

DOI: 10.19783/j.cnki.pspc.201483

基于 DAE-LSTM 神经网络的配电网日线损率预测

周王峰¹, 李勇¹, 郭钊秀¹, 乔学博¹, 梅玉杰¹, 邓威²

(1. 湖南大学电气与信息工程学院, 湖南 长沙 410082; 2. 国网湖南省电力有限公司
电力科学研究院, 湖南 长沙 410007)

摘要: 针对配电网线损精益化管理的需求, 为准确把握配电线路线损率短期变化趋势, 提出一种基于降噪自编码器(DAE)和长短期记忆网络(LSTM)相结合的配电网日线损率预测模型。首先建立灰色综合关联度分析指标, 挖掘日线损率影响因素近期量与其去年同期量间的相关性, 选择去年同期量作为模型的输入变量辅助预测。然后以无监督的方式构建 DAE 模型对输入序列进行特征编码与重构, 实现输入序列的特征提取与降维。最后将编码后的序列输入 LSTM 神经网络, 经训练拟合得到日线损率预测模型。采用湖南某地市多条配电线路实测数据进行实例分析, 结果表明该模型日线损率预测准确性较高, 运算速度适中, 具有一定的实际工程应用价值。

关键词: 配电网; 线损率; 降噪自编码器; 长短期记忆网络; 预测

Daily line loss rate forecasting of a distribution network based on DAE-LSTM

ZHOU Wangfeng¹, LI Yong¹, GUO Yixiu¹, QIAO Xuebo¹, MEI Yujie¹, DENG Wei²

(1. School of Electrical Engineering and Information, Hunan University, Changsha 410082, China;
2. State Grid Hunan Electric Power Co., Ltd. Research Institute, Changsha 410007, China)

Abstract: In order to determine the short-term change trend of distribution line loss rate and meet the need of line loss lean management, this paper proposes a distribution daily line loss rate forecasting model based on a combination of Denoising Auto-Encoder (DAE) and Long Short-Term Memory (LSTM) network. First, this paper establishes a grey comprehensive correlation indicator to analyze the correlation between the recent sequences of daily line loss rate influencing factors and the same period in the previous year. The influencing factors of the previous year are added to the model input to assist prediction. Then, to realize the feature extraction and dimension reduction of input sequences, the DAE is constructed to encode and reconstruct the input in an unsupervised way. Finally, the coded sequences are input into the LSTM and the model is obtained by training. A case analysis is carried out using the data of multiple distribution lines in a city of Hunan. The results show that the proposed model has superior accuracy and moderate calculating speed. This has a certain engineering application value.

This work is supported by the International Science and Technology Cooperation Program of China (No. 2018YFE0125300), the National Nature Science Foundation of China (No. 52061130217), the Innovative Construction Program of Hunan Province of China (No. 2019RS1016) and the Excellent Innovation Youth Program of Changsha of China (No. KQ1905008).

Key words: distribution network; line loss rate; denoising autoencoder; long short-term memory network; prediction

0 引言

线损率是电力线路损耗电量与供电量的比值,

基金项目: 国家重点研发计划政府间国际科技创新合作重点项目资助(2018YFE0125300); 国家自然科学基金项目资助(52061130217); 湖湘高层次人才聚集工程项目资助(2019RS1016); 长沙市杰出创新青年计划项目资助(KQ1905008)

由线路关口供电量与各出口售电量统计得出^[1]。作为电力公司一项重要的综合性技术经济指标, 线损率反映电网规划设计与运行管理水平^[2], 对配电网基层管理人员日常线路维护工作起直接指导作用。线损率的准确预测有助于管理人员把握线损率的发展趋势, 及时判断线路的异常线损状态, 对线路运行方式做出快速排查与调整。受设备采集异常、负荷转供、双电源用户供电切换等多方面影响, 存在

统计线损率与真实值不符的少数情况, 通过线损率预测值与实际值的对照可辅助校验配电网数据量测与网络拓扑连接关系的准确性与可靠性。

目前短期线损率预测的相关研究较为匮乏, 已有的线损率预测研究多基于长时间尺度, 以多种影响因素回归的方式预测线损率。例如文献[3]以变压器容量、馈线长度、接线方式、负载系数等变量作为输入量, 通过建立多灰色模型预测配电网线路年线损率。文献[4]以类似参数作为输入, 通过建立灰色模型与 BP 神经网络的组合预测模型进一步提升年线损率的预测精度。由于时间尺度不同, 上述研究的影响因素难以用于日线损率预测。

随着用电信息采集系统在配电网的覆盖, 海量量测数据为日线损率预测提供了可靠数据支撑^[5]。考虑到日线损率自身波动特性, 应考虑学习历史数据的动态时序规律, 采用时间序列预测模型而非单纯使用静态数据回归。基于自回归差分移动平均^[6]、支持向量机^[7-8](Support Vector Machine, SVM)等模型的时间序列预测方法已在短期负荷预测与风电功率预测等领域获得广泛应用^[9-11]。长短期记忆(Long Short-Term Memory, LSTM)网络^[12]作为一种特殊的递归神经网络^[13](Recurrent Neural Network, RNN)结构, 能够记忆输入序列的时序相关性, 在充分利用时序信息的同时避免了传统 RNN 训练时的梯度消失和梯度爆炸问题, 其结构特性与时间序列预测的需求十分契合。

时间序列预测的多维输入中往往包含冗余信息, 增加了预测模型的训练难度, 影响模型的学习效率与预测准确性^[14]。鉴于此, 有必要对维度广、数量大的输入数据进行降维处理, 减少预测模型的计算负担。主成分分析^[15-16](Principal Component Analysis, PCA)算法常被用于提取多维序列主要成分, 以减少冗余信息输入。PCA 为一种线性降维方式, 特征提取能力存在一定的局限性。近年来, 自编码器(Autoencoder, AE)因其强大的非线性特征表征能力在图像分类、异常检测等诸多领域已得到广泛应用^[17-18]。降噪自编码器^[19-20](Denosing Autoencoder, DAE)作为 AE 的改进模型, 通过噪声输入增强模型特征学习的鲁棒性, 在去除冗余信息的同时能最大化保留原始序列的有效信息, 因此能够为日线损率预测提供可靠的训练数据。

