

DOI: 10.7667/PSPC170564

考虑主动需求的主动配电网负荷预测

刘会家, 管鑫, 陈波, 黄泰相, 程璐瑶, 刘士祥

(三峡大学电气与新能源学院, 湖北 宜昌 443002)

摘要: 主动配电网的主动需求管理技术(Active Demand, AD)通过市场引导机制来改变用户的典型用电行为, 电网负荷特性随之发生改变, 降低了传统负荷预测技术的预测精度。针对 AD 对主动配电网负荷预测的影响, 考虑用户响应特性分析影响 AD 响应负荷的因素, 作为负荷预测的外生输入量, 然后利用粒子群优化的支持向量机技术在黑盒框架下建立含 AD 输入的完备负荷预测模型, 提出了适用于考虑主动需求的主动配电网负荷预测新方法。基于用户响应行为的现实考虑, 建立时变 AD 模型产生含 AD 效应的负荷数据集来测试所提出的负荷预测方法。实验结果表明, 所提负荷预测模型与不含 AD 输入的负荷预测模型相比, 预测精度更高。

关键词: 主动配电网; 主动需求; 负荷预测; 支持向量机; 粒子群优化

Load forecasting for active distribution network in the presence of active demand

LIU Huijia, GUAN Xin, CHEN Bo, HUANG Taixiang, CHENG Luyao, LIU Shixiang

(College of Electrical Engineering & New Energy, China Three Gorges University, Yichang 443002, China)

Abstract: Active Demand (AD) of active distribution network changes user's typical power consumption behavior through market guidance mechanism, the load characteristics of power grid change accordingly, which reduces the accuracy of traditional load forecasting technology. To counter the influence of AD on load forecasting for active distribution network, this paper extracts the variables that affect the AD response load as the exogenous input of load forecasting by considering user's response feature, establishes the complete load forecasting model containing AD input under black box framework based on support vector machine optimized by particle swarm, and proposes a new load forecasting method for active distribution network considering AD. Based on practical considerations about consumers' behavior, a time-varying AD model is built to produce a data set of load including AD effect to test the proposed load forecasting method. The experimental results show that the proposed load forecasting model is more accurate than the load forecasting model without AD input.

This work is supported by National Natural Science Foundation of China (No. 51477090).

Key words: active distribution network; active demand; load forecasting; support vector machine (SVM); particle swarm optimization (PSO)

0 引言

目前, 针对大规模分布式电源接入配电网引发的一系列问题, 配电网模式由被动向主动转变, 主动配电网(Active Distributed Net, ADN)应运而生^[1-4]。主动配电网的出现使得配电网引入了许多新的技术, 这些新技术之一就有主动需求管理技术(Active Demand, AD), 它使得主动配电网具有完全集成的需求和分布式能源资源, 主要通过实时电价和一定

的补贴等方式, 使得用户根据电力市场的动态调整自身的用电行为^[5-6]。因此, AD 代表一个通过灵活性, 提供解决网络约束和支持可再生能源开发的新机会, 潜在地给所有参与者提供经济效益。

在主动配电网, 可靠工具预测负荷是关键需求。这些工具对于在网络中能量流动管理提供有用的信息, 使配电系统去平衡供应和需求, 从而确保供电的连续性和可靠性^[7]。因为 AD 导致典型用户用电行为的改变, 不考虑 AD 的经典负荷预测工具当应用于包含 AD 的负荷时间序列都会给出不准确的预测。因此, 研究存在 AD 的主动配电网负荷预测新

方法成为必然。目前, 相关研究已经吸引了部分国内外研究者的注意。文献[8]全面分析了主动配电网的负荷分类, 将能够完全响应某种引导机制的负荷归类为友好负荷, 提出了含友好负荷的整体负荷预测方法, 但对于 AD 响应负荷并没有明确考虑。文献[9]分析了存在 AD 情况下的负荷预测问题, 首次引入用户响应负荷作为残差模型的附加输入扰动项, 但对 AD 响应的研究采用的是线性时不变模型。文献[10]将用户主动响应计划作为传统负荷预测技术(线性/非线性)的附加输入, 比较了含 AD 输入的各类负荷预测方法的精度, 但都是建立在灰盒框架下的负荷预测模型, 需要预处理原始负荷时间序列。

本文论述了存在 AD 的主动配电网负荷预测问题, 分析了 AD 所引起的负荷改变, 提出将 AD 视为 SVM 模型的外部输入, 对引起 AD 响应变化的因素线性参数化以合并用户响应模型, 形成了具有 AD 输入的 SVM 模型, 并验证了该方法在主动配电网负荷预测中的有效性和准确性。

