

Filtro de Kalman: teoría y aplicaciones*

Alfonso Novales
Departamento de Economía Cuantitativa
Universidad Complutense

Diciembre 2017
Versión preliminar
No citar sin permiso del autor
©Copyright 2016

Contents

1 Filtro de Kalman	1
1.1 Comienza el procedimiento recursivo	3
1.2 Actualización de inferencias acerca de ξ_t	4
1.2.1 Resumen: Filtro de Kalman	5
1.3 Predicción s períodos hacia adelante	6
1.4 Smoothing (suavizado)	6
2 Aplicaciones	9
2.1 Estimación de la tendencia subyacente	9
2.1.1 Modelo de camino aleatorio	9
2.1.2 Modelo de doble camino aleatorio	10
2.1.3 Descomposición de una variable en tendencia y ciclo	10
2.2 El filtro de Kalman con parámetros cambiantes	11
2.3 Aplicación: Regresión con parámetros cambiantes en el tiempo	12
2.4 Aplicación: CAPM con coeficientes cambiantes en el tiempo	13
2.5 Aplicación: Ratio de cobertura de mínimos cuadrados	14

1 Filtro de Kalman

El filtro de Kalman es un algoritmo para actualizar, observación a observación, la proyección lineal de un sistema de variables sobre el conjunto de información disponible, según se va disponiendo de nueva información. Para ello, es preciso representar el modelo en la formulación conocida como espacio de los estados. El filtro de Kalman permite calcular de modo sencillo la verosimilitud de un

*Estas notas se basan en el Capítulo 13 de Hamilton: "Time Series Analysis"

modelo dinámico lineal, uniecuacional o multiecuacional, lo que permite estimar los parámetros de dicho modelo, así como obtener predicciones de dicho tipo de modelos.

La representación en forma de espacio de los estados es:

$$\begin{matrix} \xi_{t+1} \\ (rx1) \end{matrix} = \begin{matrix} F \\ (rxr) \end{matrix} \xi_t + \begin{matrix} v_{t+1}, \\ (rx1) \end{matrix} \text{ ecuación de estado} \quad (1)$$

$$\begin{matrix} y_t \\ (nx1) \end{matrix} = \begin{matrix} A' \\ (nxk)(kx1) \end{matrix} x_t + \begin{matrix} H' \\ (nxr) \end{matrix} \xi_t + \begin{matrix} w_t, \\ (nx1) \end{matrix} \text{ ecuación de observación} \quad (2)$$

con:

$$\begin{aligned} E(v_t v_t') &= Q, \text{ matriz } r \times r; E(v_t v_s') = 0_{r \times r}, \text{ si } t \neq s \\ E(w_t w_t') &= R, \text{ matriz } n \times n; E(w_t w_s') = 0_{n \times n}, \text{ si } t \neq s \\ E(v_t w_s') &= 0, \text{ matriz } r \times n \forall t, s \\ E(\xi_t w_s') &= 0, \text{ matriz } r \times n \forall t, s \end{aligned}$$

El vector ξ_t de variables de estado es generalmente no observable, mientras que y_t y x_t son observables. El vector x_t contiene variables exógenas. Ello significa que x_t no contiene información sobre ξ_{t+s} o w_{t+s} que no esté ya contenida en $(y_{t-1}, y_{t-2}, \dots, y_1)$. El vector x_t puede contener retardos de y_t o variables que estén incorrelacionadas con ξ_τ y w_τ para todo τ .

Nuestro objetivo es predecir ξ_{t+1} e y_{t+1} a partir de información disponible en t . Denotamos la predicción un periodo hacia adelante como:

$$\hat{\xi}_{t+1|t} = E(\xi_{t+1} | Y_t);$$

donde Y_t denota el conjunto de información disponible para el analista al hacer las predicciones para el periodo $t+1$: $Y_t = (x'_t, x'_{t-1}, \dots, x'_1, y'_t, y'_{t-1}, \dots, y'_1)$. En otras ocasiones calcularemos predicciones condicionales en el conjunto Y_{t-1} o en el conjunto (x'_t, Y_{t-1}) . También analizaremos predicciones a horizontes más largos.

Que las variables x_t sean exógenas o predeterminadas implica que:

$$E(\xi_t | x_t, Y_{t-1}) = E(\xi_t | Y_{t-1}) = \hat{\xi}_{t|t-1}$$

Asociadas a cada una de estas predicciones tendremos una matriz de Error Cuadrático Medio:

$$P_{t|t-1} = E \left[\left(\xi_t - \hat{\xi}_{t|t-1} \right) \left(\xi_t - \hat{\xi}_{t|t-1} \right)' \right]$$

Suponiendo que tuviéramos condiciones iniciales $\hat{\xi}_{1|0}, P_{1|0}$, querríamos encontrar expresiones recursivas que nos permitan pasar de $\hat{\xi}_{t|t-1}, P_{t|t-1}$ a $\hat{\xi}_{t+1|t}, P_{t+1|t}$. El procedimiento recursivo comienza con $\hat{\xi}_{1|0}$, que denota la predicción de ξ_1

sin utilizar información sobre y o x . Dicha predicción es la media incondicional de ξ_1 :

$$\hat{\xi}_{1|0} = E(\xi_1)$$

con matriz de ECM:

$$P_{1|0} = E[(\xi_1 - E\xi_1)(\xi_1 - E\xi_1)']$$

Si los autovalores de F están todos dentro del círculo unidad, entonces el proceso propuesto para ξ_t es estacionario en covarianza. En ese caso, la media incondicional de ξ_t puede obtenerse tomando esperanza matemática en (1) : $E(\xi_{t+1}) = F.E(\xi_t)$, por lo que si es estacionario en covarianza, tendremos: $(I_r - F)E(\xi_t) = 0$, y si ningún autovalor es igual a cero, entonces: $E(\xi_t) = 0$.

