

$$x_{i+1} = x_i - a \cdot \text{sign} \left\{ \hat{f}(x_i + g) - \hat{f}(x_i - g) \right\},$$

где $a - \text{const}$, $g - \text{const}$ в процессе поиска x_* :

$$x_{i+1} = x_i - a_i \cdot \left\{ \frac{\hat{f}(x_i + g_i) - \hat{f}(x_i - g_i)}{2g_i} \right\},$$

где $\hat{f}(x_i + g_i)$, $\hat{f}(x_i - g_i)$ - оценки по МНК. В этом алгоритме величины g_i , a_i зависят от номера «i» поискового смещения x_i , и по форме этот алгоритм эквивалентен МСА (рис. 4.15).




Рис. 4.15 Алгоритм поиска в САО с парными пробами как эквивалентная процедура МСА.

Из рисунка следует:

$$\frac{\hat{f}(x_i + g_i) - \hat{f}(x_i - g_i)}{2g_i} \approx f'(x_i),$$

поэтому с точностью до обозначений:

$$\underbrace{x_{i+1} = x_i - a_i \cdot \dot{y}(x_i)}_{MCA} \Leftrightarrow \underbrace{x_{i+1} = x_i - a_i \cdot \dot{y}_n(x_i)}_{\substack{\text{адаптивный алгоритм} \\ \text{с парными пробами}}}.$$

Наложим ограничения на величины a_i , g_i в адаптивном алгоритме с парными пробами как это сделано в МСА.

Оценки $\hat{f}(x_i + g_i)$, $\hat{f}(x_i - g_i)$ по МНК как было показано ранее являются линейными комбинациями текущих измерений y_i^+ , y_i^- :

$$\hat{f}(x_i + g_i) = \sum_{j=1}^n b_j y_i^+; \quad \hat{f}(x_i - g_i) = \sum_{j=1}^n b_j y_i^- ,$$

поэтому можно записать:

$$\hat{f}(x_i + g_i) = f(x_i + g_i) + \varepsilon_i^+; \quad \hat{f}(x_i - g_i) = f(x_i - g_i) + \varepsilon_i^- ,$$

где ε_i^+ , ε_i^- есть случайные величины и имеют свойства:

$$\varepsilon_i^+ : \quad E\varepsilon_i^+ = 0; \quad D\varepsilon_i^+ = D\hat{f}(x_i + g_i);$$

$$\varepsilon_i^- : \quad E\varepsilon_i^- = 0; \quad D\varepsilon_i^- = D\hat{f}(x_i - g_i).$$

Здесь $D\hat{f}(x_i + g_i)$, $D\hat{f}(x_i - g_i)$ элементы дисперсионной матрицы оценок по МНК:

$$D\hat{f}(x_i + g_i) = D\hat{f}(x_i - g_i) = \delta^2(1, 0) \left[(X^T X)^{-1} \right] \begin{pmatrix} 1 \\ 0 \end{pmatrix}, \quad X^T = \begin{pmatrix} 1 & \dots & 1 \\ e^{-\tau/T} & \dots & e^{-n\tau/T} \end{pmatrix}_{(2 \times n)}.$$

Запишем адаптивный алгоритм в другой форме:

$$x_{i+1} = x_i - \left(\frac{a_i}{2g_i} \right) \cdot [f(x_i + g_i) + \varepsilon_i^+ - f(x_i - g_i) - \varepsilon_i^-].$$

Разложим $f(x_i + g_i)$, $f(x_i - g_i)$ в ряд Тейлора в окрестности x_i , полагая, что g_i является маленькой величиной:

$$f(x_i + g_i) + \varepsilon_i^+ - f(x_i - g_i) - \varepsilon_i^- \simeq \dot{f}(x = x_i) \cdot 2g_i + \varepsilon_i^+ - \varepsilon_i^-.$$

Подставим это выражение в адаптивный алгоритм:

$$\Delta x_i = x_{i+1} - x_i \simeq - \left[a_i \cdot \dot{f}(x = x_i) + 0,5 \frac{a_i}{g_i} (\varepsilon_i^+ - \varepsilon_i^-) \right].$$

Для расстояния l_N от начальной точки x_1 до конечной точки x_N имеем по аналогии с МСА (рис. 4.13):




Рис 4.13. Итерационная процедура МСА.

$$l_N = \sum_{i=1}^N |\Delta x_i| = \sum_{i=1}^N a_i \cdot \underbrace{\dot{f}(x=x_i)}_{=\max(\bullet)=F} + 0,5 \sum_{i=1}^N \frac{a_i}{g_i} (\varepsilon_i^+ - \varepsilon_i^-) \leq F \cdot \sum_{i=1}^N a_i + 0,5 \sum_{i=1}^N \frac{a_i}{g_i} (\varepsilon_i^+ - \varepsilon_i^-),$$

где $F = \max_i \dot{f}(x=x_i)$.

