

带不确定性的船舶航向动态神经模糊跟踪控制

汪洋¹ 岳殿武¹ 郭晨¹ 郭丽丽²

摘要

针对常规水面船舶的航向跟踪控制中建模参数随航速时变引起的不确定性问题,提出一种基于动态神经模糊模型的控制算法.动态神经模糊模型在学习中同时调整结构和参数,充分逼近船舶的逆动力学.训练好的动态神经模糊模型作为逆控制器,与传统的PD控制器并联,用于船舶航向的跟踪控制,且控制过程中能进一步调整模型权值.以5446TEU大型集装箱船为例,进行航向跟踪控制的仿真结果表明,该算法能克服建模参数不确定性的影响,快速有效地跟踪期望航向,控制效果良好.

关键词

航向跟踪;不确定性;动态神经模糊模型;规则调整

中图分类号 TP273.3

文献标志码 A

0 引言

Introduction

在常规水面船舶的航向跟踪控制问题中,由于船舶航速的变化引起建模参数时变而产生的不确定性一直令研究者甚感棘手^[1-2],探寻先进控制算法显得尤为重要.当前,神经网络和模糊逻辑是解决这一问题的有力工具.现有方法大多是先确定网络结构或预先给定模糊规则,再用泛化误差评价建模精度,然后直接用于航向控制^[3-4].由于采用试凑的方法或依赖于领域专家的知识来确定结构或规则,这类算法本身就具有较大的不确定性和局限性^[5].为此,本文提出一种基于动态神经模糊模型的控制算法,可成功解决航向跟踪控制中的不确定性问题.

1 船舶运动数学模型

Mathematic model of ship motion

常规水面船舶航向控制的 Norrbin 非线性模型为

$$\dot{\psi} = -a_1\psi - a_2\psi^3 + b\delta. \quad (1)$$

式中, ψ 、 δ 分别为航向角与控制舵角. $a_1 = \alpha b$, $a_2 = \beta b$, $b = K/T$ 均为模型参数, K 、 T 为船舶指数, α 、 β 为非线性系数,这4个参数均与船舶航速有关,且分别随航速的变化呈现出线性或近似线性的变化规律.所以本文将它们设定为时变参数,籍此研究航向跟踪控制中的不确定性问题.将式(1)离散化,变换后整理如下:

$$\begin{aligned} \psi(k+1) = & c_1\psi(k) + c_2\psi(k-1) + c_3\psi(k-2) + \\ & c_4[\psi(k-1) - \psi(k-2)]^3 + c_5\delta(k-2). \end{aligned} \quad (2)$$

式中: $c_1 = 2$, $c_2 = -(1 + a_1h)$, $c_3 = a_1h$, $c_4 = -a_2/h$, $c_5 = bh^2$, h 为采样周期, k 为采样时刻.显然, K 、 T 、 α 、 β 的变化导致了 c_i ($i = 1, \dots, 5$)的变化,使跟踪控制问题具有不确定性.

2 动态神经模糊模型

Dynamic neuro-fuzzified model

受文献[6-7]的启发,本文提出一种动态神经模糊模型(后文简称为“模型”),用于逼近船舶的逆动力学特性.模型的结构不是预先设定的,而是在学习中与参数同时调整.模糊规则在学习过程中逐渐增长形成,规则数不随输入变量的增加而指数增长,且无需领域的专

收稿日期 2009-07-20

资助项目 国家自然科学基金(60774046)

作者简介

汪洋,男,博士生,主要研究船舶智能自动化理论与技术. w_y_blest@126.com

1 大连海事大学 信息科学技术学院,大连,116026

2 深圳信息职业技术学院,深圳,518029

家知识即可实现自动建模.

2.1 动态神经模糊模型的结构

本文的模型结构上是一个扩展的 RBF 神经网络,功能上等价于 T-S 模糊系统. 这里的“扩展”指 RBF 网络超过 3 层结构,且输出层的权值是输入的函数而不是实常数.




图 1 动态神经模糊模型

Fig. 1 Dynamic neuro-fuzzified model

第 1 层:输入层,节点表示输入的语言变量,输入个数为 r .

第 2 层:隶属函数层,每个节点分别表示一个高斯隶属函数

$$\mu_{ij}(x_i) = \exp\left[-\frac{(x_i - c_{ij})^2}{\sigma_j^2}\right], \quad i = 1, \dots, r; \quad j = 1, \dots, u. \quad (3)$$

式中: μ_{ij} 是 x_i 的第 j 个隶属函数; c_{ij} 是该函数的中心; σ_j 是该函数的宽度; r 是输入变量数; u 是隶属函数的个数,也表示系统总的规则数.

