

## EDEs regressivas e a conexão com EDPs

# Gerador de uma difusão de Itô

- Uma difusão de Itô é uma solução da EDE estocástica

$$X_t = x + \int_0^t b(X_s) ds + \int_0^t \sigma(X_s) dB_s$$

# Gerador de uma difusão de Itô

- Uma difusão de Itô é uma solução da EDE estocástica

$$X_t = x + \int_0^t b(X_s) ds + \int_0^t \sigma(X_s) dB_s$$

- Notamos que a solução dessa EDE é um processo estocástico contínuo  $X : [0, T] \times \Omega \rightarrow \mathbb{R}^n$ ,  $X(t, \omega)$ . Ele pode ser considerado como uma variável aleatória

$$\Omega \rightarrow C([0, T], \mathbb{R}^n), \omega \mapsto X(\cdot, \omega),$$

porque  $X(\cdot, \omega) : t \mapsto X(t, \omega)$  é uma função contínua com  $X(0, \omega) = x$

# Gerador de uma difusão de Itô

- Uma difusão de Itô é uma solução da EDE estocástica

$$X_t = x + \int_0^t b(X_s) ds + \int_0^t \sigma(X_s) dB_s$$

- Notamos que a solução dessa EDE é um processo estocástico contínuo  $X : [0, T] \times \Omega \rightarrow \mathbb{R}^n$ ,  $X(t, \omega)$ . Ele pode ser considerado como uma variável aleatória

$$\Omega \rightarrow C([0, T], \mathbb{R}^n), \omega \mapsto X(\cdot, \omega),$$

porque  $X(\cdot, \omega) : t \mapsto X(t, \omega)$  é uma função contínua com  $X(0, \omega) = x$

- Seja  $P^x = \mathbb{P} \circ X^{-1}$  a distribuição da variável aleatória  $X : \Omega \rightarrow C([0, T], \mathbb{R}^n)$ .

# Gerador de uma difusão de Itô

- Uma difusão de Itô é uma solução da EDE estocástica

$$X_t = x + \int_0^t b(X_s) ds + \int_0^t \sigma(X_s) dB_s$$

- Notamos que a solução dessa EDE é um processo estocástico contínuo  $X : [0, T] \times \Omega \rightarrow \mathbb{R}^n$ ,  $X(t, \omega)$ . Ele pode ser considerado como uma variável aleatória

$$\Omega \rightarrow C([0, T], \mathbb{R}^n), \omega \mapsto X(\cdot, \omega),$$

porque  $X(\cdot, \omega) : t \mapsto X(t, \omega)$  é uma função contínua com  $X(0, \omega) = x$

- Seja  $P^x = \mathbb{P} \circ X^{-1}$  a distribuição da variável aleatória

$$X : \Omega \rightarrow C([0, T], \mathbb{R}^n).$$

- Notamos que  $X^{-1}$  é uma aplicação  $C([0, T], \mathbb{R}^n) \rightarrow \Omega$ . Assim,  $P^x$  é uma medida em  $C([0, T], \mathbb{R}^n)$ . O índice 'x' significa que  $X(0, \omega) = x$ .

# Gerador de uma difusão de Itô

- Seja  $E^x$  esperança em relação a  $P^x$ , ou seja

$$E^x[\Phi] = \int_{C([0, T], \mathbb{R}^n)} \Phi(y) P^x(dy)$$

# Gerador de uma difusão de Itô

- Seja  $E^x$  esperança em relação a  $P^x$ , ou seja

$$E^x[\Phi] = \int_{C([0, T], \mathbb{R}^n)} \Phi(y) P^x(dy)$$

- Definimos

$$(\mathcal{A}f)(x) = \lim_{t \rightarrow 0^+} \frac{E^x[f(X_t)] - f(x)}{t}.$$

# Gerador de uma difusão de Itô

- Seja  $E^x$  esperança em relação a  $P^x$ , ou seja

$$E^x[\Phi] = \int_{C([0, T], \mathbb{R}^n)} \Phi(y) P^x(dy)$$

- Definimos

$$(\mathcal{A}f)(x) = \lim_{t \rightarrow 0^+} \frac{E^x[f(X_t)] - f(x)}{t}.$$

## TEOREMA

Seja  $X_t$  uma difusão de Itô, ou seja  $X_t = x + \int_0^t b(X_s) ds + \int_0^t \sigma(X_s) dB_s$ . Seja  $f \in C_b^2(\mathbb{R}^n)$ . Então,  $f \in D(\mathcal{A})$  e o gerador  $\mathcal{A}$  de  $X_t$  tem a seguinte representação:

$$(\mathcal{A}f)(x) = \frac{1}{2} \sum_{i,j=1}^n (\sigma \sigma^\top)_{ij}(x) \partial_{x_i x_j}^2 f(x) + \sum_{i=1}^n b_i(x) \partial_{x_i} f(x).$$



