

3.4. Movimento Browniano Generalizado - Processo de Ito

Ao descrevermos o movimento Browniano nos itens anteriores, estabelecemos que os parâmetros *drift* e variância seriam constantes. Mas, se esses parâmetros não fossem constantes, e variassem, por exemplo, com o tempo. Qual processo que a equação estocástica seguiria? Como ficaria a média e variância deste processo? Ainda seria um processo de Markov? Tentaremos responder essas questões agora.

A generalização do Movimento Browniano, conhecida como Processo de Ito, é dada pela seguinte equação

$$dx = a(x,t)dt + b(x,t)dz \quad \text{Equação 11}$$

onde novamente dz é um incremento do Processo de *Wiener* e $a(x,t)$ e $b(x,t)$ são funções (não aleatórias) conhecidas. As variáveis \underline{a} e \underline{b} são também conhecidas como parâmetros *drift* e variância, mas agora são funções do tempo e do estado atuais.

Do mesmo modo que fizemos para o Processo de *Markov*, o Processo de *Wiener* e o Processo de *Wiener* Generalizado, iremos calcular a média

$$E(dx) = E[a(x,t)dt + b(x,t)dz]$$

$$E(dx) = a(x,t)dt + b(x,t)E(dz)$$

$$E(dx) = a(x,t)dt$$

e Variância

$$Var(dx) = E\{[dx - E(dx)]^2\}$$

$$Var(dx) = E[(dx)^2] - [E(dx)]^2$$

$$Var(dx) = E\{[a(x,t)dt + b(x,t)dz]^2\} - [a(x,t)dt]^2$$

$$Var(dx) = E\{[a(x,t)dt]^2 + 2a(x,t)b(x,t)dtdz + [b(x,t)dz]^2\} - [a(x,t)dt]^2$$

$$Var(dx) = 2a(x,t)b(x,t)dtE(dz) + E\{[b(x,t)dz]^2\}$$

$$Var(dx) = [b(x,t)]^2 E(\varepsilon^2)dt$$

$$Var(dx) = [b(x,t)]^2 dt$$

Os parâmetros $a(x,t)$ e $b(x,t)$ são conhecidos como taxa de crescimento esperado instantâneo e taxa de variância instantânea, respectivamente, do Processo de Ito.

3.4.1. Movimento Geométrico Browniano

Movimento Geométrico Browniano (MGB) é um caso particular do Processo de Ito. Geralmente é o processo utilizado para modelar preço de ações, taxas de juros, preços de produtos e outras variáveis financeira e econômicas. A restrição que existe ao uso do Movimento Geométrico Browniano, é o fato de que este processo pode divergir levando $x(t)$ para o infinito, e assim alguns modelos que seguem o MGB podem não ser muito realistas.

No MGB os parâmetros *drift* e variância são dados por

$$\begin{aligned}a(x, t) &= \alpha x \\ b(x, t) &= \sigma x\end{aligned}$$

Se substituirmos esses valores na equação do Processo de Ito, teremos

$$dx = \alpha x dt + \sigma x dz \quad \text{Equação 12}$$

No caso anterior do Movimento Aritmético Browniano (MAB), onde $dx = \alpha dt + \sigma dz$, vimos que dx tinha uma distribuição Normal, com parâmetros $N \approx (\alpha, \sigma)$. Agora, no caso do MGB, qual seria a distribuição de dx ? Observe que se dividirmos o MGB por x , transformamos o processo num MAB:

$$\begin{aligned}dx &= \alpha x dt + \sigma x dz \\ \frac{dx}{x} &= \alpha dt + \sigma dz \\ \frac{\Delta x}{x} &= \alpha \Delta t + \sigma \Delta z\end{aligned}$$

Assim, as variações proporcionais de x , $(\Delta x / x)$, tem uma distribuição normal, pois $\Delta x / x$ segue uma MAB. Mas podemos ver que:

$$\frac{d}{dx}(\ln x) = \frac{1}{x} dx = \frac{dx}{x}$$

$\Delta x / x$ é o incremento no log de x e tem distribuição normal pois o seu processo é um MAB, portanto, podemos concluir que se $\log x$ tem distribuição normal, x terá uma distribuição lognormal.

Qual será a média e variância de uma variável $x(t)$ que segue um processo MGB? Sabemos que $x(t)$ tem uma distribuição lognormal, então podemos dizer que $F(x) = \ln x$ terá uma distribuição normal.

