

2

Noções sobre Martingais em tempo discreto e contínuo

Começamos recordando algumas noções básicas da Teoria de Probabilidade.

Definição 2.1 Um Espaço de Probabilidade é uma tripla $(\Omega, \mathcal{F}, \mathbb{P})$, onde:

1. $\Omega \neq \emptyset$ é um conjunto arbitrário (dito “espaço amostral”);
2. \mathcal{F} é uma σ -álgebra de subconjuntos de Ω (os “eventos”), isto é:
 - (a) $\emptyset \in \mathcal{F}$
 - (b) $A \in \mathcal{F} \Rightarrow A^c \in \mathcal{F}$
 - (c) $\{A_n\}_{n \geq 1} \subset \mathcal{F} \Rightarrow \bigcup_{n \geq 1} A_n \in \mathcal{F}$
3. \mathbb{P} é uma função de conjunto

$$\mathbb{P} : \mathcal{F} \rightarrow [0, 1]$$

$$A \mapsto \mathbb{P}(A),$$

tal que,

- (i) $\mathbb{P}(\emptyset) = 0, \mathbb{P}(\Omega) = 1$
- (ii) $\{A_n\}_{n \geq 1} \subset \mathcal{F}$, disjuntos dois a dois ($A_i \cap A_j = \emptyset, i \neq j$)
 $\Rightarrow \mathbb{P}\left(\bigcup_{n \geq 1} A_n\right) = \sum_{n \geq 1} \mathbb{P}(A_n)$ (σ - aditividade).

Obs: $\mathbb{P}(A)$ é a probabilidade do evento A . Em teoria da medida, o par (Ω, \mathcal{F}) chama-se espaço mensurável, sendo os elementos de \mathcal{F} chamados conjuntos mensuráveis.

Propriedades Básicas:

1. $A \in \mathcal{F} \Rightarrow \mathbb{P}(A^c) = 1 - \mathbb{P}(A)$;
2. $A, B \in \mathcal{F}$ e $A \subset B \Rightarrow \mathbb{P}(A) \leq \mathbb{P}(B)$ (Monotonicidade);
3. $\mathbb{P}(\bigcup_{n \geq 1} A_n) \leq \sum_{n \geq 1} \mathbb{P}(A_n)$ (σ -sub aditividade).

Exemplo: Seja $\Omega = \{\omega_1, \dots, \omega_n\}$ um espaço amostral finito, $\mathcal{F} = \mathcal{P}(\Omega)$ (conjunto das partes de Ω) e suponha que existam números reais $p_i \geq 0, i = 1, \dots, N$ com $\sum_{i=1}^N p_i = 1$. Então, se definirmos $\forall A \in \mathcal{F} : \mathbb{P}(A) \equiv \sum_{\omega_i \in A} p_i$, segue que $(\Omega, \mathcal{F}, \mathbb{P})$ é espaço de probabilidade.

Para lidar com o caso extremamente importante em que $\Omega = \mathbb{R}$, é conveniente a seguinte definição.

Definição 2.2 A σ -álgebra gerada por uma coleção de subconjuntos de Ω ζ é a menor σ -álgebra contendo esta coleção, isto é, a interseção de todas as σ -álgebras contendo ζ .

Exemplo: Se $\Omega = \mathbb{R}$, a σ -álgebra de borel é

$$\begin{aligned} \mathcal{B}(\mathbb{R}) &= \sigma(\{\text{intervalos semi-abertos } (a, b)\}) \\ &= \sigma(\{\text{intervalos } (a, b)\}), \text{ isto é, a } \sigma\text{-álgebra gerada pelos abertos de } \mathbb{R} \\ &= \sigma(\{\text{intervalos fechados } [a, b]\}) \\ &= \sigma(\{(-\infty, a]\}) \end{aligned}$$

Para construir medidas de probabilidade em $(\mathbb{R}, \mathcal{B}(\mathbb{R}))$, usa-se a noção de *função de distribuição*. Note que dada uma medida de probabilidade $\mathbb{P} : \mathcal{B}(\mathbb{R}) \rightarrow [0, 1]$ em $(\mathbb{R}, \mathcal{B}(\mathbb{R}))$ e definindo a função:

$$\begin{aligned} F : \mathbb{R} &\longrightarrow \mathbb{R} \\ x &\longmapsto F(x) \equiv \mathbb{P}(-\infty, x], \end{aligned}$$

então tem-se que :

1. F é monótona não-decrescente;
2. F é contínua à direita com limites à esquerda;
3. $\lim_{x \rightarrow +\infty} F(x) = 1, \lim_{x \rightarrow -\infty} F(x) = 0$.

Definição 2.3 Uma função $F : \mathbb{R} \rightarrow \mathbb{R}$ satisfazendo 1 – 3 é dita uma função de distribuição.

Reciprocamente, o teorema seguinte afirma que uma função de distribuição determina univocamente uma medida de probabilidade em $(\mathbb{R}, \mathcal{B}(\mathbb{R}))$.

Teorema 2.4 Dada uma função de distribuição $F : \mathbb{R} \rightarrow \mathbb{R}$ existe uma única medida de probabilidade \mathbb{P} em $(\mathbb{R}, \mathcal{B}(\mathbb{R}))$ tal que $\mathbb{P}(-\infty, x] = F(x)$ (ver [18]).

Exemplo: $F(x) = \int_{-\infty}^x f(t)dt$ onde $f : \mathbb{R} \rightarrow \mathbb{R}$, não negativa com $\int_{-\infty}^{\infty} f(t)dt = 1$, dita função densidade de probabilidade.

Por exemplo, $f(x) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{(x-m)^2}{2\sigma^2}}$ é uma densidade de probabilidade, dita normal/Gaussiana com parâmetros $m \in \mathbb{R}, \sigma > 0$.

Definição 2.5 Dizemos que uma propriedade S em $(\Omega, \mathcal{F}, \mathbb{P})$ vale \mathbb{P} quase-certamente (\mathbb{P} – qc ou com \mathbb{P} probabilidade um) se existe um conjunto $\Omega_0 \in \mathcal{F}$ com $\mathbb{P}(\Omega_0) = 1$ tal que a propriedade S é satisfeita $\forall \omega \in \Omega_0$.

Obs: Em geral, o conjunto $\{\omega \in \Omega : \omega \text{ satisfaz } S\} \subset \Omega_0$ não é necessariamente mensurável. Porém, se $(\Omega, \mathcal{F}, \mathbb{P})$ for *completo* (ou seja, se \mathcal{F} contém todo subconjunto de conjuntos de probabilidade zero), isto é verdade. Como todo espaço de probabilidade pode ser completado, supomos sempre que trabalhamos com $(\Omega, \mathcal{F}, \mathbb{P})$ completo (ver [18]).

