

doi: 10.7690/bgzdh.2016.03.014

# 基于神经网络的风洞马赫数预测控制仿真研究

金志伟, 杨兴锐, 苏北辰

(中国空气动力研究与发展中心高速所, 四川 绵阳 621000)

**摘要:** 针对 2.4 m 跨声速风洞很难用精确的机理模型表示系统的动态特性的问题, 提出了基于神经网络模型的风洞马赫数预测控制策略。综合了模型预测控制和神经网络建模的优点, 对于控制参数未知、非线性和时变系统具有很好的处理效果。利用基于径向基函数的神经网络模型预测系统的动态响应、非线性神经网络模型可以在训练过程中捕获系统的动态特性等措施, 实现了将神经网络模型应用到 MPC 结构中。仿真结果表明, 该控制策略具有很好的跟踪性能和控制效果。

**关键词:** 风洞; 预测控制; 神经网络

**中图分类号:** TP391.99 **文献标志码:** A

## Predictive Control Simulation Research of Mach Number in Wind Tunnel Based on Neural Network

Jin Zhiwei, Yang Xingrui, Su Beichen

(High Speed Institute, China Aerodynamics Research & Development Center, Mianyang 621000, China)

**Abstract:** It is hard to use precise mechanism to describe system dynamic feature of 2.4 m transonic wind tunnel. Put forwards wind tunnel Mach number predictive control strategy based on neural network. Combine the advantages of model predictive control and neural network modeling, it is good at processing control parameter unknown, nonlinear system and time varying system. Use dynamic response of neural network based on radial basis function and nonlinear neural network to capture system dynamic feature, apply neural network model in MPC structure. The simulation results show that the control strategy has a good control effect and trace performance.

**Keywords:** wind tunnel; perception control; neural network

### 0 引言

2.4 m 风洞是亚洲最大的跨声速风洞, 主要用于研究作用到飞行器表面气动流场特性的空气动力学试验, 由于其结构复杂, 具有非线性、时变等特点, 很难用精确的机理模型表示系统的动态特性。近年来, 尽管基于逼近动态模型的马赫数控制等相关研究有所进展; 但要获得理想的控制效果, 控制器的设计会变得十分复杂<sup>[1]</sup>。

神经网络具有自学习和非线性逼近能力, 模型预测控制具有处理约束和模型不确定性的能力。近年来, 在鲁棒模型预测控制和非线性模型预测控制方面国内外也有相应研究成果, 已经广泛为学者和工业界接受, 并成功应用到工业多变量控制系统中。基于此, 笔者结合了模型预测控制和神经网络的优点, 提出了基于神经网络模型的马赫数预测控制策略(model predictive control, MPC)。仿真结果表明, 对于控制风洞这类参数不确定、非线性和时变系统具有很好的效果<sup>[2]</sup>。

### 1 风洞建模

笔者采用的神经网络模型具有 3 层结构, 即输入层、输出层和隐含层。神经网络模型由 2 个被控变量(总压和静压), 3 个控制变量(主调压阀、主排气阀和栅指), 以及 3 个可测扰动变量(气源压力和攻角), 过程可用 NARMAX 模型描述, 形式如下:

$$y(k) = f \begin{pmatrix} y(k-1), \dots, y(k-n_y), \\ u_1(k-d_1), \dots, u_1(k-d_1-(n_1-1)\tau_1), \\ u_2(k-d_2), \dots, u_2(k-d_2-(n_2-1)\tau_2), \\ \vdots \\ u_i(k-d_i), \dots, u_i(k-d_i-(n_i-1)\tau_i) \end{pmatrix} \quad (1)$$

式中:  $y(k)$ 、 $u(k)$  分别为输出和输入;  $\tau_1 \dots \tau_i$  分别为变量的采样间隔;  $n_y$ 、 $n_1 \dots n_i$  为变量的阶次;  $d_1 \dots d_i$  为时间延迟;  $f(\bullet)$  向量值为非线性函数。当神经网络应用于系统建模时, 在不同采样时刻的测量数据将被作为神经网络的输入训练模型, 同时网

收稿日期: 2015-12-03; 修回日期: 2016-01-06

作者简介: 金志伟(1976—), 男, 山东人, 硕士, 从事自动化控制策略及风洞试验中的应用研究。

络使用非线性函数的估计形式表示  $\hat{f}(\cdot)$ ，相应方程如下：

$$\hat{y}(k) = \hat{f} \begin{pmatrix} y(k-1), \dots, y(k-n_y), \\ u_1(k-d_1), \dots, u_1(k-d_1-(n_1-1)\tau_1), \\ u_2(k-d_2), \dots, u_2(k-d_2-(n_2-1)\tau_2), \\ \vdots \\ u_i(k-d_i), \dots, u_i(k-d_i-(n_i-1)\tau_i) \end{pmatrix} \quad (2)$$

