

组合导航系统的神经元信息融合模型*

陶俊勇, 温熙森, 陶利民

(国防科技大学机电工程与自动化学院, 湖南长沙 410073)

摘要: 提出了一种基于神经元状态融合的组合导航系统信息融合模型, 给出了神经元融合权重在线自适应学习算法。将该模型应用于车载 SINS/GPS 组合导航系统, 通过仿真计算和实验室静态组合导航实验, 验证了该信息融合模型及融合权重在线自适应学习算法在实际应用中的有效性和可行性。

关键词: 神经元; 组合导航系统; 信息融合

中图分类号: TP277 **文献标识码:** A

Information Fusion Model of Integrated Navigation System Based on Neurons

TAO Jun-yong, WEN Xi-sen, TAO Li-min

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

Abstract: An information fusion model of integrated navigation system based on neurons is proposed, and also an on-line adaptive training algorithm of the weights of neuron is given. Moreover the fusion model of the SINS/GPS integrated navigation system for vehicle is implemented. The theoretical analysis and laboratory experimental results show that this model and adaptive training algorithm are effective and practical.

Key words: neuron; integrated navigation system; information fusion

基于分散卡尔曼滤波的组合系统信息融合过程分两个阶段, 即先由各局部滤波器得到系统状态的局部估计, 然后将各局部状态估计传递给融合中心, 产生一个全局状态估计, 为了得到最优全局状态估计, 需要知道各局部状态估计的协方差, 文献 [1] 给出了各种估计协方差的方法, 但要保证这些方法的有效性, 要求载体的状态方程非常精确。为了在缺少协方差的情况下, 仍能使融合中心有效地融合各局部状态估计, 文献 [2] 提出了一种用于状态估计的神经元融合方法, 文献 [3] 将这种方法应用于组合系统信息融合中, 并在各局部滤波器中用残差 χ^2 检验检测各子系统故障, 以便根据各子系统的工作状态选择不同的神经元组作为融合中心, 由于残差 χ^2 检验对系统缓变故障不敏感, 因此可能影响到该方法的应用效果。文献 [2, 3] 中用于状态融合的神经元权重采用离线训练在线应用方式, 如果在融合过程中某一局部状态估计的精度发生变化, 而相应的神经元融合权重不变, 将影响到全局融合的精度。本文提出了一种组合系统的神经元信息融合模型及权重在线自适应学习算法。

1 组合导航系统的神经元信息融合模型

1.1 基于神经元的状态融合方法

假设组合系统由 N 个子系统组成, 相应地, 由 N 个局部滤波器在 k 时刻得到对系统状态的 N 个局部估计为: $\hat{X}_i(k)$, $i = 1, 2, \dots, N$ 。最优全局融合状态是这 N 个局部估计及相应协方差 P_i 所决定的条件均值, 即

$$\hat{X}_f(k) = E \{X(k) | \hat{X}_i, P_i, i = 1, 2, \dots, N\} \quad (1)$$

* 收稿日期: 2002-01-08

基金项目: 国家部委基金资助项目 (97J9.3.6KG0136)

作者简介: 陶俊勇 (1969—), 男, 讲师, 博士。

参见文献 [2] 推导过程得到极大似然估计 \hat{X}_f 及其协方差阵 P_f 为：

$$\begin{cases} \hat{X}_f = (e^T \Sigma^{-1} e)^{-1} e^T \Sigma^{-1} \mu \\ P_f = (e^T \Sigma^{-1} e)^{-1} \end{cases} \quad (2)$$

其中 $e_{nN \times n} = [I, I, \dots, I]^T$

$$\Sigma_{nN \times nN} = [E \{ (X - \hat{X}_i)(X - \hat{X}_j)^T \}], \mu_{nN \times 1} = (\hat{X}_1^T, \hat{X}_2^T, \dots, \hat{X}_N^T)^T$$

为了得到最优全局状态估计，在各局部状态估计协方差未知的情况下，需要精确估计矩阵 Σ 。然而由 (2) 式可见，实际上并不需要知道 Σ ，而只需要得到 $W = (e^T \Sigma^{-1} e)^{-1} e^T \Sigma^{-1}$ 的估计值，即

$$\hat{X}_f = W\mu \quad (3)$$

如果 \hat{X}_f 是一标量，对于 N 个局部状态估计，则 W 是一个 $(1 \times N)$ 的矢量。假设第 i 个局部状态估计的方差是 σ_i^2 ，且各局部状态估计相互独立，则 Σ 是一对角矩阵，且 W 的第 i 个元素为

$$w_i = (1/\sigma_i^2) / \sum_{i=1}^N (1/\sigma_i^2) \quad (4)$$

显然上式满足约束条件

$$\sum_{i=1}^N w_i = 1, \quad w_i \geq 0 \quad (5)$$

如果用一个神经元来表示 (3) 式的融合过程，则 W 和 μ 分别是神经元的输入权重矢量和输入矢量，因此要得到最优全局估计 \hat{X}_f ，只需要估计神经元的权重即可，而无须估计方差。