Definição 2.6 Dado um espaço de probabilidade $(\Omega, \mathcal{F}, \mathbb{P})$, uma variável aleatória (va) é uma função

$$X : \Omega \rightarrow \mathbb{R}$$

$$\omega \mapsto X(\omega),$$

$$\text{tal que } \forall B \in \mathcal{B}(\mathbb{R}), \{\omega \in \Omega : X(\omega) \in B\} \equiv X^{-1}(B) \in \mathcal{F}.$$

Obs: Isto garante que faz sentido calcular $\mathbb{P}(X^{-1}(B)) \equiv \mathbb{P}_X(B)$; não é difícil checar que $\mathbb{P}_X(\cdot)$ é uma medida de probabilidade em $\mathcal{B}(\mathbb{R})$ chamada de distribuição da va X .

Em teoria da medida, uma va nada mais é que uma função $\mathcal{F}/\mathcal{B}(\mathbb{R})$ mensurável.

A noção de independência é crucial em teoria da probabilidade.

Definição 2.7 :

1. Eventos $A, B \in \mathcal{F}$ são independentes se $\mathbb{P}(A \cap B) = \mathbb{P}(A)\mathbb{P}(B)$; uma coleção $\{A_i\}_{i \in I}$ de eventos é independente se, para todo subconjunto finito $J \subset I$:

$$\mathbb{P}(\cap_{i \in J} A_i) = \prod_{i \in J} \mathbb{P}(A_i).$$

2. Uma coleção $\{\mathcal{Q}_i\}_{i \in I}$, onde cada \mathcal{Q}_i é uma coleção de eventos, é independente se, para todo $J \subset I$ finito tem-se $\mathbb{P}(\cap_{i \in J} A_i) = \prod_{i \in J} \mathbb{P}(A_i)$, onde $A_i \in \mathcal{Q}_i$.
3. Uma coleção $\{X_i\}_{i \in I}$ de va's é independente quando $\{\sigma(X_i)\}_{i \in I}$ é independente.

Obs: $\sigma(X_i)$ é a σ -álgebra gerada por todos os conjuntos da forma $X^{-1}(B)$, $B \in \mathcal{B}(\mathbb{R})$.

2.1**Esperança/Valor médio/Valor esperado**

Lembramos o processo de construção da esperança de uma variável aleatória.

Seja X uma va simples, isto é, $X(\omega) = \sum_{i=1}^n a_i \mathbb{I}_{A_i}(\omega)$, $A_i \in \mathcal{F}$, $\Omega = \sum_{i=1}^n A_i$ (união disjunta), onde os a_i 's são todos distintos (pense $A_i = \{\omega \in \Omega : X(\omega) = a_i\}$), e $\mathbb{I}_{A_i}(\omega) = \begin{cases} 1, & \text{se } \omega \in A_i, \\ 0, & \text{caso contrário.} \end{cases}$, chamada a função indicadora de A_i .

Se X é simples definimos a esperança de X por: $E[X] \equiv \sum_{i=1}^n a_i \mathbb{P}(A_i)$.

Em seguida, se $X \geq 0$, existe sequência não-decrescente $\{X_n\}_{n \geq 1}$ de va's simples, não negativas, tal que $\forall \omega \in \Omega$:

$$X(\omega) = \lim_{n \rightarrow \infty} X_n(\omega). \text{ Então define-se nesse caso:}$$

$$E[X] = \lim_{n \rightarrow \infty} E[X_n] \text{ (podendo ser } +\infty).$$

Finalmente, se X é uma va qualquer, como $X = X^+ - X^-$, onde $X^+ = \max(X, 0)$ e $X^- = \max(-X, 0)$, define-se: $E[X] = E[X^+] - E[X^-]$, desde que $E[X^+] < \infty$ ou $E[X^-] < \infty$.

Obs: Se $E[|X|] < \infty$, X é dita integrável.

Notação: $E[X] = \int_{\Omega} X(\omega) \mathbb{P}(d\omega) = \int_{\Omega} X d\mathbb{P}$ (integral de Lebesgue com respeito a \mathbb{P}). Note também que:

$$E[X \mathbb{I}_A] = \int_{\Omega} X \mathbb{I}_A d\mathbb{P} \equiv \int_A X d\mathbb{P}.$$

Propriedades básicas(ver [5]):

1. Se X, Y são integráveis, então $\alpha X + \beta Y$ é integrável e
 $E[\alpha X + \beta Y] = \alpha E[X] + \beta E[Y]$, $\alpha, \beta \in \mathbb{R}$ (linearidade);
2. $|E[X]| \leq E|X|$;
3. Se X, Y são integráveis e independentes, então XY é integrável e
 $E[XY] = E[X]E[Y]$;
4. Se X é uma va e $g : \mathbb{R} \rightarrow \mathbb{R}$ uma função mensurável tal que
 $E|g(X)| < +\infty$, então,
 $E[g(X)] = \int_{\Omega} g(X(\omega))\mathbb{P}(d\omega) = \int_{\mathbb{R}} g(x)\mathbb{P}_X(dx)$;
(Se X tem densidade f , então $E[g(X)] = \int_{-\infty}^{+\infty} g(x)f(x)dx$).
5. Se $X(\omega) = 0, \forall \omega \in N^c$, onde $N \in \mathcal{F}, \mathbb{P}(N) = 0$, então X é integrável
e $E[X] = 0$ (Em particular, se X, Y são integráveis e $X = Y \mathbb{P} - qc$,
então $E[X] = E[Y]$);
6. Se $g : \mathbb{R} \rightarrow [0, \infty]$ é $\mathcal{B}(\mathbb{R})$ -mensurável e não-decrescente, então:
 $g(c)\mathbb{P}(X \geq c) \leq E[g(X)]$, $c \in \mathbb{R}$ (Desigualdade de Markov).

Observações:

1. $X = Y \mathbb{P} - qc \iff \mathbb{P}(\omega \in \Omega : X(\omega) = Y(\omega)) = 1$.
2. X é va, $E[X^2] < \infty \implies E[|X|] < \infty$ e definimos a *variância* de X
 $Var(X) \equiv E[(X - E[X])^2] = E[X^2] - (E[X])^2$, e $\sqrt{Var(X)}$ chama-se
desvio padrão.

Exemplo: Se X é uma va normal com parâmetros $m \in \mathbb{R}, \sigma > 0$,
temos:

$$E[X] = \frac{1}{\sqrt{2\pi\sigma^2}} \int_{-\infty}^{+\infty} xe^{-\frac{(x-m)^2}{2\sigma^2}} dx = m,$$

e

$$Var(X) = E[X^2] - (E[X])^2 = \frac{1}{\sqrt{2\pi\sigma^2}} \int_{-\infty}^{+\infty} xe^{-\frac{(x-m)^2}{2\sigma^2}} dx - m^2 = \sigma^2$$

Notação: $X \stackrel{d}{=} N(m, \sigma^2)$.