第 3 层: T-范数层,每个节点分别表示一个可能的模糊规则中的 IF 部分,反映了模糊规则数. 每个节点均用一个 RBF 单元表示,同时也是一条可能的模糊规则,文中的“动态”即表现为这层的节点数不是固定的,而是在建模和控制的过程中变化的. 第 j 个规则 R_j 的输出为

$$\phi_j = \exp\left[-\frac{\|\mathbf{X} - \mathbf{C}_j\|^2}{\sigma_j^2}\right], \quad (4)$$

式中: $\mathbf{C}_j = (c_{1j}, c_{2j}, \dots, c_{rj}) \in \mathbf{R}^r$ 是第 j 个 RBF 单元的中心; $\mathbf{X} = (x_1, x_2, \dots, x_r) \in \mathbf{R}^r$.

第 4 层:归一化层,将该层的每个节点称为 N 节点. 易知 N 节点数与模糊规则数相等第 j 个节点 N_j 的输出为

$$\varphi_j = \frac{\phi_j}{\sum_{k=1}^u \phi_k}. \quad (5)$$

第 5 层:输出层,该层节点表示模型的输出变量,可以是单输出,也可以是多输出. 本文采用单输

出模式. 输出量的物理意义为动态神经模糊模型提供的控制舵角. 表现为上层节点的所有输出按权值的线性叠加

$$y(\mathbf{X}) = \sum_{k=1}^u \omega_k \cdot \varphi_k, \quad (6)$$

式中 ω_k 是 THEN 部分(结果参数)或者第 k 个规则的连接权值,表现为模型的所有输入量按照系数的线性叠加

$$\omega_k = a_{k0} + a_{k1}x_1 + a_{k2}x_2 + \dots + a_{kr}x_r, \quad k = 1, \dots, u. \quad (7)$$

整理之后,可得模型的输出变量的详细表达式

$$y(\mathbf{X}) = \frac{\sum_{i=1}^u \left[\left(a_{i0} + \sum_{j=1}^r a_{ij}x_j \right) \exp\left(-\frac{\|\mathbf{X} - \mathbf{C}_i\|^2}{\sigma_i^2}\right) \right]}{\sum_{i=1}^u \exp\left(-\frac{\|\mathbf{X} - \mathbf{C}_i\|^2}{\sigma_i^2}\right)}. \quad (8)$$

2.2 动态神经模糊模型的学习算法

在模型的第 3 层中,每个节点表示规则的 IF 部分或 RBF 单元,由于需要辨识模糊规则数,就不能预先确定模型的结构. 因此,本文采用一种能自动确定规则数,使参数和结构同时调整的学习算法,主要分为模糊规则的确定和权值的确定两方面.

采用分级学习思想^[8],根据模型的输出误差 e_i 和高斯函数的覆盖范围 d_{\min} 确定是否产生新规则. 对于第 i 个观测数据 (\mathbf{X}_i, o_i) , \mathbf{X}_i 为模型的输入向量, o_i 为期望输出.

定义输出误差

$$\|e_i\| = \|o_i - y_i\|, \quad (9)$$

y_i 为式(8)计算出的模型当前结构下的全部输出. 若 $\|e_i\| > k_e$,则考虑增加一条新规则. k_e 为预先设定的误差指数. 定义覆盖范围

$$d_{\min} = \arg \min(d_i(j)). \quad (10)$$

\mathbf{C}_j 为当前所有 RBF 单元的中心向量. 若 $d_{\min} > k_d$,则考虑增加一条新规则. k_d 为预先设定的覆盖范围的有效半径. 只有当 $\|e_i\| > k_e$ 且 $d_{\min} > k_d$ 同时成立时,才产生一条新规则. 而对于其他三种可能出现的情况,只需调整现有 RBF 单元的宽度和 THEN 部分的权值.

