
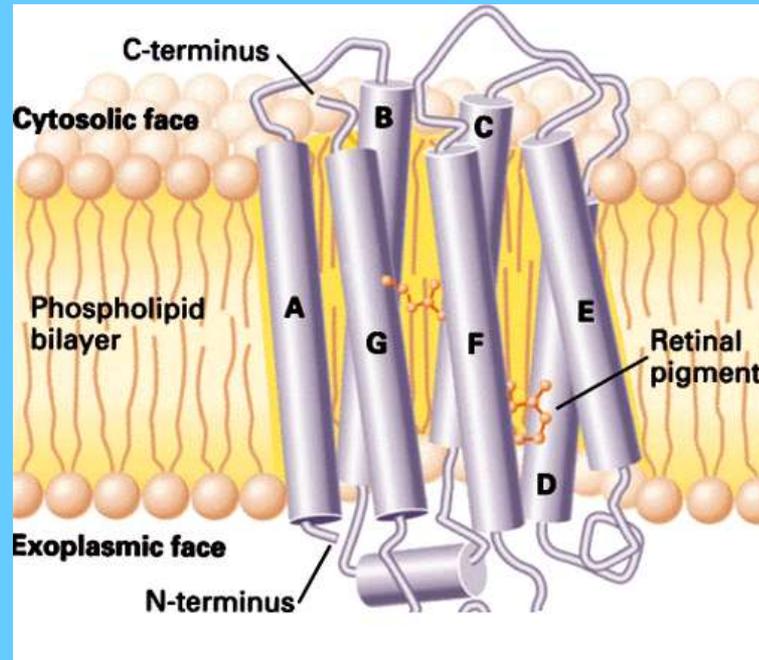
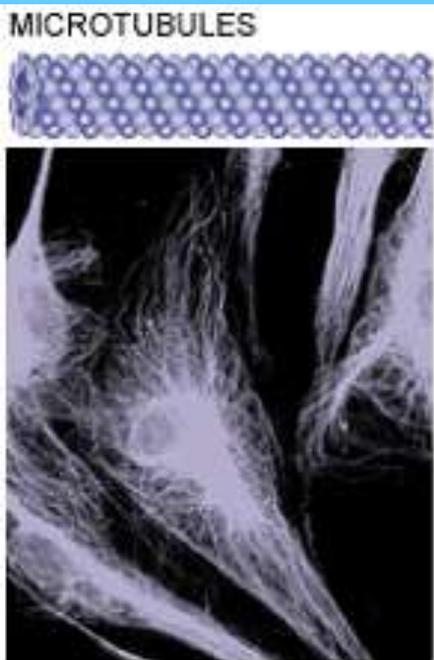


# Efeito das flutuações térmicas locais na cinética do processo de *folding* de proteínas



Grupo de Física Biológica  
Departamento de Física e Química  
FCFRP – USP



Proteína Estrutural

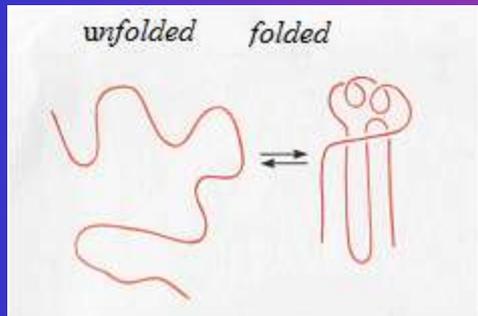
Proteína de Membrana

Proteína Globular

# O problema sob a abordagem da MENE

## Folding de proteína

- Características do *folding*
- Modelos de *folding*
- O modelo Estereoquímico:
  - objetivos
  - dificuldades



## Mecânica Estatística Não-Extensiva

- Origem: generalização da entropia .  
 $\ln W = \lim_{q \rightarrow 1} (W^{q-1} - 1)/(q - 1)$   
 $W > 0; q \in \mathbb{R}$
- Peso de Tsallis como uma média do peso de Boltzmann devido à flutuação térmica local.

$$S_q = k \frac{1 - \sum_{i=1}^w p_i^q}{q - 1}$$

# Proteínas Globulares

Proteínas são heteropolímeros lineares e flexíveis, cujas unidades provém de um repertório típico de 20 diferentes aminoácidos (aa) naturais.