1 考虑 AD 的主动配电网总体负荷

含 AD 的主动配电网的负荷预测要考虑市场运营对于用户的影响, 即要引入用户负荷 AD 需求侧响应模型。根据负荷响应 AD 需求特性的不同, 可将 AD 响应负荷分为可控负荷和可调负荷。其中可控负荷是指与电力公司签订了可中断协议的用户, 而可调负荷是指对电价等引导机制比较敏感的用户, 主动配电网总体负荷分类如图 1 所示。

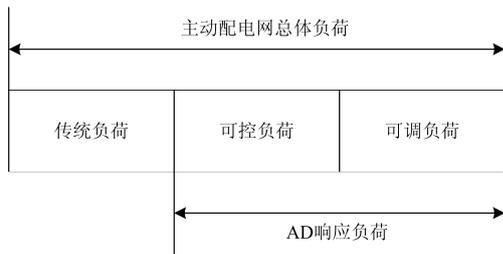


图 1 主动配电网总体负荷分类

Fig. 1 General load classification of ADN

1.1 AD 响应负荷

通过电网调度和灵活互动的运营方式, 请求 AD 信号将导致用户负荷曲线的修改, 本文考虑的就是基于预期不存在 AD 响应负荷的传统负荷曲线的改变。将电网发给用户的请求 AD 响应量用 ad 表示, 用户实际响应请求信号的负荷由 ad^{true} 表示, 事实上, 电网通过管理用户用电行为的灵活性构建 AD 响应负荷, 但是, 原则上不能确保所有用户适时或者完全调整他们的用电行为。因此, ad^{true} 通常会与

ad 不同。AD 响应示例如图 2 所示。图的顶部显示标准的 AD 响应负荷 ad , 由两部分组成。第一部分是实际的 AD 负荷, 其曲线是由响应量 V_{ad} 和响应的持续时间 T_{dur} 表示。第二部分是能量回收效应, 由于请求 AD 响应结束后用户可能跟随相反的符号修改。图 3 的底部显示了一个可能的示例, 对应的实际 AD 响应负荷 ad^{true} 。

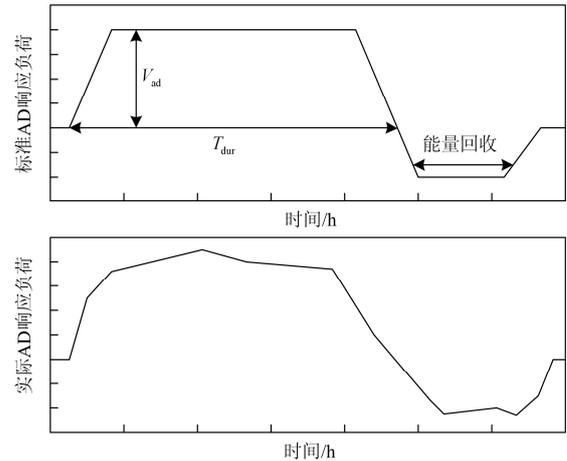


图 2 标准 AD 响应和实际 AD 响应示意图

Fig. 2 Schematics of standard and actual AD response

1.2 考虑 AD 的主动配电网负荷预测方法

主动需求管理技术使得用户负荷可以随着电力市场动态调节自身的用电行为, 这样给主动配电网的负荷预测带来了更大的不确定性, 基于传统负荷分类(线性/非线性)的负荷预测技术显然无法直接用于考虑 AD 的主动配电网的负荷预测^[11]。

考虑 AD 的主动配电网的负荷预测技术要在传统预测方法的基础上, 引入 AD 响应负荷的计算分析。主动配电网的负荷预测流程如图 3 所示。

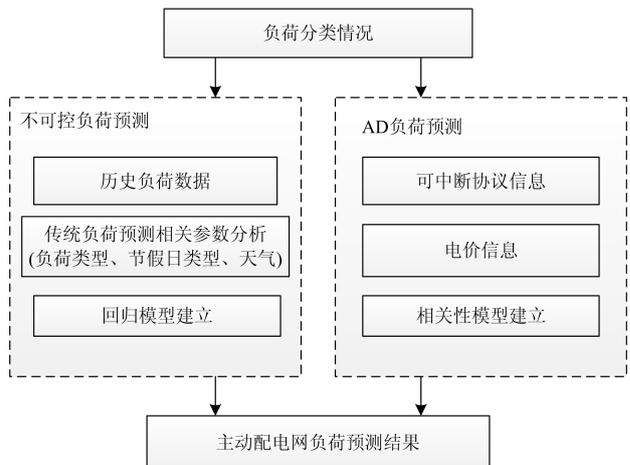


图 3 主动配电网负荷预测方法

Fig. 3 Load forecasting method of ADN

2 负荷预测模型

2.1 黑盒模型

假设每天的样本数 N_d 是整数, 选取采样时间 $T_s=15 \text{ min}$, 从时间原点到时间 kT_s 的样本变量 x 由 $x(k)$ 表示, 其中 $k=0, 1, 2, \dots$ 是离散时间指数, 问题是预测提前时间 λ 的负荷, 当然, 在历史时间 k 处有关于预测的可用信息是已知的。