在上述背景的基础上, 本文提出一种基于降噪自编码器与长短期记忆神经网络相结合的配电网日线损率预测模型。采用湖南某地市 20 条 10 kV 配电线路实测数据, 验证本文所提日线损率预测模型的

准确性与实时性。首先选取近期日线损率、日售电量、日均气温时序数据作为预测模型输入, 同时以灰色综合关联度为指标分析这些影响因素的近期量与其去年同期量间的相关性, 将去年同期量一同输入模型辅助预测; 接着以无监督方式构建 DAE 模型对输入序列进行特征编码与重构, 实现输入序列的特征提取与降维; 最后将编码后的序列输入至 LSTM 神经网络中, 经训练拟合得到最终的日线损率预测模型。

1 日线损率预测输入因素分析

1.1 日线损率影响因素

为提升日线损率预测模型的准确性, 模型输入部分除了需要日线损率历史数据以外, 还需加入相关影响因素数据辅助预测。目前已有一些文献对线损率的主要影响因素展开了探讨。文献[21]量化评估了售电量与线损率波动间的影响关系, 认为售电量对线损率波动具有较大影响。文献[22]定量分析了气温升高对导线阻值的影响, 认为气温对线损率波动也具有明显影响。基于上述研究, 本文选取近期日售电量、日均气温时序数据作为日线损率主要影响因素, 加入至预测模型的输入变量。

1.2 去年同期数据辅助预测

除了采用近期历史数据, 本文还考虑使用去年同期数据增加预测模型输入信息。去年同期数据中隐含了变量的季节性波动规律, 能够辅助提升模型预测准确性。以当前时期数据为参照, 采用灰色关联分析算法评估变量当前时期数据与去年同期数据间的相关程度。经典灰色关联分析通过比较序列的几何相似程度判断序列相关性^[23], 在经典灰色关联分析的基础上, 又提出了灰色绝对关联分析和灰色相对关联分析两种评价方法^[24]。灰色绝对关联分析通过始点零化消除空间位置对曲线形状相似程度的干扰; 灰色相对关联分析更看重曲线各点动态变化趋势的相似性。结合两者各自优势, 将其加权平均后求得灰色综合关联度, 作为变量相关性强弱的最终判据, 其中两个变量之间的灰色关联度值越大, 则变量间的相关性越强, 灰色关联度值越小, 则相关性越弱。

对于样本数为 n 的待分析序列 G , 其当前时期序列与去年同期序列分别表示为 G_0 与 G_1 。

$$\begin{cases} G = (g_0, g_1, \dots, g_n) \\ G' = (g'_0, g'_1, \dots, g'_n) \end{cases} \quad (1)$$

求灰色绝对关联度所需的初始化像 G'_0 与 G'_1 。

$$\begin{cases} G'_0 = (g_0(1) - g_0(1), g_0(2) - g_0(1), \dots, g_0(n) - g_0(1)) \\ G'_1 = (g_1(1) - g_1(1), g_1(2) - g_1(1), \dots, g_1(n) - g_1(1)) \end{cases} \quad (2)$$

求灰色绝对关联度所需的初始化像 G''_0 与 G''_1 。

$$\begin{cases} G''_0 = (g_0(1)/g_0(1), g_0(2)/g_0(1), \dots, g_0(n)/g_0(1)) \\ G''_1 = (g_1(1)/g_1(1), g_1(2)/g_1(1), \dots, g_1(n)/g_1(1)) \end{cases} \quad (3)$$

$$\begin{cases} G''_0 = (g_0^0(1) - g_0^0(1), g_0^0(2) - g_0^0(1), \dots, g_0^0(n) - g_0^0(1)) \\ G''_1 = (g_1^0(1) - g_1^0(1), g_1^0(2) - g_1^0(1), \dots, g_1^0(n) - g_1^0(1)) \end{cases} \quad (4)$$

计算灰色绝对关联度的几何因子 s'_0 与 s'_1 。

$$\begin{cases} s'_0 = \sum_{k=2}^{n-1} g'_0(k) + \frac{1}{2} g'_0(n) \\ s'_1 = \sum_{k=2}^{n-1} g'_1(k) + \frac{1}{2} g'_1(n) \end{cases} \quad (5)$$

计算灰色相对关联度的几何因子 s''_0 与 s''_1 。

$$\begin{cases} s''_0 = \sum_{k=2}^{n-1} g''_0(k) + \frac{1}{2} g''_0(n) \\ s''_1 = \sum_{k=2}^{n-1} g''_1(k) + \frac{1}{2} g''_1(n) \end{cases} \quad (6)$$

得到去年同期序列与当前时期序列间的灰色绝对关联度与灰色相对关联度 γ_1 与 γ_2 。

$$\begin{cases} \gamma_1 = \frac{1 + |s'_0| + |s'_1|}{1 + |s'_0| + |s'_1| + |s'_1 - s'_0|} \\ \gamma_2 = \frac{1 + |s''_0| + |s''_1|}{1 + |s''_0| + |s''_1| + |s''_1 - s''_0|} \end{cases} \quad (7)$$

最终加权得到灰色综合关联度 γ_3 ，其中加权系数 α 通常取 0.5。

$$\gamma_3 = \alpha\gamma_1 + (1 - \alpha)\gamma_2 \quad (8)$$

以湖南某地市 20 条 10 kV 配电线路实测数据为例。其中，将 2019 年 7 至 10 月共 123 天的时序数据作为当前时期数据，针对日线损率、日售电量、日均气温的当前时期数据与其对应去年同期数据间的相关性开展研究，所用原始数据如图 1 所示。

日线损率影响因素当前时期数据与去年同期数据间的灰色关联分析结果如表 1 所示，其中日线损率、日售电量两项的灰色关联度为 20 条线路计算结果的平均值。从表 1 可知，日线损率、日均气温的当前数据与去年同期数据的综合灰色关联度分别为 0.802 与 0.824，表明两者当前时期数据与去年同期数据间具有极强相关性；日售电量当前时期数据与去年同期数据的综合灰色关联度达 0.736，仍属于强相关范围。由于线损率预测是针对未来时刻，实际

