

# 基于 SCM-ANFIS 负荷预测的储能电站 调峰控制策略

王晓东<sup>1</sup>, 苗宜之<sup>1</sup>, 卢爽瑄<sup>2</sup>, 刘颖明<sup>1</sup>

(1. 沈阳工业大学电气工程学院, 沈阳 110870; 2. 沈阳工业大学化工过程自动化学院, 辽阳 111003)

**摘 要:** 针对电池储能调峰控制中预测负荷存在误差较大、峰谷识别不准等问题,提出一种基于基于减法聚类 and 自适应网络模糊推理(SCM-ANFIS)电网负荷预测和调峰目标动态规划相结合的储能电站调峰控制策略。负荷预测中采用减法聚类减少模糊规则数目,并通过混合学习算法训练神经网络参数,从而减小预测计算量,提高预测精度。调峰过程中基于负荷预测信息通过引入分阶段滚动优化,在储能系统容量约束下实现调峰效果最优。基于某区域实际电网负荷数据的算例结果验证预测算法和控制算法的可行性和有效性。

**关键词:** 储能; 负荷预测; 模糊推理; 削峰填谷; 多阶段目标动态规划

**中图分类号:** TM919

**文献标识码:** A

## 0 引 言

间歇性新能源发电大规模并网、负荷峰谷差越来越大等因素使得电网面临的调峰压力日益增大。传统的调峰一般采用火电机组,其成本高、能源利用率低<sup>[1,2]</sup>。大规模储能系统在削峰填谷方面具有较大优势,是解决峰谷差的有效途径之一。

负荷预测精度和调峰目标规划是影响调峰效果的2个关键因素,也是调峰控制研究的重点。负荷预测方面,文献[3]采用小波分解、模糊灰色关联聚类以及神经网络相互配合进行负荷预测,在提高预测精度的同时算法复杂性大幅增加。文献[4]基于气候因素使用 ANN 模型进行负荷预测,预测精度依赖于气候预测偏差。文献[5,6]采用自适应网络模糊推理(ANFIS)用于短期负荷预测。采用该方法进行短期负荷预测的最大问题是输入数据维度高、隶属度函数数目过多。但文献[5,6]就如何确定输入输出、隶属度函数数目等重要信息均未明确说明。文献[7]将 ANFIS 模型和减法聚类的方法用于动力电池的短时峰值功率预测,有较好的预测效果。较动力电池的短时峰值功率,电力系统短期负荷的影响因素更多、更复杂,输入数据维度更高。

现有负荷预测误差受预测参数影响较大,在不同负荷形态下的预测误差也不尽相同。

现有的储能电站调峰控制研究中二次规划是具有代表性的目标规划方法之一<sup>[8]</sup>,通过动态规划进行储能电站充放电控制优化逐渐成为研究特点。文献[9]选择储能电池电量为目标,基于动态规划对调峰进行实时优化,通过限制充放电次数和放电深度达到延长电池寿命的目的。其算例以预测负荷与实际负荷相同为假定条件,这与实际情况相差较大。文献[10,11]针对风电功率波动平滑、终端用户用电费用优化应用,采用动态规划对储能系统充放电进行优化,其应用模式、优化目标和调峰区别较大。

本文针对储能调峰控制中预测负荷存误差较大、峰谷识别不准等问题,提出一种基于减法聚类 and 自适应网络模糊推理(SCM-ANFIS)的电网负荷预测和多阶段调峰目标动态规划相结合的储能电站调峰控制策略,在储能电站安全容量约束下实现最佳的调峰效果,防止出现反调峰现象。

## 1 基于 SCM-ANFIS 的电网负荷预测

为实现在不大幅增加计算量的前提下,提高负

收稿日期: 2018-01-08

基金项目: 国家自然科学基金(51677121); 辽宁省自然科学基金指导计划(201602549); 辽宁省教育厅资助项目(LGD2016031)

通信作者: 卢爽瑄(1978—), 男, 博士、讲师, 主要从事风电机组控制、大规模储能系统及其应用技术方面的研究。lushixuan@yeah.net

荷预测精度,本文综合神经网络的学习算法和模糊推理的算法提出一种 SCM-ANFIS 电网负荷预测方法,基于历史数据进行建模和预测,该方法既有神经网络学习机制,又具有模糊推理的语言推理能力,能通过对训练数据的学习,产生相应的数值解。