3. Definimos $L^1(\Omega, \mathcal{F}, \mathbb{P})$ como sendo o espaço das va's integráveis (identificadas a menos de um conjunto de probabilidade zero), que é um espaço vetorial normado completo, isto é, um espaço de Banach (ver [5]) com norma:

$$\|X\|_1 = E[|X|]$$

$$\text{(mais geralmente } L^p(\Omega, \mathcal{F}, \mathbb{P}), \|X\|_p = (E[|X|^p])^{\frac{1}{p}}, p \geq 1)$$

Definição 2.8 (Noções de convergência de va's) *Seja $\{X_n\}_{n \geq 1}$ sequência de va's e X va. Então dizemos que $\{X_n\}_{n \geq 1}$ converge a X :*

1. \mathbb{P} -qc quando

$$\mathbb{P}(\omega \in \Omega : X_n(\omega) \xrightarrow{n \uparrow \infty} X(\omega)) = 1.$$

2. Em probabilidade, se $\forall \epsilon > 0$

$$\mathbb{P}(\omega \in \Omega : |X_n(\omega) - X(\omega)| \geq \epsilon) \xrightarrow{n \uparrow \infty} 0.$$

3. Em $L^p(\Omega, \mathcal{F}, \mathbb{P})$ se

$$\|X - X_n\|_p^p = E[|X - X_n|^p] \xrightarrow{n \uparrow \infty} 0.$$

2.2

Esperança Condicional

A noção de dependência pode ser formalizada pela noção de condicionamento.

Dado $(\Omega, \mathcal{F}, \mathbb{P})$, $B \in \mathcal{F}$ tal que $\mathbb{P}(B) > 0$, definimos a probabilidade condicional de $A \in \mathcal{F}$ dado B por

$$\mathbb{P}_B(A) = \mathbb{P}(A|B) = \frac{\mathbb{P}(A \cap B)}{\mathbb{P}(B)}.$$

Se A e B são independentes então $\mathbb{P}_B(A) = \mathbb{P}(A)$.

Note que $\mathbb{P}_B(\cdot)$ é uma medida de probabilidade em (Ω, \mathcal{F}) com $\mathbb{P}_B(B) = 1$ e $\mathbb{P}_B(B^c) = 0$. Dada uma va integrável X , definimos a esperança condicional de X dado B por: $E[X|B] \equiv \frac{E[X\mathbb{I}_B]}{\mathbb{P}(B)}$.

Obs: Não é difícil checar que se $\Omega = \sum_{n=1}^{+\infty} A_n$ (união disjunta), $A_n \in \mathcal{F}$, $\mathbb{P}(A_n) > 0$, então $E[X] = \sum_{n=1}^{+\infty} E[X|A_n]\mathbb{P}(A_n)$.

A seguir, suponha que $\Omega = \sum_{i=1}^n B_i$, $\mathbb{P}(B_i) > 0$. Seja $\mathcal{D} = \sigma(\{B_i\}_{i=1}^n)$, então definimos a esperança condicional com respeito à σ -álgebra \mathcal{D} denotada por $E[X|\mathcal{D}]$, como a va simples dada por:

$$E[X|\mathcal{D}](\omega) = \sum_{i=1}^n E[X|B_i]\mathbb{I}_{B_i}(\omega), \quad \forall \omega \in \Omega.$$

Note que $E[X|\mathcal{D}]$ é \mathcal{D} -mensurável e $E[E[X|\mathcal{D}]\mathbb{I}_D] = E[X\mathbb{I}_D], \forall D \in \mathcal{D}$. Estas duas propriedades motivam a definição geral de esperança condicional.

Definição 2.9 Dado um espaço de probabilidade $(\Omega, \mathcal{F}, \mathbb{P})$, X uma variável aleatória tal que $E[|X|] < \infty$, e $\mathcal{G} \subset \mathcal{F}$ uma sub- σ -álgebra de \mathcal{F} , então a esperança condicional de X com respeito a \mathcal{G} é aquela variável aleatória, denotada por $E[X|\mathcal{G}]$, tal que

- a) $E[X|\mathcal{G}]$ é \mathcal{G} -mensurável;
- b) $E[E[X|\mathcal{G}]\mathbb{I}_D] = E[X\mathbb{I}_D], \forall D \in \mathcal{G}$.

Obs: Pode-se mostrar que tal va existe (ver [18]).

Note que $E[X|\mathcal{G}]$ é definida a menos de um conjunto de probabilidade zero e qualquer va Z que satisfaz a definição acima chama-se uma *versão* de $E[X|\mathcal{G}]$.

Algumas propriedades da esperança condicional:

- (i) Se Z é qualquer versão de $E[X|\mathcal{G}]$, então $E[X] = E[Z]$;
- (ii) $E[\alpha X + \beta Y|\mathcal{G}] = \alpha E[X|\mathcal{G}] + \beta E[Y|\mathcal{G}]$
 $\mathbb{P} - qc$, $\alpha, \beta \in \mathbb{R}$ (linearidade);
- (iii) Se X é \mathcal{G} -mensurável, então $E[X|\mathcal{G}] = X \mathbb{P} - qc$.
- (iv) Se $X \geq 0 \mathbb{P} - qc$, então $E[X|\mathcal{G}] \geq 0 \mathbb{P} - qc$ (positividade);
- (v) Se X é independente de \mathcal{G} , então $E[X|\mathcal{G}] = E[X] \mathbb{P} - qc$.
- (vi) Se X é \mathcal{G} -mensurável, Y e XY integráveis, então $E[XY|\mathcal{G}] = XE[Y|\mathcal{G}] \mathbb{P} - qc$;
- (vii) Se \mathcal{A}, \mathcal{G} são sub- σ -álgebras com $\mathcal{A} \subset \mathcal{G} \subset \mathcal{F}$, então $E[E[X|\mathcal{A}|\mathcal{G}] = E[E[X|\mathcal{G}|\mathcal{A}]] = E[X|\mathcal{A}] \mathbb{P} - qc$ (propriedade de iteração ou da torre);
- (viii) Se $\varphi : \mathbb{R} \rightarrow \mathbb{R}$ é convexa e $E[|\varphi(X)|] < \infty$, então $E[\varphi(X)|\mathcal{G}] \leq \varphi(E[X|\mathcal{G}]) \mathbb{P} - qc$. (desigualdade de Jensen condicional)

2.3

Martingais em tempo discreto

Estamos agora em condições de definir o conceito fundamental de martingal. Precisamos da noção de filtração:

Definição 2.10 Um espaço com filtração $(\Omega, \mathcal{F}, \mathbb{P}, \mathbb{F})$ consiste em um espaço de probabilidade $(\Omega, \mathcal{F}, \mathbb{P})$ munido de uma filtração $\mathbb{F} = \{\mathcal{F}_n\}_{n \geq 1}$, isto é, uma coleção crescente de sub- σ -álgebras de \mathcal{F} , isto é,

$$\mathcal{F}_1 \subseteq \mathcal{F}_2 \subseteq \mathcal{F}_3 \subseteq \dots \subseteq \mathcal{F}$$

Intuição: Em diversos modelos (por exemplo, em finanças), \mathbb{F} representa a “estrutura informacional” ou como a informação é disponibilizada no tempo. Usualmente \mathbb{F} é o *filtro natural* associado a uma sequência $\mathbb{X} = \{X_n\}_{n \geq 0}$, isto é, $\mathcal{F}_n = \sigma(X_0, X_1, \dots, X_n)$, que é a “história” do processo até o instante n . A monotonicidade indica que a informação é acumulada sem ser perdida ao longo do tempo.