Seja uma função F de uma variável aleatória $x(t)$, $F(x)$, dada por $F(x) = \ln x$, onde $x(t)$ tem distribuição log-normal. Para uma função de duas variáveis, por Taylor temos:

$$dF = \frac{\partial F}{\partial t} dt + \frac{\partial F}{\partial x} dx + \frac{1}{2} \frac{\partial^2 F}{\partial x^2} (dx)^2$$

onde os termos com expoente igual ou maior que dois em t são desprezados, assim como os expoentes maior que dois em dx .

$$\frac{\partial F}{\partial x} = \frac{1}{x} \quad \frac{\partial^2 F}{\partial x^2} = -\frac{1}{x^2} \quad \frac{\partial F}{\partial t} = 0$$

$$dF = \frac{1}{x} dx - \frac{1}{2} \frac{1}{x^2} (dx)^2$$

$$dF = \frac{1}{x} (\alpha x dt + \sigma x dz) - \frac{1}{2x^2} (\alpha x dt + \sigma x dz)^2$$

$$dF = \alpha dt + \sigma dz - \frac{1}{2x^2} (\underbrace{\alpha^2 x^2 dt^2}_0 + 2\alpha \sigma \underbrace{dt dz}_0 + \sigma^2 x^2 \underbrace{dz^2}_1)$$

$$dF = \alpha dt + \sigma dz - \frac{1}{2} \sigma^2 dt$$

$$dF = (\alpha - \frac{1}{2} \sigma^2) dt + \sigma dz$$

Nota:

$$(dz)^2 = (\varepsilon \sqrt{dt})^2 = \varepsilon^2 dt$$

$$Var(\varepsilon) = E(\varepsilon^2) - \underbrace{E^2(\varepsilon)}_0 = E(\varepsilon^2) = 1 \quad \text{pois} \quad \varepsilon \approx N(0,1)$$

$$E(\varepsilon^2 dt) = dt E(\varepsilon^2) = dt$$

$$Var(\varepsilon^2 dt) = \underbrace{dt^2}_0 Var(\varepsilon^2) = 0$$

Se $Var(dz)^2 = 0$, temos $dz^2 \approx N(dt, 0)$. Vemos então que dz^2 é determinístico e o seu valor é igual ao seu valor esperado $E(dz)^2 = dt$

Então temos:

$$dF = (\alpha - \frac{\sigma^2}{2}) dt + \sigma dz \quad \text{ou} \quad dF \sim N[(\alpha - \frac{\sigma^2}{2}) dt, \sigma^2 dt]$$

Considerando um intervalo de tempo $(0, T)$, fazendo $x(T) = x_T$, $x(0) = x_0$ e substituindo o valor de $F(x)$, encontraremos

$$F(x_T) - F(x_0) \sim N[(\alpha - \frac{\sigma^2}{2}) T, \sigma^2 T]$$

$$F(x_T) \sim N[F(x_0) + (\alpha - \frac{\sigma^2}{2}) T, \sigma^2 T]$$

mas $F(x_t) = \ln x$, então

$$\ln x_t \sim N[\underbrace{\ln x_0 + (\alpha - \frac{\sigma^2}{2})T}_u, \underbrace{\sigma^2 T}_{v^2}] \sim N[u, v^2]$$

Fazendo as substituições de variáveis, teremos

$$u = \ln x_0 + (\alpha - \frac{\sigma^2}{2})T$$

$$v^2 = \sigma^2 T$$

$$Y = \ln x_T \Leftrightarrow x_T = e^Y$$

teremos

$$Y = \ln x_T \sim N(u, v^2)$$

cuja função densidade de probabilidade é dada por

$$f(Y) = \frac{1}{\sqrt{2\pi v^2}} e^{-\frac{1}{2} \left(\frac{Y-u}{v} \right)^2}$$

Note que queremos achar $E(x_T)$ e $Var(x_T)$. Como sabemos que:

$$E(x_T) = E(e^Y)$$

$$Var(x_T) = Var(e^Y) = E(e^{2Y}) - E^2(e^Y)$$

basta então acharmos estes parâmetros de e^Y .

