

文章编号 :1001-2486(2001)06-0104-05

多层局部回归神经网络在 激光陀螺捷联惯导系统惯性传感器误差补偿中的应用

吴美平 胡小平

(国防科技大学机电工程与自动化学院,湖南长沙 410073)

摘要 惯导系统误差补偿技术对提高武器装备的性能具有重要的意义,而误差补偿的关键在于误差模型的辨识。探讨将多层局部回归神经网络引入到惯性传感器误差建模中,详细介绍了网络结构和对应的自适应动态梯度算法。仿真算例说明,多层局部回归神经网络在惯性传感器输出误差建模时具有一定的优点:网络收敛速度快、较好的跟踪性能、稳定性好。

关键词 捷联惯导系统;误差模型;多层局部回归神经网络;动态梯度算法

中图分类号:U666.11;TP14 文献标识码:A

A Multi-layer Local Recurrent Neural Networks Applied to Compensation for Inertial Sensors' Errors of Laser Gyro SINS

WU Mei-ping, HU Xiao-ping

(College of Mechatronics Engineering and Automation, National Univ. of Defense Technology, Changsha 410073, China)

Abstract It's important to improve the performance of the weapon by compensating for errors of inertial sensors. Identification of error model is the key of compensating for errors. A multi-layer local recurrent neural networks is adopted to model the errors of inertial sensors. The framework of networks and adaptable dynamic gradient arithmetic are presented in detail. The result of simulation example shows that multi-layer local recurrent neural networks has some advantage for modeling errors of inertial sensors' output: rapid convergence, good performance of tracking and stabilization.

Key words SINS; errors model; multi-layer local recurrent neural networks; adaptable dynamic gradient arithmetic

惯导系统采用高精度的惯性传感器是提高导航系统精度的主要手段,但是单纯依靠提高惯性传感器的精度来提高导航系统的精度,在目前情况下由于精密仪器、微电子技术领域的薄弱,困难是很大的,而且成本很高。因此,研究新的惯性传感器误差补偿技术来提高导航系统的精度就尤为重要。

由于激光陀螺捷联惯导系统具备适合于高动态环境、成本低、可靠性好、性能价格比高等优点,在军用、民用方面被广泛应用^[1~3],在现在和未来一段时间里,中等精度的激光陀螺捷联惯导系统具有广阔的市场。由于捷联系统的结构特点引起的动态误差,必须通过误差补偿技术来提高导航系统定位定向精度,因此研究激光陀螺捷联惯导系统误差补偿技术对提高武器装备的性能具有重要的意义。

对于惯性传感器误差补偿关键在于误差模型的建立。根据系统辨识理论,误差模型可以直接通过所获取的输入—输出数据来建立惯性传感器误差模型,就是直接将模型辨识和参数辨识一起通过输入—输出数据来得到。

由于前向多层神经网络和回归网络具有非线性逼近的能力,还具有自适应、自学习、并行分布式处理的特点,在控制领域中得到了广泛的应用^[4,5]。我们设想采用前向多层神经网络或回归网络来拟合惯性传感器动态输出误差模型。一些同行对此进行过有益的探讨,得到了一些有益的研究结论^[6,7]。但是,采用神经网络来建模关键在于网络训练样本的获取,即输入—输出数据的获取,和采用能反映系统动态性且收敛速度快的网络。

根据惯性传感器误差的动态特性,本文探讨将多层局部回归神经网络引入到惯性传感器误差建模

* 收稿日期:2001-05-10
基金项目:国家部委预研基金资助。
作者简介:吴美平(1970-)男,讲师,博士。

中去。由于多层局部回归神经网络是在前馈网络同层节点间引入负反馈或自反馈,理论上已证明其具有很强的动态逼近能力,可用来描述任意的非线性动态系统^[8,9]。并且为了加速网络的收敛速度,网络训练采用自适应变步长动态梯度法^[10]。

