

Sobre cognição e dimensões intrínsecas de sinais

Palestrante: Jugurta Montalvão (jmontalvao@academico.ufs.br)

Duração aproximada: 1 hora e 40 min.

Plano da palestra:

Motivação


Fundamentação

Premissas e questões pertinentes

Evidências cognitivas

Estimação de dimensão intrínseca

Experimentos



Universidade
Federal de
Sergipe

Motivação

Sugerir, através de reflexões simples:

- a) uma relação entre dimensões de sinais e graus de liberdade
- b) evidências de que cognição animal precisa filtrar dimensões
- c) utilidades de (a) e (b) em aprendizado de máquina

Sobre percepção, cognição e modelagem do mundo ao redor

Cognição – do Latim *cognitionem*.

Com o tempo, seu sentido foi estendido para incluir **percepção**.

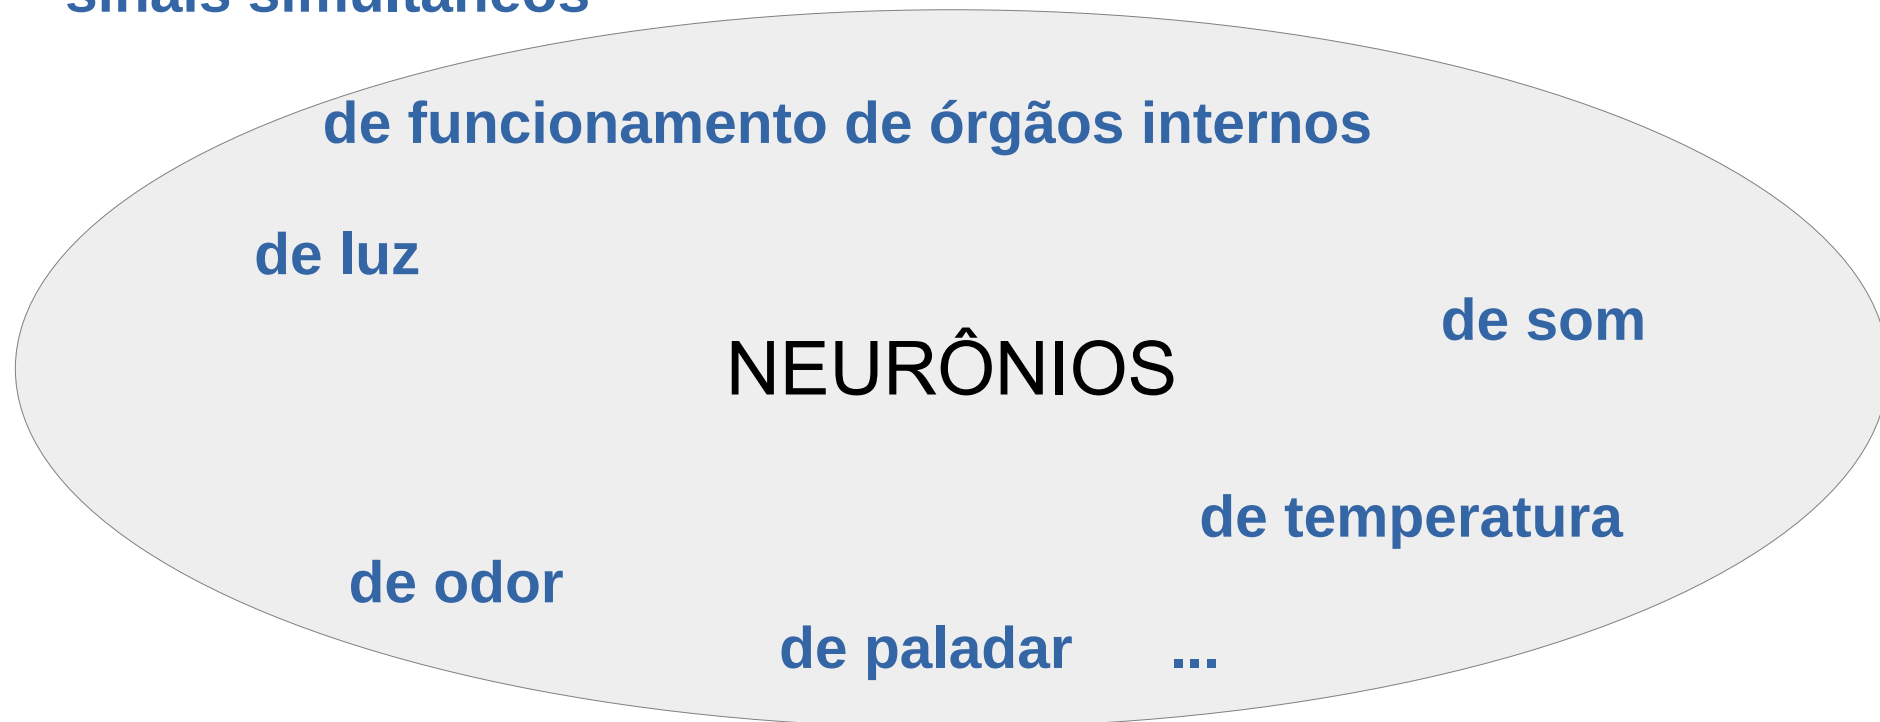
(Fonte: Online Etymology Dictionary, <https://www.etymonline.com/word/cognition>)

A percepção do mundo ao redor é feita através de sensores que captam sinais.

→ **A cognição se inicia na percepção de sinais, através de sensores.**

Sobre percepção, cognição e modelagem do mundo ao redor

Neste exato instante, cada um de nós está recebendo muitos sinais simultâneos



Sobre percepção, cognição e modelagem do mundo ao redor



Caenorhabditis elegans

primeiro organismo multicelular a ter seu genoma completamente sequenciado (1998)

302 neurônios

responsável pela quimiotaxia (movimento guiado por pistas químicas, ou seja, essencialmen cheirando).

Fonte:

https://en.wikibooks.org/wiki/Sensory_Systems/Introduction

Sobre percepção, cognição e modelagem do mundo ao redor



Learning in Plants: Lessons from *Mimosa pudica*

Charles I. Abramson^{1,2*} and Ana M. Chicas-Mosier^{1,2}


¹ Department of Psychology, Laboratory of Comparative Psychology and Behavioral Biology, Oklahoma State University, Stillwater, OK, USA, ² Department of Integrative Biology, Laboratory of Comparative Psychology and Behavioral Biology, Oklahoma State University, Stillwater, OK, USA



CrossMark

Questão fundamental (Q0):

Quantos exemplos (observações) são necessárias para que um ser cognitivo “entenda” algo?



Entender: ajustar e/ou reconhecer um modelo de causa-efeito

?



Um exemplo emblemático da era “Deep Learning”:

**Problema 'real' da
classificação de imagem (mini-fotos)**

Base **CIFAR-10** (Canadian Institute
for Advanced Research) :

60.000 imagens, 32x32 pixels coloridos cada

Cada imagem – um ponto num espaço
com **3072 dimensões** (32 x 32 x 3)

**5.000 imagens rotuladas para se aprender
a reconhecer cada uma das 10 classes!**

SUFICIENTES?

airplane



automobile



bird



cat



deer



dog



frog



horse




ship



truck





Universidade
Federal de
Sergipe

Fundamentos

Liberdade

Conceito mal definido...



Graus de Liberdade

Conceito que pode ser
bem definido.

buscando uma definição tão simples quanto possível...

Graus de Liberdade



1 grau de liberdade → Liberdade de ação em apenas uma direção

1 régua contínua de posições possíveis

Graus de Liberdade



2 graus de liberdade → ação livre em duas direções

2 réguas contínuas

Graus de Liberdade



A rainha pode se mover livremente ao longo de qualquer uma das réguas, incluindo nas duas, simultaneamente.

2 réguas discretas de posições

Quantos graus de liberdade?

Graus de Liberdade



O bispo só pode se mover ao longo de uma das diagonais, a cada movimento
(nunca nas duas diagonais ao mesmo tempo!)
Ainda temos 2 réguas discretas, mas há mais restrições de movimento

Quantos graus de liberdade?

Graus de Liberdade

De volta ao simples. Ainda mais simples... 1 régua com apenas duas posições: A e B



Se $P(A) = P(B) = 0.5 \rightarrow 1$ grau de liberdade

Se $P(A) = 1$ e $P(B) = 0 \rightarrow 0$ graus de liberdade (ou ausência de liberdade de escolha)

... e se $P(A) = 0.9$ e $P(B) = 0.1$?

Graus de Liberdade

A resposta deve estar entre 0 e 1 graus de liberdade...



Duas definições consistentes com essa expectativa:

Graus de liberdade = $-\log_2 (P(A)^2 + P(B)^2)$

entropia de colisão
ou entropia quadrática

e

Graus de liberdade = $-P(A) \log_2 (P(A)) - P(B) \log_2 (P(B))$

entropia de Shannon

Graus de Liberdade

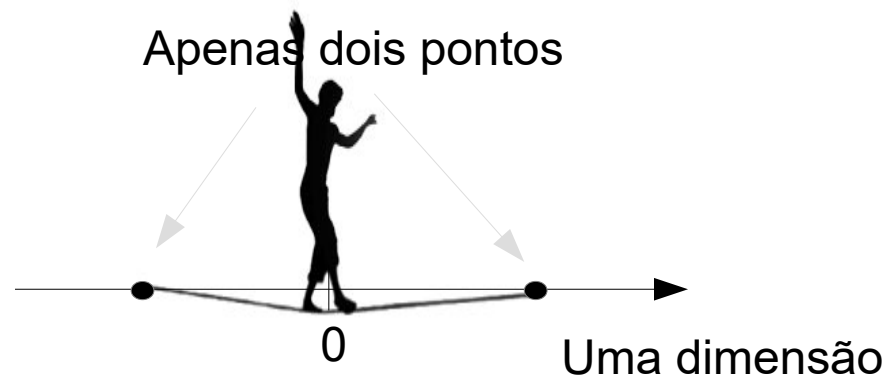
Para o cálculo do grau de liberdade com apenas dois lados/estados em uma direção (uma dimensão), precisamos conhecer as probabilidades $P(A)$ e $P(B)$.