Utilizando o conceito de *função geradora de momentos*, podemos achar o valor esperado e variância de $F(x)$, que é uma função da variável aleatória x_T .

$$M_Y(k) = E(e^{kY}) = \int_{-\infty}^{+\infty} e^{kY} f(Y) dY$$

substituindo o valor de $f(Y)$, teremos:

$$E(e^{kY}) = \int_{-\infty}^{+\infty} e^{kY} \left[\frac{1}{\sqrt{2\pi v^2}} e^{-\frac{(Y-u)^2}{2v^2}} \right] dY$$

$$E(e^{kY}) = \int_{-\infty}^{+\infty} \frac{1}{\sqrt{2\pi v^2}} e^{kY - \frac{(Y-u)^2}{2v^2}} dY$$

$$E(e^{kY}) = \int_{-\infty}^{+\infty} \frac{1}{\sqrt{2\pi v^2}} e^{\frac{2v^2 kY - (Y-u)^2}{2v^2}} dY$$

Agora, iremos completar o quadrado do numerador do expoente, $2v^2kY - (Y - u)^2$. O nosso Objetivo aqui é separar o expoente de e para que fique na forma $e^Y \cdot e^w$.

$$\begin{aligned}
 2v^2kY - (Y - u)^2 &= 2v^2kY - (Y - u)^2 + (v^4k^2 - v^4k^2) + (2v^2ku - 2v^2ku) \\
 &= -v^4k^2 + 2v^2kY - 2v^2ku - (Y - u)^2 + v^4k^2 + 2v^2ku \\
 &= -[v^4k^2 - 2v^2k(Y - u) + (Y - u)^2] + v^4k^2 + 2v^2ku \\
 &= -[v^2k - (Y - u)]^2 + v^4k^2 + 2v^2ku \\
 &= -[Y - (u + v^2k)]^2 + v^4k^2 + 2v^2ku
 \end{aligned}$$

Voltando para a expressão de $E(e^{kY})$ com a igualdade anterior, teremos

$$\begin{aligned}
 E(e^{kY}) &= \int_{-\infty}^{+\infty} \frac{1}{\sqrt{2\pi v^2}} e^{-\frac{[Y - (u + v^2k)]^2}{2v^2}} e^{\frac{v^4k^2 + 2v^2ku}{2v^2}} dY \\
 E(e^{kY}) &= e^{uk + \frac{v^2k^2}{2}} \int_{-\infty}^{+\infty} \frac{1}{\sqrt{2\pi v^2}} e^{-\frac{[Y - (u + v^2k)]^2}{2v^2}} dY
 \end{aligned}$$

Agora, considere a seguinte troca de variáveis

$$w = \frac{Y - (u + v^2k)}{v}$$

Derivando esta expressão em relação a Y , encontraremos:

$$\frac{dw}{dY} = \frac{1}{v} \Rightarrow dY = vdw$$

Substituindo ambos os valores na expressão de $E(e^{kY})$, teremos uma nova expressão, mas agora com a integral bastante familiar.

$$\begin{aligned}
 E(e^{kY}) &= e^{uk + \frac{v^2k^2}{2}} \int_{-\infty}^{+\infty} \frac{1}{\sqrt{2\pi v^2}} e^{-\frac{w^2}{2}} (v dw) \\
 E(e^{kY}) &= e^{uk + \frac{v^2k^2}{2}} \underbrace{\int_{-\infty}^{+\infty} \frac{1}{\sqrt{2\pi}} e^{-\frac{w^2}{2}} dw}_1
 \end{aligned}$$

o integrando nada mais é do que a função densidade de probabilidade para uma variável com distribuição normal padronizada, ou seja com média zero e variância 1. Ao resolvermos esta integral encontraremos o valor 1 que é a área abaixo da curva de densidade de probabilidades. Assim encontramos a seguinte expressão para $E(e^{kY})$:

$$E(e^{kY}) = e^{uk + \frac{v^2k^2}{2}}$$

Voltando com os valores de Y , u e v definidos anteriormente e fazendo $k=1$ teremos finalmente

$$E(e^{\ln x_T}) = e^{\ln x_0 + (\alpha - \frac{\sigma^2}{2})T + \frac{\sigma^2 T}{2}}$$

$$E(x_T) = e^{\ln x_0} e^{\alpha T - \frac{\sigma^2}{2}T + \frac{\sigma^2 T}{2}}$$

$$\boxed{E(x_T) = x_0 e^{\alpha T}}$$

O cálculo da variância é mais simples. Considere a definição de variância:

$$Var(e^Y) = E[(e^Y)^2] - [E(e^Y)]^2$$

$$Var(e^Y) = E[e^{2Y}] - x_0^2 e^{2\alpha T}$$

para continuarmos, devemos calcular o valor de $E(e^{2Y})$, que é imediato, pois basta substituir k por 2 na equação encontrada na demonstração anterior.

