

# Enrolamento e quantização de distribuições de probabilidade por reticulados

Fábio C. C. Meneghetti

IMECC — Unicamp

7 de junho de 2022

# Domínios fundamentais

- seja  $\Lambda \subset \mathbb{R}^n$  reticulado de posto completo ( $\dim \Lambda = n$ )

# Domínios fundamentais

- seja  $\Lambda \subset \mathbb{R}^n$  reticulado de posto completo ( $\dim \Lambda = n$ )
- um domínio fundamental é um conjunto mensurável  $\mathcal{D}$  tal que

# Domínios fundamentais

- seja  $\Lambda \subset \mathbb{R}^n$  reticulado de posto completo ( $\dim \Lambda = n$ )
- um domínio fundamental é um conjunto mensurável  $\mathcal{D}$  tal que
  - 1  $\bigcup_{\lambda \in \Lambda} (\lambda + \mathcal{D}) = \mathbb{R}^n$

# Domínios fundamentais

- seja  $\Lambda \subset \mathbb{R}^n$  reticulado de posto completo ( $\dim \Lambda = n$ )
- um domínio fundamental é um conjunto mensurável  $\mathcal{D}$  tal que
  - 1  $\bigcup_{\lambda \in \Lambda} (\lambda + \mathcal{D}) = \mathbb{R}^n$
  - 2  $(\lambda + \mathcal{D}) \cap (\lambda' + \mathcal{D}) = \emptyset, \quad \lambda \neq \lambda' \in \Lambda$

# Domínios fundamentais

- seja  $\Lambda \subset \mathbb{R}^n$  reticulado de posto completo ( $\dim \Lambda = n$ )
- um domínio fundamental é um conjunto mensurável  $\mathcal{D}$  tal que
  - 1  $\bigcup_{\lambda \in \Lambda} (\lambda + \mathcal{D}) = \mathbb{R}^n$
  - 2  $(\lambda + \mathcal{D}) \cap (\lambda' + \mathcal{D}) = \emptyset, \quad \lambda \neq \lambda' \in \Lambda$
- **Exemplos:**

# Domínios fundamentais

- seja  $\Lambda \subset \mathbb{R}^n$  reticulado de posto completo ( $\dim \Lambda = n$ )
- um domínio fundamental é um conjunto mensurável  $\mathcal{D}$  tal que

①  $\bigcup_{\lambda \in \Lambda} (\lambda + \mathcal{D}) = \mathbb{R}^n$

②  $(\lambda + \mathcal{D}) \cap (\lambda' + \mathcal{D}) = \emptyset, \quad \lambda \neq \lambda' \in \Lambda$

- **Exemplos:**

- paralelepípedo fundamental com relação a uma base  $\beta = \{b_1, \dots, b_n\}$ :

$$\mathcal{P}(\beta) = \{x_1 b_1 + \dots + x_n b_n : x_i \in [0, 1)\}$$

# Domínios fundamentais

- seja  $\Lambda \subset \mathbb{R}^n$  reticulado de posto completo ( $\dim \Lambda = n$ )
- um domínio fundamental é um conjunto mensurável  $\mathcal{D}$  tal que

①  $\bigcup_{\lambda \in \Lambda} (\lambda + \mathcal{D}) = \mathbb{R}^n$

②  $(\lambda + \mathcal{D}) \cap (\lambda' + \mathcal{D}) = \emptyset, \quad \lambda \neq \lambda' \in \Lambda$

- **Exemplos:**

- paralelepípedo fundamental com relação a uma base  $\beta = \{b_1, \dots, b_n\}$ :

$$\mathcal{P}(\beta) = \{x_1 b_1 + \dots + x_n b_n : x_i \in [0, 1)\}$$

- região de Voronói, pode ser reduzida a um domínio fundamental cortando algumas bordas:

$$\mathcal{V}(\Lambda) = \{x \in \mathbb{R}^n : \|x\| \leq \|x + \lambda\|, \quad \forall \lambda \in \Lambda\}$$







Figura: Paralelotope fundamental e região de Voronói, respectivamente.

