

3 Fundamentação Teórica de Modelos Bayesianos de Previsão

3.1. Abordagem Bayesiana para Estimação

A informação que se tem acerca de um parâmetro de interesse θ é crucial na ciência estatística. Se o valor verdadeiro de θ não é conhecido então, a idéia é buscar métodos para reduzir o desconhecimento sobre esse parâmetro. Do ponto de vista bayesiano, o grau de incerteza a respeito de θ é representado através de um modelo probabilístico para θ .

A abordagem clássica para estimação de um parâmetro populacional consiste em tomar uma amostra aleatória de tamanho n , proveniente de uma população cuja distribuição de probabilidades da variável aleatória, por exemplo, Y seja função de um parâmetro θ , distribuição essa denotada por $f(y|\theta)$ e, posteriormente, estimar o parâmetro θ através dos valores amostrais $y_i, i=1, \dots, n$. Esse estimador poderia ser construído através do método da máxima verossimilhança, por exemplo.

A abordagem bayesiana para estimação de um parâmetro populacional usa uma distribuição a priori de θ , $f(\theta)$, e a distribuição de probabilidades conjunta da amostra, $f(y_1, y_2, \dots, y_n | \theta)$, para determinar a distribuição a posteriori de θ , denotada por $f(\theta | y_1, y_2, \dots, y_n)$. Essa distribuição a posteriori para θ contém informação proveniente da amostra e da distribuição a priori de θ . Sendo assim, o parâmetro θ é visto como uma variável aleatória na abordagem bayesiana, (MONTGOMERY & RUNGER, 2003, p. 437).

Pole et al. (1994) comentam que a análise bayesiana para a formulação de um modelo começa pela quantificação do conhecimento inicial acerca desse estado inicial. Essas informações a priori são então combinadas com a informação dos dados observados e quantificados probabilisticamente através da função de verossimilhança.

O mecanismo de combinar informações a priori e verossimilhança é o teorema de Bayes. Portanto, pode-se escrever:

$$P(\theta_t | D_t) = \frac{P(Y_t = y_t | \theta_t)P(\theta_t | D_{t-1})}{P(Y_t = y_t)} \quad (12)$$

O denominador $P(Y_t = y_t)$ não é função de θ e atua como uma constante. Sendo D_t o estado do conhecimento no instante t , a verossimilhança $L(\theta_t | Y_t = y_t) \propto P(Y_t = y_t | \theta_t)$, $P(\theta_t | D_t)$ é distribuição a posteriori e $P(\theta_t | D_{t-1})$ a distribuição a priori.

O resultado de combinar informações a priori e verossimilhança é a distribuição a posteriori. Então, a distribuição a posteriori é proporcional à distribuição a priori e à verossimilhança: *posteriori* \propto *priori* \times *verossimilhança*.

Esse processo de passagem da priori para a posteriori é referida como aprendizado bayesiano, sendo o mecanismo formal através do qual as incertezas são modificadas quando da obtenção de uma nova informação, (POLE et al., 1994, p. 16).

3.2. Abordagem Bayesiana para Previsão

No que se refere a modelos de previsão de uma forma geral, Pole et al. (1994, p. 9) declaram que

Whenever we make a forecast we actually make a statement of probability, or, more generally, state a probability distribution that quantifies the nature of our uncertainty. Any and every forecast is predicated upon a fount of knowledge; forecasts are therefore conditional probability statements, the conditioning being on the existing state of knowledge. If we change our knowledge base, then, typically, our forecast will change.[...] The Bayesian paradigm provides a rational, coherent, formal framework for combining information: routine model forecast (or individual model component quantifications, and more generally components forms too) are adjusted by subjective intervention to reflect so called ‘external’ information.

A abordagem bayesiana para previsão permite que informações não contidas nos dados históricos sejam incorporadas ao modelo. A possibilidade de se obter informações externas é o centro da inferência bayesiana. Os detalhes dessa abordagem são discutidos no decorrer desse trabalho.

3.3.

