

# 数据与模型驱动的电熔镁群炉需量预报方法

杨杰<sup>1</sup> 柴天佑<sup>1,2</sup> 张亚军<sup>1</sup> 吴志伟<sup>1</sup>

**摘要** 电熔镁群炉需量指当前时刻  $k$  和  $(k-1), \dots, (k-n+1)$  时刻群炉功率的平均值, 用于度量高耗能电熔镁群炉用电量.  $(k+1)$  时刻群炉需量取决于功率变化率. 本文建立了功率变化率与电流控制系统输出电流之间由线性项与未知非线性项组成的动态模型, 其中线性项通过电流被控对象的参数和控制器的参数计算, 未知非线性项采用基于偏自相关函数 (Partial autocorrelation function, PACF) 输入变量决策的径向基函数神经网络 (Radial basis function neural network, RBFNN) 来估计. 本文提出了由当前  $k$  时刻的需量和功率,  $(k-n+1)$  时刻功率及  $k$  时刻功率变化率的估计组成的  $(k+1)$  时刻需量的计算模型. 通过某电熔镁砂厂实际数据的仿真实验和工业实验表明所提方法可准确预报需量变化趋势, 可以防止因原料变化引起需量尖峰导致错误切断电熔镁炉供电造成电熔镁砂质量降低.

**关键词** 需量预报, 电熔镁群炉, 数据与模型驱动, 径向基函数神经网络

**引用格式** 杨杰, 柴天佑, 张亚军, 吴志伟. 数据与模型驱动的电熔镁群炉需量预报方法. 自动化学报, 2018, 44(8): 1460–1474

**DOI** 10.16383/j.aas.2017.c160597

## Data and Model Driven Demand Forecasting Method for Fused Magnesium Furnace Group

YANG Jie<sup>1</sup> CHAI Tian-You<sup>1,2</sup> ZHANG Ya-Jun<sup>1</sup> WU Zhi-Wei<sup>1</sup>

**Abstract** The demand of fused magnesium furnace group (FMFG) is the average value of powers at times  $k$ ,  $(k-1)$ ,  $\dots$ ,  $(k-n+1)$ . The demand indicates the electricity consumption of the FMFG. The demand at time  $(k+1)$  depends on the rate of power change. In this paper, we develop a dynamic model of the rate of power change and the output current. The model consists of a linear term and an unknown nonlinear term, where the linear term can be calculated by the parameters of the controlled current and the controller, and the unknown nonlinear term can be estimated using the radial basis function neural network (RBFNN). The input variables of RBFNN are decided based on partial autocorrelation function (PACF). Then a computing model of demand at time  $(k+1)$  is proposed, which consists of the demand at time  $k$ , the powers at times  $k$  and  $(k-n+1)$  and the estimate of the rate of power change at time  $k$ . Simulations based on actual data and industrial experiments at a fused magnesia plant show that the proposed method can accurately forecast demand trends and can prevent reduction of fused magnesia grade caused by unnecessary cut off due to the demand spikes caused by change of raw materials.

**Key words** Demand forecasting, fused magnesium furnace group (FMFG), data and model driven, radial basis function neural network (RBFNN)

**Citation** Yang Jie, Chai Tian-You, Zhang Ya-Jun, Wu Zhi-Wei. Data and model driven demand forecasting method for fused magnesium furnace group. *Acta Automatica Sinica*, 2018, 44(8): 1460–1474

收稿日期 2016-08-20 录用日期 2017-02-03

Manuscript received August 20, 2016; accepted February 3, 2017

国家自然科学基金 (61503066, 61403071), 中国博士后科学基金 (2014M561246, 2015M581355), 教育部项目基本科研业务费培育种子基金 (N140804001, N160801001), 辽宁省博士启动基金项目 (201501151) 资助

Supported by National Natural Science Foundation of China (61503066, 61403071), China Postdoctoral Science Foundation (2014M561246, 2015M581355), Fundamental Research Funds for the Central Universities of Ministry of Education (N140804001, N160801001), and Doctoral Research Foundation of Liaoning Province (201501151)

本文责任编辑 张卫东

Recommended by Associate Editor ZHANG Wei-Dong

1. 东北大学流程工业综合自动化国家重点实验室 沈阳 110819 2. 东北大学自动化研究中心 沈阳 110819

1. State Key Laboratory of Synthetical Automation for Process Industries, Northeastern University, Shenyang 110819

电熔镁炉是一种以菱镁矿为原料, 由电流控制器控制熔炼电流来生产电熔镁砂的重要设备. 产品电熔镁砂是一种应用于冶金、化工、航天等领域的重要高级耐火材料. 电熔镁群炉需量指当前时刻和当前时刻之前一定时间内群炉功率的平均值, 用于度量高耗能电熔镁群炉的用电量. 在生产过程中需量不得超过规定的最大需量即需量峰值, 以限制电熔镁群炉的用电量. 需量监控系统对群炉需量进行实时监控, 当需量超过需量峰值的限幅值时会切断某台炉供电, 以保证群炉需量不超过需量峰值; 当需量低于限幅值时再恢复该台炉供电, 使该炉继续生

2. Research Center of Automation, Northeastern University, Shenyang 110819

产. 为了保证电熔镁砂质量, 需要电流控制器将电流控制在工艺设定值附近. 在电流控制器的调节作用下, 熔炼过程中原料杂质成分含量增大和颗粒长度变大可能会导致需量尖峰, 即需量先增大超过限幅值而后下降低于限幅值. 而需量尖峰会造成功断电熔镁炉的供电. 然而, 切断供电会破坏炉内温度场吸热和放热平衡, 降低电熔镁砂质量, 因此对需量进行准确的预报对于避免尖峰时刻的错误拉闸显得十分重要.

近年来, 针对电力系统的功率预报问题相关学者开展了一系列研究, 多采用时间序列方法<sup>[1]</sup>、支持向量回归机<sup>[2]</sup>、神经网络<sup>[3]</sup>和混合方法<sup>[4]</sup>等. 例如, 文献 [1] 为了制定某地区的发电量的日计划, 基于该地区过去 14 天用电总功率的数据 (采样周期为 15 分钟), 采用相似形时间序列法先得到参考基准曲线, 然后预报未来一天用电总功率的曲线. 文献 [2] 为了提高某地电力系统的可靠性, 使用该地过去 7 天用电总功率的数据 (采样周期为 1 小时), 采用支持向量回归机的方法预报未来一天用电总功率曲线. 文献 [3] 为了合理调度某地电力系统, 用该地过去 7 天风力发电总功率的数据 (采样周期为 0.5 小时), 采用前馈神经网络和上下限估计的方法预报未来一天风力发电总功率的上下限. 文献 [4] 为了降低某地电力市场的经济损失风险, 基于昨天和一周前的一天的用电功率数据和温度数据 (采样周期为 1 小时), 采用遗传算法—径向基函数神经网络 (Genetic algorithm—radial basis function neural network, GA-RBFNN) 方法预报未来一天的用电功率. 文献 [5] 为了准确预报群炉需量变化趋势减少不必要的切断供电, 使用某电熔镁砂厂过去时刻的群炉功率数据 (采样周期为 7 秒), 采用 RBFNN 方法预报下一时刻的群炉需量.

在电熔镁炉生产过程中, 控制系统通过调节电极位置, 改变电弧弧长, 进而控制熔炼电流稳定在电流设定值附近, 从而实现在满足产量约束的条件下尽量降低产品单吨能耗的控制目标<sup>[6]</sup>. 电熔镁炉的熔炼电流通常在 15 000 A 左右, 电能消耗巨大. 熔炼过程中, 当原料杂质成分含量增大和颗粒长度变大时, 工作电阻减小, 电流变大, 需量上升. 此时电流控制器会调节弧长使工作电阻变大, 降低电流, 需量又随之下降, 这样就会出现需量先升高后下降的尖峰现象. 因此根据功率变化特性建立需量的动态模型才能更准确地预报需量. 而文献 [1–4] 预报的对象采样周期时间尺度较大, 与电熔镁群炉的功率变化特性不同, 而且只单纯依据过去功率的数据进行预报, 没有研究对象的动态特性分析. 因此上述文献难以直接适用预报电熔镁群炉需量. 文献 [5] 虽然对电熔镁群炉需量进行了预报, 但只是将历史功率

数据和功率变化率整体视为非线性函数关系进行处理, 预报精度有待提高.

本文首先建立和分析需量动态模型, 提出由功率变化率的线性项、基于 PACF 输入变量决策的 RBFNN 未知非线性项估计和需量计算模型组成的需量预报方法, 通过某电熔镁砂厂实际数据的仿真实验和工业实验表明所提方法能够准确预报需量的变化趋势.

## 1 ( $k+1$ ) 时刻需量的动态模型

为了准确预报 ( $k+1$ ) 时刻需量, 本文首先根据需量定义建立 ( $k+1$ ) 时刻的需量模型, 然后建立功率变化率与电流控制系统输出电流之间的由线性项与未知非线性项组成的动态模型.

### 1.1 需量的定义

如图 1 所示, 在熔炼电压  $U$  作用下, 电流控制器调节升降电机转速  $u_i$ , 使电流实际值  $y_i$  跟踪电流设定值  $y^*$  而产生用电功率. 炉内原料吸收电弧释放的热量熔化形成逐渐上涨的 MgO 熔池, 熔炼结束后熔池经过冷却、结晶、破碎等工序形成产品电熔镁砂. 熔炼过程中功率变送器测量电力变压器得到群炉功率数据  $p(k), p(k-1), \dots, p(k-n+1)$ , 由需量计算装置基于定义 1 可得到当前时刻的群炉需量  $\bar{P}(k)$ .