# Teorema da representação martingale

- O processo estocástico  $X_t = \int_0^t v(s, \omega) dB_s$  é sempre um martingale:

$$\mathbb{E} \left[ \int_0^t v(r, \omega) dB_r \mid \mathcal{F}_s \right] = \int_0^s v(r, \omega) dB_r \quad s < t.$$

# Teorema da representação martingale

- O processo estocástico  $X_t = \int_0^t v(s, \omega) dB_s$  é sempre um martingale:

$$\mathbb{E} \left[ \int_0^t v(r, \omega) dB_r \mid \mathcal{F}_s \right] = \int_0^s v(r, \omega) dB_r \quad s < t.$$

## TEOREMA

Seja  $B_t = (B_t^1, B_t^2, \dots, B_t^n)$  um movimento browniano  $n$ -dimensional. Vamos supor que  $M_t$  é um martingale em relação à filtração

$\mathcal{F}_t = \sigma\{B_s^i, i = 1, \dots, n, 0 \leq s \leq t\}$  (ou seja  $\mathbb{E}|M_t| < \infty$  e  $\mathbb{E}[M_t | \mathcal{F}_s] = M_s$  para todos  $s < t$ ). Então, existe um processo estocástico  $v(t, \omega)$  do classe  $L_2(\Omega \times [0, t], \mathbb{P} \otimes \lambda)$ , adaptado em relação a  $\mathcal{F}_t$  e tal que

$$M_t(\omega) = \mathbb{E}[M_0] + \int_0^t v(s, \omega) dB_s.$$

# EDEs regressivas (Backward SDEs)

- Fixamos um espaço de probabilidade  $(\Omega, \mathcal{F}, \mathbb{P})$ , e uma filtração  $\mathcal{F}_t$  gerado por um movimento browniano  $d$ -dimensional  $B_t$ , ou seja,  $\mathcal{F}_t = \sigma\{B_s, 0 \leq s \leq t\}$ .

# EDEs regressivas (Backward SDEs)

- Fixamos um espaço de probabilidade  $(\Omega, \mathcal{F}, \mathbb{P})$ , e uma filtração  $\mathcal{F}_t$  gerado por um movimento browniano  $d$ -dimensional  $B_t$ , ou seja,  
 $\mathcal{F}_t = \sigma\{B_s, 0 \leq s \leq t\}$ .
- Consideramos a equação regressiva

$$Y_t = \xi + \int_t^T g(s, Y_s, Z_s) ds - \int_t^T Z_s dB_s, \quad \xi \text{ é } \mathcal{F}_T\text{-mensurável}$$

# EDEs regressivas (Backward SDEs)

- Fixamos um espaço de probabilidade  $(\Omega, \mathcal{F}, \mathbb{P})$ , e uma filtração  $\mathcal{F}_t$  gerado por um movimento browniano  $d$ -dimensional  $B_t$ , ou seja,  
 $\mathcal{F}_t = \sigma\{B_s, 0 \leq s \leq t\}$ .

- Consideramos a equação regressiva

$$Y_t = \xi + \int_t^T g(s, Y_s, Z_s) ds - \int_t^T Z_s dB_s, \quad \xi \text{ é } \mathcal{F}_T\text{-mensurável}$$

- A solução é um par  $(Y_t, Z_t)$  de processos  $\mathcal{F}_t$ -adaptados com valores um  $\mathbb{R}^Q \times (\mathbb{R}^Q \times \mathbb{R}^d)$ .

# EDEs regressivas (Backward SDEs)

- Fixamos um espaço de probabilidade  $(\Omega, \mathcal{F}, \mathbb{P})$ , e uma filtração  $\mathcal{F}_t$  gerado por um movimento browniano  $d$ -dimensional  $B_t$ , ou seja,  
 $\mathcal{F}_t = \sigma\{B_s, 0 \leq s \leq t\}$ .
- Consideramos a equação regressiva

$$Y_t = \xi + \int_t^T g(s, Y_s, Z_s) ds - \int_t^T Z_s dB_s, \quad \xi \text{ é } \mathcal{F}_T\text{-mensurável}$$

- A solução é um par  $(Y_t, Z_t)$  de processos  $\mathcal{F}_t$ -adaptados com valores em  $\mathbb{R}^Q \times (\mathbb{R}^Q \times \mathbb{R}^d)$ .
- A versão simplificada:  $g = g(s)$ .