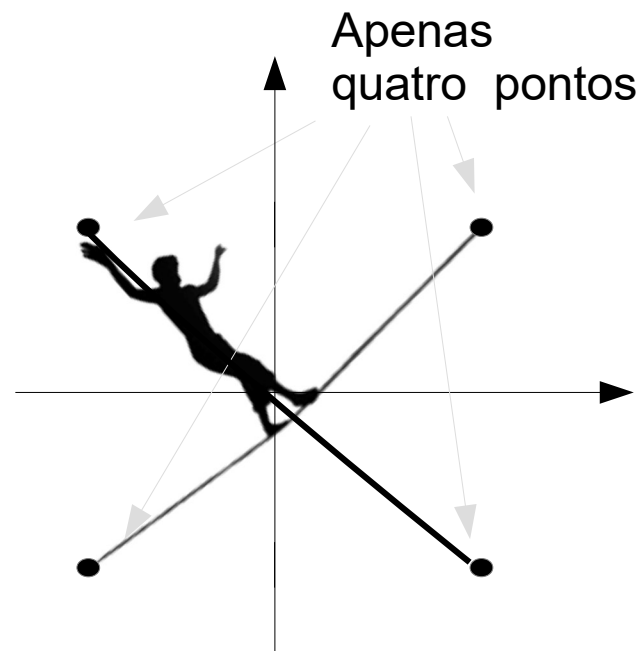
Para a estimação das probabilidades $P(A)$ e $P(B)$, precisamos de $N \gg 2$ observações independentes (dados).

Uma breve reflexão sobre espaços mal preenchidos com pontos (observações/amostras):

1 dim., 2 pontos



2 dim., 4 pontos



3 dim., 8 pontos,...


D dim., 2^D pontos ← Poucas observações

Graus de Liberdade

Lado 0

Lado 1

Cada pixel como uma direção com dois lados



0	0	0	0	0	0	0	0
0	0	0	1	0	0	0	0
0	0	1	1	0	0	0	0
0	0	0	1	0	0	0	0
0	0	0	1	0	0	0	0
0	0	0	1	0	0	0	0
0	0	1	1	1	0	0	0
0	0	0	0	0	0	0	0


Imagem como matriz (8x8 = 64 pixels)

Graus de Liberdade

Lado 0

Lado 1


Cada pixel como uma direção com dois lados



0	0	0	0	0	0	0	0
0	0	0	1	0	0	0	0
0	0	1	1	0	0	0	0
0	0	0	1	0	0	0	0
0	0	0	1	0	0	0	0
0	0	0	1	0	0	0	0
0	0	1	1	1	0	0	0
0	0	0	0	0	0	0	0

Imagem como matriz (8x8 = 64 pixels)

64 dim., $2^{64} \sim 1.8 \times 10^{19}$ ← Poucas observações (!?!)



Universidade
Federal de
Sergipe

Algumas premissas e mais questões

Premissas razoáveis:

P1: A cognição é ajustada a partir de exemplos (aprendizado)

P2: Os exemplos devem ser em número e diversidade suficiente para que as leis de formação dos exemplos sejam aprendidas

P3: Mesmo os seres primitivos com algum poder de adaptação ao ambiente possuem sensores (e.g. químicos, mecânicos, elétricos, eletromagnéticos)

P4: Cada sensor pode ser visto como uma dimensão de medida.
Por exemplo, cada bastonete no olho humano mede intensidade luminosa.

P5: O número de sensores – portanto a dimensão aparente de medidas do mundo ao redor – é muito alto. Por exemplo, no olho humano, são encontrados 100 milhões de bastonetes.

P6: Mesmo os 302 neurônios da *C. Elegans*, se forem considerados como dimensões independentes de percepção, demandariam a coleta de muito mais de 2^{302} padrões do ambiente desse animal primitivo.


Como é possível qualquer animal (ou vegetal) aprender algo sobre o mundo ao redor, se a quantidade de observações necessárias a isso parece ser sempre inviável (absurdamente grande)?

Resposta hipotética:

Apesar das altas dimensões aparentes, as dimensões intrínsecas dos fenômenos observados são muito menores, pequenas o suficiente para que as observações feitas pelos indivíduos sejam suficientes ao aprendizado.

Notas importantes:

- A dimensão aparente é determinada, em parte, pelo observador
- A dimensão intrínseca do fenômeno é determinada pelos graus de liberdade do fenômeno observado.



Universidade
Federal de
Sergipe

Evidências




Problema:

4096 sensores simultâneos de intensidade luminosa monitoram pontos de um "processo".


Em quatro instantes diferentes, foram coletados os seguintes perfis de medidas →

Alguma anomalia perceptível?


Instante 1




Instante 2



Instante 3



Instante 4












Uma “pegadinha”:









De fato, os dados foram coletados de 4096 sensores simultâneos de intensidade luminosa.

Mas esses sensores fazem parte de uma única câmera digital.

Assim, as 4096 medidas podem ser apresentadas como uma imagem com 64x64 níveis de cinza.





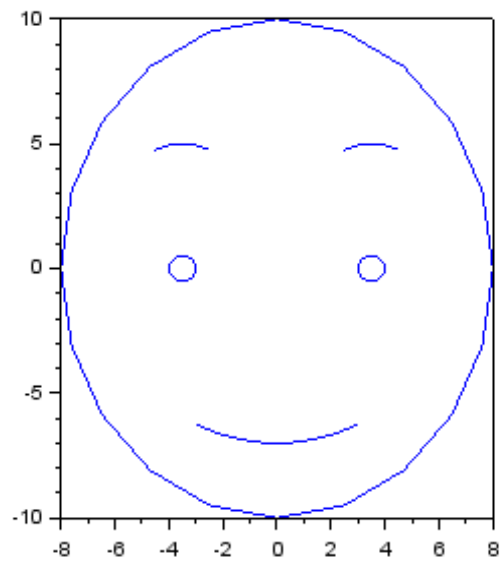


Questões para reflexão:

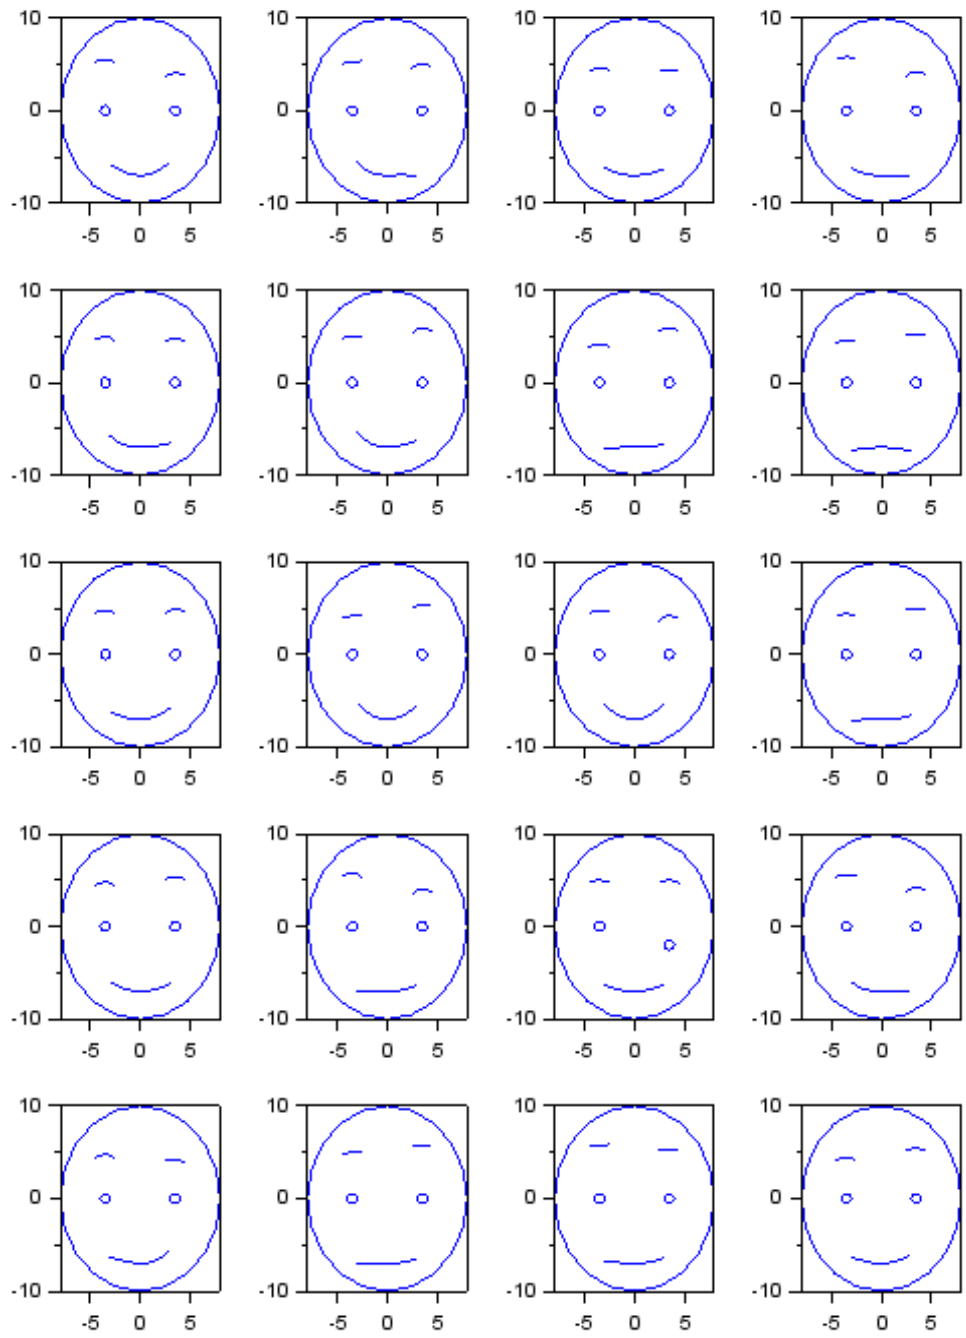
a) por que a anomalia é perceptível na representação da direita, mas não na da esquerda?

