

DOI:10.12158/j.2096-3203.2022.06.023

基于集成 LSTM 模型的数据驱动需求预测

胡聪¹, 徐敏¹, 洪德华¹, 王海鑫², 刘翠玲¹, 薛晓茹¹

(1. 国网安徽省电力有限公司, 安徽 合肥 230061;

2. 沈阳工业大学电气工程学院, 辽宁 沈阳 110870)

摘要:电力用户参与电网调度能够有效提升电网灵活性,但其行为的不确定性限制了需求响应的发展。针对此问题,文中首先构建激励型需求响应的实现框架,阐述负荷聚合商(LA)如何整合需求侧资源参与电力市场业务,并将用户随激励政策进行响应的行为转换为需求弹性。然后,基于长短时记忆(LSTM)算法,提出一种集成 LSTM 的数据驱动的需求弹性预测方法,同时为提升预测模型性能,对源数据进行平滑与缩放处理,并增加损失函数权重系数。算例结果表明,与传统 LSTM 算法及 k 近邻预测法相比,文中所提预测方法用于用户需求弹性预测时平均预测误差分别降低了 5.33%和 28.8%,用于总负荷预测时平均绝对百分比误差(MAPE)分别降低了 2.06%和 3.09%。同时文中基于集成 LSTM 分析了平滑、缩放数据预处理对预测精度的影响,结果表明对原始数据进行预处理可有效提升预测精度。

关键词:集成长短时记忆(LSTM)算法;需求弹性;数据预处理;电力市场;激励型需求响应;数据驱动

中图分类号:TM73

文献标志码:A

文章编号:2096-3203(2022)06-0193-08

0 引言

需求响应技术能够充分调用用户侧资源,引导用户主动参与电力市场,从而缓解可再生能源大规模并网导致的电力系统灵活性下降问题^[1-2]。随着电力负荷种类的增多,电网难以单独与用户进行交易,而单一的用户也难以满足电网的要求。针对此问题,有学者提出了负荷聚合商(load aggregator, LA)模式,聚合用户侧各类负荷进行统一管理^[3]。

LA 通过与用户签订合同来实现对用户的控制,为使得自身利益最大,LA 须对用户行为进行预测。当前关于负荷预测的研究较为成熟,例如神经网络算法、支持向量机、 k 近邻理论等^[4],但此类预测方法未考虑负荷参与电力市场的情况。近年来,广大学者针对 LA 模式下的负荷预测展开了研究,然而用户参与电力市场时所产生的不确定性会制约预测精度。文献[5]提出在 LA 模式下利用模糊参数描述用户参与需求响应时的不确定性,但此方法仍无法准确描述用户的不确定性。文献[6]采用缩短预测周期的方法,并依次构建数据处理模型、负荷预测模型和误差预测模型,但此方法计算量较大。文献[7]在 LA 模式下的负荷预测中引入径向基函数(radial basis function, RBF)神经网络,但针对不同的负荷预测须重新训练模型。文献[8-10]建立基于

长短时记忆(long short-term memory, LSTM)网络的短期负荷预测模型,同时为提高预测精度,将多维预测输入特征进行量化,但预测精度还须进一步提升。

通过以上文献可以看出,当用户参与电力市场时,其行为的不确定性严重制约预测精度,因此文中针对 LA 模式下的负荷预测展开研究。首先,在 LA 模式下将用户由于激励价格变动而产生的行为变化转化为需求弹性。然后,分析 LSTM 算法的特点,提出一种集成 LSTM 的激励型需求响应负荷预测方法。最后,算例结果表明该方法可有效提升需求弹性及总负荷预测精度,同时验证了对源数据进行平滑和缩放预处理,并在损失函数中增加权重系数等均可提升预测精度。

1 LA 模式下的需求响应

LA 模式下的需求响应实现过程如图 1 所示。LA 集中负荷资源后作为独立实体加入电力市场,通过竞价或其他方式从电力市场获得需求响应指标和相应补贴。在实施需求响应的同时,LA 根据自身利益及用户状态给予用户不同的补贴以实现目标响应^[11]。

LA 模式包含三大因素,分别是电力企业、LA 以及可参与需求响应的用户侧资源^[12]。其运行模式为:电力企业与 LA 提前设定价格并签订合同,电力企业依据自身运行情况判断是否需要用户侧参与调节,若需要则提前向 LA 下发负荷调节量指标。

收稿日期:2022-04-29;修回日期:2022-07-17

基金项目:辽宁省自然科学基金资助项目(2020-BS-141);
2020 年国家电网有限公司信息数据治理研究项目(SGAHX-T00XYJS2000346)