### 1.1 数据选择与构建样本

负荷预测一般分为长、中、短期负荷预测,对于储能电站调峰需求,15 min(每天 96 数据点)短期负荷预测就可满足要求。用电负荷一般受到多种因素的影响,人们根据地球自转过着严格的 24 h 规律生活,因此对于相近日期的同一个时刻对应的负荷具有很强的规律性。本文根据相邻日同一时刻的规律性作为输入输出样本构建预测模型。

设输出为预测日第  $i$  天第  $j$  时刻的负荷预测值 ( $P_{i,j}^*$ ),输入依次为第  $i-3$  天第  $j-1$ 、 $j$ 、 $j+1$  时刻负荷实际值 ( $P_{i-3,j-1}$ ,  $P_{i-3,j}$ ,  $P_{i-3,j+1}$ ),第  $i-2$  天第  $j-1$ 、 $j$ 、 $j+1$  时刻负荷实际值 ( $P_{i-2,j-1}$ ,  $P_{i-2,j}$ ,  $P_{i-2,j+1}$ ),第  $i-1$  天第  $j-1$ 、 $j$ 、 $j+1$  时刻负荷实际值 ( $P_{i-1,j-1}$ ,  $P_{i-1,j}$ ,  $P_{i-1,j+1}$ )。一个样本包含 9 个输入和 1 个输出。

由上述规则组成总样本,将总样本通过随机分组,按照 7:1.5:1.5 的比例分成训练集数据矩阵  $X$ 、验证集数据矩阵  $Y$  和测试集数据矩阵  $Z$ ,训练集数据用来训练 ANFIS 模型,验证集数据用来防止模型出现过拟合,测试数据用来测试模型预测的好坏。

### 1.2 ANFIS 预测模型

为了便于描述,以含有两个输入的 ANFIS 模型说明预测过程,其结构如图 1 所示。

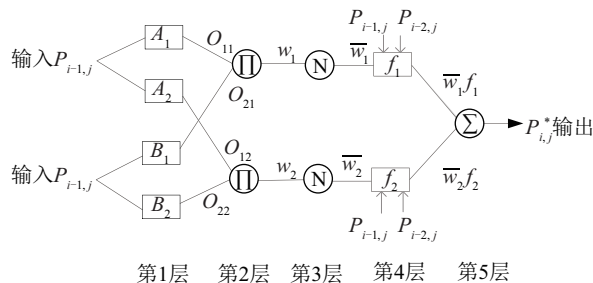


图 1 ANFIS 结构

Fig. 1 Structure of ANFIS

假设预测点为  $P_{i,j}^*$ ,输入为  $P_{i-1,j}$ 、 $P_{i-2,j}$ ,共有 5 层结构:

第 1 层:输入参数并模糊化。 $P_{i-1,j}$ 、 $P_{i-2,j}$  为输

入变量,对应和预测点相关的历史负荷数据, $A_1$ 、 $A_2$  和  $B_1$ 、 $B_2$  分别为与该节点相关的模糊变量, $O_{1k}$ 、 $O_{2k}$  分别是模糊集  $A$ 、 $B$  的隶属度函数:

$$\begin{aligned} O_{1k} &= \mu_{A_k}(P_{i-1,j}), k=1,2 \\ O_{2k} &= \mu_{B_k}(P_{i-2,j}), k=1,2 \end{aligned} \quad (1)$$

隶属度函数一般可选择高斯函数:

$$\mu_{A_k}(x) = e^{-\frac{(x-c)^2}{2\sigma^2}} \quad (2)$$

第 2 层:模糊规则激励强度的计算,将输入信号的隶属度相乘,其输出为:

$$w_k = \mu_{A_k}(P_{i-1,j})\mu_{B_k}(P_{i-2,j}), k=1,2 \quad (3)$$

式中,  $w_k$  ——模糊规则激励强度。

第 3 层:本层节点进行各条规则适用度的归一化计算,即第  $k$  个节点计算第  $k$  条规则的  $w_k$  与全部规则  $w$  值之和的比值:

$$\bar{w}_k = w_k / (w_1 + w_2) \quad (4)$$

式中,  $\bar{w}_k$  ——第  $k$  个节点归一化后的规则适用度。

第 4 层:该层节点  $k$  为自适应节点,计算每条规则的贡献,其输出为:

$$\bar{w}_k f_k = \bar{w}_k (p_k P_{i-1,j} + q_k P_{i-2,j} + r_k) \quad (5)$$

式中,  $f_k$  ——规则的贡献;  $p_k$ 、 $q_k$ 、 $r_k$  ——结论参数。

第 5 层:输出层,该层的单节点是一个固定节点,计算所有输入信号的总输出,即预测日第  $j$  时刻的负荷预测值,计算公式为:

$$P_{i,j}^* = \sum_k \bar{w}_k f_k = \frac{\sum_k w_k f_k}{\sum_k w_k} \quad (6)$$