根据上述模糊规则的确定方法,假定共有 n 个观测数据产生了 u 条模糊规则. 则第 4 层的网络输出可表示为

$$\varphi = \begin{bmatrix} \varphi_{11} & \dots & \varphi_{1n} \\ \vdots & & \vdots \\ \varphi_{u1} & \dots & \varphi_{un} \end{bmatrix}. \quad (11)$$

对任意输入 $X_j(x_{1j}, x_{2j}, \dots, x_{rj})$, 模型的输出式(8)可表示为

$$Y = W \times \Psi, \quad (12)$$

$$W = (a_{10} \dots a_{u0}, a_{11} \dots a_{u1}, \dots, a_{1r} \dots a_{ur}). \quad (13)$$

若模型的理想输出为 $O = (o_1, o_2, \dots, o_n) \in \mathbf{R}^n$, 则可采用线性最小二乘法逼近一个最优的权值向量 $W^* \in \mathbf{R}^{n \times (r+1)}$, 使误差能量最小. 这个最优的权值向量由下式确定

$$W^* = O(\Psi^T \Psi)^{-1} \Psi^T. \quad (14)$$

3 控制器设计

Design of the controller

将训练好的模型与 PD 控制器并联, 构造动态神经模糊控制器用于航向跟踪控制. 控制过程中, 在线更新动态神经模糊模型的输出层权值以补偿建模误差.

如图 2 中虚线框部分所示, 在完成对船舶逆动力学的学习之后, 得到已经训练好结构和参数的模型 1, 将其复制为模型 2, 并与 PD 控制器并联, 产生控制输入舵角

$$\tau_\delta = \tau_{\text{模型2}} + \tau_{\text{PD}}. \quad (15)$$




图 2 航向控制系统结构

Fig. 2 The structure of course control system

其中, 模型 2 用于产生补偿控制信号, 是主控制器, PD 控制器的引入则是为了实现更加快速、精确的跟踪性能. 虽然模型 2 是模型 1 的复制, 但其权值在控制过程中将进一步调整, 以补偿建模误差, 消除不确定性的影响.

模型 2 的期望控制量与实际控制量之间的误差平方为

$$E(k) = \frac{1}{2} [\tau_\delta(k) - \tau_{\text{模型2}}(k)]^2 = \frac{1}{2} \tau_{\text{PD}}^2(k). \quad (16)$$

由梯度下降法, 权值在线调整的规律为

$$W(k+1) = W(k) + \eta \tau_{\text{PD}}(k) \cdot \Psi(k), \quad (17)$$

其中, $\eta > 0$ 为学习率.

4 仿真结果

Simulation results

本文以一艘 5446TEU 大型集装箱船的航向跟踪控制为例进行仿真, 该船基本参数见文献[9]. 由于不确定参数随航速变化而变化, 所以将船舶设定为在 1 080 s 内先加速后减速的工况, 航速变化情况如图 3 所示. 即在仿真的前 120 s 航速为 13.2 knots, 120 s 至 480 s 为提速阶段, 航速升至 26.5 knots, 并保持到 600 s, 然后到 960 s 为减速过程, 减速至 22.5 knots, 最后的 120 s 稳定在 22.5 knots^[10]. 图 4 显示出不确定参数 K, T, α, β 各自对应的变化情况.




图 3 航速变化情况

Fig. 3 Changes of speed




图 4 不确定参数的变化

Fig. 4 Changes of uncertain parameters

取学习率 $\eta = 0.05$, 在线调整模型 2 的权值, 初始航向取 45° , 左舵为正. 设定期望航向角的变化规律为

$$\psi_r(k) = 27^\circ, 0 \leq k < 500;$$

$$\psi_r(k) = 69^\circ, 500 \leq k \leq 1080. \quad (18)$$

由图3至图7可知,在控制过程中,模糊规则最多产生了13条,最终稳定到10条.均方根误差维持在原点附近很小的邻域内.船舶在动态神经模糊控制器的作用下,能够快速跟踪期望航向,动舵响应快,稳态误差小.




图5 训练中的模糊规则

Fig. 5 Fuzzy rules generated in training




图6 训练中的均方根误差

Fig. 6 Root mean square error in training




图7 航向跟踪控制

Fig. 7 Course tracking control

当期望航向发生改变时,控制效果存在一定的振荡,但船舶航向能够逐渐趋于期望航向,并最终保持稳定的跟踪效果.仿真结果表明,本算法能够有效克服建模参数不确定性的影响,实现船舶航向的跟踪控制.

5 结论

Conclusions

本文提出了一种动态神经模糊控制算法,该算法无需预先确定网络隐层节点数或模糊规则数,结构和参数同时在线调整,能充分逼近船舶的逆动力学并用于航向控制.与PD控制器并联构造的控制器能有效解决船舶航向跟踪控制问题中,建模参数随航速变化引起的不确定性因素的影响,具有一定的理论意义和实际价值.

