



TEORIA DE INFORMAÇÃO – UM NANOCURSO

Max H. M. Costa
Unicamp

Set. 2016

Centenário de Shannon - SBrT - Santarém

Dedicação: a memória de Claude Shannon



Claude Shannon – 1916-2001 – matemático,
engenheiro eletrônico, inventor da Teoria de Informação

Sumário

Introdução

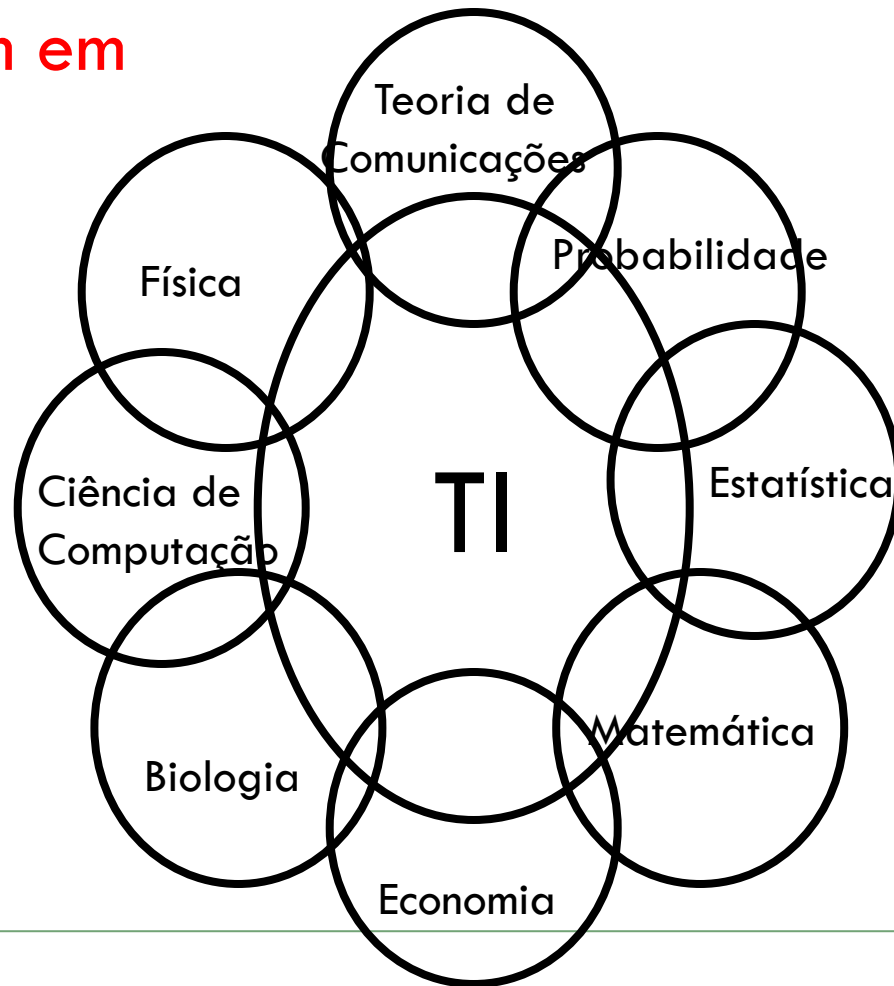
- Teoria de Informação - Interdisciplinaridade
- Entropia, Divergência de K-L, Informação Mútua
- Compressão de dados
- Transmissão por Canais Ruidosos (Codificação de Canal)
- Entropia Diferencial, Canais Gaussianos
- Aplicações de Múltiplos Usuários
- Fechamento

Algumas referências:

- [1] T. Cover and J. Thomas, Elements of Information Theory, Wiley, 2nd ed., 2006 (1991).
- [2] R. Ash, Information Theory, Dover, 1990.
- [3] R. Gallager, Information Theory and Reliable Communication, Wiley, 1968.
- [4] A. El Gamal and Y-H. Kim, Network Information Theory, Cambridge, 2011.
-

Teoria de Informação e Áreas Afins

- A paisagem em
- torno de TI:



Entropia

- Definição: $H(X)$ = A Entropia de X
- Seja X uma variável aleatória discreta com valores
- em $\{x_1, x_2, \dots, x_M\}$ com probabilidades
- $\mathbf{p} = \{p_1, p_2, \dots, p_M\}$.

- $H(X) = H(\mathbf{p}) = \sum_{k=1}^M p(x_k) \log_2 \frac{1}{p(x_k)}$ (bits) =
- $= E \left(\log_2 \frac{1}{p(X)} \right)$ bits

$H(X)$ é uma medida da incerteza de X .

Mudança de base

$$\square H_b(X) = E \left(\log_b \frac{1}{p(X)} \right) = \log_b a \quad H_a(X)$$

□ Unidades de Entropia:

□ Base 2 \rightarrow bits

□ Base 10 \rightarrow dits ou Hartleys

□ Base e \rightarrow nats

□ Base 3 \rightarrow trits (porque não?)

Exemplos

□ Ex. 1) $X \in \{0,1\}$, $p(X=0)=0$, $p(X=1)=1$

□

□ $H(X) = -0 \log 0 - 1 \log 1 = 0$


□ Note: $\lim_{p \rightarrow 0} p \log p = 0$ por l'Hôpital

Nenhuma incerteza !

X é determinística

Exemplos (continuação)


- Ex. 2) $X \in \{0,1\}$, $p(X=0)=p$, $p(X=1) = 1-p$,
- $H(X) = -p \log p - (1-p) \log (1-p)$
- $= h(p)$



$h(p)$ é a função binária de entropia

Lema

- $\ln x \leq x-1, \quad x > 0$
- Prova: Série de Taylor com resto



Divergência de Kulbach-Leibler

- Sejam $p(x)$ e $q(x)$ duas funções de massa de probabilidade definidas no alfabeto \mathcal{X} .

- *A divergência de Kullbach-Leibler*

- *de p em relação a q é dada por*

- $$D(p \parallel q) = \sum_{\mathcal{X}} p(x) \log \frac{p(x)}{q(x)}$$

Proposição: Desigualdade da Informação

$D(p \parallel q) \geq 0$ com igualdade se e somente se (sse) $p \equiv q$

- Prova: Seja $A = \{x : p(x) > 0\}$
- Use $\ln x \leq x-1$ (Lema)
-

Observação

- A divergência de K-L é muito útil em T I,
- mas não é uma métrica.