Для оператора E математического ожидания имеем:

$$El_N \leq E \left[F \cdot \sum_{i=1}^N a_i + 0,5 \sum_{i=1}^N \frac{a_i}{g_i} (\varepsilon_i^+ - \varepsilon_i^-) \right] = F \cdot \sum_{i=1}^N a_i + 0,5 \sum_{i=1}^N \frac{a_i}{g_i} \underbrace{(E\varepsilon_i^+ - E\varepsilon_i^-)}_{=0} = F \cdot \sum_{i=1}^N a_i.$$

Аналогично для оператора D дисперсии:

$$Dl_N \leq D \left[F \cdot \sum_{i=1}^N a_i + 0,5 \sum_{i=1}^N \frac{a_i}{g_i} (\varepsilon_i^+ - \varepsilon_i^-) \right] = 0 + (0,5)^2 \cdot \sum_{i=1}^N \left(\frac{a_i}{g_i} \right)^2 \cdot (D\varepsilon_i^+ - D\varepsilon_i^-).$$

Так как:

$$\hat{f}(x_i + g_i) = f(x_i + g_i) + \varepsilon_i^+ \Rightarrow \varepsilon_i^+ = \hat{f}(x_i + g_i) - \underbrace{f(x_i + g_i)}_{=const};$$

$$\hat{f}(x_i - g_i) = f(x_i - g_i) + \varepsilon_i^- \Rightarrow \varepsilon_i^- = \hat{f}(x_i - g_i) - \underbrace{f(x_i - g_i)}_{=const},$$

поэтому:

$$Dl_N \leq 0,25 \cdot \sum_{i=1}^N \left(\frac{a_i}{g_i} \right)^2 \cdot [\hat{f}(x_i + g_i) - f(x_i + g_i) - \hat{f}(x_i - g_i) - f(x_i - g_i)],$$

откуда:

$$l_N \leq 0,25 \cdot \sum_{i=1}^N \left(\frac{a_i}{g_i} \right)^2 \cdot 2D\hat{f}(x_i + g_i),$$

так как очевидно, что $D\hat{f}(x_i + g_i) = D\hat{f}(x_i - g_i)$.

$$D\left[\hat{f}(x_i + g_i) - \hat{f}(x_i - g_i)\right] = 2D\hat{f}(x_i + g_i).$$

$$D\hat{f}(x_i + g_i):$$

$$D\hat{f}(x_i + g_i) = R \cdot \delta^2 \left(X^T X \right)^{-1} \cdot R^{-1} = \delta^2(1, 0) \begin{pmatrix} D\hat{f}(x_i + g_i) & * \\ * & * \end{pmatrix} \begin{pmatrix} 1 \\ 0 \end{pmatrix} \Bigg|_{n=const} - const$$

поэтому:

$$Dl_N \leq 0,5 \cdot F_1 \cdot \sum_{i=1}^N \left(\frac{a_i}{g_i} \right)^2, \quad F_1 = \max_i D\hat{f}(x_i + g_i).$$

Для сходимости итерационного процесса необходимо:

$$\lim_{N \rightarrow \infty} El_N = \infty, \quad \lim_{N \rightarrow \infty} Dl_N = 0,$$

что в результате дает следующие условия сходимости:

1. $F = \max_i \dot{f}(x = x_i) < \infty$
2. $\sum_{i=1}^{\infty} a_i = \infty$
3. $F_1 = \max_i D\hat{f}(x_i + g_i) < \infty$
4. $\sum_{i=1}^{\infty} \left(\frac{a_i}{g_i} \right)^2 < \infty.$

Эти условия в теории адаптивных систем управления принято называть условиями Кифера и Вольфовица (Kifer J., Wolfowitz J.).

Условия 2 и 4 определяют правила для выбора a_i , g_i в адаптивной САО, например:

$$a_i = \frac{1}{i^\alpha}, \quad g_i = \frac{1}{i^\beta},$$

где α , β - некоторые параметры, для которых должны выполняться ограничения (рис. 4.16):




Рис. 4.16. Зона выбора параметров α , β в условиях Кифера-Вольфовитца.

$$0 < \alpha \leq 1, \quad \beta > 0, \quad \alpha - \beta > \frac{1}{2}.$$

В частности условия сходимости 2 и 4 выполняются при

$$\alpha = 1, \quad \beta = \frac{1}{4}.$$

Действительно:

$$\sum a_i = \sum_{i=1}^{\infty} \frac{1}{i} = \infty, \quad \sum_{i=1}^{\infty} \left(\frac{a_i}{g_i} \right)^2 = \sum_{i=1}^{\infty} \left(\frac{\frac{1}{i}}{\frac{1}{i^{1/4}}} \right)^2 = \sum_{i=1}^{\infty} \frac{1}{i^{3/2}} < \infty,$$

по признаку сходимости Даламбера:

$$\frac{a_{i+1}}{a_i} = \frac{\frac{1}{(i+1)^{3/2}}}{\frac{1}{i^{3/2}}} = \frac{1}{(1 + \frac{1}{i})^{3/2}} < 1.$$

Таким образом, алгоритм САО с адаптацией пробных « g_i » и рабочих « a_i » шагов, синтезированный по МСА имеет вид (рис 4.17):