Obs: Uma sequência $\{X_n\}_{n \geq 1}$ de va's é chamada *processo estocástico em tempo discreto*.

Definição 2.11 Um processo $\mathbb{X} = \{X_n\}_{n \geq 0}$ é dito \mathbb{F} -adaptado se para todo $n \geq 0$, X_n é \mathcal{F}_n - mensurável.

Intuição: Se \mathbb{X} é \mathbb{F} -adaptado, $X_n(\omega)$ é “conhecido” no instante n .

Obs: Se $\mathcal{F}_n = \sigma(Y_0, Y_1, \dots, Y_n)$ para algum processo $\mathbb{Y} = \{Y_n\}_{n \geq 0}$, então nesse caso X_n é \mathcal{F}_n - mensurável se, e somente se, $X_n = f_n(Y_0, Y_1, \dots, Y_n)$ para alguma função $f_n : \mathbb{R}^{n+1} \rightarrow \mathbb{R}$ que é $\mathcal{B}(\mathbb{R}^{n+1})$ - mensurável (ver [18]). Note que um processo \mathbb{X} é automaticamente adaptado ao seu filtro natural.

Definição 2.12 Um processo $\mathbb{X} = \{X_n\}_{n \geq 0}$ em $(\Omega, \mathcal{F}, \mathbb{P}, \mathbb{F})$ é um martingal (ou um (\mathbb{P}, \mathbb{F}) -martingal) quando,

1. \mathbb{X} é \mathbb{F} -adaptado;
2. $E[|X_n|] < \infty \forall n \geq 0$;
3. $E[X_{n+1} | \mathcal{F}_n] = X_n$ \mathbb{P} -q.c., $\forall n \geq 0$.

\mathbb{X} é um sub (respectivamente super) - martingal se em 3. a igualdade é trocada por \geq (resp. \leq).

Observações:

- (i) Martingais são processos “constantes em média”, no sentido de que $E[X_1] = E[X_2] = E[X_3] = \dots$, enquanto que sub (resp. super) martingais são “crescentes (resp. decrescentes) em média”;
- (ii) \mathbb{X} é super-martingal $\iff -\mathbb{X} = \{-X_n : n \geq 0\}$ é submartingal;
- (iii) \mathbb{X} é martingal $\iff \mathbb{X}$ é sub e super martingal (simultaneamente);
- (iv) \mathbb{X} com $X_0 \in L^1(\Omega, \mathcal{F}_0, \mathbb{P})$ é martingal (sub/super) $\iff \mathbb{X} - X_0 \equiv \{X_n - X_0 : n \geq 1\}$ é martingal (sub/super); Logo podemos supor $X_0 \equiv 0$;
- (v) Usando a propriedade da iteração da esperança condicional mostra-se que a propriedade β . na definição 2.12 equivale a $E[X_n | \mathcal{F}_m] = X_m$, $n > m$.

Exemplos:

1. Se $\{X_n\}_{n \geq 1}$ são v.a.'s i.i.d com $E[|X_n|] < \infty$ e $E[X_n] = 0$, $n \geq 1$, $\mathcal{F}_n = \sigma(X_0, X_1, \dots, X_n)$, $\mathcal{F}_0 = \{\phi, \Omega\}$ e $S_n \equiv \sum_{k=1}^n X_k$, então $\mathbb{S} = \{S_n : n \geq 0\}$ é (\mathbb{P}, \mathbb{F}) - martingal.

Intuição: O exemplo acima pode ser generalizado. Considere o seguinte jogo bastante simples. Uma moeda, não necessariamente honesta, é lançada sucessivamente e observa-se a face resultante. Se der cara, o jogador ganha a aposta (que é, digamos, paga pela banca de um cassino) e se der coroa ele perde (e paga à banca).

Supondo que os lançamentos sucessivos da mesma moeda sejam completamente independentes, podemos modelar a evolução do jogo através de uma sequência de variáveis aleatórias $\{X_n\}_{n \geq 0}$ independentes e com distribuição de Bernoulli:

$$\mathbb{P}(X_n = 1) = p \text{ e } \mathbb{P}(X_n = -1) = q,$$

onde $p + q = 1$ e associamos o valor 1 (respectivamente -1) quando der cara (respectivamente coroa). Isto é, $\{X_n\}_{n \geq 0}$ é um processo estocástico em tempo discreto. Seja $\mathcal{F}_n = \sigma(X_0, \dots, X_n)$ um filtro natural.

No instante $n - 1$ (já feito o lançamento correspondente) não sabemos o resultado do lançamento seguinte. Portanto, se H_n é o valor apostado sobre o resultado do instante n , H_n deve depender somente da informação disponível até o instante imediatamente anterior, $n - 1$. Isto é,

$$H_n = H_n(X_0, X_1, \dots, X_{n-1})$$

é uma função mensurável com respeito à \mathcal{F}_{n-1} , para todo $n \geq 1$. Um processo $\{H_n\}_{n \geq 1}$ tal que $H_n \in \mathcal{F}_{n-1}$ é dito *predizível*. No nosso exemplo $\{H_n\}_{n \geq 1}$ pode se pensado como uma *estratégia de aposta*.

Ora, se V_{n-1} é o montante que o apostador possui no instante $n - 1$, então, seguindo sua estratégia, o saldo no instante n será dado por:

$$V_n = V_{n-1} + H_n X_n = V_0 + \sum_{k=1}^n H_k X_k,$$

e o seu ganho esperado na n -ésima jogada é

$$\begin{aligned} E[V_n - V_{n-1} \mid \mathcal{F}_{n-1}] &= E[H_n X_n \mid \sigma(X_0, X_1, \dots, X_{n-1})] \\ &= H_n E[X_n \mid X_0, X_1, \dots, X_{n-1}] = H_n(p - q). \end{aligned}$$

Note que para $p = q = \frac{1}{2}$, correspondendo a um jogo “honesto”, tem-se

$$E[V_n \mid \mathcal{F}_{n-1}] = V_{n-1},$$

e o processo $\{V_n\}_{n \geq 0}$ é um martingal. Quando $p \leq q$ (respectivamente $p \geq q$), correspondendo a um jogo “desfavorável” (respectivamente “favorável”) tem-se $E[V_n \mid \mathcal{F}_{n-1}] \leq V_{n-1}$, (respectivamente $E[V_n \mid \mathcal{F}_{n-1}] \geq V_{n-1}$) o processo é chamado **supermartingal** (respectivamente **submartingal**).

2. Seja \mathbb{F} filtração e $X \in L^1(\Omega, \mathcal{F}, \mathbb{P})$, então se $M_n \equiv E[X \mid \mathcal{F}_n]$, $\{M_n\}_{n \geq 1}$ é (\mathbb{P}, \mathbb{F}) - martingal.