1.2 组合导航系统的神经元信息融合模型

利用神经元固有的融合特性，提出了一种组合系统神经元融合模型^[5]，其结构原理如图 1 所示。该融合模型利用两级数据处理技术，由多个局部滤波器和一个神经元融合中心组成。参考系统的输出给各局部滤波器作为测量值。各子系统的输出只给相应的局部滤波器，各局部滤波器的局部估计 \hat{X}_j 送入融合中心进行融合，得到全局最优估计 \hat{X}_f 。根据是否用融合状态 \hat{X}_f 对各局部滤波器进行重置 (图中虚线所示)，可将该融合模型分为有反馈型和无反馈型两种结构。神经元融合中心由 n 个神经元组成，第 i 个神经元 N^i 完成对所有 N 个局部状态估计 \hat{X}_j ($j=1, 2, \dots, N$) 的第 i 个分量 \hat{X}_j^i ($i=1, 2, \dots, n$) 的融合，以产生全局最优状态 \hat{X}_f 的第 i 个分量 \hat{X}_f^i ($i=1, 2, \dots, n$)，即每个神经元都有 N 个输入和一个输出。需要指出的是：融合只是对局部滤波器的公共状态进行的，对各子系统特有的误差状态不进行融合。




图 1 组合导航系统的神经元信息融合模型

Fig.1 Information fusion model of integrated navigation system based on neurons

融合中心由 n 个神经元组成，第 i 个神经元 N^i 完成对所有 N 个局部状态估计 \hat{X}_j ($j=1, 2, \dots, N$) 的第 i 个分量 \hat{X}_j^i ($i=1, 2, \dots, n$) 的融合，以产生全局最优状态 \hat{X}_f 的第 i 个分量 \hat{X}_f^i ($i=1, 2, \dots, n$)，即每个神经元都有 N 个输入和一个输出。需要指出的是：融合只是对局部滤波器的公共状态进行的，对各子系统特有的误差状态不进行融合。

2 神经元融合权重学习算法

神经元权重的学习训练分两个阶段。一是利用历史数据或仿真数据进行离线训练，以确定正常情况下各局部状态估计在全局融合中的权重；二是在融合过程中神经元权重的在线自适应学习，以便根据子系统观测精度的变化，自适应地调节神经元融合权重。

2.1 离线训练算法

考虑第 i 个神经元的训练过程，其有 N 个输入，分别为 $\hat{X}_j^i, j=1, 2, \dots, N$ 。经融合后得到一个输出 \hat{X}_f^i ，选用最简单的线性神经元，其阈值为 0。采用有监督学习训练算法，训练样本的局部状态估计为 $X_m = (\hat{X}_{1m}, \hat{X}_{2m}, \dots, \hat{X}_{Nm})^T$ ，相应的真实状态集为 X_m^T ， m 为样本数，为了使系统超定，应使 $m > n$ 。采用 Widrow-Hoff 学习算法，权重初始值取为随机小量，权重迭代公式如下：

$$W_{k+1} = W_k + \eta \epsilon_k X_m^T \quad (6)$$

其中： η 为学习步长， $0 < \eta < 1$ ， ε_k 为第 k 步的误差。

$$\varepsilon_k = X_m^T - W_k X_m \quad (7)$$

每步迭代后判断 ε_k 是否小于给定的小量（收敛准则 ep ），如小于，停止学习；反之，继续迭代。

2.2 在线自适应学习算法

各子系统正常工作时，第 i 个神经元融合权重应不随时间变化，并有如下权重状态方程和测量方程

$$\left. \begin{aligned} W(k) &= W(k-1) + \omega(k-1) \\ y(k) &= H(k)W(k) + v(k) \end{aligned} \right\} \quad (8)$$

其中 $\omega(k-1)$ 为系统白噪声，方差由系统正常工作时神经元权重允许的变化范围决定； $v(k)$ 为测量白噪声，方差由融合后组合系统精度确定，且与系统噪声相互独立。 $H(k)$ 是由各局部状态估计向量的某一分量 $\hat{X}_j^i(k)$ 组成的观测向量，其维数为 $(1 \times N)$ ； $y(k)$ 为神经元融合输出的全局估计向量的某一分量 $\hat{X}_j^i(k)$ ； $W(k)$ 是第 k 步第 i 个神经元的融合权重向量，其维数为 $(N \times 1)$ 。

