

分时电价下考虑储能调度因素的短期负荷预测模型

李卫国¹, 陈立铭¹, 张师¹, 徐备², 王旭光¹, 刘宏伟¹

(1. 东北电力大学电气工程学院, 吉林 吉林 132012; 2. 中国南方电网有限责任公司肇庆供电局, 广东 肇庆 526000)

摘要: 影响电力系统短期负荷预测的因素有多种, 因此在进行短期负荷预测时, 考虑的因素种类越多, 预测的精度越高。在考虑环境因素的基础上, 构建分时电价下考虑储能调度因素的改进鲸鱼算法优化 Elman 神经网络模型。在智能电网下, 由于储能调度能够使传统的负荷曲线发生改变, 首先在基于分时电价的基础上构建储能调度模型, 对储能用户在各时段的充放电行为进行具体分析。然后由于 Elman 神经网络具有收敛速度慢、容易陷入局部最优等缺点, 提出了一种改进的鲸鱼算法(MWOA)用于优化神经网络的权值和阈值, 进一步提高了神经网络的收敛速度和全局寻优能力。最后构建考虑储能调度因素的短期负荷预测模型, 通过对某地电网 2018 年 7 月至 8 月的数据为例进行仿真分析, 并与所提到的其他预测模型进行比较。通过误差结果分析可知所提方法的预测精度更高, 收敛速度更快。

关键词: 短期负荷预测; 储能调度; Elman 神经网络; 鲸鱼算法; 分时电价

Short-term load forecasting model considering energy storage scheduling factors under time-sharing price

LI Weiguo¹, CHEN Liming¹, ZHANG Shi¹, XU Bei², WANG Xuguang¹, LIU Hongwei¹

(1. School of Electrical Engineering, Northeast Electric Power University, Jilin 132012, China;

2. Zhaoqing Power Supply Company, China Southern Power Grid Co., Ltd., Zhaoqing 526000, China)

Abstract: There are many factors affecting the short-term load forecasting of power systems, therefore, when performing short-term load forecasting, the more types of factors are considered, the higher the accuracy of predicting is. On the basis of considering environmental factors, the improved whale algorithm optimization Elman neural network model considering the factors of energy storage scheduling under time-of-use price is constructed. Under the smart grid, because the energy storage scheduling can change the traditional load curve, firstly, based on the time-sharing price, the energy storage scheduling model is constructed to analyze the charging and discharging behavior of the energy storage users in each period. Then, because the Elman neural network has the disadvantages of slow convergence and easy to fall into local optimum, a Modified Whale Optimization Algorithm (MWOA) is proposed to optimize the weight and threshold of the neural network, which further improves the convergence and global search of the neural network excellent ability. Finally, constructing a short-term load forecasting model considering energy storage scheduling factors, the analysis of the data of a certain power grid from July to August of 2018 is carried out and compared with other prediction models mentioned. The error results analysis shows that the proposed method has higher prediction accuracy and faster convergence.

This work is supported by Science and Technology Project of State Grid Corporation of China (No. SGTJDK00DWJS1700034) "Research and Application of Stochastic Power Sources Oriented Multiple Load Active Response and Predictive Control Technology".

Key words: short-term load forecasting; energy storage scheduling; Elman neural network; whale algorithm; time-sharing price

0 引言

精准的负荷预测和调度是电力系统稳定运行

基金项目: 国家电网公司科技项目资助 (SGTJDK00DWJS1700034)
“面向随机性电源的多元负荷主动响应及预测控制技术研究与应用”

的基础。但传统的负荷调度方法是直接通过控制发电量的多少进行电能的供应, 导致在负荷峰时段发电量小于用电量, 负荷谷时段发电量远远高于用电量, 造成设备的利用率低、资源的过度浪费^[1-3]。与国家倡导的资源节约政策相违背, 不满足电网规定的经济性原则。随着智能电网的出现, 一些新的解决措施不断地产生例如需求响应、储能技术等。这

些措施弥补了传统负荷调度的不足,并且可调度资源在电网中扮演着越来越重要的角色,逐渐成为资源调度的一部分。储能的应用可以使电量的供需保持平衡,控制储能用户在负荷峰时段放电,负荷谷时段充电,可以使资源得到高效利用。还可以延缓电力系统设施的更换与扩建,减少投资,具有一定的经济性。目前储能调度在电力市场中参与越来越多的项目,主要应用在系统的一次调频、二次调频,解决线路末端低电压问题,提高电能质量以及消纳可再生能源等方面^[4-6]。