A seguinte noção é extremamente importante para o Teorema de Doob:

Definição 2.13 *Seja $(\Omega, \mathcal{F}, \mathbb{P}, \mathbb{F})$ espaço com filtração. Uma função $\tau : \Omega \rightarrow \mathbb{N} \cup \{\infty\}$ é um Tempo de Parada (TP) quando $\forall n \in \mathbb{N} = \{0, 1, 2, \dots\}$,*

$$\{\tau = n\} \equiv \{\omega \in \Omega : \tau(\omega) = n\} \in \mathcal{F}_n.$$

Observações:

1. τ pode tomar valor $+\infty$, por exemplo, modelando o tempo de espera de um evento que nunca ocorre.
2. Note que $\{\tau = +\infty\} = \{\tau < +\infty\}^c = (\bigcup_{n \in \mathbb{N}} \{\tau = n\})^c = \bigcap_{n \in \mathbb{N}} \{\tau = n\}^c \in \mathcal{F}_\infty$. Assim, $\{\tau = n\} \in \mathcal{F}_n, \forall n \in \mathbb{N} \cup \{\infty\}$;

Exemplo: O primeiro instante que um conjunto é atingido: Seja $\{X_n\}_{n \geq 0}$ processo \mathbb{F} -adaptado e $A \in \mathcal{B}(\mathbb{R})$, então $\tau \equiv \inf\{n \in \mathbb{N} : X_n \in A\}$ (onde $\inf \emptyset \equiv 0$) é um tempo de parada pois, $\forall n \in \mathbb{N}$:

$$\{\tau = n\} = \{X_0 \in A^c, X_1 \in A^c, \dots, X_{n-1} \in A^c\} \in \mathcal{F}_n.$$

Definição 2.14 *Seja τ um TP então definimos*

$$\mathcal{F}_\tau \equiv \{A \in \mathcal{F}_\infty : A \cap \{\tau = n\} \in \mathcal{F}_n, \forall n \in \mathbb{N}\} \subset \mathcal{F}_\infty$$

chamada σ -álgebra da “informação disponível até o instante τ ”.

Alguns fatos básicos (ver [5]):

1. \mathcal{F}_τ é σ -álgebra;
2. Se $\tau \equiv k \in \mathbb{N}$, então τ é TP e $\mathcal{F}_\tau = \mathcal{F}_k$;
3. Se τ é TP e $B \in \mathcal{F}_\tau$, então $B \cap \{\tau = \infty\} \in \mathcal{F}_\infty$ e portanto $B \cap \{\tau = n\} \in \mathcal{F}_n \forall n \in \mathbb{N} \cup \{\infty\}$;
4. τ é TP $\iff \{\tau \leq n\} \in \mathcal{F}_n, \forall n \in \mathbb{N} \iff \{\tau > n\} \in \mathcal{F}_n, \forall n \in \mathbb{N}$;
5. Se $B \in \mathcal{F}_\infty$ então $B \in \mathcal{F}_\tau \iff B \cap \{\tau \leq n\} \in \mathcal{F}_n \forall n \in \mathbb{N}$;
6. Se τ_1 e τ_2 são tempos de parada, então $\tau_1 + \tau_2$ é tempo de parada;
7. Se $\{\tau_k\}_{k \geq 1}$ são tempos de parada, então $\sup_k \tau_k$ e $\inf_k \tau_k$ são tempos de parada (exemplo, $\tau_n \equiv \min(\tau, n) = \tau \wedge n$);
8. Se $\{\tau_k\}_{k \geq 1}$ é sequência monótona de tempos de parada então $\lim_{k \rightarrow \infty} \tau_k$ é TP.
9. $\tau_1 \leq \tau_2 \Rightarrow \mathcal{F}_{\tau_1} \subseteq \mathcal{F}_{\tau_2}$;

10. Se $\{X_n\}_{n \in \mathbb{N}}$ é \mathbb{F} -adaptado e τ é TP, $\mathbb{P}(\tau < +\infty) = 1$, definimos

$$X_\tau(\omega) \equiv \sum_{m=0}^{+\infty} X_m \mathbb{I}_{\{\tau=m\}}(\omega).$$

Então X_τ é v.a e além disso é \mathcal{F}_τ - mensurável;

11. Em particular se $\{X_n\}_{n \in \mathbb{N}}$ é martingal (super/sub) então o “processo truncado em τ ”, $\{X_n^\tau \equiv X_{\tau \wedge n}\}_{n \in \mathbb{N}}$ é um (super/sub) \mathbb{F} -martingal.

De fato,

$$\begin{aligned} X_{\tau \wedge n} &= X_{\tau \wedge n} \mathbb{I}_{\{\tau \leq n-1\}} + X_{\tau \wedge n} \mathbb{I}_{\{\tau \geq n\}} \\ &= X_\tau \mathbb{I}_{\{\tau \leq n-1\}} + X_n \mathbb{I}_{\{\tau \geq n\}} \\ &= \sum_{m=0}^{n-1} X_m \mathbb{I}_{\{\tau=m\}} + X_n \mathbb{I}_{\{\tau \geq n\}}. \end{aligned}$$

Logo $X_{\tau \wedge n}$ é \mathcal{F}_n - mensurável e integrável Assim:

$$X_{n+1}^\tau - X_n^\tau = (X_{n+1} - X_n) \mathbb{I}_{\{\tau \geq n+1\}}.$$

Lembrando que $\{\tau \geq n+1\} = \{\tau \leq n\}^c \in \mathcal{F}_n$ e das propriedades da esperança condicional, temos:

$$\begin{aligned} E[X_{n+1}^\tau - X_n^\tau | \mathcal{F}_n] &= E[(X_{n+1} - X_n) \mathbb{I}_{\{\tau \geq n+1\}} | \mathcal{F}_n] \\ &= \mathbb{I}_{\{\tau \geq n+1\}} E[X_{n+1} - X_n | \mathcal{F}_n] = 0. \end{aligned}$$

Na última parte da tese precisaremos do seguinte resultado, uma versão do Teorema da Parada Ótima de Doob (ou Teorema da Amostragem Opcional). Este resultado afirma que sob certas condições a propriedade de (super) martingal é preservada entre instantes dados por tempos de parada.

Teorema 2.15 *Seja $\mathbb{X} = \{X_n\}_{n \in \mathbb{N}}$ um supermartingal em $(\Omega, \mathcal{F}, \mathbb{P}, \mathbb{F})$ e sejam τ_1 e τ_2 tempos de parada limitados \mathbb{P} -qc com $\mathbb{P}(\tau_1 \leq \tau_2) = 1$. Então X_{τ_1} e X_{τ_2} são integráveis e*

$$E[X_{\tau_2} | \mathcal{F}_{\tau_1}] \leq X_{\tau_1} \quad \mathbb{P}\text{-qc.}$$

Demonstração: Seja $k \in \mathbb{N}$ um majorante de τ_2 . Então

$$|X_{\tau_i}| \leq \sum_{j=1}^k |X_j|,$$

e portanto X_{τ_i} , $i = 1, 2$ é integrável. Agora, suponha que fosse $\tau_2 \equiv k \in \mathbb{N}$. Seja $A \in \mathcal{F}_{\tau_1}$. Como $A \cap \{\tau_1 = j\} \in \mathcal{F}_j$ temos para $j \leq k$, usando a propriedade de supermartingal, que:

$$\int_{A \cap \{\tau_1 = j\}} X_{\tau_1} d\mathbb{P} = \int_{A \cap \{\tau_1 = j\}} X_j d\mathbb{P} \geq \int_{A \cap \{\tau_1 = j\}} X_k d\mathbb{P}$$