### 1.3 SCM 减法聚类

减法聚类(SCM)是一种用来估计一组数据中的聚类数量以及聚类中心位置的算法。其得到的聚类估计可用于初始化 ANFIS 模糊聚类以及模型辨识。

ANFIS 模型每个输入变量的隶属度函数个数和模糊规则是依靠经验和不断尝试去确定最合适的参数,需要繁琐的步骤和较长的时间,若采用网格法生成的模糊规则数目将随着输入的增加呈现指数增长,大大超出计算机的计算范围。采用减法聚类对样本数据进行聚类估计,以决定输入变量的隶属度函数个数和模糊规则。可大大简化模型生

成步骤,缩短时间。

减法聚类将训练集数据矩阵  $X$  的每一行  $(P_{i-3,j-1}, P_{i-3,j}, \dots, P_{i-1,j+1}, P_{i,j})$  视为一个数据点  $c_i$ , 若训练集数据包含  $n$  个数据点  $(c_1, \dots, c_n)$ , 并假设数据点已归一化到一个超立方体。

首先每个数据点  $c_i$  都作为聚类中心的候选者计算每个数据点的密度指标:

$$D_i = \sum_{j=1}^n \exp\left(\frac{-\|c_i - c_j\|^2}{(r_a/2)^2}\right) \quad (7)$$

式中,  $D_i$  ——数据点  $c_i$  处的密度指标,  $r_a$  ——邻域半径, 是一个正数, 半径以外的点对该点的密度指标贡献甚微。显然, 如果一个数据点邻域半径内的数据点越多, 则该数据点密度值越大。

然后, 选择密度指标最大的数据点作为第 1 个聚类中心。设  $c_{cl}$  为聚类中心,  $D_{cl}$  为其密度指标。用式(8)对每个数据点的密度指标进行修正:

$$D_i = D_i - D_{cl} \exp\left(\frac{-\|c_i - c_{cl}\|^2}{(r_b/2)^2}\right) \quad (8)$$

式中,  $r_b$  ——密度指标显著较少的邻域。

显然, 靠近第 1 个聚类中心  $c_{cl}$  的数据点的密度指标在修改后显著减少, 难以成为下一个聚类中心。常数  $r_b$  通常大于  $r_a$ , 以避免出现相聚很近的聚类中心。修正密度指标后, 选定下一个聚类中心, 然后再次修正所有密度指标。经过不断重复后, 直到产生期望得到的聚类中心数目。

通过指定  $r_a$ 、 $r_b$  的大小可得到数据的聚类中心, 根据聚类中心的数目来确定模糊结构的模糊规则数量和隶属度函数的数量。

用减法聚类生成模糊结构如图 2 所示。确定模糊结构后通过训练集数据和验证集数据训练模型, 完成模型学习过程, 而后即可用于预测未来一天的负荷, 获得当天实际数据后可以生成新样本用于下一步的模型训练, 新的训练样本可使预测值朝着新的变化趋势靠近。每 24 h 滚动更新一次模型。

## 2 基于多阶段调峰目标动态规划的储能电站调峰控制策略

针对峰谷识别不准导致调峰效果不佳的问题,

本文提出一种基于动态规划思想的多阶段目标动态规划算法, 引入分阶段滚动优化的思想, 将一个规划问题划分为若干阶段, 然后在每一个阶段对一个目标进行规划滚动并进行决策, 每个阶段的决策都将影响到后面阶段的规划和决策。多阶段目标动态规划步骤流程如图 3 所示。