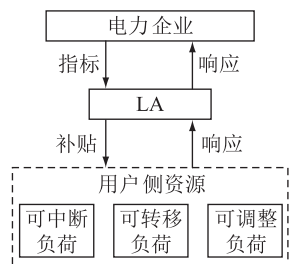


图 1 LA 模式下的需求响应

Fig.1 Demand response in LA mode

由于不同用户参与电网调节的成本相同,LA 根据自身利益调节各类负荷并给与相应补贴。

传统的电力市场服务对于偏差具有一定的要求,由于日前市场计划与实际电力之间具有一定的误差,LA 需要参与实时电力交易或购买辅助服务,以弥补此偏差。为保证用户侧调节量能够满足电力企业要求,LA 所提供的负荷调节量应具有一定的冗余,因此,可要求在调节期内 LA 中即使未参与调度的负荷也必须进行测试,以保证 LA 所提供的负荷调节量能够应对突发情况,否则将受到处罚。若 LA 上报的负荷容量较少,利润就会减少,并且如果未达到电力企业的负荷调节目标,LA 就会受到一定程度的惩罚。因此,LA 在整合负荷侧资源参与电力市场时,需要精确预测用户的响应行为。

在基于激励的需求响应的整个业务流程中,用户对不同激励的响应受到多种因素的影响,主要包含以下几点^[13]:

(1) 备选方案的可用性。如果利用其他非电力设备可代替电力设备,且效果相差不大,则用户的响应灵活性可能很高。

(2) 用户的当前负载状态。如果当前负载较高,可中断或可转移负载相对较大,用户更有可能对激励作出响应,响应弹性较高。

(3) 用电支出占总支出的比例。一般情况下,当用户经济状况较好时,电费支出占其总支出的比例较小,用户可能对激励不太敏感。反之,用户可能对激励更敏感。

(4) 外部环境。例如,在夏季中午的高温下,用户的需求弹性可能较低。因此,如果 LA 希望通过激励使得用户更换或关闭温控设备以减少负载,则需要较高的成本。而在晚上,随着外部环境温度的降低,用户的需求弹性可能会增加。

在经济学中,需求弹性用来表征用户对商品价格变化的敏感性。同样,需求弹性也可以用来描述用户对激励价格的响应,因此可将用户对不同激励的反应转换为经济学中的需求弹性,表达式如下:

$$E = \frac{\Delta R/R}{\Delta I/I} = \frac{\Delta R}{\Delta I} \cdot \frac{I}{R} \quad (1)$$

式中: E 为需求弹性; $R, \Delta R$ 分别为用户在需求响应中的响应量和响应变化量; $I, \Delta I$ 分别为用户收到的激励量和激励变化量。

用户参与需求响应会损失一定程度的舒适感或自身利益。随着用户参与需求响应的响应量增大,其舒适度和自身利益受到的影响会增大,将用户参与需求响应时的成本函数定义为:

$$\begin{cases} U(R) = \frac{1}{2}\beta_{\text{cost}}(R + \varepsilon)^2 + \alpha_{\text{cost}}(R + \varepsilon) \\ \text{s.t. } R \leq L \end{cases} \quad (2)$$

式中: $\beta_{\text{cost}}, \alpha_{\text{cost}}$ 为响应特性系数,其值取决于用户的响应特性,不同用户 β_{cost} 和 α_{cost} 的值不同; ε 为用户响应的噪声,由于用户响应的噪声较低且具有随机性,故在分析用户的需求弹性时将其忽略; L 为当前负载。

结合式(1)可得出用户需求弹性为:

$$E = \frac{dR}{dU} \cdot \frac{U}{R} = \frac{\beta_{\text{cost}}R + 2\alpha_{\text{cost}}}{2\beta_{\text{cost}}R + 2\alpha_{\text{cost}}} \quad (3)$$

通过以上分析,可知用户需求弹性与用户响应行为特性呈二次函数关系,但此关系仅限于理想状态,在实际情况下,用户的响应特性会因实际情况而产生波动。因此,使用简单的二次函数并不能准确描述用户的响应行为,需要更准确的方法来预测用户的响应行为。

2 基于集成 LSTM 模型的需求弹性预测

2.1 LSTM 模型

循环神经网络具有持续记忆的优点,可将之前的信息保留一段时间,其记忆特性适用于超短期负荷预测。但是循环神经网络在输入序列较长时存在长期依赖问题,因此文献[14]提出 LSTM 网络以解决此问题。LSTM 属于循环神经网络的改进方法,也是链式结构,但是重复模块有所差异,标准循环神经网络的重复模块内只有 1 个神经网络层,而 LSTM 在 4 个网络层之间进行交互。

对于 LSTM 网络,其输入的影响因素越相关,其预测结果越准确^[15]。但在实际情况下,有些数据难以收集或难以形成连续的结构化数据(如实时温度、湿度、风速等),或其获取成本高(如用户个人用电设备的实时耗电数据,例如空调、电热水器、照明设备等,该数据的收集需要用户的授权并安装单独的电数据采集和传输装置)。虽然影响用户用电行为的外部因素是多样的,但考虑到用户的用电行为

具有周期性,为了使算法能够识别历史相似日,将每日最大负荷、最小负荷以及时间作为输入。同时用户的当前用电行为决定了用户的最大响应潜力,因此也可以选择用户的当前用电行为作为输入之一。综上,基于 LSTM 模型的输入量为:每日最大负荷、每日最小负荷、时间、当前负荷和用户收到的激励。图 2 为典型 LSTM 网络的结构。