b) quantos graus de liberdade (aproximadamente) têm as 4096 medidas? (fotos tiradas de vários pontos de vista e vários níveis de iluminação da mesma estátua)


c) Há alguma relação entre as questões (a) e (b)?



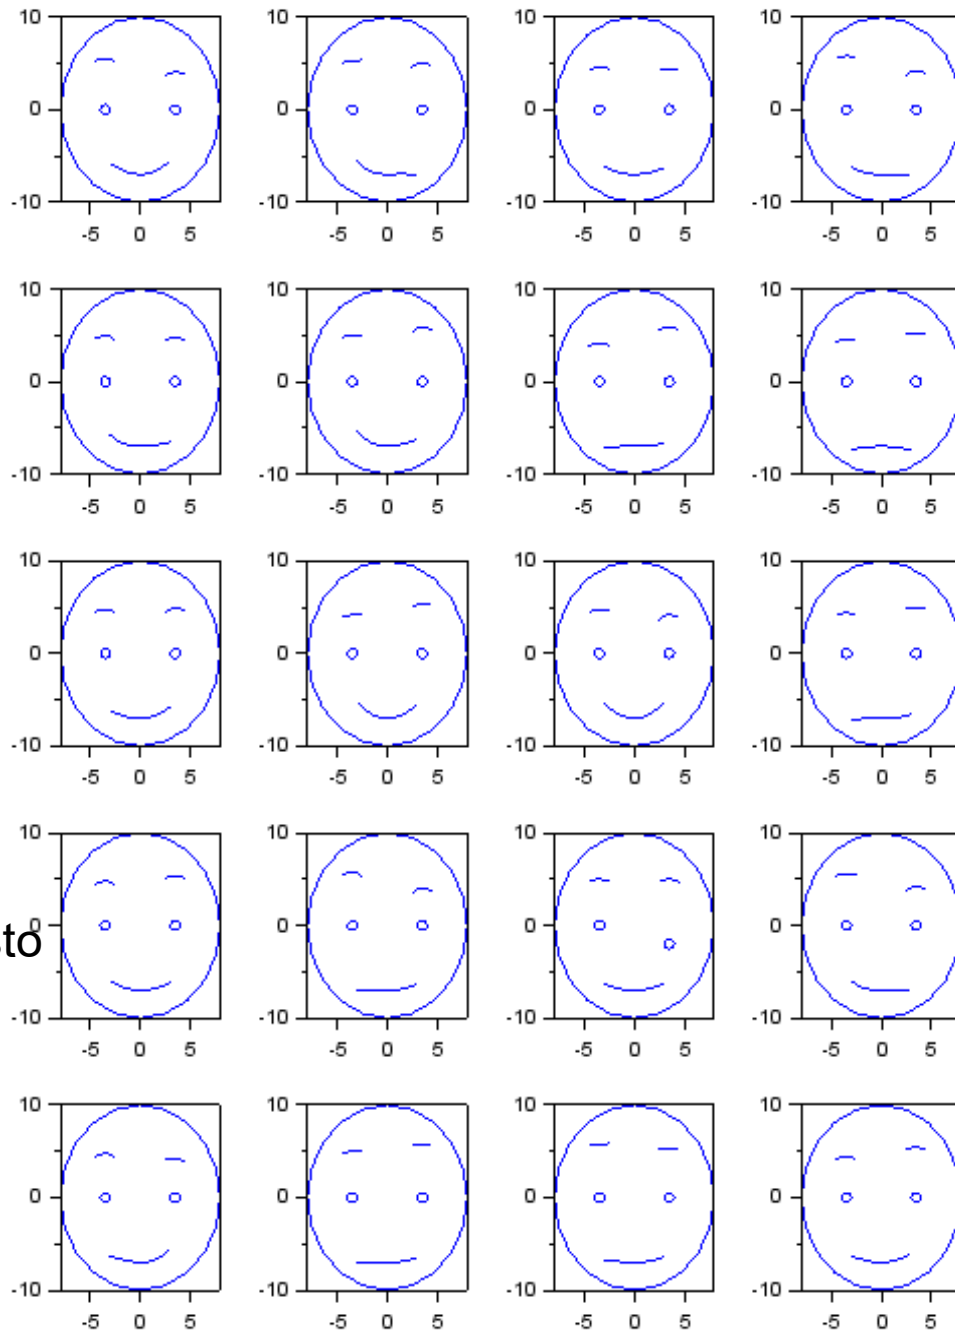
Rosto médio



Onde está a anomalia?



Rosto médio




Onde está a anomalia?

Questões:

a) Se nenhum rosto é igual ao rosto médio, então por que apenas um é anômalo.

b) Quantos graus de liberdade na geração dos rostos?

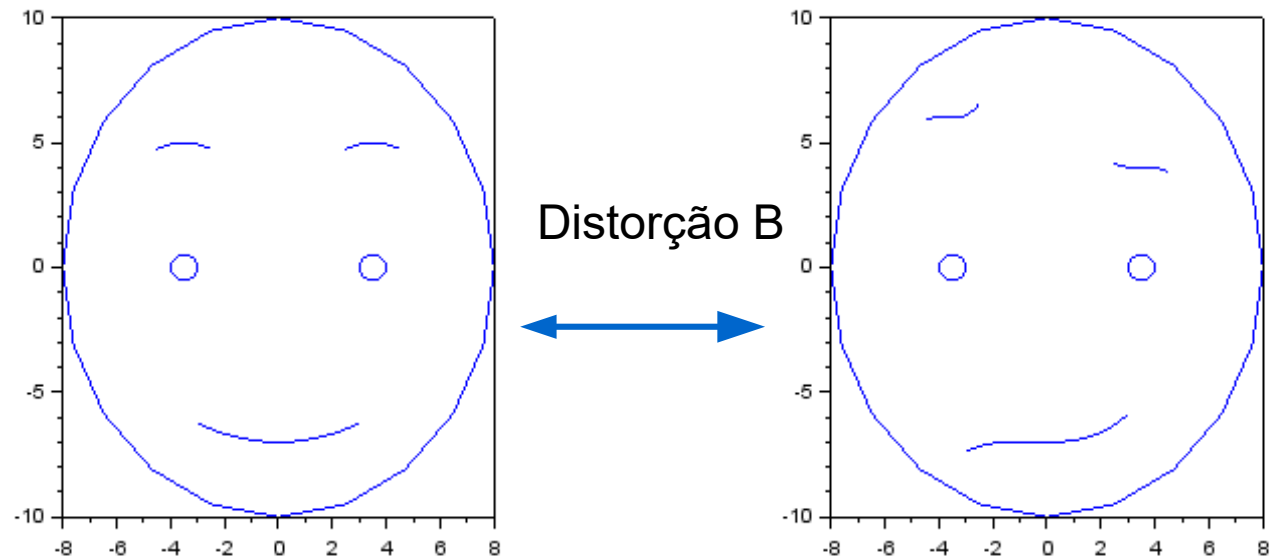
c) Qual a relação entre (a) e (b)?



Qual das duas distorções é percebida como anomalia, A ou B?

Questões:

- a) Qual a maior distorção, em termos de deslocamento de traços?
- b) Qual delas parece anômala?
- c) Onde está guardada a regra que faz com que a platéia (geralmente) concorde?



**Dependências geram
estruturas com baixas
dimensões intrínsecas
– ilustrações simples**

Observe cada blocos de 3 *pixels* (em escala de cinza) e tente inferir se há dependência entre os sorteios aleatórios (ou os *pixels*):




Fonte Aleatória

1 observação =
3 números
entre 0 e 255



0, 255, 50

64 observações



Atenção: Esta máquina pode ter sido adulterada!

Olhe novamente: outra representação dos mesmos 64 blocos de 3 *pixels* (64 amostras 3-D).


Fonte aleatória percebida?



1 observação =
3 números
sorteados

64 observações

A dependência (**lei de formação**) é melhor




Conclusão: restrição (dependência) → Estrutura (*manifold*)
Dá para perceber o *tamanho* da estrutura?

E agora?

Fonte aleatória



3000 observações



Questões: 3000 amostras no espaço 3-D

a) são suficientes à cognição de alguma lei de formação?

b) se sim, essa quantidade suficiente depende da estrutura (*manifold*) formado?