# EDEs regressivas (Backward SDEs)

- Fixamos um espaço de probabilidade  $(\Omega, \mathcal{F}, \mathbb{P})$ , e uma filtração  $\mathcal{F}_t$  gerado por um movimento browniano  $d$ -dimensional  $B_t$ , ou seja,  
 $\mathcal{F}_t = \sigma\{B_s, 0 \leq s \leq t\}$ .

- Consideramos a equação regressiva

$$Y_t = \xi + \int_t^T g(s, Y_s, Z_s) ds - \int_t^T Z_s dB_s, \quad \xi \text{ é } \mathcal{F}_T\text{-mensurável}$$

- A solução é um par  $(Y_t, Z_t)$  de processos  $\mathcal{F}_t$ -adaptados com valores um  $\mathbb{R}^Q \times (\mathbb{R}^Q \times \mathbb{R}^d)$ .
- A versão simplificada:  $g = g(s)$ .
- Nesse caso,  $Y_t = \mathbb{E}[\xi + \int_t^T g(s) ds | \mathcal{F}_t]$  porque  
 $\mathbb{E}\left[\int_t^T Z_s dB_s | \mathcal{F}_t\right] = \int_t^t Z_s dB_s = 0$

# EDEs regressivas (Backward SDEs)

- Fixamos um espaço de probabilidade  $(\Omega, \mathcal{F}, \mathbb{P})$ , e uma filtração  $\mathcal{F}_t$  gerado por um movimento browniano  $d$ -dimensional  $B_t$ , ou seja,  
 $\mathcal{F}_t = \sigma\{B_s, 0 \leq s \leq t\}$ .

- Consideramos a equação regressiva

$$Y_t = \xi + \int_t^T g(s, Y_s, Z_s) ds - \int_t^T Z_s dB_s, \quad \xi \text{ é } \mathcal{F}_T\text{-mensurável}$$

- A solução é um par  $(Y_t, Z_t)$  de processos  $\mathcal{F}_t$ -adaptados com valores um  $\mathbb{R}^Q \times (\mathbb{R}^Q \times \mathbb{R}^d)$ .
- A versão simplificada:  $g = g(s)$ .
- Nesse caso,  $Y_t = \mathbb{E}[\xi + \int_t^T g(s) ds | \mathcal{F}_t]$  porque  
 $\mathbb{E}\left[\int_t^T Z_s dB_s | \mathcal{F}_t\right] = \int_t^t Z_s dB_s = 0$
- $Y_t + \int_0^t g(s) ds = \mathbb{E}\left[\xi + \int_0^T g(s) ds | \mathcal{F}_t\right]$  é um martingale pela propriedade  
 $\mathbb{E}[\mathbb{E}[\Phi | \mathcal{F}_t] | \mathcal{F}_s] = \mathbb{E}[\Phi | \mathcal{F}_s]$



# EDEs regressivas (Backward SDEs)

- Pelo teorema da representação martingale, existe  $Z_t$  tal que

$$Y_t + \int_0^t g(s) ds = \mathbb{E} \left[ \xi + \int_0^T g(s) ds \mid \mathcal{F}_t \right] = \mathbb{E}[Y_0] + \int_0^t Z_s dB_s$$

# EDEs regressivas (Backward SDEs)

- Pelo teorema da representação martingale, existe  $Z_t$  tal que

$$Y_t + \int_0^t g(s) ds = \mathbb{E} \left[ \xi + \int_0^T g(s) ds \mid \mathcal{F}_t \right] = \mathbb{E}[Y_0] + \int_0^t Z_s dB_s$$

- Avaliando em ponto  $t = T$ , obtemos  $\xi + \int_0^T g(s) ds = \mathbb{E}[Y_0] + \int_0^T Z_s dB_s$

# EDEs regressivas (Backward SDEs)

- Pelo teorema da representação martingale, existe  $Z_t$  tal que

$$Y_t + \int_0^t g(s)ds = \mathbb{E}\left[\xi + \int_0^T g(s)ds \mid \mathcal{F}_t\right] = \mathbb{E}[Y_0] + \int_0^t Z_s dB_s$$