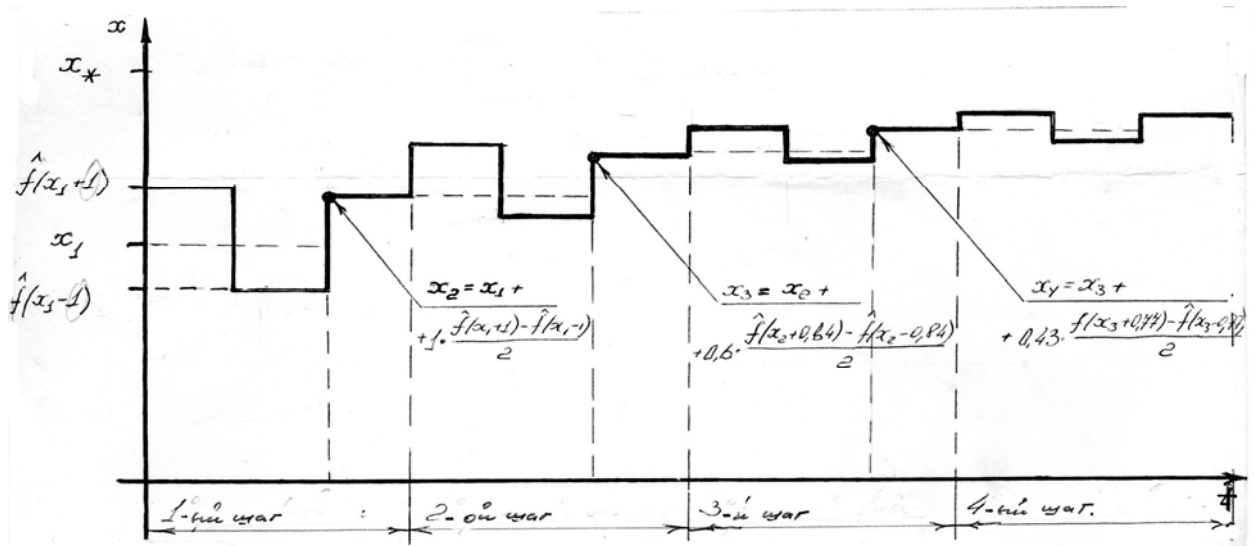


Рис. 4.17. Изменение рабочих и поисковых смещений в адаптивной САО.

$$x_{i+1} = \frac{a}{2 \cdot \frac{g}{i^{1/4}}} \cdot \left\{ \hat{f} \left(x_i + \frac{g}{i^{1/4}} \right) - \hat{f} \left(x_i + \frac{g}{i^{1/4}} \right) \right\}, \quad i = \overline{1, m},$$

$\hat{f}(\cdot)$ - оценка МНК; a , g - рабочие и пробные шаги в начале поиска экстремальной точки x_* зависимости $f(x)$.

Алгоритм вдали от экстремума, когда крутизна $y = f(x)$, измеряемая $\dot{f}(x = x_i)$, является значительной, обеспечивает большие значения параметров a_i , g_i шага поиска, а далее (рис 4.9) по мере приближения к экстремальной точке x_* , когда $\dot{f}(x = x_i)$ уменьшается, параметры шага a_i , g_i также уменьшаются.

4.2.2. Метод Качмажа (МК)

Общие положения МК

Модель объекта линейна и имеет форму:

$$y(t) = \sum_{i=0}^{n-1} a_i \cdot f_i(t) = F^T(t) \cdot A = A^T \cdot F(t),$$

гиперплоскостей. Из точки A_0 опускается перпендикуляр на правую гиперплоскость y_1 . В результате пересечения перпендикуляра с гиперплоскостью y_1 получается точка A_1 . Из точки A_1 опускается перпендикуляр на гиперплоскость y_2 , получается точка A_2 , из A_2 - перпендикуляр на гиперплоскость y_3 и. т. д. В результате образуется совокупность точек $\{A_i\}_{i=0}^N$. Доказывается, что:

$$\{A_i\}_{i=0}^N \xrightarrow{N \rightarrow \infty} \hat{A}.$$

Формализуем это геометрическое представление. Точка A_0 имеет координаты $A_0 = (a_{00}, a_{10}, \dots, a_{n-10})$, а точка A_1 , координаты $A_1 = (a_{01}, a_{11}, \dots, a_{n-11})$ и принадлежит гиперплоскости y_1 ($m. A_1 \in y_1$), поэтому:

$$a_{01} \cdot f_0(t_1) + a_{11} \cdot f_1(t_1) + \dots + a_{n-11} \cdot f_{n-1}(t_1) - y_1 = 0.$$

Вектор A_0A_1 имеет координаты:

$$A_0A_1 = (a_{01} - a_{00}, a_{11} - a_{10}, \dots, a_{n-11} - a_{n-10}).$$

Из аналитической геометрии известно, что, если в системе координат a_0, \dots, a_{n-1} имеем уравнение гиперплоскости $a_0 \cdot f_0(t_1) + \dots + a_{n-1} \cdot f_{n-1}(t_1) = y_1$, то ее направляющие векторы $f_0(t_1), \dots, f_{n-1}(t_1)$ это есть координаты перпендикуляра M_1 к гиперплоскости y_1 . Поэтому:

$$M_1 = (f_0(t_1), \dots, f_{n-1}(t_1)).$$

Из рисунка 4.18 следует, что вектора A_0A_1 и M_1 должны быть параллельны, то есть их координаты должны быть пропорциональны:

$$\frac{a_{01} - a_{00}}{f_0(t_1)} = \dots = \frac{a_{n-11} - a_{n-10}}{f_{n-1}(t_1)} = m.$$

Это дает:

$$\left[\begin{array}{l} a_{01} - a_{00} = mf_0(t_1) \\ \vdots \\ a_{n-11} - a_{n-10} = mf_{n-1}(t_1) \\ a_{01}f_0(t_1) + \dots + a_{n-10}f_{n-1}(t_1) = y_1 \end{array} \right] \begin{array}{l} A_1 A_0 \parallel M_1 \\ m, A_1 \in y_1 \end{array}$$