Características Fundamentais dos Modelos Bayesianos de Previsão de Harrison & Stevens (HS)

Segundo Souza & Farias Neto (1980), os fundamentos essenciais dos modelos bayesianos de Harrison & Stevens (HS) são:

- (i) Formulação Paramétrica (ou de espaço de estados) - Interpretação física dos parâmetros, isto é, as séries são representadas através de componentes que são diretamente interpretáveis, facilitando o entendimento do modelo por parte do analista.
- (ii) Informação Probabilística – parâmetros são variáveis aleatórias (com distribuição de probabilidade associada) e não simplesmente quantidades desconhecidas. A abordagem bayesiana explicita não apenas as estimativas dos componentes a cada instante de tempo, mas também indica automaticamente uma medida de incerteza associada a tais estimativas.
- (iii) Modelo Seqüencial – formulação através do Modelo Linear Dinâmico (MLD) que descreve como as estimativas dos parâmetros mudam temporalmente.
- (iv) Incerteza do Modelo – o modelo adequado em certo instante de tempo pode não ser mais apropriado em um instante seguinte.

Segundo Harrison & Stevens (1976), a incerteza associada ao modelo pode ser de dois tipos distintos:

Classe I – assume-se que o processo pode ser representado adequadamente por um único modelo (desconhecido).

Classe II – supõe-se que o modelo que melhor representa o processo pode mudar com o tempo. Dessa maneira, a qualquer instante de tempo considera-se que o modelo atuante é aquele de maior probabilidade associada.

A Tabela 1 faz uma comparação entre os modelos bayesianos (HS) versus os modelos tradicionais (MT) para a previsão.

Tabela 1 - Comparação dos Modelos Bayesianos (HS) com Modelos Tradicionais (MT)

Características	Modelos Tradicionais (MT)	Modelos Bayesianos (HS)
Estacionariedade do modelo	Existe um modelo constante para todo $t = 1, 2, \dots$	Pode existir mais de um modelo adequado para todo $t = 1, 2, \dots$
Informação externa	Utilizam somente os dados históricos.	Utilizam a série histórica e/ou outras informações relevantes.
Tamanho da série histórica	Tamanho suficientemente grande.	Tamanho qualquer, HS podem ser utilizados, inicialmente, mesmo na ausência de dados históricos.
Estacionariedade da série	O processo gerador dos dados deve ser estacionário e ergódico.	O processo pode ser qualquer.

3.4.

Modelo Linear Dinâmico – MLD

West & Harrison (1997) mostram que o modelo linear dinâmico normal pode ser escrito de forma geral como:

$$\text{Equação das Observações: } \mathbf{Y}_t = \mathbf{F}'_t \boldsymbol{\theta}_t + \mathbf{v}_t, \quad \mathbf{v}_t \sim N[\mathbf{0}, \mathbf{V}_t] \quad (13)$$

$$\text{Equação do Sistema: } \boldsymbol{\theta}_t = \mathbf{G}_t \boldsymbol{\theta}_{t-1} + \boldsymbol{\omega}_t, \quad \boldsymbol{\omega}_t \sim N[\mathbf{0}, \mathbf{W}_t] \quad (14)$$

onde \mathbf{Y}_t denota um vetor ($r \times 1$) das observações da série no tempo t ; \mathbf{F}_t é uma matriz ($n \times r$) de constantes conhecidas – vetor de regressão; $\boldsymbol{\theta}_t$ é o vetor ($n \times 1$) dos parâmetros de estado do modelo – vetor de estado; \mathbf{v}_t é o ruído das observações, vetor ($r \times 1$), tendo distribuição normal com média zero e variância \mathbf{V}_t , que é uma matriz ($r \times r$); \mathbf{G}_t é uma matriz ($n \times n$) de coeficientes conhecidos que determina a evolução sistemática dos parâmetros no tempo; e $\boldsymbol{\omega}_t$ é o ruído do sistema, vetor ($n \times 1$), tendo distribuição normal com média zero e matriz de covariância \mathbf{W}_t , matriz ($n \times n$). Supõe-se que \mathbf{v}_t e $\boldsymbol{\omega}_t$ são temporalmente e mutuamente independentes, ou seja, para todo t, s , tais que $t \neq s$, $\text{cov}[\mathbf{v}_t, \mathbf{v}_s] = 0$ e $\text{cov}[\boldsymbol{\omega}_t, \boldsymbol{\omega}_s] = 0$; e, para todo t, s , $\text{cov}[\mathbf{v}_t, \boldsymbol{\omega}_s] = 0$. Outra suposição importante é que $\mathbf{G}_t \equiv \mathbf{G}$, ou seja, o interesse se encontra em MLD's que possuem uma matriz de coeficientes que não se modifica com o tempo.