但是由于储能设备接入电力系统中造成传统的负荷曲线发生一定程度的变化,给短期负荷预测带来一定的难度,导致预测精度下降。而且极少的文献研究关于储能调度对短期负荷预测造成的影响。文献[7]在进行短期负荷预测时,将需求响应作为短期负荷预测的影响因素。通过对需求响应负荷特性进行分析,构建需求响应模型;然后构建 RBF 神经网络预测模型,将需求响应作为预测模型的输入变量,并利用构建好的模型对负荷数据进行预测。根据仿真结果可以发现,虽然该模型提高了短期负荷预测的精度,但未考虑储能调度因素对短期负荷预测的影响,因此精度具有一定的误差。文献[8]研究分布式储能对配电网电压稳定的影响。当分布式储能接入配电网时,通过构建电压稳定评价指标模型计算电压的值并判断是否满足配电网电压稳定性要求。文献[9]研究在进行短期负荷预测时,通过频谱分析对需求响应特性进行分析,并构建 Elman 神经网络预测模型,然后对某地电网进行短期负荷预测。根据仿真结果发现,虽然 Elman 神经网络具有较高的预测精度,但具有收敛速度慢,容易陷入局部最优等缺点,影响预测结果。文献[10]针对 BP 神经网络在短期负荷预测时具有收敛速度慢、容易陷入局部最优等缺点。构建了一种改进的 BP 神经网络短期负荷预测模型。通过将输入层与输出层直接相连提高了 BP 神经网络的收敛速度;通过改进的果蝇算法对 BP 神经网络的权值和阈值进行优化,增强全局寻优能力,提高了短期负荷预测精度。但是文中未考虑电价因素和储能因素对短期负荷预测的影响,导致预测精度不高。根据以上论述可知,由于储能调度的参与,导致短期负荷预测精度大大降低,因此有必要在预测模型中考虑储能调度这一影响因素。

基于以上文献研究,提出了在考虑环境因素的基础上,构建分时电价下考虑储能调度的改进鲸鱼算法优化 Elman 神经网络模型。首先在基于分时电价的基础上,构建储能调度模型,对储能用户各时

段的充放电行为进行具体分析;然后基于 Elman 神经网络具有收敛速度慢且容易陷入局部最优等缺点,提出了一种改进的鲸鱼算法(MWOA)用于优化神经网络的权值和阈值,提高了神经网络的收敛速度、全局优化能力,达到更高的预测精度。经仿真分析结果可以得出,在短期负荷预测模型中加入储能调度因素可显著提高预测精度,证明本文所提方法的有效性。

1 储能调度模型

1.1 分时电价下的储能调度模型

储能作为一种灵活、高效、可调度的资源,可参与需求响应。由于储能是一种较为分散的资源,因此可通过负荷聚类商(Load aggregation, LA)进行统一调度,将可参与调度的储能用户聚集到一起,共同进行需求侧管理^[11-13]。与储能用户签订合同的目的是使用户能够及时地参与负荷分配,保证电力系统的稳定运行。而 LA 可充当电力市场与储能用户的媒介,为电力市场吸引客户共同参与负荷调配。LA 也能够为储能用户制定合理的投标计划、辅助用户签订合同以及监督用户完成合同的情况^[14]。

基于电力市场实施分时电价政策,储能用户可根据不同时段的电价完成充放电。一般来说,在负荷峰时段的电价高于其他时段,而负荷谷时段的电价低于其他时段。因此储能用户可在负荷峰时段进行放电,负荷谷时段进行充电。既可以满足合同的要求,又能获取最大的经济利益^[15-17]。根据分时电价下的储能调度模型,在最优利润情况下对储能充放电进行合理安排。