- Avaliando em ponto  $t = T$ , obtemos  $\xi + \int_0^T g(s)ds = \mathbb{E}[Y_0] + \int_0^T Z_s dB_s$
- Essas equações implicam que

$$Y_t = \xi + \int_t^T g(s)ds - \int_t^T Z_s dB_s$$

# EDEs regressivas (Backward SDEs)

- Pelo teorema da representação martingale, existe  $Z_t$  tal que

$$Y_t + \int_0^t g(s) ds = \mathbb{E} \left[ \xi + \int_0^T g(s) ds \mid \mathcal{F}_t \right] = \mathbb{E}[Y_0] + \int_0^t Z_s dB_s$$

- Avaliando em ponto  $t = T$ , obtemos  $\xi + \int_0^T g(s) ds = \mathbb{E}[Y_0] + \int_0^T Z_s dB_s$

- Essas equações implicam que

$$Y_t = \xi + \int_t^T g(s) ds - \int_t^T Z_s dB_s$$

- Assim, provamos a existência do único par  $Y_t$  e  $Z_t$  que satisfaz a EDE regressiva.

# EDEs regressivas (Backward SDEs)

- Pelo teorema da representação martingale, existe  $Z_t$  tal que

$$Y_t + \int_0^t g(s) ds = \mathbb{E} \left[ \xi + \int_0^T g(s) ds \mid \mathcal{F}_t \right] = \mathbb{E}[Y_0] + \int_0^t Z_s dB_s$$

- Avaliando em ponto  $t = T$ , obtemos  $\xi + \int_0^T g(s) ds = \mathbb{E}[Y_0] + \int_0^T Z_s dB_s$
- Essas equações implicam que

$$Y_t = \xi + \int_t^T g(s) ds - \int_t^T Z_s dB_s$$

- Assim, provamos a existência do único par  $Y_t$  e  $Z_t$  que satisfaz a EDE regressiva.
- No caso geral temos um processo iterativo:

$$Y_t^{(i+1)} = \xi + \int_t^T g(s, Y_s^{(i)}, Z_s^{(i)}) ds - \int_t^T Z_s^{(i+1)} dB_s$$

# EDEs regressivas (Backward SDEs)

## TEOREMA

Vamos supor que  $g(t, y, z)$  é uma função com as propriedades

$$|g(t, y, z)| \leq K(1 + |y| + |z|), \quad \text{crescimento linear}$$

$$|g(t, y_1, z_1) - g(t, y_2, z_2)| \leq C(|y_1 - y_2| + |z_1 - z_2|), \quad \text{função Lipschitz.}$$

Então, a EDE regressiva

$$Y_t = \xi + \int_t^T g(s, Y_s, Z_s) ds - \int_t^T Z_s dB_s$$

possui uma solução  $(Y_t, Z_t)$ , que é única em relação à norma

$$\|(Y_t, Z_t)\|^2 = \sup_{t \in [0, T]} \mathbb{E}|Y_t|^2 + \int_0^T \mathbb{E}|Z_s|^2 ds.$$

# EDEs regressivas (Backward SDEs)

Ideia da demonstração

- Aplicando a formula de Itô a  $|Y_t^1 - Y_t^2|^2$ , obtemos

$$\begin{aligned} & |Y_t^1 - Y_t^2|^2 + \int_t^T |Z_s^1 - Z_s^2|^2 ds \\ &= \int_t^T (g(s, Y_s^1, Z_s^1) - g(t, Y_s^2, Z_s^2), Y_s^1 - Y_s^2) ds - \int_t^T ((Z_s^1 - Z_s^2) dB_s, Y_s^1 - Y_s^2) \end{aligned}$$

# EDEs regressivas (Backward SDEs)

## Ideia da demonstração

- Aplicando a formula de Itô a  $|Y_t^1 - Y_t^2|^2$ , obtemos

$$\begin{aligned} & |Y_t^1 - Y_t^2|^2 + \int_t^T |Z_s^1 - Z_s^2|^2 ds \\ &= \int_t^T (g(s, Y_s^1, Z_s^1) - g(s, Y_s^2, Z_s^2), Y_s^1 - Y_s^2) ds - \int_t^T ((Z_s^1 - Z_s^2) dB_s, Y_s^1 - Y_s^2) \end{aligned}$$