Это система уравнений относительно $a_{01}, \dots, a_{n-11}, m$, т.е. имеем « $n+1$ » неизвестных и « $n+1$ » уравнений. Решаем ее методом подстановки:

$$a_{01} = a_{00} + m \cdot f_0(t_1); a_{11} = a_{10} + m \cdot f_1(t_1); \dots; a_{n-11} = a_{n-10} + m \cdot f_{n-1}(t_1).$$

$$\left[a_{00} + m \cdot f_0(t_1) \right] \cdot f_0(t_1) + \dots + \left[a_{n-10} + m \cdot f_{n-1}(t_1) \right] \cdot f_{n-1}(t_1) = y_1,$$

откуда, разрешая относительно « m » последнее уравнение, получим:

$$m = \frac{y_1 - \sum_{i=0}^{n-1} a_{0i} \cdot f_i(t_1)}{\sum_{i=0}^{n-1} f_i^2(t_1)} = \frac{y_1 - (A_0^T, F(t_1))}{(F^T(t_1), F(t_1))},$$

где (\cdot, \cdot) - скалярное произведение.

Подставим « m » в первые « n » уравнений, тогда:

$$A_1 = A_0 + \frac{y_1 - (A_0^T, F(t_1))}{(F^T(t_1), F(t_1))} \cdot F(t_1).$$

Таким образом, нашли координаты $m, A_1 \in y_1$ (гиперплоскость).

Аналогично:

$$\begin{aligned} A_2 &= A_1 + \frac{y_2 - (A_1^T, F(t_2))}{(F^T(t_2), F(t_2))} \cdot F(t_2) \\ &\vdots \\ A_N &= A_{N-1} + \frac{y_N - (A_{N-1}^T, F(t_N))}{(F^T(t_N), F(t_N))} \cdot F(t_N). \end{aligned}$$

Этот алгоритм достаточно простой при его реализации на μK , однако он обладает низкой скоростью сходимости. Адаптация состоит в последовательной процедуре обработки текущих измерений (в темпе с процессом поступления измерений – on line).

Условие останова процесса задается в виде:

$$|A_N - A_{N-1}| \leq \varepsilon, \quad \varepsilon - \text{заданное число.}$$

Синтез адаптивного алгоритма САО на базе МК




Рис. 4.7. Модель объекта (а) и переходные процессы на его выходе.

Имеем объект типа Н.-Л. С известной величиной T (рис 4.7) и для уменьшения влияния T на время поиска x_* зависимости $y = f(x)$ используется прогнозирование установившегося значения $f(x_i + g)$, $f(x_i - g)$ при подаче на вход объекта парных проб $\pm g$ относительно x_i .

В этом случае имеем:

$$y^+(t) = f(x_i + g) \cdot 1 + a_1^+ e^{-t/T} = f(x_i + g) \cdot f_0(t) + a_1^+ \cdot f_1(t)$$

Или в терминах МК:

$$f_0(t) = 1, \quad f_1(t) = e^{-t/T}.$$

В соответствии с процедурой МК имеем:

$$\begin{aligned}
\hat{f}_N(x_i + g) &= (1, 0) \left[\begin{pmatrix} \hat{a}_{0,N-1} \\ \hat{a}_{1,N-1} \end{pmatrix} + \frac{y_N - (A_{N-1}^T, F(t_N))}{(F^T(t_N), F(t_N))} \cdot \begin{pmatrix} f_0(t_N) \\ f_1(t_N) \end{pmatrix} \right] = \\
&= (1, 0) \cdot \left[\begin{pmatrix} \hat{f}_{N-1}(x_i + g) \\ \hat{a}_{1,N-1} \end{pmatrix} + \frac{z_N - \left[\hat{f}_{N-1}(x_i + g) + \hat{a}_{1,N-1} \cdot e^{-\frac{N\tau}{T}} \right]}{1 + \left(e^{-\frac{N\tau}{T}} \right)^2} \cdot \begin{pmatrix} 1 \\ e^{-\frac{N\tau}{T}} \end{pmatrix} \right] = \\
&= b_N \cdot z_N + c_N \cdot \hat{f}_{N-1}(x_i + g) - d_N \cdot \hat{a}_{1,N-1}, \\
b_N &= (1 + e^{-\frac{2N\tau}{T}})^{-1}, \quad c_N = e^{-\frac{2N\tau}{T}} (1 + e^{-\frac{2N\tau}{T}})^{-1}, \quad d_N = e^{-\frac{N\tau}{T}} (1 + e^{-\frac{2N\tau}{T}})^{-1}.
\end{aligned}$$

Аналогичные вычисления делаются для $\hat{f}_N(x_i - g)$, поэтому:

$$x_{i+1} = x_i + a \cdot \text{sign} \{ \hat{f}_N(x_i + g) - \hat{f}_N(x_i - g) \}.$$

4.2.3. Метод фильтра Калмана (МФК)

Общие положения МФК

Имеется динамический объект, модель которого задана в форме дифференциального уравнения в пространстве состояний. На вход и выход объекта воздействуют случайные возмущения, которые моделируют ошибки в управлении и измерении состояний. Необходимо синтезировать алгоритм оценки состояний объекта, который обеспечивает минимум дисперсии его оценок.