**定义 1.** 群炉需量  $\bar{P}(k)$  为  $k$  时刻和 ( $k-1$ ),  $\dots$ , ( $k-n+1$ ) 时刻群炉功率  $p(k)$  的平均值

$$\bar{P}(k) = \frac{1}{n} \sum_{j=0}^{n-1} p(k-j) \quad (1)$$

其中, 群炉功率  $p(k)$  为

$$p(k) = \sum_{i=1}^m \sqrt{3} U y_i(k) \cos \varphi \quad (2)$$

其中,  $m$  为电熔镁群炉台数, 各炉熔炼电压为  $U$  (常量),  $y_i(k)$  为第  $i$  台电熔镁炉的熔炼电流,  $\cos \varphi$  为功率因数.

### 1.2 ( $k+1$ ) 时刻需量模型

由定义 1 可递推得到 ( $k+1$ ) 时刻的需量  $\bar{P}(k+1)$ .

$$\begin{aligned} \bar{P}(k+1) &= \frac{1}{n} \sum_{j=0}^{n-1} p(k+1-j) = \\ &\bar{P}(k) + \frac{p(k) - p(k+1-n) + \Delta p(k)}{n} \end{aligned} \quad (3)$$




图 1 电熔镁群炉需量监控原理图

Fig. 1 Schematic diagram of demand monitoring process for FMFG

其中,  $\bar{P}(k)$ ,  $p(k)$ ,  $p(k+1-n)$  都已知, 可见预报  $\bar{P}(k+1)$  的关键在于估计未知的功率变化率  $\Delta p(k)$ .

### 1.3 功率变化率与电流之间的动态模型

式 (3) 中功率变化率  $\Delta p(k)$  的定义为

$$\Delta p(k) = p(k+1) - p(k) = \sum_{i=1}^m \sqrt{3}U(y_i(k+1) - y_i(k)) \cos \varphi \quad (4)$$

其中,  $y_i(k+1)$  和  $y_i(k)$  是电流闭环控制系统的输出.

首先建立以电极升降电机转速  $u_i$  为输入, 以电流  $y_i$  为输出的被控对象模型. 电流  $y_i$  与工作电阻  $R_i$  之间关系有

$$y_i = \frac{U}{\sqrt{3}R_i} \quad (5)$$

其中,  $R_i^{[7]}$  为电弧电阻  $R_{i,\text{arc}}$  和熔池电阻  $R_{i,\text{pool}}$  之和, 即

$$R_i = R_{i,\text{arc}} + R_{i,\text{pool}} \quad (6)$$

其中, 电弧电阻  $R_{i,\text{arc}}^{[8]}$  为

$$R_{i,\text{arc}} = G_0 L_{i,\text{arc}} = G_0 (h_{i,\text{elec}} - h_{i,\text{pool}}) =$$

$$G_0 \left( \int_0^T u_i(t) r dt - h_{i,\text{pool}}(B_{i,1}, B_{i,2}, y_i) \right) \quad (7)$$

其中, 参数  $G_0 = (g_0 \pi r_{\text{arc}}^2 \exp(-T_0/T_1))^{-1}$ ,  $g_0$  为电弧电导率常数,  $r_{\text{arc}}$  为电弧弧柱半径,  $T_0$  为气体电离温度常数,  $T_1$  为电弧间隙温度,  $L_{i,\text{arc}}$  为电弧长度,  $h_{i,\text{elec}}$  为电极末端位置,  $T$  为运行时间,  $u_i$  为升降电机转速,  $r$  为升降机构等效齿轮半径<sup>[9]</sup>,  $h_{i,\text{pool}}(B_{i,1}, B_{i,2}, y_i)$  为熔池高度,  $B_{i,1}$  为原料杂质成分含量,  $B_{i,2}$  为原料颗粒长度.

熔池电阻  $R_{i,\text{pool}}^{[10]}$  为

$$R_{i,\text{pool}} = \frac{\rho_{i,\text{pool}}(B_{i,1}, B_{i,2})}{\pi D} \times \left( 1 - \frac{D}{2h_{i,\text{pool}}(B_{i,1}, B_{i,2}, y_i)} \right) \quad (8)$$

其中,  $\rho_{i,\text{pool}}$  为熔池电阻率,  $D$  为熔池直径. 由式 (7) 和式 (8), 得

$$\begin{aligned}\frac{dR_{i,\text{arc}}}{dt} &= G_0 \left( u_i r - \frac{dh_{i,\text{pool}}(B_{i,1}, B_{i,2}, y_i)}{dt} \right) \\ \frac{dR_{i,\text{pool}}}{dt} &= \frac{\rho_{i,\text{pool}}(B_{i,1}, B_{i,2})}{2\pi h_{i,\text{pool}}^2} \times \\ &\quad \frac{dh_{i,\text{pool}}(B_{i,1}, B_{i,2}, y_i)}{dt}\end{aligned}\quad (9)$$

对式 (5) 两边求导, 代入式 (9) 得到以升降电机转速  $u_i$  为输入, 电流  $y_i$  为输出的动态模型, 即

$$\begin{aligned}\frac{dy_i}{dt} &= -\frac{\sqrt{3}y_i^2}{U} \times \frac{dR_i}{dt} = \\ &= -\frac{\sqrt{3}y_i^2}{U} \left( \frac{dR_{i,\text{arc}}}{dt} + \frac{dR_{i,\text{pool}}}{dt} \right) = \\ &= -\left[ \left( \frac{\rho_{i,\text{pool}}(B_{i,1}, B_{i,2})}{2\pi h_{i,\text{pool}}^2} - G_0 \right) \times \right. \\ &\quad \left. \frac{dh_{i,\text{pool}}(B_{i,1}, B_{i,2}, y_i)}{dt} \right] \frac{\sqrt{3}}{U} y_i^2 - \frac{\sqrt{3}G_0 r}{U} u_i y_i^2\end{aligned}\quad (10)$$

显然, 式 (10) 中  $u_i y_i^2$  表明电流  $y_i$  与升降电机转速  $u_i$  之间为非线性关系, 且  $y_i^2$  系数中包含未知的熔池电阻率  $\rho_{i,\text{pool}}(B_{i,1}, B_{i,2})$  和熔池高度非线性变化  $\frac{dh_{i,\text{pool}}(B_{i,1}, B_{i,2}, y_i)}{dt}$ . 由于工艺要求将电流控制在电流设定值附近, 电熔镁炉在工作点附近运行. 将其在工作点附近线性化后, 被控对象 (10) 可由一阶线性模型与未建模动态的形式表示, 即

$$\begin{aligned}A(z^{-1})y_i(k+1) &= \\ B(z^{-1})u_i(k) &+ v_i[y_i(k), u_i(k), \mathbf{h}_{i,\text{pool}}]\end{aligned}\quad (11)$$

其中,  $A(z^{-1})$ ,  $B(z^{-1})$  是关于  $z^{-1}$  的多项式,  $A(z^{-1}) = 1 + a_1 z^{-1}$ ,  $B(z^{-1}) = b_0$ ,  $\mathbf{h}_{i,\text{pool}} \in \mathbf{R}^{n_c}$ ,  $n_c$  未知.  $v_i[\cdot]$  为高阶非线性项, 称未建模动态.

设计电流 PID 控制器为

$$H(z^{-1})u_i(k) = G(z^{-1})[y^* - y_i(k)]\quad (12)$$

其中,  $H(z^{-1}) = 1 - z^{-1}$ ,  $G(z^{-1}) = g_0 + g_1 z^{-1} + g_2 z^{-2}$ . 将控制器 (12) 作用于被控对象 (11), 得电流控制系统的闭环方程, 即

$$\begin{aligned}T(z^{-1})y_i(k+1) &= B(z^{-1})G(z^{-1})y^* + \\ (1 - z^{-1})v_i[y_i(k), u_i(k), \mathbf{h}_{i,\text{pool}}]\end{aligned}\quad (13)$$

其中,  $T(z^{-1}) = (1 - z^{-1})A(z^{-1}) + z^{-1}B(z^{-1}) \times G(z^{-1})$ , 由式 (13) 得到电流控制系统闭环方程的输出, 即

$$\begin{aligned}y_i(k+1) &= -T^*(z^{-1})y_i(k+1) + \\ B(z^{-1})G(z^{-1})y^* &+ \\ (1 - z^{-1})v_i[y_i(k), u_i(k), \mathbf{h}_{i,\text{pool}}]\end{aligned}\quad (14)$$

其中,  $T^*(z^{-1}) = T(z^{-1}) - 1$ . 从式 (14) 可以看出,  $y_i(k+1)$  与过去时刻的电流  $-T^*(z^{-1})y_i(k+1)$ 、电流设定值  $y^*$ 、未建模动态  $v_i[y_i(k), u_i(k), \mathbf{h}_{i,\text{pool}}]$  相关.

将式 (14) 代入式 (4) 中可得功率变化率  $\Delta p(k)$  的动态模型.

$$\begin{aligned}\Delta p(k) &= \sum_{i=1}^m \sqrt{3}U (y_i(k+1) - y_i(k)) \cos \varphi = \\ &= [-zT^*(z^{-1}) - 1] C \sum_{i=1}^m y_i(k) + \\ &= B(z^{-1})G(z^{-1})mCy^* + \\ &= C \sum_{i=1}^m (1 - z^{-1})v_i[y_i(k), u_i(k), \mathbf{h}_{i,\text{pool}}]\end{aligned}\quad (15)$$

其中,  $C = \sqrt{3}U \cos \varphi$ ,  $C \sum_{i=1}^m (1 - z^{-1})v_i[y_i(k), u_i(k), \mathbf{h}_{i,\text{pool}}]$  为高阶非线性项. 式 (15) 表明了功率变化率  $\Delta p(k)$  与电流  $y_i(k)$  之间的关系.

