

doi:10.3969/j.issn.1673-9833.2020.04.005

基于实时电价特征的Seq2Seq-Attention 网络短期电价预测

厉宇程, 李长云

(湖南工业大学 智能信息感知及处理技术湖南省重点实验室, 湖南 株洲 412007)

摘要: 电价预测中常选择负荷与电价作为输入特征, 由于输入信息量少, 难以得到较好的预测效果。为准确捕捉短期电价变化规律, 提出基于实时电价原理进行电价特征提取, 从电价形成机制的角度对电价波动原因进行分析, 筛选出用于短期电价预测的实时电价特征。并使用擅于捕捉电价预测数据规律的Seq2Seq-Attention网络进行预测。通过美国PJM电力市场公开数据进行验证, 证明了该方法的有效性。

关键词: 实时电价特征; Seq2Seq网络; Attention机制; 电价预测

中图分类号: TM715

文献标志码: A

文章编号: 1673-9833(2020)04-0029-06

引文格式: 厉宇程, 李长云. 基于实时电价特征的Seq2Seq-Attention网络短期电价预测[J]. 湖南工业大学学报, 2020, 34(4): 29-34.

Short-Term Electricity Price Forecast in Seq2Seq-Attention Network Based on Real-Time Electricity Price Features

LI Yucheng, LI Changyun

(Key Laboratory of Intelligent Information Perception and Processing Technology,
Hunan University of Technology, Zhuzhou Hunan 412007, China)

Abstract: Due to the small amount of input information available with load and price selected as input features in electricity price forecasting, it is difficult to achieve a better forecasting effect. In order to accurately capture the change frequency of short-term electricity price, it is proposed to extract the characteristics of electricity price based on the principle of real-time electricity price, followed by an analysis of the causes of electricity price fluctuation from the perspective of electricity price formation mechanism, with the characteristics of real-time electricity price selected for short-term electricity price prediction. Moreover, a recommendation has been made of Seq2Seq-attention network, which is good at capturing the law of electricity price forecast data to forecast. The validity of this proposed method has been verified by the public data of PJM power market in the United States.

Keywords: real-time electricity price feature; Seq2Seq network; Attention mechanism; electricity price forecasting

收稿日期: 2019-08-06

基金项目: 国家重点研发计划基金资助项目(2018YFB1700200), 国家自然科学基金资助青年项目(61702177)

作者简介: 厉宇程(1991-), 男, 湖南衡阳人, 湖南工业大学硕士生, 主要研究方向为工业节能及电力市场,

E-mail: 280935527@qq.com

通信作者: 李长云(1972-), 男, 湖南衡阳人, 湖南工业大学教授, 博士生导师, 主要从事软件自动化及物联网方面的教学与研究, E-mail: 362330193@qq.com

0 引言

电价是电力市场中的核心部分,国内外研究者对于电价预测已经开展了较多工作,如使用经典回归分析方法基于数理统计知识对时间序列进行回归拟合,由于模型大多为线性,因此用于预测的特征量一般使用电价数据本身,如文献[1]利用小波分析法聚焦电价信号中的无序特征,降低因为非线性因素带来的误差。随着计算机性能的提升,机器学习的方法得到了大量应用,也开始尝试进行多特征输入,如文献[2-5]尝试使用基于神经网络的结构方法进行预测,但也仅局限于关键时间点的价格作为特征输入。随着模型的复杂度提升,文献[6-7]使用混合预测模型,开始加入与电价相关性较高的特征为输入。可以发现,当模型复杂度提升时,需要选择更多合适的特征量提取有效信息才能提升复杂模型的效果,而目前电价预测工作侧重于模型结构和预测算法的研究,对输入特征的研究较少。