La varianza incondicional es:

$$\begin{aligned} \Sigma &= E(\xi_{t+1}\xi_{t+1}') = E[(F\xi_t + v_{t+1})(F\xi_t + v_{t+1})'] = F[E(\xi_t\xi_t')]F' + E(v_{t+1}v_{t+1}') = \\ &= F\Sigma F' + Q \end{aligned}$$

ecuación que tiene por solución:¹

$$vec(\Sigma) = [I_{r^2} - (F \otimes F)]^{-1} vec(Q)$$

1.1 Comienza el procedimiento recursivo

Por tanto, bajo el supuesto mencionado para los autovalores de F , comenzaremos la recursión con $\hat{\xi}_{1|0} = 0$, y con $P_{1|0}$ igual a la matriz $r \times r$ Σ que se obtiene de la ecuación anterior. En cualquier otra circunstancia, puede tomarse otro valor de $\hat{\xi}_{1|0}$, mientras que $P_{1|0}$ puede escogerse de modo que refleje la incertidumbre existente acerca de dichos valores iniciales. Valores numéricos más elevados a lo largo de la diagonal de $P_{1|0}$ reflejarán mayor incertidumbre acerca del verdadero valor de la variable de estado correspondiente.

Nuestro objetivo es predecir el valor de y_t :

$$\hat{y}_{t|t-1} \equiv E(y_t | x_t, Y_{t-1})$$

Ahora bien, como:

$$E(y_t | x_t, \xi_t) = A'x_t + H'\xi_t$$

aplicando la ley de proyecciones iteradas, tenemos:

$$\hat{y}_{t|t-1} = A'x_t + H'E(\xi_t | x_t, Y_{t-1}) = A'x_t + H'\hat{\xi}_{t|t-1}$$

¹ $\Sigma = F\Sigma F' + Q \Rightarrow vec(\Sigma) = vec(F\Sigma F') + vec(Q) \Rightarrow$
 $vec(\Sigma) = (F \otimes F)vec(\Sigma) + vec(Q) \Rightarrow vec(\Sigma) = [I_{r^2} - (F \otimes F)]^{-1} vec(Q)$

por lo que el error de predicción es:

$$\begin{aligned} y_t - \hat{y}_{t|t-1} &= (A'x_t + H'\xi_t + w_t) - (A'x_t + H'\hat{\xi}_{t|t-1}) = \\ &= H'(\xi_t - \hat{\xi}_{t|t-1}) + w_t \end{aligned}$$

con matriz de error cuadrático medio

$$V_t = E \left[(y_t - \hat{y}_{t|t-1}) (y_t - \hat{y}_{t|t-1})' \right] = H' P_{t|t-1} H + R$$

donde $P_{t|t-1}$ denota la matriz de error cuadrático medio de $\xi_t - \hat{\xi}_{t|t-1}$, y donde hemos utilizado que: $E \left[w_t (\xi_t - \hat{\xi}_{t|t-1})' \right] = 0$. Esta igualdad se justifica porque w_t está incorrelacionado con ξ_t y porque como $\hat{\xi}_{t|t-1}$ es una combinación lineal de variables en Y_{t-1} , también ha de estar incorrelacionada con w_t .

1.2 Actualización de inferencias acerca de ξ_t

Una vez que observamos y_t , actualizamos nuestra estimación de ξ_t para obtener: $\hat{\xi}_{t|t} = E(\xi_t | x_t, y_t, Y_{t-1}) = E(\xi_t | Y_t)$, mediante:²

$$\begin{aligned} \hat{\xi}_{t|t} &= \hat{\xi}_{t|t-1} + \left\{ E \left[(\xi_t - \hat{\xi}_{t|t-1}) (y_t - \hat{y}_{t|t-1})' \right] \right\} \times \\ &\quad \left\{ E \left[(y_t - \hat{y}_{t|t-1}) (y_t - \hat{y}_{t|t-1})' \right] \right\}^{-1} (y_t - \hat{y}_{t|t-1}) \end{aligned}$$

Pero:

$$E \left[(\xi_t - \hat{\xi}_{t|t-1}) (y_t - \hat{y}_{t|t-1})' \right] = E \left\{ (\xi_t - \hat{\xi}_{t|t-1}) \left[H' (\xi_t - \hat{\xi}_{t|t-1}) + w_t \right]' \right\} = P_{t|t-1} H$$

por lo que:

$$\hat{\xi}_{t|t} = \hat{\xi}_{t|t-1} + P_{t|t-1} H (H' P_{t|t-1} H + R)^{-1} (y_t - A'x_t - H'\hat{\xi}_{t|t-1})$$

²Utilizamos la expresión:

$$P(A_3 | A_2, A_1) = \Omega_{31} \Omega_{11}^{-1} A_1 + H_{32} H_{22}^{-1} (A_2 - \Omega_{21} \Omega_{11}^{-1} A_1) =$$

con:

$$H_{22} = E \left[(A_2 - P(A_2 | A_1)) (A_2 - P(A_2 | A_1))' \right]$$

$$H_{32} = E \left[(A_3 - P(A_3 | A_1)) (A_2 - P(A_2 | A_1))' \right]$$

para $A_3 \equiv \xi_t, A_2 \equiv y_t, A_1 \equiv (x_t, Y_{t-1})$. Su matriz de error cuadrático medio es:

$$E \left[(A_3 - P(A_3 | A_2, A_1)) (A_3 - P(A_3 | A_2, A_1))' \right] = H_{33} - H_{32} H_{22}^{-1} H_{23}$$

con error cuadrático medio (ver pie de página anterior):

$$\begin{aligned} P_{t|t} &= E \left[\left(\xi_t - \hat{\xi}_{t|t} \right) \left(\xi_t - \hat{\xi}_{t|t} \right)' \right] = \\ &= P_{t|t-1} - \left[P_{t|t-1} H_t \left(H_t' P_{t|t-1} H_t + R \right)^{-1} H_t' P_{t|t-1} \right] \end{aligned}$$

Como hemos visto, el filtro de Kalman se inicializa con:

$$\begin{aligned} \hat{\xi}_{1|0} &= E(\xi) \\ P_{1|0} &= E[(\xi - E(\xi))(\xi - E(\xi))'] = [I_{r,2} - (F \otimes F)]^{-1} \text{vec}(Q) \end{aligned}$$