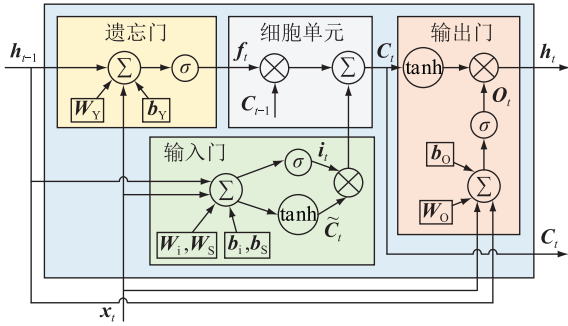


图 2 LSTM 网络结构

Fig.2 Structure of LSTM network

LSTM 通过输入门、遗忘门、输出门 3 个控制单元选择保留或者丢弃信息^[16-18]。在 LSTM 结构中,遗忘门确定保留下的信息。遗忘门向细胞单元输出 0 或 1,当输出值为 0 时,将丢弃所有信息;当输出值为 1 时,将保留所有信息。根据遗忘门的输出,只保留有用的信息。遗忘门更新公式见式(4)。

$$f_t = \sigma(\mathbf{W}_Y[\mathbf{h}_{t-1}, \mathbf{x}_t] + \mathbf{b}_Y) \quad (4)$$

式中: f_t 为遗忘门输出量; σ 为 sigmoid 函数; \mathbf{W}_Y 为遗忘门的权重; \mathbf{b}_Y 为遗忘门的偏置常数; \mathbf{h}_{t-1} 为上一时刻的输出; \mathbf{x}_t 为当前时刻的输入。

由 sigmoid 函数计算得出输入门的输出量,而候选值向量由 tanh 函数计算得出。输入门更新公式见式(5)和式(6)。

$$\mathbf{i}_t = \sigma(\mathbf{W}_i[\mathbf{h}_{t-1}, \mathbf{x}_t] + \mathbf{b}_i) \quad (5)$$

$$\tilde{\mathbf{C}}_t = \tanh(\mathbf{W}_s[\mathbf{h}_{t-1}, \mathbf{x}_t] + \mathbf{b}_s) \quad (6)$$

式中: \mathbf{i}_t 为输入门中经 sigmoid 函数处理后的输出量; $\mathbf{W}_i, \mathbf{b}_i$ 分别为输入门的权重和偏置常数; $\mathbf{W}_s, \mathbf{b}_s$ 分别为候选向量的权重和偏置常数; $\tilde{\mathbf{C}}_t$ 为候选值向量。

细胞单元记录了上一时刻状态,并基于当前输入数据,更新细胞单元中的状态信息。细胞单元的更新公式见式(7)。

$$\mathbf{C}_t = f_t \cdot \mathbf{C}_{t-1} + \mathbf{i}_t \cdot \tilde{\mathbf{C}}_t \quad (7)$$

式中: \mathbf{C}_t 为当前时刻细胞单元更新后的输出量; \mathbf{C}_{t-1} 为上一时刻细胞单元更新后的输出量。更新细胞单元的状态后,需要根据细胞单元状态内容和当前输入,即用户的预期响应量,确定要输出的内容。

输出门中间输出量更新公式见式(8)。

$$\mathbf{O}_t = \sigma(\mathbf{W}_o[\mathbf{h}_{t-1}, \mathbf{x}_t] + \mathbf{b}_o) \quad (8)$$

式中: \mathbf{O}_t 为输出门中间输出量; $\mathbf{W}_o, \mathbf{b}_o$ 分别为输出门的权重和偏置量。最终输出 \mathbf{h}_t 为:

$$\mathbf{h}_t = \mathbf{O}_t \cdot \tanh(\mathbf{C}_t) \quad (9)$$

2.2 集成 LSTM 预测方法

预测模型最终须实现线上应用,因此应具备自动连续产生负荷预测值的功能,这就要求模型能够精准泛化新数据,并使输入噪声具有鲁棒性,故文中提出一种集成 LSTM 预测模型,总体结构见图 3。

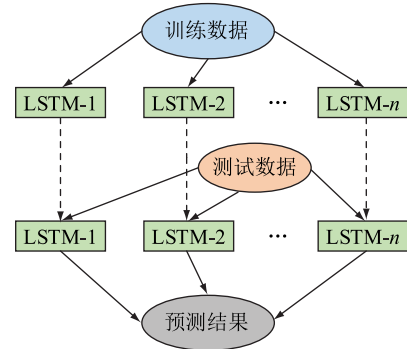


图 3 集成 LSTM 结构

Fig.3 Structure of integrated LSTM

集成 LSTM 预测模型首先并行训练具有不同初始值的 n 个 LSTM 模型,然后在预测过程中将每个预测结果平均,此集成方法可有效提升预测模型的鲁棒性。同时,为确保模型能够抵抗输入数据的干扰,在每个模型的训练过程中,2 个 LSTM 层的每个时间步长之间的隐藏状态都加入了高斯噪声。在推理过程中,多次使用噪声注入对模型进行评估,然后对所有输出进行平均。考虑噪声后,输出门最终输出见式(10)。

$$\tilde{\mathbf{h}}_t = \mathbf{h}_t + \boldsymbol{\gamma}N(0,1) \quad (10)$$

式中: $\tilde{\mathbf{h}}_t$ 为考虑噪声后的最终输出; $\boldsymbol{\gamma}$ 为可调参数矩阵; $N(0,1)$ 为正态分布。在每次评估时,对噪声进行独立采样。