由式 (5) 可知影响电流  $y_i(k)$  的直接因素是工作电阻  $R_i(k)$ . 将式 (5) 代入式 (15) 可得功率变化率  $\Delta p(k)$  与工作电阻  $R_i(k)$  之间的关系.

$$\begin{aligned}\Delta p(k) &= [-zT^*(z^{-1}) - 1] C \sum_{i=1}^m \left[ \frac{U}{\sqrt{3}R_i(k)} \right] + \\ &= B(z^{-1})G(z^{-1})mCy^* + \\ &= C \sum_{i=1}^m (1 - z^{-1})v_i \left[ \frac{U}{\sqrt{3}R_i(k)}, u_i(k), \mathbf{h}_{i,\text{pool}} \right]\end{aligned}\quad (16)$$

再由式 (7) 和式 (8) 进一步得到功率变化率  $\Delta p(k)$  和电流影响因素 (原料杂质成分含量  $B_{i,1}$ 、颗粒长度  $B_{i,2}$ ) 之间的关系

$$\begin{aligned}\Delta p(k) &= [-zT^*(z^{-1}) - 1] \times \\ &= C \sum_{i=1}^m \left[ \frac{U}{\sqrt{3}f_{R_i}(B_{i,1}(k), B_{i,2}(k))} \right] + \\ &= B(z^{-1})G(z^{-1})mCy^* + C \sum_{i=1}^m (1 - z^{-1}) \times \\ &= v_i \left[ \frac{U}{\sqrt{3}f_{R_i}(B_{i,1}(k), B_{i,2}(k))}, u_i(k), \mathbf{h}_{i,\text{pool}} \right]\end{aligned}\quad (17)$$

其中,  $f_{R_i}(B_{i,1}(k), B_{i,2}(k))$  为关于原料杂质成分含量  $B_{i,1}$ 、颗粒长度  $B_{i,2}$  的函数.

$$f_{R_i}(B_{i,1}(k), B_{i,2}(k)) = \frac{G_0(h_{i,\text{elec}}(k) - h_{i,\text{pool}}[B_{i,1}(k), B_{i,2}(k)]) + \rho_{i,\text{pool}}[B_{i,1}(k), B_{i,2}(k)]}{\pi D} \times \left(1 - \frac{D}{2h_{i,\text{pool}}[B_{i,1}(k), B_{i,2}(k)]}\right) \quad (18)$$

由式 (3), (15)~(18) 可以看出群炉需量与电流及电流因素之间的关系. 当多台电熔镁炉出现原料杂质成分含量  $B_{i,1}$  增大和颗粒长度  $B_{i,2}$  变大的工况时, 会使熔池高度  $h_{i,\text{pool}}$  升高<sup>[11]</sup>, 电弧长度  $L_{i,\text{arc}}$  减小, 进而电阻  $R_i$  减小, 电流  $y_i$  变大, 功率变化率  $\Delta p > 0$ , 需量  $\bar{P}$  增大. 由于电流控制系统调节电机转速  $u_i$  使电弧长度  $L_{i,\text{arc}}$  增大, 又使电流  $y_i$  减小到设定值  $y^*$  附近, 需量  $\bar{P}$  又减小, 导致需量  $\bar{P}$  先增大然后减小, 出现需量尖峰.

$u_i(k)$  与过去时刻的电流  $y_i(k)$  相关, 可表示为

$$u_i = u_i(y_i(k)) \quad (19)$$

熔炼过程中熔池高度  $h_{i,\text{pool}}$  增大, 电流  $y_i(k)$  会随之增大, 因此  $h_{i,\text{pool}}$  与  $y_i(k)$  也相关, 即

$$h_{i,\text{pool}} = h_{i,\text{pool}}(y_i(k)) \quad (20)$$

所以  $v_i[y_i(k), u_i(k), h_{i,\text{pool}}]$  可简记为电流  $y_i$  的非线性函数  $V_i(y_i)$ ,  $y_i = [y_i(k), y_i(k-1), \dots]^T$ . 将式 (15) 改写为

$$\Delta p(k) = [-zT^*(z^{-1}) - 1]p(k) + B(z^{-1})G(z^{-1})p^* + C \sum_{i=1}^m (1 - z^{-1})V_i(y_i) \quad (21)$$

其中,  $C \sum_{i=1}^m (1 - z^{-1})V_i(y_i)$  为各炉电流的函数乘以熔炼电压  $U$  和功率因数  $\cos \varphi$  再累加, 与群炉功率有关. 故可将线性组合  $[-zT^*(z^{-1}) - 1]p(k) + B(z^{-1})G(z^{-1})p^*$  之外的部分记为非线性函数  $\bar{V}(p)$ , 则  $\Delta p(k)$  的动态模型进一步改写为

$$\Delta p(k) = [-zT^*(z^{-1}) - 1]p(k) + B(z^{-1})G(z^{-1})p^* + \bar{V}(p) \quad (22)$$

其中,  $\bar{V}(p)$  为关于  $p = [p(k), p(k-1), \dots]^T$  和过去时刻的  $\bar{V}(p)$  的未知非线性函数. 至此,  $(k+1)$  时刻的需量动态模型由式 (3) 和式 (22) 组成.

在需量的动态模型中, 影响需量的主要因素为原料杂质成分含量  $B_{i,1}$  和颗粒长度  $B_{i,2}$ . 而熔池内

的气泡、电弧闪变抖动等因素对需量的干扰本文视为均值为零, 方差有界的白噪声. 在生产过程中电流控制器工作在稳定状态,  $B_{i,1}$  和  $B_{i,2}$  变化引起的电流变化是有界的, 即在一个闭集中. 由于电流变化是有界的, 功率也有界, 可以采用神经网络的方法对功率变化率的非线性项进行估计. 在此条件下, 本文提出一种数据与模型驱动的需量预报方法.

## 2 需量预报方法

根据式 (3) 和式 (22) 组成的需量动态模型, 本文提出由线性模型、基于 PACF 输入变量决策的 RBFNN 未知非线性函数估计和需量计算模型组成的需量预报方法.

### 2.1 需量预报策略

需量动态模型中, 功率变化率  $\Delta p(k)$  包含的线性部分  $[-zT^*(z^{-1}) - 1]p(k) + B(z^{-1})G(z^{-1})p^*$  已知, 将需量动态模型的式 (22) 改写为

$$\Delta p(k) = \Delta p_1(k) + \bar{V}(k) \quad (23)$$

其中,  $\Delta p_1(k)$  和  $\bar{V}(k)$  分别为  $\Delta p(k)$  的线性部分和未建模动态, 即

$$\begin{aligned} \Delta p_1(k) &= [-zT^*(z^{-1}) - 1]p(k) + B(z^{-1})G(z^{-1})p^* \\ \bar{V}(k) &= f_v(p(k), p(k-1), \dots, \\ &\quad \bar{V}(k-1), \bar{V}(k-2), \dots) \end{aligned} \quad (24)$$

其中, 参数  $a_1, b_0$  由式 (11) 结合实验确定, 控制器参数已知, 因此可计算求得线性部分  $\Delta p_1(k)$ . 因为  $\bar{V}(k)$  的非线性函数  $f_v(\cdot)$  的输入和输出都有界, 是一个闭集, 因此可基于文献 [12-13] 采用 RBFNN 估计出, 结合  $\Delta p_1(k)$  得到  $\Delta \hat{p}(k)$ , 再代入式 (3) 中即可计算出  $(k+1)$  时刻需量预报值  $\hat{P}(k+1)$ .

因此, 本文提出由线性模型、基于 PACF 输入变量决策的 RBFNN 未知非线性项估计和  $(k+1)$  时刻需量计算模型组成的预报模型结构, 如图 2 所示.

1) 线性模型. 线性部分  $\Delta p_1(k)$  根据工艺实验确定被控对象的线性模型参数  $a_1, b_0$  和控制器参数  $g_0, g_1, g_2$  计算.

2) 非线性项函数  $\bar{V}(k)$  估计. 根据采集的功率序列样本  $\{p(i), i = 1, 2, \dots, N\}$ , 采用 PACF 方法分析, 决策  $\hat{V}(k)$  估计模型的功率历史数据输入个数  $n_f$  和未建模动态历史数据输入个数  $n_v$ . 以过去的功率和非线性项为输入, 采用 RBFNN 估计出  $\hat{V}(k)$ .




图2 电熔镁群炉需量预报方法结构框图

Fig. 2 The structure diagram of demand forecasting method for FMFG

3)  $(k+1)$  时刻需量计算模型. 根据检测的  $p(k)$ ,  $p(k-n+1)$ 、非线性函数估计值  $\hat{V}(k)$  和计算的线性部分  $\Delta p_1(k)$ , 求出最终的需量预报值  $\hat{P}(k+1)$ .

