

对于滚动姿态的角加速度，则有

$$\ddot{\phi}_H(n) = u(n) + w(n) \quad (4.4.39)$$

式中 $u(n)$ 为 n 时刻系统喷气所产生的加速度，并且喷气时间和大小是已知的； $w(n)$ 是由外力干扰产生的加速度，假定它为零均值的平稳白噪声过程，且各时区之间互不相关，但具有某个已知的方差 $E\{w^2(n)\} = \sigma_w^2$ 。

定义状态向量

$$\mathbf{x}(n) = \begin{bmatrix} x_1(n) \\ x_2(n) \\ x_3(n) \end{bmatrix} = \begin{bmatrix} \phi_H(n) \\ \dot{\phi}_H(n) \\ \ddot{\phi}_H(n) \end{bmatrix} \quad (4.4.40)$$

则式 (4.4.37) ~ 式 (4.4.39) 可以合并写作下面的状态方程：

$$\mathbf{x}(n) = \mathbf{F}\mathbf{x}(n-1) + \mathbf{u}(n) + \mathbf{w}(n) \quad (4.4.41)$$

式中，状态转移矩阵

$$\mathbf{F} = \begin{bmatrix} 1 & T & 0 \\ 0 & 1 & T \\ 0 & 0 & 0 \end{bmatrix} \quad (4.4.42)$$

且系统输入向量为

$$\mathbf{u}(n) = [0, 0, u(n)]^T \quad (4.4.43)$$

系统噪声向量为

$$\mathbf{w}(n) = [0, 0, w(n)]^T \quad (4.4.44)$$

因此，系统噪声的相关矩阵可以计算为

$$\mathbf{Q}_w = \begin{bmatrix} 0 & 0 & 0 \\ 0 & 0 & 0 \\ 0 & 0 & \sigma_w^2 \end{bmatrix} \quad (4.4.45)$$

将状态方程 (4.4.41) 与 Kalman 滤波器的标准状态方程比较知，描述滚动姿态的状态转移矩阵与离散时间无关，并且多了一个已知的输入向量 $\mathbf{u}(n)$ 。

另一方面，观测方程可以写作

$$y(n) = \mathbf{h}^T \mathbf{x}(n) + v(n) \quad (4.4.46)$$

式中，滚动姿态的角观测值 $y(n)$ 就是实际的滚动姿态角 $\phi_H(n)$ ，它等于 $\mathbf{h}^T \mathbf{x}(n)$ 与一白噪声 $v(n)$ 的叠加，而观测矩阵 $\mathbf{C}(n)$ 简化为一行向量 $\mathbf{h}^T = [1, 0, 0]$ 。令 $v(n)$ 的均值为零，方差 σ_v^2 为已知。

前面介绍的标准 Kalman 滤波器的基础是一步预测。与之不同，这里是一个纯滤波问题。

状态向量存在两种不同的估计子。第一种估计子 $\hat{x}^{(1)}(n)$ 由状态方程式 (4.3.41) 给出：

$$\hat{x}^{(1)}(n) = F\hat{x}(n-1) + u(n) \quad (4.4.47)$$

再由观测方程 (4.4.46)，又可得到状态向量的第二种估计子 $\hat{x}^{(2)}(n)$ 为

$$y(n) = h^T \hat{x}^{(2)}(n) \quad (4.4.48)$$

容易验证 $\hat{x}^{(1)}(n)$ 和 $\hat{x}^{(2)}(n)$ 相互独立。为了使它们给出一个统一的估计，可以采用它们的线性组合形式：

$$\hat{x}(n) = [I - A(n)]\hat{x}^{(1)}(n) + A(n)\hat{x}^{(2)}(n) \quad (4.4.49)$$

式中 $A(n)$ 为一加权矩阵。也可采用另一种线性组合形式： $\hat{x}(n) = A(n)\hat{x}^{(1)}(n) + [I - A(n)]\hat{x}^{(2)}(n)$ 。根据最小均方误差准则，最优加权矩阵应使估计误差 $x(n) - \hat{x}(n)$ 的均方值最小。

