

基于机器学习的短期电力负荷 预测方法比较及改进研究

韩雅莹 石梦舒 黄元生 刘敦楠 段文军

【摘 要】针对电力系统对短期电力负荷预测精确性的需求,以长短期记忆算法为基础,采用差分自适应进化算法对其进一步改进,从而提出一种基于机器学习的混合算法(SaDE-LSTM)对电力负荷进行短期预测。基于我国2004-2018年间月度社会用电负荷数据,对改进后的混合算法进行性能测试,首先利用差分进化算法的自适应变异和交叉因子来优化长短期记忆算法的初始参数,在此基础上,运用寻优得到的参数训练长短期记忆算法从而得到优化后的预测结果。为证明其优越性,对同组数据采用支持向量机(SVM)、反向传播神经网络、自回归积分滑动平均等算法分别预测。各方法预测结果和真实结果对比分析证明,SaDE-LSTM算法对时间序列数据量要求较低,同时相比其他传统算法有更高的预测精度。该改进算法能够为参与电力系统调度的虚拟电厂、负荷聚合商等对小样本和高精度预测有需求的主体提供参考。

【关键词】SaDE-LSTM算法;时间序列分析;电力负荷预测;长短期记忆循环神经网络;差分进化算法

【作者简介】韩雅莹(1998-),女,辽宁抚顺人,华北电力大学经济与管理学院硕士研究生,主要研究方向为电力市场、能源互联网(北京102206);石梦舒(1995-),通信作者,女,河北衡水人,华北电力大学经济与管理学院博士研究生,主要研究方向为综合能源系统(北京102206);黄元生(1958-),男,山东青岛人,华北电力大学(保定)经济与管理系教授,博士研究生导师,博士,主要研究方向为电力市场(河北保定071003);刘敦楠(1979-),男,北京人,华北电力大学经济与管理学院教授,博士研究生导师,博士,主要研究方向为电力市场、能源互联网(北京102206);段文军(1969-),女,北京人,北京信息科技大学经济管理学院副教授,硕士,主要研究方向为财务管理、财务建模方法与技术、财务分析(北京100192)。

【原文出处】《科技管理研究》(广州),2023.1.163~170

【基金项目】国家社会科学基金重大项目“面向国家能源安全的智慧能源创新模式与政策协同机制研究”(19ZDA081)。

1 研究背景

能源消费与经济发展密切相关,随着我国经济稳中向好增长,我国社会用电需求也将持续增速^[1]。电力负荷预测是对未来电力负荷的时间分布和空间分布的预测,是能源系统高效、安全和稳定运行的前提和重要保障。中长期负荷预测是电力规划的基础,关系到我国未来能源发展战略的制定^[2];短期的负荷预测是电力系统运行的基础,在电力调度工作中起到关键性作用^[3]。调度机构通过短期电力负荷预测,可以高效定制发电计划,避免电力供应过剩或不足,在保障民生的同时降低调度成本,以节约能源,从而更好地保证电网安全稳定运行^[4]。尹春杰等^[5]、郭亦宗等^[6]认为,售电公司、虚拟电厂、负荷聚合商等电力市场主体可以通过开展短期负荷预测负荷提高经营收益、发展新的商业模式。然而,由于短期负荷受自然情况、数据规模等影响,较为精准的预测具有一定的难度。

当前负荷预测主要有以下几种方法:基于历史数据的统计方法、基于数学思想的预测方法以及基于人工智能的机器学习方法^[7]。相比于后期发展的机器学习算法,统计学的原理较为简单,理论也较为成熟。贾庆兰等^[8]建立基于多变量时间序列的电力负荷预测模型,以获得更高可信度和精度的电力负荷预测结果。梁荣等^[9]、Liu等^[10]都以ARIMA模型为基础,分别结合深度学习和神经网络对短期电力负荷预测方法进行改进,前者提高了精度但未关注预测速度,后者以牺牲精度为代价取得了预测速度上的提高。李文静等^[11]则是简化了LSTM神经网络用于时间序列预测的门结构,以降低预测时间和复杂度。以上文献都采用了常用于负荷预测