设第 $k-1$ 步时由 N 个局部卡尔曼滤波器得到对状态 X 的第 i 个分量的估计为 $\hat{X}_j^i(k-1)$ ， $i=1, 2, \dots, n$ ； $j=1, 2, \dots, N$ ；及对第 k 步状态的预测值为 $\hat{X}_j^i(k/k-1)$ 。预测值只根据组合系统各局部滤波器的数学模型来递推估计系统的状态，而不用各子系统的测量值对估计值进行修正，在各子系统正常工作时，预测值和估计值都是系统状态的无偏估计，它们之差 ξ 是均值为零的高斯分布白噪声。如果第 k 时刻第 j 个子系统的观测性能发生变化，将使相应的局部估计 $\hat{X}_j^i(k)$ 的精度发生变化，但 $\hat{X}_j^i(k/k-1)$ 将不受观测值的影响，因此第 j 个子系统观测性能的变化必将通过 ξ_j^i 反映出来，这样就可以将 ξ_j^i 引入到神经元权重的在线自适应学习算法中，从而可根据子系统的观测性能调节融合权重。由卡尔曼滤波理论和 (8) 式得到权重递推修正公式如下：

$$\left. \begin{aligned} \hat{W}(k, k-1) &= \hat{W}(k-1) \\ P(k, k-1) &= P(k-1) + Q(k-1) \\ \hat{W}(k) &= \hat{W}(k, k-1) + K(k) [y(k) - H(k)\hat{W}(k, k-1)] \\ K(k) &= P(k, k-1)H^T(k) [H(k)P(k, k-1)H^T(k) + R(k)]^{-1} \\ P(k) &= [I - K(k)H(k)]P(k, k-1) \end{aligned} \right\} \quad (9)$$

在各子系统正常工作情况下，有以下两个条件成立：

(1) 神经元的融合权重不随时间变化，因此有 $W(k) = W(k-1)$ 成立；

(2) $\hat{X}_j^i(k)$ 和 $\hat{X}_j^i(k/k-1)$ 都是系统状态的无偏估计，即 $E[\hat{X}_j^i(k)] = E[\hat{X}_j^i(k/k-1)]$ 成立。

因此可用由 $\hat{X}_j^i(k/k-1)$ 组成的观测向量，记为 $H(k-1)$ 和 $W(k-1)$ 代替式 (8) 的第 2 式中由 $\hat{X}_j^i(k)$ 组成的观测向量，记为 $H(k)$ 和 $W(k)$ ，将式 (8) 的第 2 式代入 (9) 式中。并考虑第 k 步由各局部滤波器对第 i 个状态分量的预测值和估计值之差组成的向量 $\xi(k)$ 后，可将 (9) 式中第 1 式和第 3 式合并为下式：

$$\hat{W}(k) = \hat{W}(k-1) + K(k) \xi(k) \hat{W}(k-1) \quad (10)$$

其中 $\xi(k) = H(k-1) - H(k)$ ，其维数为 $(1 \times N)$ 。

综合 (10) 式和 (9) 式中的第 2 式、第 4 式、第 5 式就得到了在线自适应学习算法。

3 实验研究与结果分析

首先建立车载 SINS/GPS 组合系统状态方程和各子系统观测方程；其次设计系统神经元融合模型，通过仿真计算和系统的实测数据对模型结构，及神经元权重在线自适应学习算法进行了实验研究。

3.1 组合系统状态方程的建立

在东北天地理坐标系中，为了确定载体的位置和速度，且考虑到 GPS 不能给出载体的姿态信息，因此系统状态变量取为 $X = [x_e, v_e, x_n, v_n]^T$ ，其中 x_e 和 x_n 分别为东向和北向位置 (m)； v_e 和 v_n

分别为东向和北向速度 (m/s)。设采样间隔为 Δ , 则有下述组合系统状态方程

$$\mathbf{X}(k+1) = \Phi(k+1, k)\mathbf{X}(k) + \mathbf{G}(k)\mathbf{W}(k) \tag{11}$$

其中 $\Phi(k+1, k) = \begin{bmatrix} 1 & \Delta & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & \Delta \\ 0 & 0 & 0 & 1 \end{bmatrix}$, $\mathbf{G}(k) = \begin{bmatrix} \Delta^2/2 & 0 \\ \Delta & 0 \\ 0 & \Delta^2/2 \\ 0 & \Delta \end{bmatrix}$, $\mathbf{W}(k)$ 为零均值的白噪声序列, 并有 $E[\mathbf{W}(k)\mathbf{W}^T(j)] = \mathbf{Q}(k)\delta(k, j)$, $\mathbf{Q}(k) \geq 0$, 其中 $\delta(k, j)$ 是 Kronecker 函数。

