

doi: 10.7690/bgzdh.2020.07.003

改进型 LM-RBF 神经网络在自抗扰控制器上的应用

唐 冲, 童仲志, 侯远龙

(南京理工大学机械工程学院, 南京 210000)

摘要: 为解决自抗扰控制器(active disturbance rejection control, ADRC)中参数较多且难以整定的问题, 提出一种基于 LM 算法且网络结构可在线优化的径向基函数(radial basis function, RBF)神经网络。利用滑动窗口的思想将在线输入的样本放入一个长度固定的队列, 将 LM-RBF 网络应用于 ADRC, 在线整定控制器参数, 并以永磁同步电机为对象在 Matlab 里进行仿真分析。结果表明: 与基于 RBF 的常规自抗扰控制器相比, 改进后 LM-RBF 使控制器有更快的响应速度及更优的抗干扰能力, 能有效提高被控系统的稳定性, 满足非线性时变系统对自抗扰控制器的性能要求。

关键词: LM 算法; RBF 神经网络; 在线整定; 自抗扰控制器

中图分类号: TP273⁺.1 **文献标志码:** A

Application of Improved LM-RBF Neural Network in ADRC

Tang Chong, Tong Zhongzhi, Hou Yuanlong

(School of Mechanical Engineering, Nanjing University of Science & Technology, Nanjing 210000, China)

Abstract: In order to solve the problem of many parameters and difficult to set in the active disturbance rejection control (ADRC), a radial basis function (RBF) neural network based on LM algorithm and online optimization of network structure is proposed. Using the idea of sliding window, the online input samples are put into a fixed-length queue, the LM-RBF network is applied to ADRC, the controller parameters are set online, and the permanent magnet synchronous motor is used as the object for simulation analysis in Matlab. The results show that compared with the RBF-based conventional active disturbance rejection controller, the improved LM-RBF enables the controller to have faster response speed and better anti-interference ability, which can effectively improve the stability of the controlled system and meet the performance requirements of the nonlinear time-varying system for the active disturbance controller.

Keywords: LM algorithm; RBF neural network; online setting; active disturbance rejection controller

0 引言

非线性时变系统的控制一直是工业控制领域内广受关注的研究热点^[1-3]。自抗扰控制器(ADRC)以其优良的适应性和鲁棒性迅速被普及到各个领域。由于待整定参数过多、过程繁琐, 加之没有成熟的理论和规律可循, ADRC 的待定参数一般都是通过试凑法进行, 工作量庞大, 给工程技术人员带来了诸多不便^[4-6]。径向基函数(RBF)神经网络是一种典型的前向神经网络, 拥有强大的非线性系统映射能力, 鲁棒性强, 且能够克服局部极小点的问题, 在工控、信号处理和非线性系统建模等领域都有所应用^[7-9]。目前已有诸多先例将 RBF 神经网络应用于 ADRC 中参数的整定工作, 免除了繁杂的参数计算, 同时获得了相对良好的控制效果^[10-12], 但就 RBF 中参数的学习算法而言, 上述应用均采用梯度下降法, 属于 1 阶算法, 在实际应用过程中收敛速度慢,

不利于 ADRC 在控制精度和响应速度方面的性能发挥。LM (levenberg-marquard) 算法是一种结合了高斯-牛顿法和梯度下降法的 2 阶算法, 有着高斯-牛顿法的局部收敛性, 同时就全局搜索的能力而言, 它的搜索速度远快于 1 阶的梯度下降法^[13-14]。LM 算法可以通过 Hessian 矩阵得出误差曲面各个梯度上的学习率, 是当前在训练神经网络应用中最有效的算法^[15]。文献 [16] 中提出的 ErrCor (error correction) 算法是使用 LM 算法来训练 RBF 神经网络。该算法鲁棒性好, 收敛速度快, 极大地改善了 RBF 网络的学习性能, 但 ErrCor 算法属于离线式设计, 无法在线训练网络参数, 在非线性时变系统的控制中, 无法发挥作用。鉴于此, 笔者设计一种基于 LM 算法的在线 RBF 神经网络算法, 利用滑动窗口的思想将在线输入的样本放入一个长度固定的队列, 在此基础上增加了对网络结构的优化操作, 实现了基于 LM 算法的 RBF 参数在线学习, 同时也增