预测过程中通常采用近期历史数据，并且缺乏未来时刻的日均气温与售电量数据。由于未来时刻数据与其对应的去年同期数据具有强相关性，因此应该考虑将去年同期数据作为输入变量加至预测模型中，辅助日线损率预测。

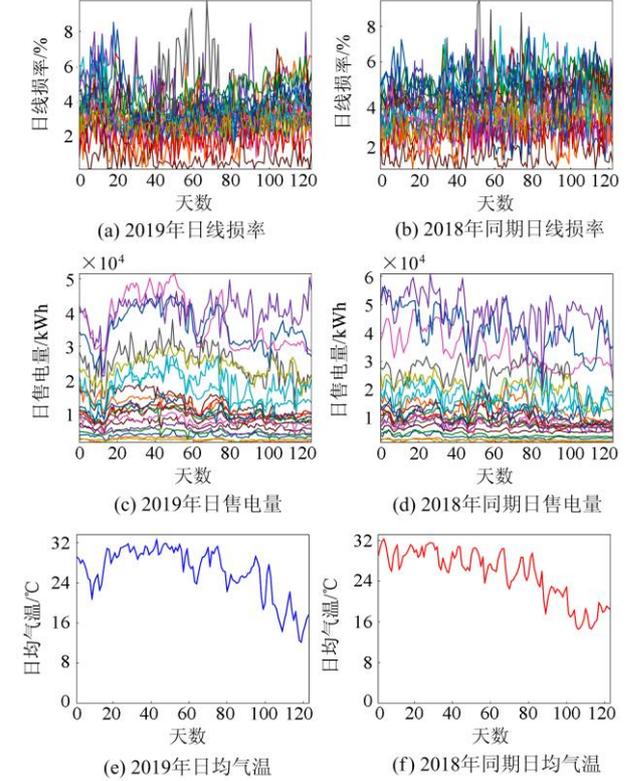


图 1 线路原始数据展示

Fig. 1 Visualization of original lines data

表 1 近期序列与去年同期序列相关性分析结果

Table 1 Correlation analysis results between the recent series and the same period last year

数据类型	日线损率	日售电量	日均气温
绝对灰色关联度	0.859	0.716	0.818
相对灰色关联度	0.745	0.757	0.829
综合灰色关联度	0.802	0.736	0.824

2 输入序列特征提取

2.1 自编码器原理

自编码器以自身输入为目标进行无监督学习，其主要结构如图 2 所示，共由输入层、隐含层、输出层三层神经元组成，输入层与输出层神经元个数相同，结构上可分为编码器与解码器两部分。

模型输入信息 x 经输入层后被编码为隐含层信息 h ，隐含层信息 h 经解码又重新被映射为输出信息 y 。整体过程可以描述为

$$\mathbf{h} = \eta(\mathbf{W}_1 \mathbf{x} + \mathbf{b}_1) \quad (9)$$

$$\mathbf{y} = \eta(\mathbf{W}_2 \mathbf{h} + \mathbf{b}_2) \quad (10)$$

式中: \mathbf{W}_1 与 \mathbf{b}_1 、 \mathbf{W}_2 与 \mathbf{b}_2 分别为编码器与解码器的权重参数与偏置参数矩阵; η 为神经元间的激活函数, 一般为 Selu 等非线性函数。通常设置隐含层神经元数量小于其他两层, 此时编码器起降维作用, 隐含层信息即为提取到的输入信息低维特征。

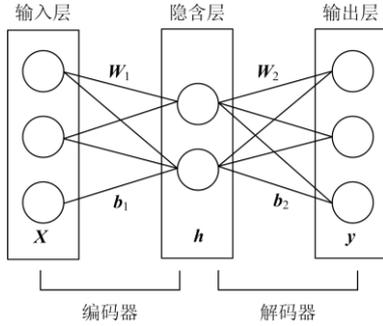


图2 自编码器结构

Fig. 2 Structure of auto-encoder

自编码器在迭代中寻求输入信息 \mathbf{x} 与输出信息误差 \mathbf{y} 的最小化, 通过最小化损失函数求解编码器与解码器参数并更新, 其损失函数可以表征为式(11)。

$$J(\mathbf{W}, \mathbf{b}) = \sum \|\mathbf{y}, \mathbf{x}\|^2 \quad (11)$$

2.2 降噪自编码器

降噪自编码器从传统自编码器的基础上发展而来。为了使自编码器能够学习到更具鲁棒性的隐含层特征, 通过人为地对原始输入信息 \mathbf{z} 进行损坏, 得到含噪信息 \mathbf{z} , 将含噪信息 \mathbf{z} 作为自编码器的输入, 而以原始输入信号 \mathbf{x} 作为输出层的学习目标, 其结构如图3所示。

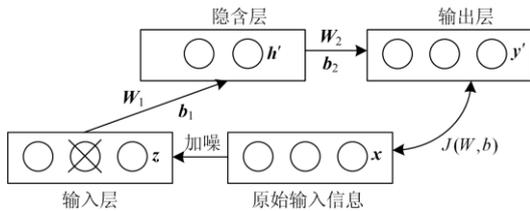


图3 降噪自编码器结构

Fig. 3 Structure of denoising autoencoder

此时隐含层信息 \mathbf{h}' 与输出层信息 \mathbf{y}' 更新为

$$\mathbf{h}' = \eta(\mathbf{W}_1 \mathbf{z} + \mathbf{b}_1) \quad (12)$$

$$\mathbf{y}' = \eta(\mathbf{W}_2 \mathbf{h}' + \mathbf{b}_2) \quad (13)$$

降噪自编码器的参数迭代过程同样以输出信息 \mathbf{y}' 与原始输入信息 \mathbf{x} 的误差最小化为目标, 其损失函数计算过程与式(11)相同。降噪自编码器被要求从含噪信息中重构原始信息, 这需要编码部分能够