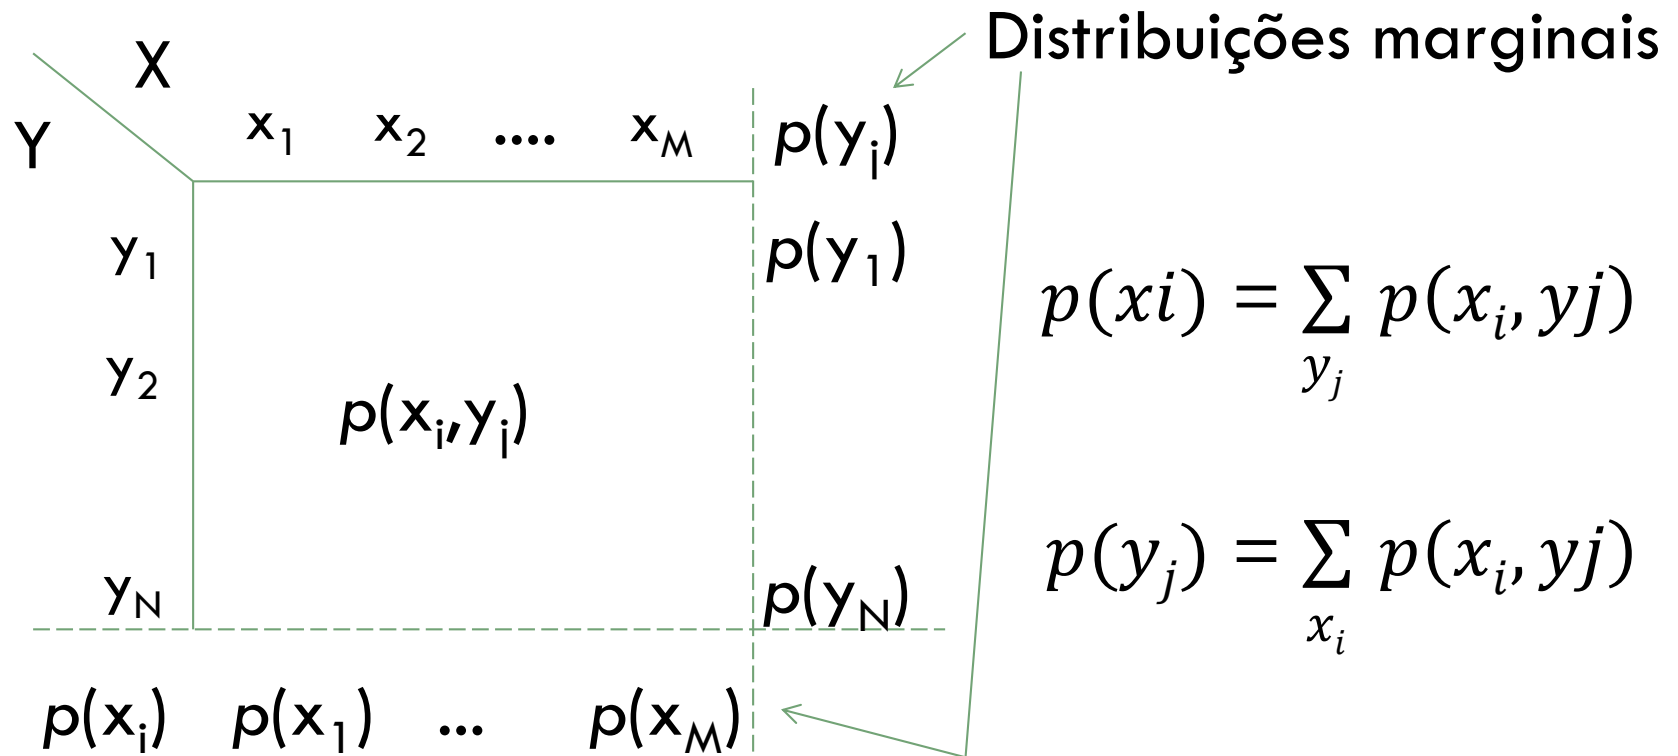
- Ela não é simétrica e não satisfaz a desigualdade do triângulo.

Aplicação

- Seja q a distribuição uniforme
- $q_i = 1/n$ for $i=1, \dots, n$
- $p = \{p_1, p_2, \dots, p_n\}$
- Então $D(p \parallel q) \geq 0$
- $\sum p_i \log \frac{p_i}{q_i} \geq 0$
- $\sum p_i \log p_i \geq \sum p_i \log q_i = \sum p_i \log 1/n$
- Portanto $H(p) \leq \log n$
- A distribuição uniforme tem máxima entropia.

Distribuições conjunta, marginais e condicionais

□ Distribuição conjunta:



Distribuições Condicionais:

- $$p(y_j|x_i) = \frac{p(x_i, y_j)}{p(x_i)}$$

- $$p(x_i|y_j) = \frac{p(x_i, y_j)}{p(y_j)}$$

A distribuição conjunta determina as distribuições marginais e condicionais.

Note: As marginais não determinam a distribuição conjunta.

Entropia Conjunta

$$\square H(X,Y) = H(\mathbf{p}(\cdot, \cdot)) = \sum_{(x_i, y_j)} p(x_i, y_j) \log \frac{1}{p(x_i, y_j)}$$

Entropias Condicionais

$$\square H(X | Y) = \sum p(x_i, y_j) \log \frac{1}{p(x_i | y_j)} = - E (\log p(X | Y))$$

$$\square H(Y | X) = \sum p(y_j, x_i) \log \frac{1}{p(y_j | x_i)} = - E (\log p(Y | X))$$

Regra da Cadeia (como descascar cebola)

$$H(X,Y) = H(X) + H(Y | X)$$

- $= H(Y) + H(X | Y)$

- Prova: Sugestão para casa.

- Simples manipulação algébrica.

- Corolário (forma condicional):

- $H(X,Y | Z) = H(X | Z) + H(Y | X,Z)$

- $= H(Y | Z) + H(X | Y,Z)$

Informação Mútua

- A Informação Mútua entre X e Y é
- a divergência de K-L entre a distribuição
- conjunta $p(x,y)$ e o produto das marginais $p(x) p(y)$.

- $I(X;Y) = D(p(x,y) \parallel p(x) p(y))$

- $$= \sum_x \sum_y p(x,y) \log \frac{p(x,y)}{p(x)p(y)}$$

Propriedades de $I(X;Y)$

- 1) Não-negatividade: $I(X;Y) \geq 0$, com igualdade
□ sse X and Y forem independentes.
□ Prova: $I(X;Y)$ é uma divergência de K-L .

- 2) Simetria:
□ $I(X;Y) = I(Y;X)$
□ Prova: Trivial ($p(x)p(y) = p(y)p(x)$)

Informação Mútua e Entropia

- $I(X;Y) = \sum \sum p(x,y) \log \frac{p(x,y)}{p(x)p(y)}$
- $= H(X) + H(Y) - H(X,Y)$ (simplificando)
- $= H(X) - H(X|Y)$ (regra da cadeia)
- $= H(Y) - H(Y|X)$ (forma alternativa)

- Note: A Informação mútua entre duas variáveis
- aleatórias é a incerteza residual sobre uma variável quando a outra é revelada.

Informação Mútua


- A informação mútua entre X e Y é a diferença entre as entropias de X antes e depois de conhecer Y :

- $$I(X;Y) = H(X) - H(X | Y)$$

- Também

- $$I(X;Y) = H(Y) - H(Y | X)$$

Diagrama de Venn



Informação não atrapalha

- Condicionamento não aumenta entropia:


- $$H(X | Y) \leq H(X)$$

- Prova:
$$I(X; Y) = H(X) - H(X | Y) \geq 0$$

- Na média o conhecimento de Y não pode aumentar a incerteza sobre X .