# Toro como espaço quociente

- o quociente de  $\mathbb{R}^n$  por  $\Lambda$  é

$$\mathbb{R}^n/\Lambda := \{x + \Lambda : x \in \mathbb{R}^n\},$$

que é munido de uma função projeção  $\pi: \mathbb{R}^n \rightarrow \mathbb{R}^n/\Lambda$ ,

$$\pi(x) = x + \Lambda.$$

# Identificação entre $\mathcal{D}$ e $\mathbb{R}^n/\Lambda$

## Proposição

*O mapa restrito  $\pi|_{\mathcal{D}}: \mathcal{D} \rightarrow \mathbb{R}^n/\Lambda$  é bijeção, para qualquer região fundamental  $\mathcal{D}$ .*

# Identificação entre $\mathcal{D}$ e $\mathbb{R}^n/\Lambda$

## Proposição

*O mapa restrito  $\pi|_{\mathcal{D}}: \mathcal{D} \rightarrow \mathbb{R}^n/\Lambda$  é bijeção, para qualquer região fundamental  $\mathcal{D}$ .*

# Identificação entre $\mathcal{D}$ e $\mathbb{R}^n/\Lambda$

## Proposição

*O mapa restrito  $\pi|_{\mathcal{D}}: \mathcal{D} \rightarrow \mathbb{R}^n/\Lambda$  é bijeção, para qualquer região fundamental  $\mathcal{D}$ .*

## Demonstração.

# Identificação entre $\mathcal{D}$ e $\mathbb{R}^n/\Lambda$

## Proposição

O mapa restrito  $\pi|_{\mathcal{D}}: \mathcal{D} \rightarrow \mathbb{R}^n/\Lambda$  é bijeção, para qualquer região fundamental  $\mathcal{D}$ .

## Demonstração.

- Injetividade:**  $\pi|_{\mathcal{D}}(x) = \pi|_{\mathcal{D}}(y) \iff x + \Lambda = y + \Lambda \iff x - y \in \Lambda \iff x + 0 = y + \lambda$  para algum  $\lambda \in \Lambda$ . Ter  $\lambda \neq 0$  iria contradizer  $(\mathcal{D} + 0) \cap (\mathcal{D} + \lambda) = \emptyset$ , portanto  $x = y$ .

# Identificação entre $\mathcal{D}$ e $\mathbb{R}^n/\Lambda$

## Proposição

O mapa restrito  $\pi|_{\mathcal{D}}: \mathcal{D} \rightarrow \mathbb{R}^n/\Lambda$  é bijeção, para qualquer região fundamental  $\mathcal{D}$ .

## Demonstração.

- Injetividade:**  $\pi|_{\mathcal{D}}(x) = \pi|_{\mathcal{D}}(y) \iff x + \Lambda = y + \Lambda \iff x - y \in \Lambda \iff x + 0 = y + \lambda$  para algum  $\lambda \in \Lambda$ . Ter  $\lambda \neq 0$  iria contradizer  $(\mathcal{D} + 0) \cap (\mathcal{D} + \lambda) = \emptyset$ , portanto  $x = y$ .
- Sobrejetividade:** tome  $(x + \Lambda) \in \mathbb{R}^n/\Lambda$ . De  $\mathbb{R}^n = \bigcup_{\lambda \in \Lambda} (\lambda + \mathcal{D})$ , existem  $\bar{x} \in \mathcal{D}$ ,  $\lambda \in \Lambda$  tais que  $x = \bar{x} + \lambda$ . Assim

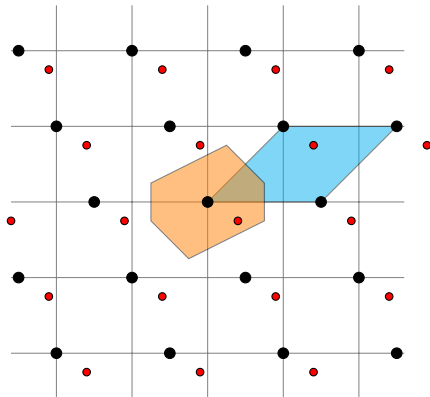
$$(x + \Lambda) = (\bar{x} + \Lambda) = \pi|_{\mathcal{D}}(\bar{x}).$$



- em outras palavras, cada classe  $x + \Lambda$  possui um único representante em  $\mathcal{D}$ .