Пусть имеем модель объекта в пространстве состояний (рис. 4.19):




Рис. 4.19. Модель объекта при воздействии случайных возмущений на его входе и выходе.

$$\begin{cases} \dot{X}(t) = A_c(t) \cdot X(t) + D_c(t) \cdot U(t) + V_c(t) \\ Y(t) = H_c(t) \cdot X(t) + W(t) \end{cases},$$

где $X(t) = (x_1(t), \dots, x_n(t))$ - вектор состояний объекта;

$U(t) = (u_1(t), \dots, u_n(t))$ - вектор управления;

$H_c(t)$ - матрица;

$Y^T(t) = (y_1(t), \dots, y_n(t))$ - вектор измерений выхода объекта;

$V_c^T(t) = (v_1(t), \dots, v_n(t))$ - вектор случайных возмущений управления;

$W^T(t) = (w_1(t), \dots, w_n(t))$ - вектор случайных возмущений при измерении

состояний объекта.

Ковариационные матрицы:

$$DW(t), \quad DV_c(t)$$

Случайных процессов $W(t)$, $V_c(t)$ заданы.

Пример. Пусть $DW(t) = 0$, $DV_c(t)$; модель объекта:

$$\ddot{y}(t) = a_0, \quad a_0 - const.$$

Необходимо записать эту модель в пространстве состояний.

В канонической (стандартной) форме модель объекта имеет вид:

$$1 \cdot \underbrace{\ddot{y}(t)}_{\dot{x}_2} + 0 \cdot \underbrace{\dot{y}(t)}_{x_2 = \dot{x}_1} + 0 \cdot \underbrace{y(t)}_{x_1} = a_0.$$

После замены переменных (замена Коши) получим:

$$\begin{cases} y = x_1 \\ \dot{x}_1 = x_2 \\ \dot{x}_2 = a_0 \end{cases}$$

или в матричной форме:

$$\begin{cases} \dot{x}_1 = 0 \cdot x_2 + 1 \cdot x_2 + 0 \cdot a_0 \\ \dot{x}_2 = 0 \cdot x_1 + 0 \cdot x_2 + 1 \cdot a_0 \\ y = 1 \cdot x_1 + 0 \cdot x_2 \end{cases} \Leftrightarrow \begin{cases} \underbrace{\begin{pmatrix} \dot{x}_1 \\ \dot{x}_2 \end{pmatrix}}_{\dot{X}} = \underbrace{\begin{pmatrix} 0 & 1 \\ 0 & 0 \end{pmatrix}}_{A_c} \underbrace{\begin{pmatrix} x_1 \\ x_2 \end{pmatrix}}_X + \underbrace{\begin{pmatrix} 0 & 0 \\ 1 & 0 \end{pmatrix}}_{D_c} \underbrace{\begin{pmatrix} a_0 \\ 0 \end{pmatrix}}_U \\ \underbrace{\begin{pmatrix} y \\ 0 \end{pmatrix}}_{\dot{Y}} = \underbrace{\begin{pmatrix} 1 & 0 \\ 0 & 0 \end{pmatrix}}_{H_c} \underbrace{\begin{pmatrix} x_1 \\ x_2 \end{pmatrix}}_X \end{cases}.$$

Рассмотрим дискретный вариант модели в пространстве состояний. Для этого используем обозначения:

$$X(t) = X[k], \quad X(t \rightarrow \tau) = X[k+1], \quad \tau - \text{шаг по времени, } k - \text{номер измерения,}$$

тогда:

$$\dot{X}(t) \approx \frac{X(t+\tau) - X(t)}{\tau} = \frac{X[k+1] - X[k]}{\tau}.$$

Разностная модель будет иметь вид:

$$\begin{cases} X[k+1] = A[k] \cdot X[k] + D[k] \cdot U[k] \cdot V[k] \\ Y[k+1] = H[k] \cdot X[k] \cdot W[k] \end{cases},$$

где $A[k] = \{I + A_c[k] \cdot \tau\}$; $D[k] = D_c[k] \cdot \tau$; $V[k] = V_c[k] \cdot \tau$.

Для простоты положим:

$$A[k] = A; \quad D[k] = D; \quad H[k] = H,$$

тогда в результате получим:

$$\begin{cases} X[k+1] = AX[k] + DU[k] \cdot V[k] \\ Y[k+1] = H[k] \cdot X[k] \cdot W[k] \end{cases}.$$

Относительно случайных возмущений полагаем:

1. $\begin{cases} EV[k] = 0 \\ EW[k] = 0 \end{cases}$ условия центрированности возмущений;

$$\begin{aligned} & DV[k] = R \cdot \delta_{K_j} \sim \begin{pmatrix} * & & 0 \\ & \ddots & \\ 0 & & * \end{pmatrix} \\ & 2. \quad DW[k] = Q \cdot \delta_{K_j} \sim \begin{pmatrix} * & & 0 \\ & \ddots & \\ 0 & & * \end{pmatrix} \end{aligned} \left. \vphantom{\begin{aligned} DV[k] = R \cdot \delta_{K_j} \sim \begin{pmatrix} * & & 0 \\ & \ddots & \\ 0 & & * \end{pmatrix} \\ DW[k] = Q \cdot \delta_{K_j} \sim \begin{pmatrix} * & & 0 \\ & \ddots & \\ 0 & & * \end{pmatrix} \right\} \begin{array}{l} \text{условия на измерения на входе и выходе} \\ \text{объекта относительно их} \\ \text{некоррелированности} \end{array} \right.$$

$$\delta_{K_j} = \begin{cases} 1, & k = j \\ 0, & k \neq j \end{cases}$$

$$R, Q - \text{заданные матрицы}$$

3. $E\{V[k] \cdot W^T[k]\} = 0$ - условие некоррелированности случайных процессов

$V[k]$ и $W[k]$.