Passando informação adiante:

- Sejam X e Y variáveis aleatórias dependentes

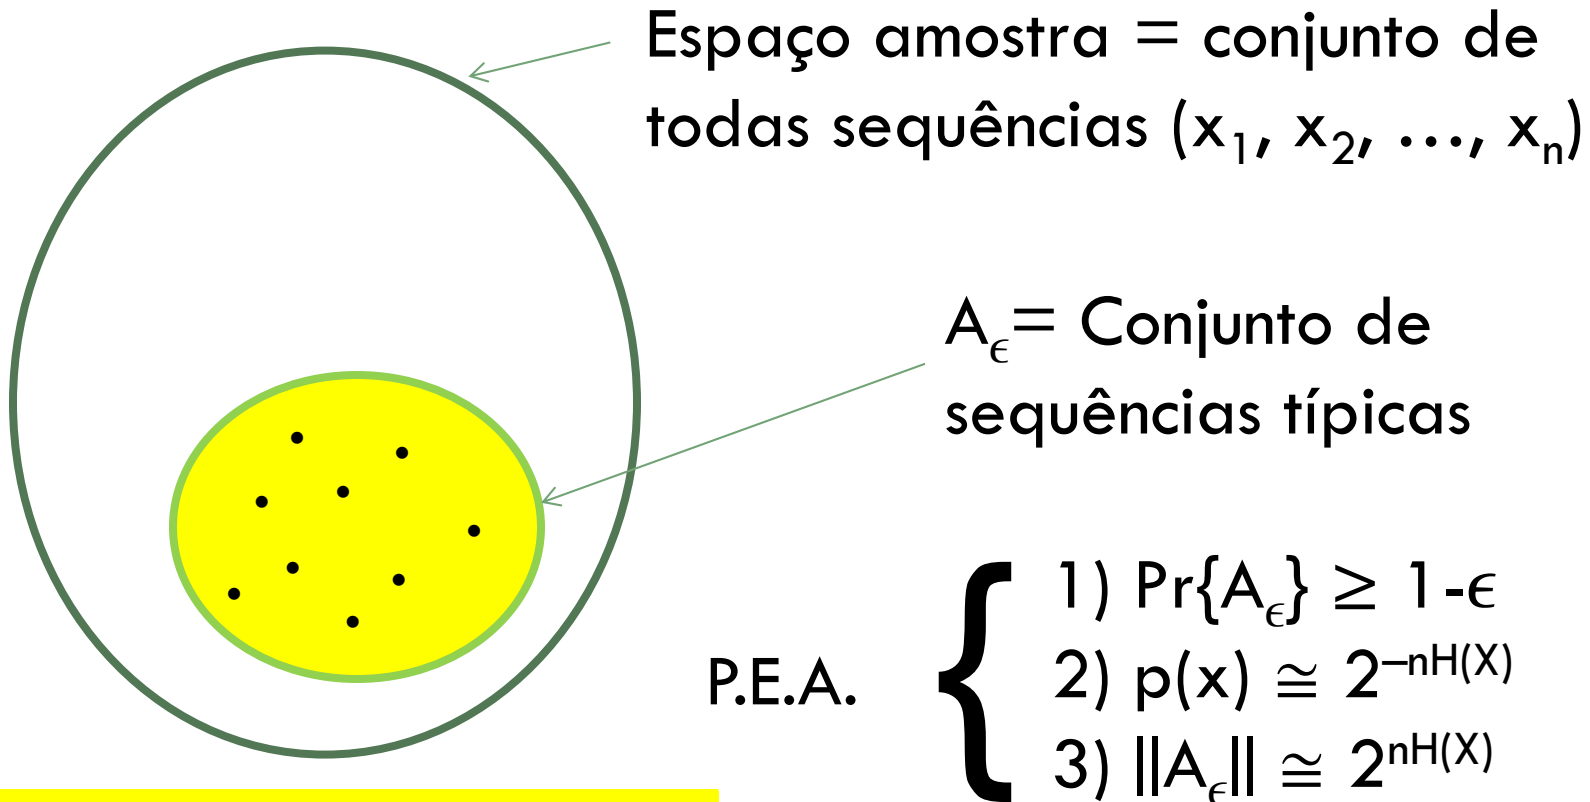


- Proposição: $I(X;Y) \geq I(X; \phi(Y))$
- Prova: $I(X;Y) = H(X) - H(X | Y)$
- $= H(X) - H(X | Y, \phi(Y))$
- $\geq H(X) - H(X | \phi(Y)) = I(X; \phi(Y))$ Condicionamento reduz entropia

- Desigualdade de Processamento de dados.

Propriedade da Equipartição Assintótica

- Sejam X_1, X_2, \dots, X_n i.i.d. segundo $p(x)$



P.E.A é o DNA de T.I. !

Exemplo de sequências típicas

- Seja X uma moeda viciada com
 - $P(\text{Cara})=0.9$ e $P(\text{Coroa}) = 0.1$
 - Considere o conjunto de 1000 lançamentos da moeda.
 - Sequências típicas são aquelas aproximadamente 900 Caras e 100 Coroas.
- Note: A sequência mais provável, qual seja a de 1000 Caras, não é típica !

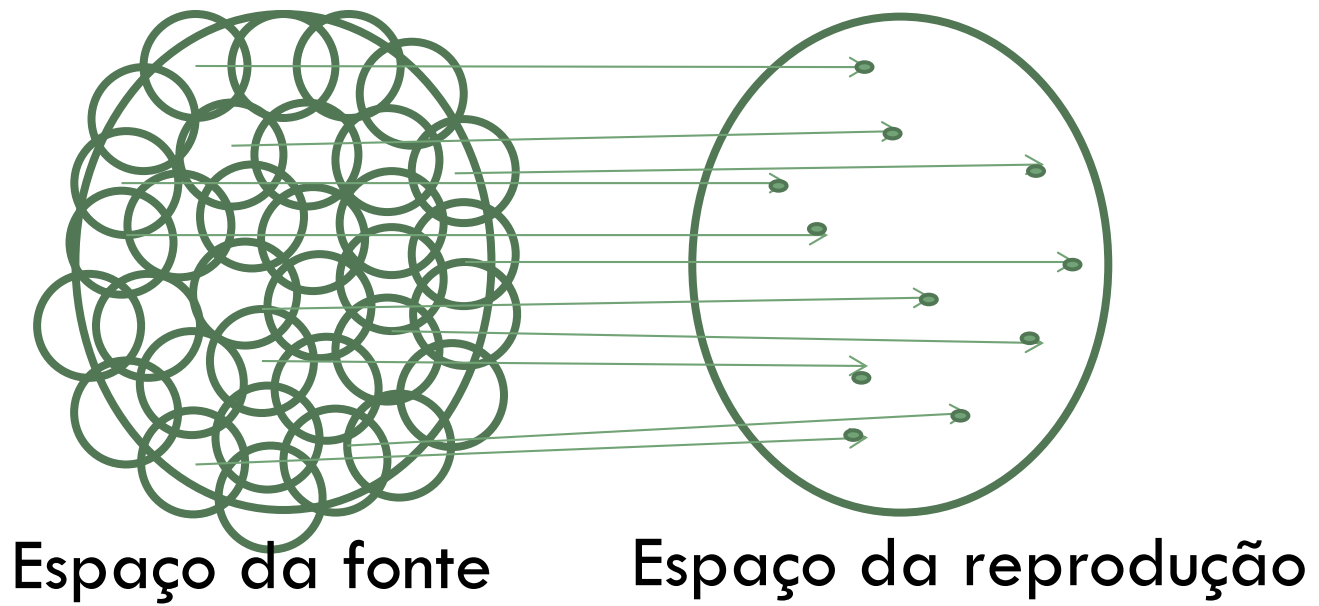
Conclusão da P.E.A. :



Melhor apostar em A_ϵ !