本文基于实时电价的形成机理,提出一种按实时电价各分量度量值提取特征的方法,并利用该特征群,选择适合电价预测特点的 Seq2Seq (sequence-to-sequence)-Attention 网络进行验证,数据取自美国 PJM (Pennsylvania-New Jersey-Maryland) 市场的公开数据,通过对仅采用电价和负荷特征进行预测的方式进行对比,准确性有较大提升,验证了该方法的可行性。

1 实时电价特征提取

实时电价理论由 F. C. Schweppe 教授提出^[8],按实时电价的物理和经济意义,主要将其分为3个部分:边际燃料和维护分量、发电生产边际价值分量、网络运行边际价值分量。

1.1 边际燃料和维护分量 $\lambda(t)$ 参数的确定

$\lambda(t)$ 表达式为

$$\lambda(t) = \gamma_F(t) + \gamma_M(t) = \frac{\partial G_{FM}[g(t)]}{\partial d(t)} \quad (1)$$

式中: $\gamma_F(t)$ 为发电边际燃料成本; $\gamma_M(t)$ 为发电边际维护成本;

$d(t)$ 为时刻 $t(h)$ 的系统总需求;

$g(t)$ 为 $t(h)$ 全系统等值发电机的发电量;

$G_{FM}[g(t)]$ 为全系统等值发电机的燃料和维护成本。

由式(1)可知,实时市场价格受系统边际发电量和用电量的影响,忽略网损时,发电量与用电量是

相等的。当系统总发电量波动时,边际机组的成本差异将导致该分量的波动;当系统总发电量趋于稳定时,因调用发电机组的机组类型差异带来的燃料和维护成本差异也将导致该分量的波动。因此该分量所代表的度量应该是评判系统总发电量,以及机组类型的参数。

1.2 发电生产边际价值分量 $\gamma(t)$ 特征参数的确定

$\gamma(t)$ 分量与 $\lambda(t)$ 分量的差异仅在于发电供电质量分量 $\gamma_{QS}(t)$,发电供电质量的定义是为使用户减少用电量,直至发电量降低到基于发电可用容量和运行备用要求的临界发电容量所产生成本的值。其与用户需削减的负荷量有关。在实际计算 $\gamma_{QS}(t)$ 的值时,缺供电能价值法在反映每小时发电供电质量的形成原因是依托于物理参数且概念最为清晰的,宜选择该计算方法。其表达式为

$$\gamma_{QS}(t) = \frac{\partial G_{QS}[g(t)]}{g(t)} \quad (2)$$

式中 $G_{QS}[g(t)]$ 为 $t(h)$ 的发电供电质量成本。

由式(2)可见发电生产边际价值分量与发电量有密切联系,但由其定义可知,真正对其产生影响的因素是临界发电容量(电量),该分量的度量主要应反映发电量的边际信息价值,电力系统中的需求响应与调频与该分量密切相关。

1.3 网络运行边际价值分量特征参数的确定

网络运行边际价值分量包括网络损耗和网络供电质量两部分。

1.3.1 网络损耗分量 $\eta_{L,k}(t)$

网络损耗分量 $\eta_{L,k}(t)$ 与网络的潮流相关,用户用的电量与其所处位置的不同,将影响该分量的值。该分量的度量应能反映出网络在运行中的损耗情况。其表达式为

$$\eta_{L,k}(t) = [\lambda(t) + \gamma_{QS}(t)] \sum_{i=1}^N R_i Z_i^2(t) \frac{\partial Z_i(t)}{\partial d_k(t)} \quad (3)$$

式中: $\eta_{L,k}(t)$ 为第 k 个用户的在 t 时刻的网络损耗;

$Z_i(t)$ 为流经线路 i 的电能数量;

R_i 为取决于线路电阻的常数。

由于网络结构在短期内可以认为是基本不变的,由式(3)可知,该分量主要与系统用电量、各线路损耗相关,其度量是线路分布结构引起的损耗成本。由于网络参数和潮流信息的数据量大、维度多且不易获取,其对实时电价的影响也相对较小,如全部考虑将影响模型计算性能、增加模型复杂度,可考虑用系统高压线路损耗近似代替。