## 2.2 需量预报算法

基于上述策略, 提出需量预报算法如下:

$$\hat{P}(k+1) = \bar{P}(k) + \frac{p(k) - p(k-n+1) + \Delta \hat{p}(k)}{n} \quad (25)$$

其中, 功率变化率的估计  $\Delta \hat{p}(k)$  为线性部分  $\Delta p_1(k)$  和非线性函数估计值  $\hat{V}(k)$  之和, 即

$$\Delta \hat{p}(k) = \Delta p_1(k) + \hat{V}(k) \quad (26)$$

### 2.2.1 线性模型

由式 (22) 可得  $\Delta p_1(k)$ , 即

$$\begin{aligned} \Delta p_1(k) = & [-zT^*(z^{-1}) - 1]p(k) + B(z^{-1})G(z^{-1})p^* = \\ & a_1[-p(k) + p(k-1)] + b_0(g_0 + g_1 + g_2)p^* - \\ & b_0[g_0p(k) + g_1p(k-1) + g_2p(k-2)] \end{aligned} \quad (27)$$

### 2.2.2 $n_f$ 和 $n_v$ 决策算法

采用文献 [3, 5] 中的 PACF 决策  $n_f$  和  $n_v$  值. 首先采集功率样本序列  $\{p(i), i = 1, 2, \dots, N\}$ , 然后按文献 [5] 的计算步骤求得 PACF 函数  $\psi(n_f)$ . 当

$$\begin{aligned} \psi(n_f - 1) < \frac{-2}{\sqrt{N + n_f}} \text{ 或 } \psi(n_f - 1) > \frac{2}{\sqrt{N + n_f}} \\ \frac{-2}{\sqrt{N + n_f}} < \psi(n_f) < \frac{2}{\sqrt{N + n_f}} \end{aligned} \quad (28)$$

则选择此时的  $n_f$  值.

决策  $n_v$  的方法类似, 具体决策条件如下:

$$\begin{aligned} \psi(n_v - 1) < \frac{-2}{\sqrt{N + n_v}} \text{ 或 } \psi(n_v - 1) > \frac{2}{\sqrt{N + n_v}} \\ \frac{-2}{\sqrt{N + n_v}} < \psi(n_v) < \frac{2}{\sqrt{N + n_v}} \end{aligned} \quad (29)$$

### 2.2.3 $\bar{V}(k)$ 的估计算法

由于  $\bar{V}(k)$  和过去时刻的  $\bar{V}(k-1), \dots, \bar{V}(k-n_v)$  相关, 也和  $p(k), \dots, p(k-n_f+1)$  相关. 因此,  $\bar{V}(k)$  表示以  $n_f$  个过去时刻功率和  $n_v$  个过去时刻非线性项为输入的未知非线性函数  $f_v(\cdot)$ , 即

$$\begin{aligned} \bar{V}(k) = f_v(p(k), p(k-1), \dots, p(k-n_f+1), \\ \bar{V}(k-1), \bar{V}(k-2), \dots, \bar{V}(k-n_v)) \end{aligned} \quad (30)$$

根据文献 [5], RBFNN 输出当前的  $\hat{V}(k)$  为

$$\begin{aligned} \hat{V}(k) = \sum_{j=1}^H \phi_j(\mathbf{d}_j \mathbf{x}) \omega_j^b + \beta \\ \phi_j(\mathbf{d}_j \mathbf{x}) = \exp\left(-\frac{1}{2\sigma^2} \|\mathbf{d}_j \mathbf{x} - \mathbf{C}_j\|^2\right), \\ j = 1, 2, \dots, H \end{aligned} \quad (31)$$

其中,  $H$  为 RBFNN 的隐含层节点的个数,  $\mathbf{d}_j = \text{diag}\{\omega_{1j}^a, \omega_{2j}^a, \dots, \omega_{(n_f+n_v)j}^a\}$ ,  $\omega_{ij}^a$  表示输入层神经元  $i$  与隐含层神经元  $j$  之间的连接权, 全部元素  $\omega_{ij}^a$  组成连接权矩阵  $\omega^a$ ,  $n_f + n_v$  行  $H$  列即  $\omega^a \in \mathbf{R}^{(n_f+n_v) \times H}$ ,  $\mathbf{x} = [p(k), \dots, p(k-n_f+1), \bar{V}(k-1), \dots, \bar{V}(k-n_v)]^T$  向量的维数为  $n_f + n_v$ ,  $\mathbf{x} \in \mathbf{R}^{n_f+n_v}$ ,  $\sigma$  为高斯函数的宽度,  $\|\cdot\|$  为欧几里得范数,  $\mathbf{C}_j$  是第  $j$  个高斯函数中心点,  $\omega^b$  为输出层权值向量, 维数为  $H$ ,  $\omega^b \in \mathbf{R}^H$ ,  $\beta$  为偏置.

1) 输入层到隐含层的连接权矩阵  $\omega^a$  的设定

由文献 [14] 知  $\omega^a$  对 RBFNN 拟合精度的作用很小, 所以将  $\omega^a$  所有元素设为 1, 即

$$\omega_{i,j}^a = 1, \quad i = 1, 2, \dots, n_f + n_v, \quad j = 1, 2, \dots, H \quad (32)$$

则  $\phi_j(\mathbf{d}_j \mathbf{x}) = \phi_j(\mathbf{x})$ .

2) 隐含层节点数  $H$  及对应中心点  $\mathbf{C}_j$  和高斯函数宽度  $\sigma$  的选择

对训练样本  $\{(\bar{V}(k), \mathbf{x}_k), k = 1, \dots, N\}$  进行 5 折交叉验证实验, 将 5 折后每 4 份数据样本数记为  $M$ , 即  $M = \frac{4}{5}N$ , 并作为隐含层中心点的候选集, 剩下  $\frac{1}{5}N$  的训练样本作为验证集. RBFNN 对训练样本集合  $\{(\bar{V}(k), \mathbf{x}_k), k = 1, \dots, N\}$  的回归映射表示如下<sup>[15]</sup>:

$$\bar{\mathbf{V}} = \Phi \omega^b + \Xi \quad (33)$$

其中,

$$\begin{aligned} \bar{\mathbf{V}} &= [\bar{V}(1), \bar{V}(2), \dots, \bar{V}(N)]^T \\ \Phi &= [\phi_1, \phi_2, \dots, \phi_M] \\ \phi_i &= [\phi_i(\mathbf{x}_1), \dots, \phi_i(\mathbf{x}_N)]^T, \quad 1 \leq i \leq M \\ \Xi &= [\varepsilon(1), \varepsilon(2), \dots, \varepsilon(N)]^T \end{aligned} \quad (34)$$

其中,  $\bar{\mathbf{V}} \in \mathbf{R}^N$  为导师信号, 即期望输出向量,  $\Phi \in \mathbf{R}^{N \times H}$  为 RBFNN 隐含层输出矩阵,  $\Xi \in \mathbf{R}^N$  为 RBFNN 对训练样本建模的误差向量.  $\phi_i(\mathbf{x}_j)$  为

$$\begin{aligned} \phi_i(\mathbf{x}_j) &= \exp\left(-\frac{1}{2\sigma^2}\|\mathbf{x}_j - \mathbf{C}_i\|^2\right), \\ i &= 1, 2, \dots, M, \quad j = 1, 2, \dots, N \end{aligned} \quad (35)$$

$\mathbf{x}_j = [p(j), \dots, p(j - n_f + 1), \bar{V}(j - 1), \dots, \bar{V}(j - n_v)]^T$ ,  $\mathbf{C}_i = [p(i), p(i - 1), \dots, p(i - n_f + 1), \bar{V}(i - 1), \dots, \bar{V}(i - n_v)]^T$ . 对矩阵  $\Phi$  用 Gram-Schmidt 方法<sup>[16]</sup> 进行正交分解来逐一确定中心点, 步骤如下:

步骤 1. 对于所有  $1 \leq i \leq M$ , 计算如下公式:

$$\begin{cases} \mathbf{q}_1^{(i)} = \phi_i \\ g_1^{(i)} = \frac{\langle \mathbf{q}_1^{(i)}, \bar{\mathbf{V}} \rangle}{\langle \mathbf{q}_1^{(i)}, \mathbf{q}_1^{(i)} \rangle} \\ [err]_1^{(i)} = g_1^{(i)} \frac{\langle \mathbf{q}_1^{(i)}, \bar{\mathbf{V}} \rangle}{\langle \bar{\mathbf{V}}, \bar{\mathbf{V}} \rangle} \end{cases} \quad (36)$$

得到  $M$  个候选样本作为中心点的贡献程度指标  $[err]_1^{(i)}$ , 最大的贡献度指标为

$$[err]_1^{(i_1)} = \max\{[err]_1^{(i)}, 1 \leq i \leq M\} \quad (37)$$

选择

$$\mathbf{q}_1 = \mathbf{q}_1^{(i_1)} = \phi_{i_1} \quad (38)$$

以上标  $i_1$  对应的样本  $\mathbf{x}_{i_1}$  作为第 1 个中心点

$$\mathbf{C}_1 = \mathbf{x}_{i_1} \quad (39)$$

步骤  $H$  ( $2 \leq H \leq H_{\max}$ ). 对于所有的  $1 \leq i \leq M$ ,  $i \neq i_1, \dots, i \neq i_{H-1}$ , 其中,  $i_1, \dots, i_{H-1}$  为前面  $H - 1$  步已经选择作为中心点的样本下标. 计算如下公式:

$$\begin{cases} l_{jH}^{(i)} = \frac{\langle \mathbf{q}_j, \phi_i \rangle}{\langle \mathbf{q}_j, \mathbf{q}_j \rangle}, \quad 1 \leq j \leq H \\ \mathbf{q}_H^{(i)} = \phi_i - \sum_{j=1}^{H-1} l_{jH}^{(i)} \mathbf{q}_j \\ g_H^{(i)} = \frac{\langle \mathbf{q}_H^{(i)}, \bar{\mathbf{V}} \rangle}{\langle \mathbf{q}_H^{(i)}, \mathbf{q}_H^{(i)} \rangle} \\ [err]_H^{(i)} = g_H^{(i)} \frac{\langle \mathbf{q}_H^{(i)}, \bar{\mathbf{V}} \rangle}{\langle \bar{\mathbf{V}}, \bar{\mathbf{V}} \rangle} \end{cases} \quad (40)$$

$M$  个候选样本中的贡献度指标第  $H$  大的值为

$$\begin{aligned} [err]_H^{(i_H)} &= \\ \max \{ [err]_H^{(i)}, 1 \leq i \leq M, i \neq i_1, \dots, i_{H-1} \} \end{aligned} \quad (41)$$

选择

$$\mathbf{q}_H = \mathbf{q}_H^{(i_H)} = \phi_{i_H} - \sum_{j=1}^{H-1} l_{jH}^{(i_H)} \mathbf{q}_j \quad (42)$$

以上标  $i_H$  对应的样本  $\mathbf{x}_{i_H}$  作为第  $H$  个中心点

$$\mathbf{C}_H = \mathbf{x}_{i_H} \quad (43)$$

当  $H = H_{\max}$  时,  $H_{\max}$  个中心点选择完毕.