放电时段储能用户最大收益为

$$W_{\max} = \sum_{t \in T_c} (\rho_t Q_m - W_t) \quad (1)$$

式中: ρ_t 表示电价; Q_m 表示储能用户在 t 时刻的电能释放量; W_t 表示 LA 在 t 时刻的交易成本; T_c 表示放电时段。

电能释放量 Q_m 的表达式为

$$Q_m = \sum_{k \in N} P_{kt} \quad (2)$$

式中, P_{kt} 表示合同 k 在 t 时刻的电能释放量。

交易成本 W_t 的表达式为

$$W_t = \sum_{t \in N} c_{kt} P_{kt} \quad (3)$$

式中, c_{kt} 表示放电合同 k 在 t 时刻的价格。

这里 P_{kt} 的大小会受到储能装置的制约,即

$$0 \leq P_{kt} \leq \eta_{\max} P_{kt} \quad (4)$$

式中, η_{kt} 表示储能装置最大放电效率。

$$0 \leq \sum_{t \in T} P_{kt} \leq E_{k\max} \quad (5)$$

式中, $E_{k\max}$ 表示储能装置的最大存储电量。

充电时段储能用户最优经济收益为

$$W_{\min} = \sum_{t \in T_f, k \in N} (c_{kt} - \rho_t) Q_n \quad (6)$$

式中, Q_n 表示储能用户 k 合同 t 时刻的充电量; T_f 表示充电时段。

$$0 \leq \sum_{t \in T_c} P_{kt} \leq \sum_{t \in T_f} Q_n \quad (7)$$

根据储能调度模型可以制定分时电价下储能调度合同, 如图 1 所示。由图 1 可知, 在不同时刻不同电价下实施储能合同可以实现削峰填谷。

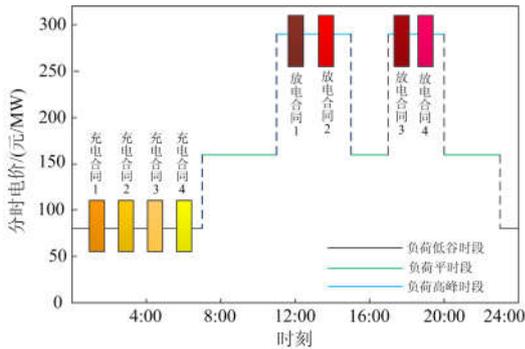


图 1 分时电价下储能调度合同

Fig. 1 Energy storage and dispatching contract under time-sharing price

1.2 储能调度对短期负荷预测的影响

从电力负荷曲线可以看出, 峰时段的负荷量远远高于谷时段的负荷量。因此在峰时段时, 电网需要增加数台机组满足供电量的要求, 而在谷时段又需要撤去数台机组, 循环操作会对电力系统的稳定性造成不利的影 响。储能调度的应用能够在负荷峰时段控制其放电, 在谷时段控制其充电, 减少机组的投切次数, 提高系统的稳定性。如图 2 所示为储能参与调度后的日负荷曲线。由图 2 可以发现, 储能参与后, 峰负荷量减少, 谷负荷量增大。因此储能调度的加入引起原始的负荷曲线发生变化, 对短期负荷预测造成一定的影响, 使预测精度下降。因此

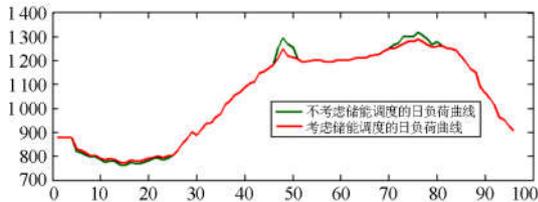


图 2 储能参与调度后的日负荷曲线

Fig. 2 Daily load curve after energy storage participated in dispatching

在进行短期负荷预测时, 有必要考虑储能调度这一影响因素。

2 改进的 Elman-NN 模型的构建

2.1 Elman-NN 模型的构建

Elman-NN 是一种具有局部记忆单元和局部反馈连接的动态递归神经网络^[18]。它比 BP 神经网络多了一层承接层, 即由输入层、隐含层、承接层和输出层构成。输入层将数据接收并传输到隐含层; 隐含层对数据进行加权迭代, 将处理后的数据传递给输出层; 承接层是将隐含层处理的数据进行延迟与存储, 再回传给隐含层, 反复循环使神经网络具有动态处理信息的能力。如图 3 所示为 Elman 神经网络结构图。

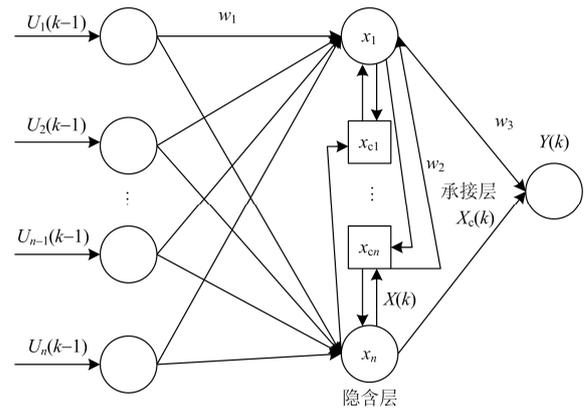


图 3 Elman-NN 结构图

Fig. 3 Elman-NN structure diagram

由图 3 知, 假设网络有 n 个输入, m 个输出, r 个神经元。且输入层与隐含层之间的权值为 w_1 , 承接层与隐含层之间的权值为 w_2 , 隐含层与输出层之间的权值为 w_3 。则有

$$\begin{cases} \mathbf{x}(k) = f(w_1 \mathbf{u}(k-1) + w_2 \mathbf{x}_c(k)) \\ \mathbf{x}_c(k) = \mathbf{x}(k-1) \\ \mathbf{y}(k) = g(w_3 \mathbf{x}(k)) \end{cases} \quad (8)$$

式中: $f(\cdot)$ 表示隐含层的传递函数, 本文选用 S 型函数; $g(\cdot)$ 表示输出层的传递函数, 选用线性函数。

则 S 型函数的表达式为

$$f(x) = \frac{1}{1 + e^{-x}} \quad (9)$$

误差函数 e 的表达式为

$$e = \frac{1}{2} \sum_{i=1}^n [d(k) - y(k)]^2 \quad (10)$$

式中, $d(k)$ 表示目标输出量。

Elman-NN 具有收敛速度较慢, 容易陷入局部

最优的缺点,对预测精度造成一定的影响。因此本文对其进行优化,增强全局寻优能力。

2.2 鲸鱼优化算法(WOA)