收稿日期: 2020-02-12; 修回日期: 2020-04-18

作者简介: 唐 冲(1992—), 男, 安徽人, 硕士, 从事智能检测与控制、自抗扰控制与神经网络控制研究。E-mail: n19758797@163.com。

强了 RBF 网络的紧凑性，最后将该 LM-RBF 网络应用于 ADRC，在线整定控制器参数。

1 RBF 网络及其结构优化

1.1 RBF 神经网络

RBF 网络是一种典型的前馈型神经网络，基本的网络结构为输入层、隐含层和输出层 3 层，信息从输入层逐层向前传输，直至输出层。假设该 RBF 有 I 个输入结点， H 个隐节点，输出结点为 1。其结构如图 1 所示。




图 1 RBF 神经网络结构

设 RBF 神经网络的 I 个输入样本中第 m 个节点为 $x_m=[x_{m,1},x_{m,2},x_{m,3},\dots,x_{m,I}]$ ，则隐节点 h 的输出为

$$\varphi_h(x_m) = \exp\left(-\frac{\|x_m - c_h\|^2}{\sigma_h}\right) \quad (1)$$

式中： c_h 为隐节点 h 的核函数中心； σ_h 为隐节点 h 的宽度； $\|x_m - c_h\|$ 为两者的欧氏距离。

第 m 个样本在 RBF 网络中的输出为：

$$O_m = \sum_{h=1}^H w_h \varphi_h(X_m) + w_0 \quad (2)$$

式中： w_h 为隐节点 h 与输出节点之间的连接权值； w_0 为偏置。

1.2 LM 算法

LM 算法是一种广为使用的非线性最小二乘优化算法。目前已成功运用在 BP 神经网络中，另外，文献[16]对 LM 算法进行改进，并成功用于 RBF 网络的训练。LM 算法属于增长型算法，训练出的 RBF 神经网络结构紧凑。

RBF 网络中需要训练的参数有隐节点中核函数的中心 c 、宽度 σ 、隐节点与输出节点间的连接权值 w 。参数按如下规则进行更新：

$$\Delta_{k+1} = \Delta_k - (Q_k + \mu_k I)^{-1} g_k \quad (3)$$

式中： Q 为 Quasi-Hessian 矩阵； μ 为组合系数； I

为单位矩阵； g 为梯度向量。

将子梯度向量 η_p 求和可得梯度向量

$$g = \sum_{m=1}^M \eta_m, \eta_m = j_m^T e_m \quad (4)$$

由 Subquasi-Hessian 矩阵可得 Quasi-Hessian 矩阵：

$$Q = \sum_{m=1}^M q_m, q_m = j_m^T j_m \quad (5)$$

训练误差：

$$e_m = y_m - o_m \quad (6)$$

式中： y_m 为网络标准输出； o_m 为网络实际输出。

雅克比矩阵是 1 阶偏导数以一定方式排列成的矩阵，矩阵中第 n 行元素 $j_{m,n}$ 的计算式为：

$$j_{m,n} = \partial e_m / \partial \Delta_n \quad (7)$$

式中 n 代表 3 个可调参数： $c_{h,i}$ 、 σ_i 及 w_i 。

由微分链式法则及式(1)、(2)、(6)可得雅克比矩阵在对第 p 个样本进行学习时的行元素值为：

$$\frac{\partial e_m}{\partial w_h} = -\varphi_h(X_m), \frac{\partial e_m}{\partial w_0} = -1; \quad (8)$$

$$\frac{\partial e_m}{\partial c_{h,i}} = -\frac{2w_h \varphi_h(X_m)(x_{m,i} - c_{h,i})}{\sigma_h}; \quad (9)$$

$$\frac{\partial e_m}{\partial \sigma_h} = -\frac{w_h \varphi_h(X_m) \|X_m - c_h\|^2}{\sigma_h^2} \quad (10)$$