1.3.2 网络供电质量分量 $\eta_{QS,t}(t)$

网络供电质量分量 $\eta_{QS,t}(t)$ 是当输送电量即将达到网络的容量极限时,将大幅增加的一个量,用于限制用户对网络的过度使用,该分量应对网络容量的使用情况进行度量,并应对网络容量接近极限时有一定的敏感性。采用网络投资年化成本法计算时,其表达式为

$$\eta_{QS}(t) = \frac{2A_{QS,\eta} [d(t) - d_{crit,\eta}(t)]}{8760 [d(t) - d_{crit,\eta}(t)] prob [d(t) > d_{crit,\eta}(t)]} \quad (4)$$

式中: $A_{QS,\eta}$ 为根据最优网络扩容计划每年新增 1 kW 网络容量所需年度投资;

$d_{crit,\eta}$ 为受网络容量限制的临界需求电量。

对式(4)分析可知,用电需求超临界用电量的值和概率将决定 $\eta_{QS}(t)$ 值,考虑到年化投资对每小时的分摊在以小时为颗粒度的实时电价中难以体现其波动特征,而用电量超限在区域内的物理影响为产生输电阻塞,因此可以考虑输电阻塞费用进行替代,由于阻塞费用并不是博弈的结果,而是根据节点电价计算规则和网络阻塞情况计算得出的值,可以在一定程度上反映网络容量使用情况。

实时电价的相关分量及其对应的特征参数汇总于表 1。

表 1 输入特征参数

Table 1 Input characteristic parameter

序号	代表分量	特征名称	单位
1		系统总用电量	MW·h
2		核电发电量	MWh
3		气电发电量	MW·h
4	边际燃料和维护分量	煤电发电量	MW·h
5		风电发电量	MW·h
6		氢电发电量	MW·h
7		经济调度发电容量	MW
8		RegA 有效调频容量	MW
9	发电生产边际价值分量	RegD 有效调频容量	MW
10		系统总容量利用率	%
11		高压线路损失电量	MW·h
12	网络运行边际价值分量	输电阻塞价格	美元/(MW·h)
13		计量负荷量	MW·h

2 Seq2Seq-Attention 预测模型

Seq2Seq 用于处理序列到序列的问题,是一种 Encoder-Decoder 结构的网络^[9],使用 LSTM (long short-term memory) 作为其基本单元^[10],其首先在机器翻译领域取得了巨大成功,近年也在电力领域有诸多应用,如电力负荷预测^[11]和非侵入式负荷分解^[12]。

Seq2Seq 结构的特点是可以解决输入序列与输出序列长度不一致的问题,是基于循环神经网络 (recurrent neural network, RNN) 的改进,由编码层 (encoder)、语义向量 C 、解码层 (decoder) 组合而成,编码层与普通 RNN 网络并无区别,而解码层的输出关系变为

$$s_t = f(y_{t-1}, s_{t-1}, C); \quad (5)$$

$$y_t = g(y_{t-1}, s_t, C). \quad (6)$$

式(5)(6)中: s_t 为解码层 t 时刻的隐藏状态;

y_t 为解码层 t 时刻的输出值。

由式(5)(6)可知,Seq2Seq 网络的缺点在于其输入序列的信息全部压缩在最后的语义向量上,一旦输入序列过长,有效信息被分配的权重一起降低,导致信息量被压缩。通过引入 Attention 机制,可以解决长序列中信息压缩的问题^[13],与 Seq2Seq 网络相结合后的结构如图 1 所示。