A eq. (13) descreve a forma como cada observação é gerada para um dado estado do sistema no instante t , é chamada equação das observações. A eq. (14), por conseguinte, descreve o modelo dinâmico, ou seja, a evolução paramétrica entre o instante $t-1$ e o instante t , e é chamada equação do sistema.

O problema de estimação do MLD refere-se a encontrar estimativas para o vetor de estados $\boldsymbol{\theta}_t$, a cada instante t , com base nas observações disponíveis até aquele instante, inclusive.

3.4.1.

Algoritmo do MLD com variância V_t conhecida

Em muitas situações é mais simples utilizar o Y_t (caso escalar) no lugar do vetor de observações \mathbf{Y}_t , esse procedimento caracteriza o MLD como univariado. West & Harrison (1997) definem o MLD univariado geral com variância V_t conhecida, como:

$$\text{Equação das Observações: } Y_t = \mathbf{F}_t' \boldsymbol{\theta}_t + \nu_t, \quad \nu_t \sim N[0, V_t] \quad (15)$$

$$\text{Equação do Sistema: } \boldsymbol{\theta}_t = \mathbf{G}_t \boldsymbol{\theta}_{t-1} + \boldsymbol{\omega}_t, \quad \boldsymbol{\omega}_t \sim N[\mathbf{0}, \mathbf{W}_t] \quad (16)$$

Especificações iniciais do usuário:

$$(\boldsymbol{\theta}_0 | D_0) \sim N(\mathbf{m}_0, \mathbf{C}_0) \text{ e } \{\mathbf{F}_t, \mathbf{G}_t, \mathbf{V}_t \text{ e } \mathbf{W}_t\}$$

$D_0 \rightarrow$ estado do conhecimento no instante inicial.

$D_t \rightarrow$ estado do conhecimento no instante t .

Informação:

$$(\boldsymbol{\theta}_{t-1} | D_{t-1}) \sim N[\mathbf{m}_{t-1}, \mathbf{C}_{t-1}] \rightarrow \text{posteriori no instante } t-1.$$

$$(\boldsymbol{\theta}_t | D_{t-1}) \sim N[\mathbf{a}_t, \mathbf{R}_t] \rightarrow \text{priori no instante } t.$$

$$\mathbf{a}_t = \mathbf{G}_t \mathbf{m}_{t-1} \quad (17)$$

$$\mathbf{R}_t = \mathbf{G}_t \mathbf{C}_{t-1} \mathbf{G}_t' + \mathbf{W}_t \quad (18)$$

Previsão no instante t :

$$(Y_t | D_{t-1}) \sim N[f_t, Q_t]$$

$$f_t = \mathbf{F}_t' \mathbf{a}_t \quad (19)$$

$$Q_t = \mathbf{F}_t' \mathbf{R}_t \mathbf{F}_t + V_t \quad (20)$$

Atualização:

$$(\boldsymbol{\theta}_t | D_t) \sim N[\mathbf{m}_t, \mathbf{C}_t] \rightarrow \text{posteriori no instante } t$$

$$\mathbf{m}_t = \mathbf{a}_t + \mathbf{A}_t e_t \quad (21)$$

$$\mathbf{C}_t = \mathbf{R}_t - \mathbf{A}_t \mathbf{Q}_t \mathbf{A}_t' \quad (22)$$

$$e_t = Y_t - f_t \quad (23)$$

$$\mathbf{A}_t = \mathbf{R}_t \mathbf{F}_t \mathbf{Q}_t^{-1} \quad (24)$$

Previsões na origem t , k passos à frente ($k \geq 1$):