WOA是由某学者在2016年提出的一种新型的群体智能算法,是一种根据座头鲸觅食行为的全局优化算法。WOA通过搜索代理实现问题的全局最优,即通过初始随机给定的一组解,然后不断地进行优化,直到出现一组最优解为止。座头鲸能够识别猎物的位置,然后对猎物进行攻击并显示自己的位置所在。WOA步骤如下。

(1) 猎物包围

每一个座头鲸相当于一个搜索代理,搜索代理识别到的目标猎物均可成为待选择的最优解,然后确定位置所在。其他的搜索代理通过目标猎物不断地更新自己的位置。用数学模型表示为

$$D = |CX^*(t) - X(t)| \quad (11)$$

$$X(t+1) = X^*(t) - AD \quad (12)$$

式中: D 表示搜索代理与目标猎物的距离; t 表示当前迭代次数; A 、 C 表示系数向量; $X^*(t)$ 表示目前最优解位置向量; $X(t)$ 表示当前位置向量。

随着最优解的不断出现, A 、 C 将不断更新。表达式为

$$A = 2r_a - a \quad (13)$$

$$C = 2r_c \quad (14)$$

式中: r_a, r_c 的取值范围为[0,1]。

(2) 狩猎策略

座头鲸在追寻猎物时以螺旋路径前进,并且在移动的过程中吐气泡形成陷阱用于抓捕猎物。

螺旋路径用数学模型表示为

$$X_{(t+1)} = |X^*(t) - X(t)|e^{bl} \cos(2\pi l) + X^*(t) \quad (15)$$

式中: b 表示描述螺旋形状的常量; l 的取值范围为[-1,1]。

对座头鲸的狩猎行为进行描述,更新位置后的数学模型表达式为

$$X_{(t+1)} = \begin{cases} X^*(t) - AD & p < 0.5 \\ |X^*(t) - X(t)|e^{bl} \cos(2\pi l) + X^*(t) & p \geq 0.5 \end{cases} \quad (16)$$

式中, p 的取值范围为[0,1]。

(3) 猎物搜索

座头鲸在觅食的过程中,还需要不断地进行随机搜索猎物。

可用数学模型进行描述,其表达式为

$$D = |CX_{\text{rand}}(t) - X(t)| \quad (17)$$

$$X(t+1) = X_{\text{rand}}(t) - AD \quad (18)$$

式中, X_{rand} 表示随机选择的座头鲸位置向量。

2.3 改进的鲸鱼优化算法(MWOA)

由上述式子可以发现,鲸鱼算法中只有两个可变的参数 A 和 C ,因此该方法具有操作容易、调节方便的特点。由于在WOA算法中采用自适应变化策略,使其具有搜索能力强,容易跳出陷入局部最优的特点。但是由于 A 的值是随机给定的,导致WOA在迭代的过程中存在收敛速度慢、精度低的缺点。因此本文对WOA进行改进,以达到提高速度与精度的效果。

文献[19]提出将惯性权重引入到鲸鱼算法中。通过仿真分析发现,不同的惯性权重对鲸鱼个体的优化效果不同。增大惯性权重能够提高粒子的全局寻优能力,而减小惯性权重能够提高粒子的局部寻优能力以及收敛速度。因此可知,适当的惯性权重大小既可以加强寻优能力又可以提高收敛速度。基于此,本文将WOA算法中引入非线性自适应权重,其表达式为

$$\omega(t)_i = \begin{cases} \omega_1 - \frac{(\omega_2 - \omega_1)}{T_{\max}} \cdot \frac{f(t)_i - f(t)_{\min}}{f(t)_{\max} - f(t)_{\text{avg}}} & f(t)_i < f(t)_{\text{avg}} \\ \omega_2 + \frac{(\omega_2 - \omega_1)}{T_{\max}} \cdot \frac{f(t)_i - f(t)_{\min}}{f(t)_{\max} - f(t)_{\min}} & f(t)_i \geq f(t)_{\text{avg}} \end{cases} \quad (19)$$

式中: $\omega(t)_i$ 表示第 i 个搜索代理在第 t 次迭代的权重; T_{\max} 表示最大迭代次数; ω_1, ω_2 表示初始最小权重和最大权重; $f(t)_{\min}, f(t)_{\text{avg}}, f(t)_{\max}$ 表示第 t 次迭代种群最小适应度、平均适应度以及最大适应度。