学习输入信息的本质特征, 从而实现输入降噪。

3 基于 DAE-LSTM 的日线损率预测

3.1 长短期记忆网络

长短期记忆网络能够记忆当前时刻信息并在下一时刻有选择地传递或遗忘网络的隐藏状态, 具有时间序列记忆能力, 因而被广泛运用于与序列信息处理密切相关的各类领域, 其单个神经元的结构如图4所示。

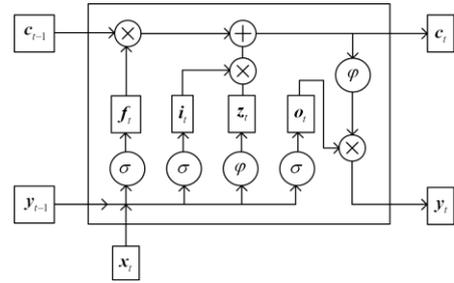


图4 LSTM 神经元结构

Fig. 4 Structure of an LSTM neuron

LSTM 神经元由 1 个记忆单元与 3 个控制门构成, 神经元每一时刻输出量由当前时刻输入量 x_t 、上一时刻输出量 y_{t-1} 和记忆单元存储信息 c_{t-1} 共同决定。这些信息经遗忘门 f_t , 输入门 i_t 运算后得到新的记忆单元存储信息 c_t , 由记忆单元存储信息 c_t 与输出门状态 o_t 决定神经元输出量 y_t 。具体的计算过程如式(14)一式(19)所示。

$$f_t = \sigma(W_{f_y} y_{t-1} + W_{f_x} x_t + W_{f_c} c_{t-1}) \quad (14)$$

$$i_t = \sigma(W_{i_y} y_{t-1} + W_{i_x} x_t + W_{i_c} c_{t-1}) \quad (15)$$

$$z_t = \tanh(W_{z_y} y_{t-1} + W_{z_x} x_t + W_{z_c} c_{t-1}) \quad (16)$$

$$c_t = c_{t-1} f_t + i_t z_t \quad (17)$$

$$o_t = \sigma(W_{o_y} y_{t-1} + W_{o_x} x_t + W_{o_c} c_{t-1}) \quad (18)$$

$$y_t = \phi(c_t) o_t \quad (19)$$

式中: z_t 为记忆单元更新需要的中间信息; σ 与 ϕ 分别表示 Sigmoid 与 Tanh 激活函数; W_{f_y} 、 W_{f_x} 、 W_{f_c} 、 W_{i_y} 、 W_{i_x} 、 W_{i_c} 、 W_{z_y} 、 W_{z_x} 、 W_{z_c} 、 W_{o_y} 、 W_{o_x} 、 W_{o_c} 为网络权重参数矩阵; b_f 、 b_i 、 b_z 、 b_o 为网络偏置参数矩阵。

3.2 DAE-LSTM 日线损率预测模型

针对预测输入量中既含有丰富时序信息同时可能包含一定冗余信息的特点, 本文提出一种基于降噪自编码器与长短期记忆网络相结合(DAE-LSTM)的日线损率预测模型, 该模型整体框架如图5所示, 预测模型构建步骤具体如下。

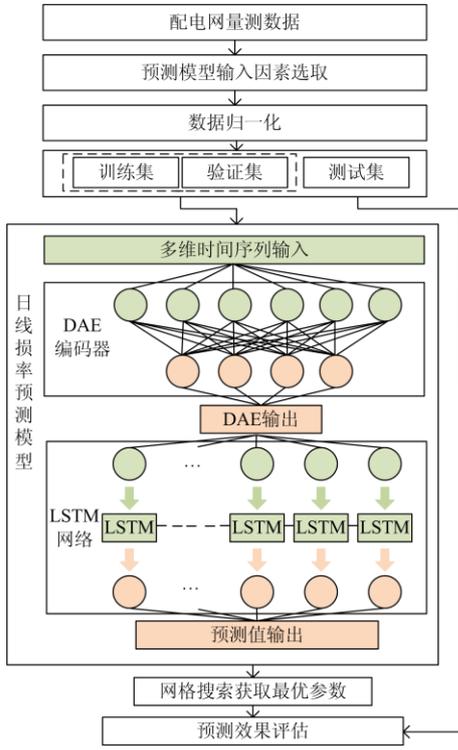


图 5 日线损率预测框架

Fig. 5 Daily line loss rate forecasting framework

步骤 1: 选取日线损率、日售电量、日均气温的近期及去年同期时间序列作为日线损率预测的原始数据,按式(20)对数据进行归一化处理,并且划分数据为训练集、验证集与测试集。

$$d_k^N = \frac{d_k - \min(Q)}{\max(Q) - \min(Q)} \quad (20)$$

式中: $D(i)$ 表示第 i 条序列的所有样本; d_k 表示第 i 条序列位置 k 处的数据; d_k^N 为该数据经归一化后的数值。

步骤 2: 构建降噪自编码器模型,设定编码维度,代入训练集数据训练得到编码器与解码器。通过比较解码器输出与降噪自编码原始输入验证模型特征提取的有效性。

步骤 3: 构建长短期记忆网络模型,设定模型参数范围及样本输入模型的时间窗长度。将训练集中多维时间序列依次输入至 DAE 解码器与 LSTM 网络中进行学习训练,每次训练后对模型在验证集上的表现进行评估,采用网格搜索^[25]方式获取模型最优参数,最终得到日线损率预测模型。

步骤 4: 输入测试集数据,构建评估指标对模型预测效果进行评估。为评估本文模型的预测效果,采取平均绝对百分误差(Mean Absolute Percentage

Error, MAPE)与均方根误差(Root Mean Squared Error, RMSE)这两种常规评价指标对日线损率预测结果进行误差分析。两种评价指标的计算方式分别如式(21)和式(22)所示。

$$\delta_m = \frac{1}{N} \sum_{i=1}^N \frac{|p'_i - p_i|}{p_i} \times 100\% \quad (21)$$

$$\delta_r = \sqrt{\frac{\sum_{i=1}^N (p'_i - p_i)^2}{N}} \quad (22)$$

式中: δ_m 与 δ_r 分别代表 MAPE 与 RMSE 误差值; N 为测试数据总长度; p'_i 与 p_i 分别为第 i 个数据样本对应的日线损率预测值与实际值。