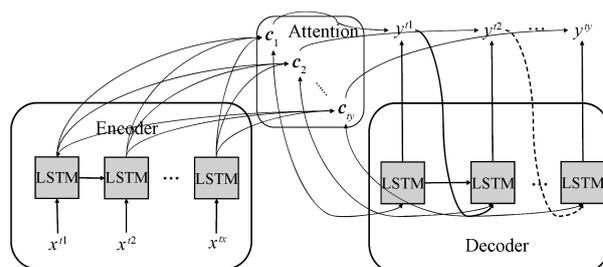


图 1 Seq2Seq-Attention 网络结构

Fig.1 Seq2Seq-Attention network structure

Seq2Seq-Attention 原理是将语义向量推广至每个时间步上,使每个时间步都拥有自己独特的语义向量。通过这个语义向量,解码层各时间步可以选择自己最关注的编码层序列内容,由于每个时间步的语义向量都独立出来,故不存在信息压缩问题。新语义向量计算方式如下:

$$c_i = \sum_{j=1}^{t_n} \alpha_{ij} h_j; \quad (7)$$

$$\alpha_{ij} = \frac{\exp(e_{ij})}{\sum_{k=1}^{t_n} \exp(e_{ik})}; \quad (8)$$

$$e_{ij} = V \times \tanh(W \times h_j + U \times s_{t-1} + b). \quad (9)$$

式(7)~(9)中: c_i 为 Attention 机制下各时间步的语义向量;

α_{ij} 为隐藏层的权重系数;

h_j 为编码层在相应时刻的隐藏状态;

e_{ij} 为输出序列隐藏层 i 对输入序列隐藏层 j 的相关系数;

i 取值为 $1, 2, \dots, t_s$;

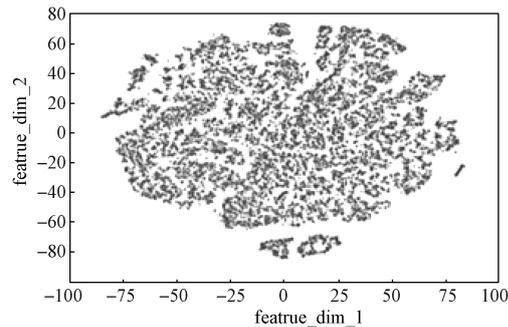
V 、 W 、 U 与 b 为模型待训练参数； s 为解码层隐藏状态。

3 算例与结果分析

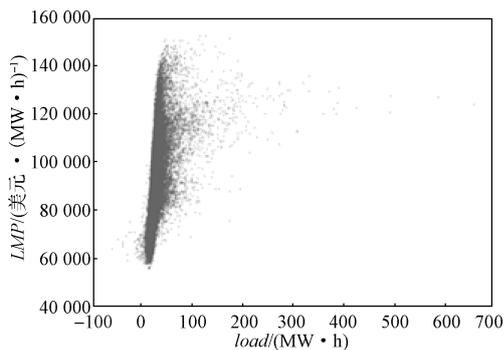
3.1 数据准备与特征分析

本文采用美国 PJM 电力市场的公开数据作为数据集，以世界标准时作为时间标签选取 2016 年 1 月 1 日 5 时至 2018 年 12 月 31 日 5 时的数据，即美国时间下的 2016 年至 2018 年共 3 a 的数据。以时间长度为标准，将数据集的 80.0%、19.5%、0.5% 3 部分，分别划为训练集、测试集、验证集。使用表 1 内的特征数据对 24 h 节点边际电价 (locational marginal prices, LMP) 进行预测。

在输入数据方面，由于输入特征量较多，为便于分析，使用流形学习中的 t-SNE 算法找出特征在高维空间的低维流形^[14]，求出相应的嵌入映射，如图 2 所示。



a) 使用全部特征降维所得输入数据



b) 仅使用负荷与 LMP 特征作为输入数据

图 2 实时电价特征与其它特征对比

Fig. 2 Comparison of real-time electricity price features with other features

由图 2 的二维平面 (图 2a) 中可见，其总分布形状围绕中心点呈椭圆形广泛分布，类与类之间的间隙较为明显，说明其所含有效信息量较大，是较好的神经网络输入数据。对仅使用负荷和 LMP 电价数据作为输入特征 (图 2b) 进行分析可知，虽然其大致呈正相关的线性关系，但噪点分布具有明显的异方差