- Daqui,

$$\begin{aligned} & \mathbb{E}|Y_t^1 - Y_t^2|^2 + \int_t^T \mathbb{E}|Z_s^1 - Z_s^2|^2 ds \\ & \leq K_1 \mathbb{E} \int_t^T |Y_s^1 - Y_s^2|^2 ds + K_2 \mathbb{E} \int_t^T |Y_s^1 - Y_s^2| |Z_s^1 - Z_s^2| ds \\ & \leq K_1 \int_t^T \mathbb{E}|Y_s^1 - Y_s^2|^2 ds + K_2 \int_t^T \mathbb{E} \sqrt{K_2} |Y_s^1 - Y_s^2| \frac{1}{\sqrt{K_2}} |Z_s^1 - Z_s^2| ds \\ & \leq \tilde{K}_1 \int_t^T \mathbb{E}|Y_s^1 - Y_s^2|^2 ds + \frac{1}{2} \int_t^T \mathbb{E}|Z_s^1 - Z_s^2|^2 ds. \end{aligned}$$



# EDEs regressivas (Backward SDEs)

Ideia da demonstração

- Temos

$$\mathbb{E}|Y_t^1 - Y_t^2|^2 \leq K \int_t^T \mathbb{E}|Y_s^1 - Y_s^2|^2 ds$$

# EDEs regressivas (Backward SDEs)

Ideia da demonstração

- Temos

$$\mathbb{E}|Y_t^1 - Y_t^2|^2 \leq K \int_t^T \mathbb{E}|Y_s^1 - Y_s^2|^2 ds$$

- Lembramos que essa desigualdade permite aplicar o mesmo método, de ponto fixo, como para EDEs tradicionais; envolvendo a constante

$$\frac{K^n T^n}{n!} < 1.$$

# EDEs regressivas (Backward SDEs)

## Connexão com EDPs

- Vamos supor  $\xi = h(B_T)$  e consideramos o seguinte problema do valor final para uma EDP:

$$\begin{cases} \partial_t \theta(t, x) + \frac{1}{2} \Delta \theta(t, x) + g(t, \theta(t, x), \nabla \theta(t, x)) = 0 \\ \theta(T, x) = h(x) \end{cases}$$

# EDEs regressivas (Backward SDEs)

## Connexão com EDPs

- Vamos supor  $\xi = h(B_T)$  e consideramos o seguinte problema do valor final para uma EDP:

$$\begin{cases} \partial_t \theta(t, x) + \frac{1}{2} \Delta \theta(t, x) + g(t, \theta(t, x), \nabla \theta(t, x)) = 0 \\ \theta(T, x) = h(x) \end{cases}$$

- Vamos supor que o problema acima tem uma solução  $\theta(t, x)$ .

# EDEs regressivas (Backward SDEs)

## Connexão com EDPs

- Vamos supor  $\xi = h(B_T)$  e consideramos o seguinte problema do valor final para uma EDP:

$$\begin{cases} \partial_t \theta(t, x) + \frac{1}{2} \Delta \theta(t, x) + g(t, \theta(t, x), \nabla \theta(t, x)) = 0 \\ \theta(T, x) = h(x) \end{cases}$$

- Vamos supor que o problema acima tem uma solução  $\theta(t, x)$ .
- Aplicando a fórmula de Itô a  $\theta(t, B_t)$  obtemos

$$\theta(t, B_t) = h(B_T) - \int_t^T \left( \partial_s \theta(s, B_s) + \frac{1}{2} \Delta \theta(s, B_s) \right) ds - \int_t^T \nabla \theta(s, B_s) dB_s$$

# EDEs regressivas (Backward SDEs)

## Connexão com EDPs

- Vamos supor  $\xi = h(B_T)$  e consideramos o seguinte problema do valor final para uma EDP:

$$\begin{cases} \partial_t \theta(t, x) + \frac{1}{2} \Delta \theta(t, x) + g(t, \theta(t, x), \nabla \theta(t, x)) = 0 \\ \theta(T, x) = h(x) \end{cases}$$

- Vamos supor que o problema acima tem uma solução  $\theta(t, x)$ .
- Aplicando a fórmula de Itô a  $\theta(t, B_t)$  obtemos

$$\theta(t, B_t) = h(B_T) - \int_t^T \left( \partial_s \theta(s, B_s) + \frac{1}{2} \Delta \theta(s, B_s) \right) ds - \int_t^T \nabla \theta(s, B_s) dB_s$$

- Ou seja,

$$\theta(t, B_t) = h(B_T) - \int_t^T g(s, \theta(s, B_s), \nabla \theta(s, B_s)) ds - \int_t^T \nabla \theta(s, B_s) dB_s$$