节点数  $H$  逐一增加, 对候选集拟合的误差越来越小, 但当  $H$  增至某临界值  $H_c$  值时, 验证集拟合的误差开始增大, 出现过拟合现象. 因此权衡预报精度和避免过拟合的要求, 选择节点数  $H$ .

$$H = H_c, \quad 1 < H_c < H_{\max} \quad (44)$$

当节点数  $H$  确定之后, 对完整训练样本进行正交分解得到贡献度较大的前  $H$  个中心点.

$$\{\mathbf{C}_j, j = 1, \dots, H\} \quad (45)$$

隐层节点的高斯函数采用相同的  $\sigma$ , 采用文献 [17] 的方法, 在一个合理区间  $[\sigma_{\min}, \sigma_{\max}]$  内进行 5

折交叉验证实验, 选择验证集预报误差收敛速度变化不明显的临界值  $\sigma_c$ .

$$\sigma = \sigma_c, \quad \sigma_{\min} < \sigma_c < \sigma_{\max} \quad (46)$$

3) 输出层权重向量  $\omega^b$  和偏置  $\beta$  的求解  
采用最小二乘法求如下方程:

$$[\Phi \mathbf{s}] \begin{bmatrix} \omega^b \\ \beta \end{bmatrix} = \bar{\mathbf{V}} \quad (47)$$

其中,  $\mathbf{s} = [1, \dots, 1]^T$ ,  $\mathbf{s} \in \mathbf{R}^N$ , 求得  $\omega^b$  和  $\beta$ .

$$\begin{bmatrix} \omega^b \\ \beta \end{bmatrix} = [\Phi \mathbf{s}]^\dagger \bar{\mathbf{V}} \quad (48)$$

其中,  $[\cdot]^\dagger$  为广义逆矩阵, 由奇异值分解方法解得. 至此,  $\hat{V}(k)$  由 RBFNN 的估计算法如下:

$$\hat{V}(k) = \sum_{j=1}^H \exp\left(-\frac{1}{2\sigma^2} \|\mathbf{x} - \mathbf{C}_j\|^2\right) \omega_j^b + \beta$$

$$\mathbf{x} = [p(k), \dots, p(k - n_f + 1), \bar{V}(k - 1), \dots, \bar{V}(k - n_v)]^T \quad (49)$$

其中,  $n_f$  和  $n_v$  由式 (28) 和式 (29) 给出,  $H$ ,  $\mathbf{C}_j$  和  $\sigma$  由式 (44)~(46) 给出,  $\omega^b$  和  $\beta$  由式 (48) 给出.

4)  $\bar{V}(k)$  预报模型的在线更新

由于群炉生产状态会发生迁移, 需根据当前预报误差对预报模型的参数  $\omega^b$  进行更新. 设  $\omega^b$  在  $k$  时刻为  $\omega_k^b$ , 求  $(k+1)$  时刻的权值向量  $\omega_{k+1}^b$ .

$$\omega_{k+1}^b = \omega_k^b + \Delta\omega_k^b \quad (50)$$

采用文献 [18] 递推正交最小二乘法的更新步骤如下:

**步骤 1.**  $k$  时刻  $\omega^b$  的值为  $\omega_k^b$ , 隐含层输出矩阵为  $\Phi_k$ , 对  $\Phi_k$  正交分解

$$\Phi_k = Q_k \begin{bmatrix} R_k \\ O \end{bmatrix} \quad (51)$$

其中,  $Q_k \in \mathbf{R}^{N \times N}$  是正交矩阵,  $R_k \in \mathbf{R}^{H \times H}$  是上三角矩阵,  $O \in \mathbf{R}^{(N-H) \times H}$  是零矩阵.

**步骤 2.**  $k+1$  时刻递推正交分解求得  $R_{k+1}$ .

$$\begin{bmatrix} R_k \\ \vartheta_{k+1}^T \end{bmatrix} = Q_{k+1} \begin{bmatrix} R_{k+1} \\ 0 \end{bmatrix} \quad (52)$$

其中,  $\vartheta_{k+1}^T = [\phi_1(\mathbf{x}_{k+1}), \dots, \phi_H(\mathbf{x}_{k+1})]$ . 再由  $Q_{k+1}$  计算  $\Omega_{k+1}$

$$\begin{bmatrix} \Omega_{k+1} \\ \Delta\tilde{V}(k) \end{bmatrix} = Q_{k+1}^T \begin{bmatrix} 0 \\ \varepsilon(k+1) \end{bmatrix} \quad (53)$$

其中,  $\varepsilon(k+1) = \bar{V}(k+1) - \vartheta_{k+1}^T \omega_k^b$ .

**步骤 3.** 由最小二乘法求得  $\Delta\omega_k^b$ .

$$\Delta\omega_k^b = [R_{k+1}]^\dagger \Omega_{k+1} \quad (54)$$

代入式 (50) 得到  $\omega_{k+1}^b$ , 更新  $k = k+1$ , 返回步骤 2.

综上所述, 本文预报方法由式 (25) 给出, 其中功率变化率预报值  $\Delta\hat{p}(k)$  由式 (26) 给出. 式 (26) 中的线性部分  $\Delta p_1(k)$  由式 (27) 给出.  $\hat{V}(k)$  为  $\Delta p(k)$  的未建模动态的神经网络估计, 由式 (49) 给出.

### 3 仿真实验与工业实验

#### 3.1 仿真实验

将本文所提预报方法对某电熔镁砂厂 1 号电力变压器的 1 个炉次的群炉需量数据进行仿真实验, 以验证方法的有效性. 实验数据中功率的采样周期为 7 秒, 需量参数  $n = 30$ , 群炉生产台数为 4 台, 当天设定的需量限幅值为 22 100 kVA. 从该炉次 4 620 组数据中选取 4 000 组数据  $p(i)$ ,  $i = 1, \dots, 4 000$  进行仿真实验, 其中  $p(i)$ ,  $i = 1, \dots, 2 000$  为训练集,  $p(i)$ ,  $i = 2 001, \dots, 4 000$  为测试集. 根据下式求得建模所用的  $\Delta p(i)$

$$\Delta p(i) = p(i+1) - p(i) \quad (55)$$

##### 3.1.1 线性模型 $\Delta p_1(i)$

根据现场工艺实验在工作点  $y^* = 15 000$  A,  $u^* = 6.1918 \times 10^{-4} \text{ rad} \cdot \text{s}^{-1}$  处线性化被控对象模型, 计算得到参数  $a_1$ ,  $b_0$  如下:

$$a_1 = -1.01, \quad b_0 = 0.1 \quad (56)$$

控制器参数  $g_0 = 6.300 035$ ,  $g_1 = -11.9$ ,  $g_2 = 5.6$ , 则功率变化率线性模型  $\Delta p_1(i)$  计算公式为

$$\Delta p_1(i) = a_1 [-p(i) + p(i-1)] + b_0(g_0 + g_1 + g_2)p^* - b_0[g_0 p(i) + g_1 p(i-1) + g_2 p(i-2)] \quad (57)$$

其中,  $p^* = \sqrt{3}mU \cos \varphi y^*$ ,  $m = 4$ ,  $U = 190$ ,  $\cos \varphi = 0.92$ .

##### 3.1.2 $n_f$ 和 $n_v$ 的决策

对 2 000 组训练数据组成的功率时间序列求 PACF 序列值为

$$\begin{aligned} \psi(1) &= 0.9402, & \psi(2) &= -0.2357 \\ \psi(3) &= 0.1486, & \psi(4) &= -0.0050 \\ \psi(5) &= -0.0078, & \psi(6) &= 0.0068 \end{aligned}$$

$$\begin{aligned} & \vdots \\ \psi(10) &= 0.0070 \end{aligned} \quad (58)$$

PACF 的 95 % 的置信区间为  $[-0.0448, 0.0448]$ , 当  $n_f = 4$  时, PACF 值落入 95 % 置信区间内, 因此设定

$$n_f = 4 \quad (59)$$

类似地, 对 2000 组训练数据组成的未建模动态求 PACF 序列值为

$$\begin{aligned} \psi(1) &= 0.9269, & \psi(2) &= -0.9471 \\ \psi(3) &= 0.8522, & \psi(4) &= -0.6768 \\ \psi(5) &= 0.2228, & \psi(6) &= -0.2071 \\ \psi(7) &= 0.0239, & \dots & \\ & \vdots & & \\ \psi(10) &= 0.0278 \end{aligned} \quad (60)$$

PACF 的 95 % 的置信区间为  $[-0.0448, 0.0448]$ , 设定

$$n_v = 7 \quad (61)$$

### 3.1.3 基于 RBFNN 的 $\bar{V}(i)$ 估计

根据下式整理 RBFNN 训练所需的输入和输出数据:

$$\hat{V}(i) = \sum_{j=1}^H \phi_j(\mathbf{x}) \omega_j^b + \beta \quad (62)$$

其中,  $\mathbf{x} = [p(i), \dots, p(i - n_f + 1), \bar{V}(i - 1), \dots, \bar{V}(i - n_v)]^T$ . 先将  $\sigma$  由经验选为 0.8, 将节点数  $H$  由 1 逐一增加至  $H_{\max} = 200$ .