A partir de la ecuación de estado (1) obtenemos las ecuaciones de *predicción*:

$$\begin{aligned} \hat{\xi}_{t+1|t} &= E(\xi_{t+1} | Y_t) = F.E(\xi_t | Y_t) + E(v_{t+1} | Y_t) = F\hat{\xi}_{t|t} = \\ &= F\hat{\xi}_{t|t-1} + FP_{t|t-1}H(H'P_{t|t-1}H + R)^{-1}(y_t - A'x_t - H'\hat{\xi}_{t|t-1}) = \\ &F\hat{\xi}_{t|t-1} + K_t(y_t - \hat{y}_{t|t-1}) \end{aligned}$$

donde K_t denota la *ganancia* del filtro de Kalman:

$$K_t = FP_{t|t-1}H_t(H_t'P_{t|t-1}H_t + R)^{-1}$$

La matriz de Error Cuadrático Medio es:

$$\begin{aligned} P_{t+1|t} &= E \left[\left(\xi_{t+1} - \hat{\xi}_{t+1|t} \right) \left(\xi_{t+1} - \hat{\xi}_{t+1|t} \right)' \right] = \\ &= E \left[\left(F\xi_t + v_{t+1} - F\hat{\xi}_{t|t} \right) \left(F\xi_t + v_{t+1} - F\hat{\xi}_{t|t} \right)' \right] = \\ &= FP_{t|t}F' + Q = (FP_{t|t-1} - K_tH'P_{t|t-1})F' + Q \end{aligned}$$

puesto que los productos cruzados tiene esperanza matemática nula.

1.2.1 Resumen: Filtro de Kalman

$$\begin{aligned} y_t - \hat{y}_{t|t-1} &= y_t - A'x_t - H'\hat{\xi}_{t|t-1} \\ ECM(y_t) &= V_t = H'P_{t|t-1}H + R \\ \hat{\xi}_{t|t} &= \hat{\xi}_{t|t-1} + P_{t|t-1}HV_t^{-1}(y_t - \hat{y}_{t|t-1}) \\ P_{t|t} &= P_{t|t-1} - P_{t|t-1}HV_t^{-1}H'P_{t|t-1} \\ K_t &= FP_{t|t-1}HV_t^{-1} \\ \hat{\xi}_{t+1|t} &= F\hat{\xi}_{t|t} \\ P_{t+1|t} &= FP_{t|t}F' + Q \end{aligned}$$

Nótese que si $F = I_n$, entonces $\hat{\xi}_{t+1|t} = \hat{\xi}_{t|t}$.

Por último, para formar la función log-verosimilitud bajo el supuesto de Normalidad, necesitamos:

$$E(y_t | x_t, Y_{t-1}) = A'x_t + H_t'\hat{\xi}_{t|t-1}$$

$$E \left[\left(y_t - A'x_t - H_t'\hat{\xi}_{t|t-1} \right) \left(y_t - A'x_t - H_t'\hat{\xi}_{t|t-1} \right)' | x_t, Y_{t-1} \right] = H_t'P_{t|t-1}H_t + R$$

y finalmente, la función de densidad del vector y_t cada periodo y la función de verosimilitud, en logaritmos, son:

$$\begin{aligned} \ln f(y_t | x_t, Y_{t-1}) &= -\frac{n}{2} \ln(2\pi) - \frac{1}{2} \ln(|H_t'P_{t|t-1}H_t + R|) - \\ &\quad - \frac{1}{2} \left(y_t - A'x_t - H_t'\hat{\xi}_{t|t-1} \right)' (H_t'P_{t|t-1}H_t + R)^{-1} \left(y_t - A'x_t - H_t'\hat{\xi}_{t|t-1} \right) \end{aligned}$$

$$\log Lik = \sum_{t=1}^T \ln f(y_t | x_t, Y_{t-1})$$

Que puede maximizarse respecto de los parámetros que aparecen en las matrices F, Q, A, H y R .

1.3 Predicción s períodos hacia adelante

A partir de la ecuación de estado, y suponiendo que las variables x son deterministas, tenemos:

$$\begin{aligned} \xi_{t+s} &= F^s \xi_t + F^{s-1}v_{t+1} + F^{s-2}v_{t+2} + \dots + Fv_{t+s-1} + v_{t+s}, \quad s = 1, 2, \dots \\ E(\xi_{t+s} | \xi_t, Y_t) &= F^s \xi_t \Rightarrow \hat{\xi}_{t+s|t} = E(\xi_{t+s} | Y_t) = F^s \hat{\xi}_{t|t} \\ \xi_{t+s} - \hat{\xi}_{t+s|t} &= F^s \left(\xi_t - \hat{\xi}_{t|t} \right) + F^{s-1}v_{t+1} + F^{s-2}v_{t+2} + \dots + Fv_{t+s-1} + v_{t+s} \\ &\Rightarrow P_{t+s|t} = F^s P_{t|t} (F')^s + F^{s-1}Q(F')^{s-1} + F^{s-2}Q(F')^{s-2} + \dots + FQF' + Q \\ \hat{y}_{t+s|t} &= E(y_{t+s} | Y_t) = A'x_{t+s} + H'\hat{\xi}_{t+s|t} \Rightarrow y_{t+s} - \hat{y}_{t+s|t} = H' \left(\xi_{t+s} - \hat{\xi}_{t+s|t} \right) + w_{t+s} \\ MSE &: E \left[\left(y_{t+s} - \hat{y}_{t+s|t} \right) \left(y_{t+s} - \hat{y}_{t+s|t} \right)' \right] = H'P_{t+s|t}H + R \end{aligned}$$

1.4 Smoothing (suavizado)

La estimación suavizada de las variables de estado es:

$$\xi_{t|T} = E(\xi_t | Y_T)$$

Supongamos que hemos estimado ξ_t con datos hasta t , $\xi_{t|t}$ y que posteriormente observamos el verdadero valor de ξ_{t+1} . Podríamos utilizar la expresión de actualización de una proyección lineal que vimos en el pie de página anterior para obtener:

$$E(\xi_t | \xi_{t+1}, Y_t) = \xi_{t|t} + E \left[(\xi_t - \xi_{t|t}) (\xi_{t+1} - \xi_{t+1|t})' \right] \cdot E \left[(\xi_{t+1} - \xi_{t+1|t}) (\xi_{t+1} - \xi_{t+1|t})' \right]^{-1} \cdot (\xi_{t+1} - \xi_{t+1|t})$$