$$E(e^{kY}) = e^{uk + \frac{v^2 k^2}{2}}$$

$$E(e^{2Y}) = e^{2(u+v^2)}$$

Voltando para a expressão da variância teremos:

$$Var(e^Y) = e^{2(u+v)} - x_0^2 e^{2\alpha T}$$

substituindo os valores de u e v encontraremos:

$$Var(e^{\ln x_T}) = e^{2\ln x_0 + 2\alpha T + \sigma^2 T} - x_0^2 e^{2\alpha T}$$

$$\boxed{Var(x_T) = x_0^2 e^{2\alpha T} (e^{\sigma^2 T} - 1)}$$

Agora, calcularemos o valor esperado de $x(t)$, dado que $x(0)=x_0$ e considerando $\sigma=0$. Esta última suposição nos diz que x é totalmente determinístico e podemos prever valores futuros de x com certeza. Para isso devemos resolver a seguinte equação diferencial ordinária:

$$dx = \alpha x dt + \sigma x dz$$

$$dx = \alpha x dt$$

$$\frac{dx}{x} = \alpha dt$$

$$dt = \frac{1}{\alpha} \cdot \frac{dx}{x}$$

Aplicando integral em ambos os lados da equação teremos

$$\begin{aligned}\int_0^t du &= \int_{x_0}^x \frac{1}{\alpha} \cdot \frac{dk}{k} \\ t - 0 &= \frac{1}{\alpha} \ln(k) \Big|_{x_0}^x \\ \alpha t &= \ln(x) - \ln(x_0) \\ \ln(x) &= \ln(x_0) + \ln(e^{\alpha t}) \\ \ln(x) &= \ln(x_0 e^{\alpha t}) \\ x(t) &= x_0 e^{\alpha t}\end{aligned}$$

Assim, $E(x_t) = x_0 e^{\alpha t}$. Note que o valor esperado de x_T para o caso determinístico é o mesmo que o valor esperado para o caso aleatório. E, obviamente, a variância não será a mesma para ambos os casos.

O valor esperado e a variância de $x(t)$ poderão ser utilizados para calcular o valor presente descontado esperado de $x(t)$ sobre algum período de tempo. Como exemplo, temos:

$$E\left[\int_0^{\infty} x(t) e^{-rt} dt\right] = \int_0^{\infty} x_0 e^{-(r-\alpha)t} dt = \frac{x_0}{r-\alpha} \quad \text{Equação 14}$$

Esta fórmula será útil mais tarde quando necessitarmos calcular o valor presente descontado de fluxo de lucro que segue um Movimento Geométrico Browniano.

Do mesmo modo que fizemos com o Movimento Browniano, iremos agora dar alguns exemplos de MGB. Utilizaremos parâmetros compatíveis com os parâmetros do NYSE, para exemplificar.

$$\begin{aligned}\alpha = \text{Drift Rate} &= 9\% \text{ a.a.} \\ \sigma = \text{Variância} &= 20\% \text{ a.a.}\end{aligned}$$

Com a equação 15 a seguir, foi montado o gráfico 3.3 que mostra 3 caminhos possíveis calculados com intervalo de tempo Δt igual a 1 mês. A equação do MGB fica:

$$\begin{aligned}\Delta x &= \alpha x \Delta t + \sigma x \Delta z \\ x_t - x_{t-1} &= \alpha x_{t-1} \Delta t + \sigma x_{t-1} \varepsilon_t \sqrt{\Delta t} \\ x_t &= x_{t-1} + 0.09 x_{t-1} \Delta t + 0.20 x_{t-1} \varepsilon_t \sqrt{\Delta t}\end{aligned}$$

Como os dados disponíveis estão em períodos de um mês, ao invés de um ano, dividimos o Δt original, que é de um ano, por 12.

$$\begin{aligned}\alpha \Delta t &= 0.09 (1/12) = 0.007500 \\ \sigma \Delta t &= 0.20 (\sqrt{1/12}) = 0.057735\end{aligned}$$

$$x_t = x_{t-1} + 0.09x_{t-1}\Delta t + 0.20x_{t-1}\varepsilon_t\sqrt{\Delta t}$$

$$x_t = x_{t-1} + 0.09x_{t-1}\frac{1}{12} + 0.20x_{t-1}\varepsilon_t\sqrt{\frac{1}{12}}$$


$$x_t = x_{t-1} + 0.0075x_{t-1} + 0,057735x_{t-1}\varepsilon_t$$

$$x_t = 1.0075x_{t-1} + 0,057735x_{t-1}\varepsilon_t$$


Equação 15

Começaremos o caminho em 1950 e $x_{1950} = 100$ e calcularemos também teremos a linha de tendência, obtida quando $\varepsilon_t = 0$, isto é, a parte determinística do processo:

$$x_t = 1.0075x_{t-1}$$



O gráfico 3.5 mostra a previsão ótima para este processo. Como anteriormente, um caminho será gerado de 1950 até 1974 e então as previsões para $x(t)$ serão feitas até 2000. Como o MGB é um Processo de *Markov*, então ele segue a propriedade de *Markov* que diz que somente o valor atual de $x(t)$ é necessário para realizar as previsões para o futuro.