1 多层局部回归神经网络结构

多层局部回归神经网络是在前馈网络同层节点间引入负反馈与自反馈,而在相邻层节点间没有反馈连接。网络结构如图1所示。




图1 多层局部回归神经网络结构图

Fig.1 Construction of RNN

设一个多层局部回归神经网络有 L 层,第 l 层有 n_l 个节点($l = 1, \dots, L$),节点特性为 Sigmoid 型,则网络回归方程为

$$X_l(k) = W_{l-1,d} Y_{l-1}(k) + W_{l,d} Y_l(k-1) + B_l \quad (1)$$

$$Y_l(k) = f[X_l(k)] \triangleq \begin{bmatrix} f[x_{l,1}(k)] \\ \vdots \\ f[x_{l,m_l}(k)] \end{bmatrix} \quad (2)$$

其中, $X_l(k) = [x_{l,1}(k) \dots x_{l,m_l}(k)]^T$ 表示第 l 层节点在 k 时刻的状态,

$Y_l(k) = [y_{l,1}(k) \dots y_{l,m_l}(k)]^T$ 表示第 l 层节点在 k 时刻的输出,

$Y_l(k-1) = [y_{l,1}(k-1) \dots y_{l,m_l}(k-1)]^T$ 表示第 l 层节点在 $k-1$ 时刻输出,

$Y_{l-1}(k) = [y_{l-1,1}(k) \dots y_{l-1,m_{l-1}}(k)]^T$ 表示第 $l-1$ 层节点在 k 时刻的输出,

$W_{l-1,d}$ 表示第 $l-1$ 层节点与第 l 层节点间的连接权值,

$W_{l,d}$ 表示第 l 层节点间的自回归连接权值。

2 自适应变步长动态梯度学习算法

根据惯性导航系统的使用特点,要求辨识误差模型时所需的时间短。因此,在训练多层局部回归网络时采用自适应变步长动态梯度学习算法,这样可以大大提高网络训练的收敛速度。

网络采用批处理学习方法,设误差函数为

$$E = \frac{1}{2} \sum_{k=1}^M \left\{ \sum_{j=1}^{n_L} [y_{L,j}(k) - \hat{y}_{L,j}(k)]^2 \right\} \quad (3)$$

式中, M 为序列长度(即训练样本数), n_L 为输出层的节点数, $y_{L,j}(k)$ 、 $\hat{y}_{L,j}(k)$ 分别为输出层节点 j 在 k 时刻的实际输出和期望输出。网络的动态梯度计算如下:

$$\frac{\partial E(k)}{\partial \omega_{[l,j][l,i]}} = \sum_{m=1}^{n_L} \left\{ [y_{L,m}(k) - \hat{y}_{L,m}(k)] \frac{\partial y_{L,m}(k)}{\partial \omega_{[l,j][l,i]}} \right\} \quad (4)$$

而

$$\frac{\partial y_{L,m}(k)}{\partial \omega_{[l,j][l,i]}} = f[x_{L,m}(k)] \left\{ \sum_{p=1}^{n_{L-1}} \omega_{[L-1,p][L,m]} \frac{\partial y_{L-1,p}(k)}{\partial \omega_{[l,j][l,i]}} + \sum_{q=1}^{n_L} \omega_{[L,q][L,m]} \frac{\partial y_{L,q}(k-1)}{\partial \omega_{[l,j][l,i]}} \right\} \quad (5)$$

网络节点输出对权值的动态梯度为

$$\begin{cases} \frac{\partial y_{l,m}(k)}{\partial \omega_{[l,j]I_{l,i}}} = f[x_{l,m}(k)] \left\{ y_{l,j}(k-1) + \sum_{m=1}^{n_l} \omega_{[l,m]I_{l,n}} \frac{\partial y_{l,m}(k-1)}{\partial \omega_{[l,j]I_{l,i}}} \right\} \\ \frac{\partial y_{l,m}(k)}{\partial \omega_{[l-1,j]I_{l,i}}} = f[x_{l,m}(k)] \left\{ y_{l-1,j}(k) + \sum_{m=1}^{n_l} \omega_{[l,m]I_{l,n}} \frac{\partial y_{l,m}(k-1)}{\partial \omega_{[l-1,j]I_{l,i}}} \right\} \\ \frac{\partial y_{l,m}(k)}{\partial b_{l,i}} = f[x_{l,m}(k)] \left\{ 1 + \sum_{m=1}^{n_l-1} \omega_{[l,m]I_{l,n}} \frac{\partial y_{l,m}(k-1)}{\partial b_{l,i}} \right\} \end{cases} \quad (6)$$