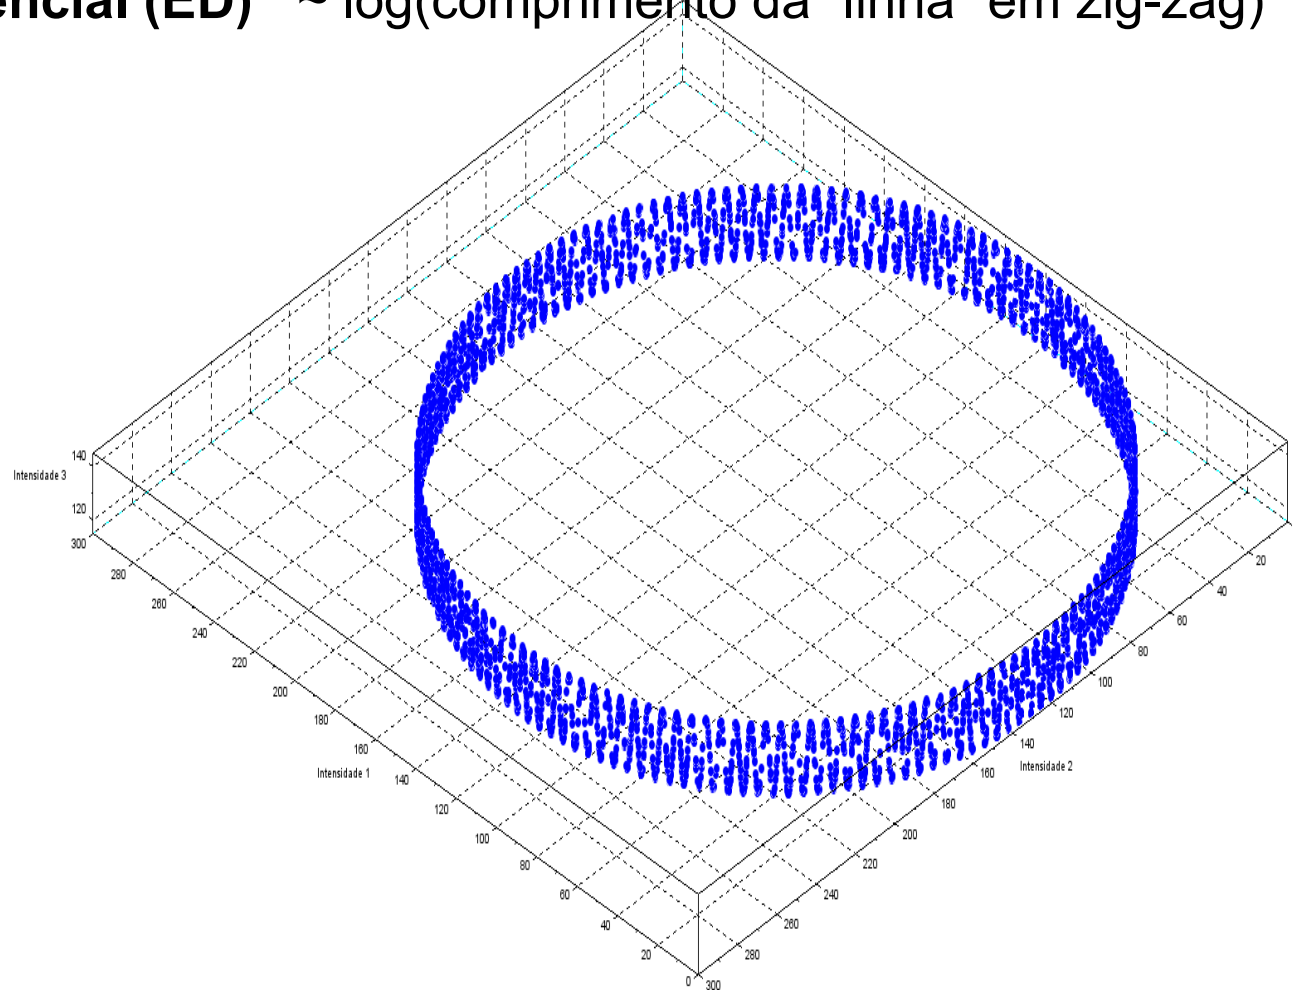
Nesta ilustração:

Dimensão Intrínseca (DI) = 1 (pois a estrutura percebida pode ser cortada e esticada em uma linha)

Entropia Diferencial (ED) $\sim \log(\text{comprimento da "linha" em zig-zag})$



3000 amostras



Variedades matemáticas (*Manifold*, em Inglês), conceito teórico sistematizado por B. Riemann.

E se... fossem blocos de 4096 (64x64) pixels em escala de cinza (0 a 255):

Fonte aleatória



de blocos com
64x64 pixels

698 observações

(Obs.: apenas 64
das 698 imagens
são mostradas ao
lado)



... ou ainda blocos de 1024 (32x32) pixels em escala de cinza (0 a 255):

Fonte aleatória



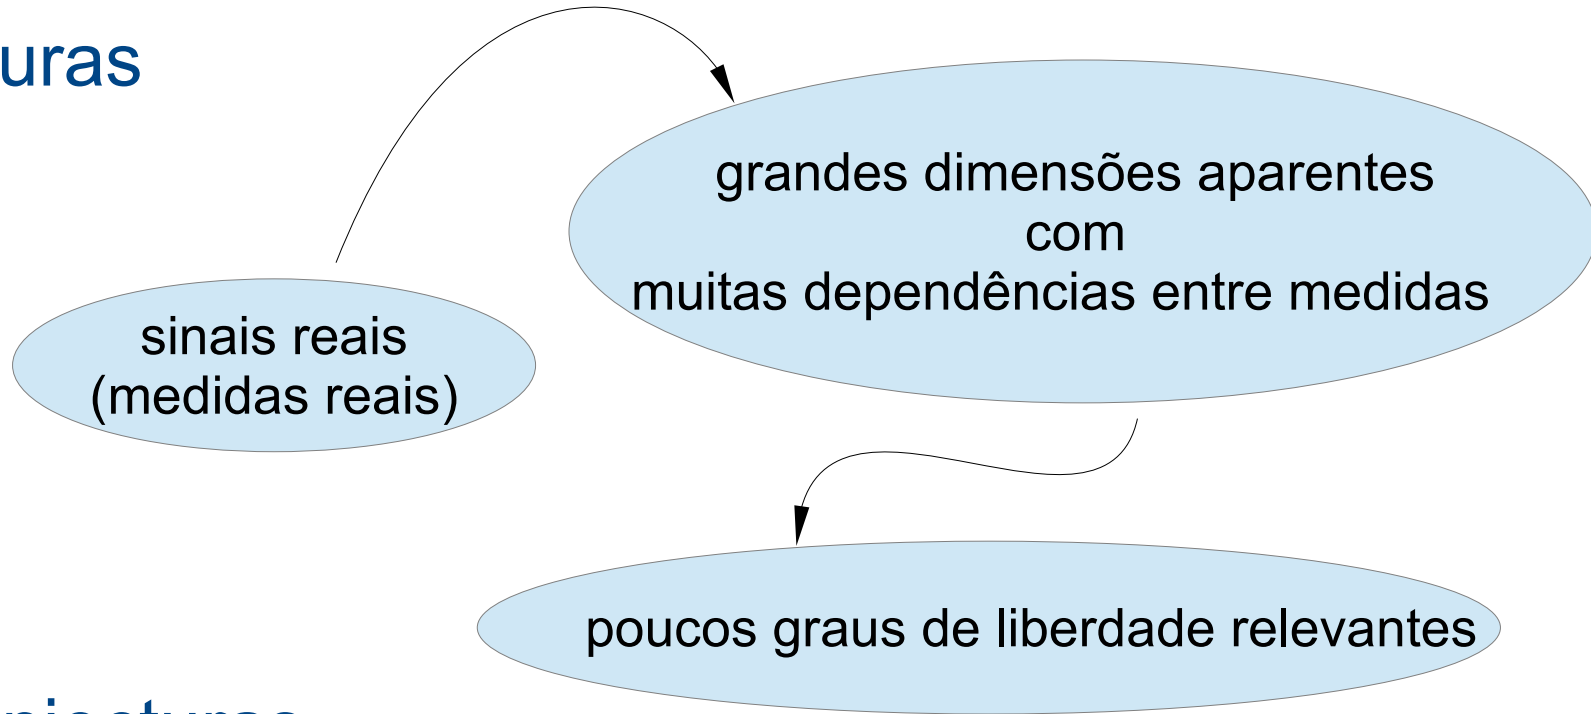
de blocos com
32x32 pixels

50000 observação

(Obs.: apenas 64
das 50.000 imagens
são mostradas ao
lado)



Conjecturas



Mais conjecturas

A **cognição** e a **percepção de leis de formação** são fortemente relacionadas (possivelmente idênticas, mas isto é tema para filósofos...)

Leis de formação em sinais reais geram estruturas (*manifolds*)

O que fazer para começar a entender a cognição?

- Medir as variedades (dimensão intrínseca, volume, curvatura etc.)
- Modelar as variedades
- Desenrolar as variedades (representação da essência dos sinais)

Quem também andou pensando assim?

IEEE TRANSACTIONS ON NEURAL NETWORKS AND LEARNING SYSTEMS, VOL. 27, NO. 10, OCTOBER 2016

Why Deep Learning Works: A Manifold Disentanglement Perspective

Pratik Prabhanjan Brahma, Dapeng Wu, *Fellow, IEEE*, and Yiyuan She

J Stat Phys
DOI 10.1007/s10955-017-1836-5

Why Does Deep and Cheap Learning Work So Well?