由式(19)可知,当 $f(t)_i < f(t)_{\text{avg}}$ 时,权重 ω 的值比较小,可以使搜索代理在最优解邻域空间中精细搜索;当 $f(t)_i \geq f(t)_{\text{avg}}$ 时,权重 ω 的值比较大,可以使搜索代理在大空间内寻找最优解。权重 ω 随着种群平均适应度的改变而自动地发生变化,有效地使WOA算法达到收敛速度快、全局寻优能力强的特点。

引入非线性自适应权重后的位置更新表达式为

$$X_{(t+1)} = \begin{cases} \omega(t)X^*(t) - AD, & p < 0.5 \\ |X^*(t) - X(t)|e^{bl} \cos(2\pi l) + \omega(t)X^*(t), & p \geq 0.5 \end{cases} \quad (20)$$

2.4 MWOA 优化 Elman-NN

利用神经网络进行负荷预测时,首先需要设置神经网络的初始权值和阈值。由于权值与阈值的选取是随机的,容易使神经网络陷入局部最优。因此

本文利用 MWOA 优化 Elman-NN 的初始参数, 然后在训练的过程中不断地改变网络的权值和阈值, 最终得到全局最优解。利用 MWOA 优化 Elman-NN 的流程图如图 4 所示。

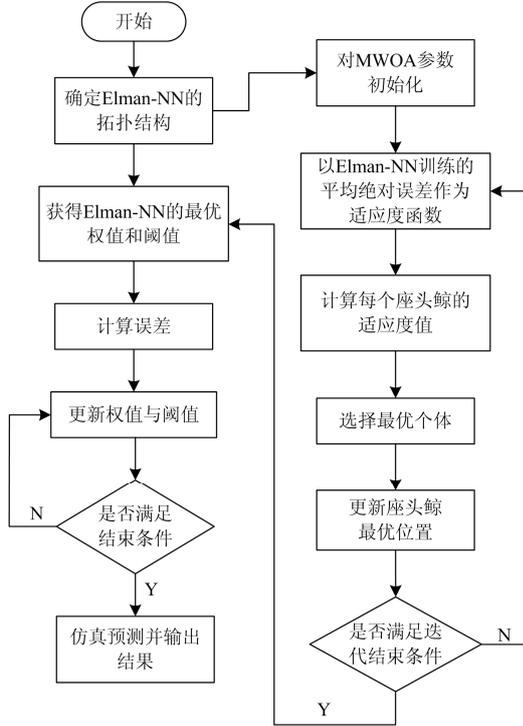


图 4 MWOA 优化 Elman-NN 流程图

Fig. 4 Flow chart of Elman-NN optimization for MWOA

3 考虑储能调度因素的短期负荷预测模型

3.1 预测样本数据

影响短期负荷变化的因素主要有温度、相对湿度、季节变化、日期类型、电价以及储能调度等^[20]。因此在构建改进的 Elman-NN 预测模型时, 应充分考虑这些因素对短期负荷预测造成的影响。在处理历史负荷数据时, 距离预测日较远的负荷数据对负荷预测产生的影响较小, 因此所占的权重越小, 在预测模型中赋予较小的权值, 并对一天中各时刻建立预测模型^[21]。本文所选取的输入变量有: 前一天的最高温度 T_{\max} 、平均温度 T_{ave} 、最低温度 T_{\min} 、日期种类、相对湿度、分时电价和储能调度数据、前一天各预测点的负荷数据; 预测当日的最高温度 T_{\max} 、平均温度 T_{ave} 、最低温度 T_{\min} 、日期种类、相对湿度、分时电价和储能调度数据。

将以上数据作为神经网络预测模型的输入变量, 循环迭代后得到的负荷数据作为输出量。

3.2 数据的预处理

由于上述所提到的各类影响因素之间的单位和量纲不同, 因此需要进行归一化处理, 使得到的

值在[0,1]之间, 有利于提高神经网络的训练速度与预测效果^[22-23]。

对温度、相对湿度、电价和负荷数据进行归一化处理的表达式为

$$x' = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (21)$$

式中: x' 表示归一化后的值; x_{\max} 表示归一化前数据的最大值; x_{\min} 表示归一化前数据的最小值。

对储能充放电数据进行归一化处理的表达式为

$$s' = \frac{s - l_{\min}}{l_{\max} - l_{\min}} \quad (22)$$

式中: s, s' 表示对储能数据归一化前后的结果; l_{\max}, l_{\min} 表示负荷数据的最大值与最小值。

日期类型的设置为: 周一到周五为 1, 周六、周日为 0.5。

季节的设置: 夏季与冬季为 1, 春季与秋季为 0.8。

3.3 模型效果的评价指标

本文选用平均相对误差 E_{MAPE} 、均方根误差 E_{RMSE} 、平均绝对误差 E_{MAE} 和达到收敛需要的时间 t 对预测模型的精度进行评估^[24]。

$$E_{\text{MAPE}} = \frac{1}{n} \sum_{t=1}^n \frac{|x_t - x'_t|}{|x_t|} \quad (23)$$