为了确定最优加权矩阵 $A(n)$ ，令

$$A(n) = m(n)h^T \quad (4.4.50)$$

将式 (4.4.50) 代入式 (4.4.49)，有

$$\hat{x}(n) = [I - m(n)h^T] \hat{x}^{(1)}(n) + m(n)h^T \hat{x}^{(2)}(n) \quad (4.4.51a)$$

$$= [I - m(n)h^T] \hat{x}^{(1)}(n) + m(n)y(n) \quad (4.4.51b)$$

另一方面，容易验证恒等式

$$x(n) \equiv [I - m(n)h^T] x(n) + m(n)h^T x(n) \quad (4.4.52)$$

式 (4.4.52) 减去式 (4.4.51b)，得到信号的估计误差向量为

$$\begin{aligned} x(n) - \hat{x}(n) &= [I - m(n)h^T] [x(n) - \hat{x}^{(1)}(n)] + m(n)[h^T x(n) - y(n)] \\ &= [I - m(n)h^T] [x(n) - \hat{x}^{(1)}(n)] + m(n)v(n) \end{aligned} \quad (4.4.53)$$

考虑估计误差向量的相关矩阵

$$\begin{aligned}
 \mathbf{P}(n) &= \mathbb{E} \left\{ [\mathbf{x}(n) - \hat{\mathbf{x}}(n)] [\mathbf{x}(n) - \hat{\mathbf{x}}(n)]^T \right\} \\
 &= \mathbb{E} \left\{ \left[(\mathbf{I} - \mathbf{m}(n)\mathbf{h}^T) (\mathbf{x}(n) - \hat{\mathbf{x}}^{(1)}(n)) - \mathbf{m}(n)v(n) \right] \times \right. \\
 &\quad \left. \left[(\mathbf{I} - \mathbf{m}(n)\mathbf{h}^T) (\mathbf{x}(n) - \hat{\mathbf{x}}^{(1)}(n)) - \mathbf{m}(n)v(n) \right]^T \right\} \\
 &= [\mathbf{I} - \mathbf{m}(n)\mathbf{h}^T] \mathbb{E} \left\{ [\mathbf{x}(n) - \hat{\mathbf{x}}^{(1)}(n)] [\mathbf{x}(n) - \hat{\mathbf{x}}^{(1)}(n)]^T \right\} \times \\
 &\quad [\mathbf{I} - \mathbf{m}(n)\mathbf{h}^T]^T + \mathbf{m}(n)\sigma_v^2 \mathbf{m}^T(n) \\
 &= [\mathbf{I} - \mathbf{m}(n)\mathbf{h}^T] \mathbf{P}_1(n) [\mathbf{I} - \mathbf{m}(n)\mathbf{h}^T]^T + \mathbf{m}(n)\sigma_v^2 \mathbf{m}^T(n) \quad (4.4.54)
 \end{aligned}$$

式中

$$\mathbf{P}_1(n) = \mathbb{E} \left\{ [\mathbf{x}(n) - \hat{\mathbf{x}}^{(1)}(n)] [\mathbf{x}(n) - \hat{\mathbf{x}}^{(1)}(n)]^T \right\}$$

表示第一个估计子的误差方差矩阵，而 σ_v^2 是第二种估计子的误差方差。

由于使均方误差最小等价于使误差方差矩阵 \mathbf{P} 的迹 $\text{tr}[\mathbf{P}(n)]$ 最小。对其求导数得

$$\frac{\partial \text{tr}[\mathbf{P}(n)]}{\partial \mathbf{m}(n)} = -2\mathbf{P}_1(n)\mathbf{h} + 2\mathbf{m}(n)\mathbf{h}^T \mathbf{P}_1(n)\mathbf{h} + 2\mathbf{m}(n)\sigma_v^2 \quad (4.4.55)$$

令其为零，则

$$\mathbf{m}(n) = \mathbf{P}_1(n)\mathbf{h} \left[\mathbf{h}^T \mathbf{P}_1(n)\mathbf{h} + \sigma_v^2 \right]^{-1} \quad (4.4.56)$$

将式 (4.4.56) 代入式 (4.4.54)，并加以整理，有下面的简洁结果：

$$\mathbf{P}(n) = [\mathbf{I} - \mathbf{m}(n)\mathbf{h}^T] \mathbf{P}_1(n) \quad (4.4.57)$$