根据式(8)–(10)，利用全体样本求得雅克比矩阵，由式(5)算出 Quasi-Hessian 矩阵 Q ，由式(4)得梯度向量 g ，最终根据式(3)对 RBF 神经网络中的 3 个参数进行调节。

1.3 改进型 LM-RBF 在线神经网络结构及优化

尽管 LM 算法目前在训练神经网络方面的效果比其他算法都要好，但由于其只能采用批处理的方式进行离线训练，导致无法适用于需要在线训练的非线性时变系统。神经网络进行在线学习时应尽量使用最新的一组动态样本对网络参数进行调节。基于此，使用滑动窗口对在线样本进行储存，实质上是一个“先进先出”的长度固定队列，队列中的样本按照产生的时间先后顺序排列。假设队列的长度为 L ，则该队列中的元素可表示为 $[(x_i, y_i), (x_{i+1}, y_{i+1}), \dots, (x_{i+L-1}, y_{i+L-1})]$ 。每当新的样本元素产生时，处于队首的样本出队，其余元素向队首方向移动一个单位，腾出队末位置让最新样本插入。考虑到最新的样本元素具有更高的实时性，信息量更大，引

入遗忘因子 β_i 对不同时间产生的样本进行加权, 遗忘因子的计算公式为

$$\beta_i = \frac{2i}{L(L+1)}, \sum_i^L \beta_i = 1。 \quad (11)$$

由上式可知, 队列中最新的样本加权系数更大, 以提高 RBF 参数学习的有效性。

基于式(3), 得出 LM 算法训练 RBF 时的目标函数:

$$e_L = \sum_{i=1}^L \beta_i (y_i - o_i)^2。 \quad (12)$$

窗口中第 i 个样本的实际输出和标准输出分别表示 o_i 和 y_i ; L 表示窗口固定长度。

为了使 RBF 的结构更紧凑, 保证其泛化性能, 在滑动窗口的基础上添加 3 个操作: 隐节点的增加、删除、合并。

在 RBF 参数训练的同时, 检测并统计每组窗口样本学习时的均方差, 若在一定步长内的连续多组窗口样本的均方差都无法低于目标值 e_{obj} , 则新增一隐节点, 将该节点的核函数中心设为多组窗口中训练误差值最大的样本, 宽度和连接权值设为 1。窗口样本均方差的计算公式为

$$e_{rmse} = \sqrt{e_L/L}。 \quad (13)$$

若训练时, 连续多组窗口样本都无法激活某隐节点, 则删除该节点, 窗口样本的激活条件为

$$r_h^k = \left\| \frac{w_h^k \exp(-\|x_k - c_h\|^2 / \sigma_h)}{\phi_{\max}^k} \right\| \geq \lambda。 \quad (14)$$

式中: w_h^k 为 k 时刻隐节点 h 与输入节点间的连接权值; ϕ_{\max}^k 为 k 时刻所有隐节点的输出值中绝对值最大的值; r_h^k 为 k 时刻隐节点 h 的归一化输出; λ 为给定阈值。

当 RBF 网络中 2 个隐节点的中心距离以及宽度都十分接近时, 合并这 2 个隐节点, 在不影响 RBF 网络性能的同时精简了网络结构。合并操作如下:

$$\left. \begin{aligned} c_i &= (c_i + c_j) / 2 \\ \sigma_i &= \max(\sigma_i, \sigma_j) \\ w_i &= w_i + w_j \end{aligned} \right\}。 \quad (15)$$

改进后的 RBF 神经网络通过滑动窗口实现 LM 算法无法在线学习 RBF 网络参数的问题, 同时新增的 3 个操作让隐节点的增删更具针对性, 确保 RBF 网络结构紧凑, 泛化性能优。

综合以上设计思想, 将基于 LM 算法的且网络

结构可在线优化的 RBF 神经网络算法描述如下:

- 1) 初始化隐节点数为 1, 窗口长度 L 自定, 并滑入第一个窗口样本。
- 2) 滑入最新的在线输入样本, 并移除队首元素。
- 3) 根据式(13)计算当前窗口中样本的均方差, 记录当前训练误差绝对值最大的样本。据式(14)计算所有隐节点的输出, 并判断其激活状态。
- 4) 达到预定步长时: ① 如果 $e_{rmse} > e_{obj}$, 则增加隐节点; ② 如果存在多个样本都无法激活的隐节点, 则删除; ③ 检测是否存在冗余的隐节点, 如果存在, 则根据式(15)将其合并。
- 5) 根据式(3)—(10)用 LM 算法调整 RBF 神经网络中的可调参数。
- 6) 如果训练到达最后一个样本, 则结束; 如果还有样本待训练, 则转入第 2)步。

2 自抗扰控制器

自抗扰控制器由中科院研究员韩京清于 1998 年提出, 由 3 部分组成: 跟踪微分器、扩张状态观测器、非线性反馈控制律。通过引入扩张状态观测器, 把系统内部模型的不确定性以及外部环境的扰动通过“总和扰动”的形式传给系统进行实时估计, 并将估计结果反馈给系统进行前馈补偿(考虑是否加入自抗扰控制器的经典结构图), ADRC 以其“主动抗扰”的设计思想迅速被应用于各领域内的研究工作, 但其可调参数过多且较难整定的缺点给广大研究人员带来了诸多不便, 限制了 ADRC 的推广; 因此, 利用文中改进的基于 LM 算法的在线 RBF 神经网络进行 ADRC 的参数整定, 将极大地减小研究人员的工作量, 同时由于 LM 算法具有远超一阶算法的学习速度, ADRC 控制器的快速性和鲁棒性也将得到提升。

2.1 微分跟踪器设计

微分跟踪器根据参考输入和被控对象的限制安排过渡过程, 并提供过渡过程的各阶导数, 有效改善了经典控制中由于设定值突变导致的超调现象。

采用离散形式的最速微分跟踪器:

$$\left. \begin{aligned} x_1(k+1) &= x_1(k) + hx_2 \\ x_2(k+1) &= x_2(k) + h \cdot f_h \\ f_h &= \text{fhan}(x_1(k) - v(k), x_2(k), r, h) \end{aligned} \right\}。 \quad (16)$$

式中: x_1 和 x_2 分别为指令及其微分的跟踪值; h 为积分步长; r 决定着跟踪速度; $\text{fhan}(\cdot)$ 为系统的最速控制综合函数, 其形式为:

3 仿真分析

永磁同步电机(permanent magnet synchronous motor, PMSM)是典型的非线性时变系统。选取PMSM伺服系统为实验对象,以基于梯度下降法调整网络参数的RBF-ADRC为比对,在Matlab里进行仿真分析,以验证笔者提出的基于LM算法的在线RBF神经网络在自抗扰控制器上是否能够发挥预期的效果。该被控系统的参数如下:电机转矩系数 $K_d=0.195 \text{ N}\cdot\text{m}/(\text{rad}\cdot\text{s}^{-1})$;等效转惯量 $J=5.556\times 10^{-3} \text{ kg}\cdot\text{m}^2$;摩擦力矩扰动 $T_f=850 \text{ kg}\cdot\text{m}$;负载扰动力矩 $T_L=9.32\times 10^{-3} \text{ kg}\cdot\text{m}$;减速比 $i=1039$;反电动势系数 $C_e=0.195 \text{ V}/(\text{rad}\cdot\text{s}^{-1})$;粘性摩擦系数 $B=1.43\times 10^{-4} \text{ N}\cdot\text{m}/(\text{rad}\cdot\text{s}^{-1})$ 。

通过大量搜寻实验,将笔者设计的LM-RBF-ADRC控制器的参数做以下设置:LM-RBF神经网络中 $L=3$;微分控制器中 $r=80$, $h=0.01$;扩张状态观测器中 $\alpha_1=1$, $\alpha_2=0.5$, $\alpha_3=0.25$, $\beta_{01}=20$, $\beta_{02}=100$, $\beta_{03}=200$, $b=10$;非线性控制律中 $\alpha_4=0.75$, $\alpha_5=1.25$ 。数值仿真结果见图3—5。图3为系统输入阶跃信号响应曲线,图4是系统在第4s时添加300 N·m的负载扰动后的位置响应曲线,图5为正弦跟踪误差。