如图 3 所示, 进行 5 折交叉验证实验, 可以看出一开始随着节点个数增加, 候选集和验证集的预报误差指标 (MAPE, RMSE) 都在减小, 但是当节点数  $H > 60$  时, 虽然候选集的预报误差指标依然在减小, 但是验证集的预报误差指标开始增大. 因此根据实验结果选择隐含层节点数




图 3 隐层节点数的交叉验证

Fig. 3 Cross-validation of the number of hidden nodes

$$H = 60 \quad (63)$$

如图 4 所示, 在区间范围  $[\sigma_{\min}, \sigma_{\max}] = [0.01, 2.00]$  内, 通过 5 折交叉验证实验, 随着  $\sigma$  增大候选集和验证集的预报误差指标都相应减小, 当  $\sigma > 1.2$  时预报误差指标减小的幅度很小. 因此根据实验结果选择高斯函数宽度

$$\sigma = 1.2 \quad (64)$$




图 4 高斯函数宽度的交叉验证

Fig. 4 Cross-validation of the width of Gaussian function

确定  $H$  和  $\sigma$  之后, 对整个训练集数据进行正交分解, 得到  $H$  个中心点  $\mathbf{C}_j$  的初始值  $\mathbf{C}_j(0)$ ,  $j = 1, 2, \dots, 60$ , 即

$$\begin{aligned} \mathbf{C}_1(0) &= [0.3231, 0.4961, \dots, 0.8833, 0.9910]^T \\ & \vdots \\ \mathbf{C}_{60}(0) &= [0.8934, 0.8902, \dots, 0.5330, 0.5468]^T \end{aligned} \quad (65)$$

由式 (48) 求出权值向量  $\omega^b$  的初始值  $\omega^b(0)$  和偏置  $\beta$  初始值  $\beta(0)$  为

$$\omega^b(0) = [2.1270, 7.1224, \dots, -1295.4]^T \quad (66)$$

$$\beta(0) = -0.0057 \quad (67)$$


### 3.1.4 $\Delta p(k)$ 预报算法验证

将离线训练后的预报初模型对剩余的 2000 组数据进行验证, 如图 5 所示. 可以看出功率变化率的预报值基本包括功率变化率中有规律的信息. 功率变化率预报误差为  $\Delta e_p(k) = \Delta p(k) - \Delta \hat{p}(k)$ , 可以看出误差  $\Delta e_p(k)$  序列明显呈现一个白噪声的特性. 统计的  $\Delta p(k)$  预报误差指标如表 1 所示, 预报误差序列的方差为  $1.1481\text{E}+6$ , 均方根误差为 1071.3.

表 1  $\Delta p(k)$  预报误差指标

Table 1 Forecast error indicators of  $\Delta p(k)$

| 方差        | RMSE   |
|-----------|--------|
| 1.1481E+6 | 1071.3 |

图5  $\Delta p(k)$  预报验证曲线Fig. 5 Forecast validation curves of  $\Delta p(k)$ 

### 3.1.5 $\bar{P}(k+1)$ 预报算法验证

验证实验中需量有三次较明显的先上升后下降的趋势, 分别是:  $k = 171 \sim 220$  时段, 如图 6 所示;  $k = 571 \sim 620$  时段, 如图 7 所示;  $k = 1356 \sim 1405$  时段, 如图 8 所示。

图 6 中,  $k = 171$  时, 需量实际值为  $\bar{P}(k) = 21427\text{kW}$ , 对应需量预报值  $\hat{\bar{P}}(k) = 21421\text{kW}$ ; 当  $k = 187$  时, 需量上升至该时段内最大值  $\bar{P}(k) = 21833\text{kW}$ , 对应需量预报值  $\hat{\bar{P}}(k) = 21842\text{kW}$ ; 之后由于电流控制系统的调节作用,  $\bar{P}(k)$  开始下降, 当  $k = 194$  时, 需量降低至  $\bar{P}(k) = 21598\text{kW}$ , 对应需量预报值为  $\hat{\bar{P}}(k) = 21620\text{kW}$ 。




图7 时段2 需量曲线

Fig. 7 Demand curve for the 2nd time period




图6 时段1 需量曲线

Fig. 6 Demand curve for the 1st time period




图8 时段3 需量曲线

Fig. 8 Demand curve for the 3rd time period

图 7 中,  $k = 571$  时, 需量实际值为  $\bar{P}(k) = 21\,678\text{ kW}$ , 对应需量预报值  $\hat{P}(k) = 21\,687\text{ kW}$ ;  $k = 592$  时, 需量为该时段最大值  $\bar{P}(k) = 22\,067\text{ kW}$ , 需量预报值  $\hat{P}(k) = 22\,080\text{ kW}$ ; 之后  $\bar{P}(k)$  开始下降,  $k = 620$  时, 需量  $\bar{P}(k) = 21\,730\text{ kW}$ , 对应需量预报值为  $\hat{P}(k) = 21\,704\text{ kW}$ .

图 8 中,  $k = 1\,356$  时, 需量实际值为  $\bar{P}(k) = 21\,450\text{ kW}$ , 对应需量预报值  $\hat{P}(k) = 21\,445\text{ kW}$ ;  $k = 1\,385$  时, 需量为该时段最大值  $\bar{P}(k) = 22\,011\text{ kW}$ , 需量预报值  $\hat{P}(k) = 22\,006\text{ kW}$ ; 之后  $\bar{P}(k)$  开始下降,  $k = 1\,399$  时, 需量  $\bar{P}(k) = 21\,667\text{ kW}$ , 对应需量预报值为  $\hat{P}(k) = 21\,633\text{ kW}$ .

从图 6~8 可以看出, 在三个时段中需量实际值和需量预报值的上升和下降趋势基本类似. 为定量分析预报方法的性能, 本文采用误差方差、预报精度百分比 (Percent better, PB)<sup>[19]</sup>、均方根误差 (Root mean square error, RMSE)<sup>[20-23]</sup>、平均绝对百分误差 (Mean absolute percentage error, MAPE)<sup>[3]</sup> 作为评估预报性能的指标, 计算公式如下:

$$\left\{ \begin{array}{l} \text{PB} = \frac{\sum_{k=1}^N j_k}{N} \times 100\%, \\ j_k = \begin{cases} 1, & \text{若 } |\hat{P}(k) - \bar{P}(k)| < |\bar{P}_{0.5}(k) - \bar{P}(k)| \\ 0, & \text{若 } |\hat{P}(k) - \bar{P}(k)| \geq |\bar{P}_{0.5}(k) - \bar{P}(k)| \end{cases} \\ \text{RMSE} = \sqrt{\frac{1}{N} \sum_{k=1}^N (\hat{P}(k) - \bar{P}(k))^2} \\ \text{MAPE} = \frac{1}{N} \sum_{k=1}^N \left| \frac{\hat{P}(k) - \bar{P}(k)}{\bar{P}(k)} \right| \times 100\% \end{array} \right. \quad (68)$$

其中,  $\bar{P}_{0.5}(k) = (1 + 0.5\%) \times \bar{P}(k)$ ,  $N$  为误差序列的样本数量. 对包含图 6~8 时间段测试集 2000 个采样点的预报实验误差序列由式 (68) 进行计算, 对应预报性能指标见表 2, 误差序列的方差为 1275.7, 预报精度百分比为 97.55%, RMSE 为 35.7104, MAPE 为 0.1054%, 与文献 [5] 中预报方法对比, 本文的方法明显减小了预报误差的方差和 RMSE, 提高了预报精度百分比. 由式 (25) 可知, 需量预报算法的复杂度和精度取决于  $\Delta p(k)$  的估计. 由于利用了所建立的  $\Delta p(k)$  动态模型式 (22), 将  $\Delta p(k)$  的估计分为可精确计算的线性部分  $\Delta p_1(k)$  和未建模动态  $\bar{V}(k)$ . 其中,  $\Delta p_1(k)$  由式 (27) 计算, 未知的  $\bar{V}(k)$  由式 (49) 采用神经网络估计. 因此, 与采用神经网络整体估计  $\Delta p(k)$  的文献 [5] 相比, 本文所提方法对线性部分利用已知信息进行精确四则

运算, 没有增加神经网络估计算法的复杂度, 同时使预报精度明显提高, 满足了现场预报的要求.

| 表 2 需量预报误差指标                                |               |              |                |               |
|---------------------------------------------|---------------|--------------|----------------|---------------|
| Table 2 Forecast error indicators of demand |               |              |                |               |
| 方法                                          | 方差            | PB (%)       | RMSE           | MAPE (%)      |
| 文献 [5]                                      | 1533.0        | 97.05        | 39.1921        | <b>0.0979</b> |
| 本文                                          | <b>1275.7</b> | <b>97.55</b> | <b>35.7104</b> | 0.1054        |

### 3.2 工业实验

将提出的预报方法应用于某电熔镁砂厂 1 号电力变压器负载的电熔镁群炉需量监控过程, 如图 1 所示. 该过程主要由 1 号电力变压器 (型号: SF9-22500/66, 额定容量: 22500 kVA), 高压断路器 (10 kV, DJS-10 机械闭锁), 5 台电炉变压器 (型号: HKS-4500/10, 额定容量: 4500 kVA), 5 台电熔镁炉 (直径 2.7 m, 高 3 m), 升降电机 (型号: YVP160M-4, 标称功率 11 kW), PID 电流控制器 (CPU 型号: 313-6CF03-0AB0). 当天设定需量限幅值为 21800 kW, 群炉生产台数为 4 台. 该厂对需量的管控动作分为切断和恢复两种. 当需量实际值超过需量限幅值且超过时间大于 4 个采样周期 (28 秒) 时, 进行切断操作. 当需量实际值低于需量限幅值时, 对该台电熔镁炉进行恢复供电的操作.