$$(\boldsymbol{\theta}_{t+k} | D_t) \sim N[\mathbf{a}_t(k), \mathbf{R}_t(k)]$$

$$(Y_{t+k} | D_t) \sim N[f_t(k), Q_t(k)]$$

$$\mathbf{a}_t(k) = \mathbf{G}_{t+k} \mathbf{a}_t(k-1) \quad (25)$$

$$\mathbf{R}_t(k) = \mathbf{G}_{t+k} \mathbf{R}_t(k-1) \mathbf{G}_{t+k}' + \mathbf{W}_{t+k} \quad (26)$$

$$f_t(k) = \mathbf{F}_{t+k}' \mathbf{a}_t(k) \quad (27)$$

$$Q_t(k) = \mathbf{F}_{t+k}' \mathbf{R}_t(k) \mathbf{F}_{t+k} + V_{t+k} \quad (28)$$

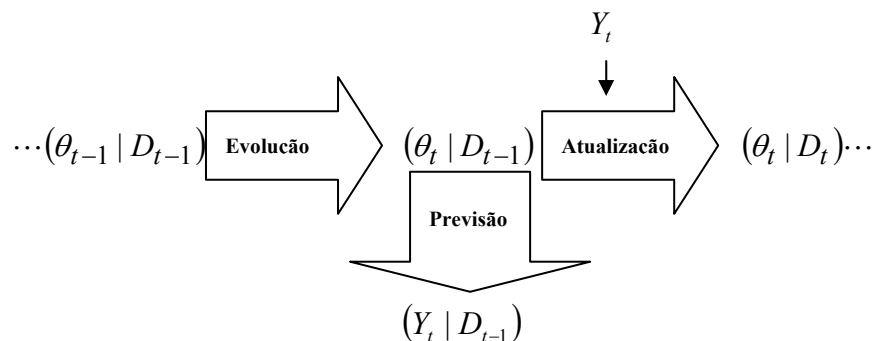
$$\mathbf{a}_t(0) = \mathbf{m}_t \quad (29)$$

$$\mathbf{R}_t(0) = \mathbf{C}_t \quad (30)$$

Como pôde ser observado, o processo de previsão envolve a estimação de três distribuições condicionais:

1. Distribuição a priori de θ_t , denotada por $(\theta_t | D_{t-1})$: representa a melhor idéia acerca do estado do sistema após observar $\langle Y_1, \dots, Y_{t-1} \rangle$, porém antes de observar Y_t .
2. Distribuição da previsão no instante t , $(Y_t | D_{t-1})$: é derivada da distribuição a priori $(\theta_t | D_{t-1})$.
3. Distribuição a posteriori de θ_t , $(\theta_t | D_t)$: esta resulta da revisão da distribuição a priori com a inclusão da observação Y_t , utilizando o Teorema de Bayes.

De forma esquemática:



3.4.2. MLD - Modelo Estático de HS

É o modelo mais simples dentro da classe de Modelos Bayesianos de HS, correspondendo ao problema clássico de estimação sequencial da média μ de uma população normal. Na formulação MLD, tem-se que:

$$\theta_t = \mu; \quad \mathbf{F}_t = 1; \quad \mathbf{G}_t \equiv \mathbf{G} = 1; \quad \nu_t \sim N[0, V]; \quad \omega_t = 0 \quad (31)$$

A formulação matemática para o modelo estático (Figura 5) se resume a:

$$\text{Equação das Observações: } Y_t = \theta_t + \nu_t; \quad \nu_t \sim N[0, V] \quad (32)$$

$$\text{Equação do Sistema: } \theta_t = \text{constante} = \mu \quad (33)$$




Figura 5 - um processo com comportamento do modelo estático.

3.4.3. MLD - Modelo Estacionário de HS

Esse modelo descreve a evolução dinâmica do nível, segundo um passeio aleatório. Nesse caso:

$$\theta_t = \mu_t; \quad \mathbf{F}_t = 1; \quad \mathbf{G}_t \equiv \mathbf{G} = 1; \quad \nu_t \sim N[0, V]; \quad \omega_t \sim N[0, W] \quad (34)$$

A formulação matemática para o modelo estacionário (Figura 6) então se resume a:

$$\text{Equação das Observações: } Y_t = \theta_t + \nu_t; \quad \nu_t \sim N[0, V] \quad (35)$$

$$\text{Equação do Sistema: } \theta_t = \theta_{t-1} + \omega_t; \quad \omega_t \sim N[0, W] \quad (36)$$




Figura 6 - um processo com comportamento do modelo estacionário.