**Sequência de aa: {Ser, Tir, Met, Glu, ..., Glu, Fen}  $\equiv$  Estrutura Primária**

**ID da proteína  $\rightarrow$  sequência de aminoácidos**

Então, o número  $N_L$  de proteínas diferentes, de tamanho  $L$ , é muito grande:  $N_L = 20^L$ .

Exemplo:  $L = 62$  (proteína relativamente pequena)

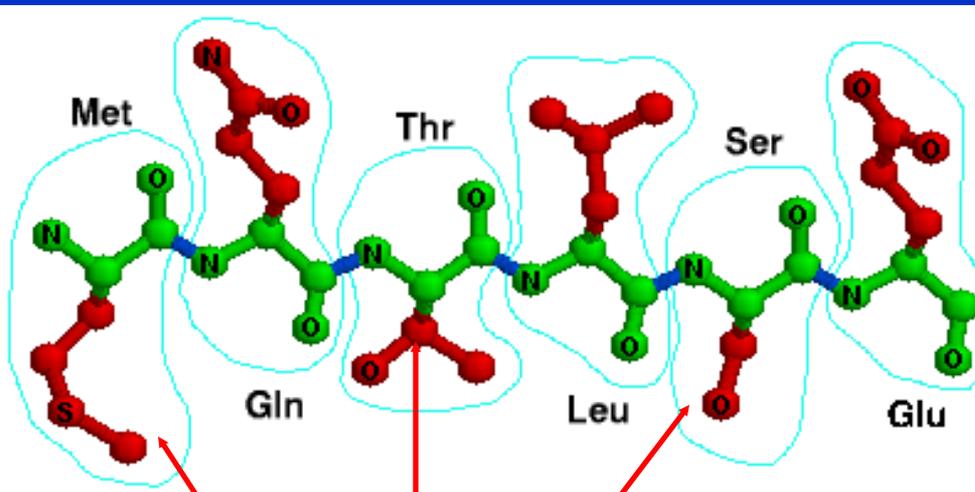
$$N^{62} \sim 10^{80}$$

Algo como o número de átomos visíveis do Universo

Proteína de tamanho  $L = 39$  aa

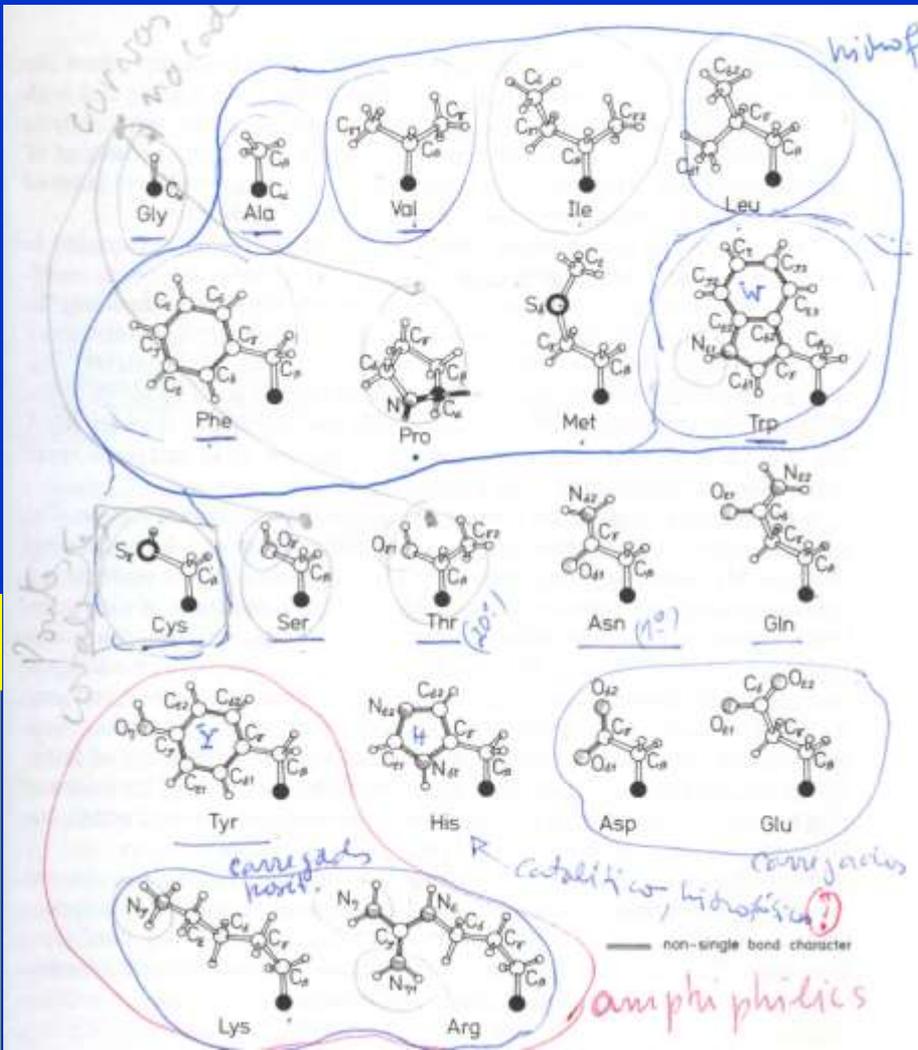