Para criar o modelo de previsão, utilizamos a equação para o valor esperado de $x(t)$ demonstrada anteriormente:

$$E(x_t) = x_0 e^{\alpha t}$$

$$E(x_{1974+T}) = x_{1974} e^{\alpha T}$$

como α é um parâmetro dado por unidade de tempo anual e T está em unidade de tempo mensal, então para compatibilizar as unidades devemos fazer:

$$E(x_{1974+T}) = x_{1974} e^{\frac{\alpha}{12} T}$$

como $\alpha=0.09$ ao ano, então $\alpha=0.09/12=0.0075$ ao mês. Logo, a equação para o valor esperado de $x(t)$ a partir de janeiro de 1975 é dado por:

$$E(x_{1974+T}) = x_{1974} e^{0.0075T}$$

$$E(x_{1974+T}) = x_{1974} (e^{0.0075})^T$$

$$E(x_{1974+T}) = x_{1974} (1.007528)^T$$

Podemos também fazer nossas previsões utilizando um intervalo de confiança. Supondo um intervalo de confiança de 66%, então o limite superior e inferior do intervalo de confiança é dado por

$$x_{1974} e^{\alpha t} \pm \tau_{66\%} \sqrt{x_{1974}^2 e^{2\alpha t} (e^{\sigma^2 t} - 1)}$$

$$x_{1974} e^{\alpha t} (1 \pm \tau_{66\%} \sqrt{e^{\sigma^2 t} - 1})$$

usando a seguinte igualdade

$$e^x = 1 + x + \frac{x^2}{2!} + \frac{x^3}{3!} + \dots$$

e fazendo $x = \sigma^2 t$, ficamos com:

$$e^{\sigma^2 t} = 1 + \sigma^2 t + \frac{\sigma^4 t^2}{2!} + \frac{\sigma^6 t^3}{3!} + \dots$$

Considerando que $\sigma < 1$ e t é pequeno, podemos ignorar os termos de ordem superior, ficando com uma expressão aproximada:

$$e^{\sigma^2 t} = 1 + \sigma^2 t$$

$$e^{\sigma^2 t} - 1 = \sigma^2 t$$

E assim encontramos

$$x_{1974} e^{\alpha t} (1 \pm \tau_{66\%} \sqrt{\sigma^2 t})$$

$$x_{1974} e^{\alpha t} (1 \pm \tau_{66\%} \sigma \sqrt{t})$$

usando novamente a identidade para e^x encontraremos

$$x_{1974} e^{\alpha t} e^{\pm \tau_{66\%} \sigma \sqrt{t}}$$

Substituindo os valores de α , σ e considerando $\tau_{66\%}=1$, encontraremos os limites inferiores e superiores:

$$x_{1974} (1.007528)^T (1.0594)^{\pm \sqrt{T}}$$

3.4.2. Processo de Reversão para a Média

Como visto nas figuras do Movimento Geométrico Browniano, este processo tende a divergir para longe do seu ponto de partida original. Em alguns casos, esta é uma característica desejada, como em preços de ativos especulativos, mas em outros não. Preços de commodities como o cobre ou o óleo tendem a estar relacionado com o custo marginal de produção de longo prazo. Isto significa que no curto prazo o preço do petróleo, por exemplo, pode subir ou descer aleatoriamente, mas no longo prazo ele tende a voltar para o custo marginal de produção. Logo o preço do petróleo ou do cobre devem seguir o *processo de reversão para a média*.

A Equação Diferencial Estocástica que define este processo, também conhecida com processo de Ornstein-Uhlenbeck, é dada por:

$$dx = \eta(\bar{x} - x)dt + \sigma dz \quad \text{Equação 16}$$

onde dz é um incremento de *Wiener*, η é a velocidade da reversão e \bar{x} é o nível normal de x (o nível para o qual x tende a reverter). O processo de reversão para a média é um Processo de Markov, mas não possui incrementos independentes. Isto fica claro ao notarmos que a variação esperada em x depende da diferença entre x e \bar{x} . Assim, se x é maior (menor) do que \bar{x} , então é mais provável uma queda (subida) no próximo intervalo curto de tempo.

Do mesmo modo como foi feito para o outros processos, iremos calcular a média e a variância de dx .