3.4.4.

MLD – Modelo de Crescimento Linear (MCL) de HS

No modelo de crescimento linear (MCL), o processo é composto de um nível e de uma inclinação que variam no tempo segundo as equações:

$$\text{Equação das Observações: } Y_t = \mu_t + \varepsilon_t; \quad \varepsilon_t \sim N[0, V_t] \quad (37)$$

$$\mu_t = \mu_{t-1} + \beta_t + \delta_{\mu_t}; \quad \delta_{\mu_t} \sim N[0, V_{\mu}] \quad (38)$$

$$\text{Equações do Sistema: } \beta_t = \beta_{t-1} + \delta_{\beta_t}; \quad \delta_{\beta_t} \sim N[0, V_{\beta}] \quad (39)$$

onde,

μ_t - Nível no instante t .

β_t - Inclinação no instante t .

ε_t - Ruído das observações no instante t .

δ_{μ_t} - Ruído do nível no instante t .

δ_{β_t} - Ruído da inclinação no instante t .

O vetor de estado compreende dois elementos, $\theta_t = [\mu_t \quad \beta_t]'$: o primeiro representa o nível e o segundo a inclinação. Na formulação MLD, pode-se mostrar que:

$$\mathbf{F}_t = \begin{bmatrix} 1 \\ 0 \end{bmatrix}; \quad \mathbf{G}_t \equiv \mathbf{G} = \begin{bmatrix} 1 & 1 \\ 0 & 1 \end{bmatrix}; \quad v_t = \varepsilon_t; \quad \boldsymbol{\omega}_t = \begin{bmatrix} \delta_{\mu_t} + \delta_{\beta_t} \\ \delta_{\beta_t} \end{bmatrix} \quad (40)$$

O modelo estático e o modelo estacionário são casos particulares do modelo de crescimento linear. Se $\beta_t = 0$ e $\delta_{\beta_t} = 0$ para todo t , então fica caracterizado o modelo estacionário anteriormente citado.

Quando $\beta_t = 0$, $\delta_{\beta_t} = 0$, $\delta_{\mu_t} = 0$ e $\mu_t = \mu_{t-1}$ para todo t , então o modelo estático entra em uso.

Farias Neto (1981, p. 47-50) mostra que a matriz de covariância pode ser dada por:

$$\mathbf{W}_t = \begin{bmatrix} V_{\mu} + V_{\beta} & V_{\beta} \\ V_{\beta} & V_{\beta} \end{bmatrix} \quad (41)$$

Existem outros modelos, como o MCL sazonal, mas que não seriam úteis no contexto desse trabalho, ou seja, CEP para dados autocorrelacionados. Maiores detalhes da operacionalização de um modelo bayesiano geral de HS podem ser encontrados em Pole et al. (1994, p. 43 e p.63).

3.4.5.

Fatores de Desconto para \mathbf{W}_t

Ameen e Harrison (1985) introduziram o conceito de *fatores de desconto* com intuito de substituir a matriz de variância \mathbf{W}_t do MCL-HS. Citam que os fatores de desconto proporcionam simplicidade ao modelo.

O fator de desconto controla o grau de “envelhecimento” do conteúdo informativo de uma observação. O uso de fatores de desconto baseia-se na idéia de descontar a informação contida nas observações mais antigas; quanto maior o fator de desconto, menor será a perda de informações com o passar do tempo (o sistema é mais conservador). A recíproca também é verdadeira, quanto menor o fator desconto, menor será a relevância das observações antigas.

Utilizando a notação adotada por Baratojo (1989), β_x denota os fatores de desconto, onde x é a especificação da componente não observável. O valor de β_x é definido entre $0 < \beta_x \leq 1$, sendo que valores próximos de 1 fazem com que o sistema seja menos sensível a novas observações (conservador). Já valores próximos de 0 fazem com que o sistema seja mais sensível. Tabela 2 resume o uso de fatores de desconto.