3.2 观测方程的建立

对于 SINS (子系统 1), 状态变量 $\mathbf{X}_1 = \mathbf{X}$, 其状态方程等同组合系统状态方程 (11)。假设只观测到车体沿东向和北向的位置信息, 观测向量 $\mathbf{Z}_1 = [x_e, x_n]^T$, 则 SINS 观测方程为

$$\mathbf{Z}_1(k) = \mathbf{H}_1(k)\mathbf{X}(k) + \mathbf{V}_1(k) \tag{12}$$

其中 $\mathbf{H}_1 = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 \end{bmatrix}$, 测量噪声 $\mathbf{V}_1(k)$ 为零均值的白噪声序列, 并有

$$E[\mathbf{V}(i)\mathbf{V}^T(j)] = \mathbf{R}_1(k)\delta(i, j), \mathbf{R}_1(k) \geq 0$$

对于 GPS (子系统 2), 状态变量 $\mathbf{X}_2 = \mathbf{X}$, 状态方程等同组合系统状态方程 (11)。同样假设只观测到车体的位置信息, 观测向量 $\mathbf{Z}_2 = [x_e, x_n]^T$, 观测方程为

$$\mathbf{Z}_2(k) = \mathbf{H}_2(k)\mathbf{X}(k) + \mathbf{V}_2(k) \tag{13}$$

其中 $\mathbf{H}_2(k)$, $\mathbf{V}_2(k)$ 和 SINS 观测方程相应变量意义相同, 此处不再赘述。

3.3 SINS/GPS 组合系统的神经元信息融合模型

SINS/GPS 组合系统神经元信息融合模型如图 2 所示。其中, 两个局部滤波器分别处理来自 SINS 和 GPS 子系统的信息, 局部滤波器状态方程与测量方程如前述, 由此得到状态的两个局部最优估计 $\hat{\mathbf{X}}_i(k)$, $i = 1, 2$ 。各局部状态估计传递给神经元融合中心, 其由 4 个神经元构成单层网络, 每个神经元单独处理来自两个局部估计向量的同一个分量, 在融合前对神经元融合权重进行在线自适应学习, 以确定融合权重。由于状态变量取为车体的位置和速度, 且 SINS 为航位推算系统, 为了抑制 SINS 位置和速度误差随时间的积累, 隔一定时间间隔后要重置 SINS 的初始位置和速度。

3.4 实验结果与分析

对图 2 的模型进行仿真计算, 假设载体沿东向和北向分别以 20 m/s 和 40 m/s 的速度匀速运行, 取采样间隔 $\Delta = 0.05$ s, 采样时间为 60 s。设子系统 1 的观测向量为 \mathbf{Z}_1 , 子系统 2 的观测向量为 \mathbf{Z}_2 , 且都只观测到了位置信息, \mathbf{Z}_2 在 60 s 内给出对位置的良好观测, \mathbf{Z}_1 在前 30 s 内给出对位置的良好观测, 后 30 s 内给出对位置的有偏观测 (偏置为 100m)。初始状态为: $\mathbf{X}_1 = \mathbf{X}_2 = 0$, 初始协方差阵为 $\mathbf{P}_1 = \mathbf{P}_2 = \text{diag}(20^2, 1^2, 20^2, 1^2)$; 观测噪声方差矩阵为 $\mathbf{R}_1 = \mathbf{R}_2 = \text{diag}(0.3^2, 0.3^2)$, 系统噪声方差矩阵为 $\mathbf{Q}_1 = \mathbf{Q}_2 = \text{diag}(0.06^2, 0.06^2)$ 。离线训练时, 学习步长 $\mu = 0.01$, 收敛准则 $ep = 0.001$ 。在线学习时, 权重 \mathbf{W} 的初始值取为离线训练收敛后的值, 初始协方差阵 $\mathbf{P} = \text{diag}(5^2, 5^2)$, 系统噪声方差矩阵为 $\mathbf{Q} = \text{diag}(0.05^2, 0.05^2)$, 观测噪声方差 $R = 0.09$, 图 3 为相应子系统 1 的用于东向位置融合的神经元融合权重 w_1 的变化曲线。训练结果表明, 在离线训练 91 步后 (仿真 4.55 s), 权重收敛到 (0.4952, 0.5048), 而后根据各子系统观测精度对 w_1 进行在线自适应学习, 在 30 s 前 \mathbf{Z}_1 和 \mathbf{Z}_2 观测精度相当, 因此权重基本不变, 在后 30 s 由于 \mathbf{Z}_1 是有偏观测, 子系统 1 对状态的估计精度下降, 因此权重 w_1 有较大的减小, 最后权重收敛到 (0.2569, 0.7431), 和希望的结果相吻合。