Compressão de dados (Codificação de fonte)

- Objetivo: representar a fonte eficientemente.



Código eficiente: Código de Shannon

- Seja $\ell_i = \left\lceil \log_D \frac{1}{p_i} \right\rceil$,
- Use uma palavra de código com este comprimento.
- Este código satisfaz
- $H_D(X) \leq L \leq H_D(X) + 1$

Código eficiente: Huffman (1952)

- O código de Huffman é o código ótimo de prefixo (menor comprimento esperado) para uma dada distribuição $p(x)$.

- Exemplo:

□ X $p(x)$

□ 1 0.25

□ 2 0.25

□ 3 0.2

□ 4 0.15

□ 5 0.15

0.3

0.25

0.25

0.2

0.45

0.3

0.25

0.55

0.45

0

1

1

Código

01

10

11

000

001

Este código tem comprimento médio de 2.3 bits/símbolo.


Códigos eficientes:

Outros códigos eficientes:

- Códigos Shannon-Fano-Elias
- Códigos Aritméticos
- Códigos de Lempel-Ziv (Universal – aprende a
□ distribuição da fonte)
- Códigos de corridas + códigos de Golomb (muito simples)

Transmissão por Canais Ruidosos

- ○ Problema da codificação de canal:



- $W \in \{1, 2, \dots, 2^{nR}\}$ = conjunto de mensagens (Taxa R)
- $\underline{X} = (x_1 \ x_2 \ \dots \ x_n)$ = palavra-código de entrada no canal
- $\underline{Y} = (y_1 \ y_2 \ \dots \ y_n)$ = palavra-código de saída do canal
- \hat{W} = mensagem decodificada $P(\text{erro}) = P\{W \neq \hat{W}\}$

Exemplos

- Máquina de escrever sem ruído:




Número de símbolos sem ruído = 4

Pode-se transmitir $R = \log_2 4 = 2$ bits/transmissão

Exemplos simples

- Máquina de escrever ruidosa (tipo 1):




Número de símbolos sem ruído = 2

Pode-se transmitir $R = \log_2 2 = 1$ bit/transmissão

Exemplos simples

- Máquina de escrever ruidosa (tipo 2):




Número de símbolos sem ruído = 2

Pode-se transmitir $R = \log_2 2 = 1$ bit/transmissão

Exemplos simples

- Máquina de escrever ruidosa (tipo 3):




Número de símbolos sem ruído = 2

Use só $X=1$ e $X=3$

Pode-se transmitir $R = \log_2 2 = 1$ bit/transmissão

Exemplos simples

- Máquina de escrever mais complicada:



Quantos símbolos livres de ruído?

Claramente pelo menos 2, talvez mais.

Exemplos

- Considere dois usos consecutivos do canal:


A 5x5 grid representing a channel with two consecutive uses, X_1 and X_2 . The grid is empty, with axes labeled 1 to 5.

$X_1 \backslash X_2$	1	2	3	4	5
1					
2					
3					
4					
5					

Código:
Que quadrados
Escolher ?

Exemplos simples

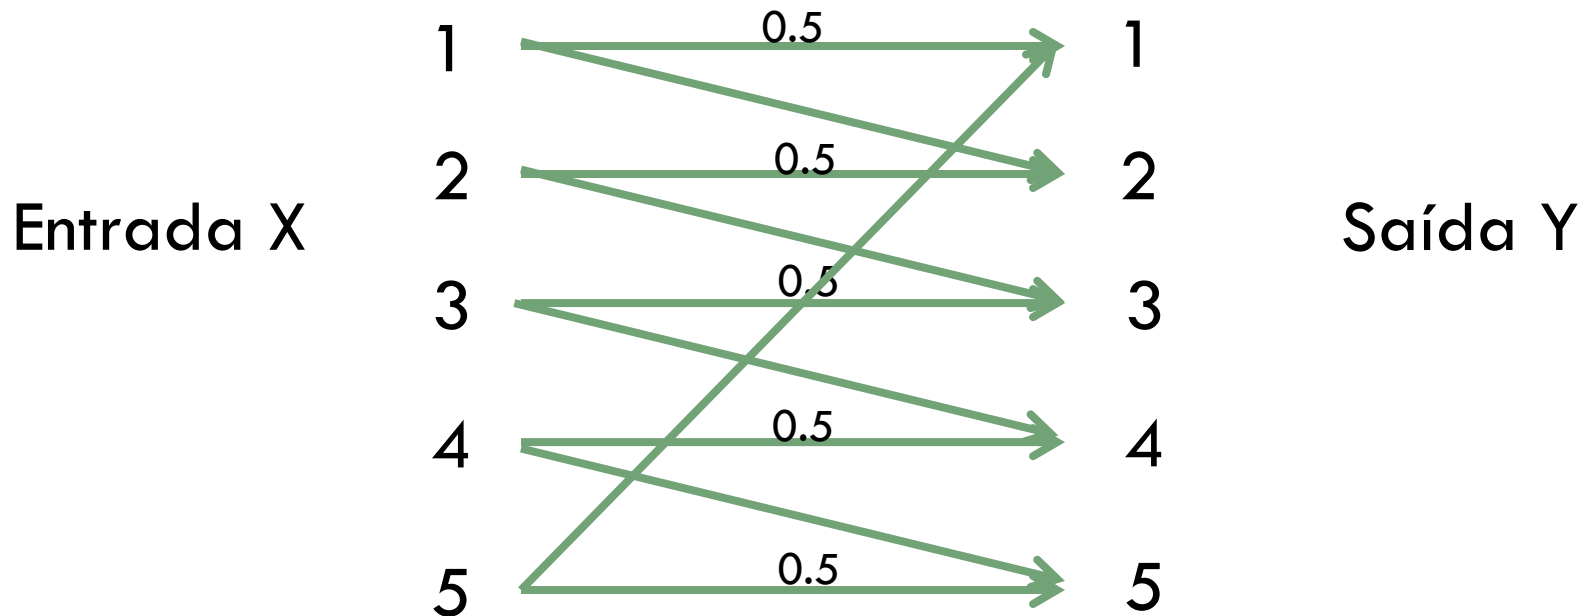
- Dois usos consecutivos do canal:



Sejam os pontos
 $\{X_1, X_2\} =$
 $\{(1,1), (2,3),$
 $(3,5), (4,2),$
 $(5,4)\}$

Relembrando o canal


- Máquina de escrever complicada:



Quantos símbolos livres de ruído?
Mais de 2 ?

Exemplos simples

- Olhando as saídas do canal:




Sejam $\{X_1, X_2\} = \{(1,1), (2,3), (3,5), (4,2), (5,4)\}$

Exemplo simples - observações

- Pode-se transmitir 5 símbolos livres de ruído em $n=2$ transmissões.
- Portanto tem-se taxa de $\frac{\log_2 5}{2} = 1.16$ bits/transmissão
- com $P(\text{erro}) = 0$.
- Pode-se usar códigos mais longos ($n \rightarrow \infty$) para
- obter $\log_2 (5/2) = 1.32$ bits/transmissão, a
- capacidade do canal.

Exemplos: Canal Binário Simétrico (BSC)


- Quantos símbolos livres de ruído ?



A.: Claramente para $n=1$ não há nenhum.
Que tal para n grande ?