图3 阶跃响应




图4 加入负载扰动的阶跃响应




图5 正弦跟踪误差

从图3可以看出:LM-RBF-ADRC和RBF-ADRC均无超调,但后者的响应速度相对于前者明显较慢,响应时间为0.8s,前者仅用时0.45s,速度提升近1倍。同时,在抗扰能力方面,LM-RBF-ADRC也很大程度减弱了扰动的影响。

从图4可以看到:当负载扰动出现时,采用LM-RBF神经网络的自抗扰控制器能够更快地恢复到正常状态,并且其偏离目标信号的程度相比RBF-ADRC有大幅度下降。

由图5可知:LM-RBF-ADRC对正弦输入信号的跟踪误差范围为 $[-0.1, 0.1]$,而RBF-ADRC对于正弦信号的跟踪误差范围是 $[-0.5, 0.3]$ 。可以看出:经LM-RBF神经网络整定的自抗扰控制器跟踪误差更小,控制精度更高。

以上对比反映出基于LM-RBF-ADRC拥有比RBF-ADRC更优秀的控制性能。这主要得益于LM-RBF具有以下特性:1)相较于梯度下降法等一阶算法,LM是2阶算法,收敛速度快且鲁棒性强,是到目前为止最为高效的神经网络学习算法;2)经过改进后的RBF神经网络在结构上更加紧凑灵活,泛化能力也更强。

4 结束语

针对ADRC中参数较多且难以整定的问题,将RBF神经网络引入ADRC,设计了基于LM算法的改进型RBF网络,并将改进型LM-RBF与ADRC控制技术相结合,应用在非线性时变系统的控制中,既充分发挥了LM算法的快速收敛性能和RBF神经网络对非线性函数优良的逼近能力,又克服了ADRC参数过多不易整定的问题。仿真结果表明:结合了LM-RBF的ADRC显著提高了控制系统的敏捷性和抗扰能力,具有良好的应用前景。

参考文献:

- [1] 孙明轩,何海港,孔颖.基于时变动态神经网络的非线性时变系统辨识[C]//第三十二届中国控制会议论文集.西安:中国自动化学会控制理论专业委员会,中国系统工程学会,2013:6.
- [2] 曲子芳,杜贞斌.非线性时变时延系统的模糊采样最优控制[J].控制与决策,2018,33(11):152-155.
- [3] 童仲志,张媛,邢宗义,等.某装备扫雷犁系统的遗传神经网络建模研究[J].兵工学报,2010,31(5):650-656.
- [4] 李杰,齐晓慧,万慧,等.自抗扰控制:研究成果总结与展望[J].控制理论与应用,2017,34(3):281-295.




图 6 部分炸点捕捉示意

4 结束语

针对炮兵对抗训练系统中炸点捕捉难的问题，笔者提出一种基于 YOLACT 的快速炸点区域分割方法。针对炸点目标特性对特征提取网络特征融合方式及候选框参数进行修改和微调，提高了识别精度和速度；通过掩膜生成网络和预测分支对多个掩膜进行融合，实现了炸点目标识别及分割。实验结果表明：在构建的炸点数据集上，文中算法实现了快速准确地识别炸点目标，能够较好地解决炮兵对抗训练中的问题。

参考文献：

[1] 靳莹, 杨润泽. 声测定位技术的现状研究[J]. 电声技术, 2007, 31(2): 4-8.

[2] 羽佳. 主动式高速目标探测方法的研究[D]. 天津: 天津大学, 2004: 9-12.

[3] 赵艳丽. 弹道导弹雷达跟踪与识别研究[D]. 长沙: 国防科技大学, 2007: 5-7.