的典型统计方法,然而可以发现,传统的预测方法在预测精度上存在误差较大以及不稳定的缺点,此外,该方法对于数据的要求更高,对于小样本以及不稳定的时间序列预测并不准确,因此部分学者开始研究机器学习方法,以打破负荷预测技术发展瓶颈。Guo 等^[12]、Fan 等^[13]认为,机器学习方法能够在一定程度上弥补传统方法的缺陷,为较为常用的随机森林(random forest, RF)、支持向量机(support vector machine, SVM)、人工神经网络(artificial neural network, ANN)等机器学习算法,具有较高的适应性和较好的拟合能力。

冯荣强等^[14]运用长短期记忆神经网络(long short-term memory, LSTM)对于用户的家庭用电需求进行了预测, Megn 等^[15]采用灰色模型和无线基函数神经网络分别对上升趋势和周期波进行建模,证明了相比于传统方法,基于人工神经网络的改进算法在预测精度和预测风险方面表现更好。He 等^[16]为提升负荷预测的精确度,考虑了最小绝对收缩以及选择算子分位数回归神经网络(LASSO-QRNN),通过方法的组合,陈振宇等^[17]、王飞等^[18]提出了一种考虑负荷区间的概率密度预测方法,在一定程度上突破了负荷预测精度难以提高的限制。袁保平等^[19]在差分进化算法和多层感知引擎的基础上,提出基于神经网络的短期电力负荷预测法和混沌智能特征选择。在算例分析中将本方法结果与其他短期负荷预测技术进行对比,证明将差分进化算法(differential evolution, DE)应用于人工神经网络能够更有效的提高预测的准确度。Tvrđik 等^[20]采用了3种类型的自适应差分进化算法(self-adaptive differential evolution, SaDE)的非混合和混合变体解决4个实际基准问题,并将算法优缺点进行对比,为相关研究提供方向。

本文综合了长短期记忆算法和自适应差分进化算法的优点,在进行时间序列分析的基础上,利用自适应差分进化算法优化长短期记忆算法,提出了一种用于短期负荷预测的混合算法(SaDE-LSTM)。本文以我国2004-2018年社会月度用电量数据作为输入数据,首先对改进后的混合算法进行性能测试,其次对比相同场景下分别采用支持向量机、反向传播神经网络、自回归积分滑动平均等模型的预测结果,证明了SaDE-LSTM算法综合了长短期记忆算法在长序列预测准确率上表现优异和自适应差分进化算法搜索效率高的优点,能够快速寻优,提高收敛精度,从而提高预测精度。

2 模型相关算法原理

2.1 长短期记忆网络原理

长短期记忆网络是在循环神经网络(recurrent neural networks, RNN)的基础上发展而来,其结构如图1所示,是常用于预测的方法之一。Neeraj 等^[21]、Chahla 等^[22]基于该方法实现时间序列的分类及回归,进而对电力负荷进行预测。




图1 简单长短期记忆网络体系结构

为克服周期性神经网络的梯度消失和爆炸等缺陷,改进了长短期记忆网络的存储器单元结构^[23],如图2所示。荆昱阳等^[24]通过一个时间序列数据的拟合和预测问题,验证了改进的长短期记忆网络的单元结构在处理时间序列时具有良好的性能。查博等^[25]则结合传统回归模型及神经网络模型,通过对比分析证明了长短期记忆网络在预测方面的优越性。




图2 长短期记忆记忆单元结构

长短期记忆网络结构的每个内存单元都包含3个重要组件:遗忘门 f_t 、输入门 i_t 、输出门 o_t 分别更新每个节点的遗忘、输入以及输出信息,从而实现信息传递和记忆长期状态。在信息传输过程中,长短期记忆网络通过当前输入信息、最后时刻的隐藏层状态信息以及最后时刻的单元状态和结构来处理单元状态信息,根据遗忘门和输入门的输出更新单元格状态优选信息。单元格状态更新是对该时刻单元格的历史状态信息和输入的新信息的同时更新。最后,隐藏层根据更新的单元格状态输出最终状态。长短期记忆网络的记忆单元更新流程如下。