4 实例分析

4.1 数据来源

本文采用在 1.2 节中所述的 20 条 10 kV 配电线路实测数据作为原始样本数据,包含日线损率序列、日售电量序列、日均气温时序数据。划分 2019 年 7 月 1 日至 10 月 31 日数据作为训练集,2019 年 11 月 1 日至 14 日数据作为测试集,每次从训练集中随机抽取 10% 的样本作为预测模型验证集。

4.2 DAE 特征提取结果

构建 DAE 模型对日线损率、日售电量、日均气温的当年数据及去年同期数据共 6 维序列进行降维与特征提取。DAE 模型的主要参数为隐层神经元个数即数据降维维度,这里以传统 PCA 算法的线性降维效果为参考依据。PCA 算法通过主成分贡献度反映降维信息的有效性,计算算例中 20 条线路的主成分贡献率并统计其平均值,结果如表 2 所示。在保留 4 维主成分时,PCA 模型能保留 92.96% 以上的原始信息。设置 DAE 模型降维维度为 4,设置 DAE 模型输入维度为 6,输出维度为 6,隐层层与输出层激活函数采用 Selu,优化算法采用 Adam 算法,损失函数为 MSE。模型输入随机叠加均值为 0 的高斯噪声,并限制噪声幅值不超过输入值的 10%。

表 2 模型输入序列的 PCA 分解结果

Table 2 PCA analysis results of model input

主成分	主成分贡献率/%	主成分累计贡献率/%
1	53.27	53.27
2	21.50	74.77
3	10.77	85.54
4	7.41	92.96
5	5.17	98.13
6	1.87	100.00

6 维输入序列经 DAE 编码后被压缩为 4 维特征序列, 再经 DAE 解码网络还原得到 6 维解码序列, 以 MAPE 为指标计算算例中 20 条 24 线路解码序列与原始输入序列间的相对误差的平均值, 验证 DAE 模型多维日线损率影响因素序列特征提取的有效性, MAPE 误差计算结果如表 3 所示。

表 3 DAE 特征序列信息损失程度分析

Table 3 Information loss degree analysis of feature sequences

数据类型	日线损率序列		日售电量序列		日均气温序列	
	近期	去年同期	近期	去年同期	近期	去年同期
	MAPE 误差/%	0.575	0.973	1.356	1.777	3.708

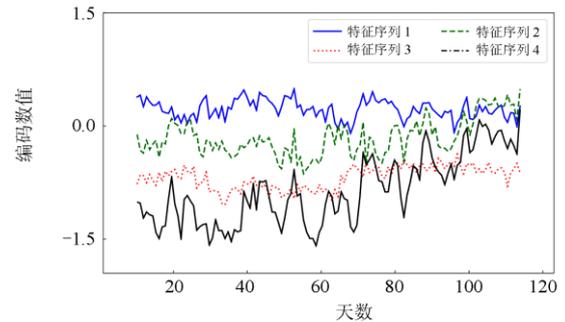
从 20 条线路的 DAE 特征序列信息损失分析结果可知, 6 条序列中日线损率近期与去年同期序列损失信息极少, 相对误差在 1% 以内; 日售电量解码信息与原始信息相对误差介于 1%~2%, 曲线基本贴合; 日均气温解码信息与原始信息相对误差介于 3%~4%, 出现局部信息损失, 但仍在可接受范围。上述结果表明 DAE 模型在提取原始序列特征, 剔除冗余信息的同时有效保留了原始信息, 为日线损率预测模型的输入提供可靠有效的低维样本。

由于算例包含的线路较多, 并且各线路的 DAE 解码还原精度基本相似(精度在 96%~99%之间), 这里以 20 条线路中的 1 条为例展示具体的编码与解码过程, 如图 6 所示。图 6(a)中为该线路原始 6 维影响因素输入序列经 DAE 编码器压缩后的 4 维特征序列, 特征序列中包含了原始序列的绝大部分信息, 同时去除了序列冗余信息, 作为 LSTM 神经网络的输入进行预测模型训练。图 6(b)中为 4 维特征序列经 DAE 解码器还原后的 6 维序列, 用以检验编码信息的有效性, 该线路经 DAE 编码再还原后的日线损率、日售电量、日均气温近期序列的 MAPE 误差依次为 0.123%、1.522%、4.104%, 对应同期序列的 MAPE 误差依次为 0.156%、1.779%、3.137%, 解码序列与原始序列波动基本一致, 绝大部分原始信息在编码后仍然得到保留。

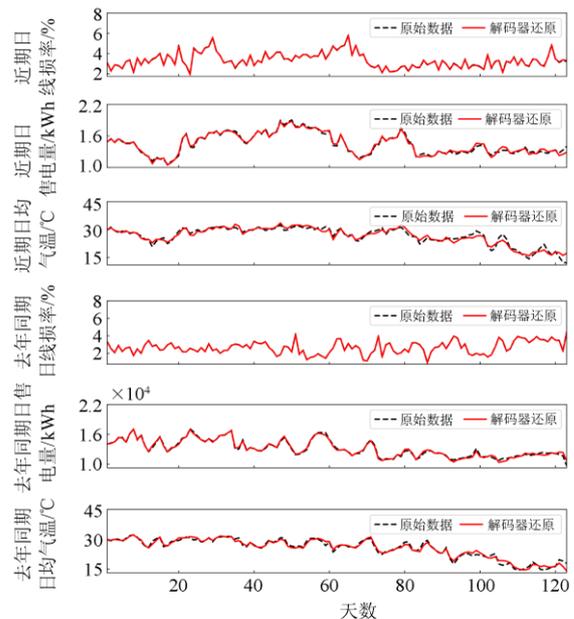
4.3 日线损率预测结果分析

为验证本文选取的日线损率影响因素及其去年同期数据在日线损率预测中的作用, 检验本文提出的 DAE-LSTM 模型对日线损率的有效性, 共设置了 6 组预测实验。其中, Model 1—Model 5 为 5 组对照预测实验, Model 6 采用本文提出的基于近期和同期历史数据的 DAE-LSTM 预测方法。实验使用输入数据及模型如表 4 所示。其中, 基于 LSTM 模型设置实验 Model 1—Model 3, 通过不同