通过选择参数映射 $f(\cdot; \theta)$, 在时间 $k + \lambda$ 处对负荷 y 建模。

$$y(k + \lambda) = f(z(k); \theta) + e(k; \theta) \quad (1)$$

其中 $z(k)$ 是包含在时间 k 处用于负荷预测的可用信息的回归向量, 以及选择参数矢量 $\theta = \theta^*$, 使得误差 $e(k; \theta)$ 相对于评估数据范数最小化, 不同的预测器估计每个提前时间 λ , 预测器由式(2)给出。

$$\hat{y}(k + \lambda | k) = f(z(k); \theta^*) \quad (2)$$

2.2 粒子群优化的 SVM 模型

关于选择参数映射 $f(\cdot; \theta)$, 它可以从简单的线性结构到非线性结构, 本文中考虑使用粒子群优化的 SVM 模型。

SVM 是有监督的学习模型, 用于分类和回归分析^[12-13]。SVM 的基本原理是确定一个非线性映射 ϕ , 将数据 x 映射到高维特征空间 R , 其中提升的数据可以通过线性参数模型来适当地描述。当采用 SVM 进行回归时, 最重要的关键问题是用于映射回归量到特征空间的核函数的选择。典型核函数包括线性、多项式(齐次和不齐次)以及高斯径向基函数。

用函数 $f(x) = [w \cdot \phi(x)] + b$ 进行拟合线性回归。

假设训练样本集 $(x_i, y_i)_{i=1}^n$, $x_i \in R_n$ 是输入值, 则 $y_i \in R$ 是对应的输出值。根据统计理论, 对下面的目标函数极小化可以得出

$$\min \left\{ \frac{1}{2} \|w\|^2 + C \sum_{i=1}^n (\xi_i + \xi_i^*) \right\} \quad (3)$$

约束条件

$$\begin{cases} y_i - w \cdot \phi(x) - b \leq \varepsilon + \xi_i^* \\ w \cdot \phi(x) + b - y_i \leq \varepsilon + \xi_i \\ \xi_i, \xi_i^* \geq 0 \end{cases} \quad (4)$$

式中: w 为权值; C 是惩罚因子; ξ_i 和 ξ_i^* 为非负松弛变量; ε 为不敏感损失函数参数; 可以用下列公式表示。

$$|f(x) - y|_{\varepsilon} = \begin{cases} |f(x) - y| - \varepsilon & |f(x) - y| \geq \varepsilon \\ 0 & |f(x) - y| < \varepsilon \end{cases} \quad (5)$$

将其转化为对偶问题

$$\max - \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n (a_i - a_i^*)(a_j - a_j^*) k(x_i, x_j) + \quad (6)$$

$$\sum_{i=1}^n a_i^*(y_i - \varepsilon) - \sum_{i=1}^n a_i(y_i - \varepsilon)$$

约束条件

$$\sum_{i=1}^n (a_i - a_i^*) = 0 \quad 0 \leq a_i, a_i^* \leq c \quad (7)$$

式中, $K(x_i, x_j) = \langle \phi(x_i) \cdot \phi(x_j) \rangle$ (支持向量机的核函数)。

选取 RBF 基函数作为核函数:

$$K(x_i, x_j) = \exp\left(-\frac{\|x_i - x_j\|^2}{\sigma^2}\right) \quad (8)$$

综上, 得到回归函数。

SVM 回归函数:

$$f(x) = \sum_{i=1}^n (a_i - a_i^*) K(x_i, x) + b \quad (9)$$

当 $a_i - a_i^* \neq 0$ 时, 对应的训练样本即为支持向量, b 需要满足最优化条件

$$\begin{cases} b = y_i - \varepsilon - \langle w \cdot \phi(x_i) \rangle, & a_i, a_i^* \in [0, c] \\ b = y_i + \varepsilon - \langle w \cdot \phi(x_i) \rangle, & a_i, a_i^* \in [0, c] \end{cases} \quad (10)$$