以上模型可以对系统输出做出下一步超前预测，用于训练神经网络。在设计控制器时，这一结构可以保证实时性，同时便于在线调整控制器的参数；因此，在没有过程精确数学模型的情况下，可将神经网络模型作为仿真模型，并得到系统的下一步超前预测值，相应形式如下：

$$\hat{y}(k+1) = \hat{f} \begin{pmatrix} \hat{y}(k), \dots, \hat{y}(k-n_1+1), \\ u_1(k-d_1+1), \dots, u_1(k-d_1-(n_1-1)\tau_1+1), \\ u_2(k-d_2+1), \dots, u_2(k-d_2-(n_2-1)\tau_2+1), \\ \vdots \\ u_i(k-d_i+1), \dots, u_i(k-d_i-(n_i-1)\tau_i+1) \end{pmatrix} \quad (3)$$

## 2 预测控制器设计

预测控制是一种基于预测模型的控制算法。预测模型的功能是根据对象的历史信息和输入预测其未来输出。这里只强调模型的功能而不强调其结构形式<sup>[3]</sup>；因此，状态方程、传递函数这类传统的模型都可以作为预测模型。对于线性稳定对象，甚至阶跃响应、脉冲响应这类非参数模型，也可直接作为预测模型使用。此外，非线性系统、分布参数系统的模型，只要具备上述功能，也可在对这类系统进行预测控制时作为预测模型使用<sup>[4]</sup>。

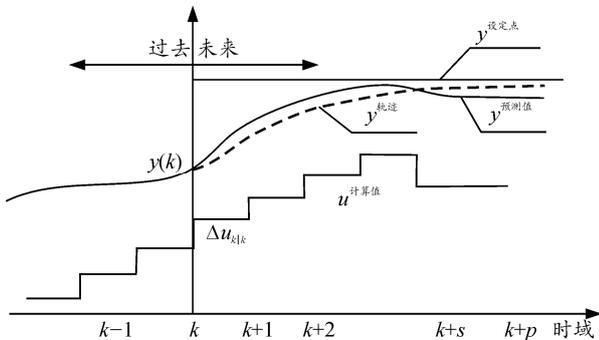


图 1 基于模型的预测控制图例

模型预测控制策略已经得到了广泛的研究与应用。在模型预测算法中，使用控制对象的动态模型和当前过程的测量值来计算控制变量的未来动作，

并保证所有的输入输出满足约束条件，而后 MPC 将计算好的多个控制输入值下载到调节器控制回路中，由调节器完成基础的控制作用<sup>[5]</sup>。模型预测控制思想如图 1 所示，其中： $p$  为预测时域； $s$  为控制时域； $\Delta u_{k|k}$  为当前给出的控制信号。

笔者采用径向基函数神经网络模型用于预测系统未来过程响应。这些预测值通过数值优化程序计算出每一采样时刻的最优控制信号，并将当前最邻近的一个控制量  $u(k|k)$  作用于被控对象。模型预测控制需要在线求解优化控制问题，这种情况下最小化性能指标函数要求服从于控制变量和被控变量的约束。基于输入输出模型的 MPC 算法通常看作是解如下迭代的优化问题：

$$\min_{\Delta U_j} J = \sum_{i=0}^m \left[ (Y_{spi} - \hat{Y}_i) Q (Y_{spi} - \hat{Y}_i)^T \right] + \sum_{j=0}^m \left[ (\Delta U) R (\Delta U)^T \right] \quad (4)$$

Subject to:

$$y_{\min i} \leq \hat{Y}_i \leq y_{\max i} \quad (i = 1, \dots, p);$$

$$u_{\min j} \leq U_j \leq u_{\max j} \quad (j = 1, \dots, m);$$

$$\Delta U_j \leq u_{\max j} \quad (j = 1, \dots, m)。$$

其中：

$$Y_{spi}^T = [y_{spi}(k), \dots, y_{spi}(k + N_p)];$$

$$\hat{Y}_i^T = [\hat{y}_{spi}(k), \dots, \hat{y}_{spi}(k + N_p)];$$

$$\Delta U_j^T = [\Delta u_j(k-1), \dots, \Delta u_j(k + N_c - 1)];$$

$$Q = I_p q_i;$$

$$R = I_m r_j。$$

其中： $Y_{spi}^T$  是参考轨迹； $\hat{Y}_i$  为预测输出； $r_j$  为用于约束操纵变量的约束因子  $j$ ； $q_i$  为权重系数，用于限制被控变量； $I$  为对角线矩阵； $N_c$  为控制时域； $N_p$  为预测时域，且有  $N_c \leq N_p$ 。之后只有计算出来的控制输入序列中的第 1 个元素应用到系统中，也就是控制输出为  $u(k) = u(k|k)$ ，在下一个采样时刻  $t(k+1)$ ，将会生成一个新的系统输出，这个过程在预测时域  $N_p$  内会一直重复。每一个过程预测时域都是等长的，但是需要移动实现下一步超前预测。

## 3 仿真结果

为验证文中提出模型预测控制策略的有效性，