- em outras palavras, cada classe  $x + \Lambda$  possui um único representante em  $\mathcal{D}$ .
- essa identificação é mensurável: não altera o volume de subconjuntos, e esse volume é o mesmo para qualquer domínio fundamental escolhido.



**Figura:** Classe lateral  $x + \Lambda$  interseccionando cada região fundamental em apenas um ponto.

# Distribuição enrolada

- seja  $p: \mathbb{R}^n \rightarrow \mathbb{R}_+$  função tal que  $\int_{\mathbb{R}^n} p(x) dx = 1$  (chamada função densidade de probabilidade)

# Distribuição enrolada

- seja  $p: \mathbb{R}^n \rightarrow \mathbb{R}_+$  função tal que  $\int_{\mathbb{R}^n} p(x) dx = 1$  (chamada função densidade de probabilidade)
- a **distribuição enrolada** por um reticulado  $\Lambda$  é definida como  $p_\pi: \mathcal{D} \rightarrow \mathbb{R}_+$ ,

$$p_\pi(x) = \sum_{\lambda \in \Lambda} p(x + \lambda)$$

# Distribuição enrolada

- seja  $p: \mathbb{R}^n \rightarrow \mathbb{R}_+$  função tal que  $\int_{\mathbb{R}^n} p(x) dx = 1$  (chamada função densidade de probabilidade)
- a **distribuição enrolada** por um reticulado  $\Lambda$  é definida como  $p_\pi: \mathcal{D} \rightarrow \mathbb{R}_+$ ,

$$p_\pi(x) = \sum_{\lambda \in \Lambda} p(x + \lambda)$$

- em outras palavras, somamos a probabilidade para cada classe  $(x + \Lambda) \in \mathbb{R}^n/\Lambda$

# Distribuição enrolada

- seja  $p: \mathbb{R}^n \rightarrow \mathbb{R}_+$  função tal que  $\int_{\mathbb{R}^n} p(x) dx = 1$  (chamada função densidade de probabilidade)
- a **distribuição enrolada** por um reticulado  $\Lambda$  é definida como  $p_\pi: \mathcal{D} \rightarrow \mathbb{R}_+$ ,

$$p_\pi(x) = \sum_{\lambda \in \Lambda} p(x + \lambda)$$

- em outras palavras, somamos a probabilidade para cada classe  $(x + \Lambda) \in \mathbb{R}^n/\Lambda$
- alternativamente, poderia ser vista como distribuição sobre  $\mathbb{R}^n/\Lambda$

# Exemplos

① **Normal univariada.**  $p(x) = \frac{1}{\sqrt{2\pi}\sigma} \exp\left(\frac{-(x-\mu)^2}{2\sigma^2}\right)$ ,  $\Lambda = k\mathbb{Z}$

$$p_{\pi}(x) = \frac{1}{\sqrt{2\pi}\sigma} \sum_{z \in \mathbb{Z}} \exp\left(\frac{-(x + kz - \mu)^2}{2\sigma^2}\right)$$

# Exemplos

① **Normal univariada.**  $p(x) = \frac{1}{\sqrt{2\pi}\sigma} \exp\left(\frac{-(x-\mu)^2}{2\sigma^2}\right)$ ,  $\Lambda = k\mathbb{Z}$


$$p_{\pi}(x) = \frac{1}{\sqrt{2\pi}\sigma} \sum_{z \in \mathbb{Z}} \exp\left(\frac{-(x + kz - \mu)^2}{2\sigma^2}\right)$$