由于支持向量机技术在实际运用中存在关键参数设置和选择难度较大的问题, 因此采用粒子群优化算法^[14-15]对 SVM 回归函数的核函数参数和平衡参数等关键参数实现最优选择, 假设参数样本在一个 n 维的空间中, 将每一个参数样本看作为 n 维空间某一位置的第 i 个粒子, 粒子 i 的移动速度为 V_{id} ($d=1, 2, 3, \dots, n$), 采用算法搜索粒子个体当前的最优位置 P_i , 衡量粒子位置的优劣搜索出整个粒子群的最优位置 P_{gd} 。

迭代过程公式

粒子 i 移动速度:

$$V_{id}^k = w_{id}^k + c_1 r_1 (P_{id} - X_{id}) + c_2 r_2 (P_{gd} - X_{id}) \quad (11)$$

粒子 i 更新位置:

$$X_{id}^{k+1} = X_{id}^k + V_{id}^{k+1}$$

惯性权重因子:

$$w = w_{\max} - \frac{w_{\max} - w_{\min}}{k_{\max}} k \quad (12)$$

($w \in [0, 1]$)

式中: k 为当前迭代次数; c_1, c_2 为加速因子; r_1, r_2 为 $[0, 1]$ 间的随机数。

2.3 考虑主动需求的负荷预测模型

基于传统负荷预测技术在黑盒框架下建立了负

荷预测模型, 接下来考虑的是输入变量的选择, 与传统不可控负荷相关的输入变量不加描述, 最重要的是选择能够引起 AD 响应负荷变化的输入变量, 在这里, $z(k)$ 是包含输入变量的向量。

对于固定提前时间 λ , 回归向量 $z(k)$ 具有以下结构:

$$z(k) = \begin{bmatrix} y(k) \cdots, y(k - m_y + 1) \cdots, \\ ad(k + \lambda) \cdots, ad(k + \lambda - m_{ad} + 1) \cdots, \\ t_1(k + \lambda) \cdots, t_{24}(k + \lambda) \cdots, \\ d_1(k + \lambda) \cdots, d_7(k + \lambda) \end{bmatrix}^T \quad (13)$$

其中 m_y 和 m_{ad} 是固定的整数, 以及二进制变量 $t_i(k)$ 和 $d_j(k)$ 用于选择一周中的某一天, 一天中的某一时^[16]。特别地, 如果时间指数 k 落入一天中的第 i 个小时, $i = 1, \dots, 24$, 变量 $t_i(k)$ 为 1, 并且如果时间指数 k 落入一周中的第 j 天, $j = 1, \dots, 7$, 则变量 $d_j(k)$ 为 1。年的月份变量不使用, 因为可用的数据应用跨度小于一年。

给定回归向量式(13), 确定了式(1)中的参数映射 $f(\cdot; \theta)$, 然后有

$$y(k + \lambda) = f(\cdot; \theta)z(k) + e(k; \theta) \quad (14)$$

其中 $\theta \in R^{m_y + m_{ad} + 31}$ 是参数向量, 可以通过经典最小二乘法估计。模型式(14)可以表示为具有外部输入的 SVM 模型。

2.4 时变 AD 模型

由于 AD 尚未实践, 因此没有包含 AD 响应负荷真正的数据集可用于测试所提出的负荷预测方法。因此, 在下一节中算例分析的验证是基于模拟 AD 效应并添加到实际负荷时间系列的数据集。接下来建立时变 AD 模型模拟用户的响应行为。模型是基于用户行为的现实考虑。

1) AD 请求在时间上具有有限的持续时间, 因此可以假设, 用户响应的持续时间是有限的。

2) 用户可能不会完全遵守请求。这可能导致关于请求的 AD 分布延迟和/或部分响应。

事实上, 可以认为在实践中的用户响应度本质上是不稳定的, 受到几个外部因素影响, 如一年中的日期、一天中的时钟、天气条件或电价。这将导致到时变模型

$$ad^{true}(k) = b_0(w(k))ad(k) + b_1(w(k-1))ad(k-1) + \cdots + b_{n_b-1}(w(k-n_b+1))ad(k-n_b+1) + v(k) \quad (15)$$

其中 $w(k)$ 是包含外部因素的矢量, 可以影响用户在时间 k 的响应度, 而函数 $b_i(w)$, $i = 0, \dots, n_b - 1$,

怎样将这些因素合适的参数化影响在时间 $k-i$ 处的 AD 响应负荷。如果函数 $b_i(w)$ 被线性参数化, 这样就可以容易将用户的响应模型(15)合并到负荷预测模型中。让

$$b_i(w) = b_{i,0} + b_{i,1}\beta_1(w) + b_{i,2}\beta_2(w) + \cdots + b_{i,p}\beta_p(w) \quad (16)$$