Henry W. Lin¹ · Max Tegmark² · David Rolnick³

“(...) it is still not fully understood why deep learning works so well. In contrast to GOF AI (“good old-fashioned AI”) algorithms(...)”

- [6] Y. Bengio, O. Delalleau, and N. L. Roux, “The curse of highly variable functions for local kernel machines,” in *Proc. Adv. Neural Inf. Process. Syst.*, Vancouver, BC, Canada, 2005, pp. 107–114.
- [7] G. E. Hinton and R. R. Salakhutdinov, “Reducing the dimensionality of data with neural networks,” *Science*, vol. 313, no. 5786, pp. 504–507, 2006.
- [8] L. Wan, M. Zeiler, S. Zhang, Y. LeCun, and R. Fergus, “Regularization of neural networks using DropConnect,” in *Proc. 30th Int. Conf. Mach. Learn.*, Atlanta, GA, USA, Jun. 2013, pp. 1058–1066.
- [9] G. Hinton *et al.*, “Deep neural networks for acoustic modeling in speech recognition: The shared views of four research groups,” *IEEE Signal Process. Mag.*, vol. 29, no. 6, pp. 82–97, Nov. 2012.
- [10] Y. Bengio, G. Mesnil, Y. Dauphin, and S. Rifai, “Better mixing via deep representations,” in *Proc. 30th Int. Conf. Mach. Learn.*, Atlanta, GA, USA, Jun. 2013, pp. 552–560.
- [11] Y. Bengio, A. Courville, and P. Vincent, “Representation learning: A review and new perspectives,” *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 35, no. 8, pp. 1798–1828, Aug. 2013.


Como medir as estruturas a partir das observações?

- dimensão intrínseca
- volume (ou entropia diferencial)

Estimadores de dimensões intrínsecas

Box-counting
(teoria de fractais)

Dimensão de correlação
(contagem de coincidências)
Grassberger-Procaccia,
1983



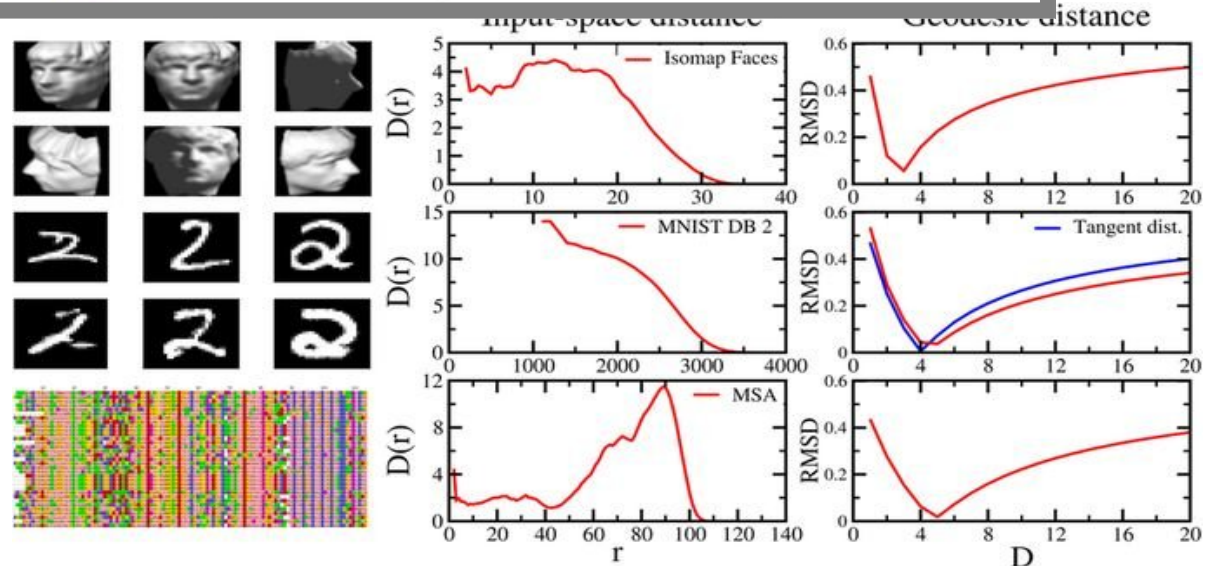
Estimating the intrinsic dimension
of datasets by a minimal
neighborhood information

2017

Elena Facco, Maria d'Errico, Alex Rodriguez & Alessandro Laio

Distâncias geodésicas (grafos)

Análise PCA local
(mais métodos)...



Uma (meta) coincidência de métodos

Journal of Statistical Physics, Vol. 26, No. 2, 1981

1981

Calculation of Entropy from Data of Motion

Shang-keng Ma¹

Received November 18, 1980

We discuss the question of determining the entropy given the phase space trajectory which describes the detailed history of a many-body system over a

2.1. Coincidence and the Size of a Region

The basic idea of using coincidence counting to calculate entropy is extremely simple. Suppose that the trajectory is a set of n points randomly distributed in a region of Γ positions. Even if n is much smaller than Γ , there is a nonzero chance for coincidence, i.e., some positions will get more than one point. Since the probability for a point to fall in any given position is $1/\Gamma$, the number of coincidences is easily estimated:

$$N_c = n(n-1)/2 \times 1/\Gamma \quad (2.1)$$

Let us define R to be the coincidence rate which is the probability of finding a coincidence per trial. There are $n(n-1)/2$ trials; therefore,

$$R = 1/\Gamma \quad (2.2)$$

$$\Gamma = N_t/N_c$$

$$N_t = n(n-1)/2$$

$$S = \ln(1/R) \quad (2.3)$$

Physical 9D (1983) 189-208
North-Holland Publishing Company

1983

MEASURING THE STRANGENESS OF STRANGE ATTRACTORS

Peter GRASSBERGER[†] and Itamar PROCACCIA

Department of Chemical Physics, Weizmann Institute of Science, Rehovot 76100, Israel

Received 16 November 1982

Revised 26 May 1983

We study the correlation exponent ν introduced recently as a characteristic measure of strange attractors which allows one to distinguish between deterministic chaos and random noise. The exponent ν is closely related to the fractal dimension and the information dimension, but its computation is considerably simpler. The computation of ν for systems with a large number of degrees of freedom from very high dimensional systems is stressed. Algorithm

$$C(l) = \lim_{N \rightarrow \infty} \frac{1}{N^2} \times \{ \text{number of pairs } (i, j) \text{ whose distance } |X_i - X_j| \text{ is less than } l \}. \quad (1.5)$$

The correlation integral is related to the standard correlation function

$$c(r) = \lim_{N \rightarrow \infty} \frac{1}{N^2} \sum_{\substack{i, j=1 \\ i \neq j}}^N \delta^F(X_i - X_j - r) \quad (1.6)$$

by

$$C(l) = \int_0^l d^F r c(r). \quad (1.7)$$

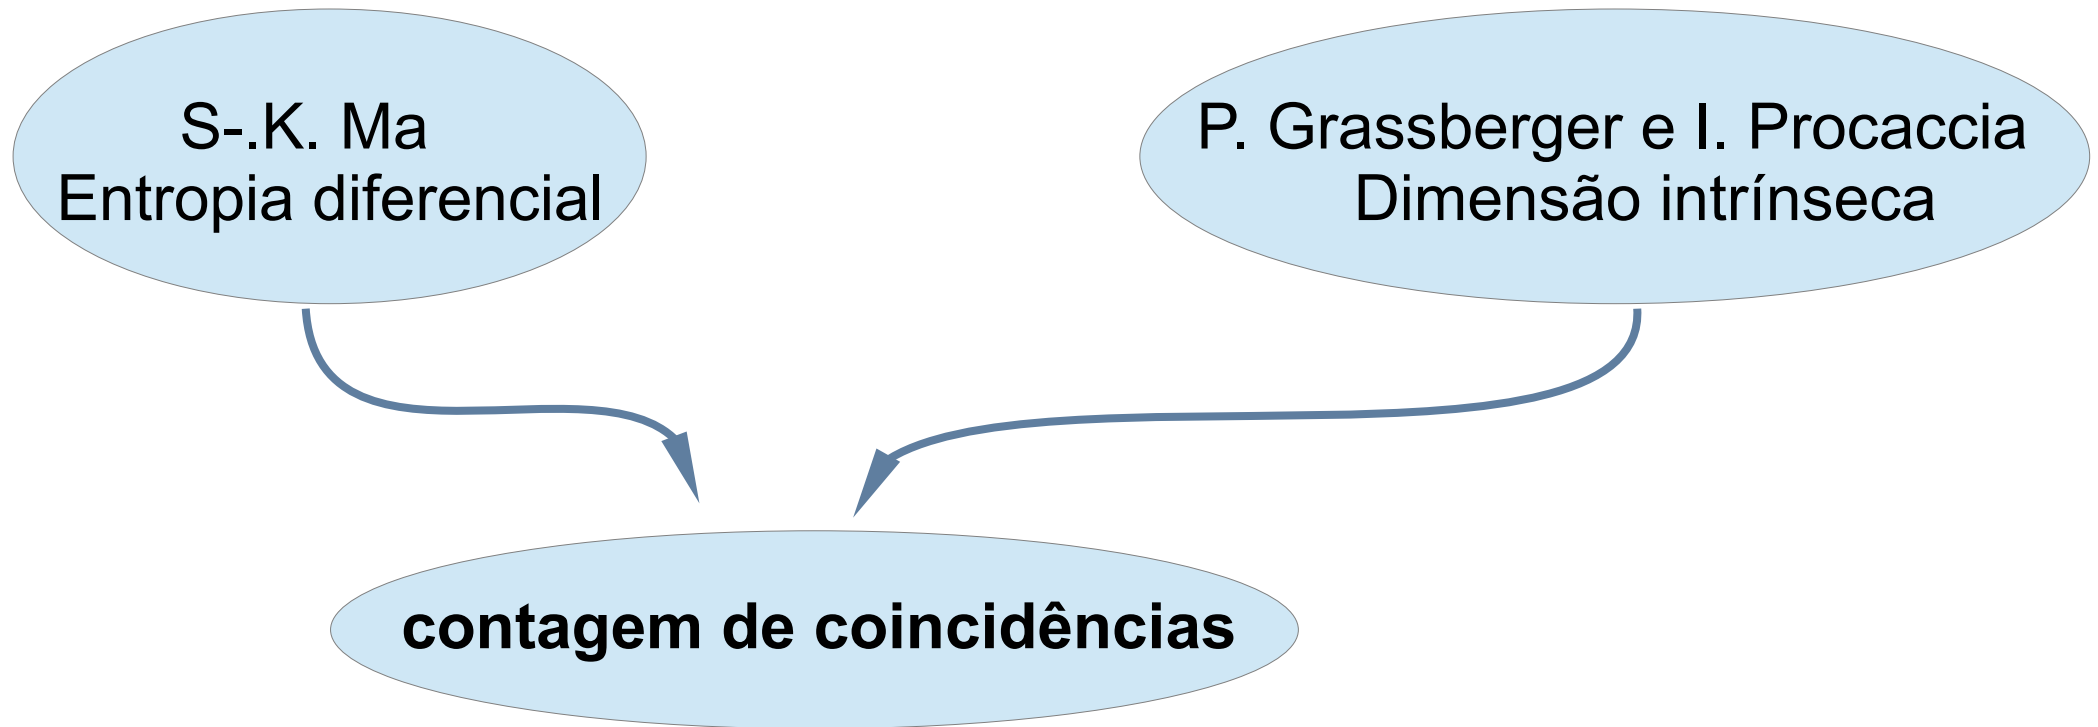
One of the central aims of this paper is to establish that for small l 's $C(l)$ grows like a power