下面考虑 $\mathbf{P}_1(n)$ 的计算。根据定义，有

$$\begin{aligned}
 \mathbf{P}_1(n) &= \mathbb{E} \left\{ [\mathbf{x}(n) - \hat{\mathbf{x}}^{(1)}(n)] [\mathbf{x}(n) - \hat{\mathbf{x}}^{(1)}(n)]^T \right\} \\
 &= \mathbb{E} \left\{ \left[\mathbf{F}(\mathbf{x}(n-1) - \hat{\mathbf{x}}^{(1)}(n-1)) + \mathbf{w}(n) \right] \times \right. \\
 &\quad \left. \left[\mathbf{F}(\mathbf{x}(n-1) - \hat{\mathbf{x}}^{(1)}(n-1)) + \mathbf{w}(n) \right]^T \right\}
 \end{aligned}$$

由于 F 为常数矩阵, 故上式可写作

$$\begin{aligned} \mathbf{P}_1(n) &= \mathbf{F}\mathbf{E}\left\{\left[\mathbf{x}(n-1) - \hat{\mathbf{x}}^{(1)}(n-1)\right]\left[\mathbf{x}(n-1) - \hat{\mathbf{x}}^{(1)}(n-1)\right]^T\right\}\mathbf{F}^T + \\ &\quad \mathbf{F}\mathbf{E}\left\{\left[\mathbf{x}(n-1) - \hat{\mathbf{x}}^{(1)}(n-1)\right]\mathbf{w}^T(n)\right\} + \\ &\quad \mathbf{E}\left\{\mathbf{w}(n)\left[\mathbf{x}(n-1) - \hat{\mathbf{x}}^{(1)}(n-1)\right]^T\right\}\mathbf{F}^T + \mathbf{E}\{\mathbf{w}(n)\mathbf{w}^T(n)\} \\ &= \mathbf{F}\mathbf{P}_1(n-1)\mathbf{F}^T + \mathbf{Q}_w \end{aligned} \quad (4.4.58)$$

综合以上分析, 求姿态角速度最小均方误差估计的 Kalman 滤波算法可以描述如下。

算法 4.4.2 (姿态角速度估计的 Kalman 滤波算法)

初始条件: $\hat{\mathbf{x}}(1) = 0, \mathbf{P} = \mathbf{I}$

输入:

滚动姿态角观测值 $y(n)$

已知参数:

系统噪声 $w(n)$ 的方差 σ_w^2

观测噪声 $v(n)$ 的方差 σ_v^2

观测向量 $\mathbf{h} = [1, 0, 0]^T$

状态转移矩阵 \mathbf{F} , 如式 (4.4.42) 所示

对 $n = 1, 2, \dots$ 计算

$$\begin{aligned} \mathbf{P}_1(n) &= \mathbf{F}\mathbf{P}_1(n-1)\mathbf{F}^T + \mathbf{Q}_w \\ \mathbf{m}(n) &= \mathbf{P}_1(n)\mathbf{h}\left[\mathbf{h}^T\mathbf{P}_1(n)\mathbf{h} + \sigma_v^2\right]^{-1} \\ \mathbf{P}(n) &= [\mathbf{I} - \mathbf{m}(n)\mathbf{h}^T]\mathbf{P}_1(n) \\ \hat{\mathbf{x}}^{(1)}(n) &= \mathbf{F}\hat{\mathbf{x}}^{(1)}(n-1) + \mathbf{u}(n) \\ \hat{\mathbf{x}}(n) &= [\mathbf{I} - \mathbf{m}(n)\mathbf{h}^T]\hat{\mathbf{x}}^{(1)}(n) + \mathbf{m}(n)y(n) \end{aligned}$$

用以上算法得到的状态估计向量 $\hat{\mathbf{x}}(n)$ 的第二个分量即为滚动状态角速度的估计 $\hat{\phi}_H(n)$ 。

4.5 LMS 类自适应算法

考虑图 4.3.2 所示 FIR 滤波器的自适应实现。所谓自适应实现乃是指: M 阶 FIR 滤波器的抽头权系数 w_0, \dots, w_{M-1} 可以根据估计误差 $e(n)$ 的大小自动调节, 使得某个代价函数最小。图 4.5.1 画出了自适应 FIR 滤波器的原理图。

滤波器设计最常用的准则是使滤波器实际输出 $y(n) = \mathbf{u}^H(n)\mathbf{w}^* = \mathbf{w}^H\mathbf{u}(n)$ 与期望响应 $d(n)$ 之间的均方误差 $E\{|\epsilon(n)|^2\}$ 为最小, 这就是最小均方误差 (MMSE) 准则。