(1)遗忘门 f_t 的计算。遗忘门能够当前的输入以及历史的隐藏层输出,即控制 t 时刻输入值 x_t 和 $t-1$ 时刻隐藏层输出 h_{t-1} 被遗忘的程度,进而筛选有效信息。遗忘门 f_t 的计算公式是:

$$f_t = \sigma(w_f \times [h_{t-1}, x_t] + b_f) \quad (1)$$

式(1)中, w_f 所代表的概念是在 t 时刻遗忘门 f_t 的权值矩阵, b_f 所代表的概念是偏置量, σ 一般为sigmoid函数,起到门控作用。

(2)输入门 i_t 的计算。输出门控制 t 时刻输入值 x_t 和 $t-1$ 时刻隐藏层输出 h_{t-1} 更新到记忆单元的程度大小。输入门 i_t 的计算公式是:

$$i_t = \sigma(w_i \times [h_{t-1}, x_t] + b_i) \quad (2)$$

式(2)中: w_i 所代表的概念是 t 时刻输入门 i_t 的权值矩阵; b_i 所代表的概念是偏置量。

(3)记忆单元的候选状态 c_t 的计算。 c_t 由 t 时刻输入值 x_t 和 $t-1$ 时刻隐藏层输出 h_{t-1} 共同决定。记忆单元的候选状态 c_t 的计算公式是:

$$c_t = \tanh h + (w_c \times [h_{t-1}, x_t] + b_c) \quad (3)$$

式(3)中: w_c 所代表的概念是 t 时刻候选状态 c_t 的权值矩阵; b_c 所代表的概念是偏置量。

(4)记忆单元状态值 c_t 的更新计算。记忆单元状态值 c_t 的更新计算公式为:

$$c_t = f_t \times C_{t-1} + i_t \times c_t \quad (4)$$

记忆单元 c_t 通过输入门 i_t 和遗忘门 f_t 调整自身状态 c_{t-1} 和当前候选记忆状态值 c_t ,从而更新记忆单元的状态。

(5)输出门 o_t 的计算。输出门控制 t 时刻输入值 x_t 和 $t-1$ 时刻隐藏层输出 h_{t-1} 取决于 t 时刻记忆单元的程度大小。

输出门 o_t 的计算公式为:

$$o_t = \sigma(w_o \times [h_{t-1}, x_t] + b_o) \quad (5)$$

公式(5)中: w_o 所代表的概念是 t 时刻输出门 o_t 的权值矩阵; b_o 所代表的概念是偏置量。

(6)隐藏层输出值 h_t 计算。隐藏层输出值 h_t 是由 t 时刻输出值 o_t 与记忆单元状态值 c_t 决定的,计算公式如下:

$$h_t = o_t \times \tanh(c_t) \quad (6)$$

相比于循环神经网络在长序列预测的准确率低于短序列的情况,长短期记忆算法在长序列预测上也表现出较高的精度,长短期记忆网络能够对负荷数据之间的时间相关性进行充分利用,对时间序列进行分类、处理和预测,进而更加精确地进行负荷预测。

2.2 差分进化算法原理

区别于其他一些优化算法,差分进化算法的目标是全局优化,这使差分进化算法在电力系统频率预测这类对时间较高要求的领域有一定优势^[26]。差分进化算法在优化过程中,从父代个体中随机挑选两个个体进而计算矢量差以生成差异矢量。通过选择新的个体以及对应差分向量来生成一个实验个体。在此基础上,父母和子代杂交产生新的后代个体。最后,通过选择符合条件的个体,将该个体信息保存到下一代,汪慎文等^[27]对差分进化算法的原理进行了较为详细的介绍。标准的差分进化算法包括4个步骤,每个步骤的细节如下。

(1)初始化。在此步骤中,首先初始化参数,包括种群大小 N ,基因维度 D ,变异因子(也称为缩放因子) F ,交叉率 CR 以及每个基因的取值范围 $[U_{\min}, U_{\max}]$ 。然后,按照公式(7)随机初始化总体:

$$x_{ij} = U_{\min} + \text{rand} \times (U_{\max} - U_{\min}) \quad (7)$$

在公式(5)中, $i=1,2,\dots,N,j=1,2,\dots,D$,rand是均匀分布的随机数。

(2)突变。对于每个目标向量 $x_i^G, i=1,2,\dots,N$,标准差分进化算法将根据公式(8)生成相应的变化向量:

$$v_i^{G+1} = x_{r_1}^G + F \times (x_{r_2}^G - x_{r_3}^G) \quad (8)$$

在公式(8)中,个体序列号 r_1, r_2 和 r_3 是随机选择的并且彼此不同,并且与目标个体的数量 i 不同,因此种群大小 $N \geq 4$ 。

(3)交叉。通过公式(9)的交叉操作产生了一个实验个体:

$$u_{ij}^{G+1} = \begin{cases} v_{ij}^{G+1}, & \text{if: } r(j) \leq CR; \text{ or, } j = \text{rn}(i) \\ x_{ij}^G, & \text{else} \end{cases} \quad (9)$$