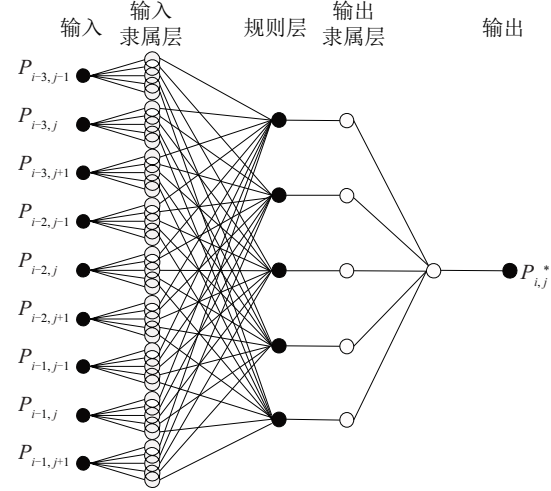


图2 ANFIS结构

Fig. 2 Structure of ANFIS

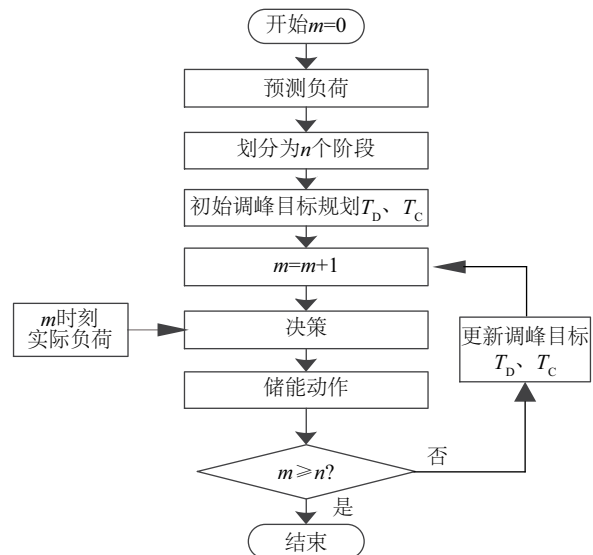


图3 多阶段目标动态规划法步骤流程图

Fig. 3 Multi-stage objective dynamic programming process

根据预测负荷数据, 将整个规划问题划分为  $n$  个阶段, 每个阶段时间跨度为  $\Delta t$ ,  $m$  为当前阶段,  $0 \leq m \leq n$ ,  $m=0$  是准备阶段, 用于初始调峰目标的规划。对于每一个阶段, 需有该阶段的调峰上下限目标  $T_d$ 、 $T_c$ , 以及该阶段的实际负荷, 根据实际负荷与



调峰上下限目标对比得到储能充放电的功率指令。

1) 初始调峰目标规划。初始调峰目标规划是在第一阶段开始前所进行的调峰目标初始化, 求取初始调峰目标令调峰目标更新公式中  $m=0$  即可。

2) 决策与储能动作。对于  $m$  阶段, 得到当前阶段的实际负荷  $P_{act,m}$  后先与调峰目标  $T_D$ 、 $T_C$  比较, 有以下 3 种情况: 如果  $P_{act,m} < T_C$ , 则执行充电策略, 储能动作指令  $P_{action} = P_{Caction,m}$ ; 如果  $P_{act,m} > T_D$ , 则执行放电策略, 动作指令  $P_{action} = P_{Daction,m}$ ; 如果  $T_C \leq P_{act,m} \leq T_D$ , 则储能电站动作指令  $P_{action} = 0$ 。储能动作指令为:

$$P_{action} = \begin{cases} P_{Caction,m} = T_C - P_{act,m}, & P_{act,m} < T_C \\ 0, & T_C \leq P_{act,m} \leq T_D \\ P_{Daction,m} = T_D - P_{act,m}, & P_{act,m} > T_D \end{cases} \quad (9)$$

式中,  $P_{action}$  ——储能动作指令, MW;  $P_{Caction,m}$  —— $m$  阶段储能充电策略, MW;  $P_{Daction,m}$  —— $m$  阶段储能放电策略, MW;  $P_{act,m}$  —— $m$  阶段的实际负荷值, MW。

决策完成后, 需要计算储能剩余可充电安全容量和储能剩余可放电安全容量:

$$\begin{cases} E_{11} = E_1 - \sum_{i=1}^m P_{Caction,i} \cdot \Delta t \\ E_{22} = E_2 - \sum_{i=1}^m |P_{Daction,i}| \cdot \Delta t \end{cases} \quad (10)$$

式中,  $E_{11}$  ——储能剩余可充电安全容量, MWh;  $E_{22}$  ——储能剩余可放电安全容量, MWh;  $E_1$  ——储能充电安全容量, MWh;  $E_2$  ——储能放电安全容量, MWh;  $E_1$ 、 $E_2$  不考虑损耗的情况下取储能总容量的 90%;  $i$  ——已经完成充放电的阶段。