#### 3.2.1 需量预报系统简介

采用本文所提的预报方法研制了需量预报系统, 硬件平台为图 1 中的研华 IPC-7120 需量监控计算机以及 Siemens CP5621 通讯板卡.

需量预报软件平台包括: STEP7-Micro/WIN 编程软件, PC Access OPC 服务器软件, SIMATIC WinCC Explorer 过程监视软件, jdk1.7 版本的 JAVA 软件开发工具包, JAVA 集成开发环境 Eclipse 各 1 套以及 Windows 7 操作系统. 基于上述软件平台和本文所提算法研制的需量预报软件的界面如图 9 所示, 其中实线表示需量实际值, 虚线表示需量预报值.




图 9 需量预报软件界面  
Fig. 9 The interface of demand forecasting software

### 3.2.2 预报模型的参数选择

预报模型的参数为仿真实验结束时的预报模型参数, 即模型输入变量个数  $n_f = 4$ ,  $n_v = 7$ , 隐含层节点数  $H = 60$ , 高斯函数宽度  $\sigma = 1.2$ , 其他参数值具体如下, 中心点  $C_j$ ,  $j = 1, 2, \dots, 60$  为

$$\begin{aligned} C_1(0) &= [0.3231, 0.4961, \dots, 0.9910]^T \\ &\vdots \\ C_{60}(0) &= [0.8934, 0.8902, \dots, 0.5468]^T \end{aligned} \quad (69)$$

输出层的权值向量  $\omega^b$  为

$$\omega^b = [-2.5886, 7.6589, \dots, -879.1062]^T \quad (70)$$

偏置  $\beta$  为

$$\beta = 0.2957 \quad (71)$$

### 3.2.3 实验结果

在时段 21:00:00~05:22:29 进行的工业实验中, 正常情况下需量实际值和预报值曲线如图 10~12 所示。

在时段 1 (22:48:23~22:54:13) 中,  $\bar{P}(k)$  由 22:48:23 的 20801 kW 上升至 22:51:11 的 21689 kW,  $\hat{P}(k)$  由 22:48:23 的 20810 kW 上升至 22:51:11 的 21690 kW; 之后  $\bar{P}(k)$  下降至 22:54:13 的 21104 kW,  $\hat{P}(k)$  降至 21123 kW, 如图 10 所示。




图 10 时段 1 需量曲线  
Fig. 10 Demand curve for the 1st time period




图 11 时段 2 需量曲线  
Fig. 11 Demand curve for the 2nd time period




图 12 时段 3 需量曲线  
Fig. 12 Demand curve for the 3rd time period

在时段 2 (23:18:43~23:24:33) 中,  $\bar{P}(k)$  由 23:18:43 的 21253 kW 上升至 23:21:10 的 21783 kW,  $\hat{P}(k)$  由 23:18:43 的 21247 kW 上升至 23:21:10 的 21786 kW; 之后  $\bar{P}(k)$  下降至 23:24:33 的 21041 kW,  $\hat{P}(k)$  降至 21049 kW, 如图 11 所示。

在时段 3 (00:46:13~00:52:03) 中,  $\bar{P}(k)$  由 00:46:13 的 21122 kW 上升至 00:49:08 的 21780 kW,  $\hat{P}(k)$  由 00:46:13 的 21127 kW 上升至 00:49:08 的 21813 kW; 之后  $\bar{P}(k)$  下降至 00:52:03 的 21375 kW,  $\hat{P}(k)$  降至 21369 kW, 如图 12 所示。

超限拉闸情况下, 需量实际值和预报值曲线如图 13 所示, 在 22:38:00 为 21826 kW 时出现了拉闸操作。拉闸前后一段时间 (10 个采样周期) 需量实际值与需量预报值及误差见表 3。




图 13 超限拉闸时段需量曲线  
Fig. 13 Demand curve for cut off time period

由表 3 看出, 在 22:36:50~22:37:53 拉闸前半段时间内需量实际值为上升趋势, 对应的需量预报值同样为上升趋势, 趋势相同。在 22:37:32 时  $\bar{P}(k)$  为 21812 kW, 开始超出需量限幅值, 对应  $\hat{P}(k)$  为 21829 kW; 22:37:32 之后连续 4 次采样时刻需量为 21834 kW, 21835 kW, 21833 kW, 21826 kW, 对应的预报值为 21849 kW, 21839 kW, 21829 kW, 21822 kW, 拉闸前 4 次采样时刻的需量实际值和需量预报值的趋势相同, 工厂在 22:38:00

进行拉闸操作, 拉闸时的  $\bar{P}(k)$  为 21 826 kW,  $\hat{P}(k)$  为 21 822 kW; 从 22:38:07~22:39:03 拉闸后半段时间  $\bar{P}(k)$  下降迅速, 对应的  $\hat{P}(k)$  也开始下降.

表 3 超限拉闸时段需量预报误差  
Table 3 Demand forecast errors during cut off  
time period

| 时间       | 需量实际值 (kW) | 需量预报值 (kW) | 误差 (kW) |
|----------|------------|------------|---------|
| 22:36:50 | 21 626     | 21 635     | -9      |
| 22:36:57 | 21 654     | 21 650     | 4       |
| 22:37:04 | 21 692     | 21 685     | 7       |
| 22:37:11 | 21 728     | 21 725     | 3       |
| 22:37:18 | 21 754     | 21 751     | 4       |
| 22:37:25 | 21 788     | 21 787     | 1       |
| 22:37:32 | 21 812     | 21 829     | -17     |
| 22:37:39 | 21 834     | 21 849     | -15     |
| 22:37:46 | 21 835     | 21 839     | -4      |
| 22:37:53 | 21 833     | 21 829     | 4       |
| 22:38:00 | 21 826     | 21 822     | 4       |
| 22:38:07 | 21 691     | 21 819     | -128    |
| 22:38:14 | 21 510     | 21 463     | 47      |
| 22:38:21 | 21 335     | 21 318     | 17      |
| 22:38:28 | 21 191     | 21 176     | 15      |
| 22:38:35 | 21 049     | 21 056     | -7      |
| 22:38:42 | 20 908     | 20 907     | 1       |
| 22:38:49 | 20 751     | 20 769     | -18     |
| 22:38:56 | 20 581     | 20 577     | 4       |
| 22:39:03 | 20 407     | 20 385     | 22      |

上述需量变化过程中, 虽然需量实际值超过了需量限幅值, 但没有超过需量峰值. 从图 13 和表 3 可以看出, 需量预报值在拉闸时刻附近趋于缓慢下降趋势, 如果不拉闸需量实际值有可能会下降到限幅值以下, 那么这次拉闸就可能是不必要的拉闸. 因此, 将本文所提预报方法与现有需量监控系统结合将有助于减少尖峰引起的不必要拉闸, 对提高需量限幅值的设定值, 从而提高生产过程的电能利用率有一定的指导作用.

超限拉闸时段的需量预报误差变化曲线如图 14 所示, 由于预报方法是基于拉闸时和之前的功率数据来预报, 预报的是不拉闸情况的下一时刻需量, 所以在拉闸后下一时刻需量预报误差与之前预报误差相比发生了较大的波动变化; 随着时间推移, 预报模型的输入变量开始包含拉闸之后的功率数据, 在经

过 2 个采样时刻之后, 需量预报误差又逐渐减小, 说明预报模型可以及时地随着需量动态变化而在线调整.




图 14 超限拉闸时段需量预报误差变化曲线  
Fig. 14 Demand forecast error curve during cut off  
time period

根据现场实验的数据, 对恢复动作时间段的需量预报进行了仿真实验, 如图 15 所示. 图中  $a$  处 22:39:17 时刻对断电的电熔镁炉进行恢复供电的动作; 图中  $b$  处 22:40:48 时刻该台电熔镁炉由于刚恢复供电炉内工况不稳, 电弧闪灭出现了跳闸. 图中  $c$  处 22:43:22 该台电熔镁炉再次恢复供电.




图 15 恢复供电动作下的需量预报  
Fig. 15 Demand forecast curve during restore operations

在  $a$ ,  $c$  两处恢复供电的动作之后的需量预报误差变化如图 16 所示.  $a$  处首次恢复供电, 由于该炉停止供电一段时间造成炉内熔池温度下降, 所以恢复供电后的熔炼电流值要低于切断之前的电流值. 所以需量会有上升但不会达到断电之前的需量值. 当 3 个采样周期之后需量预报误差减小至正常范围内. 在  $b$  处跳闸之后需量又开始突然下降, 需量预报误差经过 2 个采样周期之后减小至正常范围. 在  $c$  处再次恢复供电, 需量开始减缓下降并逐渐开始上升, 需量预报误差经过 3 个采样周期减小至正常范围. 说明对于恢复供电的动作, 本文提出的预报方法的预报误差也会产生较大波动, 但随着时间推移预报误差又减小到正常范围内.