在公式(9)中, $r(j)$ 是一个服从 $[0, 1]$ 均匀分布的随机数, j 表示基因的数量,交叉率 CR 通常由用户设置,范围为 $[0, 1]$ 。从公式(9)可以得知,得到的交叉率 CR 越小,全局的搜索效果越好。

(4)选择。DE 采用“贪婪”的搜索策略,它将每个目标个体 x_i^G 与其对应的个体 u_i^{G+1} 竞争,比较适应性值。只有当实验个体 u_i^{G+1} 的适应性值优于目标个体 x_i^G 时,实验个体 u_i^{G+1} 才可以被选作后代个体。否则,目标个体 x_i^G 将被选作后代。以最小化优化为例,选择操作如公式(10)所示,类似代价函数和误差预测函数, $f(\cdot)$ 是一种适应性函数。

$$x_i^{G+1} = \begin{cases} u_i^{G+1}, & \text{if: } f(u_i^{G+1}) < f(x_i^G) \\ x_i^G, & \text{else} \end{cases} \quad (10)$$

2.3 SaDE-LSTM 原理

长短期记忆算法通过机器学习求出负荷和负荷的影响因素之间的非线性映射关系,但是其仅考虑了当前时刻的输入特征,忽略了连续负荷样本之间的序列的相关关系,缺乏了对历史信息处理。为此,本文利用自适应差分进化算法改进长短期记忆算法。

自适应差分进化算法本身可塑性较强。吴文海等^[28]将其与随机邻域策略和广义反向学习结合,进一步提高了算法寻优精度高和收敛速度。赵杨等^[29]则将其与策略融合变异结合,提高了目标优化的搜索能力。随机自适应微分进化算法使用基于随机选择策略的突变运算,以较低的概率干扰自适应控制突变因子和交叉概率,以满足算法不同阶段的要求。自适应差分进化算法重点包含有自适应差分进化算法与适应差分进化算法(adaptive differential evolution, ADE)。适应差分进化算法仅使用自适应突变因子。自适应差分进化算法在适应差分进化的基础上引入了适应性交叉因子, Qin 等^[30]对差分进化算法进行了深入解析。

(1)适应性突变因子。变异因子 F 决定了差分向量的尺度。得到的 F 越大,差分进化算法的搜索效率越低,导致全局搜索结果更差。但是,如果得到的 F 太小,种群多样性则会降低,并且算法会产生早熟。因此,本文提出了一种自适应突变因子,其基本原理公式(11)所示。

$$F = F_{\min} + (F_{\max} - F_{\min}) \times e^{\frac{1 - \text{GenM}}{\text{GenM} - G + 1}} \quad (11)$$

式(11)中, $F_{\min}$ 是最小变化因子, $F_{\max}$ 是最大变化因子, GenM 是最大迭代次数, G 是当前迭代次数。

(2)适应性交叉因子。初始时的大交叉因子能够确保变化在全局范围内发生,其后较小交叉率保证了局部收敛性。交叉因子的交叉速率随着迭代次数的增加发生动态变化。自适应交叉因子的设计如公式(12)所示:

$$CR = CR_{\max} - G(CR_{\max} - CR_{\min}) / \text{GenM} \quad (12)$$

式(12)中, $CR_{\min}$ 所代表的概念是交叉参数的最小值, $CR_{\max}$ 所代表的概念是交叉参数的最大值。

在进行时间序列预测的问题上,长短期记忆算法由于需要人工设定初始参数,例如隐含层层数、时滞、隐含层每层单元数等,人为设定难以实现最优解,且耗时费力。差分进化算法不依赖问题的特征信息,与其他优化算法相比,收敛速度快,全局优化能力强。在此基础上,自适应差分进化算法又能进一步解决差分进化算法在进化后期种群的多样性降低,以及容易出现过早收敛和精度不高的问题。因此,本文运用自适应差分进化算法确定最优的隐含层数以及每个隐含层的单元个数,运用自适应差分进化算法优化长短期记忆参数,提出 SaDE-LSTM 对短期负荷进行预测。