3) 更新调峰目标。对于当前阶段, 经过去阶段的实际负荷和储能动作功率已知, 其方差为常数, 则目标函数变为最小化未来  $n-m$  个阶段的方差:

$$\min Z = \frac{1}{n-m} \sum_{k=m+1}^n (P_k + P_{Ch,k} - P_{Dis,k} - \bar{P})^2 \quad (11)$$

式中,  $P_k$  ——预测负荷数据, MW;  $P_{Ch,k}$  ——充电功率序列, MW;  $P_{Dis,k}$  ——放电功率序列, MW;  $\bar{P}$  ——预测负荷序列均值, MW。

优化模型中包含 2 个约束条件:

① 容量约束。储能电池充(放)电容量不能超过剩余可充(放)电的安全容量。

$$\begin{cases} \sum_{k=m+1}^n P_{Ch,k} \cdot \Delta t \leq E_{11} \\ \sum_{k=m+1}^n P_{Dis,k} \cdot \Delta t \leq E_{22} \end{cases} \quad (12)$$

② 最大功率约束。电池放放电功率不能超过最大功率。

$$\begin{cases} 0 \leq P_{Ch,k} \leq P_{Cmax} \\ 0 \leq P_{Dis,k} \leq P_{Dmax} \end{cases} \quad (13)$$

式中,  $P_{Cmax}$  ——电池允许充电最大功率, MW;  $P_{Dmax}$  ——电池允许放电的最大功率, MW。

当电池剩余可充电容量小于某一个正的极小值  $\varepsilon$  时, 可认为电池充满, 需停止充电, 那么调峰下限目标设为 0; 当剩余可放电容量小于某一个正的极小值  $\varepsilon$  时, 可认为电池耗尽, 需停止放电, 那么调峰上限目标设为一个极大值  $\infty$ 。由式(11)~式(13)可知, 在容量和功率约束下以方差最小化的充电序列和放电序列能够使得远离均值的点尽可能的向均值靠近, 调峰目标上下限取调整后的序列最大值与最小值, 能跟随序列调整后的数值, 且能在可用容量耗尽时降低调峰目标下限, 提高调峰目标上限。

$$T_C = \begin{cases} \min(P_k + P_{Ch,k}), & E_{11} > \varepsilon \\ 0, & E_{11} \leq \varepsilon \end{cases} \quad (14)$$

$$T_D = \begin{cases} \infty, & E_{22} \leq \varepsilon \\ \max(P_k - P_{Dis,k}), & E_{22} > \varepsilon \end{cases} \quad (15)$$

4) 重复循环执行步骤 2)~4), 更新  $T_C$ 、 $T_D$ 。逐渐执行到第  $n$  阶段结束一个周期的规划。

### 3 算例分析

为验证本文调峰控制策略的效果和有效性, 以某地区实际负荷数据进行案例分析, 并和二次规划调峰策略效果进行对比。负荷数据采样时间间隔  $\Delta t = 15$  min, 每日样本数  $N=96$ 。储能电站电池容量为 34 MWh, 安全容量为  $E_1 = E_2 = 30$  MWh, 最大充放电功率为  $P_{Cmax} = P_{Dmax} = 10$  MW,  $\varepsilon = 1$  MWh。

#### 3.1 负荷预测结果及误差分析

基于 SCM-ANFIS 的电网负荷预测方法结果如图 4 所示。图 5 为预测结果的误差率分布情况, 百分比误差在 0.02 以内的占 79.7%, 在 0.02~0.04 之间的占 17.7%, 在 0.05 以内占 96.7%。文献[3]中数据, 其预测百分比误差在 0.05 以内的比例为 92.71%。样本差异可能对预测结果有一定的影响。




图4 预测负荷与实际负荷对比

Fig. 4 Comparing of forecasting and actual load




图5 误差率分布

Fig. 5 Distribution of error rate

### 3.2 调峰效果及其分析

为了验证本文调峰控制策略的效果,利用ANFIS模型预测的数据,对比二次规划算法和多阶段目标规划方法的调峰效果。

1)图6为一般工况下2种方法调峰效果对比。采用多阶段目标规划调峰填谷后的曲线更加平滑。实际负荷方差为91.89027,采用二次规划算法后方差为46.75154,采用多阶段目标规划后方差