Então, somando em $j = 0, 1, \dots, k$,

$$\int_A X_{\tau_1} d\mathbb{P} = \sum_{j=0}^k \int_{A \cap \{\tau_1 = j\}} X_j d\mathbb{P} \geq \sum_{j=0}^k \int_{A \cap \{\tau_1 = j\}} X_k d\mathbb{P} = \int_A X_{\tau_2} d\mathbb{P}$$

o que demonstra o teorema no caso de $\tau_2 \equiv k$. Suponha agora que $\tau_2 \leq k$ (não constante). Aplicamos o resultado anterior para o supermartingal truncado $\{X_n^{\tau_2}\}_{n \geq 0}$ e para tempos de parada τ_1 e k . Então temos, $\forall A \in \mathcal{F}_{\tau_1}$:

$$\int_A X_{\tau_1} d\mathbb{P} = \int_A X_{\tau_1}^{\tau_2} d\mathbb{P} \geq \int_A X_k^{\tau_2} d\mathbb{P} = \int_A X_{\tau_2} d\mathbb{P}. \square$$

Corolário Se \mathbb{X} é martingal, sob as hipóteses acima então $E[X_{\tau_2} | \mathcal{F}_{\tau_1}] = X_{\tau_1}$ \mathbb{P} -qc.

Demonstração: Basta aplicar o resultado anterior a \mathbb{X} e $-\mathbb{X}$. \square

2.4

Integrabilidade Uniforme e Convergência em L^1

Afim de generalizar o teorema de Doob para o caso de tempo contínuo, a ser utilizado no cap. 3, vamos precisar de alguns resultados sobre integrabilidade uniforme e convergência de martingais.

Definição 2.16 Uma coleção ζ de variáveis aleatórias em $(\Omega, \mathcal{F}, \mathbb{P})$ é dita Uniformemente Integrável (UI) se

$$\lim_{a \rightarrow \infty} \sup_{X \in \zeta} E[|X| \mathbb{I}_{\{|X| > a\}}] = 0.$$

Equivalentemente, dado $\epsilon > 0$, existe $k \geq 0$ tal que $\forall X \in \zeta$:

$$E[|X| \mathbb{I}_{\{|X| > k\}}] < \epsilon.$$

Observações:

1. Se ζ é coleção UI então tomando k_1 associada a $\epsilon = 1$ temos $\forall X \in \zeta$:

$$E|X| = E[|X| \mathbb{I}_{\{|X| > k_1\}}] + E[|X| \mathbb{I}_{\{|X| \leq k_1\}}] \leq 1 + k_1 < +\infty,$$

ou seja, $\forall X \in \zeta : X \in L^1(\Omega, \mathcal{F}, \mathbb{P})$. Isto é, uma família UI de variáveis aleatórias é necessariamente limitada em $L^1(\Omega, \mathcal{F}, \mathbb{P})$. Porém, não vale a recíproca. Por exemplo, seja $(\Omega, \mathcal{F}, \mathbb{P}) = ([0, 1], \mathcal{B}[0, 1], \lambda)$ e considere $\{X_n\}_{n \geq 1}$, onde $X_n \equiv n \mathbb{I}_{B_n}$, onde $B_n = (0, \frac{1}{n})$, mas dado $k > 0$, $\forall n > k$

$$E[|X| \mathbb{I}_{\{|X| > k\}}] = n \mathbb{P}(B_n) = 1,$$

portanto ζ não é UI.

2. Um critério simples para UI: dominação.

Se existe $Y \in L^1(\Omega, \mathcal{F}, \mathbb{P})$, tal que $\forall X \in \zeta : |X| \leq Y$ \mathbb{P} -qc, então ζ é UI. De fato:

$$\sup_{X \in \zeta} E[|X| \mathbb{I}_{\{|X| > a\}}] \leq E[Y \mathbb{I}_{\{|X| > a\}}] \xrightarrow{a \uparrow +\infty} 0$$

Em particular, se $X_i \in L^1(\Omega, \mathcal{F}, \mathbb{P})$, $i = 1, \dots, n$ então $\zeta = \{X_1, \dots, X_n\}$ é UI pois $\forall i = 1, \dots, n$

$$|X_i| \leq \sum_{j=1}^n |X_j| = Y \in L^1(\Omega, \mathcal{F}, \mathbb{P})$$

Proposição 2.17 *Seja $X \in L^1(\Omega, \mathcal{F}, \mathbb{P})$; então a coleção $\zeta = \{E[X|\mathcal{G}] : \mathcal{G}$ é sub- σ -álgebra de $\mathcal{F}\}$ é UI.*

Demonstração : Seja \mathcal{G} uma sub- σ -álgebra de \mathcal{F} e Y uma versão de $E[X|\mathcal{G}]$. Pela desigualdade de Jensen condicional: $|Y| \leq E[|X||\mathcal{G}]$ \mathbb{P} -q.c e então:

$$\begin{aligned} & \int_{\{|Y| \geq a\}} |Y| d\mathbb{P} \leq \int_{\{|Y| \geq a\}} E[|X||\mathcal{G}] d\mathbb{P} \leq \\ & \leq \int_{\{|Y| \geq a; |X| \leq b\}} |X| d\mathbb{P} + \int_{\{|Y| \geq a; |X| > b\}} |X| d\mathbb{P} \leq b\mathbb{P}(|Y| \geq a) + \int_{\{|X| > b\}} |X| d\mathbb{P} \\ & \leq \frac{b}{a} E[|Y|] + \int_{\{|X| > b\}} |X| d\mathbb{P} \leq \frac{b}{a} E[|X|] + E[|X| \mathbb{I}_{\{|X| > b\}}] \end{aligned}$$

que vai a zero quando fazemos $a \rightarrow +\infty$ e então $b \rightarrow +\infty$, ou seja,

$$\lim_{a \rightarrow \infty} \sup_{Y \in \zeta} E[|Y| \mathbb{I}_{\{|Y| \geq a\}}] = 0,$$

ou seja, ζ é uma família UI.