# Repertório: tamanhos, formas e função química

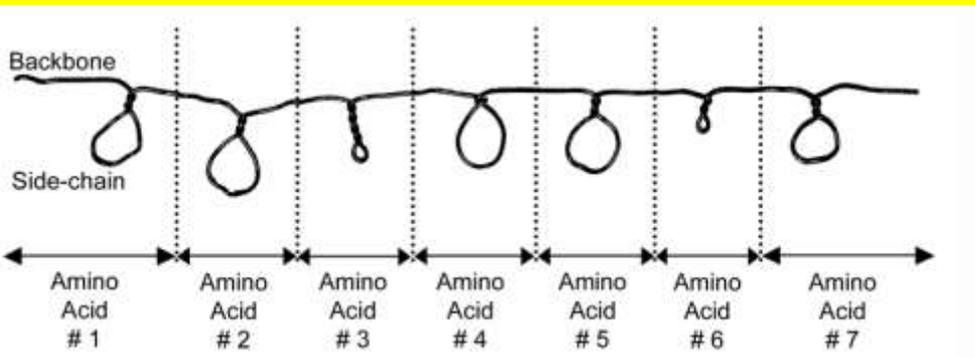


cadeias laterais

## Alfabeto de 20 amino ácidos distintos



## ID: sequência de aa (apelidos: função, ...)



# Representação da estrutura nativa de uma proteína

PDB ID: 1TSK

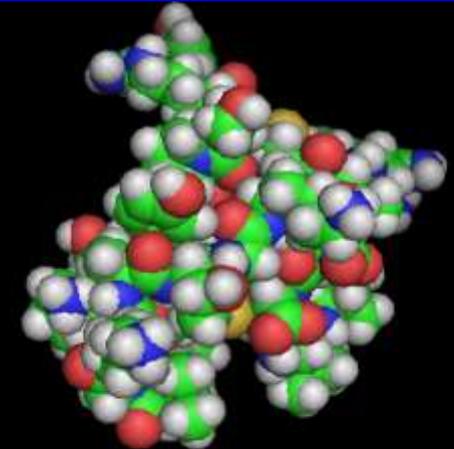
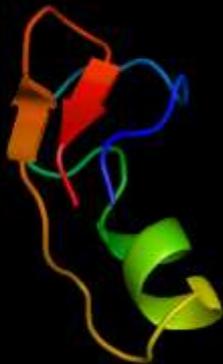
SEQUÊNCIA: Met - Lys - Val - Leu - ...

MKVLYGILIIIFILCSMFYLSQEVVIGQRCYRSPDCYSACKKLVGKATGKCTNGRCDC

Estrutura secundária (*cartoon*)