其中 $\beta_j(w)$, $j = 1, \dots, p$ 是带有 w 的函数。在这种情况下, 式(13)中回归矢量 $z(k)$ 应该包括项

$$\beta_j(w(k + \lambda))ad(k + \lambda), \dots, \beta_j(w(k + \lambda - m_{ad} + 1))ad(k + \lambda - m_{ad} + 1), j = 1, \dots, p$$

需要注意的是, 可能需要用相应的预测来替换外部信号 $w(k)$ 的未来值, 例如天气或电价预测。

考虑用户响应的实际情况, 用户的响应通过模型式(15)和式(16)可以被模拟, 考虑一天的变化, 其中 $p = 1$, $w(k)$ 等于一天中的时钟样本 k (在 0 和 23 之间表示), 和

$$\beta_1(w(k)) = \begin{cases} w(k), & 0 \leq w(k) \leq 12 \\ 24 - w(k), & 12 \leq w(k) \leq 23 \end{cases} \quad (17)$$

2.5 不含 AD 输入的模型

为了突出 AD 对于主动配电网负荷预测的重要性, 建立不含 AD 输入的负荷模型以起到比较的作用。此时通用回归量不含 AD 输入, $z(k)$ 具有以下结构:

$$z(k) = \begin{bmatrix} y(k) \cdots, y(k - m_y + 1) \cdots, \\ t_1(k + \lambda) \cdots, t_{24}(k + \lambda) \cdots, \\ d_1(k + \lambda) \cdots, d_7(k + \lambda) \end{bmatrix}^T \quad (18)$$

3 算例分析

3.1 含模拟 AD 效应数据集

原始数据集来源于中国某市某年 10~11 月的历史用电数据, 选取采样时间 $T_s = 15 \text{ min}$, 每天有 96 个数据样本。通常模型描述的整体系统行为越好, 任意系统输入的预测性能越好, 因此选择在响应时间段随机生成 AD 输入, 响应时间段为用电高峰期和用电低谷期。AD 输入 $ad(k)$ 通过使 AD 容量 V_{ad} 和响应持续时间 T_{dur} 分别在区间 $[10, 90] \text{ MW}$ 和 $[2, 6] \text{ h}$ 内随机选择来产生。能量回报幅度等于 V_{ad} 的 $1/5$, 而其持续时间被假定为 $1/3T_{dur}$ 。

选取训练样本中 10 个相似日的历史用电数据, 原始数据集如图 4 上面图形所示, 然后将用户响应模型产生的模拟 AD 效应添加到原始数据集, 其中 $n_b = 3$, $p = 1$, $b_{0,0} = 0.3$, $b_{1,0} = 0.15$, $b_{2,0} = 0.05$, $b_{0,1} = 0.02$, $b_{1,1} = 0.01$, $b_{2,1} = 0.01$ 。含模拟 AD 效应的数据集如图 4 下面图形所示。可以看出, 从总

体上来讲, 电网通过主动响应整合所有的用户资源确实对总体负荷起到了削峰填谷的作用, 大大降低了峰谷差, 并且这种作用随着响应度的提高而提高。当然, 随着响应时间的结束, 能量回收效应在一定程度上可能起着反作用, 这主要取决于响应时间的长短, 因此选取合适的响应时间尤为重要。

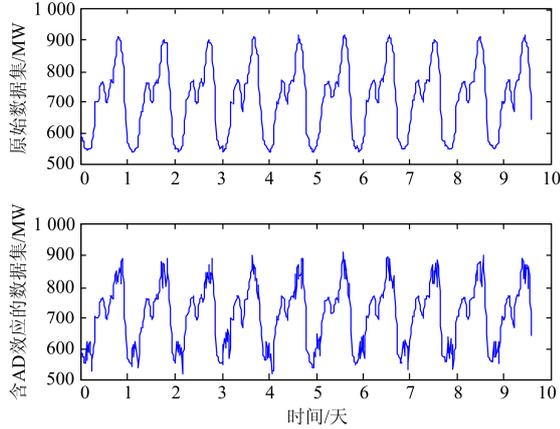


图4 原始数据集和含AD效应的数据集

Fig. 4 Original data set and data set including AD effect

3.2 AD 响应负荷对于传统负荷曲线的影响

含AD效应负荷曲线相对于传统负荷曲线的变化是由AD响应负荷决定的, 即受响应量 V_{ad} 和响应持续时间 T_{dur} 控制。响应量 V_{ad} 直接受响应合约计划影响。在这里重点考虑响应持续时间 T_{dur} 对于传统负荷曲线的影响。

选取11月25日的负荷作为原始负荷, 对其添加不同响应时间的AD响应负荷。对于响应时间 $T_{dur1} = 4\text{h}$, 效果如图5含AD效应负荷曲线(1)所示,