# Exemplos

1 **Normal univariada.**  $p(x) = \frac{1}{\sqrt{2\pi}\sigma} \exp\left(\frac{-(x-\mu)^2}{2\sigma^2}\right)$ ,  $\Lambda = k\mathbb{Z}$

$$p_{\pi}(x) = \frac{1}{\sqrt{2\pi}\sigma} \sum_{z \in \mathbb{Z}} \exp\left(\frac{-(x + kz - \mu)^2}{2\sigma^2}\right)$$



(a) Original



(b) Enrolada

2 **Exponencial.**  $p(x) = \nu e^{-\nu x}$ ,  $x > 0$ ,  $\Lambda = k\mathbb{Z}$



$$p_{\pi}(y) = \frac{\nu e^{-\nu y}}{1 - e^{-k\nu}}$$

2 **Exponencial.**  $p(x) = \nu e^{-\nu x}$ ,  $x > 0$ ,  $\Lambda = k\mathbb{Z}$

$$p_{\pi}(y) = \frac{\nu e^{-\nu y}}{1 - e^{-k\nu}}$$

2 Exponencial.  $p(x) = \nu e^{-\nu x}$ ,  $x > 0$ ,  $\Lambda = k\mathbb{Z}$

$$p_{\pi}(y) = \frac{\nu e^{-\nu y}}{1 - e^{-k\nu}}$$



# Aplicações

- 1 **Estatística direcional.** estuda a estatística de dados que são circulares, definidos no círculo, esfera ( $\mathbb{S}^n$ ) ou toro ( $\mathbb{T}^n$ ) — esta último é nosso caso.

Exemplos:

# Aplicações

- 1 **Estatística direcional.** estuda a estatística de dados que são circulares, definidos no círculo, esfera ( $S^n$ ) ou toro ( $T^n$ ) — esta último é nosso caso.

Exemplos:

- a frequência de um evento em função do dia do ano é um dado circular

# Aplicações

- 1 **Estatística direcional.** estuda a estatística de dados que são circulares, definidos no círculo, esfera ( $S^n$ ) ou toro ( $T^n$ ) — esta último é nosso caso.

Exemplos:

- a frequência de um evento em função do dia do ano é um dado circular
- a distribuição de substâncias na superfície de um planeta é um dado esférico

# Aplicações

- 1 **Estatística direcional.** estuda a estatística de dados que são circulares, definidos no círculo, esfera ( $\mathbb{S}^n$ ) ou toro ( $\mathbb{T}^n$ ) — esta último é nosso caso.

## Exemplos:

- a frequência de um evento em função do dia do ano é um dado circular
- a distribuição de substâncias na superfície de um planeta é um dado esférico
- a distribuição conjunta de quaisquer dois dados circulares é um dado no toro  $\mathbb{T}^2 = \mathbb{S}^1 \times \mathbb{S}^1$



## 2 Codificação em canais AWGN e Wiretap.

## 2 Codificação em canais AWGN e Wiretap.

- O *fator de achamento* é definido como a distância  $L^\infty$  entre uma distribuição enrolada e uma uniforme em  $\mathcal{D}$ :

$$\epsilon_\Lambda(p) = \sup_{x \in \mathcal{D}} \left| p_w(x) - \frac{1}{\det \Lambda} \right|$$

## 2 Codificação em canais AWGN e Wiretap.

- O *fator de achatamento* é definido como a distância  $L^\infty$  entre uma distribuição enrolada e uma uniforme em  $\mathcal{D}$ :

$$\epsilon_\Lambda(p) = \sup_{x \in \mathcal{D}} \left| p_w(x) - \frac{1}{\det \Lambda} \right|$$

- quando temos um canal AWGN ou Wiretap com ruído gaussiano, o fator de achatamento pode ser usado construir códigos com eficiência máxima (atingem a capacidade de Shannon)