El primer término de la derecha puede escribirse:

$$E \left[(\xi_t - \xi_{t|t}) (\xi_{t+1} - \xi_{t+1|t})' \right] = E \left[(\xi_t - \xi_{t|t}) (F\xi_t + v_{t+1} - F\xi_{t|t})' \right]$$

y como v_{t+1} está incorrelacionado con ξ_t y con $\xi_{t|t}$, entonces:

$$E \left[(\xi_t - \xi_{t|t}) (\xi_{t+1} - \xi_{t+1|t})' \right] = E \left[(\xi_t - \xi_{t|t}) (\xi_t - \xi_{t|t})' F' \right] = P_{t|t} F'$$

Sustituyendo esta igualdad y la definición de $P_{t+1|t}$ en la primera expresión, tenemos:

$$E(\xi_t | \xi_{t+1}, Y_t) = \xi_{t|t} + P_{t|t} F' P_{t+1|t}^{-1} (\xi_{t+1} - \xi_{t+1|t})$$

y si definimos:

$$J_t = P_{t|t} F' P_{t+1|t}^{-1}$$

llegamos a:

$$E(\xi_t | \xi_{t+1}, Y_t) = \xi_{t|t} + J_t (\xi_{t+1} - \xi_{t+1|t})$$

Pero esta proyección es la misma que $E(\xi_t | \xi_{t+1}, Y_T)$ puesto que conocer los valores futuros y_{t+j}, x_{t+j} , $j > 0$, no añade información una vez que conocemos ξ_{t+1} . Esto se debe a que el error de proyección $\xi_t - E(\xi_t | \xi_{t+1}, Y_t)$ está incorrelacionado con ξ_{t+1} por las propiedades de una proyección lineal, y también con $x_{t+j}, w_{t+j}, v_{t+j}, v_{t+j-1}, \dots, v_{t+2}$ bajo las hipótesis que expusimos al comienzo. Por tanto, el error de proyección está incorrelacionado con y_{t+j}, x_{t+j} , $j > 0$. En consecuencia:

$$E(\xi_t | \xi_{t+1}, Y_T) = \xi_{t|t} + J_t (\xi_{t+1} - \xi_{t+1|t})$$

Por la ley de las proyecciones iteradas, la proyección $E(\xi_t | Y_T)$ puede obtenerse proyectando $E(\xi_t | \xi_{t+1}, Y_T)$ sobre Y_T . Pero $\xi_{t|t}$ es una función lineal exacta

de Y_t . Los coeficientes de dicha función son momentos poblacionales, y son por tanto constantes deterministas a efectos de una nueva proyección. Luego la proyección de $\xi_{t|t}$ sobre Y_T es $\xi_{t|T}$. Lo mismo sucede con $\xi_{t+1|t}$. El término J_t también es una función de momentos poblacionales y su proyección es él mismo. Por tanto:

$$E(\xi_t | Y_T) = \xi_{t|t} + J_t \left[E(\xi_{t+1} | Y_T) - \xi_{t+1|t} \right]$$

o:

$$\xi_{t|T} = \xi_{t|t} + J_t \left(\xi_{t+1|T} - \xi_{t+1|t} \right) \quad (3)$$

Procedemos de la siguiente manera: aplicamos el filtro de Kalman para obtener las sucesiones: $\left\{ \xi_{t|t} \right\}_{t=1}^T$, $\left\{ \xi_{t+1|t} \right\}_{t=1}^{T-1}$, $\left\{ P_{t|t} \right\}_{t=1}^T$, $\left\{ P_{t+1|t} \right\}_{t=1}^{T-1}$. La estimación suavizada de la última observación muestral, $\xi_{T|T}$ es la última observación en la sucesión $\left\{ \xi_{t|t} \right\}_{t=1}^T$. Luego, generamos $\left\{ J_t \right\}_{t=1}^{T-1}$, y utilizamos (3) con $t = T - 1$ para obtener $\xi_{T-1|T}$:

$$\xi_{T-1|T} = \xi_{T-1|T-1} + J_{T-1} \left(\xi_{T|T} - \xi_{T|T-1} \right)$$

A continuación, utilizamos la misma expresión con $t = T - 2$:

$$\xi_{T-2|T} = \xi_{T-2|T-2} + J_{T-2} \left(\xi_{T-1|T} - \xi_{T-1|T-2} \right)$$

y así sucesivamente. Para obtener el error cuadrático medio, a partir de (3) tenemos:

$$\begin{aligned} \xi_t - \xi_{t|T} &= \xi_t - \xi_{t|t} - J_t \xi_{t+1|T} + J_t \xi_{t+1|t} \Rightarrow \\ \xi_t - \xi_{t|T} + J_t \xi_{t+1|T} &= \xi_t - \xi_{t|t} + J_t \xi_{t+1|t} \end{aligned}$$

Multiplicando por su traspuesta y tomando esperanzas:

$$\begin{aligned} E \left[\left(\xi_t - \xi_{t|T} \right) \left(\xi_t - \xi_{t|T} \right)' \right] + J_t E \left[\xi_{t+1|T} \xi_{t+1|T}' \right] J_t' \\ = E \left[\left(\xi_t - \xi_{t|t} \right) \left(\xi_t - \xi_{t|t} \right)' \right] + J_t E \left[\xi_{t+1|t} \xi_{t+1|t}' \right] J_t' \end{aligned}$$

y tras varios desarrollos se llega a:

$$P_{t|T} = P_{t|t} + J_t \left(P_{t+1|T} - P_{t+1|t} \right) J_t'$$

una expresión que puede utilizarse de nuevo hacia atrás en el tiempo, comenzando con $t = T - 1$.

2 Aplicaciones

2.1 Estimación de la tendencia subyacente

2.1.1 Modelo de camino aleatorio

Consideremos un modelo de series temporales:

$$\begin{aligned} y_t &= \mu_t + e_t, \quad e_t \sim N(0, \sigma_e^2) \\ \mu_{t+1} &= \beta\mu_t + \eta_t, \quad \eta_t \sim N(0, \sigma_\eta^2) \end{aligned}$$

con $E(e_t, \eta_s) = 0, \forall t, s$.