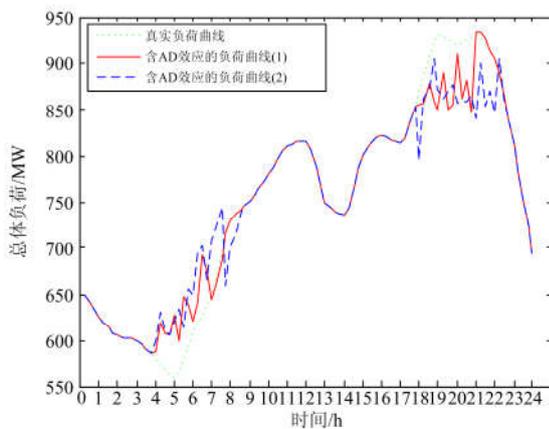


图5 含不同响应时间的AD效应负荷曲线

Fig. 5 Load curve including AD effect with different response time

可以看出在3:30—7:30的用电低谷期(或17:30—21:30的用电高峰期), 相比不含AD效应的总体负荷用电量有所增加(或减少)。请求响应结束后的能量回报效应也使得总体负荷向相反的方向变化。在用电高峰期, 由于响应时间结束后仍处于用电总量较大的时刻, 基于此时的用电负荷, 能量回收效应又使得总体负荷有所增加, 这样在21:30-22:30又形成了十分高的峰值负荷, 这在一定程度上大大降低了AD响应负荷的效果。因此, 考虑历史相似日负荷曲线, 选取响应时间 $T_{dur2} = 5\text{h}$, 效果如图5含AD效应的负荷曲线(2)所示, 此时的负荷曲线更好的体现了AD响应负荷削峰填谷的积极作用。

3.3 负荷预测性能评估

模型的性能通过归一化均方误差来评估

$$MSE = \frac{1}{n} \sum_{i=1}^n e_i^2 = \frac{1}{n} \sum_{i=1}^n (x_i - x_i^*)^2$$

$$NRMSE = \frac{\sqrt{MSE}}{\bar{y}} \times 100\%$$

式中: x_i 和 x_i^* 为第 i 个实际负荷值和预测负荷值; MSE 为均方误差; \bar{y} 为 y 的样本均值; NRMSE 值越小, 代表预测精度越高。

以10月14日~11月24日的历史用电数据并添加模拟AD效应作为训练样本, 训练本文所提出的含AD输入的PSO-SVM算法来预测11月25日当天的负荷值。粒子群优化算法寻找最优SVM模型参数为 $C = 86$, $\sigma = 4.2$, 尝试了从1到96的 m_y 和 m_{ad} 值的多个不同组合, 寻找回归向量 $z(k)$ 中最优组合 $m_y = 96$, $m_{ad} = 2$, 预测结果如图6所示。计算不同提前时间 λ 对应的平均NRMSE, $\lambda = kT_s$, 即从预测时间原点到提前一天对应的预测精度, 对应的负荷预测平均NRMSE如图7所示。

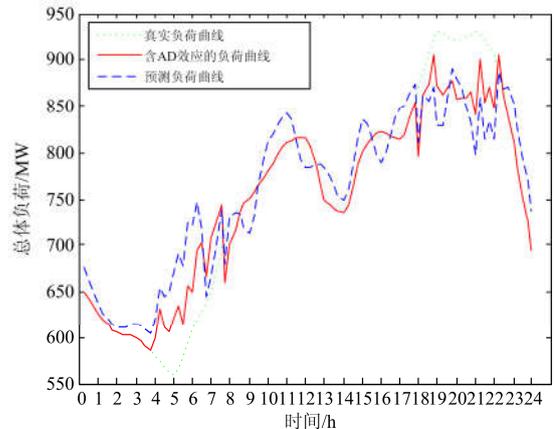


图6 含AD效应的日负荷预测曲线

Fig. 6 Daily load forecasting curve including AD effect

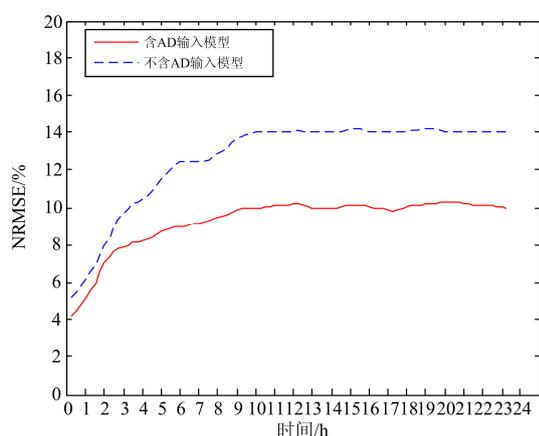


图7 提前一天日负荷预测平均 NRMSE 值

Fig. 7 Average NRMSE values for a day-ahead load forecasting

从预测结果可以看出, 预测日响应后负荷预测曲线与实际响应后负荷曲线有着良好的拟合度, 而从平均 NRMSE 来看, 总体预测性能良好, 而且越靠近预测时间原点预测精度越高, 由此验证了本文所提含 AD 输入负荷预测模型的有效性。