图6 调峰效果对比

Fig. 6 Comparison of peak effect

为43.77073,较二次规划方法负荷方差下降了4%。在文献[9]中,动态规划法优化虽然延长了电池寿命,但将电池容量离散化造成储能出力不连续,调峰效果较二次规划控制略差。

2)图7为负荷预测误差较大时2种方法调峰效果对比。二次规划方法中;在第1个波峰处时由于实际负荷比预测负荷提前,其未能有效识别出第1个波峰的提前,也未能识别出波峰的提前结束,出现反调峰现象。多阶段目标动态规划法对第1个波峰的提前出现和提前结束均能有效识别,而且调峰完成后的曲线比二次规划完成调峰后曲线更平滑。经过计算,实际负荷方差为98.39776,采用二次规划算法后方差为47.41796,采用多阶段目标规划后方差为45.38651。




图7 预测误差较大情况下的调峰效果对比

Fig. 7 The peak shaving result comparing in the case of large prediction error

3)图8为储能电池充满和放空发生时多阶段目标规划调峰效果。I区储能电池的荷电状态(SOC)达到0.9,电池接近满充状态,由于剩余可充电容量减小多阶段目标规划方法能够及时减小调峰下限目标,使得储能充电电量减小并逐渐停止充电,在放电之前将无法参与充电调峰;在第2个波峰(II区)处,储能电池SOC达到0.1,电池接近放光状态,由于剩余可放电容量减小多阶段目标规划方法能够及时增大调峰上限目标,使得电池放电电量减小并逐渐停止放电,无法参与放电调峰。

对比2种方法在不同预测精度下的调峰效果,二次规划明显要受到预测精度的影响,而多阶段目标规划算法中预测负荷仅能影响未来的规划目标,而且由于采用逐段规划,其规划的目标也将随着储能剩余容量不断动态调整,储能出力能够跟随实际

负荷上下波动,有效识别波峰波谷,防止反调峰现象出现。




图 8 电池充满和放空工况下的调峰效果

Fig. 8 The peak shaving result comparing in the case of fulfilled and emptied battery

## 4 结 论

针对储能电站调峰中的负荷预测精度较差、在较大预测误差时调峰效果不理想的情况,本文提出一种基于 SCM-ANFIS 电网负荷预测和多阶段调峰目标动态规划相结合的储能电站调峰控制策略。基于某区域实际电网负荷数据的算例分析验证其可行性和有效性,得到以下结论:

1) 负荷预测中采用 SCM-ANFIS 的建模预测方法针对区域典型负荷预测进行预测,百分比误差在落在 0.05 以内的达到 96% 以上,完全满足储能电站对负荷预测的要求。

2) 与传统方法相比,多阶段目标动态规划法在预测误差较大时仍能准确识别波峰和波谷,有效防止反调峰现象的出现,并且其优化曲线更平滑,其方差相比二次规划方法减少 4% 以上。

### 【参考文献】

[1] 王嘉阳,申建建,程春田,等. 基于负荷重构策略的火电切负荷调峰方法[J]. 中国电机工程学报, 2014, 34(16): 2684—2691.  
[1] Wang Jiayang, Shen Jianjian, Cheng Chuntian, et al. A load shedding method for thermal power plants with peak regulation based on load reconstruction strategy[J]. Proceedings of the CSEE, 2014, 34(16): 2684—2691.  
[2] 程 雄. 响应调峰需求的水电系统优化调度方法研究及应用[D]. 大连: 大连理工大学, 2015.