En términos de la notación de Hamilton:

$$\begin{aligned} \xi_t &= \mu_t; \quad F \equiv \beta; \quad x_t = 0 \forall t; \quad H'_t = 1; \quad A = 0; \\ w_t &\equiv e_t; \quad v_t = \eta_t; \quad Q = \sigma_\eta^2; \quad R = \sigma_e^2 \end{aligned}$$

y, teniendo en cuenta que tenemos una única variable de estado y una única variable de observación, el fitro de Kalman resulta:

$$\begin{aligned} y_t - \hat{y}_{t|t-1} &= y_t - \mu_{t|t-1} \\ V_t &= P_{t|t-1} + \sigma_e^2 \\ K_t &= \beta P_{t|t-1} / V_t \\ \hat{\mu}_{t|t} &= \hat{\mu}_{t|t-1} + P_{t|t-1} (y_t - \hat{y}_{t|t-1}) / V_t \\ P_{t|t} &= P_{t|t-1} - \frac{P_{t|t-1}^2}{V_t} = P_{t|t-1} \left(1 - \frac{P_{t|t-1}}{V_t} \right) \\ \hat{\mu}_{t+1|t} &= \beta \hat{\mu}_{t|t} = \beta \hat{\mu}_{t|t-1} + K_t (y_t - \hat{y}_{t|t-1}) \\ P_{t+1|t} &= \beta^2 P_{t|t} + \sigma_\eta^2 \end{aligned}$$

en el que todas las variables, vectores y matrices son escalares, de dimensión 1x1.

Analicemos en este ejemplo la elección de condiciones iniciales. Tenemos que:

$$\begin{aligned} y_1 - y_{1|0} &= y_1 - \mu_{1|0}; \quad V_1 = P_{1|0} + \sigma_e^2 \\ \mu_{2|1} &= \mu_{1|0} + \frac{P_{1|0}}{V_1} w_1 = \mu_{1|0} + \frac{P_{1|0}}{P_{1|0} + \sigma_e^2} (y_1 - \mu_{1|0}) \\ P_{2|1} &= P_{1|0} \left(1 - \frac{P_{1|0}}{P_{1|0} + \sigma_e^2} \right) + \sigma_e^2 = \frac{P_{1|0}}{P_{1|0} + \sigma_e^2} \sigma_e^2 + \sigma_e^2 \end{aligned}$$

Por tanto, si dejamos que $P_{1|0}$ tienda a infinito, tendremos: $\mu_{2|1} = y_1$, y $P_{2|1} = \sigma_e^2 + \sigma_w^2$. Esto equivale a tratar y_1 como un parámetro fijo y suponer:

$\mu_1 \sim N(y_1, \sigma_e^2)$, lo cual se conoce como una inicialización difusa, porque tomar $P_{1|0}$ muy grande significa que se tiene una importante incertidumbre acerca de la condición inicial.

2.1.2 Modelo de doble camino aleatorio

Consideremos un modelo de series temporales:

$$\begin{aligned} y_t &= \mu_t + x_t \\ \mu_t &= g_{t-1} + \mu_{t-1} + v_t, v_t \sim i., i.d.N(0, \sigma_v^2) \\ g_t &= g_{t-1} + w_t, w_t \sim i., i.d.N(0, \sigma_w^2) \\ x_t &= \phi_1 x_{t-1} + \phi_2 x_{t-2} + e_t, e_t \sim i., i.d.N(0, \sigma_e^2) \end{aligned}$$

con $E(e_t \cdot \eta_s) = E(e_t \cdot w_s) = E(w_t \cdot \eta_s) = 0, \forall t, s$.

En términos de la notación de Hamilton:

$$\begin{aligned} \xi_t &= (\mu_t, x_t, x_{t-1}, g_t); \quad H'_t = (1, 1, 0, 0); \quad A = 0; \\ F &\equiv \begin{pmatrix} 1 & 0 & 0 & 1 \\ 0 & \phi_1 & \phi_2 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 1 \end{pmatrix}; \\ w_t &\equiv 0 \forall t; \quad v_t = (v_t, e_t, 0, w_t, \eta_t); \quad R = 0; \quad Q = \text{diag}(\sigma_v^2, \sigma_e^2, 0, \sigma_w^2) \end{aligned}$$

y, teniendo en cuenta que tenemos una única variable de estado y una única variable de observación, el filtro de Kalman resulta:

$$\begin{aligned} y_t - \hat{y}_{t|t-1} &= y_t - H' \mu_{t|t-1} \\ V_t &= H' P_{t|t-1} H \\ K_t &= F P_{t|t-1} H V_t^{-1} \\ \hat{\mu}_{t|t} &= \hat{\mu}_{t|t-1} + P_{t|t-1} H V_t^{-1} (y_t - \hat{y}_{t|t-1}) \\ P_{t|t} &= P_{t|t-1} - P_{t|t-1} H V_t^{-1} H' P_{t|t-1} \\ \hat{\mu}_{t+1|t} &= F \hat{\mu}_{t|t} = \beta \hat{\mu}_{t|t-1} + K_t (y_t - \hat{y}_{t|t-1}) \\ P_{t+1|t} &= (F - K_t H') P_{t|t} (F - K_t H')' + Q \end{aligned}$$

2.1.3 Descomposición de una variable en tendencia y ciclo

Modelo:

$$\begin{aligned} y_t &= T_t + c_t \\ T_{t+1} &= T_t + v_{t+1}, v_t \sim i., i.d.N(0, \sigma_v^2) \\ c_{t+1} &= \phi c_t + e_t, e_t \sim i., i.d.N(0, \sigma_e^2) \end{aligned}$$

donde y_t puede ser el logaritmo del PIB, o de un índice de bolsa, por ejemplo.