参数修正采用变步长自适应梯度下降法, 设

$$\begin{cases} \Delta \omega_{[l,j]I_{l,i}}(k) = -\eta_{[l,j]I_{l,i}}(s) = \frac{\partial E(k)}{\partial \omega_{[l,j]I_{l,i}}(k)} \\ \Delta \omega_{[l-1,j]I_{l,i}}(k) = -\gamma_{[l-1,j]I_{l,i}}(s) = \frac{\partial E(k)}{\partial \omega_{[l-1,j]I_{l,i}}(k)} \\ \Delta b_{l,i}(k) = -\zeta_{l,i}(s) = \frac{\partial E(k)}{\partial b_{l,i}(k)} \end{cases} \quad (7)$$

式中, s 为递归次数。

$$\begin{cases} \eta_{[l,j]I_{l,i}}(s) = \eta_{[l,j]I_{l,i}}(s-1) + \Delta \eta_{[l,j]I_{l,i}}(s) \\ \gamma_{[l-1,j]I_{l,i}}(s) = \gamma_{[l-1,j]I_{l,i}}(s-1) + \Delta \gamma_{[l-1,j]I_{l,i}}(s) \\ \zeta_{l,i}(s) = \zeta_{l,i}(s-1) + \Delta \zeta_{l,i}(s) \end{cases} \quad (8)$$

$$\begin{cases} \Delta \eta_{[l,j]I_{l,i}}(s) = \epsilon_1 \cdot \lambda_{[l,j]I_{l,i}}(s) \cdot \eta_{[l,j]I_{l,i}}(s-1) \\ \Delta \gamma_{[l-1,j]I_{l,i}}(s) = \epsilon_2 \cdot \alpha_{[l-1,j]I_{l,i}}(s) \cdot \gamma_{[l-1,j]I_{l,i}}(s-1) \\ \Delta \zeta_{l,i}(s) = \epsilon_3 \cdot \chi_{l,i}(s) \cdot \zeta_{l,i}(s-1) \end{cases} \quad (9)$$

$$\begin{cases} \lambda_{[l,j]I_{l,i}}(s) = \text{sign} \left\{ \frac{\partial E}{\partial \omega_{[l,j]I_{l,i}}(s)} \frac{\partial E}{\partial \omega_{[l,j]I_{l,i}}(s-1)} \right\} \\ \alpha_{[l-1,j]I_{l,i}}(s) = \text{sign} \left\{ \frac{\partial E}{\partial \omega_{[l-1,j]I_{l,i}}(s)} \frac{\partial E}{\partial \omega_{[l-1,j]I_{l,i}}(s-1)} \right\} \\ \chi_{l,i}(s) = \text{sign} \left\{ \frac{\partial E}{\partial b_{l,i}(s)} \frac{\partial E}{\partial b_{l,i}(s-1)} \right\} \end{cases} \quad (10)$$

其中, $\epsilon_1, \epsilon_2, \epsilon_3$ 为 $[0, 1]$ 的常数。

因此, 可得权值修正公式为

$$\omega_{[l,j]I_{l,i}}(k) = \omega_{[l,j]I_{l,i}}(k-1) + \Delta \omega_{[l,j]I_{l,i}}(k) \quad (11)$$

$$\omega_{[l-1,j]I_{l,i}}(k) = \omega_{[l-1,j]I_{l,i}}(k-1) + \Delta \omega_{[l-1,j]I_{l,i}}(k) \quad (12)$$

$$b_{l,i}(k) = b_{l,i}(k-1) + \Delta b_{l,i}(k) \quad (13)$$

3 跑车试验^[11]