对上述 21:00:00~05:22:29 时间段的实验结

果进行性能分析, 实验的需量预报误差的概率分布和白度分析如图 17 所示, 可以看出需量预报误差大部分在  $[-70, 70]$  之内, 误差序列的自相关系数大部分在白度测试<sup>[24]</sup> 的 95% 置信区间  $[-0.0299, 0.0299]$  之内, 因此可将预报误差视为白噪声序列, 说明了需量预报值的可靠性。




图 16 恢复供电动作下的需量预报误差  
Fig. 16 Demand forecast error curve during restore operations




图 17 工业实验需量预报误差白度分析

Fig. 17 The whiteness analysis of demand forecast error in industrial experiment

根据式 (68) 计算得到工业实验的需量预报方法性能指标见表 4, 方差为 1049.8, 预报精度百分比为 97.68%, RMSE 为 32.3981, MAPE 为 0.0996%。从表 4 可以看出, 采用本文提出的需量预报方法能够较为准确地预报出下一时刻的需量值, 对提高需量限幅值的设定值具有指导意义。

表 4 工业实验需量预报误差指标  
Table 4 Demand forecast error indicators of industrial experiment

| 方差     | PB (%) | RMSE    | MAPE   |
|--------|--------|---------|--------|
| 1049.8 | 97.68  | 32.3981 | 0.0996 |

## 4 结论

本文建立了  $(k+1)$  时刻电熔镁群炉需量模型, 利用  $(k+1)$  时刻需量  $\bar{P}(k)$  取决于功率变化率  $\Delta p(k)$ , 以及  $\Delta p(k)$  取决于电流控制系统输出电流的特点, 提出了电熔镁群炉需量预报方法。该方法由线性模型、基于 PACF 输入变量个数决策的 RBFNN 未知非线性函数估计和  $(k+1)$  时刻需量

$\bar{P}(k+1)$  计算模型组成。通过某电熔镁砂厂实际数据的仿真实验和工业实验表明, 该方法可准确预报需量变化趋势, 不仅对预报需量尖峰防止不必要拉闸有实际意义, 而且对于工业过程控制系统的运行指标的预报具有一定参考价值。

## References

- Papadoditis E, Sapatinas T. Short-term load forecasting: the similar shape functional time-series predictor. *IEEE Transactions on Power Systems*, 2013, **28**(4): 3818–3825
- Ceperic E, Ceperic V, Baric A. A strategy for short-term load forecasting by support vector regression machines. *IEEE Transactions on Power Systems*, 2013, **28**(4): 4356–4364
- Quan H, Srinivasan D, Khosravi A. Short-term load and wind power forecasting using neural network-based prediction intervals. *IEEE Transactions on Neural Networks and Learning Systems*, 2014, **25**(2): 303–315
- Kebriaei H, Araabi B N, Rahimi-Kian A. Short-term load forecasting with a new nonsymmetric penalty function. *IEEE Transactions on Power Systems*, 2011, **26**(4): 1817–1825
- Yang J, Chai T Y. Data-driven demand forecasting method for fused magnesium furnaces. In: *Proceedings of the 12th World Congress on Intelligent Control and Automation*. Guilin, China: IEEE, 2016. 2015–2022
- Wu Z, Chai T Y, Sun J. Intelligent operational feedback control for fused magnesium furnace. In: *Proceedings of the 19th World Congress on International Federation of Automatic Control*. Cape Town, South Africa: IFAC, 2014. 8516–8521
- Ozgun O, Abur A. Flicker study using a novel arc furnace model. *IEEE Transactions on Power Delivery*, 2002, **17**(4): 1158–1163
- Wang Qi-Ping. *Arc Theory of Electrical Appliances*. Beijing: Metallurgical Industry Press, 1991.  
(王其平. 电熔电弧理论. 北京: 机械工业出版社, 1991.)
- Shigley J E, Mischke C R, Budynas R G. *Mechanical Engineering Design*. New York, USA: McGraw-Hill, 1989.
- Guo Mao-Xian. *Industry Furnace*. Beijing: Metallurgical Industry Press, 2002.  
(郭茂先. 工业电炉. 北京: 冶金工业出版社, 2002.)
- Wu Z W, Wu Y J, Chai T Y, Sun J. Data-driven abnormal condition identification and self-healing control system for fused magnesium furnace. *IEEE Transactions on Industrial Electronics*, 2015, **62**(3): 1703–1715
- Cecati C, Kolbusz J, Rózycki P, Siano P, Wilamowski B. A novel RBF training algorithm for short-term electric load forecasting and comparative studies. *IEEE Transactions on Industrial Electronics*, 2015, **62**(10): 6519–6529
- Yu H, Xie T T, Paszczynski S, Wilamowski B M. Advantages of radial basis function networks for dynamic system design. *IEEE Transactions on Industrial Electronics*, 2011, **58**(12): 5438–5450
- Xie T T, Yu H, Hewlett J, Rózycki P, Wilamowski B. Fast and efficient second-order method for training radial basis function networks. *IEEE Transactions on Neural Networks and Learning Systems*, 2012, **23**(4): 609–619

- 15 Du K L, Swamy M N S. Radial basis function networks. *Neural Networks and Statistical Learning*. London, UK: Springer, 2014. 299–335
- 16 Chen S, Cowan C F N, Grant P M. Orthogonal least squares learning algorithm for radial basis function networks. *IEEE Transactions on Neural Networks*, 1991, **2**(2): 302–309
- 17 Park J, Sandberg I W. Universal approximation using radial-basis-function networks. *Neural Computation*, 1991, **3**(2): 246–257
- 18 Gomm J B, Yu D L. Selecting radial basis function network centers with recursive orthogonal least squares training. *IEEE Transactions on Neural Networks*, 2000, **11**(2): 306–314
- 19 Armstrong J S, Collopy F. Error measures for generalizing about forecasting methods: empirical comparisons. *International Journal of Forecasting*, 1992, **8**(1): 69–80
- 20 Dai W, Chai T Y, Yang S X. Data-driven optimization control for safety operation of hematite grinding process. *IEEE Transactions on Industrial Electronics*, 2015, **62**(5): 2930–2941
- 21 Dai Wei, Chai Tian-You. Data-driven optimal operational control of complex grinding processes. *Acta Automatica Sinica*, 2014, **40**(9): 2005–2014  
(代伟, 柴天佑. 数据驱动的复杂磨矿过程运行优化控制方法. 自动化学报, 2014, **40**(9): 2005–2014)
- 22 Wu Zhi-Wei, Chai Tian-You, Wu Yong-Jian. A hybrid prediction model of energy consumption per ton for fused magnesia. *Acta Automatica Sinica*, 2013, **39**(12): 2002–2011  
(吴志伟, 柴天佑, 吴永建. 电熔镁砂产品单吨能耗混合预报模型. 自动化学报, 2013, **39**(12): 2002–2011)
- 23 Huang Yu-Bin, Yuan Jing-Qi, Wang Rui-Qing, Zhao Ping-Wei. Data-driven modeling for daily water demand forecast of Shanghai city. *Control Engineering of China*, 2010, **17**(S2): 58–60  
(黄宇斌, 袁景淇, 汪瑞清, 赵平伟. 数据驱动的上海市日需水量预报建模研究. 控制工程, 2010, **17**(S2): 58–60)
- 24 Landau I D, Zito G. *Digital Control Systems: Design, Identification and Implementation*. London, UK: Springer, 2006.



**杨 杰** 东北大学流程工业综合自动化国家重点实验室博士研究生. 主要研究方向为工业过程数据驱动建模技术及应用. 本文通信作者.  
E-mail: yjercou@126.com  
(**YANG Jie** Ph.D. candidate at the State Key Laboratory of Synthetic Automation for Process Industries,

Northeastern University. His research interest covers data driven modeling technology and application for industrial process. Corresponding author of this paper.)



**柴天佑** 中国工程院院士, 东北大学教授, IEEE Fellow, IFAC Fellow, 欧亚科学院院士. 1985 年获得东北大学博士学位. 主要研究方向为自适应控制, 智能解耦控制, 流程工业综合自动化理论、方法与技术.

E-mail: tychai@mail.neu.edu.cn


(**CHAI Tian-You** Academician of Chinese Academy of Engineering, professor at Northeastern University, IEEE Fellow, IFAC Fellow. He received his Ph.D. degree from Northeastern University in 1985. His research interest covers adaptive control, intelligent decoupling control, and integrated automation theory, method and technology of industrial process.)



**张亚军** 东北大学博士后. 主要研究方向为非线性模糊自适应控制理论, 广义预测控制, 多模型切换控制, 智能解耦控制, 数据驱动控制, 智能控制系统的大数据建模, 工业过程大数据建模及其应用.

E-mail: zhangyajun79@gmail.com

(**ZHANG Ya-Jun** Postdoctoral at Northeastern University. His research interest covers nonlinear fuzzy adaptive control theory, generalized predictive control, multiple models and switching systems, intelligent decoupling control, data-based driven control, big data-driven modelling theory, method and technology of intelligent control systems and process industries, and their applications.)



**吴志伟** 东北大学讲师. 2015 年获得东北大学博士学位. 主要研究方向为复杂工业过程的运行控制和工业嵌入式控制系统开发.

E-mail: wuzhiwei.2006@163.com

(**WU Zhi-Wei** Lecturer at Northeastern University. He received his Ph.D. degree from Northeastern University in 2015. His current research interest covers operational control for complex industry process and industrial embedded control system.)