Representación en espacio de los estados:

Ecuación de observación:

$$y_t = \underbrace{(1 \ 1)}_G \underbrace{\begin{pmatrix} T_t \\ c_t \end{pmatrix}}_{x_t^i}$$

Ecuación de estado:

$$\underbrace{\begin{pmatrix} T_{t+1} \\ c_{t+1} \end{pmatrix}}_{x_{t+1}^i} = \underbrace{\begin{pmatrix} 1 & 0 \\ 0 & \phi \end{pmatrix}}_F \underbrace{\begin{pmatrix} T_t \\ c_t \end{pmatrix}}_{x_t^i} + \underbrace{\begin{pmatrix} v_t \\ e_t \end{pmatrix}}_{\eta_t}; \quad \eta_t \sim N\left(0_2, \begin{pmatrix} \sigma_v^2 & 0 \\ 0 & \sigma_e^2 \end{pmatrix}\right)$$

Condiciones iniciales razonables serían:

$$\begin{aligned} \hat{x}_{1|0} &= (\ln y_1; 0), \\ \text{vec}(\Sigma_{1|0}) &= \text{vec}(x_1 x_1') = [I_4 - F \otimes F]^{-1} \text{vec}(Q) \quad [\text{Matriz singular, habria que buscar alternativas}] \end{aligned}$$

2.2 El filtro de Kalman con parámetros cambiantes

En muchas situaciones, la representación en espacio de los estados se obtiene con parámetros cambiantes en el tiempo:

$$\begin{aligned} \xi_{t+1} &= F(x_t)\xi_t + v_{t+1} \\ y_t &= a(x_t) + H(x_t)'\xi_t + w_t \end{aligned}$$

En esta situación, el supuesto de Normalidad condicional para las perturbaciones, que en el caso general no es necesaria, resulta crucial. Si suponemos:

$$\begin{pmatrix} v_{t+1} \\ w_t \end{pmatrix} \mid x_t, Y_{t-1} \sim N\left(\begin{bmatrix} 0 \\ 0 \end{bmatrix}, \begin{bmatrix} Q(x_t) & 0 \\ 0 & R(x_t) \end{bmatrix}\right)$$

entonces la expresión del filtro de Kalman es similar a la del caso más restringido que contempla parámetros constantes, con las variaciones que naturalmente provienen del hecho de que las matrices y vectores F, A, H son ahora cambiantes en el tiempo.

Puede probarse (Hamilton, sección 13.8) que:

$$\begin{aligned} \hat{\xi}_{t|t} &= \hat{\xi}_{t|t-1} + \left\{ P_{t|t-1} H(x_t) [H(x_t)' P_{t|t-1} H(x_t) + R(x_t)]^{-1} (y_t - a(x_t) - H(x_t)'\hat{\xi}_{t|t-1}) \right\} \\ P_{t|t} &= P_{t|t-1} - P_{t|t-1} H(x_t) [H(x_t)' P_{t|t-1} H(x_t) + R(x_t)]^{-1} H(x_t)' P_{t|t-1} \end{aligned}$$

de lo que se obtiene:

$$\begin{aligned} V_t &= H_t' P_{t|t-1} H_t + R \\ K_t &= F_t P_{t|t-1} H_t V_t^{-1} \end{aligned}$$

$$\begin{aligned} \hat{\xi}_{t+1|t} &= F(x_t) \hat{\xi}_{t|t} \\ P_{t+1|t} &= F(x_t) P_{t|t} F(x_t)' + Q(x_t) \end{aligned}$$

2.3 Aplicacion: Regresión con parámetros cambiantes en el tiempo

Consideremos el modelo de regresión:

$$y_t = x_t' \beta_t + w_t$$

en el que suponemos que las variables en x_t son retardos de y_t o variables que son independientes de w_τ para todo τ . Suponemos que los parámetros evolucionan de acuerdo con:

$$\beta_{t+1} - \beta = F(\beta_t - \beta) + v_{t+1}$$

lo que implica que si los autovalores de F son inferiores a la unidad, entonces $E(\beta_t) = \beta$.

Suponemos tambien:

$$\left(\begin{array}{c} v_{t+1} \\ w_t \end{array} \mid x_t, Y_{t-1} \right) \sim N \left(\left[\begin{array}{c} 0 \\ 0 \end{array} \right], \left[\begin{array}{cc} Q & 0 \\ 0 & \sigma^2 \end{array} \right] \right)$$

La regresión puede escribirse:

$$y_t = x_t' \beta + x_t' \xi_t + w_t$$

donde el vector de estado es el vector de coeficientes de la regresión en diferencias respecto de su media:

$$\xi_t = \beta_t - \beta$$

por lo que la predicción un periodo hacia adelante es:

$$E(y_t \mid x_t, Y_{t-1}) = x_t' \beta + x_t' \hat{\xi}_{t|t-1}$$

donde $\hat{\xi}_{t|t-1}$ se obtiene a partir de:

$$\begin{aligned} \hat{\xi}_{t|t} &= \hat{\xi}_{t|t-1} + P_{t|t-1} x_t (x_t' P_{t|t-1} x_t + \sigma^2)^{-1} (y_t - x_t' \beta - x_t' \hat{\xi}_{t|t-1}) \\ \hat{\xi}_{t+1|t} &= F \hat{\xi}_{t|t} \\ P_{t|t} &= P_{t|t-1} - P_{t|t-1} x_t (x_t' P_{t|t-1} x_t + \sigma^2)^{-1} x_t' P_{t|t-1} \\ P_{t+1|t} &= F P_{t|t} F' + Q(x_t) \end{aligned}$$

comenzando con las condiciones iniciales habituales. En este caso, la matriz $x_t' P_{t|t-1} x_t + \sigma^2$ es escalar, por lo que multiplicar por su inversa equivale a dividir por ella. La matriz de Error Cuadrático medio es:

$$E \left[\left(y_t - x_t' \beta - x_t' \hat{\xi}_{t|t-1} \right)^2 \mid x_t, Y_{t-1} \right] = x_t' P_{t|t-1} x_t + \sigma^2$$

y la función de verosimilitud:

$$\begin{aligned} \ln f(y_t \mid x_t, Y_{t-1}) &= -\frac{n}{2} \ln(2\pi) - \frac{1}{2} \sum_{t=1}^T \ln (x_t' P_{t|t-1} x_t + \sigma^2) - \\ &\quad - \frac{1}{2} \sum_{t=1}^T \frac{\left(y_t - x_t' \beta - x_t' \hat{\xi}_{t|t-1} \right)^2}{x_t' P_{t|t-1} x_t + \sigma^2} \end{aligned}$$