Cálculo da Média e Variância:

Definimos uma variável $w = f(x, t)$:

$$w = (x - \bar{x}) e^{\eta(t-t_0)}$$

Calculando o incremento dw :

$$dw = \frac{\partial w}{\partial x} dx + \frac{\partial w}{\partial t} dt + \frac{1}{2} \frac{\partial^2 w}{\partial x^2} dx^2 + ..$$

$$\text{Mas:} \quad \frac{\partial w}{\partial x} = e^{\eta(t-t_0)} \quad \frac{\partial w}{\partial t} = (x - \bar{x})e^{\eta(t-t_0)} \cdot \eta \quad \frac{\partial^2 w}{\partial x^2} = 0$$

$$\begin{aligned} \text{Então:} \quad dw &= e^{\eta(t-t_0)} \cdot (\eta(\bar{x} - x)dt + \sigma dz) + (x - \bar{x})e^{\eta(t-t_0)} \cdot \eta \cdot dt \\ dw &= e^{\eta(t-t_0)} \cdot \eta(\bar{x} - x)dt + e^{\eta(t-t_0)} \cdot \sigma dz + (x - \bar{x})e^{\eta(t-t_0)} \cdot \eta \cdot dt \end{aligned}$$

$$\boxed{dw = e^{\eta(t-t_0)} \cdot \sigma dz}$$

Sabemos que dw tem distribuição Normal, pois o termo estocástico é função apenas de dz .

$$\begin{aligned} dw &\sim N(0, e^{2\eta(t-t_0)} \cdot \sigma^2 dt) \\ w_t - w_0 &\sim N(0, e^{2\eta(t-t_0)} \cdot \sigma^2 dt) \\ w_t &\sim N(w_0, e^{2\eta(t-t_0)} \cdot \sigma^2 dt) \end{aligned}$$

$$\begin{aligned} E(dw) &= 0 \\ E(w_t) &= w_0 = (x_0 - \bar{x}) e^{\eta(t_0-t_0)} \\ E(w_t) &= (x_0 - \bar{x}) \end{aligned}$$

Média: Para calcularmos $E(x_t)$ precisamos achar a relação entre x_t e w_t .

$$\begin{aligned} w_t &= (x_t - \bar{x}) e^{\eta(t-t_0)} \\ \ln w_t &= \ln[(x_t - \bar{x}) e^{\eta(t-t_0)}] \\ \ln w_t &= \ln(x_t - \bar{x}) + \ln(e^{\eta(t-t_0)}) \\ \ln w_t &= \ln(x_t - \bar{x}) + \eta(t - t_0) \\ \ln(x_t - \bar{x}) &= \ln w_t - \eta(t - t_0) \\ x_t - \bar{x} &= e^{\ln w_t - \eta(t-t_0)} \end{aligned}$$

$$\boxed{x_t = \bar{x} - w_t \cdot e^{-\eta(t-t_0)}}$$

Calculando agora $E(x)$:

$$\begin{aligned} E(x_t) &= E[\bar{x} - w_t \cdot e^{-\eta(t-t_0)}] \\ E(x_t) &= \bar{x} - E[w_t] e^{-\eta(t-t_0)} \\ E(x_t) &= \bar{x} - w_0 \cdot e^{-\eta(t-t_0)} \end{aligned}$$

$$\boxed{E(x_t) = \bar{x} - (x_0 - \bar{x}) \cdot e^{-\eta(t-t_0)}}$$

Equação 17

Variância:

$$Var(w_t) = Var(w_t - w_0)$$

$$Var(w_t) = Var(w_t - w_{t-\Delta t} + w_{t-\Delta t} - w_{t-2\Delta t} + \dots + w_{t-(N-1)\Delta t} - w_0)$$

$$Var(w_t) = Var(w_t - w_{t-\Delta t}) + Var(w_{t-\Delta t} - w_{t-2\Delta t}) + \dots + Var(w_{t-(N-1)\Delta t} - w_0)$$

$$Var(w_t) = \sum_1^N Var(\Delta w_t) = \int_{t_0}^t Var(dw_t)$$

Mas:

$$Var(dw) = Var(e^{\eta(t-t_0)} \cdot \sigma dz) = e^{2\eta(t-t_0)} \cdot \sigma^2 \underbrace{Var(dz)}_{dt}$$

$$Var(dw) = e^{2\eta(t-t_0)} \cdot \sigma^2 dt$$

Substituindo

$$Var(w_t) = \int_{t_0}^t e^{2\eta(t-t_0)} \cdot \sigma^2 dt = \frac{\sigma^2 e^{2\eta(t-t_0)} - \sigma^2}{2\eta} \Big|_{t_0}^t$$