2.3 集成 LSTM 预测方法

LSTM 具有记忆功能,能够反映负荷数据在时间顺序上的联系。利用集成 LSTM 进行预测时,由于原始数据量大且乱、模型参数较多,训练较为困难,因此须对负荷数据进行预处理并确定模型参数。集成 LSTM 的负荷预测具体步骤见下文。

2.3.1 数据预处理

(1) 数据平滑处理。为使模型更容易地捕捉到局部特征和主要趋势,须对原始数据进行平滑处理,原则为:将每一个数据点替换为超过 k 个连续数据点在之前状态(包括自身)的平均值,见式(11)。

$$a_t^{\text{smooth}} = \frac{1}{k} \sum_{l=0}^{k-1} a_{t-l} \quad (11)$$

式中: a_t^{smooth} 为平滑后的数据值; a_{t-l} 为 $t-l$ 时刻的数据值。

(2) 原始数据缩放。原始数据具有不同的规模和分布,因此在输入模型之前须进行适当缩放,否则会出现训练收敛缓慢、训练模型性能较差的现象。为此,应用 min-max 缩放变换将所有特征转换为一个固定范围 $[m, M]$, 缩放变换方法见式(12)。

$$a_t^{\text{scaled}} = \frac{a_t^{\text{smooth}} - a_{\min}}{a_{\max} - a_{\min}}(M - m) + m \quad (12)$$

式中: a_t^{scaled} 为缩放后的数据值; a_{\max}, a_{\min} 分别为数据中的最大和最小值; M, m 分别为缩放范围的上限值和下限值。

2.3.2 初始化参数

将图2中所有变量(包括权重和偏差)进行初始化,可利用正态分布初始化权重,平均值为0,标准差为1,所有初始偏置常数设置为0.1^[19-20]。

2.3.3 训练 LSTM 模型

采用梯度下降法训练 LSTM 模型,规定 θ 为神经网络的参数(权重和偏差),优化的核心是沿着与梯度相反的方向更新参数 θ ,最终得出一个参数 θ ,可令损失函数取最小值,即:

$$\theta_{n+1} = \theta_n - \alpha \frac{\partial L(\theta_n)}{\partial \theta_n} \quad (13)$$

式中: α 为学习率; $L(\theta_n)$ 为损失函数。

$$L(\theta_n) = \frac{1}{N\zeta} \sum_{i=1}^N \sum_{t=1}^{\zeta} |\hat{y}'_{i,t} - y_{i,t}| \quad (14)$$

式中: $\hat{y}'_{i,t}$ 为第 i 个数据链第 t 个时间步长的预测输出; $y_{i,t}$ 为第 i 个数据链第 t 个时间步长的实际输出; N 为负荷数据个数; ζ 为时间步长总数。

然而,在重新调节的过程中,会对绝对误差的值产生影响,导致预测精度降低。为了解决此问题,在损失函数中增加权重系数,以降低绝对误差的影响。加权后的损失函数如下:

$$L_w(\theta_n) = \frac{1}{N\zeta} \sum_{i=1}^N \sum_{t=1}^{\zeta} w_i |\hat{y}'_{i,t} - y_{i,t}| \quad (15)$$

式中: $L_w(\theta_n)$ 为加权后的损失函数; w_i 为加权系数。

$$w_i = \omega \frac{a_{\max} a_{i,t} - a_{\min} a_{i,t}}{\bar{a}_i} \quad (16)$$

式中: $a_{i,t}$ 为第 i 个数据链第 t 个时间步长未经处理的数据值; ω 为正则化权值的常数; \bar{a}_i 为第 i 个数据链负荷数据平均值。

在此步骤中利用随机梯度下降法可有效缩短训练时间,即在每次迭代中,随机选取训练样本的

损失函数进行优化,可有效加快每次迭代更新的速度,但随机梯度下降法得到的结果能否代表所有数据的最小损失还存在一定的争议。针对此问题,结合梯度下降和随机梯度下降的特点,可采用批处理的方式,即每次只计算部分训练数据的损失函数。批处理具有迭代次数少、迭代中优化的参数不会太小、结果更加接近梯度的优点。

2.3.4 负荷预测

在 LSTM 网络上训练 n 次后,损失函数会降低到一个较低的水平,此时训练完成,保存模型。使用 2.3.1 节中的方法来标准化输入数据,然后调用经过训练的模型来预测用户的响应。

2.4 评价指标

文中结合统计学误差分析与实际运行的需要,将平均绝对百分比误差(mean absolute percentage error, MAPE)作为所提模型的评价指标^[21-22]。

$$X_{\text{MAPE}} = \frac{1}{N\zeta} \sum_{i=1}^N \sum_{t=1}^{\zeta} \frac{|\hat{y}'_{i,t} - y_{i,t}|}{y_{i,t}} \quad (17)$$