# EDEs regressivas (Backward SDEs)

Connexão com EDPs

- Isso implica que a solução da EDE regressiva toma a forma

$$Y_t = \theta(t, B_t), \quad Z_t = \nabla \theta(t, B_t)$$

# EDEs regressivas (Backward SDEs)

Connexão com EDPs

- Isso implica que a solução da EDE regressiva toma a forma

$$Y_t = \theta(t, B_t), \quad Z_t = \nabla \theta(t, B_t)$$

- Por outro lado, se  $(Y_t^{\tau,x}, Z_t^{\tau,x})$  é uma solução da EDE regressiva

$$Y_t^{\tau,x} = h(B_T^{\tau,x}) + \int_t^T g(s, Y_s^{\tau,x}, Z_s^{\tau,x}) ds - \int_t^T Z_s^{\tau,x} dB_s^{\tau,x}, \quad t \in [\tau, T]$$

com  $B_t^{\tau,x} = x + B_t - B_\tau, \quad t \in [\tau, T]$



# EDEs regressivas (Backward SDEs)

Connexão com EDPs

- Isso implica que a solução da EDE regressiva toma a forma

$$Y_t = \theta(t, B_t), \quad Z_t = \nabla \theta(t, B_t)$$

- Por outro lado, se  $(Y_t^{\tau,x}, Z_t^{\tau,x})$  é uma solução da EDE regressiva

$$Y_t^{\tau,x} = h(B_T^{\tau,x}) + \int_t^T g(s, Y_s^{\tau,x}, Z_s^{\tau,x}) ds - \int_t^T Z_s^{\tau,x} dB_s^{\tau,x}, \quad t \in [\tau, T]$$

com  $B_t^{\tau,x} = x + B_t - B_\tau, \quad t \in [\tau, T]$

- Então,  $Y_\tau^{\tau,x}$  é uma função determinística e  $\theta(\tau, x) = Y_\tau^{\tau,x}$  é uma solução do problema de valor final para a EDP

# EDEs regressivas (Backward SDEs)

Ideia de demonstração

- $$\begin{aligned}\theta(\tau + \delta, x) - \theta(\tau, x) &= Y_{\tau+\delta}^{\tau+\delta, x} - Y_{\tau}^{\tau, x} = Y_{\tau+\delta}^{\tau+\delta, x} - Y_{\tau+\delta}^{\tau, x} + Y_{\tau+\delta}^{\tau, x} - Y_{\tau}^{\tau, x} \\ &= (\theta(\tau + \delta, x) - \theta(\tau + \delta, B_{\tau+\delta}^{\tau, x})) + (Y_{\tau+\delta}^{\tau, x} - Y_{\tau}^{\tau, x}).\end{aligned}$$

# EDEs regressivas (Backward SDEs)

Ideia de demonstração

- $$\begin{aligned}\theta(\tau + \delta, x) - \theta(\tau, x) &= Y_{\tau+\delta}^{\tau+\delta, x} - Y_{\tau}^{\tau, x} = Y_{\tau+\delta}^{\tau+\delta, x} - Y_{\tau+\delta}^{\tau, x} + Y_{\tau+\delta}^{\tau, x} - Y_{\tau}^{\tau, x} \\ &= (\theta(\tau + \delta, x) - \theta(\tau + \delta, B_{\tau+\delta}^{\tau, x})) + (Y_{\tau+\delta}^{\tau, x} - Y_{\tau}^{\tau, x}).\end{aligned}$$
- Aplicamos a fórmula de Itô à primeira diferença e usamos a EDE regressiva para a segunda diferença.

# EDEs regressivas (Backward SDEs)

Ideia de demonstração

- $$\begin{aligned}\theta(\tau + \delta, x) - \theta(\tau, x) &= Y_{\tau+\delta}^{\tau+\delta, x} - Y_{\tau}^{\tau, x} = Y_{\tau+\delta}^{\tau+\delta, x} - Y_{\tau+\delta}^{\tau, x} + Y_{\tau+\delta}^{\tau, x} - Y_{\tau}^{\tau, x} \\ &= (\theta(\tau + \delta, x) - \theta(\tau + \delta, B_{\tau+\delta}^{\tau, x})) + (Y_{\tau+\delta}^{\tau, x} - Y_{\tau}^{\tau, x}).\end{aligned}$$
- Aplicamos a fórmula de Itô à primeira diferença e usamos a EDE regressiva para a segunda diferença.
- $$\begin{aligned}\frac{1}{\delta} (\theta(\tau + \delta, x) - \theta(\tau, x)) &= -\frac{1}{\delta} \mathbb{E} \left[ \int_{\tau}^{\tau+\delta} \left( \frac{1}{2} \Delta \theta(\tau + \delta, x + B_{r+\delta} - B_{\tau}) \right. \right. \\ &\quad \left. \left. + g(\tau + \delta, \theta(\tau + \delta, x + B_r - B_{\tau}), \nabla \theta(\tau + \delta, x + B_r - B_{\tau})) \right) dr \right]\end{aligned}$$

