



## Teoria das Probabilidades e Cadeias de Markov.

Marianna Degani\*, Francys Souza, Paulo Ruffino.

### Resumo

Nesse projeto, caracterizamos a probabilidade segundo os axiomas de Kolmogorov [3]. Começamos com as ideias "básicas" (teoria dos conjuntos,  $\sigma$ -álgebra e  $\sigma$ -álgebra de Borel) a partir do qual evoluímos para os conceitos de variável aleatória, esperança vista como integral de Lebesgue [2], Teorema de Radon-Nikodym, esperança condicional e os teoremas limites. Na segunda parte do projeto, caracterizamos filtragem, e processos estocásticos. Nos concentrando em cadeias de Markov [1] no qual estudamos conceitos como tempos de parada, estados de uma cadeia de Markov, probabilidades de transição, autovalores, cadeias irredutíveis e comportamento limite de uma cadeia de Markov.

### Palavras-chave:

Probabilidade,  $\sigma$ -álgebra, Cadeias de Markov.

### Introdução

A probabilidade é o ato de atribuirmos "pesos" aos eventos, mas a qual eventos vamos atribuir probabilidade?

Para responder essa questão adotamos a definição proposta por Kolmogorov (1932) de uma consequência da construção axiomática de probabilidade. Também definimos a integral de Lebesgue, a esperança condicional e o teorema de Radon-Nikodym representando um funcional linear sobre um espaço de Hilbert.

### Resultados e Discussão

Definição 1.1: Um experimento com espaço amostral  $\Omega$  e classe de eventos  $A$ . Além disso, a probabilidade deve satisfazer os seguintes axiomas:

- $\mathbb{P}(\Omega) = 1$  e  $\mathbb{P}(\emptyset) = 0$ .
- $0 \leq \mathbb{P}(A) \leq 1$ , para todo evento  $A$ .
- Para qualquer sequência de eventos mutuamente exclusivos  $A_1, A_2, \dots$ , isto é, eventos para os quais  $A_i \cap A_j = \emptyset$  quando  $i \neq j$  temos

que:

$$\mathbb{P}\left(\bigcup_{i=1}^{\infty} A_i\right) = \sum_{i=1}^{\infty} \mathbb{P}(A_i).$$

Teorema 1.1: Continuidade monótona, presente também na esperança, se  $A_n \uparrow A$ , então  $\mathbb{P}(A_n) \uparrow \mathbb{P}(A)$ , similarmente se  $A_n \downarrow A$  então  $\mathbb{P}(A_n) \downarrow \mathbb{P}(A)$ .

Definição 2.1: Seja uma variável aleatória simples, na forma  $X(\omega) = \sum_{i=1}^n x_i \mathbb{1}_{A_i}(\omega)$ ,  $\omega \in \Omega$ ; no qual  $x_i \in \mathbb{R}$  são números reais distintos e  $\{A_i : i = 1, 2, \dots, n\} \subset A$ , é uma partição de  $\Omega$ . Teorema 2.1: Para todo  $X$ , uma variável aleatória positiva, existe uma sequência de variáveis aleatórias simples que converge pontualmente para  $X$ . Definição 2.2: Esperança como limite de v.a.'s simples:

$$E(X) = \lim_{n \rightarrow \infty} E(X_n) = \lim_{n \rightarrow \infty} \sum_{i=1}^n x_i \mathbb{P}(A_i).$$

Definição 3.1: Seja uma variável aleatória positiva  $X$ , dado a  $\sigma$ -álgebra  $G \subset F$ , é denotada por  $E(X|G)$  é a única ( $\mathbb{P}$ -q.c.) v.a. satisfazendo que  $E[X|G]$  é

$G$ -mensurável e que para todo  $A \in G$  temos  $\int_A X d\mathbb{P} = \int_A E[X|G] d\mathbb{P}$ .

$E[X|G] d\mathbb{P}$ . Teorema 3.1: (Teorema de Radon-Nikodym) Seja  $(X, F, \mu)$  um espaço de medida, com  $\mu$  medida finita. Se  $\nu$  é uma medida finita sobre  $F$  absolutamente contínua com respeito a medida  $\mu$ , então existe uma

função mensurável finita  $f$  sobre  $X$  tal que  $\nu(E) = \int_E f d\mu$

para todo conjunto mensurável  $E$ .

Definição 4.1: Um conjunto de v.a.'s que descrevem a evolução de um sistema ao longo do tempo através da filtragem. Teorema 4.1: Dado  $(\Omega, F, \mathbb{P})$  um espaço de probabilidade, uma coleção de v.a.'s  $\{X(t), t \in T\}$ , onde  $T \subset \mathbb{R}$  é um conjunto de índices. Cada  $X(t)$  assume valores em um conjunto  $S \subset \mathbb{R}$  ( $S$  é o espaço de estados), e  $X(t)$  é o estado do processo no tempo  $t$ . Assim:

$$F_{t_1, \dots, t_n}(x_1, \dots, x_n) = \mathbb{P}\left[\bigcap_{i=1}^n \{\omega \in \Omega / X_{t_i}(\omega) \leq x_i\}\right].$$

Definição 5.1: Seja um processo estocástico  $\{X_n, n \geq 0\}$  assumido valores em  $S \subset \mathbb{Z}$  e descrito por:  $X_n = i$  (o processo está no estado  $i$  no tempo  $n$ ) então existe uma probabilidade fixada  $\mathbb{P}_{ij}$  que esteja no estado  $j$  no tempo  $n+1$ . Isto é, admite-se que:  $\mathbb{P}[X_{n+1} = j | X_n = i, X_{n-1} = i_{n-1}, \dots, X_0 = i_0] = \mathbb{P}[X_{n+1} = j | X_n = i] = \mathbb{P}_{ij}$  para quaisquer estados  $i_0, i_1, \dots, i, j$  e todo  $n \geq 0$ .  $\{X_n, n \geq 0\}$ .

Teorema 5.1: (Chapman-Kolmogorov):

$$\mathbb{P}[X_m = j | X_n = i] = \sum_{m=1}^{\infty} \mathbb{P}_{m-k}[X_m, j] \mathbb{P}_{k-n}[i, X_n]$$

### Conclusões

Foram desenvolvidos conceitos acerca da construção de uma  $\sigma$ -álgebra, em seguida definimos a probabilidade via os axiomas de Kolmogorov. Além disso, definimos propriedades da probabilidade e da esperança (integral de Lebesgue), a qual é uma generalização da integral de Riemann. Em seguida, foi caracterizada a esperança condicional, que mostramos que existe e está bem definida via o teorema de Radon-Nikodym. Por fim, analisou-se processos estocásticos com variáveis aleatórias em diferentes estados ao longo do tempo.

[1] Chung, Kai Lai. *Markov chains*. Berlin: Springer-Verlag, 1967.

[2] Protter, P. E. *Stochastic modelling and applied probability*, 2005.

[3] Shiryaev, A. N. *Probability*, volume 95 of graduate texts in mathematics, 1996.