Постановка задачи. Имеем число « k » измерений управления $u[j]$, $j = \overline{1, k}$ со случайными возмущениями $V[j]$, $j = \overline{1, k}$ на входе объекта и число « k »

измерений $y[j]$, $j = \overline{1, k}$ со случайными возмущениями $W[j]$, $j = \overline{1, k}$ на выходе объекта. Имеем дискретную модель объекта и модель измерительной системы в пространстве состояний. Для момента « i » времени необходимо найти оценку \hat{X} вектора состояний X из условия (рис. 4.20)

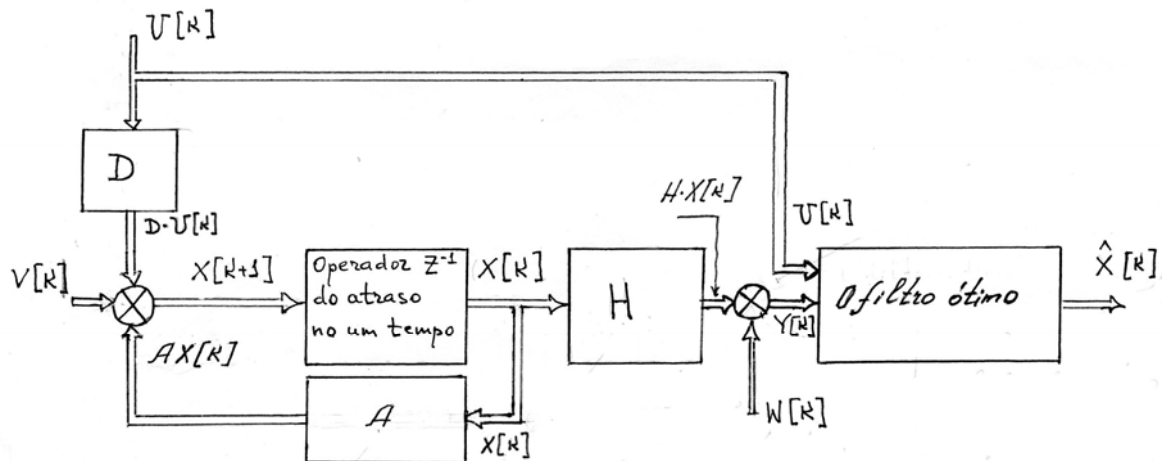


Рис. 4.20. Оптимальная фильтрация с помощью фильтра Калмана.

$$\min D\hat{X}[i], \quad i = \overline{1, k}.$$

В теории цифровых систем управления обычно используется следующая терминология:

- $i < k$ - задача сглаживания;
- $i = k$ - задача оптимальной фильтрации;
- $i > k$ - задача прогнозирования.

Рассмотрим частный случай фильтра, который затем обобщим. Пусть имеем:

1. $U[k] = 0$ - управление отсутствует;
2. $V[k] = 0$ - случайные возмущения отсутствуют;
3. $Y^T[k] = y_1[k]$ - вектор измерений на выходе имеет одну компоненту.

В условиях 1-3 будем иметь модель объекта и измерительной системы в виде:

$$\begin{cases} X[k+1] = AX[k] \\ y_1[k] = h^T \cdot X[k] + W_1[k] \end{cases}.$$

Из первого уравнения:

$$X[k] = A^{-1} \cdot X[k+1],$$

которое подставляем во второе уравнение:

$$y_1[k] = h^T A^{-1}[k+1] + W_1[k].$$

Оператор A^{-1} преобразует вектор $X[i+1]$ в вектор $X[i]$ ($X[i+1] \xrightarrow{A^{-1}} X[i]$), поэтому будем иметь цепочку отношений:

$$\begin{aligned} X[1] &= A^{-1} \cdot X[2] = A^{-1}(A^{-1}X[3]) = \dots = A^{-(k-1)}X[k]; \\ X[2] &= A^{-1} \cdot X[3] = A^{-1}(A^{-1}X[4]) = \dots = A^{-(k-2)}X[k]; \\ &\vdots \\ X[i] &= A^{-(k-i)} \cdot X[k], \quad i = \overline{1, k}. \end{aligned}$$

При наличии числа « k » измерений $y_1[1], y_1[2], \dots, y_1[k]$ на выходе будем иметь СЛАУ относительно неизвестного вектора $X^T[k] = (x_1[k], \dots, x_n[k])_{(1 \times n)}$:

$$\begin{cases} y_1[1] = h^T A^{-1}X[2] + w_1[1] = \{X[2] = A^{-(k-2)} \cdot X[k]\} = h^T A^{-(k-2)} \cdot X[k] + w_1[1] \\ \vdots \\ y_1[k] = h^T A^{-(k-k)} \cdot X[k] + w_1[k] \end{cases}$$

или в матричной форме:

$$Y_1[k] = \Phi[k] \cdot X[k] + W_1[k],$$

где $Y_1^T[k] = (y_1[1], \dots, y_1[k])$; $W_1^T[k] = (w_1[1], \dots, w_1[k])$;

$$\Phi[k] = \begin{pmatrix} h_{(1 \times n)}^T & A_{(n \times n)}^{-(k \times 1)} \\ \vdots & \\ h_{(1 \times n)}^T & A_{(n \times n)}^{-(k \times k)} \end{pmatrix} - \text{матрица размером } \dim(k \times n).$$

Полагаем далее, что число « k » измерений: $k > n$, где n - число неизвестных параметров $X^T[k] = (x_1[k], \dots, x_n[k])$, кроме этого полагаем, что $EW_1 = 0$, $DW_1 = \delta^2 \cdot I$.