$$E_{\text{RMSE}} = \sqrt{\frac{1}{n} \sum_{t=1}^n (x_t - x'_t)^2} \quad (24)$$

$$E_{\text{MAE}} = \frac{1}{n} \sum_{t=1}^n |x_t - x'_t| \quad (25)$$

式中: x_t 表示原始负荷值; x'_t 表示预测后的负荷值。

4 算例分析

4.1 实验数据分析

结合某地区电网 2018 年 7 月 1 日至 8 月 1 日共 31 天的短期负荷数据作为实验样本数据。本文提到的日短期负荷数据是每隔 15 min 采集一次负荷数据作为一个点, 一天 24 个小时共 96 点。以 7 月 1 日到 7 月 31 日共 30 天 2 880 个点作为训练数据, 通过本文构建的预测模型对 8 月 1 日各点的负荷进行预测。然后将预测的负荷数据与 8 月 1 日实际的负荷数据进行比较, 计算本文所提方法的预测精度。

为了证明本文所提方法能够提高短期负荷预测的精度, 利用其他预测模型对实验数据进行训练预测, 通过计算各模型的平均相对误差 E_{MAPE} 、均方根误差 E_{RMSE} 和平均绝对误差 E_{MAE} , 然后进行比较,

验证本文所提方法的有效性。本文设置的模型有：
 P1, 未考虑储能调度因素的 Elman-NN 预测模型；
 P2, 考虑储能调度因素的 Elman-NN 预测模型；
 P3, 未考虑储能调度因素的改进鲸鱼算法优化 Elman-NN 预测模型；
 P4, 考虑储能调度因素的改进鲸鱼算法优化 Elman-NN 预测模型。

Elman-NN 预测模型的参数设置：隐含层神经元的数目设置为 25，动态因子取 0.9，学习速率为 0.01，目标误差设置为 0.005，最大训练次数设置为 5 000。输入神经元数量的设置如表 1 所示。

前一天的最高温度 T_{max} 、平均温度 T_{ave} 、最低温度 T_{min} 、日期种类、相对湿度、分时电价和储能调度数据、前一天预测点的负荷数据；预测当日的最高温度 T_{max} 、平均温度 T_{ave} 、最低温度 T_{min} 、日期种类、相对湿度、分时电价和储能调度数据。

表 1 网络的输入变量

Table 1 Network input variables	
输入神经元	网络输入变量
1	预测日的最高温度
2	预测日的平均温度
3	预测日的最低温度
4	预测日的日期种类
5	预测日的相对湿度
6~7	预测日的分时电价
8~9	预测日的储能调度数据
10	前一天的最高温度
11	前一天的平均温度
12	前一天的最低温度
13	前一天的日期类型
14	前一天的相对湿度
15	前一天的分时电价
16	前一天的储能调度因素
17~18	前一天的负荷数据

4.2 实验结果分析

为了证明考虑储能调度因素的短期负荷预测模型能够提高预测精度，本文利用某地区电网 2018 年 7 月份数据进行仿真，并与未考虑储能调度因素的短期负荷预测模型比较。为了证明改进的 Elman-NN 模型能够提高收敛速度，通过与传统的 Elman-NN 模型比较达到收敛所需要的时间便可得出结论。通过在 Matlab2014a 仿真分析，得到的预测结果如图 5 所示，负荷精度结果如表 2 所示。

根据 P1 与 P2(P3 与 P4)比较可知，在短期负荷预测模型中考虑储能调度能够提高预测精度。根据 P1

与 P3(P2 与 P4)比较可知，改进的 Elman-NN 模型相比于传统的 Elman-NN 模型收敛时间明显缩短，因此收敛速度明显提高。根据表 2 可知，P4 模型得到的各相误差均优于 P1、P2 和 P3，证明了本文所提方法的有效性。

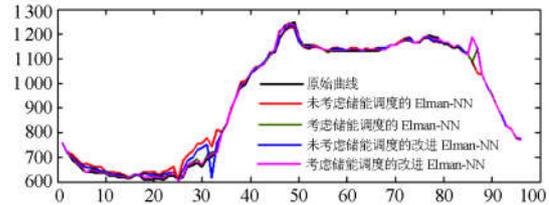


图 5 负荷预测结果

Fig. 5 Load prediction results

表 2 负荷精度对比

Table 2 Comparison of load accuracy

	P1	P2	P3	P4
E_{MAE}/MW	8.97	5.44	7.86	3.97
E_{RMSE}/MW	31.45	25.12	27.01	20.01
$E_{MAPE}/\%$	4.87	2.35	4.41	1.47
收敛时间/s	15.75	17.34	12.08	12.96