Tabela 2 - Fatores de Desconto

Fatores de Desconto β_x	Variância do Sistema	Confiança nas Observações Antigas	Sensibilidade do Modelo
Próximos de 1	Pequena	Alta	Baixa
Próximos de 0	Grande	Baixa	Alta

Fonte: adaptado de Baratojo (1989)

Como pode ser visto em Pole et al. (1994, p.52), a matriz \mathbf{W}_t pode ser calculada através da formulação de fatores de desconto como:

$$\mathbf{W}_t = (\beta_x^{-1} - 1) \mathbf{G}_t \mathbf{C}_{t-1} \mathbf{G}'_t \quad (42)$$

$$\mathbf{R}_t = \beta_x^{-1} \mathbf{G}_t \mathbf{C}_{t-1} \mathbf{G}'_t \quad (43)$$

Desta forma, a variância da priori no instante t (R_t) é calculada como função da variância da posteriori (C_{t-1}) no instante $t-1$, de acordo com o fator de desconto β_x .

Em modelos com múltiplos componentes, Pole et al. (1994) recomendam que o procedimento seja feito componente por componente diferentes. Fatores de desconto são especificados para cada componente e a evolução de componentes individuais da matriz de variância é calculada. Então na forma matricial tem-se que:

$$\mathbf{R}_t = \boldsymbol{\beta} \mathbf{G} \mathbf{C}_{t-1} \mathbf{G}' \boldsymbol{\beta} \quad (44)$$

$$\boldsymbol{\beta} = \text{Diag} \left[\left(\frac{1}{\sqrt{\beta_1}} \right) \mathbf{I}_1, \left(\frac{1}{\sqrt{\beta_2}} \right) \mathbf{I}_2, \dots, \left(\frac{1}{\sqrt{\beta_k}} \right) \mathbf{I}_k \right]$$

$\mathbf{I}_i \rightarrow$ Matriz identidade de ordem $n_i \times n_i$.

O uso de $\boldsymbol{\beta}$ acima está associado à possibilidade de se escrever a matriz de transição \mathbf{G} estruturada em blocos, um para cada componente do sistema, ou seja, $\mathbf{G} = \text{Diag}[\mathbf{G}_1, \mathbf{G}_2, \dots, \mathbf{G}_k]$.

Onde $\mathbf{G}_i =$ bloco matricial, de ordem $n_i \times n_i$ correspondente ao i -ésimo componente.

Para exemplificar, seja o modelo com duas componentes, tendência (T) e sazonalidade (S). Definindo β_T e β_S como sendo os fatores de desconto para os respectivos componentes, então:

$$\mathbf{W}_t = \begin{bmatrix} \mathbf{W}_T & 0 \\ 0 & \mathbf{W}_S \end{bmatrix}_t$$

$$\mathbf{W}_t = \begin{bmatrix} (\beta_T^{-1} - 1)\mathbf{G}_T\mathbf{C}_{T,t-1}\mathbf{G}'_T & 0 \\ 0 & (\beta_S^{-1} - 1)\mathbf{G}_S\mathbf{C}_{S,t-1}\mathbf{G}'_S \end{bmatrix}$$

3.4.6.

Algoritmo do MLD com variância V_t Desconhecida

Novamente, utilizando o procedimento descrito por Pole et al. (1994, p. 63) e sua notação, para MLD univariado e variância $V_t = k_t\phi^{-1}$ desconhecida e k_t conhecido, tem-se que:

$$\text{Equação das Observações: } Y_t = \mathbf{F}'_t \boldsymbol{\theta}_t + \nu_t, \quad \nu_t \sim N[0, k_t\phi_t^{-1}] \quad (45)$$

$$\text{Equação do Sistema: } \boldsymbol{\theta}_t = \mathbf{G}_t\boldsymbol{\theta}_{t-1} + \boldsymbol{\omega}_t, \quad \boldsymbol{\omega}_t \sim t_{n_{t-1}}[0, \mathbf{W}_t] \quad (46)$$