性，由于实时电价的形成原因十分复杂，同时涉及经济规律与物理规律，较少的输入数据特征所得分析结果也将不具备可解释性。

3.2 评价指标

在回归类问题中，评价回归模型效果的评价指标一般为均方误差。而平均绝对百分比误差可以较为直观地了解预测值与真实值之间的差距，本文同时使用这两项指标作为模型的评价指标。计算公式如下：

平均绝对百分比误差 (mean absolute percent error, MAPE) 为

$$MAPE = \frac{1}{T_0 - T_1} \sum_{t=T_0}^{T_1} \frac{\text{abs}(\tilde{y}_t - y_t)}{y_t} \times 100\%。 \quad (10)$$

均方误差 (mean squared error, MSE) 为

$$MSE = \frac{1}{T_0 - T_1} \sum_{t=T_0}^{T_1} (\tilde{y}_t - y_t)^2。 \quad (11)$$

式 (10) (11) 中： T 为预测时间区间；

\tilde{y}_t 为 t 时刻的预测值；

y_t 为 t 时刻的真实值。

3.3 Seq2Seq-Attention 网络电价预测步骤

利用 Seq2Seq-Attention 网络进行电价预测，其求解步骤如下：

1) 对输入特征数据进行编码。将用于预测的输入特征传入编码层。经过 LSTM 计算后得到编码层隐藏状态。输入特征的信息被压缩在隐藏状态内。

2) 解码。将编码层隐藏状态与目标电价信息传入解码层，经 LSTM 计算后得到解码层隐藏状态。输入特征与电价通过解码层在此形成了联系。

3) 计算语义矩阵。由于每个时刻的隐藏状态不同，Attention 模块将编码层隐藏状态与解码层隐藏状态按式 (9) 求得其相关系数，并据此求出每一时刻的语义向量 c_t ，得到语义矩阵 C 。建立特征与目标电价之间的联系权重。

4) 求解预测电价。通过最终的激活函数，将语义矩阵 C 与解码层隐藏状态联系起来，求解所需的预测电价。

5) 反向传播与迭代。利用损失函数计算预测电价与目标电价的误差，并通过一定的学习率反向传播不断迭代，直至达到终止条件。

在此过程中，输入特征被不断编码解码，信息以隐藏状态的方式在网络中流动，依靠网络结构与其相应的神经元节点参数被记忆保存，最终由激活函数输出预测结果。

3.4 预测结果

本文预测模型首先在训练集上进行迭代，训练完

毕后使用测试集进行预测效果测试, 当通过调参取得理想测试效果后再使用验证集进行模型验证, 取验证集的验证结果作为模型预测效果。其中, 编码层和解码层都使用两层 LSTM 结构, 隐藏节点数分别为 256 和 128, 通过注意力机制进行连接, 损失函数采用 Log-Cosh 损失函数。输入序列的长度为 7 d, 目标序列长度为 1 d, 即用 168 个时间点的数据对接下来 24 个时间点的数据进行预测。为保证模型的计算效率与适应性, 模型内还引入了正则化、学习率衰减、Mini-batch 等方法。考虑到需对基于实时电价特征输入与仅使用历史负荷和节点边际电价作为特征输入进行对照实验, 两者使用同样的网络结构。且为避免在一次预测中可能产生的误差影响对比情况, 本文在验证集中取最后一周的数据做为在该周期上的平均表现对照。预测结果如图 3 所示。

由图 3 可以看出, 仅使用负荷和电价特征作为输入时, 模型虽对电价的变化趋势捕捉较好, 但拟合度较差, 不能准确捕捉到电价变化的细节, 且预测结果较真实值整体偏高, 原因可能是电价数据集整体均值为 30.891 美元/(MW·h), 验证数据整体在均值以下所导致。在采用基于实时电价特征的输入时, 模型对电价变化趋势的捕捉较为准确, 较仅使用负