## 2 Codificação em canais AWGN e Wiretap.

- O *fator de achatamento* é definido como a distância  $L^\infty$  entre uma distribuição enrolada e uma uniforme em  $\mathcal{D}$ :

$$\epsilon_\Lambda(p) = \sup_{x \in \mathcal{D}} \left| p_w(x) - \frac{1}{\det \Lambda} \right|$$

- quando temos um canal AWGN ou Wiretap com ruído gaussiano, o fator de achatamento pode ser usado para construir códigos com eficiência máxima (atingem a capacidade de Shannon)

## 3 Criptografia baseada em reticulados.

## 2 Codificação em canais AWGN e Wiretap.

- O *fator de achatamento* é definido como a distância  $L^\infty$  entre uma distribuição enrolada e uma uniforme em  $\mathcal{D}$ :

$$\epsilon_\Lambda(p) = \sup_{x \in \mathcal{D}} \left| p_w(x) - \frac{1}{\det \Lambda} \right|$$

- quando temos um canal AWGN ou Wiretap com ruído gaussiano, o fator de achatamento pode ser usado para construir códigos com eficiência máxima (atingem a capacidade de Shannon)

## 3 Criptografia baseada em reticulados.

- O parâmetro de suavização, equivalente ao fator de achatamento, é um parâmetro de garantia de segurança e confiabilidade na criptografia pós-quântica baseada em reticulados.

# Distribuições quantizadas

- pode ser considerada uma operação dual ao enrolamento.

# Distribuições quantizadas

- pode ser considerada uma operação dual ao enrolamento.
- a **distribuição quantizada** por um reticulado  $\Lambda$  e uma região fundamental  $\mathcal{D}$  é a distribuição  $p_{\mathcal{Q}}: \Lambda \rightarrow \mathbb{R}_+$ ,

$$p_{\mathcal{Q}}(\lambda) = \int_{\mathcal{D}} p(x + \lambda) dx.$$

# Distribuições quantizadas

- pode ser considerada uma operação dual ao enrolamento.
- a **distribuição quantizada** por um reticulado  $\Lambda$  e uma região fundamental  $\mathcal{D}$  é a distribuição  $p_{\mathcal{Q}}: \Lambda \rightarrow \mathbb{R}_+$ ,

$$p_{\mathcal{Q}}(\lambda) = \int_{\mathcal{D}} p(x + \lambda) dx.$$

- se o enrolamento é somar  $p(x + \lambda)$  em  $\lambda$ , a quantização é “somar” (integrar)  $p(x + \lambda)$  em  $x$ .




# Distribuições quantizadas


- pode ser considerada uma operação dual ao enrolamento.
- a **distribuição quantizada** por um reticulado  $\Lambda$  e uma região fundamental  $\mathcal{D}$  é a distribuição  $p_{\mathcal{Q}}: \Lambda \rightarrow \mathbb{R}_+$ ,

$$p_{\mathcal{Q}}(\lambda) = \int_{\mathcal{D}} p(x + \lambda) dx.$$


- se o enrolamento é somar  $p(x + \lambda)$  em  $\lambda$ , a quantização é “somar” (integrar)  $p(x + \lambda)$  em  $x$ .
- é uma forma de transformar uma distribuição de probabilidade contínua em uma discreta.



(a) Original



(b) Enrolada



(c) Quantizada

# Descrição em variáveis aleatórias

- uma função densidade  $p(x)$  descreve a distribuição de uma variável aleatória  $X$ , com

$$\mathbb{P}[X \in A] = \int_A p(x) dx$$

Notação:  $X \sim p$

# Descrição em variáveis aleatórias

- uma função densidade  $p(x)$  descreve a distribuição de uma variável aleatória  $X$ , com

$$\mathbb{P}[X \in A] = \int_A p(x) dx$$

Notação:  $X \sim p$

- temos duas funções: o enrolamento  $\pi: \mathbb{R}^n \rightarrow \mathcal{D}$  e a quantização  $Q: \mathbb{R}^n \rightarrow \Lambda$ , que são definidas por

$$\pi(y + \lambda) = y, \quad Q(y + \lambda) = \lambda,$$

para todo  $y \in \mathcal{D}$ ,  $\lambda \in \Lambda$

- as distribuições enroladas podem ser descritas em termos de variáveis aleatórias:

$$X \sim p \implies \begin{cases} X_\pi := \pi(X) \sim p_\pi \\ X_Q := Q(X) \sim p_Q \end{cases},$$