3 时间序列分析

3.1 序列的平稳性检验

本文选取我国31个省份2004年1月至2018年12月的月度全社会用电量数据作为原始数据^[31],对数据进行处理。

如图2、图3所示,社会用电呈现清晰的逐年增长趋势和年周期规律,因此该数据的序列是非平稳的时间

序列。




图3 2004—2018 年我国 31 个省份用电负荷数据




图4 2004—2018 年我国 31 个省份电力消费散点

在数据序列呈显著上升的情况下采用自相关图进行分析。如图5、图6所示,时间序列的自相关系数始终在x轴上方缓慢降低,存在拖尾特征,因此该序列为非平稳的。同时自相关系数长期位于零轴一侧,该序列为单调趋势序列。时间序列的自相关和偏自相关同时存在,进一步对序列进行差分运算。在5%的显著水平下,对时间序列平稳性进行检验,如表1所示,原序列在3种情况下都是非平稳序列,但其一阶差分序列和二阶差分序列都是稳态数组。




图5 2004—2018 年我国 31 个省份电力消费自相关
表1 2004—2018 年我国 31 个省份电力消费时间序列平稳性检验




图6 2004—2018 年我国 31 个省份电力消费偏自相关

外生变量	单位根检验	滞后长度	<i>t</i> 统计	<i>P</i> 值	结果
无	水平序列	11	7.111200	1.0000	非平稳
	一阶差分	13	-2.995000	0.0029	平稳
	二阶差分	13	-10.596900	<0.0001	平稳
截距项	水平序列	11	-0.505300	0.8860	非平稳
	一阶差分	10	-14.797900	<0.0001	平稳
	二阶差分	13	-10.563100	<0.0001	平稳
截距项	水平序列	11	-1.574253	0.7992	非平稳
线性度	一阶差分	10	-14.760000	<0.0001	平稳
趋势项	二阶差分	13	-10.527410	<0.0001	平稳

3.2 纯随机性检验

对数据进行延迟6阶和延迟12阶的白噪声检验,从表2可以看出,不同滞后期下*P*值均远小于0.05,因此该序列为非白噪声序列。

此外,由图7至图9可以看出该序列是具有随机性趋势的差分平稳序列,因此利用自回归综合移动平均模型拟合分析。

表 2 2004—2018 年我国 31 个省份电力消费滞后相关性 Q 检验

X^2	自由度	P 值
762.22	6	<2.2e-16
1396	12	<2.2e-16




图 7 我国 31 个省份电力消费一阶差分序列的时序




图 8 2004—2018 年我国 31 个省份电力消费一阶差分序列的自相关




图 9 2004—2018 年我国 31 个省份电力消费一阶差分序列的偏相关

4 模型检验及结果对比分析

本文以国研网数据库得到的月度负荷数据为基础,对提出的模型进行验证。其中,算例中将 2004 年 1 月至 2018 年 2 月月度用电量数据为训练集,以 2018 年 3 月至 2018 年 12 月的月度用电量数据作为测试集。

基于时间序列分析,运用自回归综合移动平均模型对算例数据进行预处理,如图 10 所示,用电数据模型呈现季节性和周期性特征。分别采用传统预测方法和本文提出的改进算法进行短期负荷预测。




图 10 自回归积分滑动平均模型预处理的我国 31 个省份用电数据

4.1 支持向量机算法预测结果

支持向量机算法作为适用于小样本的预测方法之一,在负荷预测领域得到了广泛应用。如图 11 所示,采用支持向量机算法预测的负荷与实际数据存在较大的误差,并且存在变化趋势相反的情况。其中,最低误差 9%,最高误差达 27%。这表明,对于波动性和周期性较强的数据,支持向量机并未表现出良好的适应性和预测准确性。

4.2 长短期记忆算法预测结果

相比于支持向量机算法,长短期记忆算法更适用于具有波动性的时间序列预测。图 12 为采用长短期记忆算法预测的电力负荷趋势。参照图 13 显示,将预期结果与实际价值进行比较,我们可以看到明显的误差,