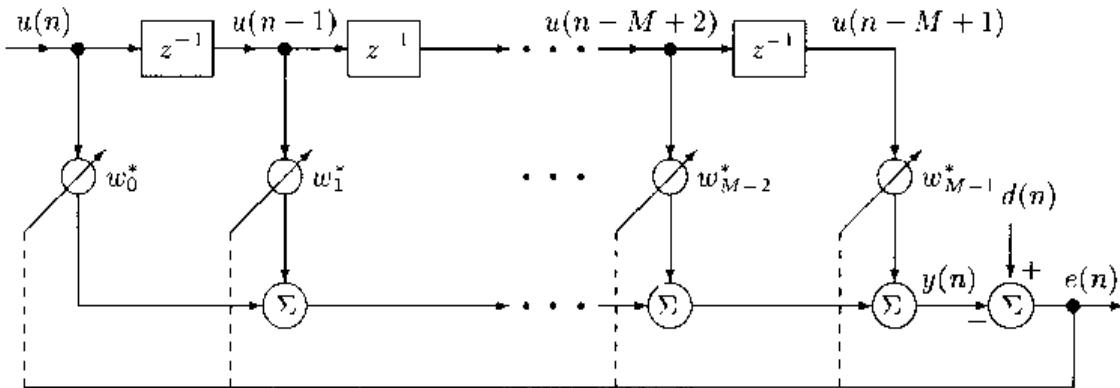


图 4.5.1 自适应 FIR 滤波器

令

$$\epsilon(n) = d(n) - \mathbf{w}^H \mathbf{u}(n) \quad (4.5.1)$$

表示滤波器在 n 时刻的估计误差, 并定义均方误差

$$J(n) \stackrel{\text{def}}{=} E\{|\epsilon(n)|^2\} = E\left\{ |d(n) - \mathbf{w}^H \mathbf{u}(n)|^2 \right\} \quad (4.5.2)$$

为代价函数。

由式 (4.3.10) 知, 代价函数相对于滤波器抽头权向量 \mathbf{w} 的梯度为

$$\begin{aligned} \nabla_k J(n) &= -2E\{u(n-k)\epsilon^*(n)\} \\ &= -2E\left\{u(n-k)[d(n) - \mathbf{w}^H \mathbf{u}(n)]^*\right\}, \quad k = 0, 1, \dots, M-1 \end{aligned} \quad (4.5.3)$$

令 $w_i = a_i + jb_i, i = 0, 1, \dots, M-1$, 并定义梯度向量

$$\nabla J(n) \stackrel{\text{def}}{=} [\nabla_0 J(n), \nabla_1 J(n), \dots, \nabla_{M-1} J(n)]^T \quad (4.5.4)$$

$$= \begin{bmatrix} \frac{\partial J(n)}{\partial a_0(n)} + j \frac{\partial J(n)}{\partial b_0(n)} \\ \frac{\partial J(n)}{\partial a_1(n)} + j \frac{\partial J(n)}{\partial b_1(n)} \\ \vdots \\ \frac{\partial J(n)}{\partial a_{M-1}(n)} + j \frac{\partial J(n)}{\partial b_{M-1}(n)} \end{bmatrix} \quad (4.5.5)$$

以及输入向量和抽头权向量:

$$\mathbf{u}(n) = [u(n), u(n-1), \dots, u(n-M+1)]^T \quad (4.5.6)$$

$$\mathbf{w}(n) = [w_0(n), w_1(n), \dots, w_{M-1}(n)]^T \quad (4.5.7)$$

则式(4.5.5)可以写作以下向量形式:

$$\nabla J(n) = -2E\{\mathbf{u}(n)[d^*(n) - \mathbf{u}^H(n)\mathbf{w}(n)]\} \quad (4.5.8a)$$

$$= -2\mathbf{r} + 2\mathbf{R}\mathbf{w}(n) \quad (4.5.8b)$$

式中

$$\mathbf{R} = E\{\mathbf{u}(n)\mathbf{u}^H(n)\} \quad (4.5.9a)$$

$$\mathbf{r} = E\{\mathbf{u}(n)d^*(n)\} \quad (4.5.9b)$$

最广泛使用的自适应算法形式为“下降算法”:

$$\mathbf{w}(n) = \mathbf{w}(n-1) + \mu(n)\mathbf{v}(n) \quad (4.5.10)$$

式中 $\mathbf{w}(n)$ 为第 n 步迭代(也即时刻 n)的权向量, $\mu(n)$ 为第 n 次迭代的更新步长,而 $\mathbf{v}(n)$ 为第 n 次迭代的更新方向(向量)。