5 结论

为了提高短期负荷预测的精度，本文构建分时电价下考虑储能调度因素的改进 Elman-NN 预测模型，并通过实际算例分析得到以下结论：

(1) 通过构建分时电价下的储能调度模型可知，负荷聚类商利用储能调度使储能用户在电价高时放电、电价低时充电，起到降低峰谷差的作用。但储能的应用导致传统的负荷曲线发生变化，因此在进行短期负荷预测时需考虑储能调度因素的影响。

(2) 利用传统的 Elman-NN 模型进行预测时，具有收敛速度慢、容易陷入局部最优的缺点。本文利用 MWOA 算法优化 Elman-NN 预测模型，有效地提高网络的收敛速度和全局寻优能力。

(3) 通过算例仿真分析，并与其他模型进行比较可知，考虑储能调度因素的改进 Elman-NN 模型具有更高的预测精度。

利用本文所提方法可提高短期负荷预测精度，可应用于电网负荷预测。如何进一步提高预测精度和收敛速度是继续研究的内容所在。

参考文献

[1] PARVANIA M, FOTUHI-FIRUZABAD M, SHAHIDEHPUR M. Optimal demand response aggregation in wholesale electricity markets[J]. IEEE

- Transactions on Smart Grid, 2013, 4(4): 1957-1965.
- [2] GARULLI A, PAOLETTI S, VICINO A. Models and techniques for electric load forecasting in the presence of demand response[J]. IEEE Transactions on Control Systems Technology, 2015, 23(3): 1087-1097.
- [3] 王剑晓, 钟海旺, 夏清. 基于成本—效益分析的温控负荷需求响应模型与方法[J]. 电力系统自动化, 2016, 40(5): 45-53.
WANG Jianxiao, ZHONG Haiwang, XIA Qing. Model and method of temperature control load demand response based on cost-benefit analysis[J]. Automation of Electric Power Systems, 2016, 40(5): 45-53.
- [4] 杜鹏, 米增强, 贾雨龙. 基于网损灵敏度方差的配电网分布式储能位置与容量优化配置方法[J]. 电力系统保护与控制, 2019, 47(6): 103-109.
DU Peng, MI Zengqiang, JIA Yulong. Optimal allocation method of distributed energy storage location and capacity in distribution network based on sensitivity variance of network loss[J]. Power System Protection and Control, 2019, 47(6): 103-109.
- [5] 杨欢红, 王洁. 基于灰靶决策和多目标布谷鸟算法的微电网分布式电源鲁棒优化[J]. 电力系统保护与控制, 2019, 47(1): 20-27.
YANG Huanhong, WANG Jie. Robust optimization of microgrid distributed power supply based on grey target decision and multi-target cuckoo algorithm[J]. Power System Protection and Control, 2019, 47(1): 20-27.
- [6] 齐先军, 程桥, 吴红斌. 激励型需求响应对配电网运行可靠性的影响[J]. 电工技术学报, 2018, 33(22): 5319-5326.
QI Xianjun, CHENG Qiao, WU Hongbin. Influence of incentive demand response on operation reliability of distribution network[J]. Transactions of China Electrotechnical Society, 2018, 33(22): 5319-5326.
- [7] 张智晟, 于道林. 考虑需求响应综合影响因素的RBF-NN短期负荷预测模型[J]. 中国电机工程学报, 2018, 38(6): 1631-1638, 1899.
ZHANG Zhisheng, YU Daolin. RBF-NN short-term load prediction model considering the comprehensive influence factors of demand response[J]. Proceedings of the CSEE, 2018, 38(6): 1631-1638, 1899.
- [8] 王铃, 徐备, 张师. 分布式储能对配电网电压稳定的影响分析[J]. 广东电力, 2017, 30(5): 48-51.
WANG Qian, XU Bei, ZHANG Shi. Analysis on the influence of distributed energy storage on voltage stability of distribution network[J]. Guangdong Electric Power, 2017, 30(5): 48-51.
- [9] 于道林, 张智晟, 韩少晓. 计及需求响应的Elman-NN短期负荷预测模型研究[J]. 电工电能新技术, 2017, 36(4): 59-65.
YU Daolin, ZHANG Zhisheng, HAN Shaoxiao. Research on Elman-NN short-term load prediction model considering demand response[J]. New Technology of Electrical Energy, 2017, 36(4): 59-65.
- [10] 王亚琴, 王耀力, 王力波. 一种改进果蝇算法优化神经网络短期负荷预测模型[J]. 电测与仪表, 2018, 55(22): 13-18, 24.
WANG Yaqin, WANG Yaoli, WANG Libo. A modified fruit fly algorithm to optimize the short-term load prediction model of neural network[J]. Electrical Measurement & Instrumentation, 2018, 55(22): 13-18, 24.
- [11] 田浩, 刘文颖, 王方雨. 基于负荷参与的源荷互动调峰多目标优化方法[J]. 电网与清洁能源, 2018, 34(11): 32-38.
TIAN Hao, LIU Wenyong, WANG Fangyu. Multi-objective optimization method for source-charge interaction peak-sharing based on load participation[J]. Power System and Clean Energy, 2018, 34(11): 32-38.
- [12] 周海军, 肖博文, 周冬. 考虑需求响应的智能微电网日前竞价方案[J]. 电网与清洁能源, 2018, 34(11): 39-44.
ZHOU Haijun, XIAO Bowen, ZHOU Dong. A smart microgrid pre-bidding plan considering demand response[J]. Power System and Clean Energy, 2018, 34(11): 39-44.
- [13] 岳红权, 王建渊, 杨文字. 基于互联网+的充电站配电设备在线监测研究[J]. 电网与清洁能源, 2018, 34(4): 29-35.
YUE Hongquan, WANG Jianyuan, YANG Wenyu. On-line monitoring of power distribution equipment for charging stations based on internet+[J]. Power System and Clean Energy, 2018, 34(4): 29-35.
- [14] 张志义, 余涛, 王德志. 基于集成学习的含电气热商业楼宇群的分时电价求解[J]. 中国电机工程学报, 2019, 39(1): 112-125, 326.
ZHANG Zhiyi, YU Tao, WANG Dezhi. Time-sharing electricity price solution for commercial buildings with electrical heating based on integrated learning[J]. Proceedings of the CSEE, 2019, 39(1): 112-125, 326.
- [15] 杨晓萍, 刘浩杰, 黄强. 考虑分时电价的风光储联合“削峰”优化调度模型[J]. 太阳能学报, 2018, 39(6): 1752-1760.
YANG Xiaoping, LIU Haojie, HUANG Qiang.