Informação:

$$(\boldsymbol{\theta}_{t-1} | D_{t-1}) \sim t_{n_{t-1}}[\mathbf{m}_{t-1}, \mathbf{C}_{t-1}] \rightarrow \text{posteriori no instante } t-1.$$

$$(\boldsymbol{\theta}_t | D_{t-1}) \sim t_{\delta_t n_{t-1}}[\mathbf{a}_t, \mathbf{R}_t] \rightarrow \text{priori no instante } t.$$

$$(\phi_{t-1} | D_{t-1}) \sim G\left[\frac{n_{t-1}}{2}, \frac{d_{t-1}}{2}\right]$$

$$(\phi_t | D_{t-1}) \sim G\left[\frac{\delta_t n_{t-1}}{2}, \frac{\delta_t d_{t-1}}{2}\right]$$

$$\mathbf{a}_t = \mathbf{G}_t \mathbf{m}_{t-1} \quad (47)$$

$$\mathbf{R}_t = \mathbf{G}_t \mathbf{C}_{t-1} \mathbf{G}'_t + \mathbf{W}_t \quad (48)$$

Previsão no instante t :

$$(Y_t | D_{t-1}) \sim t_{\delta_t n_{t-1}}[f_t, Q_t]$$

$$f_t = \mathbf{F}'_t \mathbf{a}_t \quad (49)$$

$$Q_t = \mathbf{F}'_t \mathbf{R}_t \mathbf{F}_t + k_t S_{t-1} \quad (50)$$

Atualização:

$$(\boldsymbol{\theta}_t | D_t) \sim t_{n_t}[\mathbf{m}_t, \mathbf{C}_t] \rightarrow \text{posteriori no instante } t$$

$$(\phi_t | D_t) \sim G\left[\frac{n_t}{2}, \frac{d_t}{2}\right]$$

$$\mathbf{m}_t = \mathbf{a}_t + \mathbf{A}_t e_t \quad (51)$$

$$\mathbf{C}_t = \left(\frac{S_t}{S_{t-1}} \right) \left[\mathbf{R}_t - \mathbf{A}_t \mathbf{A}_t' Q_t \right] \quad (52)$$

$$e_t = Y_t - f_t \quad (53)$$

$$\mathbf{A}_t = \frac{\mathbf{R}_t \mathbf{F}_t}{Q_t} \quad (54)$$

$$n_t = \delta_t n_{t-1} + 1$$

$$d_t = \delta_t d_{t-1} + \frac{S_{t-1} e_t^2}{Q_t}$$

$$S_t = \frac{d_t}{n_t}$$

Previsões na origem t , k passos à frente ($k \geq 1$):

$$(\boldsymbol{\theta}_{t+k} | D_t) \sim t_{\delta_t n_t} [\mathbf{a}_t(k), \mathbf{R}_t(k)]$$

$$(Y_{t+k} | D_t) \sim t_{\delta_t n_t} [f_t(k), Q_t(k)]$$

$$\mathbf{a}_t(k) = \mathbf{G}_{t+k} \mathbf{a}_t(k-1) \quad (55)$$

$$\mathbf{R}_t(k) = \mathbf{G}_{t+k} \mathbf{R}_t(k-1) \mathbf{G}_{t+k}' + \mathbf{W}_{t+k} \quad (56)$$

$$f_t(k) = \mathbf{F}_{t+k}' \mathbf{a}_t(k) \quad (57)$$

$$Q_t(k) = \mathbf{F}_{t+k}' \mathbf{R}_t(k) \mathbf{F}_{t+k} + k_{t+k} S_t \quad (58)$$

$$\mathbf{a}_t(0) = \mathbf{m}_t \quad (59)$$

$$\mathbf{R}_t(0) = \mathbf{C}_t \quad (60)$$

Desta forma, em qualquer instante de tempo o MLD pode ser caracterizado por:

$$M_t = \left\{ \mathbf{F}_t; \mathbf{G}; V_t; \mathbf{W}_t \right\} \quad (61)$$

O vetor M_t é conhecido como vetor de caracterização do sistema. O vetor \mathbf{F}_t é sempre conhecido a priori, assim como a matriz \mathbf{G} também será conhecida. Já os elementos de V_t e \mathbf{W}_t são todos desconhecidos e terão de ser especificados a priori. Para V_t , usualmente considera-se a lei de variância para modelar o aspecto de que a variância do componente irregular tende a variar de

acordo com o nível das séries. No caso da matriz \mathbf{W}_t , faz-se uso de fatores de desconto para caracterizar sua evolução temporal.