下降算法(4.5.10)有两种主要实现方式。一种是自适应梯度算法,另一种是自适应高斯-牛顿算法。自适应梯度算法包括 LMS 算法及其各种变型和改进(统称 LMS 类自适应算法),自适应高斯-牛顿算法则包括 RLS 算法及其变型和改进。本节介绍 LMS 类自适应算法,下一节介绍后一类自适应算法。

4.5.1 LMS 算法及其基本变型

最常用的下降算法为梯度下降法,常称最陡下降法。在这种算法里,更新方向向量 $\mathbf{v}(n)$ 取作第 $n-1$ 次迭代的代价函数 $J[\mathbf{w}(n-1)]$ 的负梯度,即最陡下降法(也称梯度算法)的统一形式为

$$\mathbf{w}(n) = \mathbf{w}(n-1) - \frac{1}{2}\mu(n)\nabla J(n-1) \quad (4.5.11)$$

系数 $1/2$ 是为了使得到的更新公式更简单。

将式(4.5.8b)代入式(4.5.11),即可得到抽头权向量 $\mathbf{w}(n)$ 的更新公式为

$$\mathbf{w}(n) = \mathbf{w}(n-1) + \mu(n)[\mathbf{r} - \mathbf{R}\mathbf{w}(n-1)], \quad n = 1, 2, \dots \quad (4.5.12)$$

更新公式(4.5.12)表明:

- (1) $[r - R\mathbf{w}(n-1)]$ 为误差向量, 它代表了 $\mathbf{w}(n)$ 每步的校正量;
- (2) 参数 $\mu(n)$ 与校正量相乘, 它是控制 $\mathbf{w}(n)$ 每步的实际校正量的参数, 因此 $\mu(n)$ 称为在时间 n 的“步长参数”。这一参数决定了更新算法 (4.5.12) 的收敛速度。
- (3) 当自适应算法趋于收敛时, 则有 $r - R\mathbf{w}(n-1) \rightarrow 0$ (若 $n \rightarrow \infty$), 即有

$$\lim_{n \rightarrow \infty} \mathbf{w}(n-1) = R^{-1}r$$

即抽头权向量收敛为式 (4.3.25) 所示的 Wiener 滤波器。

当式 (4.5.8a) 中的数学期望项 $E\{\mathbf{u}(n)d^*(n)\}$ 和 $E\{\mathbf{u}(n)\mathbf{u}^H(n)\}$ 分别用它们各自的瞬时值 $\mathbf{u}(n)d^*(n)$ 和 $\mathbf{u}(n)\mathbf{u}^H(n)$ 代替时, 便得到真实梯度向量的估计值

$$\hat{\nabla}J(n) = -2[\mathbf{u}(n)d^*(n) - \mathbf{u}(n)\mathbf{u}^H(n)\mathbf{w}(n)] \quad (4.5.13)$$

习惯称之为瞬时梯度。

若梯度算法 (4.5.11) 中的真实梯度向量 $\nabla J(n-1)$ 用瞬时梯度向量 $\hat{\nabla}J(n-1)$ 代替后, 即得到瞬时梯度算法如下:

$$\begin{aligned} \mathbf{w}(n) &= \mathbf{w}(n-1) + \mu(n)\mathbf{u}(n)[d(n) - \mathbf{u}^T(n)\mathbf{w}^*(n-1)]^* \\ &= \mathbf{w}(n-1) + \mu(n)e^*(n)\mathbf{u}(n) \end{aligned} \quad (4.5.14a)$$

式中

$$e(n) = d(n) - \mathbf{u}^T(n)\mathbf{w}^*(n-1) = d(n) - \mathbf{w}^H(n-1)\mathbf{u}(n) \quad (4.5.14b)$$

注意, 虽然 $e(n)$ 与式 (4.5.3) 定义的 $\epsilon(n)$ 都是表示滤波器在 n 时刻的估计误差, 但它们是不同的: $e(n)$ 由 $\mathbf{w}(n-1)$ 决定, 而 $\epsilon(n)$ 则由 $\mathbf{w}(n)$ 决定。为区别计, 常称 $e(n)$ 为先验估计误差, $\epsilon(n)$ 为后验估计误差。