荷和电价特征作为输入时提高了约 5%, 说明使用大量实时电价形成机理的特征进行输入时, 一些在负荷和电价数据本身无法反映的变化规律被挖掘出来, 但其在电价突变的时间点的预测效果仍不太理想。例如 12 月 26 日 12:00PM 附近电价突升的时间点两者都没有很好地预测到, 说明模型对异常信息检测的能力有限, 抑或是本文选择的输入特征与最终形成电价之间仍存在时滞, 当电价可能发生突变时, 本文所选的特征信息并不能被及时地反映出来, 导致模型未能预测到这一现象。

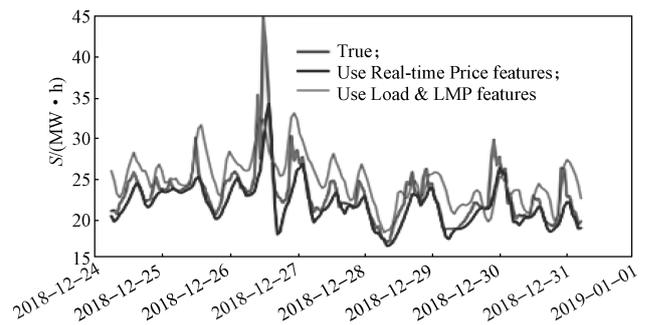


图3 电价预测曲线

Fig.3 Curves of price forecasting

不同评价特征预测结果如表 2 所示。

表 2 不同输入特征预测结果

Table 2 Prediction results of different input characteristics

预测时间段	实时电价特征输入		仅负荷与电价特征输入	
	MAPE/%	MSE	MAPE/%	MSE
2018-12-24 6:00 AM—2018-12-25 5:00 AM	3.92	1.37	8.58	5.22
2018-12-25 6:00 AM—2018-12-26 5:00 AM	4.35	2.45	10.25	9.81
2018-12-26 6:00 AM—2018-12-27 5:00 AM	9.53	22.15	15.44	24.57
2018-12-27 6:00 AM—2018-12-28 5:00 AM	4.21	1.45	11.73	7.87
2018-12-28 6:00 AM—2018-12-29 5:00 AM	5.41	2.77	9.38	5.82
2018-12-29 6:00 AM—2018-12-30 5:00 AM	4.87	3.65	9.49	7.71
2018-12-30 6:00 AM—2018-12-31 5:00 AM	4.93	3.20	11.30	8.30

从表 2 可以看出, 在使用实时电价特征输入时, 每一天的预测误差均小于仅使用负荷与电价特征输入所得误差。两者虽然在电价突变情况的 2018 年 12 月 26 日数据集上表现较为接近, 但在其它时段采用实时电价特征作为输入数据时误差明显降低, 验证了该方法的可行性。

4 结语

本文基于实时电价理论, 对实时电价形成原因进行深入分析, 将形成电价的各分量分别选取一定的特征参数作为输入数据, 并根据电价预测的特点, 建立了 Seq2Seq-Attention 网络进行预测, 通过与仅

使用历史负荷和电价数据进行预测的结果进行对比, 证明了在使用 Seq2Seq-Attention 网络模型时, 基于实时电价特征的多特征参数输入能更好地预测电价的变化趋势, 有更高的准确性。

未来将考虑对实时电价的特征进行深入分析, 寻找对电价变化, 特别是电价突变时, 具有较好跟踪效果的特征, 以提升对电价突变时的预测效果。

参考文献:

- [1] 周明, 聂艳丽, 李庚银, 等. 基于小波分析的短期电价 ARIMA 预测方法 [J]. 电网技术, 2005, 29(9): 50-55.