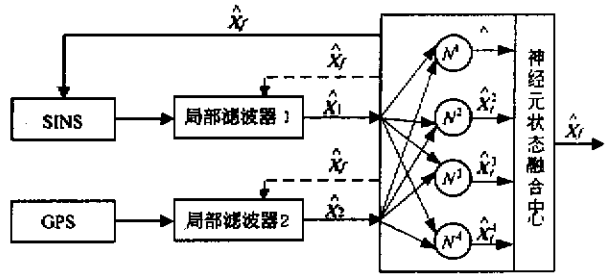





图 2 SINS/GPS 组合系统的神经元信息融合模型

Fig.2 Information fusion model of SINS/GPS based on neurons

图3 仿真数据权重 w_1 曲线Fig.3 Weight w_1 of simulation data图4 实测数据权重 w_1 曲线Fig.1 Weight w_1 of experiment data

对图2的模型进行车载SINS/GPS组合系统实验研究初始状态为： $X_1 = X_2 = 0$ ，系统协方差初始值为 $P_1 = P_2 = \text{diag}(100^2, 1^2, 100^2, 1^2)$ ；系统噪声方差为 $Q_1 = Q_2 = \text{diag}(0.4^2, 0.4^2)$ ；中等精度SINS的观测噪声方差 $R_1 = \text{diag}(200^2, 200^2)$ ，GPS的观测噪声方差由所选用的GPS OEM板精度决定，即 $R_2 = \text{diag}(100^2, 100^2)$ 。神经元融合中心的信息综合时间间隔为 $\Delta = 1$ s，采样时间为1200 s。图4为相应于SINS用于东向位置融合的神经元融合权重 w_1 的变化曲线。训练结果表明，在离线训练711步（运行711 s）后，权重收敛到 $(0, 1)$ ，而后用于融合并根据各子系统观测精度对 w_1 进行在线自适应学习。由离线训练时权重 w_1 的变化过程可知，在开始阶段由于中等精度SINS短期定位精度和GPS基本相当，因此用于SINS和GPS东向位置的神经元融合权重基本一样，随着SINS误差随时间的积累，其融合权重 w_1 逐渐减小，最后为0；由于陀螺漂移和加速度零偏造成的SINS观测误差远远大于GPS观测误差，因此在自适应学习阶段 w_1 基本保持不变。显然融合后的东向位置取决于局部滤波器2的估计输出。

为进一步说明该算法的有效性，将890 s后局部滤波器1东向位置估计输出人为提高精度。图5为修正后的 w_1 变化曲线，显然由于890 s后局部滤波器1东向位置估计的精度提高， w_1 得到了改善，最后权重收敛到 $(0.1166, 0.8834)$ 。但由于采用无反馈模式，使得修正后的局部滤波器1东向位置输出相对于局部滤波器2而言仍然较大，因此 w_1 增加量较小，融合后的东向位置以局部滤波器2的估计输出为主。实验研究中发现如果人为对局部滤波器1的估计精度提高较大，则 w_1 的增加量也较大。

图5 修正后数据权重 w_1 曲线Fig.5 Weight w_1 of correctional experiment data

4 结论

本文提出了一种基于神经元的组合系统信息融合模型结构，利用卡尔曼滤波理论较好地解决了神经元融合权重在线自适应学习问题，增强了模型对子系统工作状态的自适应性和容错性。通过仿真计算和SINS/GPS组合系统的静态组合实验，验证了神经元在线自适应学习算法的有效性，同时也说明了基于神经元的组合系统信息融合模型具有良好的实际应用价值。

参考文献：

- [1] Kim K H. Development of Track to Track Fusion Algorithms [A]. Proc. American Control Conf. , 1994 , 1037-1041.
- [2] Chowdhury F N. A Neural Approach to Data Fusion [A]. Proc. American Control Conf. , 1995 , 1693-1697.
- [3] 马昕, 袁信. 基于神经元的容错组合导航系统设计 [J]. 宇航学报, 1999 , 20(2) : 7-13.
- [4] Carlson N A. Federated Filter for Fault-tolerant Integrated Navigation [R]. N 96-13415.
- [5] 陶俊勇. 组合导航系统信息融合理论与故障检测与诊断技术研究 [D]. 长沙: 国防科学技术大学博士学位论文, 2000.