$$Var(w_t) = \frac{\sigma^2 (e^{2\eta(t-t_0)} - 1)}{2\eta}$$

Queremos Var (x_t)

$$Var(x_t) = Var(\bar{x} - w_t \cdot e^{-\eta(t-t_0)})$$

$$Var(x_t) = e^{-2\eta(t-t_0)} Var(w_t)$$

Substituindo Var (w_t)

$$Var(x_t) = e^{-2\eta(t-t_0)} \cdot \frac{\sigma^2 (e^{2\eta(t-t_0)} - 1)}{2\eta}$$

$$Var(x_t) = \frac{\sigma^2 e^{-2\eta(t-t_0)} (e^{2\eta(t-t_0)} - 1)}{2\eta}$$

$$\boxed{Var(x_t) = \frac{\sigma^2}{2\eta} (1 - e^{-2\eta(t-t_0)})}$$

Equação 18

Quando $t \rightarrow \infty$, o valor esperado tende para:

$$\begin{aligned}\lim_{T \rightarrow \infty} E(x_T) &= \lim_{T \rightarrow \infty} [\bar{x} + (x_0 - \bar{x}) \frac{1}{e^{\eta T}}] \\ &= \bar{x} + (x_0 - \bar{x}) \lim_{T \rightarrow \infty} [\frac{1}{e^{\eta T}}]\end{aligned}$$

quando $T \rightarrow \infty$, $e^{\eta T} \rightarrow \infty$ e $(x_0 - \bar{x}) \frac{1}{e^{\eta T}} \rightarrow 0$. Assim teremos

$$\lim_{T \rightarrow \infty} E(x_T) = \bar{x}$$

Do mesmo modo, quando $t \rightarrow \infty$, a variância tende para

$$\lim_{T \rightarrow \infty} Var(x_T) = \lim_{T \rightarrow \infty} [\frac{\sigma^2}{2\eta} (1 - e^{-2\eta T})]$$

$$\lim_{T \rightarrow \infty} Var(x_T) = \frac{\sigma^2}{2\eta} \lim_{T \rightarrow \infty} [(1 - e^{-2\eta T})]$$

$$\lim_{T \rightarrow \infty} Var(x_T) = \frac{\sigma^2}{2\eta}$$

Quando $\eta \rightarrow \infty$, encontraremos:

$$\lim_{\eta \rightarrow \infty} E(x_T) = \lim_{\eta \rightarrow \infty} [\bar{x} + (x_0 - \bar{x}) e^{-\eta T}]$$

$$\lim_{\eta \rightarrow \infty} E(x_T) = \bar{x} + (x_0 - \bar{x}) \underbrace{\lim_{\eta \rightarrow \infty} e^{-\eta T}}_0$$

$$\lim_{\eta \rightarrow \infty} E(x_T) = \bar{x}$$

e para a variância

$$\lim_{\eta \rightarrow \infty} Var(x_T) = \lim_{\eta \rightarrow \infty} (\frac{\sigma^2}{2\eta}) \lim_{\eta \rightarrow \infty} (1 - e^{-2\eta T})$$

$$\lim_{\eta \rightarrow \infty} Var(x_T) = 0 \cdot (1 - 0) = 0$$

Estes valores nos indicam que, mesmo momentaneamente, x não pode desviar-se de \bar{x} .

Agora vamos analisar como a variância se comporta quando $\eta \rightarrow 0$.

$$\lim_{\eta \rightarrow 0} Var(x_T) = \lim_{\eta \rightarrow 0} [\frac{\sigma^2}{2\eta} (1 - e^{-2\eta T})]$$

Analisando primeiro a parcela do exponencial, e lembrando que

$$e^x = 1 + x + \frac{x^2}{2!} + \frac{x^3}{3!} + \dots$$

Como $x \rightarrow 0$, então as potência de x acima de 1 terão impacto insignificante no valor final da expressão. Assim, podemos simplificar a expressão para:

$$e^x = 1 + x$$

como estamos considerando $x = -2\eta T$, então

$$e^{-2\eta T} = 1 - 2\eta T$$

$$2\eta T = 1 - e^{-2\eta T}$$

substituindo esses valores na equação de $\text{Var}(x_T)$, teremos finalmente


$$\lim_{\eta \rightarrow 0} \text{Var}(x_T) = \lim_{\eta \rightarrow 0} \left[\frac{\sigma^2}{2\eta} (2\eta T) \right]$$

$$\lim_{\eta \rightarrow 0} \text{Var}(x_T) = \lim_{\eta \rightarrow 0} [\sigma^2 (T)]$$

$$\lim_{\eta \rightarrow 0} \text{Var}(x_T) = \sigma^2 T$$

Assim, podemos concluir que quando $\eta \rightarrow 0$, o Processo de Reversão à Média tende para o Movimento Browniano Simples. Uma outra maneira de verificar esta conclusão é substituir η por zero na equação do Processo de Reversão para a Média, com isso teremos a equação do Movimento Browniano.