Exemplo: Canal Binário Simétrico (BSC)

□




- $C = \max (H(Y) - H(Y | X))$
- $= 1 - h(\epsilon)$ bits/transmissão

□ Note: $C=0$ para $\epsilon = 1/2$



Segundo Teorema de Shannon

- Usa-se o canal n vezes:



Segundo Teorema de Shannon

- A Capacidade de um canal discreto sem memória

- é

-

$$C = \max_{p(x)} I(X; Y).$$

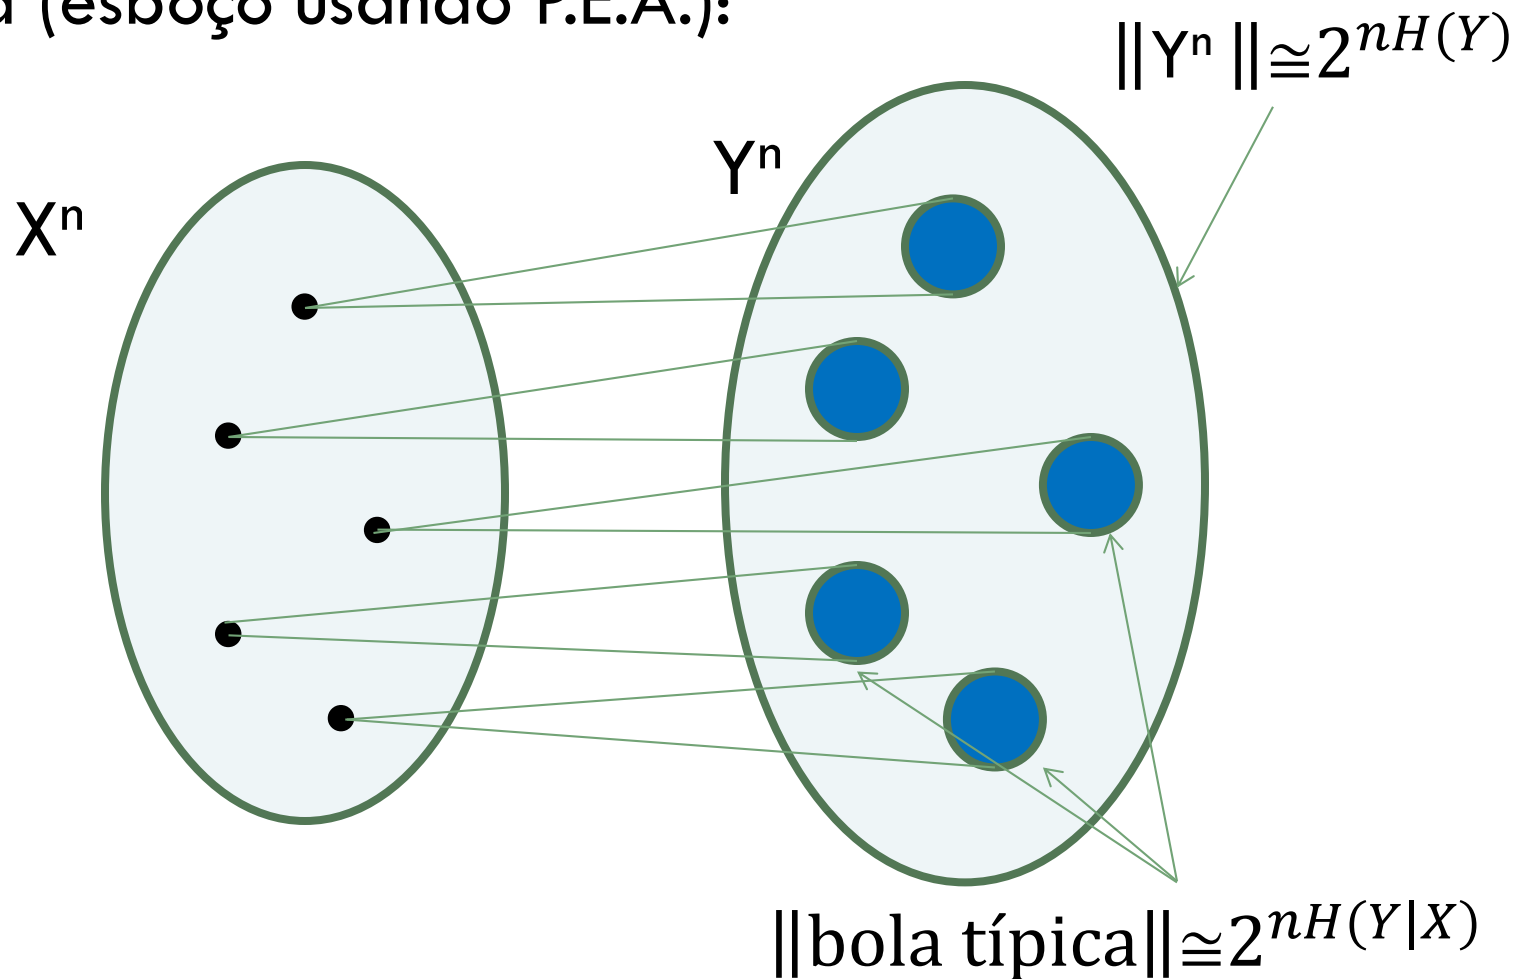
- Note:

- $I(X; Y)$ é uma function de $p(x, y) = p(x)p(y|x)$.

- Mas $p(y|x)$ é fixada pelo canal.

Segundo Teorema de Shannon

- Prova (esboço usando P.E.A.):



Entropia Diferencial

- Seja X uma variável aleatória contínua com densidade de probabilidade $f(x)$ e suporte S .
- A entropia diferencial de X é dada por

$$h(X) = - \int_S f(x) \log f(x) dx \quad (\text{se existir}).$$

Note: Também é denotada por $h(f)$.

Exemplos: Distribuição Uniforme


- Seja X uniforme no intervalo $[0, a]$. Então
- $f(x) = \frac{1}{a}$ no intervalo e $f(x) = 0$ fora dele.
- $$h(X) = - \int_0^a \frac{1}{a} \log \frac{1}{a} dx = \log a$$
- Note que $h(X)$ pode ser negativa (quando $a < 1$).
- No entanto, $2^{h(f)} = 2^{\log a} = a$ é o tamanho do conjunto-suporte, que é não-negativo.

Exemplo: Distribuição Gaussiana

- Seja $X \sim \phi(x) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left(\frac{-x^2}{2\sigma^2}\right)$
- Então $h(X) = h(\phi) = -\int \phi(x) \left[-\frac{x^2}{2\sigma^2} - \ln\sqrt{2\pi\sigma^2}\right] dx$
- $= \frac{EX^2}{2\sigma^2} + \frac{1}{2} \ln 2\pi\sigma^2$
- $= \frac{1}{2} \ln 2\pi e\sigma^2$ nats
- Mudando a base tem-se $h(X) = \frac{1}{2} \log_2 2\pi e\sigma^2$ bits

Relação entre Entropias Diferencial e Discreta

- Considere uma quantização de X , denotada por X^Δ



- Seja $X^\Delta = x_i$ dentro do intervalo i .

$$\begin{aligned} \text{Ent\~{a}o } H(X^\Delta) &= - \sum_i p_i \log p_i \\ &= - \sum_i \Delta f(x_i) \log f(x_i) - \log \Delta \\ &\cong h(f) - \log \Delta \end{aligned}$$

Entropia diferencial de um vetor Gaussiano

- Teorema: Seja \mathbf{X} um vetor Gaussiano n -dimensional com média μ e matriz covariância K .
Então


- $$h(\mathbf{X}) = \frac{1}{2} \log ((2\pi e)^n |K|)$$

- onde $|K|$ denota o determinante de K .