- as distribuições enroladas podem ser descritas em termos de variáveis aleatórias:

$$X \sim p \implies \begin{cases} X_\pi := \pi(X) \sim p_\pi \\ X_Q := Q(X) \sim p_Q \end{cases},$$

- se definimos  $X_\pi$  e  $X_Q$  dessa forma, temos que  $X = X_\pi + X_Q$

- as distribuições enroladas podem ser descritas em termos de variáveis aleatórias:

$$X \sim p \implies \begin{cases} X_\pi := \pi(X) \sim p_\pi \\ X_Q := Q(X) \sim p_Q \end{cases},$$

- se definimos  $X_\pi$  e  $X_Q$  dessa forma, temos que  $X = X_\pi + X_Q$
- essa descrição estabelece uma relação entre as distribuições enrolada e quantizada, e nos permite investigar propriedades dessa relação

# Esperança

- a esperança (média) de uma variável aleatória  $X$  (ou de uma distribuição  $p$ ) é  $E[X] := \int_{\mathbb{R}^n} xp(x) dx$



# Esperança

- a esperança (média) de uma variável aleatória  $X$  (ou de uma distribuição  $p$ ) é  $E[X] := \int_{\mathbb{R}^n} xp(x) dx$
- as esperanças enrolada e quantizada são  $E[X_\pi] = \int_{\mathcal{D}} xp_\pi(x) dx$  e  $E[X_Q] = \sum_{\lambda \in \Lambda} \lambda p_Q(\lambda)$

# Esperança

- a esperança (média) de uma variável aleatória  $X$  (ou de uma distribuição  $p$ ) é  $E[X] := \int_{\mathbb{R}^n} xp(x) dx$
- as esperanças enrolada e quantizada são  $E[X_\pi] = \int_{\mathcal{D}} xp_\pi(x) dx$  e  $E[X_Q] = \sum_{\lambda \in \Lambda} \lambda p_Q(\lambda)$
- disso, temos que  $E[X] = E[X_\pi] + E[X_Q]$

# Entropia

$$H[X] = - \int_{\mathbb{R}^n} p(x) \log p(x) dx,$$

$$H[X_\pi] = - \int_{\mathcal{D}} p_\pi(y) \log p_\pi(y) dy,$$

$$H[X_Q] = - \sum_{\lambda \in \Lambda} p_Q(\lambda) \log p_Q(\lambda)$$

- temos  $H[X] \leq H[X_\pi] + H[X_Q]$


# Entropia

$$H[X] = - \int_{\mathbb{R}^n} p(x) \log p(x) dx,$$

$$H[X_\pi] = - \int_{\mathcal{D}} p_\pi(y) \log p_\pi(y) dy,$$

$$H[X_Q] = - \sum_{\lambda \in \Lambda} p_Q(\lambda) \log p_Q(\lambda)$$

- temos  $H[X] \leq H[X_\pi] + H[X_Q]$
- mais precisamente,  $H[X] = H[X_\pi] + H[X_Q] - I(X_\pi; X_Q)$



# Informação mútua

- estamos interessados em entender como essa informação mútua se comporta


# Informação mútua

- estamos interessados em entender como essa informação mútua se comporta
- ela pode ser caracterizada através da divergência de Kullback-Leibler como


$$I(X_\pi; X_Q) = D_{\text{KL}}(p || p_\pi \otimes p_Q),$$

onde  $p$  é a distribuição original e  $p_\pi \otimes p_Q(x) = p_\pi(\pi(x))p_Q(Q(x))$