Proposição 2.18 *Se $\{X_n\}_{n \geq 1}$ é uma sequência UI e $\lim_{n \rightarrow \infty} X_n = X$ \mathbb{P} -qc, então X é integrável e $\lim_{n \rightarrow \infty} E[|X_n - X|] = 0$*

Demonstração : Pelo Lema de Fatou (ver [5]),

$$\begin{aligned} E|X| &= E\left[\lim_{n \rightarrow +\infty} |X_n|\right] \leq \lim_{n \rightarrow +\infty} E[|X_n|] \leq \sup_n E[|X_n|] \\ &\leq \sup_n E[|X_n| \mathbb{I}_{\{|X_n| > a\}}] + a < +\infty \\ &\Rightarrow X \in L^1(\Omega, \mathcal{F}, \mathbb{P}) \end{aligned}$$

Agora,

$$|X_n - X| \leq |X_n - X| \mathbb{I}_{\{|X_n| \leq a\}} + |X| \mathbb{I}_{\{|X_n| > a\}} + |X_{\{n\}}| \mathbb{I}_{\{|X_n| > a\}} \quad (*)$$

O primeiro termo é limitado por $(a + |X|) \in L^1$ e portanto novamente pelo Teorema da Convergência Dominada (TCD): $\lim_{n \rightarrow +\infty} E[|X_n - X| \mathbb{I}_{\{|X_n| \leq a\}}] = 0$. O segundo termo é dominado por $|X| \in L^1$ e portanto novamente pelo

TCD temos: $\lim_{n \rightarrow +\infty} E[|X|\mathbb{I}_{\{|X_n|>a\}}] = E[|X|\mathbb{I}_{\{|X|>a\}}]$. A esperança do terceiro termo é $E[|X|\mathbb{I}_{\{|X_n|>a\}}] \leq \sup_n E[|X|\mathbb{I}_{\{|X_n|>a\}}]$. Assim, tomando a esperança em (*) temos:

$$\lim_{n \rightarrow \infty} E|X_n - X| \leq E[|X|\mathbb{I}_{\{|X|>a\}}] + \sup_n E[|X_n|\mathbb{I}_{\{|X_n|>a\}}]$$

que vai a zero quando $a \rightarrow +\infty$. Logo:

$$\|X_n - X\|_1 \xrightarrow{n \uparrow \infty} 0.$$

Proposição 2.19 *Se $\{X_n\}_{n \geq 1}$ é uma sequência UI e $\lim_{n \rightarrow \infty} X_n = X$ \mathbb{P} -q.c, então $\lim_{n \rightarrow +\infty} E[X_n|\mathcal{G}] = E[X|\mathcal{G}]$ em L^1 e em probabilidade.*

Demonstração : Da proposição anterior sabemos que $X_n \xrightarrow{n \uparrow \infty} X$ em L^1 . Agora, pela desigualdade de Jensen condicional:

$$\|E[X|\mathcal{G}]\|_1 \leq \|X\|_1$$

$$\|E[X_n|\mathcal{G}] - E[X|\mathcal{G}]\|_1 \leq \|X_n - X\|_1 \xrightarrow{n \uparrow \infty} 0$$

e portanto $E[X_n|\mathcal{G}] \xrightarrow{n \uparrow \infty} E[X|\mathcal{G}]$ em L^1 . Pela desigualdade de Markov: convergência $L^1 \Rightarrow$ convergência em probabilidade.

2.5

Processos Estocásticos

Dado $(\Omega, \mathcal{F}, \mathbb{P})$ e $\mathbb{T} = [0, +\infty)$ ou $[0, 1]$, então um processo estocástico é uma coleção $\mathbb{X} = \{X_t\}_{t \in \mathbb{T}}$, onde cada X_t é uma variável aleatória.

Note que um processo estocástico pode ser pensado como uma função de duas variáveis

$$\mathbb{X} : \mathbb{T} \otimes \Omega \longrightarrow \mathbb{R}$$

$$(t, \omega) \mapsto \mathbb{X}(t, \omega),$$

onde fixando $t \in \mathbb{T}$, então

$$\mathbb{X}(t, \cdot) : \Omega \longrightarrow \mathbb{R}$$

$$\omega \mapsto \mathbb{X}(t, \omega) = X_t(\omega)$$

é uma va enquanto que fixando $\omega \in \Omega$,

$$\mathbb{X}(\cdot, \omega) : \mathbb{T} \longrightarrow \mathbb{R}$$

$$t \mapsto \mathbb{X}(t, \omega) = X_t(\omega),$$

é a “trajetória” (ou realização) do processo associada a ω .

Várias noções vistas anteriormente para sequências de va's são introduzidas para processos estocásticos. Assim, uma filtração é uma coleção crescente ($\mathcal{F}_t \subseteq \mathcal{F}_s \forall t \leq s$) $\mathbb{F} = \{\mathcal{F}_t\}_{t \in \mathbb{T}}$ de sub- σ -álgebras de \mathcal{F} e um processo $\mathbb{X} = \{X_t\}_{t \in \mathbb{T}}$ é dito \mathbb{F} adaptado se $\forall t \in \mathbb{T}$, X_t é \mathcal{F}_t -mensurável. Usualmente \mathbb{F} é o filtro natural, $\mathcal{F}_t = \sigma(X_s; s \leq t)$ ¹. Da mesma forma, um *tempo de parada* é uma va $\tau : \Omega \longrightarrow \mathbb{T}$ (possivelmente tomando valor $+\infty$) tal que $\forall t \in \mathbb{T}$, $\{\tau \leq t\} \in \mathcal{F}_t$. Define-se também $\mathcal{F}_\tau = \{A \in \mathcal{F} : \forall t \in \mathbb{T}, A \cap \{\tau \leq t\} \in \mathcal{F}_t\}$, que é uma σ -álgebra.

Várias propriedades de tempos de parada continuam valendo em tempo contínuo, por exemplo se τ é tempo de parada, então τ é \mathcal{F}_τ -mensurável, se τ, σ são tempos de parada, então $\tau \vee \sigma, \tau \wedge \sigma$ são tempos de parada, se $\tau \leq \sigma$ são t.p, então $\mathcal{F}_\tau \subseteq \mathcal{F}_\sigma$, etc. (ver [9]).

Exemplo O *processo de Wiener* (ou movimento Browniano) (standard) em $(\Omega, \mathcal{F}, \mathbb{P})$, munido do filtro natural \mathbb{F} , é um processo estocástico $\{W_t\}_{t \in \mathbb{T}}$ tal que

1. $\mathbb{P}(W_0 = 0) = 1$
2. Se $0 \leq s < t$ a va $W_t - W_s = \eta(0, t - s)$ é independente da $\sigma(W_u; u \leq s) = \mathcal{F}_s$ (variação é independente do passado).
3. $t \longrightarrow W_t(\omega)$ são contínuas \mathbb{P} -qc

Obs: Pode-se mostrar que um tal processo existe (ver [5]).

Definição 2.20 Dado espaço de probabilidade $(\Omega, \mathcal{F}, \mathbb{P})$ e uma filtração $\mathbb{F} = \{\mathcal{F}_t\}_{t \in \mathbb{T}}$, um processo $\mathbb{M} = \{M_t\}_{t \in \mathbb{T}}$ é um (\mathbb{P}, \mathbb{F}) -martingal se:

- $\{M_t\}$ é \mathbb{F} adaptado;
- $E|M_t| < \infty, \forall t \in \mathbb{T}$;
- $\forall s \leq t, E[M_t | \mathcal{F}_s] = M_s$ \mathbb{P} -qc

¹Por razões técnicas usualmente supõe-se que a filtração \mathbb{F} satisfaz as chamadas condições usuais, a saber $\forall t \in \mathbb{T}$, \mathcal{F}_t é *completa* e *contínua á direita*, isto é, $\mathcal{F}_t = \bigcap_{s>t} \mathcal{F}_s$, ver [9]

(análogo para sub/super)

Exemplo: Não é difícil checar que o processo de Wiener é um martingal com respeito ao filtro natural.