为了验证神经网络补偿模型的效果, 我们进行了一次跑车试验。试验中, 我们同时采集惯性敏感器的输出数据和 GPS 的数据, 然后对数据进行处理。

由于在跑车试验中, 标称点参数无法获取。而惯导系统在长时间工作后, 累积的系统误差远大于 GPS 的噪声, 因此采用同一时刻的 GPS 参数作为标称参数。

神经网络拟合惯性敏感器输出误差模型时, 采用四层局部回归神经网络(RNN 网络)时, 激光陀螺和加速度计输出误差网络分别为 $3 \times 3 \times 3 \times 3$ 结构。对试验数据进行处理, 得到不同时间对应的水平位置、速度参数的误差(与 GPS 参数比较), 见表 1。其中, SINS 表示纯惯导系统; RNN 表示采用局部回归神经网络补偿模型补偿的惯导系统。

表1 水平位置、速度参数误差比较

Tab.1 Errors comparison of level position and velocity

时间 (min)	方案	水平位置误差		水平速度误差	
		$\Delta L(m)$	$\Delta \lambda(m)$	$\Delta V_x(m/s)$	$\Delta V_y(m/s)$
5	SINS	181.25	-931.81	-5.00	-2.31
	RNN	91.18	-830.63	-4.13	-4.13
10	SINS	-985.18	-4144.24	-11.19	-3.47
	RNN	-570.43	-3380.33	-9.21	-1.63
15	SINS	-2769.87	-7219.89	-10.02	-6.36
	RNN	-1308.76	-4818.11	3.72	-1.97
20	SINS	-4853.66	-10581.32	-8.87	7.27
	RNN	-1494.46	-5490.81	2.40	-0.53
22	SINS	-5643.15	-11817.8	9.36	-5.05
	RNN	-1294.31	-5174.13	2.44	1.53