[2] Cheng Xiong. Study and application of optimal dispatching method for hydropower system in response to peak load demand [D]. Dalian: Dalian University of Technology, 2015.  
[3] 张 平, 潘学萍, 薛文超. 基于小波分解模糊灰色聚类 and BP 神经网络的短期负荷预测[J]. 电力自动化设备, 2012, 32(11): 121—125, 141.  
[3] Zhang Ping, Pan Xueping, Xue Wenchao. A short-term load forecasting based on wavelet decomposition fuzzy gray clustering and BP neural network [J]. Electric Power Automation Equipment, 2012, 32(11): 121—125, 141.  
[4] Silva L N, Abaide A R, Figueiró I C. Development of Brazilian multi region short-term load forecasting model considering climate variables weighting in ANN model [A]. 2017 52nd International Universities Power Engineering Conference (UPEC) [C], Heraklion, Crete, Greece, 2017, 1—6.  
[5] 郭 恒, 罗 可. ANFIS 在短期负荷预测中的应用 [J]. 高电压技术, 2006, 31(8): 105—107.  
[5] Guo Heng, Luo Ke. Application of ANFIS in short-term load forecasting [J]. High Voltage Engineering, 2006, 31(8): 105—107.  
[6] 罗 可, 郭 恒, 唐贤瑛. 基于自适应神经模糊推理系统(ANFIS)的电力系统短期负荷预测[J]. 水科学与工程技术, 2005, (6): 56—58.  
[6] Luo Ke, Guo Heng, Tang Xiangying. Analysis of short-term load in power system based on adaptive neuro-fuzzy inference system (ANFIS) [J]. Journal of Water Science and Engineering, 2005, (6): 56—58.  
[7] 孙丙香, 高 科, 姜久春. 基于 ANFIS 和减法聚类的动力电池放电峰值功率预测[J]. 电工技术学报, 2015, 30(4): 272—280.  
[7] Sun Bingxiang, Gao Ke, Jiang Jichun. Prediction of peak power of power battery based on ANFIS and subtraction clustering [J]. Transactions of China Electrotechnical Society, 2015, 30(4): 272—280.  
[8] 申建建, 程春田, 李卫东. 多电网调峰的水火核电力系统网间出力分配方法[J]. 中国电机工程学报, 2014, 34(7): 1041—1051.  
[8] Shen Jianjian, Cheng Chuntian, Li Weidong. Multi-grid peak-distributed power distribution method among hydro-nuclear power systems [J]. Proceedings of the CSEE, 2014, 34(7): 1041—1051.  
[9] 鲍冠南, 陆 超, 袁志昌, 等. 基于动态规划的电池储能系统削峰填谷实时优化[J]. 电力系统自动化,

- 2012, 36(12): 11—16.
- [9] Bao Guannan, Lu Chao, Yuan Zhichang, et al. A real-time optimization of peak load and valley filling for battery energy storage system based on dynamic programming [J]. Automation of Electric Power Systems, 2012, 36(12): 11—16
- [10] 李相俊, 张晶琼, 何宇婷. 基于自适应动态规划的储能系统优化控制方法[J]. 电网技术, 2016, 40(5): 1355—1362.
- [10] Li Xianjun, Zhang Jingqiong, He Yuting. An optimal control method of energy storage system based on adaptive dynamic programming [J]. Power System Technology, 2016, 40(5): 1355—1362.
- [11] 王澄, 刘德荣, 魏庆来. 带有储能设备的智能电网电能迭代自适应动态规划最优控制[J]. 自动化学报, 2014, 40(9): 1984—1990.
- [11] Wang Cheng, Liu Derong, Wei Qinglai. Optimal control of smart grid with energy storage based on iterative adaptive dynamic programming [J]. Acta Automatica Sinica, 2014, 40(9): 1984—1990.

## PEAK REGULATION CONTROL STRATEGY OF ENERGY STORAGE POWER STATION BASED ON SCM-ANFIS LOAD FORECAST

Wang Xiaodong<sup>1</sup>, Miao Yizhi<sup>1</sup>, Lu Shixuan<sup>2</sup>, Liu Yingming<sup>1</sup>

(1. School of Electrical Engineering, Shenyang University of Technology, Shenyang 110870, China;

2. School of Chemical Process Automation, Shenyang University of Technology, Liaoyang 111003, China)

**Abstract:** Aiming at the problems of large errors in the predicted load and inaccurate identification of peaks and valleys in battery energy storage peak regulation control, the peak regulation control strategy of energy storage power station combining power grid load forecasting and peak regulation target dynamic planning was proposed based on subtractive clustering method and adaptive network fuzzy inference system (SCM-ANFIS). The subtractive clustering method was used to reduce the number of fuzzy rules in load forecasting, and neural network parameters were trained by hybrid learning algorithm, thereby reducing the amount of prediction calculation and improving the prediction accuracy. In the process of peak regulation, based on the load forecasting information, by introducing the phased rolling optimization, the peak regulation effect is optimal under the constraint of the capacity of the energy storage system. Based on the results of the actual grid load data in a certain area, the feasibility and effectiveness of the prediction algorithm and control algorithm were verified.

**Keywords:** energy storage; electric load forecasting; fuzzy inference; peak-shaving and valley filling; multi-stage target dynamic planning