- Prova: Manipulação algébrica.

○ Canal Gaussiano

- ○ Problema do canal Gaussiano:



$W \in \{1, 2, \dots, 2^{nR}\}$ = conjunto de mensagens de taxa R

- $\underline{X} = (x_1 \ x_2 \ \dots \ x_n)$ = entrada do canal

- $\underline{Y} = (y_1 \ y_2 \ \dots \ y_n)$ = saída do canal

- \widehat{W} = mensagem decodificada $P(\text{erro}) = P\{W \neq \widehat{W}\}$

○ canal Gaussiano

-
- *Capacidade* $C = \max_{f(x): EX^2 \leq P} I(X; Y)$
- $I(X; Y) = h(Y) - h(Y|X) = h(Y) - h(X + Z|X)$
- $= h(Y) - h(Z) \leq \frac{1}{2} \log 2\pi e(P + N) - \frac{1}{2} \log 2\pi eN$
- $= \frac{1}{2} \log \left(1 + \frac{P}{N} \right)$ bits/transmissão

○ Canal Gaussiano

-
- *Capacidade:* $C = \max_{f(x): EX^2 \leq P} I(X; Y)$

- $$C = \frac{1}{2} \log \left(1 + \frac{P}{N} \right) \text{ bits/transmissão}$$

○ Canal Gaussiano de Banda Limitada



$$C = W \log\left(1 + \frac{P}{N_0 W}\right) \text{ bits/segundo}$$



□ Note: Se $W \rightarrow \infty$



tem-se $C = \frac{P}{N_0} \log_2 e$ bits/segundo.

Canal Gaussiano de Banda W

- Seja $\frac{R}{W}$ a eficiência espectral ν em bits por segundo por Hertz. Também seja $P = E_b R$ onde E_b é a energia disponível por bit de informação.

- Obtem-se

- $$\frac{R}{W} \leq \frac{C}{W} = \log\left(1 + \frac{E_b R}{N_0 W}\right) \text{ bits/segundo.}$$

- Portanto

- $$\frac{E_b}{N_0} \geq \frac{2^\nu - 1}{\nu}$$

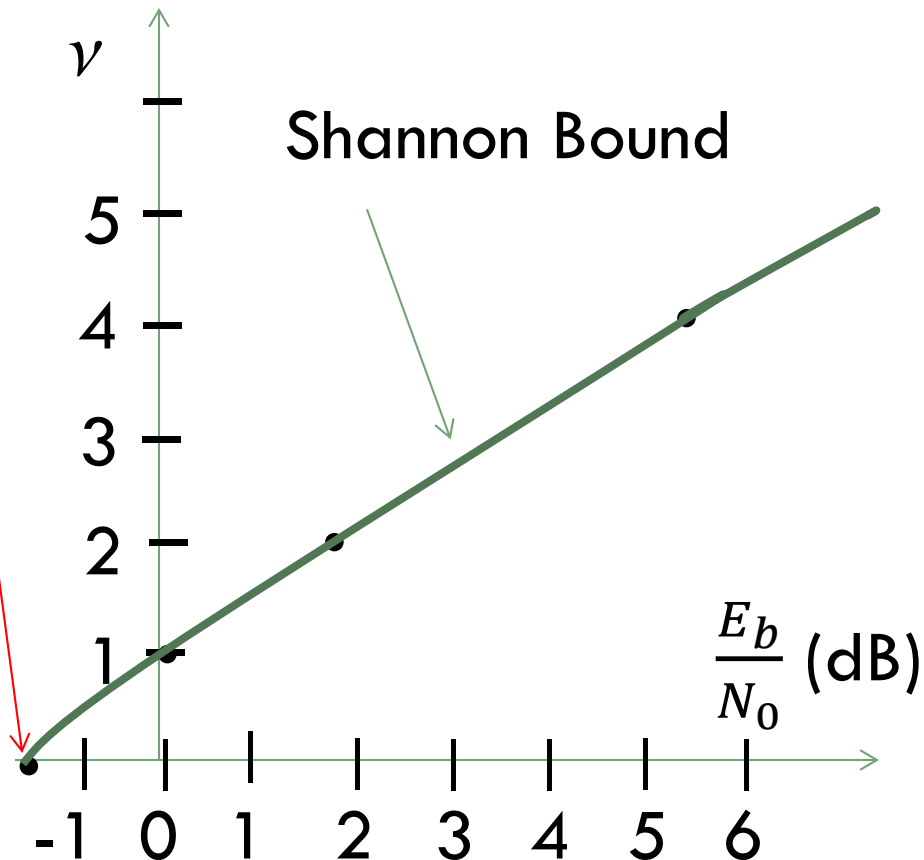
Esta relação define o chamado Limitante de Shannon.

○ Limitante de Shannon

□

$$\frac{E_b}{N_0} \geq \frac{2^{\nu} - 1}{\nu}$$

ν	$\frac{E_b}{N_0}$	$\frac{E_b}{N_0}$ (dB)
$\rightarrow 0$	0.69	-1.59
0.1	0.718	-1.44
0.25	0.757	-1.21
0.5	0.828	-0.82
1	1	0
2	1.5	1.76
4	3.75	5.74
8	31.87	15.03



Solução de “Water-Filling” (Shannon)