式中: X_{MAPE} 为平均百分比误差。

3 算例分析

3.1 算例数据

为验证文中方法的科学性和可靠性,采用国网某公司提供的5个大型工厂同一季度连续40d的负荷数据,数据采样周期为15min。选取前30d的负荷数据作为训练数据,其余10d的负荷数据作为测试数据。由于负荷数据选自同一季度,故每天的激励政策基本相同,每天0时—20时的激励政策见图4,21时—24时无激励政策。为反应用户行为特征中的随机噪声 ε , β_{cost} 和 α_{cost} 的取值遵循正态分布,具体取值见表1^[23]。




图4 不同时间的激励

Fig.4 Incentive at different time

3.2 结果分析

首先,通过与传统 LSTM 算法及 k 近邻预测法对比验证集成 LSTM 负荷预测模型的优越性。然后,说明在数据预处理中提到的平滑、缩放、对损失

表 1 需求响应参数

Table 1 The parameters of demand response

| 参数 | 0 时—6 时 | 7 时—12 时 | 13 时—18 时 | 19 时—20 时 |
|---------------------|---------|----------|-----------|-----------|
| α_{cost} 平均值 | 1.5 | 3.0 | 1.0 | 1.7 |
| β_{cost} 平均值 | 6.0 | 5.0 | 6.0 | 4.2 |
| 标准差 | 0.2 | 0.2 | 0.2 | 0.2 |

函数加权如何影响预测模型的性能,及经预处理后模型预测精度是否得到提高。

3.2.1 需求弹性及总负荷预测结果对比

(1) 需求弹性预测结果对比。基于图 4 的激励政策及表 1 的需求响应参数,集成 LSTM、传统 LSTM、 k 近邻法对需求弹性的预测结果见表 2 和图 5—图 7(21 时—24 时无激励政策,不需要进行需求弹性预测,故图中仅展示 0 时—20 时的预测情况)。

表 2 需求弹性预测结果对比
Table 2 Comparison of demand elasticity prediction results %

| 方法 | 平均误差 |
|-----------|-------|
| 集成 LSTM 法 | 10.14 |
| 传统 LSTM 法 | 15.47 |
| k 近邻法 | 38.94 |

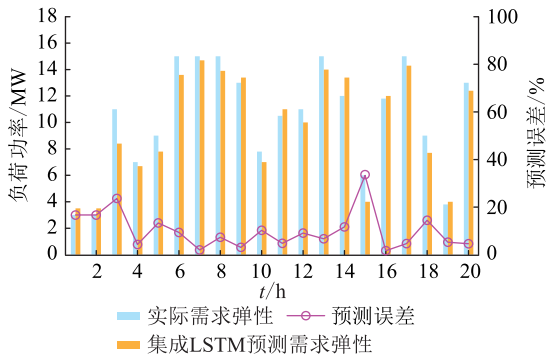


图 5 基于集成 LSTM 法的需求弹性预测
Fig.5 Demand elasticity prediction based on integrated LSTM method




图 6 基于传统 LSTM 法的需求弹性预测
Fig.6 Demand elasticity prediction based on traditional LSTM method




图 7 基于 k 近邻法的需求弹性预测
Fig.7 Demand elasticity prediction based on k -nearest neighbor method

由表 2 可知,不同预测方法的平均误差存在较大差异,其中集成 LSTM 法的平均误差最小,为 10.14%,相比 k 近邻预测法低了 28.8%,相比传统 LSTM 预测法低了 5.33%。

图 5—图 7 具体展示了不同预测方法在不同时间的需求弹性预测误差,其中 k 近邻法预测误差最大超过 150%,传统 LSTM 法最大预测误差在 50%左右,集成 LSTM 法最大预测误差不超过 40%。通过需求弹性平均预测误差及不同时间预测误差可以看出,文中所提集成 LSTM 法对于需求弹性预测具有较好的准确性和稳定性。结合图 4 可以看出,需求弹性与激励政策趋势总体相同,当激励较多时,用户负荷调节量较大,当激励较少时,用户负荷调节量也较小。

(2) 总负荷预测结果对比。为进一步说明集成 LSTM 预测法的优越性,将集成 LSTM、传统 LSTM 及 k 近邻预测法应用于总负荷预测并进行对比分析,3 种预测方法的结果见表 3、图 8 和图 9(总负荷预测须对 24 h 的负荷进行预测,故图中展示 0 时—24 时的负荷预测情况)。首先对预测结果进行横向对比分析,由表 3 可知,集成 LSTM 负荷预测法的 MAPE 值为 1.08%,相比传统 LSTM 法低了 2.06%,相比 k 近邻法低了 3.09%。因此集成 LSTM 法优于传统 LSTM 法和 k 近邻法。

表 3 总负荷预测结果对比
Table 3 Comparison of total load prediction results %

| 方法 | X_{MAPE} |
|-----------|------------|
| 集成 LSTM 法 | 1.08 |
| 传统 LSTM 法 | 3.14 |
| k 近邻法 | 4.17 |