Além disso, antes de se iniciar o processo de estimação, também é necessário estipular alguns parâmetros:

- as condições iniciais para os componentes do modelo (m_0) e suas respectivas variâncias (R_0), ou seja, os parâmetros da distribuição a priori inicial;
- os fatores de desconto β_x para cada componente e δ para a lei de variância;
- o expoente da lei de variância i .

quando não se tem informação sobre a distribuição a priori inicial, inicializa-se o filtro adotando-se uma “priori de referência”, fazendo $m_0 = 0$ e $\mathbf{R}_0 = h\mathbf{I}$, onde h é um número grande e \mathbf{I} é a matriz identidade. Isto equivale a supor ignorância total a priori quanto ao vetor de estados θ_t .

3.5. Fator de Bayes

Segundo Pole et al. (1994) e Souza (2003), a ferramenta de avaliação de um MLD é o fator de Bayes, que lida com a razão da verossimilhança preditiva de dois modelos: o corrente e o alternativo.

Sendo:

M : modelo corrente; preditiva $\Rightarrow p(y_t | D_{t-1}; M)$.

M_A : modelo alternativo; preditiva $\Rightarrow p(y_t | D_{t-1}; M_A)$.

Então o fator de Bayes é definido por:

$$H_t = \frac{p(y_t | D_{t-1}; M)}{p(y_t | D_{t-1}; M_A)} \quad (62)$$

Dessa forma, o modelo corrente será adequado quando $H_t \gg 1$. Pole et al. (1994) e Souza (2003) sugerem que:

$H_t \geq 10 \Rightarrow$ indica evidência em favor de modelo corrente.

$H_t \geq 100 \Rightarrow$ indica forte evidência em favor de modelo corrente.

3.5.1. Fator de Bayes Acumulado

O fator de Bayes H_t mede a evidência de um dado modelo em uma única observação no tempo t com relação a outro modelo. Observar uma seqüência de observações é uma outra forma de avaliar o desempenho da previsão segundo Pole et al. (1994). O fator de Bayes acumulado para uma seqüência de observações $Y_t, Y_{t-1}, \dots, Y_{t-k+1}$ é definido como:

$$H_t(k) = \prod_{i=0}^{k-1} H_{t-i} \quad (63)$$

$$H_t(k) = H_t \cdot H_{t-1}(k-1)$$

Souza (2003) afirma que o fator de Bayes acumulado pode ser utilizado para detectar, rapidamente, variações no comportamento do processo provocadas por descontinuidades dos tipos transientes ou mudanças estruturais.

3.5.2. Algoritmo para identificação de Descontinuidades

Passo 1 – Calcular seqüencialmente as quantidades L_t e l_t :

$$L_t = H_t \cdot \min(1, L_{t-1})$$

$$l_t = \begin{cases} 1 + l_{t-1} & \Rightarrow L_{t-1} < 1 \\ 1 & \Rightarrow L_{t-1} \geq 1 \end{cases}$$

l_t é conhecido como comprimento da descontinuidade e L_t como fator de Bayes acumulado. Para efeito de inicialização, Pole et al. (1994) sugerem utilizar $L_0 = 1$ e $l_0 = 1$.

Passo 2 – Regra de decisão

Baratojo (1989) e Souza (2003) afirmam que se $L_t \geq \tau$, onde τ é um real positivo pré-estabelecido, o sistema será considerado em controle, ou seja, não é observada descontinuidade no instante t . Caso se $L_t < \tau$ no instante t , então:

- (i) $l_t = 1 \rightarrow$ a descontinuidade detectada em t é do tipo transiente.
- (ii) $l_t > 1 \rightarrow$ a descontinuidade detectada em t é do tipo mudança estrutural e ocorreu provavelmente a partir de $t - l_t + 1$.