(上接第 15 页)

[5] WANG R, LU B, HOU Y, et al. Passivity-based control for rocket launcher position servo system based on improved active disturbance rejection technology[J]. Advances in Mechanical Engineering, 2018, 10(3): 168781401876674.

[6] 魏立新, 赵默林, 范锐, 等. 基于改进鲨鱼优化算法的自抗扰控制参数整定[J]. 控制与决策, 2019, 34(4): 816-820.

[7] 胡达, 童仲志, 侯远龙, 等. 基于神经网络的 PMSM 分数阶积分滑模控制[J]. 兵工自动化, 2019(5): 81-85.

[8] 周维华. RBF 神经网络隐层结构与参数优化研究[D]. 上海: 华东理工大学, 2014: 23-28.

[9] 姜雪莹, 陶文华, 施惠元, 等. 基于 RBF 神经网络的非线性迭代预测控制[J]. 控制工程, 2019, 26(3): 454-460.

[10] 李匡成. 基于 RBF 神经网络的伺服系统自适应自抗扰控制[J]. 电气自动化, 2010, 32(2): 23-25.

[11] 袁川. 某型多管火箭炮伺服系统负载扰动抑制研究与

防科学技术大学, 2007: 5-7.

[4] 刘峰, 赵广伟, 王向军. 增强区域全卷积网络下的炸点检测方法研究[J]. 计算机辅助设计与图形学学报, 2019, 31(3): 412-420.

[5] S, HE K, GIRSHICK R, et al. Faster R-CNN: towards real-time object detection with region proposal networks[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2015, 39(6): 1137-1149.

[6] LIU W, ANGUELOV D, ERHAN D, et al. SSD: single shot multibox detector[C]. European Conference on Computer Vision, 2016: 21-37.

[7] TIAN Z, SHEN C H, CHEN H, et al. FCOS: fully convolutional one-stage object detection[EB/OL]. [2019-04-02]. <https://arxiv.org/abs/1904.01355>.

[8] KAIMING H, GEORGIA G, PIOTR D, et al. Mask R-CNN[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2018, 99: 1.

[9] BOLYA D, ZHOU C, XIAO F, et al. YOLACT: real-time instance segmentation[EB/OL]. [2019-04-04]. <https://arxiv.org/abs/1904.02689>.

[10] 王涵, 朱虹旭, 周双喜. 基于虚拟现实技术的对抗指挥训练[J]. 国防科技, 2018, 39(1): 117-119.

[11] LIN T Y, DOLLÁR P, GIRSHICK R, et al. Feature pyramid networks for object detection[C]. Honolulu: The 31th IEEE Conference on Computer Vision and Pattern Recognition, Honolulu, USA, July 22-25, 2017.

[12] HE K, ZHANG X, REN S, et al. Deep Residual Learning for Image Recognition[C]. IEEE Conference on Computer Vision and Pattern Recognition, 2016: 770-778.

实现[D]. 南京: 南京理工大学, 2014: 46-51.

[12] 丁网芳, 刘星桥. 采用自抗扰控制的三电机同步协调系统[J]. 信息技术, 2018, 27(2): 22-27.

[13] HAGAN M T, MENHAJ M B. Training feedforward networks with the Marquardt algorithm[J]. IEEE Transactions on Neural Networks, 1994, 5(6): 989-993.

[14] WILAMOWSKI B M, CHEN Y, MALINOWSKI A. Efficient algorithm for training neural networks with one hidden layer[C]//International Joint Conference on Neural Networks. IEEE Xplore, 1999: 827-834.

[15] WILAMOWSKI B M, YU H. Improved Computation for Levenberg-Marquardt Training[J]. IEEE Transactions on Neural Networks, 2010, 21(6): 930-937.

[16] YU H, REINER P D, XIE T, et al. An Incremental Design of Radial Basis Function Networks[J]. IEEE Transactions on Neural Networks and Learning Systems, 2014, 25(10): 1793-1803.

[17] 韩京清. 自抗扰控制技术——估计补偿不确定因素的控制技术[M]. 北京: 国防工业出版社, 2008: 276-292.