的输入变量, 验证输入影响因素选择的有效性。在输入相同特征情况下, 设置实验 Model 3—Model 6, 对比分析不同降维方法和预测模型对日线损率预测结果的影响。



(a) DAE模型6维输入序列编码结果示例



(b) DAE模型编码序列还原结果示例

图 6 DAE 模型单线路编码、解码结果示例

Fig. 6 Examples coding and decoding results by DAE model

表 4 对比实验模型与数据设置

Table 4 Comparison of experimental models and data settings

模型名称	输入数据	预测模型
Model1	线损率(近期)	LSTM
Model2	线损率、售电量、气温(近期)	LSTM
Model3	线损率、售电量、气温(近期+去年同期)	LSTM
Model4	线损率、售电量、气温(近期+去年同期)	PCA-LSTM
Model5	线损率、售电量、气温(近期+去年同期)	DAE-SVM
Model6	线损率、售电量、气温(近期+去年同期)	DAE-LSTM

实验中每个 LSTM 网络设置为 3 层, 前两层激活函数为 Tanh, 最后一层输出层为 Selu, 损失函数

为均方误差 MSE, 在 LSTM 层后加入 Dropout 层^[26]防止模型过拟合, Dropout 系数设为 10%。LSTM 网络其余参数通过网格搜索确定, 范围如表 5 所示。设置每个 SVM 模型的参数搜索范围, 如表 6 所示。

表 5 LSTM 网络参数范围

Table 5 Parameter range of LSTM network

类型	输入时间窗	一层神经元	二层神经元	学习率
范围	[1-10]	[50,30,20]	[30,20,10]	[0.01,0.1,1]

表 6 SVM 参数范围

Table 6 Parameter range of SVM

类型	核函数	惩罚系数 C	核函数系数 Sigma
范围	[Linear, RBF]	[0.01,0.1,1,10,100]	[0.01,0.1,1,10,100]

通过 Model 1—Model 6 预测模型学习训练, 得到算例中 20 条配电线路在各模型下的日线损率预测值。统计 20 条线路的平均日线损率预测误差并记录各模型在 i5-4210M 处理器下的单核运算时间, 结果如表 7 所示。图 7 以预测结果中 6 条线路损率波动各异的配电线路为例, 直观展示各组预测模型的日线损率预测效果差异。

首先分析 Model 1—Model 3 的日线损率预测精度, 验证本文影响因素选取的有效性。由图 7 和表 7 的日线损率预测结果可知, 相较单纯采用近期日线

表 7 Model 1—Model 6 日线损率预测结果评估

Table 7 Evaluation of daily line loss rate prediction results of Model 1 to Model 6

预测模型	MAPE/%	RMSE	运算时长/s
Model1	7.523 2	0.316 6	1.057 124
Model2	6.515 5	0.286 3	1.394 353
Model3	5.984 7	0.268 1	2.349 835
Model4	5.176 9	0.238 6	1.525 377
Model5	4.879 6	0.219 3	1.975 561
Model6	4.332 4	0.199 1	1.712 963

损率的 Model 1, 加入近期日售电量与日均气温数据的 Model 2 在总体趋势上与实际日线损率更贴近, 预测精度高于 Model 1, 这表明了日售电量与日均气温两项影响因素作为预测模型输入的有效性。此外, 在加入去年同期影响因素后, Model 3 相较 Model 2 的 MAPE 误差值从 6.5155% 降至 5.9847%, RMSE 误差值从 0.286 3 降至 0.268 1, 表明去年同期影响因素的加入可进一步降低日线损率预测误差, 改善模型的预测精度。

分析 Model 4—Model 6 的日线损率预测精度, 检验本文所提 DAE-LSTM 模型的预测准确性。由表 7 可知, 相比于未加入输入降维处理的 Model3, Model 4—Model 6 的日线损率预测误差均有所减小, 表明冗余信息减少有助于增强模型学习能力, 提升预测效果与泛化能力。在 Model 4—Model 6 三组实验中, DAE-SVM 的预测误差稍优于 PCA-LSTM, 而本文所提 DAE-LSTM 的预测误差最小, MAPE 与 RMSE 分别为 4.3324% 与 0.199 1, 由图 7 可知, DAE-LSTM 的日线损率预测曲线与实际日线损率最为贴近, 拟合效果最佳。

对比分析本文模型的运算实时性。算例中各模型训练样本时间范围均为 2019 年 7 月至 10 月共 123 天, 而在影响因素输入特征上存在差异。6 组模型的总体运算时间如表 7 所示, 图 8 为 Model 1—Model 4、Model 6 5 组模型 LSTM 网络部分在训练中损失函数值随迭代数的变化过程。由表 7 及图 8 可知, Model 6 的 DAE 环节虽增加了模型的总体训练时间, 但同时 LSTM 网络的迭代次数得到减少, 且模型收敛时其损失函数值最低, 表明 DAE 环节加快了模型收敛, 提升了模型精度。相比无降维处理的 Model 3, Model 6 达到收敛时的迭代次数由 153 次降至 97 次, 总体运算时间较 Model 3 缩短了 0.637 s。综合六组模型, 本文所提 DAE-LSTM 模型具有训练收敛所需迭代次数少, 预测误差小与运算速度适中优势, 适用于预测精度与运算速度要求较高的工程场景。