为了更好验证本文所提预测方法的有效性, 与文献[9]所提预测方法对比, 使用相同的样本数据, 对各个模型选择合适的参数, 各个模型的误差指标如表 1 所示, 三种模型都能进行考虑 AD 响应的负荷预测研究, 但显然本文所提出的负荷预测性能更好, 同时本文基于黑盒框架下建立的负荷模型相比于文献[9]在灰盒框架下建立的负荷模型计算过程更为简单。

表 1 几种模型的误差指标

Table 1 Error indicators of the three models

负荷模型	MSE	NRMSE/%
ES-SVM 模型(文献[9])	6754.54	10.9
ES-TF 模型(文献[9])	4917.09	9.3
PSO-SVM 模型	3548.11	7.9

考虑没有 AD 输入的模型, 在参数设置相同的情况下, 含 AD 输入和不含 AD 输入模型的预测性能如图 7 所示, 很显然, 不含 AD 输入的 PSO-SVM 模型具有很明显的性能恶化。当我们适当地增加 AD 请求的次数, 也可以计算出无论含 AD 输入的模型或者不含 AD 输入的模型平均 NRMSE 都有所增加, 而不含 AD 输入的模型明显增加更多。

本节用随机输入的 AD 来验证本文所提出的含 AD 输入的负荷预测模型, 验证数据来源于一个市的负荷量, 不得不说大量的随机 AD 响应负荷增加了验证难度, 是一个颇具挑战性的验证测试。根据图 6 和图 7 可以看出, 本文所提出的负荷预测方

法是能够满足实际需求的, 这也证明 AD 输入的使用对于在 AD 存在的情况下开发有效的负载预测工具是非常正确的方向。同时通过比较也可以看出 AD 对于主动配电网负荷预测有着重要影响, 是绝对不可忽视的重要组成部分。

4 结论

本文分析了考虑 AD 的情况下主动配电网总体负荷的改变, 这种改变使得传统负荷预测技术不再适用。在黑盒框架下采用 SVM 技术, 考虑 AD 输入作为负荷预测问题的通用回归量, 并基于粒子群优化算法对 SVM 关键参数优化选择, 从而建立了含 AD 输入的 PSO-SVM 模型。在算例分析中将模拟的 AD 分量添加到实际负荷时间序列, 建立了含模拟 AD 效应的数据集, 验证了本文所提负荷预测方法的有效性。分析了 AD 响应负荷对于传统负荷曲线的影响, 显示了合适的响应时间将最大化地体现 AD 响应负荷削峰填谷的积极作用。同时通过比较也证明了忽略 AD 在负荷模型的明确存在将导致负荷预测精度的下降。下一步可以考虑建立更准确的 AD 模型和对于 AD 建模误差更敏感的负荷预测算法。

参考文献

- [1] 范明天, 张祖平, 苏傲雪, 等. 主动配电系统可行性的研究[J]. 中国电机工程学报, 2013, 33(22): 12-18.
FAN Mingtian, ZHANG Zuping, SU Aoxue, et al. Enabling technologies for active distribution systems[J]. Proceedings of the CSEE, 2013, 33(22): 12-18.
- [2] 张跃, 杨汾艳, 曾杰, 等. 主动配电网的分布式电源优化规划方案研究[J]. 电力系统保护与控制, 2015, 43(15): 67-72.
ZHANG Yue, YANG Fenyan, ZENG Jie, et al. Research of distributed generation optimization planning for active distributed network[J]. Power System Protection and Control, 2015, 43(15): 67-72.
- [3] 张建华, 曾博, 张玉莹, 等. 主动配电网规划关键问题与研究展望[J]. 电工技术学报, 2014, 28(2): 13-23.
ZHANG Jianhua, ZENG Bo, ZHANG Yuying, et al. Key issues and research prospects of active distribution network planning[J]. Transactions of China Electrotechnical Society, 2014, 28(2): 13-23.
- [4] 赵波, 王财胜, 周金辉, 等. 主动配电网现状与未来发展[J]. 电力系统自动化, 2014, 38(18): 125-135.
ZHAO Bo, WANG Caisheng, ZHOU Jinhui, et al. Present and future development trend of active distribution network[J]. Automation of Electric Power Systems, 2014,