*Sticks*

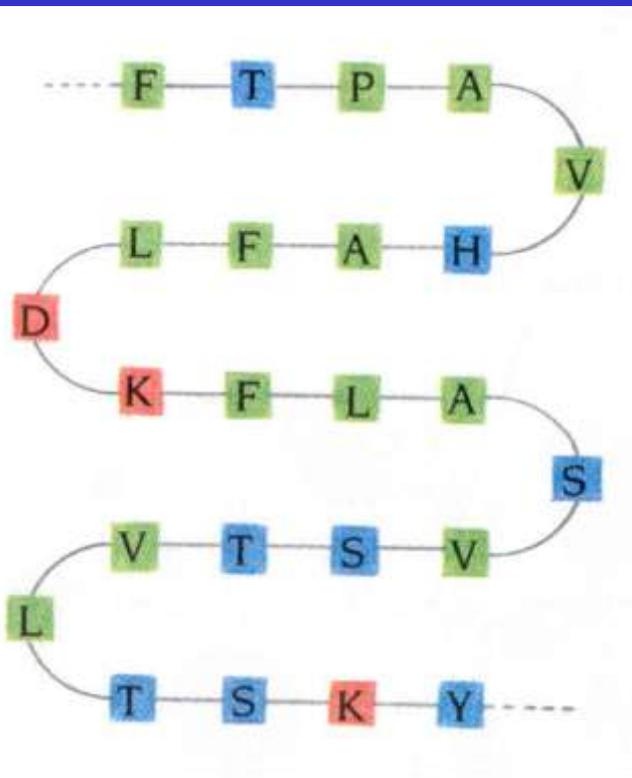
Esferas



# O problema de *fold*ing

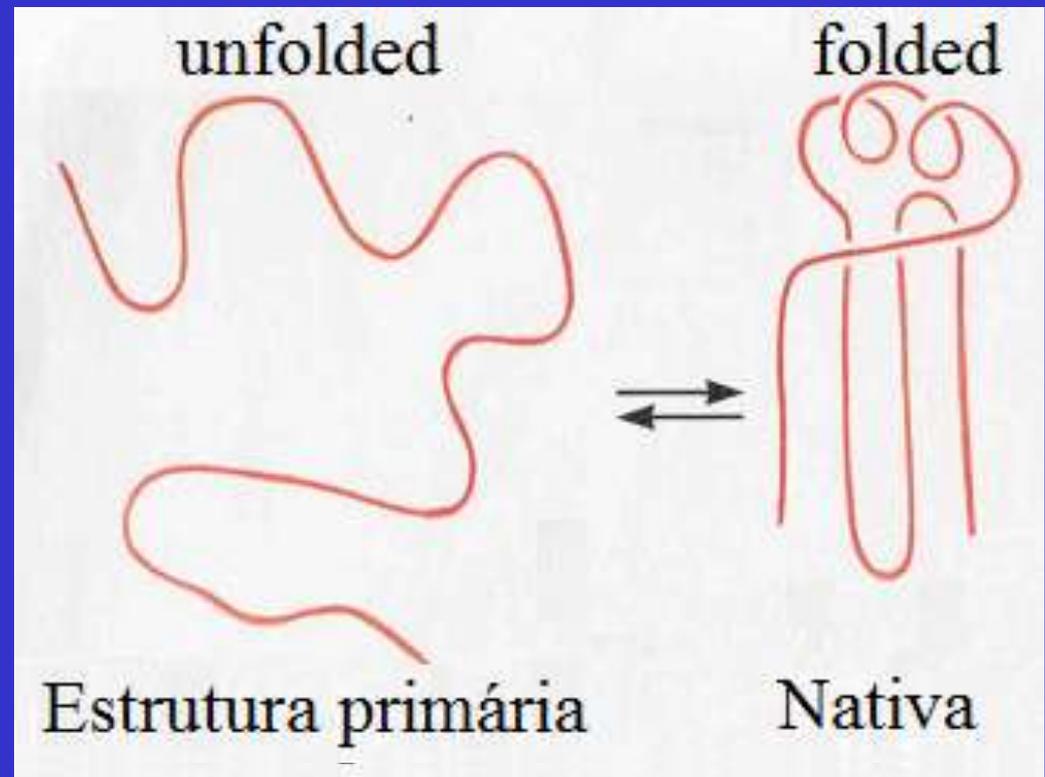
- FOLDING direto (Polissemia): Dada a estrutura primária DETERMINAR sua(s) correspondente(s) estrutura(s) terciária(s)
- FOLDING inverso (Sinonímia): Dada a estrutura terciária DETERMINAR sua(s) correspondente(s) estrutura(s) primária(s)

Representação de uma cadeia polipeptídica



Sequência: ID da proteína

Processo de *fold*ing - evolução esquemática: estrutura primária → secundária → terciária



Nativa: estrutura (3D); precisa, estável, única

# *folding* como gramática

Considere uma **sentença** constituída de uma sequência linear de **letras** (selecionadas de um “alfabeto” de 26 **letras**); pequenas regiões da **sentença** podem ter existência autônoma (chamamos tais regiões de “**palavras**”) mas o **significado da sentença** como um todo somente emerge quando todas estas **palavras** são colocadas juntas –frequentemente modificando as **palavras** quando isoladas

Trocando: **setença** → **proteína**; **letra** → **aminoácido**;  
**palavra** → **elementos de estrutura secundária**; **significado** → **função**.

