的规模, 另一方面还可以引入新的循环神经网络模型如 CW-RNNs 和 In-dRNN 进行预测。

参考文献

[1] ZHOU M, YAN Z, NI Y X, et al. A novel RIMA approach on electricity price forecasting with the improvement of predicted error [J]. Proceedings of the CSEE, 2017, 24(12): 63-68. (in Chinese) 周明, 严正, 倪以信, 等. 含误差预测校正的 ARIMA 电价预测新方法[J]. 中国电力工程学报, 2017, 24(12): 63-68.

[2] AL-MUSAYLH M S, DEO R C, ADAMOWSKI J F, et al. Short-term electricity demand forecasting with MARS, SVR and ARIMA models using aggregated demand data in Queensland, Australia [J]. Advanced Engineering Informatics, 2018, 35: 1-16.

[3] NEWSHAM G R, BIRT B J. Building-level Occupancy Data to Improve ARIMA-based Electricity Use Forecasts [C] // ACM Workshop on Embedded Sensing Systems for Energy-Efficiency in Buildings. Texas: ACM Press, 2010: 13-18.

[4] SONG K B, BAEK Y S, HONG D H. Short-Term Load Forecasting for the Holidays Using Fuzzy Linear Regression Method [J]. IEEE Transactions on Power Systems, 2005, 20(1): 96-101.

[5] PATEL H, PANDYA M, AWARE M. Short Term Load Forecasting of Indian System Using Linear Regression and Artificial Neural Network [C] // N-UICONE 2015-5th Nirma University International Conference on Engineering. New York: IEEE Press, 2015: 1-5.

[6] LV Z Y, QIAN Z M, GREEN T C. A predicted control scheme of shunt active power filter with artificial neural network [J]. Proceedings of the CSEE, 1999, 19(12): 22-26. (in Chinese) 吕征宇, 钱照明, GREEN T C. 并联有源电力滤波器的神经网络预测控制 [J]. 中国电机工程学报, 1999, 19(12): 22-26.

[7] VIEGAS J L, VIEIRA S M, MELICIO R, et al. GA-ANN Short-Term Electricity Load Forecasting [C] // IFIP Advances in Information and Communication Technology. Berlin: Springer New York, 2016: 485-493.

[8] KOLHE M, LIN T C, MAUNUKSELA J. GA-ANN for Short-Term Wind Energy Prediction [C] // Asia-Pacific Power and Energy Engineering Conference. New York: IEEE Press, 2011: 1-6.

[9] AKBAL B. Hybrid GSA-ANN Methods to Forecast Sheath Current of High Voltage Underground Cable Lines [J]. Journal of Computers, 2018, 13(4): 417-425.

[10] TANG C E. Short-term Load Forecasting of Power System Based on Alternating Particle Swarm BP Network [J]. Computer Science, 2017, 44(S2): 133-135, 165. (in Chinese) 唐承娥. 基于交替粒子群 BP 网络的电力系统短期负荷预测 [J]. 计算机科学, 2017, 44(S2): 133-135, 165.

[11] CHEN P, ZHANG Q, LI Y J, et al. Short-Term Load Forecasting Model for Power System Based on Complement of Fuzzy-Rough Set Theory and BP Neural Network [C] // Proceedings of the IEEE International Conference on Automation and Logistics. New York: IEEE Press, 2007: 1373-1377.

[12] HOCHREITER S, SCHMIDHUBER J. LSTM Can Solve Hard Long Time Lag Problems [C] // Advances in Neural Information Processing Systems. Canada: NIPS, 1996: 473-479.

[13] GRAVES A, ECK D, SCHMIDHUBER J, et al. Biologically plausible speech recognition with LSTM Neural Nets [M] // Lecture Notes in Computer Science. Berlin: Springer Verlag, 2004: 127-136.