标准误差是 684.6675,且无明显的一致性。




图 11 2018 年我国 34 个省级行政区电力消费的支持向量机算法预测结果和实际数据对比结果




图 12 采用长短期记忆算法的 2004—2018 年我国 31 个省份用电量预测结果

对原始数据进行更新,采用更新后的数据重新预测,运用长短期记忆算法预测得到的结果如图 14 所示,可以看出,标准误差为 1342.5309,数据误差较大,准确率也并没有得到提高。因此,单独使用长短期记忆算法不适合本算例场景下的短期电力负荷预测。





图 13 2004—2018 年我国 31 个省份用电预测值和实际值的误差

图 14 数据更新后 2004—2018 年我国 31 个省份用电预测值和实际值的误差

4.3 SaDE-LSTM 算法预测结果

如图 15 所示,随数据量增大,SaDE-LSTM 算法的训练结果与实际数据的重合度增加,偏离控制在 0 ~ 10% 以内,训练数据从整体略高于实际值到整体略低于实际值变化。在后续数据预测上数据重合度依然表现良好,整体趋势基本一致。在负荷低谷处的预测,误差基本为 0,但是在几个负荷高峰仍然存在预测结果低于实际负荷的情况,最高误差为 11%。




图 15 采用 SaDE-LSTM 算法 2004—2018 年我国 31 个省份用电预测结果和实际数据对比

4.4 多种算法对比分析

图 16 展示了测试集 2018 年 3 月至 2018 年 12 月的实际电力负荷曲线与分别采用自回归综合移动平均模型,误差反向传播算法(back propagation,BP),利用自适应差分进化算法优化误差反向传播算法(SaDE-BP),支持向量机,利用自适应差分进化算法优化支持向量机算法(SaDE-SVM),长短期记忆算法,利用自适应差分进化算法优化长短期记忆算法(SaDE-LSTM)预测负荷曲线的贴合情况,其中采用误差反向传播算法,长短期记忆算法,SaDE-SVM,支持向量机算法的预测结果与实际情况相差很大,表明这些智能算法并不适用于该样本集的短期电力负荷预测情景。而自回归综合移动平均模型,SaDE-BP,SaDE-LSTM 算法预测结果与实际趋势一致性较好,说明,这些方法对于具有明显时间序列趋势的数据具有更好的拟合效果,其中 SaDE-LSTM 算法预测曲线与实际曲线贴合度最高。




图 16 2018 年我国 31 个省份用电量的多种算法预测负荷与实际负荷对比

图 17 对多种算法的预测结果与实际结果偏离值进行了定量对比分析,通过对比误差反向传播算法,长短期记忆,SaDE-SVM,支持向量机等算法在短期电力负荷预测方面的预测效果,对不同算法的适用性进行了分析。可以看出,尽管误差反向传播算法、支持向量机等智能算法具有一定的优势,但是其在时间序列的预测中并未体现出优势。而单一的长短期记忆算法受参数影响较大,也存在表现不佳的情况。对图 16 中 3 种表现较好的算法的误差进行对比发现,SaDE-LSTM 算法预测结果的每一个点的结果误差基本保持在 0~0.5%之间,最大误差约 1.6%。而自回归综合移动平均算法和 SaDE-BP 算法都有个别数据存在较大误差,通过图 16 可以判断自回归综合移动平均算法的偏离主要在 5 月、7 月、8 月,其最大误差为 4.9%。SaDE-BP 算法在 7 月之后的预测偏离较大,最大误差为 10.4%。因此在短期电力负荷预测上 SaDE-LSTM 算法的准确率最高,表现最佳。

5 结论及展望

5.1 结论

本文提出了一种利用自适应差分进化算法优化长短期记忆算法的混合算法(SaDE-LSTM),在相同场景下,对比分析多种基于机器学习的负荷预测算法和所提出的改进算法的预测结果。在进行时间序列分析的基础上,经过数据训练后,自回归综合移动平均模型,SaDE-BP 算法,SaDE-LSTM 算法在月度短期负荷预测中具有更好表现。其中本文所提出的基于 SaDE-LSTM 的改进算法综合了长短期记忆算法和自适应差分进化算法的优点,弥补了长短期记忆算法搜索效率较低和自适应差分进化算法在长序列预测上准确性不足的缺点,预测短期负荷具有最高的精确的。因此,SaDE-LSTM 算法能够快速寻优,提高收敛精度,从而提高预测精度,为电力系统的发展提供有力支撑。