В этих условиях вектор неизвестных параметров $X[k]$ будем искать по МНК.

$$\min_{X[k]} W_1^T[k] \cdot W_1[k] = \min_{X[k]} (Y_1[k] - \Phi[k] \cdot X[k])^T \cdot (Y_1[k] - \Phi[k] \cdot X[k]).$$

Для получения адаптивного МНК для него используется рекуррентная форма. Эта форма базируется на следующих сведениях из алгебры матриц:

- блочное умножение матриц:

$$\left(A \mid B \right) \begin{pmatrix} C \\ \text{---} \\ D \end{pmatrix} = AC + BD;$$

- обращение матрицы, представленной в виде сумм двух матриц

$$A^{-1} = (B + CDE)^{-1} = B^{-1} - B^{-1}C(D^{-1} + EB^{-1}C)^{-1}EB^{-1}.$$

В соответствии с МНК имеем:

$$\hat{X}[k] = \left(\Phi^T[k] \cdot \Phi[k] \right)^{-1} \cdot \Phi^T[k] \cdot Y_1[k].$$

Используем обозначение:

$$P[k] = \left(\Phi^T[k] \cdot \Phi[k] \right)^{-1},$$

тогда:

$$\hat{X}[k] = P[k] \cdot \Phi^T[k] \cdot Y_1[k].$$

Запишем матрицу $\Phi[k]$ и вектор $Y_1[k]$ в блочной форме:

$$\Phi[k] = \begin{pmatrix} \Phi[k-1] \cdot A^{-1} \\ \text{---} \\ h^T \end{pmatrix}; \quad Y_1^T[k] = \left(Y_1[k-1] \mid y_1[k] \right),$$

тогда:

$$\begin{aligned} \hat{X}[k] &= P[k] \cdot \begin{pmatrix} \Phi[k-1] \cdot A^{-1} \\ \text{---} \\ h^T \end{pmatrix}^T \cdot \begin{pmatrix} Y_1[k-1] \\ \text{---} \\ y_1[k] \end{pmatrix} = \left\{ \begin{pmatrix} U \\ \text{---} \\ V \end{pmatrix}^T = \left(U \mid V \right) \right\} = \\ &= P[k] \cdot \left(\left(\Phi[k-1] \cdot A^{-1} \right)^T \mid h \right) \cdot \begin{pmatrix} Y_1[k-1] \\ \text{---} \\ y_1[k] \end{pmatrix} = \{ \text{умножение блочных матриц} \} \\ &= P[k] \cdot \{ (A^{-1})^T \Phi^T[k-1] \cdot Y_1[k-1] + h \cdot y_1[k] \}. \end{aligned}$$

Для $P[k]$ имеем:

$$\begin{aligned}
P[k] &= (\Phi^T[k] \cdot \Phi[k])^{-1} = \left[\begin{pmatrix} \Phi[k-1] \cdot A^{-1} \\ \hline h^T \end{pmatrix} \cdot \begin{pmatrix} \Phi[k-1] \cdot A^{-1} \\ \hline h^T \end{pmatrix} \right]^{-1} = \\
&= \left\{ \begin{pmatrix} U \\ \hline V \end{pmatrix}^T = \begin{pmatrix} U & | & V \end{pmatrix} \right\} = \left[\begin{pmatrix} (A^{-1})^T \cdot \Phi^T[k-1] & | & h \end{pmatrix} \begin{pmatrix} \Phi[k-1] \cdot A^{-1} \\ \hline h^T \end{pmatrix} \right]^{-1} = \\
&= \left[(A^{-1})^T \cdot \underbrace{\Phi^T[k-1] \cdot \Phi[k-1]}_{P^{-1}[k-1]} \cdot A^{-1} + h \cdot h^T \right]^{-1} = \\
&= \left[(A^{-1})^T \cdot P^{-1}[k-1] \cdot A^{-1} + h \cdot I \cdot h^T \right]^{-1} = \{U^{-1}V^{-1}Z^{-1} = (ZVU)^{-1}\} = \\
&= \left[\underbrace{(A \cdot P[k-1] \cdot A^T)^{-1}}_{M[k-1]} + h \cdot I \cdot h^T \right]^{-1} = \left[\underbrace{M^{-1}[k-1]}_B + \underbrace{h \cdot I \cdot h^T}_{\underbrace{\begin{smallmatrix} \underbrace{h}_{\tilde{C}} \cdot \underbrace{I}_{\tilde{D}} \cdot \underbrace{h^T}_{\tilde{E}} \end{smallmatrix}}_{\tilde{C}}} \right]^{-1} = \\
&= \{обратная матрица от суммы\} = \\
&= \underbrace{(M^{-1}[k-1])^{-1}}_{B^{-1}} - \underbrace{(M^{-1}[k-1])^{-1}}_{B^{-1}} \cdot \underbrace{h}_{\tilde{C}} \cdot \left[\underbrace{I^{-1}}_{\tilde{D}^{-1}} + \underbrace{h^T}_{\tilde{E}} \underbrace{(M^{-1}[k-1])^{-1}}_{B^{-1}} \right] \cdot \underbrace{h}_{\tilde{C}} \cdot \underbrace{h^T}_{\tilde{E}} \cdot \underbrace{(M^{-1}[k-1])^{-1}}_{B^{-1}} = \\
&= M[k-1] - M[k-1] \cdot h \cdot \left(1 + \underbrace{h^T \cdot M[k-1] \cdot h}_{\substack{(1 \times n)(n \times n)(n \times 1) = (1 \times 1) \\ \text{число } \alpha \Rightarrow (1 + \alpha[k-1])^{-1} = \gamma[k-1]}} \right) \cdot h^T \cdot M[k-1] = \\
&= M[k-1] - M[k-1] \cdot h \cdot \gamma[k-1] \cdot h^T \cdot M[k-1] = M[k-1] - \gamma[k-1] \cdot M[k-1] \cdot h \cdot h^T \cdot M[k-1].
\end{aligned}$$