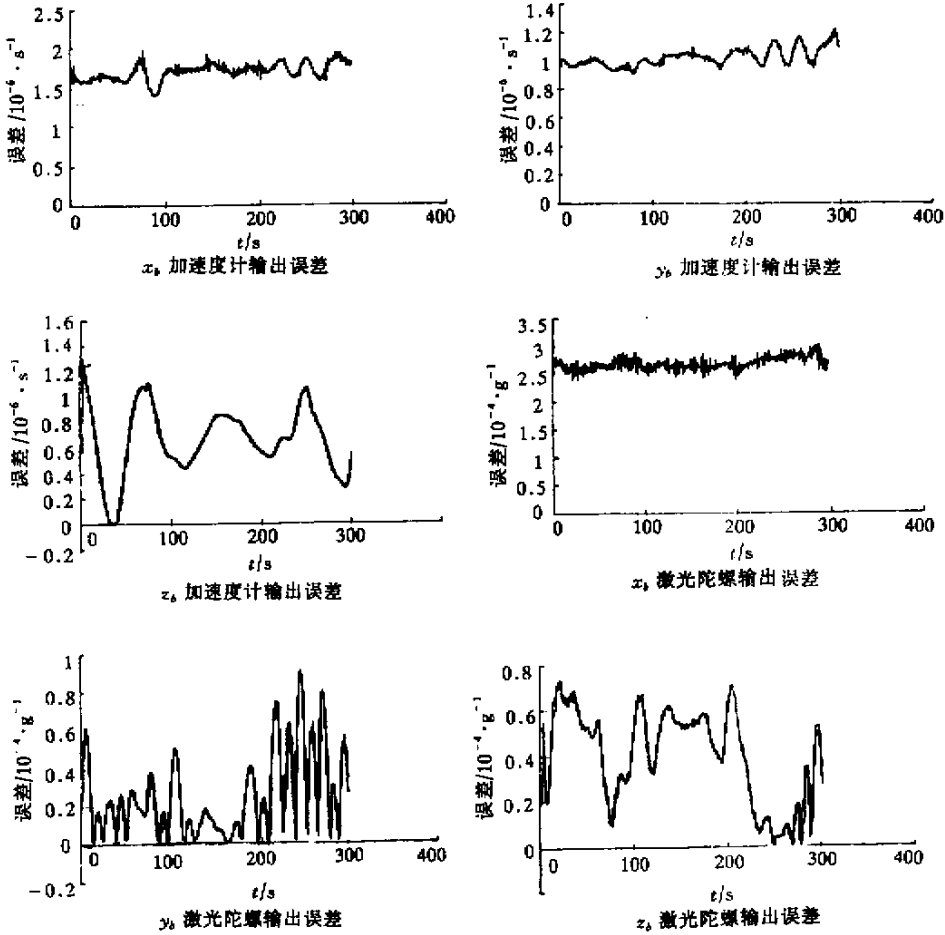


图2 惯性传感器 RNN 网络补偿器训练结果

Fig.2 Trained results of inertial sensors RNN compensator

4 结论与分析

将表1的数据进行比较可以知道,采用RNN网络模型补偿,对于纬度误差有30%~50%的抑制作用,对于经度误差有20%~50%的抑制作用。并且网络补偿模型明显地提高了测速精度。

从试验数据的处理结果可以知道,RNN网络具有好的动态跟踪特性,稳定性也更好。由于RNN网络引入负反馈和自反馈环节,使网络具有更强的动态跟踪能力。并且,RNN网络采用变步长自适应梯度算法,具有更快的收敛速度。

为了说明RNN网络对惯性敏感器误差建模的有效性,将试验中其对惯性敏感器输出误差的训练结果示于图2。可以看出,训练好的RNN网络动态跟踪性能非常好,能很好地拟合出惯性敏感器输出误差规律,网络输出数据与样本数据基本重合。

通过试验的数据处理结果分析,表明采用局部回归神经网络模型补偿惯性敏感器输出误差能有效抑制惯导系统位置、速度误差的发散,提高了惯导系统的定位、测速精度。这说明采用神经网络模型补偿惯性敏感器误差能使惯导系统在不依赖于外部信息条件下明显地提高定位、测速精度,对于发展高精度惯性导航系统有一定的借鉴意义。

参考文献:

- [1] 高伯龙. 激光陀螺[M]. 长沙:国防科技大学出版社,1984.
- [2] [俄]谢列金 B B,库库利耶夫 P M. 激光陀螺及其应用[M]. 北京:航空工业出版社,1992.
- [3] George T Schmutd. GPS/INS Technology Trends for Military Systems[C]. AIAA-Guidance, Navigation, and Control Conference, New Orleans, La. August 11-13, 1997.
- [4] 胡守仁. 神经网络导论[M]. 长沙:国防科技大学出版社,1993.
- [5] 胡守仁. 神经网络应用技术[M]. 长沙:国防科技大学出版社,1993.
- [6] 卞鸿巍等. 用灰色理论和神经网络理论建立陀螺漂移模型初探[J]. 中国惯性技术学报,1997,(4).
- [7] 陈平等. 基于神经网络的误差补偿滤波器在陀螺漂移误差模型辨识中的应用[J]. 中国惯性技术学报,1998,(1).
- [8] Markus Rupp, Sayed H. Supervised Learning of Perceptron and Output Feedback Dynamic Networks: A Feedback Analysis via the Small Gain Theorem[J]. IEEE Transaction on Neural Networks, 1977,(3).
- [9] Kumpati S Narendre, Snehasis Mukhopadhyay. Adaptive Control Using Neural Networks and Approximate Model[J]. IEEE Transaction on Neural Networks, 1977,(3).
- [10] 张兰玲等. 基于多层局部回归神经网络的复杂生产过程预测模型[J]. 模式识别和人工智能,1998,11(1).
- [11] 吴美平. 激光陀螺捷联惯导系统误差补偿技术研究[D]. 长沙:国防科技大学研究生院,2000.