$$C(l) \sim l^\nu, \quad (1.8)$$

and that this "correlation exponent" can be taken as a most useful measure of the local structure of a strange attractor. It seems that ν is more relevant,

Estimadores baseados em contagem de coincidências

Questão: Qual o ponto comum entre os métodos?

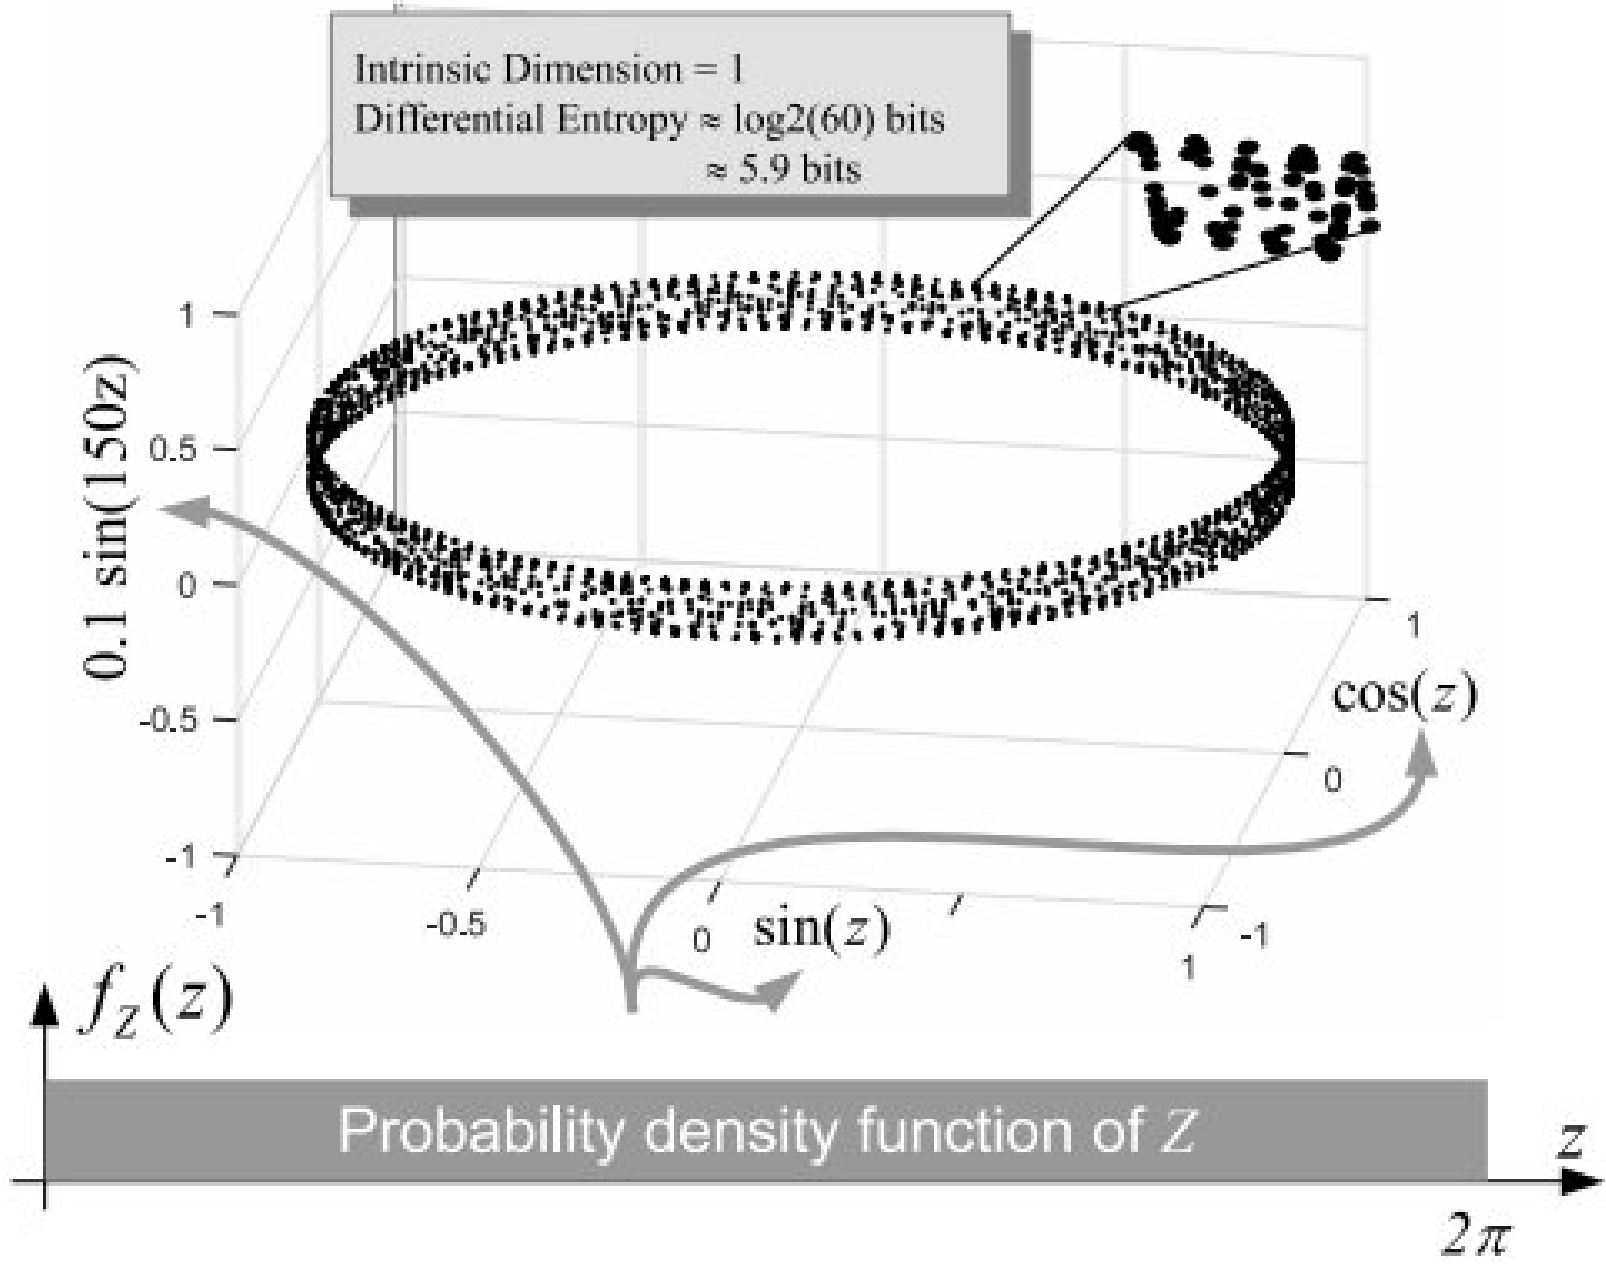




Num espaço métrico: contagem de vizinhos (observações “coincidentes”) para uma vizinhança de tamanho variável

**Aviso de auto-propaganda
no próximo *slide*!**

Noise Variance Estimation Through Joint Analysis of Intrinsic Dimension and Differential Entropy

Jugurta Montalvão 






Problemas de viés nos estimadores

Problemas à vista...