В результате получим:

$$\begin{aligned}
\hat{X}[k] &= \underbrace{(M[k-1] - \gamma[k-1] \cdot M[k-1] \cdot h \cdot h^T \cdot M[k-1])}_{P[k]} \cdot ((A^{-1})^T \cdot \Phi^T[k-1] \cdot Y_1[k-1] + h \cdot y_1[k]) = \\
&= \{раскрываем скобки и приводим подобные члены\} = \\
&= \underbrace{M[k-1] \cdot (A^{-1})^T \cdot \Phi[k-1] \cdot Y_1[k-1]}_{(1)} + \gamma[k-1] \cdot M[k-1] \cdot h \cdot y_1[k] - h^T \cdot M[k+1] \cdot (A^{-1})^T \Phi[k-1] Y_1[k-1].
\end{aligned}$$

Рассмотрим (1):

$$\begin{aligned}
(1) &= \{(A) = (A^T)^{-1}, AP[k-1]A^T = (\Phi^T[k-1] \cdot \Phi[k-1])^{-1}\} = \\
&= A \left(\Phi^T[k-1] \cdot \Phi[k-1] \right)^{-1} \cdot \underbrace{A^T (A^T)^{-1}}_I \cdot \Phi^T[k-1] \cdot Y_1[k-1] = \\
&= A \underbrace{(\Phi^T[k-1] \cdot \Phi[k-1])^{-1} \cdot \Phi^T[k-1] \cdot Y_1[k-1]}_{\mathcal{K}[k-1]} = A \cdot \mathcal{K}[k-1].
\end{aligned}$$

Таким образом, имеем следующие рекуррентные соотношения:

$$\begin{cases} \hat{X}[k] = A\hat{X}[k-1] + \gamma[k-1] \cdot M[k-1] \cdot h \left(y_1[k] - h^T \cdot A \cdot \hat{X}[k-1] \right) \\ M[k-1] = AP[k-1]A^T \\ P[k-1] = M[k-1] - \gamma[k-1] \cdot M[k-1] \cdot h \cdot h^T \cdot M[k-1] \\ \gamma[k-1] = \left(1 + h^T \cdot M[k-1] \cdot h \right)^{-1} \end{cases}.$$

Эти формулы не зависят от случайных возмущений на выходе объекта, поэтому они не имеют вероятностной интерпретации. Для устранения этого негативного свойства используем ковариационную матрицу оценок МНК:

$$D\hat{X}[k-1] = \delta^2 \underbrace{\left(\Phi^T[k-1] \cdot \Phi[k-1] \right)^{-1}}_{P[k-1]} = \delta^2 P[k-1],$$

откуда:

$$\begin{aligned} P[k-1] &= \frac{D\hat{X}[k-1]}{\delta^2}; \quad M[k-1] = A \div P[k-1] \cdot A^T = \frac{A \cdot D\hat{X}[k-1] \cdot A^T}{\delta^2}; \\ \gamma[k-1] &= \left(1 + h^T M[k-1] h \right)^{-1} = \left(1 + h^T \cdot \frac{A \cdot D\hat{X}[k-1] \cdot A^T}{\delta^2} \cdot h \right)^{-1} = \\ &= \delta^2 \underbrace{\left(\delta^2 + h^T \cdot A \cdot D\hat{X}[k-1] \cdot A^T \cdot h \right)^{-1}}_{\gamma_1[k-1]} = \delta^2 \cdot \gamma_1[k-1]. \end{aligned}$$

В результате получим:

$$\begin{cases} \hat{X}[k] = A\hat{X}[k-1] + \gamma_1[k-1] \cdot M[k-1] \cdot h \left(y_1[k] - h^T A \cdot \hat{X}[k-1] \right) \\ M[k-1] = \delta^{-2} \cdot A D\hat{X}[k-1] \cdot A^T \\ \frac{D\hat{X}[k-1]}{\delta^2} = \frac{A D\hat{X}[k-1] \cdot A^T}{\delta^2} - \gamma_1[k-1] \cdot \frac{A D\hat{X}[k-1] \cdot A^T h h^T A D\hat{X}[k-1] \cdot A^T}{\delta^2} \\ \gamma_1[k-1] = \left(\delta^2 h^T A D\hat{X}[k-1] A^T h \right)^{-1} \end{cases}$$

Эти формулы определяют дискретный фильтр Калмана в простейшей форме, то есть в отсутствии случайных возмущений V на входе объекта.