- 38(18): 125-135.
- [5] 胡勇. 主动配电网用户侧能量管理系统设计与实现[J]. 电力系统保护与控制, 2016, 44(16): 149-155.
HU Yong. Design and implementation of user energy management system on active distribution network[J]. Power System Protection and Control, 2016, 44(16): 149-155.
- [6] ZHENG Dehua, ESEYE A T, ZHANG Jianhua, et al. Short-term wind power forecasting using a double-stage hierarchical ANFIS approach for energy management in microgrids[J]. Protection and Control of Modern Power Systems, 2017, 2(2): 136-145. DOI: 10.1186/s41601-017-0041-5.
- [7] 雷涛, 吕勇, 马淑慧. 基于改进灰色理论的主动配电网中长期负荷预测[J]. 电网与清洁能源, 2016, 32(9): 22-28.
LEI Tao, LÜ Yong, MA Shuhui. Mid-long term load forecasting of active distribution network based on improved grey theory[J]. Power System and Clean Energy, 2016, 32(9): 22-28.
- [8] 钟清, 孙闻, 余南华, 等. 主动配电网规划中的负荷预测与发电预测[J]. 中国电机工程学报, 2014, 34(19): 3050-3056.
ZHONG Qing, SUN Wen, YU Nanhua, et al. Load and power forecasting in active distribution network planning[J]. Proceedings of the CSEE, 2014, 34(19): 3050-3056.
- [9] PAOLETTI S, CASINI M, GIANNITRAPANI A, et al. Load forecasting for active distribution networks[C] // 2011 2nd IEEE PES International Conference and Exhibition on Innovative Smart Grid Technologies, December, 2011, Los Alamitos, USA: 1-6.
- [10] 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.
- [11] 刘孝杰, 苏小林, 阎晓霞, 等. 面向主动响应和售电市场的主动配电网系统负荷预测[J]. 电力系统及其自动化学报, 2017, 29(2): 121-128.
LIU Xiaojie, SU Xiaolin, YAN Xiaoxia, et al. Load forecast of active distribution system based on active response and electricity market[J]. Proceedings of the CSU-EPSA, 2017, 29(2): 121-128.
- [12] 王恺, 关少卿, 汪令祥, 等. 基于模糊信息粒化和最小二乘支持向量机的风电功率联合预测建模[J]. 电力系统保护与控制, 2015, 43(2): 26-32.
WANG Kai, GUAN Shaoqing, WANG Lingxiang, et al. A combined forecasting model for wind power predication based on fuzzy information granulation and least squares support vector machine[J]. Power System Protection and Control, 2015, 43(2): 26-32.
- [13] 王宁, 谢敏, 邓佳梁, 等. 基于支持向量机回归组合模型的中长期降温负荷预测[J]. 电力系统保护与控制, 2016, 44(3): 92-97.
WANG Ning, XIE Min, DENG Jialiang, et al. Mid-long term temperature-lowering load forecasting based on combination of support vector machine and multiple regression[J]. Power System Protection and Control, 2016, 44(3): 92-97.
- [14] 谷文成, 柴宝仁, 滕艳平. 基于粒子群优化算法的支持向量机研究[J]. 北京理工大学学报, 2014, 34(7): 705-709.
GU Wencheng, CHAI Baoren, TENG Yanping. Research on support vector machine based on particle swarm optimization[J]. Transactions of Beijing Institute of Technology, 2014, 34(7): 705-709.
- [15] 潘超, 焦薇羽, 孟涛, 等. 基于混合智能粒子群算法的广义电源主动配电网优化配置[J]. 电力系统保护与控制, 2016, 44(7): 69-75.
PAN Chao, JIAO Weiyu, MENG Tao, et al. Optimal allocation of generalized power sources in active distribution network based on hybrid intelligent particle swarm optimization algorithm[J]. Power System Protection and Control, 2016, 44(7): 69-75.
- [16] ESPINOZA M, SUYKENS J, BELMANS R, et al. Electric load forecasting[J]. IEEE Control Systems, 2007, 27(5): 43-57.

收稿日期: 2017-04-19; 修回日期: 2017-09-21

作者简介:

刘会家(1969—), 男, 硕士, 副教授, 硕士生导师, 研究方向为配电网自动化、绝缘设备故障诊断; E-mail: eqallhj@ctgu.cn

管鑫(1994—), 男, 硕士研究生, 研究方向为主动配电网规划。E-mail: 269321229@qq.com

(编辑 张爱琴)