# Distribuições normais com média 0



(a) Original




(b)  $p_\pi \otimes p_Q$


●  $\sigma$  grande  $\implies p_\pi \approx \frac{1}{\det \Lambda}$  e  $p_Q \approx \det \Lambda \cdot p \implies p_\pi \otimes p_Q$  aproxima  $p$



## Distribuições normais com média 0




(a) Original

(b)  $p_\pi \otimes p_Q$ 

- $\sigma$  grande  $\implies p_\pi \approx \frac{1}{\det \Lambda}$  e  $p_Q \approx \det \Lambda \cdot p \implies p_\pi \otimes p_Q$  aproxima  $p$
- $\sigma$  pequeno  $\implies p_Q \approx \delta_0$  e  $p_\pi \approx p|_{\mathcal{D}} \implies p_\pi \otimes p_Q$  aproxima  $p$

# Distribuições normais com média 0



- $\sigma$  grande  $\implies p_\pi \approx \frac{1}{\det \Lambda}$  e  $p_Q \approx \det \Lambda \cdot p \implies p_\pi \otimes p_Q$  aproxima  $p$
- $\sigma$  pequeno  $\implies p_Q \approx \delta_0$  e  $p_\pi \approx p|_{\mathcal{D}} \implies p_\pi \otimes p_Q$  aproxima  $p$
- assim,  $I(X_\pi; X_Q) = D_{\text{KL}}(p || p_\pi \otimes p_Q) \rightarrow 0$  para  $\sigma$  grande ou para  $\sigma$  pequeno

```
In[60]:= Plot[Info[σ], {σ, 0.1, 3}]
```

gráfico




Figura:  $I(X_\pi; X_Q)$  em função de  $\sigma$ .

- máximo:  $\sigma \approx 0.38$

# Outras perspectivas

- estudar o comportamento da informação de Fisher por enrolamento em quantização ( $G_\pi \leq G$  e  $G_Q \leq G$ )

# Outras perspectivas

- estudar o comportamento da informação de Fisher por enrolamento em quantização ( $G_\pi \leq G$  e  $G_Q \leq G$ )
- estudar medidas de distância e divergência nas distribuições enrolada e quantizada (tendo em vista o fator de achatamento)

# Outras perspectivas

- estudar o comportamento da informação de Fisher por enrolamento em quantização ( $G_\pi \leq G$  e  $G_Q \leq G$ )
- estudar medidas de distância e divergência nas distribuições enrolada e quantizada (tendo em vista o fator de achatamento)
- relação com transformada de Fourier:  $\widehat{p}_\pi = \widehat{p}|_{\Lambda^*}$

- [1] T. M. Cover e Joy A. Thomas. *Elements of information theory*. 2nd ed. OCLC: ocm59879802. Hoboken, N.J: Wiley-Interscience, 2006. ISBN: 9780471241959.
- [2] Cong Ling e Jean-Claude Belfiore. “Achieving AWGN Channel Capacity With Lattice Gaussian Coding”. Em: *IEEE Transactions on Information Theory* 60.10 (out. de 2014), pp. 5918–5929. ISSN: 1557-9654. DOI: 10.1109/TIT.2014.2332343.
- [3] Cong Ling, Laura Luzzi e Jean-Claude Belfiore. “Lattice codes achieving strong secrecy over the mod- $\Lambda$  Gaussian Channel”. Em: *2012 IEEE International Symposium on Information Theory Proceedings*. ISSN: 2157-8117. Jul. de 2012, pp. 2306–2310. DOI: 10.1109/ISIT.2012.6283924.
- [4] K. V Mardia e Peter E Jupp. *Directional statistics*. English. OCLC: 1039171708. Chichester; New York: J. Wiley, 2010. ISBN: 9780470317815 9780470316979.