Lema 2.1 *Seja τ tempo de parada. Então existe uma sequência decrescente $\{\tau_n\}_{n \geq 1}$ de tempo de parada tomando valores num conjunto discreto, tal que $\tau_n \downarrow \tau$ e $\{\tau_n = +\infty\} = \{\tau = \infty\}$.*

Demonstração: Defina $\forall n \geq 1; \omega \in \Omega$:

$$\tau_n(\omega) = \begin{cases} \frac{k+1}{2^n} & \text{se } \frac{k}{2^n} < \tau(\omega) \leq \frac{k+1}{2^n}, k = 0, 1, \dots, \\ +\infty & \text{se } \tau(\omega) = +\infty. \end{cases}$$

Claramente $\tau_n \downarrow \tau$ e se $\frac{k}{2^n} < t \leq \frac{k+1}{2^n}$ temos:

$$\{\tau_n \leq t\} = \{\tau_n \leq \frac{k}{2^n}\} = \{\tau \leq \frac{k}{2^n}\} \in \mathcal{F}_{\frac{k}{2^n}} \subset \mathcal{F}_t$$

$\implies \tau_n$ é tempo de parada. \square

Seja $\{X_t\}_{t \in \mathbb{T}}$ processo estocástico em $(\Omega, \mathcal{F}, \mathbb{P}, \mathbb{T})$ e um tempo de parada τ . Seja

$$X_\tau : \Omega \longrightarrow \mathbb{R} \tag{2-1}$$

$$\omega \longmapsto X_\tau(\omega) = \begin{cases} X(\tau(\omega), \omega) & \text{se } \tau(\omega) < \infty, \\ X & \text{se } \tau(\omega) = +\infty, \end{cases} \tag{2-2}$$

onde X é uma variável aleatória fixa. ($X = X(\infty) = \lim_{t \rightarrow \infty} X_t$ se este limite existe).

Lema 2.2 *Se $\tau < \infty$ ou $X(\infty)$ existe, então X_τ é variável aleatória.*

Demonstração: Assumindo $\{X_t\}_{t \in \mathbb{T}}$ contínuo (ou mesmo contínuo à direita com limites à esquerda), então $X_\tau(\omega) = \lim_{n \rightarrow \infty} X_{\tau_n}(\omega)$, onde $\{\tau_n\}_{n \geq 1}$ é sequência aproximadora para τ . Portanto basta provar que $\forall n \geq 1, X_{\tau_n}$ é mensurável.

Mas, $\forall B \in \mathcal{B}(\mathbb{R})$, temos:

$$\{X_{\tau_n} \in B\} = \{X_\infty \in B, \tau_n = +\infty\} \bigcup_{k=0}^{+\infty} \{X_{\frac{k+1}{2^n}} \in B\} \cap \{\tau_n = \frac{k+1}{2^n}\} \in \mathcal{F}. \quad \square$$

Podemos agora demonstrar a versão em tempo contínuo do teorema da Parada Ótima:

Teorema 2.3 (Teorema da Parada Ótima, tempo contínuo) *Seja* $\{X_t\}_{t \in \mathbb{T}}$ *um* \mathbb{F} -*martingal contínuo (ou cadlag) e* τ_1, τ_2 *tempos de parada com* $\mathbb{P}(\tau_1 \leq \tau_2) = 1$, τ_2 *limitado* \mathbb{P} -*qc. Então,*

$$\mathbb{E}[X_{\tau_2} | \mathcal{F}_{\tau_1}] = X_{\tau_1} \mathbb{P} - qc$$

Demonstração: Primeiro, se $b > 0$ e τ um tempo de parada tomando valores num conjunto finito J , majorados por b , então $\{(M_u, \mathcal{F}_u)\}_{u \in J}$, onde $M_u(\omega) = X_u(\omega)$, $u \in J$ é um martingal discreto. Então, pelo teorema de Doob em tempo discreto com $\sigma_1 = \tau$ e $\sigma_2 = b$ segue que

$$\mathbb{E}[M_{\sigma_2} | \mathcal{F}_{\sigma_1}] = M_{\sigma_1}.$$

Agora, $\mathbb{E}[M_{\sigma_2} | \mathcal{F}_{\sigma_1}] = \mathbb{E}[X_b | \mathcal{F}_{\tau}]$ e

$$M_{\sigma_1}(\omega) = M_{\tau}(\omega) = \sum_{u \in J} M_u(\omega) \mathbb{I}_{\{\tau=u\}}(\omega) = \sum_{u \in J} X_u(\omega) \mathbb{I}_{\{\tau=u\}} = X_{\tau}(\omega).$$

$$\text{Assim, } \mathbb{E}[X_b | \mathcal{F}_{\tau}] = X_{\tau}.$$

Segue então pela proposição 2.17 que a coleção de va's $\{X_{\tau}\}_{\tau}$ onde τ varia sobre a coleção de tempo de parada equilimitados por b e assumindo valores num conjunto finito, é UI.

Agora, sejam $\{\tau_n^{(1)}\}_{n \geq 1}$ e $\{\tau_n^{(2)}\}_{n \geq 1}$, tempos de parada tomando valores num conjunto finito e tais que $\tau_n^{(1)} \downarrow \tau_1$, $\tau_n^{(2)} \downarrow \tau_2$, como construídos no lema 2.1 e tal que $\forall n \geq 1$ $\tau_n^1 \leq \tau_n^2$.

Novamente pelo teorema de Doob em tempo discreto obtemos

$$\mathbb{E}[X_{\tau_n^{(2)}} | \mathcal{F}_{\tau_n^{(1)}}] = X_{\tau_n^{(1)}} \mathbb{P} - qc.$$

e condicionando com respeito a $\mathcal{F}_{\tau_1} \subseteq \mathcal{F}_{\tau_n^{(1)}}$ vem que

$$\mathbb{E}[X_{\tau_n^{(2)}} | \mathcal{F}_{\tau_1}] = \mathbb{E}[X_{\tau_n^{(1)}} | \mathcal{F}_{\tau_1}] \mathbb{P} - qc. (*)$$

Como trajetórias são contínuas (ou contínuas á direita) temos que para $n \uparrow +\infty$, $X_{\tau_n^{(1)}} \rightarrow X_{\tau_1}$ e $X_{\tau_n^{(2)}} \rightarrow X_{\tau_2}$ em toda parte. Como as seqüências $\{X_{\tau_n^{(1)}}\}_{n \geq 1}$ e $\{X_{\tau_n^{(2)}}\}_{n \geq 1}$ são UI, segue pela proposição 2.19, passando ao limite em (*) quando $n \uparrow \infty$ que, em L^1 e em probabilidade,

$$\mathbb{E}[X_{\tau_2} | \mathcal{F}_{\tau_1}] = X_{\tau_1} \mathbb{P} - qc. \quad \square$$