- Optimization scheduling model of "peak clipping" in wind-solar storage joint project considering time-sharing electricity price[J]. *Acta Solarica Sinica*, 2008, 39(6): 1752-1760.
- [16] HUANG Wujing, ZHANG Ning, KANG Chongqing. From demand response to integrated demand response: review and prospect of research and application[J]. *Protection and Control of Modern Power Systems*, 2019, 4(4): 148-150. DOI: 10.1186/s41601-019-0126-4.
- [17] MIRZAEI M A, YAZDANKHAH A S, MOHAMMADI-IVATLOO B. Stochastic security constrained operation of wind and hydrogen energy storage systems integrated with price-based demand response[J]. *International Journal of Hydrogen Energy*, 2019, 44(27).
- [18] 周步祥, 罗燕萍, 张百甫. 基于分数阶灰色 Elman 组合模型的中长期负荷预测[J]. *水电能源科学*, 2019, 37(2): 192-195.
ZHOU Buxiang, LUO Yanping, ZHANG Baifu. Medium and long term load prediction based on fractional order gray Elman combination model[J]. *Science of Hydropower and Energy*, 2019, 37(2): 192-195.
- [19] 王永贵, 曲彤彤, 李爽. 基于指数衰减惯性权重的分裂粒子群优化算法[J]. *计算机应用研究*, 2019, 37(4): 1-6.
WANG Yonggui, QU Tongtong, LI Shuang. Split particle swarm optimization algorithm based on exponential decay inertia weight[J]. *Computer Application Research*, 2019, 37(4): 1-6.
- [20] SOLTANI N Y, KIM S J, GIANNAKIS G B. Real-time load elasticity tracking and pricing for electric vehicle charging[J]. *IEEE Transactions on Smart Grid*, 2015, 6(3): 1303-1313.
- [21] LIU Feng, XIANG Changle, WU Huiliu. Asymmetric effect of static radial eccentricity on the vibration characteristics of the rotor system of permanent magnet synchronous motors in electric vehicles[J]. *Nonlinear Dynamics*, 2019, 96(4).
- [22] HEYDARI S, MOHAMMADI-HOSSEININEJAD S M, MIRSAEEDI H. Simultaneous placement of control and protective devices in the presence of emergency demand response programs in smart grid[J]. *International Transactions on Electrical Energy Systems*, 2018, 28(5): 44-48.
- [23] QIAN K, ZHOU C, ALLAN M, et al. Modeling of load demand due to EV battery charging in distribution systems[J]. *IEEE Transactions on Power Systems*, 2011, 26(2): 802-810.
- [24] MURATORI M, RIZZONI G. Residential demand response dynamic energy management and time-varying electricity pricing[J]. *IEEE Transactions on Power Systems*, 2016, 31(2): 1108-1117.

收稿日期: 2019-04-16; 修回日期: 2019-07-11

作者简介:

李卫国 (1970—), 男, 硕士, 副教授, 研究方向为电气设备状态监测研究; E-mail: 1677493048@qq.com

陈立铭 (1993—), 男, 硕士研究生, 研究方向为电力系统短期负荷预测、需求响应; E-mail: 1875155399@qq.com

张 师 (1989—), 男, 硕士, 助理实验师, 研究方向为电力系统规划。E-mail: zs472254835@qq.com

(编辑 姜新丽)