由图 8 可以看出,相比传统 LSTM 法和 k 近邻法预测结果,集成 LSTM 法的负荷预测结果最贴近实际值。由图 9 可进一步发现,集成 LSTM 法的负




图8 负荷预测结果与实际值对比

Fig.8 Comparison of load forecasting results with actual values




图9 MAPE 值对比

Fig.9 Comparison of MAPE values

荷预测误差最小, k 近邻法的预测误差最大。 k 近邻法通过与新数据点最邻近的 k 个数据点对新数据进行分类和预测, 一旦数据中存在误差数据, 其准确度会明显下降, 而 LSTM 中每个传输单元的状态贯穿于整个结构, 能够保证信息传输的不变性, 因此预测精度相对较高。文中所提集成 LSTM 法能够并行训练具有不同初始值的 LSTM 模型, 并将结果平均, 进一步提升了预测精度。

表 4 对比了不同预测方法所耗费的时间, 可以看出, 集成 LSTM 预测法虽然预测精度较高, 但相比传统 LSTM 预测法及 k 近邻法, 耗时较长, 这是由于集成 LSTM 法需要并行训练具有不同初始值的 LSTM 模型, 虽应用了批处理的方式训练模型, 但计算量较大, 耗时仍相对较长。

表 4 不同预测方法耗时比较

Table 4 Comparison of time consumption under different prediction methods min

| 方法 | 时间 |
|-----------|----|
| 集成 LSTM 法 | 30 |
| 传统 LSTM 法 | 26 |
| k 近邻法 | 14 |

3.2.2 数据预处理对预测结果的影响

上文说明了集成 LSTM 预测法的优越性, 接下来进一步探讨对源数据进行平滑、缩放预处理及采用加权损失函数对模型预测性能的影响。为排除

样本的偶然性对结果产生影响, 建立 2 个对照算例: 算例一按照前文所采用的方式, 选取前 30 d 的负荷数据作为训练数据, 后 10 d 的负荷数据作为测试数据; 算例二选取后 30 d 负荷数据作为训练数据, 前 10 d 的负荷数据作为测试数据。将 2 个算例进行对比分析验证数据预处理对预测精度的影响。

表 5 对比了算例一和算例二中对源数据进行不同方式预处理对预测精度的影响, 通过 MAPE 值可以观察到各预处理方式对预测精度的影响情况基本一致, 由此可排除同一样本测试结果的偶然性。

表 5 不同数据预处理方式预测结果比较

Table 5 Comparison of prediction results under different data preprocessing methods %

| 预处理方式 | X_{MAPE} | |
|----------|------------|------|
| | 算例一 | 算例二 |
| 未经处理 | 3.14 | 3.36 |
| 平滑 | 2.65 | 2.59 |
| 缩放 | 2.06 | 2.37 |
| 缩放+权重 | 1.70 | 1.88 |
| 平滑+缩放+权重 | 1.08 | 0.94 |

图 10 比较了算例一对源数据进行平滑、缩放及在损失函数中增加权重等处理对预测精度的影响。可以看出在传统 LSTM 预测模型的基础上, 进行平滑、缩放处理后预测误差均有所降低。同时进行缩放与加权处理时, 预测误差明显降低, 而文中预测方法同时采用平滑、缩放、增加权重的方式对数据进行预处理, 预测误差最低, 可有效提升预测精度。




图 10 数据预处理对预测精度的影响

Fig.10 The influence of data preprocessing on prediction accuracy

4 结论

基于文中提出的集成 LSTM 模型的数据驱动需求弹性预测得到以下结论:

- (1) 相比传统 LSTM 预测法及 k 近邻预测法, 集成 LSTM 预测法可有效提升需求弹性及总负荷预测精度, 需求弹性预测平均误差相比其他 2 种方法分别降低了 5.33% 和 28.8%, 总负荷预测误差相比其他 2 种方法分别降低了 2.06% 和 3.09%。

(2) 集成 LSTM 法对预测精度提升较为明显,耗时比传统 LSTM 预测法及 k 近邻预测法长,虽采取了批处理等训练方式,但须并行训练具有不同初始值的 LSTM 模型,计算负担较大,导致耗时较长。

(3) 原始数据具有不同的规模和分布,对预测模型的输入数据进行缩放、平滑预处理对于提升预测精度具有积极意义。

(4) 随着用户端分布式光伏、风电等新能源的大量并网,用户不仅消耗电能,也可供给电能。未来需要结合电力辅助服务市场及政府对可再生能源的补贴政策对用户行为模式展开更深入的研究。

参考文献:

- [1] 张晶晶,张鹏,吴红斌,等. 负荷聚合商参与需求响应的可靠性及风险分析[J]. 太阳能学报,2019,40(12):3526-3533.
ZHANG Jingjing,ZHANG Peng,WU Hongbin, et al. Reliability and risk analysis of load aggregators in demand response[J]. Acta Energetica Solaris Sinica,2019,40(12):3526-3533.
- [2] 陈锦涛,杨苹,陈滢,等. 基于综合需求侧响应策略的园区多能源系统优化运行[J]. 可再生能源,2021,39(2):222-228.
CHEN Jintao,YANG Ping,CHEN Ying, et al. Optimized operation of multi-energy system in the industrial park based on integrated demand response strategy[J]. Renewable Energy Resources,2021,39(2):222-228.
- [3] 任惠,陆海涛,卢锦玲,等. 考虑信息物理系统耦合和用户响应差异的负荷聚合商需求响应特性分析[J]. 电网技术,2020,44(10):3927-3936.
REN Hui,LU Haitao,LU Jinling, et al. Analysis of LA demand response characteristics considering cyber physical system coupling and user's response difference[J]. Power System Technology,2020,44(10):3927-3936.
- [4] 史佳琪,张建华. 基于多模型融合 Stacking 集成学习方式的负荷预测方法[J]. 中国电机工程学报,2019,39(14):4032-4042.
SHI Jiaqi,ZHANG Jianhua. Load forecasting based on multi-model by stacking ensemble learning[J]. Proceedings of the CSEE,2019,39(14):4032-4042.
- [5] 郭亦宗,冯斌,岳铂雄,等. 负荷聚合商模式下考虑需求响应的超短期负荷预测[J]. 电力系统自动化,2021,45(1):79-87.
GUO Yizong,FENG Bin,YUE Boxiong, et al. Ultra-short-term load forecasting considering demand response in load aggregator mode[J]. Automation of Electric Power Systems,2021,45(1):79-87.
- [6] 李闯,孔祥玉,朱石剑,等. 能源互联环境下考虑需求响应的区域电网短期负荷预测[J]. 电力系统自动化,2021,45(1):71-78.
LI Chuang,KONG Xiangyu,ZHU Shijian, et al. Short-term load forecasting of regional power grid considering demand response in energy interconnection environment[J]. Automation of Electric Power Systems,2021,45(1):71-78.
- [7] 陈丽娜,张智晟,于道林. 基于广义需求侧资源聚合的电力系统短期负荷预测模型[J]. 电力系统保护与控制,2018,46(15):45-51.
CHEN Lina,ZHANG Zhisheng,YU Daolin. Short-term load forecasting model of power system based on generalized demand side resources aggregation[J]. Power System Protection and Control,2018,46(15):45-51.
- [8] 韩添祎,陈曦,刘庆鑫. 峰谷电价下基于长短期记忆网络的配电网短期负荷预测研究[J]. 东北电力大学学报,2020,40(4):19-28.
HAN Tianyi,CHEN Xi,LIU Qingxin. Short-term load forecasting for distribution network in the presence of TOU price based on long-short-term memory network[J]. Journal of Northeast Electric Power University,2020,40(4):19-28.
- [9] 栗然,孙帆,丁星,等. 考虑多能时空耦合的用户级综合能源系统超短期负荷预测方法[J]. 电网技术,2020,44(11):4121-4134.
LI Ran,SUN Fan,DING Xing, et al. Ultra short-term load forecasting for user-level integrated energy system considering multi-energy spatio-temporal coupling[J]. Power System Technology,2020,44(11):4121-4134.
- [10] 陈振宇,刘金波,李晨,等. 基于 LSTM 与 XGBoost 组合模型的超短期电力负荷预测[J]. 电网技术,2020,44(2):614-620.
CHEN Zhenyu,LIU Jinbo,LI Chen, et al. Ultra short-term power load forecasting based on combined LSTM-XGBoost model[J]. Power System Technology,2020,44(2):614-620.
- [11] 程林,万宇翔,张放,等. 基于负荷聚合商业业务的空调服务运作模式及控制策略[J]. 电力系统自动化,2018,42(18):8-16.
CHENG Lin,WAN Yuxiang,ZHANG Fang, et al. Operation mode and control strategy for air-conditioning service based on business of load aggregator[J]. Automation of Electric Power Systems,2018,42(18):8-16.
- [12] 曹瑛,刘建锋,龚锦霞. 面向负荷聚合商的风光消纳调度优化模型[J]. 可再生能源,2018,36(4):563-567.
CAO Ying,LIU Jianfeng,GONG Jinxia. Optimization model for wind and solar power accommodation based on load aggregator[J]. Renewable Energy Resources,2018,36(4):563-567.
- [13] LI P,WANG H,ZHANG B S. A distributed online pricing strategy for demand response programs[J]. IEEE Transactions on Smart Grid,2019,10(1):350-360.
- [14] 许言路,武志锴,朱赫炎,等. 基于多尺度卷积神经网络的短期电力负荷预测[J]. 沈阳工业大学学报,2020,42(6):618-623.
XU Yanlu,WU Zhikai,ZHU Heyan, et al. Short-term load forecasting based on multi-scale convolutional neural network[J]. Journal of Shenyang University of Technology,2020,42(6):618-623.
- [15] 陆继翔,张琪培,杨志宏,等. 基于 CNN-LSTM 混合神经网络模型的短期负荷预测方法[J]. 电力系统自动化,2019,43(8):131-137.