En el caso de que supongamos que el vector de coeficientes β_t sigue un proceso AR(p), tendríamos:

$$\xi_{t+1} = \begin{pmatrix} \phi_1 & \phi_2 & \dots & \phi_{p-1} & \phi_p \\ I_k & 0 & \dots & 0 & 0 \\ 0 & I_k & \dots & 0 & 0 \\ \cdot & \cdot & & \cdot & \cdot \\ \cdot & \cdot & \dots & \cdot & \cdot \\ \cdot & \cdot & & \cdot & \cdot \\ 0 & 0 & \dots & I_k & 0 \end{pmatrix} \xi_t + \begin{pmatrix} v_{+1} \\ 0 \\ 0 \\ \cdot \\ \cdot \\ \cdot \\ 0 \end{pmatrix}$$

2.4 Aplicación: CAPM con coeficientes cambiantes en el tiempo

Consideremos el modelo en excesos de rendimiento respecto del activo sin riesgo:

$$\begin{aligned} r_t &= \alpha_t + \beta_t r_{M,t} + w_t, \quad w_t \sim N(0, \sigma_w^2) \\ \alpha_{t+1} &= \alpha_t + \eta_t, \quad \eta_t \sim N(0, \sigma_\eta^2) \\ \beta_{t+1} &= \beta_t + \varepsilon_t, \quad \varepsilon_t \sim N(0, \sigma_\varepsilon^2) \end{aligned}$$

con $E(e_t \cdot \eta_s) = E(e_t \cdot \varepsilon_s) = E(\varepsilon_t \cdot \eta_s) = 0, \forall t, s$. El supuesto de que la evolución de cada uno de los dos coeficientes el modelo sigue un camino aleatorio es una restricción que imponemos en el modelo.

El modelo puede escribirse:

$$r_t = \bar{\alpha} + (\alpha_t - \bar{\alpha}) + (\beta_t - \bar{\beta}) r_{M,t} + \bar{\beta} r_{M,t} + w_t$$

y las variables de estado van a ser los dos coeficientes, en diferencias respecto a su media. Dichas medias son dos de los parámetros a estimar. Los restantes parámetros son las varianzas de los 3 términos aleatorios: $w_t, \eta_t, \varepsilon_t$.

En este caso, tenemos la representación:

$$\begin{aligned} \begin{pmatrix} \tilde{\alpha}_{t+1} \\ \tilde{\beta}_{t+1} \end{pmatrix} &= \begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix} \begin{pmatrix} \tilde{\alpha}_t \\ \tilde{\beta}_t \end{pmatrix} + \begin{pmatrix} \eta_t \\ \varepsilon_t \end{pmatrix} \\ r_t &= \begin{pmatrix} 1 & r_{M,t} \end{pmatrix} \begin{pmatrix} \bar{\alpha} \\ \bar{\beta} \end{pmatrix} + \begin{pmatrix} 1 & r_{M,t} \end{pmatrix} \begin{pmatrix} \alpha_t \\ \beta_t \end{pmatrix} + w_t \end{aligned}$$

por lo que en términos de la notación de Hamilton, tenemos:

$$\begin{aligned} \xi_t &= \begin{pmatrix} \tilde{\alpha}_t, \tilde{\beta}_t \end{pmatrix}'; \quad F \equiv I_2; \quad A' = (\bar{\alpha}, \bar{\beta}); \quad x'_t = H'_t = (1, r_{M,t}); \\ v_t &\equiv (\eta_t, \varepsilon_t)'; \quad Q = \begin{pmatrix} \sigma_\eta^2 & 0 \\ 0 & \sigma_\varepsilon^2 \end{pmatrix}; \quad R = \sigma_w^2 \end{aligned}$$

y el filtro de Kalman resulta:

$$\begin{aligned} y_t - \hat{y}_{t|t-1} &= r_t - A'x_t - H'_t\xi_t \\ V_t &= H'_tP_{t|t-1}H_t + \sigma_w^2, \text{ escalar } 1 \times 1 \\ K_t &= \frac{P_{t|t-1}H_t}{V_t}, \text{ vector } 2 \times 1 \\ \begin{pmatrix} \hat{\alpha}_{t|t} \\ \hat{\beta}_{t|t} \end{pmatrix} &= \begin{pmatrix} \hat{\alpha}_{t|t-1} \\ \hat{\beta}_{t|t-1} \end{pmatrix} + K_t(y_t - \hat{y}_{t|t-1}) \\ P_{t|t} &= P_{t|t-1} - K_tH'_tP_{t|t-1} \\ \begin{pmatrix} \hat{\alpha}_{t+1|t} \\ \hat{\beta}_{t+1|t} \end{pmatrix} &= \begin{pmatrix} \hat{\alpha}_{t|t} \\ \hat{\beta}_{t|t} \end{pmatrix} = \begin{pmatrix} \hat{\alpha}_{t|t-1} \\ \hat{\beta}_{t|t-1} \end{pmatrix} + K_t(y_t - \hat{y}_{t|t-1}) \\ P_{t+1|t} &= P_{t|t} + Q \end{aligned}$$

Nótese que pr ser $F = I_2$, entonces $\xi_{t+1|t} = \xi_{t|t}$

2.5 Aplicación: Ratio de cobertura de mínimos cuadrados

Este ratio de cobertura no es sino la estimacion por minimos cuadrados ordinarios de la pendiente en una regresion lineal simple de las variaciones en el precio del contado sobre las variaciones en el precio del futuro. Vamos a permitir que dicho ratio varíe en el tiempo:

$$\Delta S_t = \alpha + \beta_t \Delta F_t + w_t$$

denotemos por $s_t = \Delta S_t - \overline{\Delta S}$, $f_t = \Delta F_t - \overline{\Delta F}$, y el modelo se transforma en:

$$s_t = \beta_t f_t + w_t \tag{4}$$

Suponemos que la evolución del ratio β_t está bien representada por un proceso AR(1):

$$\beta_t = \beta(1 - \varphi) + \varphi\beta_{t-1} + v_t$$

o, lo que es equivalente, si denotamos $\tilde{\beta} = \beta_t - \beta$:

$$\tilde{\beta}_t = \varphi\tilde{\beta}_{t-1} + v_t \quad (5)$$

Si escribimos (4) y (5) en la forma de espacio de los estados, tenemos:

$$\begin{aligned} \tilde{\beta}_{t+1} &= \varphi\tilde{\beta}_t + v_{t+1} \\ s_t &= \beta f_t + f_t\tilde{\beta}_t + w_t \end{aligned}$$

siendo la primera la ecuación de estado y la segunda la ecuación de observación.