图 17 2018 年我国 31 个省份用电量的多种算法预测结果与实际结果偏离值比较

5.2 展望

从电力系统角度看,电力调度机构需要不断改进短期负荷预测方法,进一步提高电力负荷预测的精度,减少预测的难度,从而提高发电设备的运转率和保证经济派遣的有效性,实现提高电力系统经济效益,保障电力系统安全有序运行的目的。

从电力市场角度看,在市场主体多元化发展的趋势下,基于用户需求,虚拟电厂、负荷聚合商等新型主体可以基于精确的短期负荷预测水平开展商业模式探索^[32],一方面为其他主体提供负荷预测服务扩大收益来源,一方面能够利用负荷预测结果对聚合资源灵活调配,为电力系统提供平衡服务,最终达到利用市场化手段保障电力供需平衡的目标。

从电网角度看,预测中长期地区负荷结构变化,有助于配电网规划布局;准确预测短期负荷高峰^[33],做好发、输、配、用各环节的调度,可以防止电力缺口出现,提高电网应对极端天气和特殊事件的能力,从而保障居民、工业用电,维护电网安全平稳运行。

参考文献:

- [1] 李晶. 中国能源消费与经济高质量发展的关系及影响研究[J]. 现代经济探讨, 2022(4): 11-20, 132.
- [2] 熊宁, 肖异瑶, 姚志刚, 等. 基于农村发展模式分析的中长期负荷预测方法[J]. 电力系统及其自动化学报, 2021, 33(3): 94-101.
- [3] 李玉凯, 韩佳兵, 于春浩, 等. 基于随机森林和长短期记忆网络多元负荷预测的综合能源三层规划调度[J]. 现代电力, 2021, 38(6): 695-703.
- [4] 于浩, 秦文萍, 魏斌, 等. 考虑预测误差的交直流混合微电网经济调度策略[J]. 电网技术, 2019, 43(11): 3987-3996.
- [5] 尹春杰, 肖发达, 李鹏飞, 等. 基于 LSTM 神经网络的区域微网短期负荷预测[J]. 计算机与现代化, 2022(4): 7-11.
- [6] 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.
- [7] 孟醒, 邵剑飞. 基于深度学习的电力负荷预测方法综述[J]. 电视技术, 2022, 46(1): 44-51.
- [8] 贾庆兰. 基于概率统计的电力负荷时间序列预测模型[J]. 现代电子技术, 2020, 43(21): 179-182, 186.
- [9] 梁荣, 王洪涛, 吴奎华, 等. 基于神经网络和 ARIMA 模型的冷热电短期负荷预测[J]. 电力系统及其自动化学报, 2020, 32(3): 52-58.
- [10] LIU X, LIN Z, FENG Z. Short-term offshore wind speed forecast by seasonal ARIMA-A comparison against GRU and LSTM[J]. Energies, 2021, 14(23): 7943.
- [11] 李文静, 王潇潇. 基于简化型 LSTM 神经网络的时间序列预测方法[J]. 北京工业大学学报, 2021, 47(5): 480-488.
- [12] GUO W, CHE L, SHAHIDEHPOUR M, et al. Machine-Learning based methods in short-term load forecasting[J]. The Electricity Journal, 2021, 34(1): 106884-106890.
- [13] FAN G, YU M, DONG S, et al. Forecasting short-term electricity load using hybrid support vector regression with grey catastrophe and random forest modeling[J]. Utilities Policy, 2021, 73: 101294-101311.
- [14] 冯荣强, 赵磊, 杨勇, 等. 计及电价和 Attention 机制的 LSTM 短期负荷预测模型[J]. 科技通报, 2020, 36(11): 57-62, 68.
- [15] MEGN M, NIU D, SUN W. Forecasting monthly electric energy consumption using feature extraction[J]. Energies, 2011, 4(10): 1495-1507.
- [16] HE Y, QIN S, WANG S, et al. Electricity consumption probability density forecasting method based on LASSO-Quantile Regression Neural Network[J]. Applied Energy, 2019, 233-234(1): 565-575.
- [17] 陈振宇, 杨斌, 阮文俊, 等. 基于 LSTM 神经网络的短期电能负荷预测[J]. 电力大数据, 2021, 24(4): 8-15.