- LU Jixiang, ZHANG Qipei, YANG Zhihong, et al. Short-term load forecasting method based on CNN-LSTM hybrid neural network model [J]. Automation of Electric Power Systems, 2019, 43(8):131-137.
- [16] 陈洪波, 王璨, 徐斌, 等. 基于 LSTM 网络的短期负荷预测[J]. 电工技术, 2019(9):27-29.
CHEN Hongbo, WANG Can, XU Bin, et al. Short-term load forecasting based on LSTM network[J]. Electric Engineering, 2019(9):27-29.
- [17] 张宇帆, 艾芊, 林琳, 等. 基于深度长短时记忆网络的区域级超短期负荷预测方法[J]. 电网技术, 2019, 43(6):1884-1892.
ZHANG Yufan, AI Qian, LIN Lin, et al. A ultra short-term load forecasting method based on deep LSTM RNN at zone level [J]. Power System Technology, 2019, 43(6):1884-1892.
- [18] 徐诗鸿, 张宏志, 林湘宁, 等. 基于改进评价指标的波动性负荷短期区间预测[J]. 电力系统自动化, 2020, 44(2):156-163.
XU Shihong, ZHANG Hongzhi, LIN Xiangning, et al. Improved evaluation index based short-term interval prediction of fluctuation load[J]. Automation of Electric Power Systems, 2020, 44(2):156-163.
- [19] 朱刘柱, 王绪利, 马静, 等. 基于小波包分解与循环神经网络的综合能源系统短期负荷预测[J]. 电力建设, 2020, 41(12):131-138.
ZHU Liuzhu, WANG Xuli, MA Jing, et al. Short-term load forecast of integrated energy system based on wavelet packet decomposition and recurrent neural network [J]. Electric Power Construction, 2020, 41(12):131-138.
- [20] 谢毓广, 郭力. 基于区域负荷预测值综合评价的大电网短期负荷预测[J]. 电气应用, 2017, 36(11):40-45.
XIE Yuguang, GUO Li. Short-term load forecasting of large power grid based on comprehensive evaluation of regional load forecasting values [J]. Electrotechnical Application, 2017, 36(11):40-45.
- [21] 何晔, 邹晓松, 李卓, 等. 一种面向运行可靠性的短期负荷预测方法研究[J]. 电测与仪表, 2019, 56(10):93-98.
HE Ye, ZOU Xiaosong, LI Zhuo, et al. A short-term load forecasting method oriented for operational reliability [J]. Electrical Measurement & Instrumentation, 2019, 56(10):93-98.
- [22] 朱文广, 李映雪, 杨为群, 等. 基于 K-折交叉验证和 Stacking 融合的短期负荷预测[J]. 电力科学与技术学报, 2021, 36(1):87-95.
ZHU Wenguang, LI Yingxue, YANG Weiqun, et al. Short-term load forecasting based on the K-fold cross-validation and Stacking ensemble [J]. Journal of Electric Power Science and Technology, 2021, 36(1):87-95.
- [23] YU M M, HONG S H, DING Y M, et al. An incentive-based demand response (DR) model considering composited DR resources [J]. IEEE Transactions on Industrial Electronics, 2019, 66(2):1488-1498.

作者简介:



胡聪

胡聪(1981),男,硕士,高级工程师,从事大数据、数据中台、企业中台研究相关工作(E-mail:1257227430@qq.com);

徐敏(1988),男,硕士,高级工程师,从事大数据、数据中台、数据分析相关工作;

洪德华(1993),女,硕士,工程师,从事数据应用、数据分析、数据挖掘相关工作。

Data-driven demand prediction based on integrated LSTM model

HU Cong¹, XU Min¹, HONG Dehua¹, WANG Haixin², LIU Cuiling¹, XUE Xiaoru¹

(1. State Grid Anhui Electric Power Co., Ltd., Hefei 230061, China;

2. School of Electrical Engineering, Shenyang University of Technology, Shenyang 110870, China)

Abstract: The flexibility of the power grid can be significantly promoted by the participation of power customers in dispatch. However, as the uncertainty of customer behavior, the development of demand response services is limited. To solve this problem, the framework of incentive-based demand response is constructed in this paper. The way that load aggregators integrate demand-side resources to participate in the power market is elaborated. And the behavior of power customers responding to incentive policies is transformed into demand elasticity. Then, a data-driven demand elasticity prediction method based on the integrated long short-term memory (LSTM) is proposed. Meanwhile, to improve the performance of the prediction model, the original data is smoothed and scaled, and the weight coefficients of the loss function are added. The simulation results show that, compared with the traditional LSTM algorithm and the k -proximity prediction method, the average forecasting error with the proposed model for the demand elasticity is reduced by 5.33% and 28.8%, and mean absolute percentage error (MAPE) for the total load prediction is reduced by 2.06% and 3.09%. Additionally, based on integrated LSTM, the influence of smoothing and scaling data preprocessing on prediction accuracy is analyzed. The results show that the prediction accuracy can be significantly promoted by data preprocessing.

Keywords: integrated long short-term memory (LSTM) algorithm; demand elasticity; data preprocessing; power market; incentive-based demand response; data-driven

(编辑 方晶)