Uma outra característica interessante do processo de reversão para a média é o parâmetro η . Este parâmetro indica a velocidade com que o processo tende a voltar para o valor médio. Normalmente, o processo de reversão para a média pode tomar um caminho que se desvie da média de longo prazo. Como vimos no parágrafo anterior este desvio tende a ser revertido em determinado momento, e o processo volta para a sua média de longo prazo. Esta volta pode ser demorada ou mais rápida dependendo de η . Quanto menor η mais demorada será o caminho de volta. Esta característica torna-se clara ao analisarmos o gráfico a seguir. Neste gráfico, plotamos 3 curvas que representam os processos de reversão para a média com três valores de η diferentes, 0, 0.01 e 0.5. Foram usados os valores de $\sigma = 0,05$ a.m., $\bar{x} = 1$ e $x_0 = 1$.



Para criar o modelo de previsão, utilizamos a equação para o valor esperado de $x(t)$ demonstrada anteriormente (Equação 17), considerando um $\eta = 0,02$:

$$E(x_T) = \bar{x} + (x_0 - \bar{x})e^{-\eta T}$$

$$E(x_{1980+T}) = \bar{x} + (x_{1980} - \bar{x})e^{-\eta T}$$

Como η é um parâmetro mensal, assim como T , nenhum ajuste mais é necessário. Dado que $\bar{x} = 1$, e $\eta = 0,02$, ficamos com:

$$E(x_{1980+T}) = 1 + (x_{1980} - 1)e^{-0,02T}$$

Para calcularmos um intervalo de confiança de 66%, o limite superior e inferior do intervalo de confiança será dado por:


$$E(x) \pm z_{66\%} \cdot \sigma$$

Assim: $1 + (x_{1980} - 1)e^{-\eta T} \pm z_{66\%} \cdot \sigma \cdot \sqrt{\frac{1 - e^{-2\eta T}}{2\eta}}$

Substituindo os valores de $z = 0,9557$, $\sigma = 0,05$ e $\eta = 0,02$, encontramos os limites inferiores e superiores:

$$1 + (x_{1980} - 1)e^{-0,02T} \pm 0,04779 \cdot \sqrt{\frac{1 - e^{-0,04T}}{0,04}}$$

O gráfico com a previsão e o correspondente intervalo de confiança está a seguir:



A equação 16 é a versão de tempo contínuo do processo autoregressivo de primeira ordem (AR). Especificamente, a equação 16 é o caso aonde $\Delta t \Rightarrow 0$ do seguinte processo Auto-Regressive (AR):

$$x_t - x_{t-1} = \underline{x} (1 - e^{-\eta}) + (e^{-\eta} - 1)x_{t-1} + \epsilon_t \quad \text{Equação 19}$$

aonde ϵ_t é normalmente distribuída com média zero e desvio padrão σ_ϵ dada por:

$$\sigma_\epsilon^2 = (\sigma^2 / 2\eta) (1 - e^{-2\eta})$$

Então podemos estimar os parâmetros da equação 16, $(dx = \eta (\underline{x} - x) dt + \sigma dz)$, usando informações de tempo discreto (que são as únicas informações disponíveis) pela regressão:

$$x_t - x_{t-1} = a + bx_{t-1} + \epsilon_t$$

E então calculando $\underline{x} = -a/b$, $\eta = -\log. (1 + b)$, e

$$\sigma = \sigma_\epsilon \sqrt{\frac{\ln(1+b)}{(1+b)^2 - 1}}$$

Aonde σ_ϵ é o erro padrão da regressão.

É fácil generalizar a equação 16. Por exemplo, espera-se que $x(t)$ reverta para a média \underline{x} , mas com a taxa da variância crescendo com x . Assim pode-se usar o seguinte processo:

$$dx = \eta (\underline{x} - x) dt + \sigma x dz \quad \text{Equação 20}$$

Alternativamente, mudanças proporcionais na variável pode ser modelada como um simples processo de reversão para a média. Isto é equivalente a descrever $x(t)$ pelo processo:

$$dx = \eta x (\underline{x} - x) dt + \sigma x dz \quad \text{Equação 21}$$

Vamos examinar as implicações destes diferentes processos de reversão para a média para decisões de investimentos mais adiante.