- [18] 王飞,李正辉,李渝,等. 基于数据序列分辨率压缩尺度优化的月度电量预测方法[J]. 电力系统保护与控制,2020,48(11):62-68.
- [19] 袁保平,徐毅,夏轶炜,等. 基于神经网络和混沌特征选择的短期负荷预测方法[J]. 微型电脑应用,2021,37(3):87-90.
- [20] TVRD ĭ K J, KRIV Ÿ I. Hybrid adaptive differential evolution in partitional clustering [C]//PADMA L, SURESH B, PANIGRAHI K. Proceedings of 17th International Conference on Soft Computing. Salamanca:Springer, New Delhi,2011:1-8.
- [21] NEERAJ, MATHEW J, BEHERA R K. Power load forecasting based on long short term memory-singular spectrum analysis[J]. Energy Systems,2021.
- [22] CHAHLA C, SNOUSSI H, MERGHEM L, et al. A deep learning approach for anomaly detection and prediction in power consumption data[J]. Energy Efficiency,2020,13:1633-1651.
- [23] HOCHREITER S. The vanishing gradient problem during learning recurrent neural nets and problem solutions[J]. International Journal of Uncertainty, Fuzziness and Knowledge-Based Systems,1998,6(2):107-116.
- [24] 荆昱阳,张利强. 基于 Pytorch 的长短期记忆网络实现及应用[J]. 制造业自动化,2021,43(12):167-169,177.
- [25] 查博. 基于 LSTM 神经网络的创新创业发展预测与区域发展比较:以陕西与四川为对象[J]. 科技管理研究,2021,41(19):76-85.
- [26] LI N, WANG Y L, MA W T, et al. A wind power prediction method based on DE-BP neural network[J]. Frontiers in Energy Research,2022,10:844111-844120.
- [27] 汪慎文,丁立新,张文生,等. 差分进化算法研究进展[J]. 武汉大学学报(理学版),2014,60(4):283-292.
- [28] 吴文海,郭晓峰,周思羽,等. 基于随机邻域策略和广义反向学习的自适应差分进化算法[J]. 系统工程与电子技术,2021,43(7):1928-1942.
- [29] 赵杨,熊伟丽. 基于多策略自适应差分进化算法的污水处理过程多目标优化控制[J]. 化工学报,2021,72(4):2167-2177.
- [30] QIN A, SUGANTHAN P N. Self-adaptive differential evolution algorithm for numerical optimization[C]. IEEE Congress on Evolutionary Computation. Edinburgh:IEEE,2005:1785-1791.
- [31] 中华人民共和国国家统计局. 国研网统计数据库[EB/OL]. (2019-05-29)[2021-12-15]. <http://drcnet.jskjwx.org/>.
- [32] 刘林,李苏秀,张桦,等. 能源互联网商业模式迭代体系与方法初探[J]. 中国电力,2022,55(1):203-213.
- [33] 张云飞,闵丽,田侃,等. 基于岭回归的电网调峰需求预测研究[J]. 水电与抽水蓄能,2021,7(6):74-76.

Comparison and Improvement of Short-term Power Load Forecasting Methods Based on Machine Learning

Han Yaxuan Shi Mengshu Huang Yuansheng Liu Dunnan Duan Wenjun

Abstract: To address the demand of the power system for the accuracy of short-term power load forecasting, based on the long short-term memory algorithm, it is further improved using the self-adaptive differential evolution algorithm, thus proposing a hybrid algorithm based on machine learning (SaDE-LSTM) for short-term forecasting of power load. The performance of the improved hybrid algorithm is tested based on monthly social power load data from 2004 to 2018 in China. Firstly, the initial parameters of the long short-term memory algorithm are optimized using the adaptive mutation factor and cross factor of the differential evolutionary algorithm. On this basis, the optimized forecasting results are obtained by training the long short-term memory algorithm with the parameters obtained from the optimization search. To prove its superiority, support vector machine (SVM), back propagation neural network, and autoregressive integrated moving average algorithms are used to predict based on the same group of data. The comparative analysis of the prediction results of each method and the real results proves that the SaDE-LSTM algorithm requires less time series data volume and at the same time has higher prediction accuracy compared with the those traditional algorithms. This improved algorithm can provide a reference for subjects who have a need for small sample and high accuracy forecasting, such as virtual power plants and load aggregators involved in power system dispatch.

Key words: SaDE; LSTM; time series analysis; power load forecasting; long short-term memory; differential evolution