然而,由于造成船舶运动不确定性的影响因素较多^[11-12],所以考虑由风、浪、流等外界干扰和量测误差等引起的不确定性,将有待于进一步研究.

参考文献

References

- [1] 杜佳璐,郭晨. 控制增益未知的船舶航向非线性自适应跟踪控制[J]. 控制理论与应用,2005,22(2):315-320
DU Jialu, GUO Chen. Nonlinear adaptive design for course-tracking control of ship without a priori knowledge of control gain [J]. Control Theory & Applications, 2005, 22(2): 315-320
- [2] Wang D, Huang J. Neural networks-based adaptive dynamic surface control for a class of uncertain nonlinear systems in strict-feedback form[J]. IEEE Trans Neural Networks, 2005, 16(1): 195-202
- [3] 杨国勋,郭晨,贾欣乐. 基于混合智能技术的船舶运动控制仿真研究[J]. 系统仿真学报,2002,14(5):637-640
YANG Guoxun, GUO Chen, JIA Xinle. Simulation study of ship control based on hybrid intelligent technology [J]. Journal of System Simulation, 2002, 14(5): 637-640
- [4] 张显库,吕晓菲. 船舶航向控制的鲁棒神经网络控制[J]. 船舶力学,2006,10(5):54-58
ZHANG Xianku, LÜ Xiaofei. Robust neural network control for ship's course-keeping [J]. Ship Mechanics, 2006, 10(5): 54-58
- [5] Sun F C, Sun Z Q, Zhang R J, et al. Discrete-time tracking control of robotic manipulators based on dynamic inversion using dynamic neural networks[M]. 15th IEEE International Symposium on Intelligent Control, 2000:333-338
- [6] Wu S Q, Er M J, Gao Y. A fast approach for automatic generation of fuzzy rules by generalized dynamic fuzzy neural networks[J]. IEEE Trans Fuzzy Systems, 2001, 9(4): 578-594
- [7] Yang G, Meng J E. An intelligent adaptive control scheme for post-surgical blood pressure regulation [J]. IEEE Trans Neural Networks, 2005, 16(2): 475-483
- [8] Lee S, Kil R M. A Gaussian potential function network with hierarchically self-organizing learning [J]. Neural Networks, 1991(4): 207-224
- [9] 沈智鹏. 基于广义模糊CMAC的船舶运动智能控制及其分布式仿真的研究[D]. 大连:大连海事大学,2005

- SHEN Zhipeng. Study on general fuzzified CMAC based ship motion intelligent control and its distributed simulation [D]. Dalian: Dalian Maritime University, 2005
- [10] 叶光,郭晨.基于模拟退火-强化学习算法的船舶运动控制[J].系统仿真学报,2006,18(5):1278-1282
- YE Guang, GUO Chen. Ship steering control based on SA-reinforcement learning algorithm [J]. J System Simulation, 2006, 18 (5) :1278-1282
- [11] 郭晨,汪洋,孙富春,等.欠驱动水面船舶运动控制研究综述[J].控制与决策,2009,24(3):321-329
- GUO Chen, WANG Yang, SUN Fuchun, et al. Survey of motion control of underactuated surface vessels [J]. Control and Decision, 2009, 24(3) :321-329
- [12] Wang J S, Lee G C S. Self-adaptive recurrent neuro-fuzzy control of an autonomous underwater vehicle [J]. IEEE Trans Robotics and Automation, 2003, 19(2) :283-295

Dynamic neuro-fuzzified tracking control of ship course with uncertainties

WANG Yang¹ YUE Dianwu¹ GUO Chen¹ GUO Lili²

1 College of Information Science and Technology, Dalian Maritime University, Dalian 116026

2 Department of Electronics Communication Technology, Shenzhen Institute of Information Technology, Shenzhen 518029

Abstract Aiming at the uncertainties arising from modeling parameters changing with the ship speed in course tracking control, a dynamic neuro-fuzzified model (DNFM) based tracking control algorithm is presented in this paper. The DNFM is sufficiently identified with the inverse dynamics of ship, while the structure and parameters are adjusted simultaneously. Then the well-trained DNFM, as an inverse controller, is parallel-connected with a conventional PD controller for course tracking control of the ship, with the weights value of DNFM further adjusted in this process. Simulation results of the course tracking of the large-type 5446TEU container show that the algorithm can track the course desired quickly with good control results by overcoming the effect from certainties of the modeling parameters.

Key words course tracking; uncertainties; dynamic neuro-fuzzified model; rule adjustment