En términos de la notación de Hamilton:

$$\begin{aligned} \xi_t &= \tilde{\beta}_t; \quad F \equiv \varphi; \quad A' = \beta; \quad x_t = f_t; \quad H'_t = f_t; \\ Q &= \sigma_v^2; \quad R = \sigma_w^2 \end{aligned}$$

El filtro de Kalman se inicializa con:

$$\begin{aligned} \hat{\xi}_{1|0} &= E(\xi) \Rightarrow \hat{\xi}_{1|0} = E(\tilde{\beta}) = 0 \\ P_{1|0} &= E[(\xi - E(\xi))(\xi - E(\xi))'] = [I_{r,2} - (F \otimes F)]^{-1} \text{vec}(Q) \Rightarrow \\ P_{1|0} &= \text{var}(\tilde{\beta}) = \frac{\sigma_v^2}{1 - \varphi^2} \end{aligned}$$

y a partir de las ecuaciones que describen la recursividad del filtro:

$$\begin{aligned} \hat{\xi}_{t|t} &= \hat{\xi}_{t|t-1} + \left[P_{t|t-1} H_t (H'_t P_{t|t-1} H_t + R)^{-1} (y_t - A' x_t - H'_t \hat{\xi}_{t|t-1}) \right] \\ P_{t|t} &= P_{t|t-1} - \left[P_{t|t-1} H_t (H'_t P_{t|t-1} H_t + R)^{-1} H'_t P_{t|t-1} \right] \end{aligned}$$

aplicadas a este ejemplo, vamos obteniendo las ecuaciones de *filtrado*:

$$\begin{aligned} \hat{\beta}_{t|t} &= \hat{\beta}_{t|t-1} + \left[P_{t|t-1} f_t \frac{1}{f_t^2 P_{t|t-1} + \sigma_w^2} (s_t - \beta f_t - f_t \hat{\beta}_{t|t-1}) \right] \\ P_{t|t} &= P_{t|t-1} - \frac{P_{t|t-1}^2 f_t^2}{f_t^2 P_{t|t-1} + \sigma_w^2} \end{aligned}$$

que, denotando $\Omega_t = f_t^2 P_{t|t-1} + \sigma_w^2$, pueden escribirse:

$$\begin{aligned}\widehat{\beta}_{t|t} &= \widehat{\beta}_{t|t-1} + \frac{P_{t|t-1}f_t}{\Omega_t} \left(s_t - \beta f_t - f_t \widehat{\beta}_{t|t-1} \right) \\ P_{t|t} &= P_{t|t-1} - \frac{P_{t|t-1}^2 f_t^2}{\Omega_t} = P_{t|t-1} \left(1 - \frac{f_t^2}{\Omega_t} P_{t|t-1} \right)\end{aligned}$$

La ganancia del filtro de Kalman es en este caso:

$$K_t = F P_{t|t-1} H_t (H_t' P_{t|t-1} H_t + R)^{-1} = \varphi P_{t|t-1} f_t \frac{1}{f_t^2 P_{t|t-1} + \sigma_w^2} = \frac{\varphi P_{t|t-1} f_t}{\Omega_t}$$

mientras que las habituales ecuaciones de *predicción*:

$$\begin{aligned}\widehat{\xi}_{t+1|t} &= F \widehat{\xi}_{t|t} \\ P_{t+1|t} &= F P_{t|t-1} F' + \sigma_v^2\end{aligned}$$

se convierten en este ejemplo en:

$$\begin{aligned}\widehat{\beta}_{t+1|t} &= \varphi \widehat{\beta}_{t|t} = \varphi \widehat{\beta}_{t|t-1} + \varphi \frac{P_{t|t-1} f_t}{\Omega_t} w_t = \varphi \widehat{\beta}_{t|t-1} + K_t \left(s_t - \beta f_t - f_t \widehat{\beta}_{t|t-1} \right) \\ P_{t+1|t} &= \varphi^2 P_{t|t} + \sigma_v^2 = \varphi^2 P_{t|t-1} \left(1 - \frac{f_t^2}{\Omega_t} P_{t|t-1} \right) + \sigma_v^2\end{aligned}$$

Por último, para formar la función log-verosimilitud bajo el supuesto de Normalidad, necesitamos:

$$E(y_t | x_t, Y_{t-1}) = A' x_t + H_t' \widehat{\xi}_{t|t-1}$$

$$E \left[\left(y_t - A' x_t - H_t' \widehat{\xi}_{t|t-1} \right) \left(y_t - A' x_t - H_t' \widehat{\xi}_{t|t-1} \right)' | x_t, Y_{t-1} \right] = H_t P_{t|t-1} H_t' + R$$

que, denotando $S_{t-1} = \{s_{t-1}, s_{t-2}, \dots\}$ se convierten en:

$$\begin{aligned}E(s_t | f_t, S_{t-1}) &= \beta f_t + f_t \widehat{\beta}_{t|t-1} \\ E \left[\left(s_t - \beta f_t - f_t \widehat{\beta}_{t|t-1} \right)^2 | f_t, S_{t-1} \right] &= f_t^2 P_{t|t-1} + \sigma_w^2\end{aligned}$$

y finalmente:

$$\log Lik = \sum_{t=1}^T \ln f(s_t | f_t, S_{t-1}) = -\frac{T}{2} \ln(2\pi) - \frac{1}{2} \sum_{t=1}^T \ln (f_t^2 P_{t|t-1} + \sigma_w^2) - \frac{1}{2} \sum_{t=1}^T \frac{\left(s_t - \beta f_t - f_t \widehat{\beta}_{t|t-1} \right)^2}{f_t^2 P_{t|t-1} + \sigma_w^2}$$