Considere uma **proteína** constituída de uma sequência linear de **aminoácidos** (selecionados de um “alfabeto” de 20 **aminoácidos**); pequenas regiões da **proteína** podem ter existência autônoma (chamamos tais regiões de “**elementos de estrutura secundária**”) mas a **função da proteína** como um todo somente emerge quando todos estes **elementos de estrutura secundárias** são colocados juntos –frequentemente modificando os **elementos de estrutura secundária** quando isolados.

# O processo de *folding*

**O *folding* das proteínas globulares é pensado aqui como um processo em dois estágios temporais distintos:**

1. Estágio de Busca: a cadeia polipeptídica, guiada pelo efeito hidrofóbico, evolui erráticamente e é compactada (barreira entrópica) – etapa lenta;
2. Estágio de Refinamento Estrutural: próximo o suficiente da estrutura nativa, e somente nesta condição, interações intramoleculares e interações molécula-solvente são otimizadas; a partir daí, ajustes espaciais levam à precisão conformacional e à estabilidade da proteína – etapa ultra rápida.



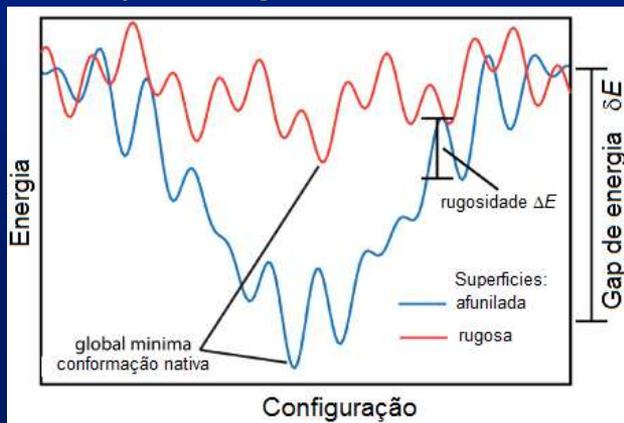
**Ênfase no primeiro estágio**

# O processo: taxa de *folding*

Para pequenas proteínas globulares ( $N \sim 100$ ) de um único domínio, sem prolinas, pontes dissulfeto ou grupos prostéticos a taxa de folding cobre seis ordens de grandeza

## Insights a partir de simulações de modelos simplificados

- diferentes sequências apresentam tempos muito distintos de *folding*;
- é difícil encontrar sequências que levam a *folding* rápidos;
- *folding* rápido estaria associado a superfícies de energia suave (espaço configuracional), e na forma de funil (rugosidade  $< k_B T$ );
- um pronunciado mínimo de energia entre o estado fundamental e o segundo estado de mais baixa energia potencial garantiria um *folding* rápido;
- taxa de *folding* estaria relacionada com colapso cooperativo da cadeia:  $\sigma = 1 - T_m/T_\theta$



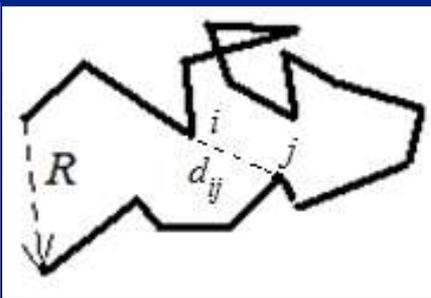
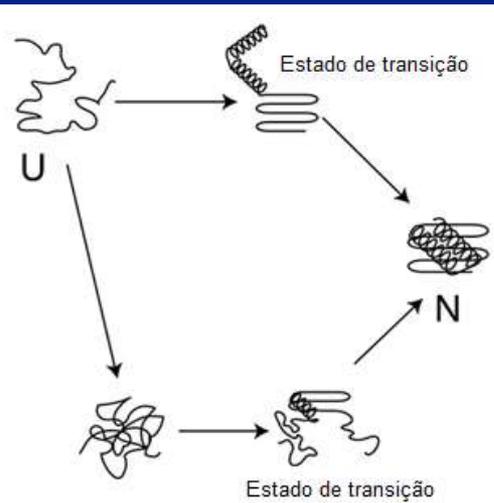
Limitação destes entendimentos para *folding*: experimentos computacionais são feitos, em geral, com sequências rápidas.