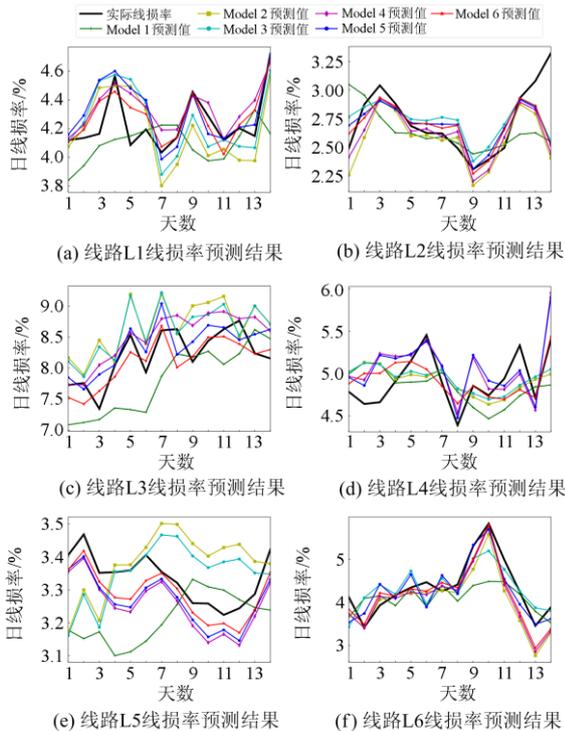


图 7 Model 1—Model 6 日线损率预测结果示例

Fig. 7 Example of daily line loss rate prediction results of Model 1 to Model 6

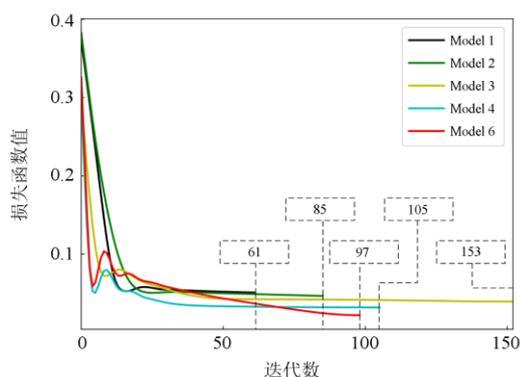


图 8 LSTM 神经网络迭代次数图

Fig. 8 Iterations of LSTM neural networks

5 结论

本文将日线损率预测相关影响因素的去年同期数据加入到预测模型中, 提出一种基于 DAE-LSTM 神经网络的配电网日线损率预测模型, 经实例分析, 得出以下结论:

1) 线损率预测相关影响因素的近期数据与去年同期数据之间具有较强相关性, 通过加入去年同期数据辅助日线损率预测, 有效减小了模型预测偏差, 提升了模型预测精度。

2) DAE 特征提取环节有效减少了模型输入数据中的冗余信息, 降低了输入维度。相较传统主成分分析方法, DAE 具有更强的非线性特征捕获能力, 对日线损率模型预测精度提升的作用更大。

本文所提出的日线损率预测模型能够有效学习原始输入变量中的多维时间序列, 算例中相较单纯使用近期日线损率与 LSTM 网络的线损率预测模型, 本文模型的 MAPE 误差值减少了 3.19%, RMSE 误差值减少了 0.656, 同时运算速度适中, 具有一定工程应用价值。

参考文献

- [1] 唐登平, 李俊, 孟展, 等. 统计线损数据准确性研究[J]. 电力系统保护与控制, 2018, 46(24): 33-39.
TANG Dengping, LI Jun, MENG Zhan, et al. Research on accuracy of statistical line losses[J]. Power System Protection and Control, 2018, 46(24): 33-39.
- [2] 岑炳成, 安海云, 周前, 等. 分压售电比例对线损率的影响分析[J]. 电力系统自动化, 2018, 42(11): 169-173.
CEN Bingcheng, AN Haiyun, ZHOU Qian, et al. Analysis on influence of electricity sales proportion on line loss rate at each voltage level[J]. Automation of Electric Power Systems, 2018, 42(11): 169-173.
- [3] 张勇军, 石辉, 翟伟芳, 等. 基于层次分析法-灰色综

合关联及多灰色模型组合建模的线损率预测[J]. 电网技术, 2011, 35(6): 71-76.

- ZHANG Yongjun, SHI Hui, ZHAI Weifang, et al. Line loss rate prediction based on combinatorial modeling by analytic hierarchy process-gray comprehensive relationship and multi grey models[J]. Power System Technology, 2011, 35(6): 71-76.
- [4] 张勤, 周步祥, 林楠, 等. 基于灰色模型与神经网络组合的线损率预测[J]. 电力系统及其自动化学报, 2013, 25(5): 162-166.
ZHANG Qin, ZHOU Buxiang, LIN Nan, et al. Line loss rate forecasting based on combination of grey model and neural network[J]. Proceedings of the CSU-EPSCA, 2013, 25(5): 162-166.
- [5] 邓威, 郭钊秀, 李勇, 等. 基于特征选择和 Stacking 集成学习的配电网网损预测[J]. 电力系统保护与控制, 2020, 48(15): 108-115.
DENG Wei, GUO Yixiu, LI Yong, et al. Power losses prediction based on feature selection and Stacking integrated learning[J]. Power System Protection and Control, 2020, 48(15): 108-115.
- [6] CARDOSO C A V, CRUZ G L. Forecasting natural gas consumption using ARIMA models and artificial neural networks[J]. IEEE Latin America Transactions, 2016, 14(5): 2233-2238.
- [7] LIU Qingzhen, SHEN Yuanbin, WU Lei, et al. A hybrid FCW-EMD and KF-BA-SVM based model for short-term load forecasting[J]. CSEE Journal of Power and Energy Systems, 2018, 4(2): 226-237.
- [8] 李应求, 安勃, 李恒通. 基于 NARX 及混沌支持向量机的短期风速预测[J]. 电力系统保护与控制, 2019, 47(23): 65-73.
LI Yingqiu, AN Bo, LI Hengtong. Short-term wind speed prediction based on NARX and chaos-support vector machine[J]. Power System Protection and Control, 2019, 47(23): 65-73.
- [9] CHEN Hao, ZHANG Jianzhong, TAO Yubo, et al. Asymmetric GARCH type models for asymmetric volatility characteristics analysis and wind power forecasting[J]. Protection and Control of Modern Power Systems, 2019, 4(4): 356-366. DOI: 10.1186/s41601-019-0146-0.
- [10] 陈勇, 李鹏, 张忠军, 等. 基于 PCA-GA-LSSVM 的输电线路覆冰负荷在线预测模型[J]. 电力系统保护与控制, 2019, 47(10): 110-119.
CHEN Yong, LI Peng, ZHANG Zhongjun, et al. Online prediction model for power transmission line icing load based on PCA-GA-LSSVM[J]. Power System Protection and Control, 2019, 47(10): 110-119.
- [11] 叶林, 刘鹏. 基于经验模态分解和支持向量机的短期