Para a estimação de dimensão,
esse viés já tinha sido modelado
desde 1988, por L. A. Smith



Volume 133, number 6

PHYSICS LETTERS A

21 November 1988

INTRINSIC LIMITS ON DIMENSION CALCULATIONS

Leonard A. SMITH

Department of Applied Mathematics and Theoretical Physics, University of Cambridge, Cambridge CB3 9EW, UK

Bias-Compensated Estimator for Intrinsic Dimension and Differential Entropy: A Visual Multiscale Approach

Jugurta Montalvão, Jânio Canuto, and Luiz Miranda

Experimentos com Imagens

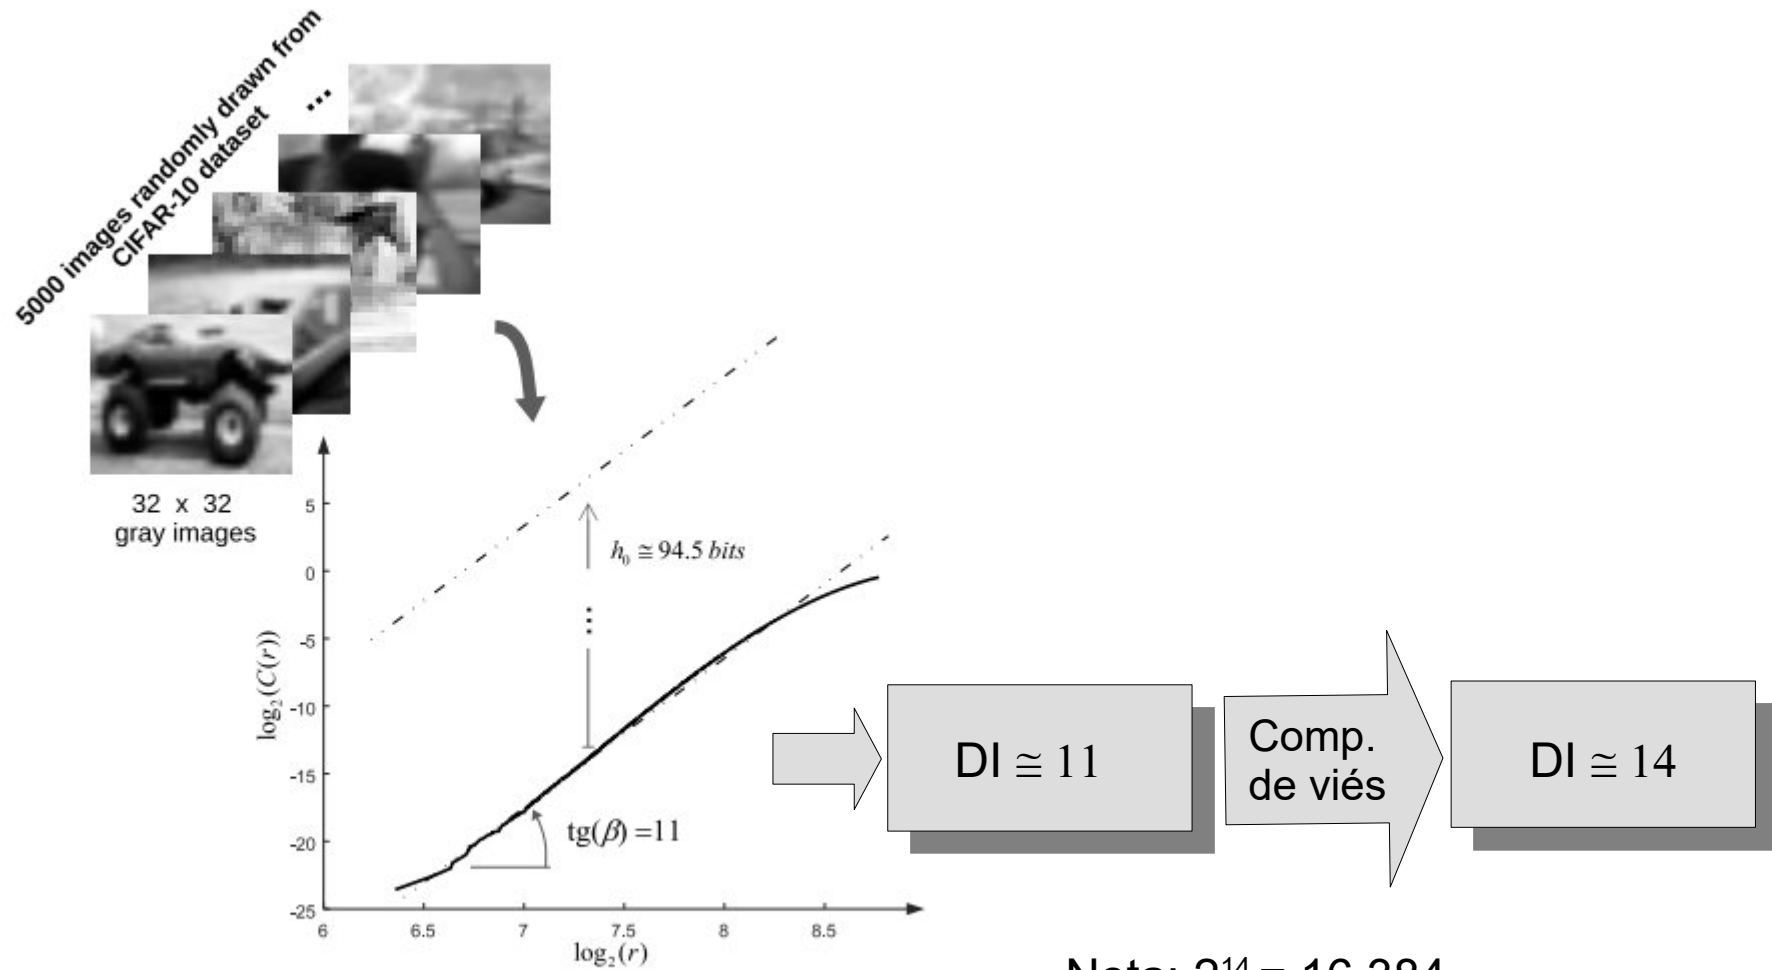


Fig. 12. ID estimation for 5000 images from the CIFAR-10 dataset. The apparent ID is about 11, whereas the apparent DE is about 94.5 bits, both biased.

Nota: $2^{14} = 16.384$

Base CIFAR-10: total de 50.000 imagens





Fig. 13. ID estimation for 5000 images randomly drawn and cropped around their center from the COCO dataset. Two main apparent ID can be observed. The smallest scale yields an apparent ID of about 9.6, for an apparent DE of about 75 bits.

**Experimentos
com
Vozes humanas**

Conjunto de dados públicos de falas masculinas e femininas em português brasileiro

Padrões de 18 Coeficientes Cepstrais de Frequência Mel (MFCC)
Representando intervalos de 25 ms

C. A. Ynoguti and F. Violaro, "A Brazilian Portuguese speech database,"
in *Proc. 26th Simpósio Brasileiro de telecomunicações*, 2008, pp. 1–4.




**Experimentos
com
Nariz Eletrônico**




Nariz com 10 sensores (8 do tipo MOX mais sensores de temperatura e umidade), expostos a 7 misturas controladas de carne bovina e suína. Base usada e publicada por



R. Sarno, S. I. Sabilla, D. R. Wijaya, D. Sunaryono, and C. Fatichah, "Electronic nose dataset for pork adulteration in beef," *Data Brief*, vol. 32, Oct. 2020, Art. no. 106139.



Nariz com 11 sensores (9 do tipo MOX mais sensores de temperatura e umidade), expostos ao ambiente rotineiro de uma cozinha doméstica (Projeto DomOdor – UFS, 2019 - 2022) .




Experimentos com Textos

Conjunto de dados *Newsgroups*, onde cada uma de 16242 postagens (textos em linguagem natural) foi codificada como um vetor binário 100D, onde a ocorrência de 100 palavras mais relevantes.



<https://cs.nyu.edu/~roweis/data/>



Experimentos com a base de sinais



**KU-HAR: An Open Dataset for Human
Activity Recognition**

DOI: [10.17632/45f952y38r.5](https://doi.org/10.17632/45f952y38r.5)

Experimentos com a sinal de caminhada

**Sinal escolhido: '1037_L_1_0.csv'
(classe *walk*)**


Apenas sinais de acelerômetro → 3 dimensões aparentes
Número de observações > 2386 pontos no 3D



$DI \cong 3$
 $ED \cong 7 \text{ bits}$


Detailed description: A grey box containing the text $DI \cong 3$ and $ED \cong 7 \text{ bits}$. A large grey arrow points from the log-log plot to this box.

Apenas sinais de giroscópio → 3 dimensões aparentes
Número de observações > 2386 pontos no 3D




Fusão de 3 sinais de acelerômetro com 3 sinais de giroscópio → 6 dimensões aparentes
Número de observações > 2386 pontos no 6D (necessidade de compensação de viés)

Atenção: intensidades das duas fontes de sinais foram equalizadas!