- ZHOU Ming, NIE Yanli, LI Gengyin, et al. Wavelet Analysis Based Arima Hourly Electricity Prices Forecasting Approach[J]. Power System Technology, 2005, 29(9): 50-55.
- [2] MANDAL P, SENJYU T, URASAKI N, et al. Price Forecasting for Day-Ahead Electricity Market Using Recursive Neural Network[C]//2007 IEEE Power Engineering Society General Meeting. Tampa: IEEE, 2007: DOI: 10.1109/PES.2007.385970.
- [3] ALANIS A Y. Electricity Prices Forecasting Using Artificial Neural Networks[J]. IEEE Latin America Transactions, 2018, 16(1): 105-111.
- [4] ANBAZHAGAN S, KUMARAPPAN N. Day-Ahead Deregulated Electricity Market Price Forecasting Using Recurrent Neural Network[J]. IEEE Systems Journal, 2013, 7(4): 866-872.
- [5] CHEN X, DONG Z Y, MENG K, et al. Electricity Price Forecasting with Extreme Learning Machine and Bootstrapping[J]. IEEE Transactions on Power Systems, 2012, 27(4): 2055-2062.
- [6] ALAMANIOTIS M, BARGIOTAS D, BOURBAKIS N G, et al. Genetic Optimal Regression of Relevance Vector Machines for Electricity Pricing Signal Forecasting in Smart Grids[J]. IEEE Transactions on Smart Grid, 2015, 6(6): 2997-3005.
- [7] 张金良. 电力市场环境下的短期电价混合预测模型研究 [D]. 北京: 华北电力大学, 2011.
ZHANG Jinliang. Research on Hybrid Forecasting Model of Short Term Electricity Price in Electricity Market Environment[D]. Beijing: North China Electric Power University, 2011.
- [8] SCHWEPPE F C, CARAMANIS M C, TABORS R D, et al. 电力现货定价原理 [M]. 朱洽中, 谢开, 译. 北京: 中国电力出版社, 2010: 26-31.
- SCHWEPPE F C, CARAMANIS M C, TABORS R D, et al. Principle of Spot Pricing of Electric Power[M]. ZHU Zhizhong, XIE Kai, Translated. Beijing: China Electric Power Press, 2010: 26-31.
- [9] CHO K, VAN MERRIENBOER B, GULCEHRE C, et al. Learning Phrase Representations Using RNN Encoder-Decoder for Statistical Machine Translation[EB/OL]. [2019-07-23]. <https://arxiv.org/abs/1406.1078>.
- [10] SUTSKEVER I, VINYALS O, LE Q V. Sequence to Sequence Learning with Neural Networks[EB/OL]. [2019-07-23]. <https://arxiv.org/abs/1409.3215>.
- [11] 彭文, 王金睿, 尹山青. 电力市场中基于 Attention-LSTM 的短期负荷预测模型 [J]. 电网技术, 2019, 43(5): 1745-1751.
PENG Wen, WANG Jinrui, YIN Shanqing. Short-Term Load Forecasting Model Based on Attention-LSTM in Electricity Market[J]. Power System Technology, 2019, 43(5): 1745-1751.
- [12] 王轲, 钟海旺, 余南鹏, 等. 基于 seq2seq 和 Attention 机制的居民用户非侵入式负荷分解 [J]. 中国电机工程学报, 2019, 39(1): 75-83, 322.
WANG Ke, ZHONG Haiwang, YU Nanpeng, et al. Nonintrusive Load Monitoring Based on Sequence-to-Sequence Model with Attention Mechanism[J]. Proceedings of the CSEE, 2019, 39(1): 75-83, 322.
- [13] BAHDANAU D, CHO K, BENGIO Y. Neural Machine Translation by Jointly Learning to Align and Translate[EB/OL]. [2019-07-23]. <https://arxiv.org/abs/1409.0473>.
- [14] MAATEN L V D, HINTON G. Visualizing Data Using t-SNE[J]. Journal of Machine Learning Research, 2008, 9: 2579-2625.

(责任编辑: 申剑)