- 风电功率组合预测模型[J]. 中国电机工程学报, 2011, 31(31): 102-108.
- YE Lin, LIU Peng. Combined model based on EMD-SVM for short-term wind power prediction[J]. Proceedings of the CSEE, 2011, 31(31): 102-108.
- [12] KONG Weicong, DONG Zhaoyang, JIA Youwei, et al. Short-term residential load forecasting based on LSTM recurrent neural network[J]. IEEE Transactions on Smart Grid, 2019, 10(1): 841-851.
- [13] SHI Heng, XU Minghao, LI Ran. Deep learning for household load forecasting—a novel pooling deep RNN[J]. IEEE Transactions on Smart Grid, 2018, 9(5): 5271-5280.
- [14] 廖玲珑, 李培强, 唐捷, 等. 信息粒化和相似数据结合的短期风速预测[J]. 电力系统及其自动化学报, 2016, 28(4): 12-17.
- LIAO Linglong, LI Peiqiang, TANG Jie, et al. Short-term wind speed forecasting based on information granulation and similar data[J]. Proceedings of the CSU-EPSA, 2016, 28(4): 12-17.
- [15] 牛成林, 张昭宇, 孙亮, 等. 基于传递函数特征的主成分和神经网络的绕组变形识别技术[J]. 智慧电力, 2019, 47(10): 7-13.
- NIU Chenglin, ZHANG Zhaoyu, SUN Liang, et al. Identification technology of winding deformation based on principal components of transfer function characteristic and neural network[J]. Smart Power, 2019, 47(10): 7-13.
- [16] 吴瞻宇, 董明, 王健一, 等. 基于模糊关联规则挖掘的电力变压器故障诊断方法[J]. 高压电器, 2019, 55(8): 157-163.
- WU Zhanyu, DONG Ming, WANG Jianyi, et al. Fault diagnosis of power transformer based on fuzzy association rules mining[J]. High Voltage Apparatus, 2019, 55(8): 157-163.
- [17] 解颖, 王丰华, 傅正财. 基于栈式自编码器的变压器机械故障诊断[J]. 高压电器, 2020, 56(9): 46-53, 59.
- XIE Ying, WANG Fenghua, FU Zhengcai. Mechanical fault diagnosis of power transformer based on stacked auto encoder[J]. High Voltage Apparatus, 2020, 56(9): 46-53, 59.
- [18] 朱乔木, 陈金富, 李弘毅, 等. 基于堆叠自动编码器的电力系统暂态稳定评估[J]. 中国电机工程学报, 2018, 38(10): 2937-2946.
- ZHU Qiaomu, CHEN Jinfu, LI Hongyi, et al. Transient stability assessment based on stacked autoencoder[J]. Proceedings of the CSEE, 2018, 38(10): 2937-2946.
- [19] MAJUMDAR A. Blind denoising autoencoder[J]. IEEE Transactions on Neural Networks and Learning Systems, 2019, 30(1): 312-317.
- [20] TAO Huamin, DENG Qiuqun, XIAO Shanzhu. Reconstruction of time series with missing value using 2D representation-based denoising autoencoder[J]. Journal of Systems Engineering and Electronics, 2020, 31(6): 1087-1096.
- [21] 田宏杰. 线损分析预测在供电管理中的应用[J]. 电力系统保护与控制, 2010, 38(7): 77-80.
- TIAN Hongjie. Application of line loss analyzing forecast in power supply management[J]. Power System Protection and Control, 2010, 38(7): 77-80.
- [22] 戚正强, 史国东. 影响配变台区线损的主要因素分析[J]. 中国高新技术企业, 2010, 17(22): 91-92.
- QI Zhengqiang, SHI Guodong. Analysis of main factors affecting line loss in distribution transformer substation[J]. China High-Tech Enterprises, 2010, 17(22): 91-92.
- [23] 刘思峰, 蔡华, 杨英杰, 等. 灰色关联分析模型研究进展[J]. 系统工程理论与实践, 2013, 33(8): 2041-2046.
- LIU Sifeng, CAI Hua, YANG Yingjie, et al. Advance in grey incidence analysis modelling[J]. Systems Engineering - Theory & Practice, 2013, 33(8): 2041-2046.
- [24] 张义涛, 王泽忠, 刘丽平, 等. 基于灰色关联分析和改进神经网络的 10 kV 配电网线损预测[J]. 电网技术, 2019, 43(4): 1404-1410.
- ZHANG Yitao, WANG Zezhong, LIU Liping, et al. A 10 kV distribution network line loss prediction method based on grey correlation analysis and improved artificial neural network[J]. Power System Technology, 2019, 43(4): 1404-1410.
- [25] WANG Zelong, JIANG Yifeng, HU Xinlei. A leaf type recognition algorithm based on SVM optimized by improved grid search method[C] // 2020 5th International Conference on Electromechanical Control Technology and Transportation (ICECTT), May 15-17, 2020, Nanchang, China: 312-316.
- [26] KO B, KIM H, OH K, et al. Controlled dropout: a different approach to using dropout on deep neural network[C] // 2017 IEEE International Conference on Big Data and Smart Computing (BigComp), February 13-16, 2017, Jeju, Korea (South): 358-362.

收稿日期: 2020-11-30; 修回日期: 2021-03-26

作者简介:

周王峰(1996—), 男, 硕士研究生, 研究方向为人工智能在电力系统中的应用; E-mail: zwf753@foxmail.com

李勇(1982—), 男, 通信作者, 教授, 博士生导师, 研究方向为电力系统运行与控制、电力电子系统与控制。E-mail: yongli@hnu.edu.cn

(编辑 周金梅)