Canais Gaussianos Paralelos

□



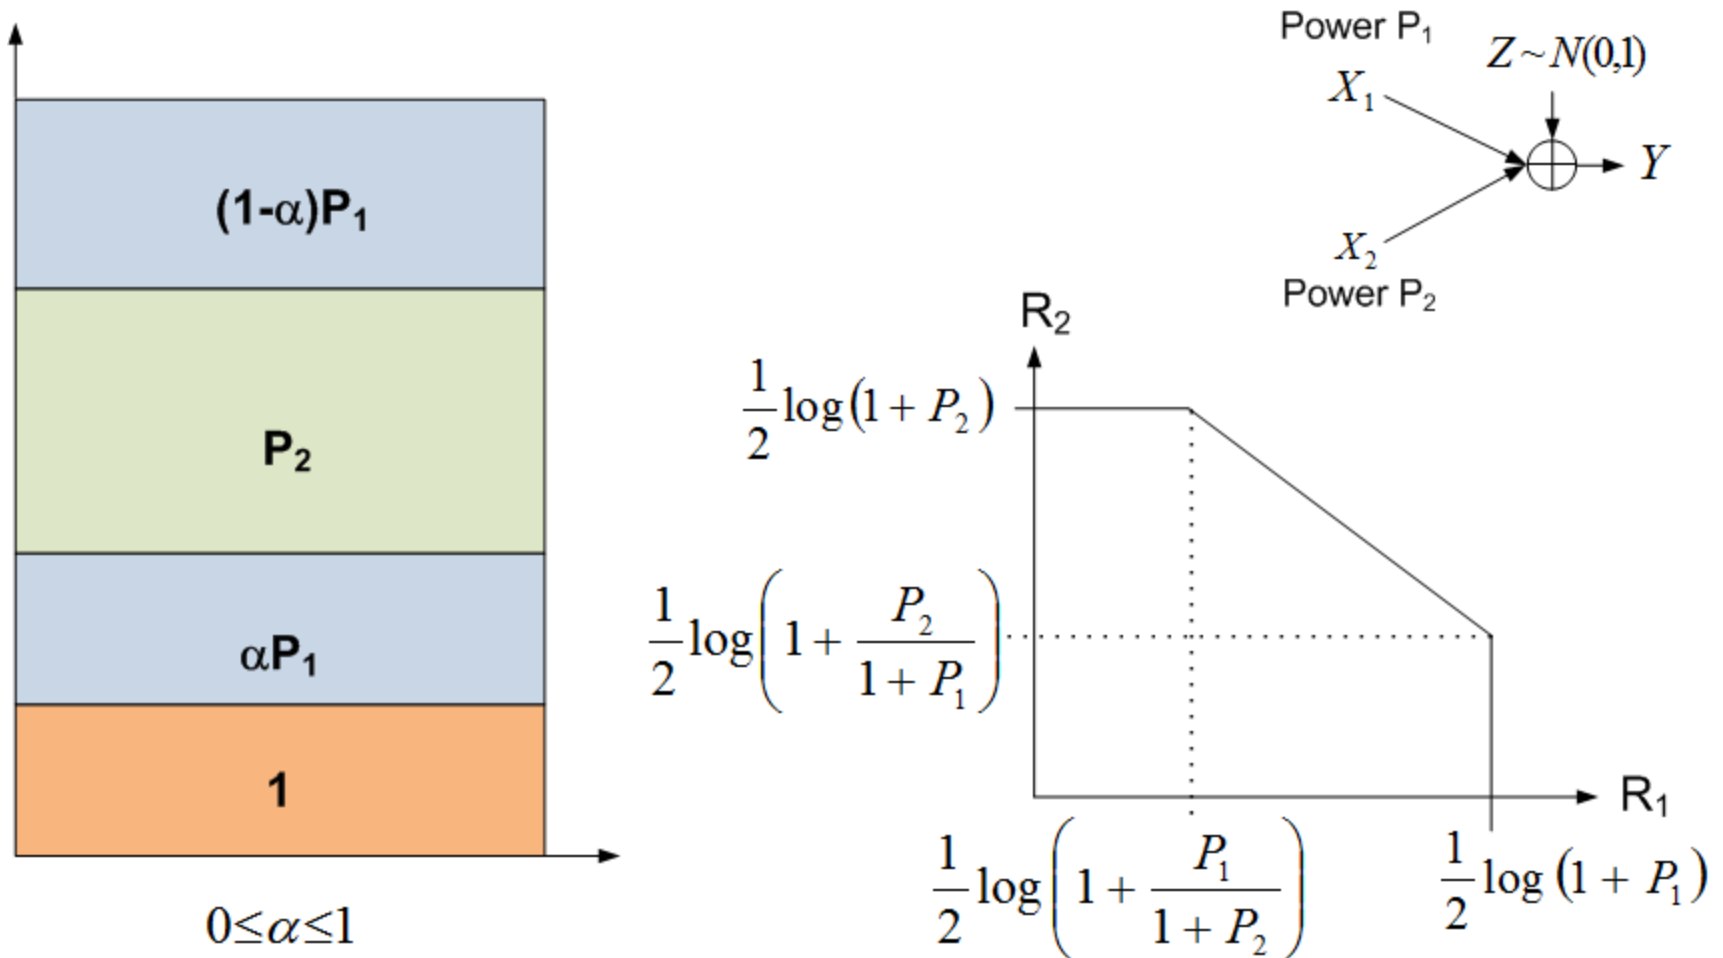
Exemplo de “Water Filling”

- Canais com níveis de ruído 2, 1 and 3.
- Potência disponível = 2
- Capacidade = $\frac{1}{2} \log \left(1 + \frac{0.5}{2}\right) + \frac{1}{2} \log \left(1 + \frac{1.5}{1}\right) + \frac{1}{2} \log \left(1 + \frac{0}{3}\right)$
- Nível de ruído mais potência de sinal = 2.5
- Nenhuma potência alocada para o terceiro canal.


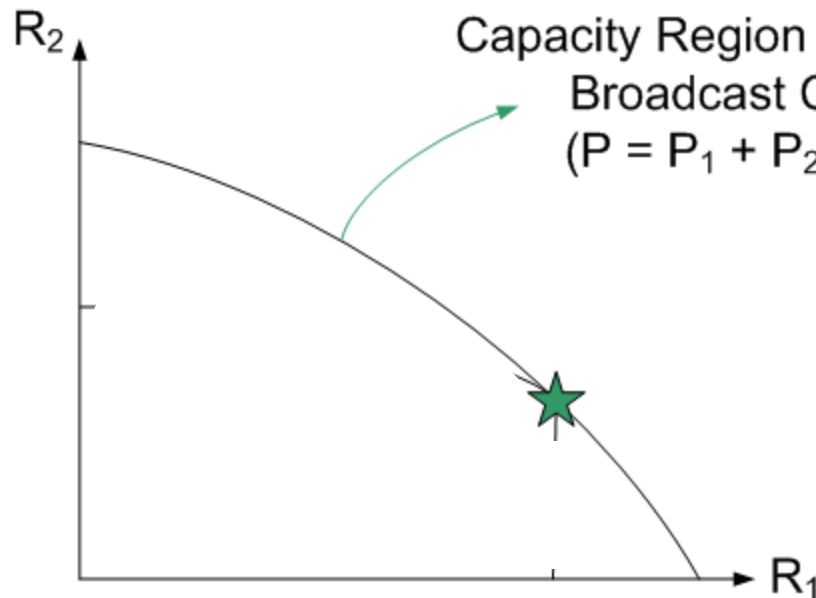
Teoria de informação de múltiplos usuários

- Blocos constituintes:
 - Canal de Múltiplo Acesso (MACs)
 - Canais de Broadcast (BCs)
 - Canais de Interferência (IFCs)
 - Canais de Relay (RCs)
- Note: Estes canais têm versões discretas sem memória e versões Gaussianas. Por simplicidade vamos ver apenas as versões Gaussianas.

Canal de Múltiplo Acesso (MAC)