Número de observações:
 $N = 2384$ pontos

Janela: $M=2 \rightarrow 2384$ pontos no 12-D
 (necessidade de compensação de viés)




Janela de M instantes de observação \rightarrow [$X_{11} X_{12} X_{13} X_{14} X_{15} X_{16}$
 $X_{21} X_{22} X_{23} X_{24} X_{25} X_{26}$
 \dots
 $X_{M1} X_{M2} X_{M3} X_{M4} X_{M5} X_{M6}$]

Ponto no $R^{6 \times M}$: \rightarrow [$X_{11} X_{12} X_{13} X_{14} X_{15} X_{16} X_{21} X_{22} X_{23} X_{24} X_{25} X_{26} \dots X_{M3} X_{M4} X_{M5} X_{M6}$]





Número de observações:
 $N = 2381$ pontos

Janela: $M=5 \rightarrow 2381$ pontos no 30-D
 (necessidade de compensação de viés)




Janela de M instantes de observação \rightarrow [$X_{11} X_{12} X_{13} X_{14} X_{15} X_{16}$
 $X_{21} X_{22} X_{23} X_{24} X_{25} X_{26}$
 \dots
 $X_{M1} X_{M2} X_{M3} X_{M4} X_{M5} X_{M6}$]

Ponto no $R^{6 \times M}$: \rightarrow [$X_{11} X_{12} X_{13} X_{14} X_{15} X_{16} X_{21} X_{22} X_{23} X_{24} X_{25} X_{26} \dots X_{M3} X_{M4} X_{M5} X_{M6}$]





Janela: $M=10 \rightarrow 2376$ pontos no 60-D
(necessidade de compensação de viés)




Janela de M instantes de observação \rightarrow [$X_{11} X_{12} X_{13} X_{14} X_{15} X_{16}$
 $X_{21} X_{22} X_{23} X_{24} X_{25} X_{26}$
 \dots
 $X_{M1} X_{M2} X_{M3} X_{M4} X_{M5} X_{M6}$]

Ponto no $R^{6 \times M}$: \rightarrow [$X_{11} X_{12} X_{13} X_{14} X_{15} X_{16} X_{21} X_{22} X_{23} X_{24} X_{25} X_{26} \dots X_{M3} X_{M4} X_{M5} X_{M6}$]





Janela: $M=25 \rightarrow 2361$ pontos no 150-D
(necessidade de compensação de viés)




Janela de M instantes de observação \rightarrow [$X_{11} X_{12} X_{13} X_{14} X_{15} X_{16}$
 $X_{21} X_{22} X_{23} X_{24} X_{25} X_{26}$
 \dots
 $X_{M1} X_{M2} X_{M3} X_{M4} X_{M5} X_{M6}$]

Ponto no $R^{6 \times M}$: \rightarrow [$X_{11} X_{12} X_{13} X_{14} X_{15} X_{16} X_{21} X_{22} X_{23} X_{24} X_{25} X_{26} \dots X_{M3} X_{M4} X_{M5} X_{M6}$]





Janela: $M=50 \rightarrow 2336$ pontos no 300-D
(necessidade de compensação de viés)




Janela de M instantes de observação \rightarrow [$X_{11} X_{12} X_{13} X_{14} X_{15} X_{16}$
 $X_{21} X_{22} X_{23} X_{24} X_{25} X_{26}$
 \dots
 $X_{M1} X_{M2} X_{M3} X_{M4} X_{M5} X_{M6}$]

Ponto no $R^{6 \times M}$: \rightarrow [$X_{11} X_{12} X_{13} X_{14} X_{15} X_{16} X_{21} X_{22} X_{23} X_{24} X_{25} X_{26} \dots X_{M3} X_{M4} X_{M5} X_{M6}$]





Janela: $M=100 \rightarrow 2286$ pontos no 600-D
(necessidade de compensação de viés)



Janela de M instantes de observação \rightarrow [$X_{11} X_{12} X_{13} X_{14} X_{15} X_{16}$
 $X_{21} X_{22} X_{23} X_{24} X_{25} X_{26}$
 \dots
 $X_{M1} X_{M2} X_{M3} X_{M4} X_{M5} X_{M6}$]

Ponto no $R^{6 \times M}$: \rightarrow [$X_{11} X_{12} X_{13} X_{14} X_{15} X_{16} X_{21} X_{22} X_{23} X_{24} X_{25} X_{26} \dots X_{M3} X_{M4} X_{M5} X_{M6}$]




Experimentos com a sinal de repouso

Sinal escolhido: '1075_F_1.csv'
(classe *lay*)

Fusão de 3 sinais de acelerômetro com 3 sinais de giroscópio → 6 dimensões aparentes
Número de observações > 2500 pontos no 6D (necessidade de compensação de viés)

Atenção: intensidades das duas fontes de sinais foram equalizadas!




Número de observações:

$N = 2499$ pontos

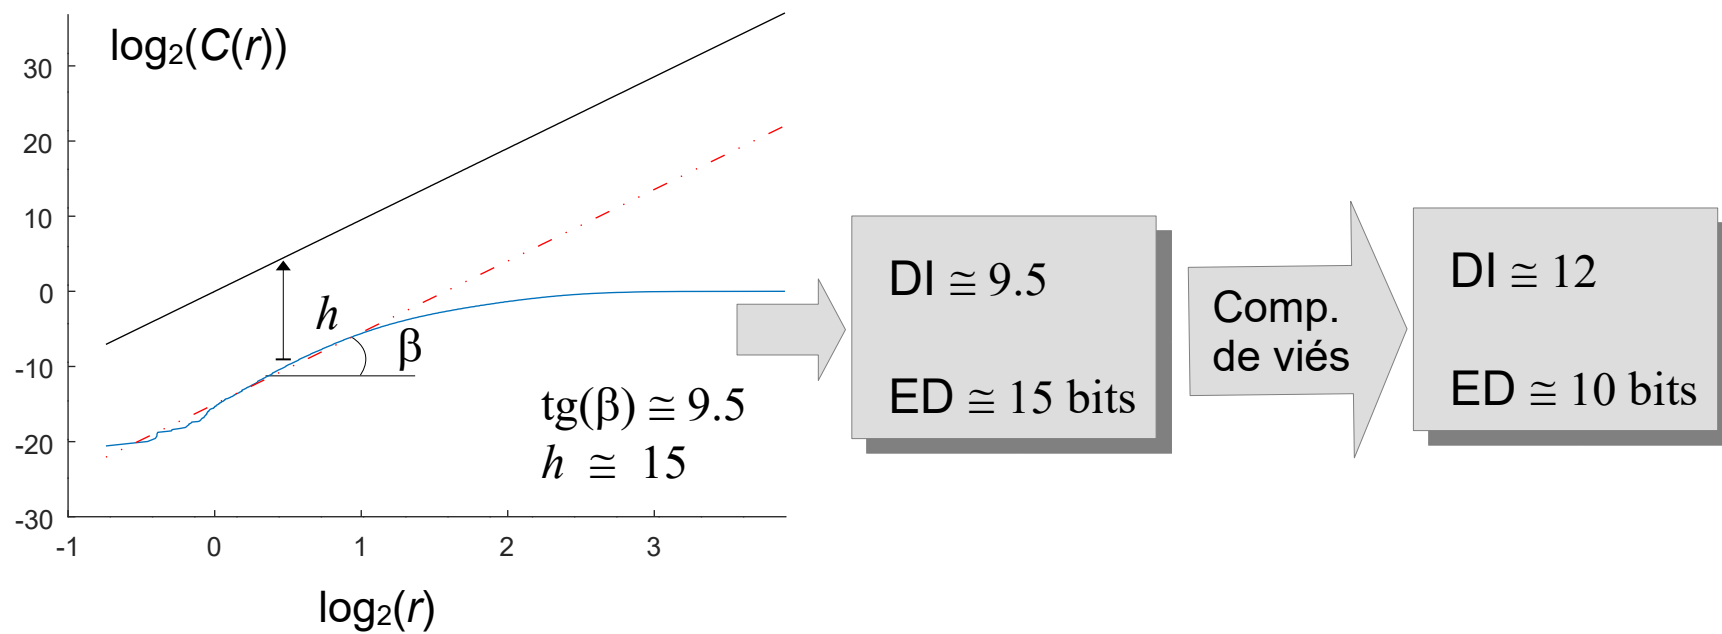
Janela: $M=2 \rightarrow 2499$ pontos no 12-D

(necessidade de compensação de viés)



Número de observações:
N = 2496 pontos

Janela: M=5 → 2496 pontos no 30-D
(necessidade de compensação de viés)



Conclusões parciais

1. Em todos os fenômenos, as dimensões intrínsecas são pequenas.
2. No caso das imagens, as DI encontradas foram menores que 15D
3. Sinais de voz, e-noses e linguagem natural resultaram em DI ainda menores.
4. Os sinais de acelerômetros e de giroscópios são parcialmente redundantes, pois:


Sem redundância 6-D aparentes \rightarrow $DI = 6$

Sinal da classe *walk* 6-D aparentes \rightarrow *DI estimada = 4*

Sinal da classe *lay* 6-D aparentes \rightarrow *DI estimada = 5*

(As redundâncias estão mais evidentes nos sinais de caminhada)

5. Acelerômetros e giroscópios, juntos, “veem” instantaneamente uma estrutura com menos 6-D, embutida num espaço 6-D.
6. Ao longo do tempo, o sinal da classe *walk* possui memória de 25 a 50 instantes de tempo.
7. A estrutura implícita toda (considerando dependências temporais também) possui em torno de 7 dimensões.



Universidade
Federal de
Sergipe

Sobre cognição e dimensões intrínsecas de sinais

Palestrante: Jugurta Montalvão

Contato: jmontalvao@academico.ufs.br

Este material ficará publicamente disponível em:

www.biochaves.website