式 (4.5.14) 所示的算法就是著名的最小均方误差自适应算法, 简称 LMS 算法, 它是 Widrow 在 20 世纪 60 年代初提出的 [206]。

容易验证, 瞬时梯度向量是真实梯度向量的无偏估计:

$$\begin{aligned} E\{\hat{\nabla}J(n)\} &= -2E\{\mathbf{u}(n)[d^*(n) - \mathbf{u}^H(n)\mathbf{w}(n-1)]\} \\ &= -2[r - R\mathbf{w}(n-1)] \\ &= \nabla J(n) \end{aligned} \quad (4.5.15)$$

为了方便读者使用, 这里将 LMS 自适应算法以及它的几种基本变型归纳如下。

算法 4.5.1 (LMS 自适应算法及其基本变型)

步骤 1 初始化: $\mathbf{w}(0) = 0$;

步骤 2 更新: $n = 1, 2, \dots$

$$e(n) = d(n) - \mathbf{w}^H(n-1)\mathbf{u}(n)$$

$$\mathbf{w}(n) = \mathbf{w}(n-1) + \mu(n)\mathbf{u}(n)e^*(n)$$

下面是关于 LMS 算法的几点注释。

注释 1: 若取 $\mu(n) = \text{常数}$, 则称之为基本 LMS 算法。

注释 2: 若取 $\mu(n) = \frac{\alpha}{\beta + \mathbf{u}^H(n)\mathbf{u}(n)}$, 其中 $\alpha \in (0, 2)$, $\beta > 0$, 则得到归一化 LMS 算法。

注释 3: 在功率归一化 LMS 算法中, 取 $\mu(n) = \frac{\alpha}{\sigma_u^2(n)}$, 其中 σ_u^2 表示 $\mathbf{u}(n)$ 的方差, 可由 $\sigma_u^2(n) = \lambda\sigma_u^2(n-1) + e^2(n)$ 递推计算, 这里 $\lambda \in (0, 1]$ 为遗忘因子, 由 $0 < \alpha < \frac{2}{M}$ 确定, 而 M 是滤波器的阶数。

注释 4: 当期望信号未知时, 步骤 2 中的 $d(n)$ 可直接用滤波器的实际输出 $y(n)$ 代替。

4.5.2 解相关 LMS 算法

在 LMS 算法中, 有一个独立性假设: 假定横向滤波器的输入向量 $\mathbf{u}(1), \mathbf{u}(2), \dots, \mathbf{u}(n)$ 是彼此统计独立的向量序列。当它们之间不满足统计独立的条件时, 基本 LMS 算法的性能将下降, 尤其是收敛速度会比较慢。因此, 在这种情况下, 就需要解除各时刻输入向量之间的相关(这一操作称为“解相关”), 使它们尽可能保持统计独立。大量的研究表明 ([78] 及其有关参考文献), 解相关能够有效加快 LMS 算法的收敛速率。

1. 时域解相关 LMS 算法

定义 $\mathbf{u}(n)$ 与 $\mathbf{u}(n-1)$ 在 n 时刻的相关系数为

$$a(n) \stackrel{\text{def}}{=} \frac{\mathbf{u}^H(n-1)\mathbf{u}(n)}{\mathbf{u}^H(n-1)\mathbf{u}(n-1)} \quad (4.5.16)$$

根据定义, 若 $a(n) = 1$, 则称 $\mathbf{u}(n)$ 是 $\mathbf{u}(n-1)$ 的相干信号; 若 $a(n) = 0$, 则 $\mathbf{u}(n)$ 与 $\mathbf{u}(n-1)$ 不相关; 当 $0 < a(n) < 1$ 时, 称 $\mathbf{u}(n)$ 与 $\mathbf{u}(n-1)$ 相关, 并且 $a(n)$ 越大, 它们之间的相关性越强。

显然, $a(n)\mathbf{u}(n-1)$ 代表了 $\mathbf{u}(n)$ 中与 $\mathbf{u}(n-1)$ 相关的部分。若从 $\mathbf{u}(n)$ 中减去该部分, 则这一减法运算相当于“解相关”。现在, 用解相关的结果作为更新方向向

量 $v(n)$:

$$v(n) = u(n) - a(n)u(n-1) \quad (4.5.17)$$

从这一角度出发，把 $a(n)$ 称为解相关系数更为贴切。

另一方面，步长参数 $\mu(n)$ 应该是满足下列最小化问题的解：

$$\mu(n) = \arg \min_{\mu} J[\mathbf{w}(n-1) + \mu v(n)] \quad (4.5.18)$$

由此得

$$\mu(n) = \frac{e(n)}{\mathbf{u}^H(n)v(n)} \quad (4.5.19)$$

综合以上结果，可以得到解相关 LMS 算法如下，它是 Doherty 与 Porayath 于 1997 年提出的 [63]。

算法 4.5.2 (解相关 LMS 算法)