# EDEs regressivas (Backward SDEs)

Ideia de demonstração

- $\theta(\tau + \delta, x) - \theta(\tau, x) = Y_{\tau+\delta}^{\tau+\delta, x} - Y_{\tau}^{\tau, x} = Y_{\tau+\delta}^{\tau+\delta, x} - Y_{\tau+\delta}^{\tau, x} + Y_{\tau+\delta}^{\tau, x} - Y_{\tau}^{\tau, x}$   
 $= (\theta(\tau + \delta, x) - \theta(\tau + \delta, B_{\tau+\delta}^{\tau, x})) + (Y_{\tau+\delta}^{\tau, x} - Y_{\tau}^{\tau, x}).$
- Aplicamos a fórmula de Itô à primeira diferença e usamos a EDE regressiva para a segunda diferença.
- $\frac{1}{\delta} (\theta(\tau + \delta, x) - \theta(\tau, x)) = -\frac{1}{\delta} \mathbb{E} \left[ \int_{\tau}^{\tau+\delta} \left( \frac{1}{2} \Delta\theta(\tau + \delta, x + B_{r+\delta} - B_{\tau}) \right. \right.$   
 $\left. \left. + g(\tau + \delta, \theta(\tau + \delta, x + B_r - B_{\tau}), \nabla\theta(\tau + \delta, x + B_r - B_{\tau})) \right) dr \right]$   
 $\rightarrow -\frac{1}{2} \Delta\theta(\tau, x) + g(\tau, x, \theta(\tau, x), \nabla\theta(\tau, x)), \quad \text{quando } \delta \rightarrow 0.$

# EDEs progressivas-regressivas (Forward-Backward SDEs)

Connexão com EDPs

- Consideramos EDEs progressivas-regressivas:

$$\begin{cases} X_t = x + \int_t^t f(s, X_s, Y_s, Z_s) ds + \int_t^t \sigma(s, X_s, Y_s) dB_s \\ Y_t = h(X_T) + \int_t^T g(s, X_s, Y_s, Z_s) ds - \int_t^T Z_s dB_s \end{cases}$$

# EDEs progressivas-regressivas (Forward-Backward SDEs)

Connexão com EDPs

- Consideramos EDEs progressivas-regressivas:

$$\begin{cases} X_t = x + \int_t^t f(s, X_s, Y_s, Z_s) ds + \int_t^t \sigma(s, X_s, Y_s) dB_s \\ Y_t = h(X_T) + \int_t^T g(s, X_s, Y_s, Z_s) ds - \int_t^T Z_s dB_s \end{cases}$$

- A solução é uma tripla de processos estocásticos  $(X_t, Y_t, Z_t)$  com valores em  $\mathbb{R}^P \times \mathbb{R}^Q \times (\mathbb{R}^Q \times \mathbb{R}^d)$  adaptados em relação à filtração  $\mathcal{F}_t$  gerada por  $B_t$ .

# EDEs progressivas-regressivas (Forward-Backward SDEs)

## Four Step Scheme



J. Ma, P. Protter, J. Yong, Solving forward-backward stochastic differential equations explicitly – a four step scheme, 1994



# EDEs progressivas-regressivas (Forward-Backward SDEs)

## Four Step Scheme



J. Ma, P. Protter, J. Yong, Solving forward-backward stochastic differential equations explicitly – a four step scheme, 1994

- Existe uma conexão forte entre EDEs progressivas-regressivas e EDPs parabólicas quasi-lineares

# EDEs progressivas-regressivas (Forward-Backward SDEs)

## Four Step Scheme



J. Ma, P. Protter, J. Yong, Solving forward-backward stochastic differential equations explicitly – a four step scheme, 1994

- Existe uma conexão forte entre EDEs progressivas-regressivas e EDPs parabólicas quasi-lineares
- Consideramos a problema de valor final para EDP

$$\left\{ \begin{array}{l} \frac{\partial \theta}{\partial t}(t, x) + \frac{1}{2} \sum_{i,j=1}^P (\sigma \sigma^*)_{ij}(t, x, \theta(t, x)) \frac{\partial^2 \theta}{\partial x_i \partial x_j}(t, x) \\ + \sum_{i=1}^P f_i(t, x, \theta(t, x), \nabla_x \theta(t, x) \sigma(t, x, \theta(t, x))) \frac{\partial \theta}{\partial x_i}(t, x) \\ + g(t, x, \theta(t, x), \nabla_x \theta(t, x) \sigma(t, x, \theta(t, x))) = 0 \\ \theta(T, x) = h(x) \end{array} \right.$$

$(t, x) \in [0, T] \times \mathbb{R}^P$ ,  $\theta$  toma valores em  $\mathbb{R}^Q$ .