Canal de Broadcast Gaussiano





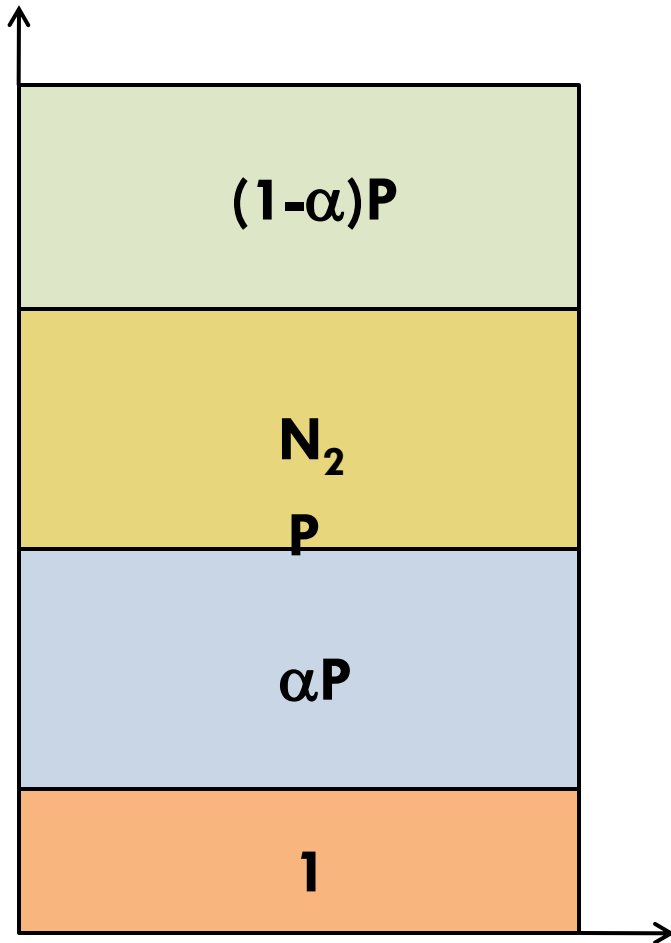
$$C_{BC} \{R_1, R_2\} :$$

$$0 \leq \alpha \leq 1$$


$$0 \leq R_1 \leq \frac{1}{2} \log(1 + \alpha P)$$

$$0 \leq R_2 \leq \frac{1}{2} \log \left(1 + \frac{(1 - \alpha)P}{1 + N_2 + \alpha P} \right)$$


Codificação por Superposição




Canal de interferência Gaussiano padrão



Canal de interferência Gaussiano simétrico



Canal de Interferência em Z




Canal de Interferência: estratégias

O que se pode fazer com interferência:

1. Ignorar (tomar a interferência como ruído,
2. Evitar (dividir o espaço de sinal (TDM/FDM)),
3. Parcialmente decodificar os dois sinais de interferência,
4. Parcialmente decodificar um e totalmente o outro,
5. Decodificar os dois sinais de interferência (a melhor opção para interferência forte, $a \geq 1$).

Canal de Relay


□



- O canal de relay é dito fisicamente degradado se $p(y, y_1 | x, x_1) = p(y_1 | x, x_1) p(y | y_1, x_1)$.
- Portanto Y é uma versão degradada do sinal de relay Y_1 .
- Teorema: $C = \sup_{p(x, x_1)} \min \{ I(X, X_1; Y_1), I(X; Y_1 | X_1) \}$

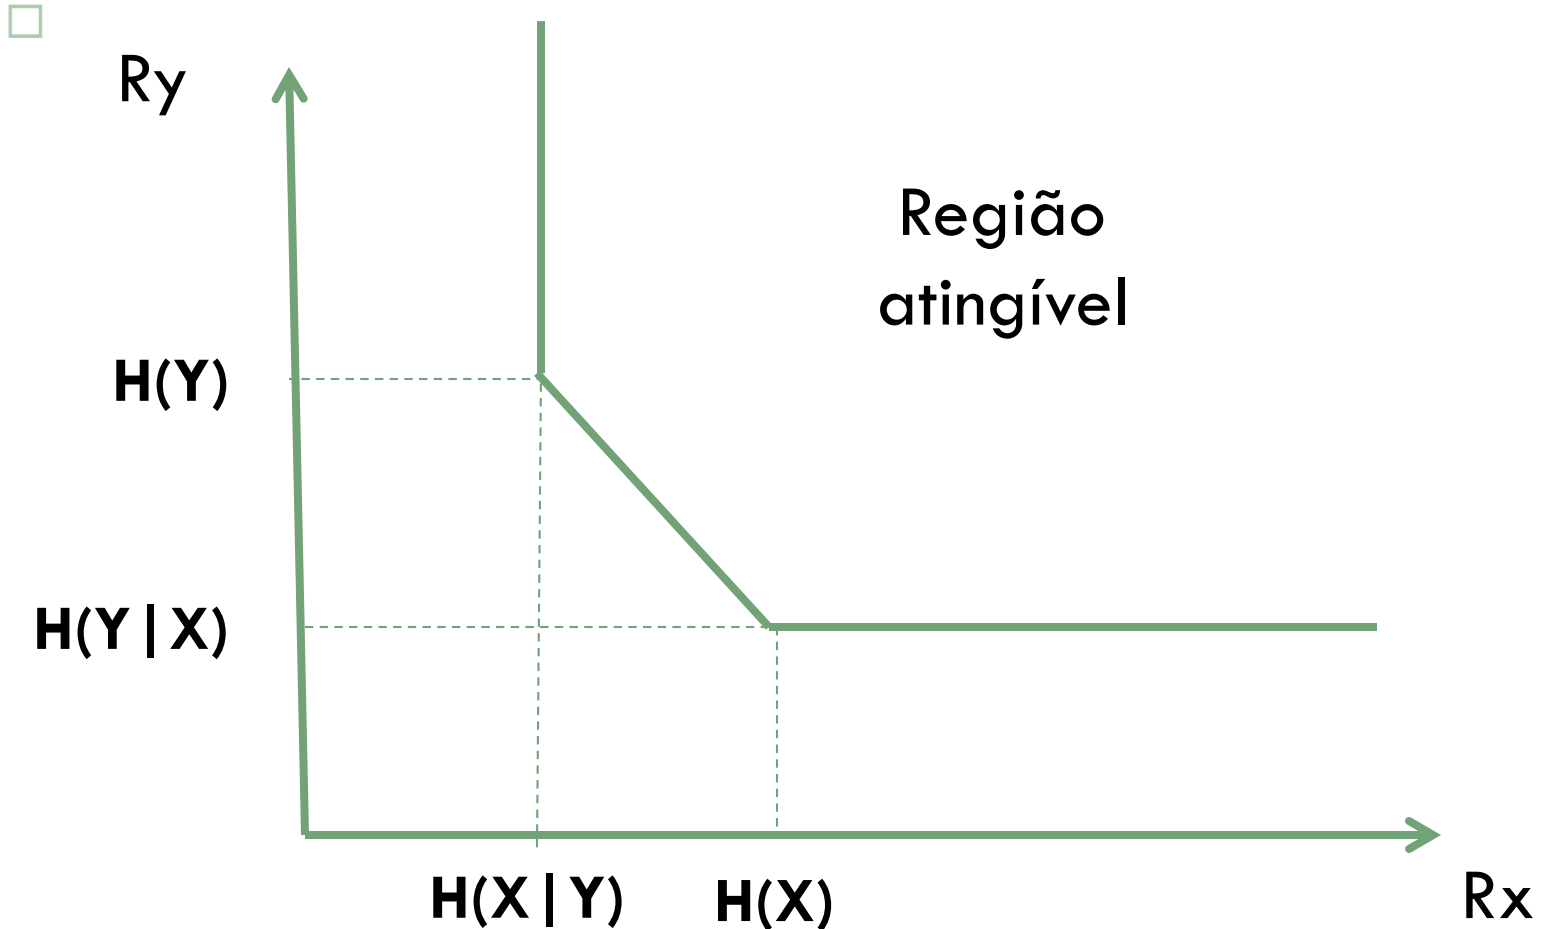
Codificação de Fonte de Slepian Wolf

- X, Y variáveis aleatórias correlatadas $\sim p(x, y)$



Índices i e k com taxas R_x and R_y , resp.

Slepian Wolf (continuação)



Fechamento

Muitas frentes de pesquisa:

Codificação conjunta de fonte e canal

Codificação para canais com informação lateral

Codificação distribuída de fonte

Estratégias de codificação para redes

“Casamento” de “Network Coding” e T I de múltiplos

usuários.



□ Obrigado !

max@fee.unicamp.br