步骤 1 初始化： $\mathbf{w}(0) = 0$ ；

步骤 2 更新： $n = 1, 2, \dots$

$$e(n) = d(n) - \mathbf{w}^H(n-1)\mathbf{u}(n)$$

$$a(n) = \frac{\mathbf{u}^H(n)\mathbf{u}(n-1)}{\mathbf{u}^H(n-1)\mathbf{u}(n-1)}$$

$$v(n) = u(n) - a(n)u(n-1)$$

$$\mu(n) = \frac{\rho e(n)}{\mathbf{u}^H(n)v(n)}$$

$$\mathbf{w}(n) = \mathbf{w}(n-1) + \mu(n)v(n)$$

上述算法中，参数 ρ 称为修整因子 (trimming factor)。

解相关 LMS 算法可视为一自适应辅助变量法，其中辅助变量由 $v(n) = u(n) - a(n)u(n-1)$ 给出。粗略地讲，辅助变量的选择原则是：它应该与滞后的输入和输出强相关，而与干扰不相关。对辅助变量方法及其自适应算法感兴趣的读者可参考文献 [229]。

更进一步地，上述算法中的辅助变量可以使用一前向预测器的误差向量代替。令 $\mathbf{a}(n)$ 为一 M 阶前向预测器的权向量，计算前向预测误差：

$$e^f(n) = u(n) + \sum_{i=1}^M a_i(n)u(n-i) = u(n) + \mathbf{a}^H(n)\mathbf{u}(n-1) \quad (4.5.20)$$

式中

$$\mathbf{u}(n-1) = [u(n-1), u(n-2), \dots, u(n-M)]^T \quad (4.5.21a)$$

$$\mathbf{a}(n) = [a_1(n), a_2(n), \dots, a_M(n)]^T \quad (4.5.21b)$$

用前向预测误差向量作辅助变量即更新方向向量:

$$\mathbf{v}(n) = \mathbf{e}^f(n) = [e^f(n), e^f(n-1), \dots, e^f(n-M+1)]^T \quad (4.5.22)$$

用前向预测器对瞬时估计误差 $e(n) = y(n) - \mathbf{w}^H(n-1)\mathbf{u}(n)$ 滤波, 则得到滤波型 LMS 算法如下^[129].

算法 4.5.3 (滤波型 LMS 算法)

步骤 1 初始化: $\mathbf{w}(0) = \mathbf{0}$;

步骤 2 更新: $n = 1, 2, \dots$

给定一前向预测器 $\mathbf{a}(n)$ 的估计

$$e(n) = d(n) - \mathbf{w}^H(n-1)\mathbf{u}(n)$$

$$\mathbf{e}(n) = [e(n), e(n-1), \dots, e(n-M+1)]^T$$

$$\mathbf{e}^f(n) = \mathbf{u}(n) + \mathbf{a}^T(n)\mathbf{u}(n-1)$$

$$\mathbf{e}^f(n) = [e^f(n), e^f(n-1), \dots, e^f(n-M+1)]^T$$

$$\tilde{e}(n) = e(n) + \mathbf{a}^H(n)e(n) \quad (\text{滤波})$$

$$\mathbf{w}(n) = \mathbf{w}(n-1) + \mu \mathbf{e}^f(n) \tilde{e}(n)$$

2. 变换域解相关 LMS 算法

改进 LMS 算法性能的早期工作是对输入数据向量 $\mathbf{u}(n)$ 使用酉变换。对某些类型的输入信号, 使用酉变换的算法可以提高收敛速率, 而计算复杂度却与 LMS 算法类似。这类算法以及它们的变型统称变换域自适应滤波算法^{[61],[137],[112],[134],[175],[16]}。

酉变换可以使用离散 Fourier 变换 (DFT)、离散余弦变换 (DCT) 和离散 Hartley 变换 (DHT), 它们都可以有效地提高 LMS 算法的收敛速率。

令 S 是一 $M \times M$ 酉变换矩阵, 即

$$SS^H = \beta I \quad (4.5.23)$$

式中 $\beta > 0$ 为一固定标量。