# Forward-backward SDEs

## Four Step Scheme

- Se  $\theta(t, x)$  é a solução do problema de valor final acima

# Forward-backward SDEs

## Four Step Scheme

- Se  $\theta(t, x)$  é a solução do problema de valor final acima
- $X_t$  é a solução da EDE

$$X_t = x + \int_{\tau}^t \tilde{f}(s, X_s) ds + \int_{\tau}^t \tilde{\sigma}(s, X_s) dB_s,$$

onde  $\tilde{f}(t, x) = f(t, x, \theta(t, x), \nabla_x \theta(t, x) \sigma(t, x, \theta(t, x)))$ ,  
 $\tilde{\sigma}(t, x) = \sigma(t, x, \theta(t, x))$

# Forward-backward SDEs

## Four Step Scheme

- Se  $\theta(t, x)$  é a solução do problema de valor final acima
- $X_t$  é a solução da EDE

$$X_t = x + \int_{\tau}^t \tilde{f}(s, X_s) ds + \int_{\tau}^t \tilde{\sigma}(s, X_s) dB_s,$$

onde  $\tilde{f}(t, x) = f(t, x, \theta(t, x), \nabla_x \theta(t, x) \sigma(t, x, \theta(t, x)))$ ,  
 $\tilde{\sigma}(t, x) = \sigma(t, x, \theta(t, x))$

- $X_t = x + \int_{\tau}^t f(s, X_s, Y_s, Z_s) ds + \int_{\tau}^t \sigma(s, X_s, Y_s) dB_s$

# Forward-backward SDEs

## Four Step Scheme

- Se  $\theta(t, x)$  é a solução do problema de valor final acima
- $X_t$  é a solução da EDE

$$X_t = x + \int_{\tau}^t \tilde{f}(s, X_s) ds + \int_{\tau}^t \tilde{\sigma}(s, X_s) dB_s,$$

onde  $\tilde{f}(t, x) = f(t, x, \theta(t, x), \nabla_x \theta(t, x) \sigma(t, x, \theta(t, x)))$ ,  
 $\tilde{\sigma}(t, x) = \sigma(t, x, \theta(t, x))$

- $X_t = x + \int_{\tau}^t f(s, X_s, Y_s, Z_s) ds + \int_{\tau}^t \sigma(s, X_s, Y_s) dB_s$
- Então, a solução da EDE progressiva-regressiva toma a forma  
 $(X_t, Y_t, Z_t) = (X_t, \theta(t, X_t), \nabla_x \theta(t, X_t) \sigma(t, X_t, \theta(t, X_t)))$

# Forward-backward SDEs (FBSDEs)

## Four Step Scheme

- Por outro lado, se  $(X_t^{T,x}, Y_t^{T,x}, Z_t^{T,x})$  a solução de FBSDEs, então

# Forward-backward SDEs (FBSDEs)

## Four Step Scheme

- Por outro lado, se  $(X_t^{T,x}, Y_t^{T,x}, Z_t^{T,x})$  a solução de FBSDEs, então
- $Y_\tau^{T,x}$  é determinístico



# Forward-backward SDEs (FBSDEs)

## Four Step Scheme

- Por outro lado, se  $(X_t^{T,x}, Y_t^{T,x}, Z_t^{T,x})$  a solução de FBSDEs, então
- $Y_\tau^{T,x}$  é determinístico
- e  $\theta(\tau, x) = Y_\tau^{T,x}$  a solução do problema de valor final para a EDP

# Forward-backward SDEs (FBSDEs)

## Four Step Scheme

- Por outro lado, se  $(X_t^{T,x}, Y_t^{T,x}, Z_t^{T,x})$  a solução de FBSDEs, então
- $Y_\tau^{T,x}$  é determinístico
- e  $\theta(\tau, x) = Y_\tau^{T,x}$  a solução do problema de valor final para a EDP
- A ideia de demonstração é a mesma do que para a EDP

$$\theta(t, B_t) = h(B_T) - \int_t^T g(s, \theta(s, B_s), \nabla\theta(s, B_s)) ds - \int_t^T \nabla\theta(s, B_s) dB_s$$