# O processo: taxa de *folding*

Para pequenas proteínas globulares ( $N \sim 100$ ) de um único domínio, sem prolinas, pontes disulfeto ou grupos prostéticos a taxa de folding cobre seis ordens de grandeza

## *Insights* a partir de experimentos

- Modelo Nucleação-condensação: estado de transição para o *folding* contém um núcleo de contatos nativos; o tempo de formação de tal núcleo poderia contribuir para a taxa de folding.
- Topologia da Nativa como um determinante das taxas de *folding*: Ordem de Contato (CO  $\equiv$  média da distância ao longo da cadeia, entre pares de resíduos contactantes da estrutura nativa), e parâmetro  $\Omega$  (média da probabilidade dos pares de contatos nativos (baseado numa cadeia guassiana)).



$$CO = (1/N_C) \sum_{\{i,j\}} d_{i,j}$$

Cadeia ideal

$$P(R) = (3/2\pi Nl^2)^{3/2} \exp(-3R^2/2Nl^2);$$

Seja:  $l = 1$ ;  $R = 1$ ;  $N = d_{ij}$ ;  $\rightarrow$

$$\Omega \propto \sum_{\{i,j\}} (L - d_{ij}) \frac{\exp(-3/2d_{ij}^2)}{d_{ij}^{3/2}}$$

# Características gerais do processo de *fold*ing de proteínas globulares

1. Rapidez: *fold*ing é um processo geral e muito rápido;
2. Robustez: *fold*ing é semelhante processo em um grande intervalo de temperatura: dependendo do organismo vivo, ocorre em todas temperaturas de 0° a 100°C;
3. Mano-máquina independente : como em partículas coloidais, o glóbulo protéico é sistematicamente agitado e deformado por forças não-balanceadas.

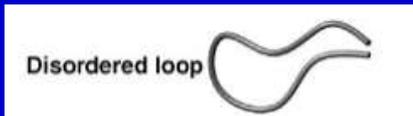
# 1. O processo de *folding* é muito rápido!

→ ... dificuldades para cálculos computacionais.

- O processo é pelo menos 10 ordens de grandeza mais rápido do que um mecanismo randômico de busca no espaço das configurações.
- Estima-se que, para proteínas globulares relativamente pequenas e de um único domínio, a **velocidade limite** de *folding* demanda um tempo  $\tau$  mínimo igual ao tempo necessário para formação correta de todos os elementos estruturais da proteína (estrutura secundária). Grosseiramente,

$$\tau \sim N/100 \text{ } \mu\text{s}$$

onde  $N$  é tamanho da proteína (número de amino ácidos).



# Conjectura de Levinthal

## Tempo característico de folding

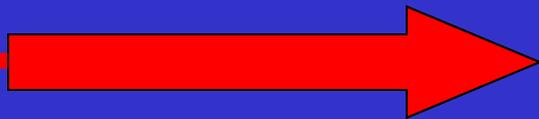
Proteína de tamanho  $N = 50$  (50 aminoácidos)

$\Gamma$  : espaço configuracional contendo  $(4,5)^{50} \sim 4,6 \times 10^{32}$  config.

Então, se  $\tau = 10^{-15}$  s é tempo para uma visita ao acaso cada config.

$$\rightarrow t_0 \sim 4,6 \times 10^{32} \times \tau = 4,610^{17} \text{ s,}$$

onde  $t_0$  é o tempo para varrer  $\Gamma$ , o que equivale, aproximadamente, a  $10 \times$  Idade do Universo<sup>1</sup> !



**Caminho(s) preferencial(is) em  $\Gamma$  !**

<sup>1</sup> Idade do universo  $\cong 13,5$  bilhões de anos  $\cong 4,3 \times 10^{16}$  s

# Velocidade limite

Para cada tipo de elemento estrutural (estrutura secundária:  $\alpha$ -hélices;  $\beta$ -strands; loops), o tempo característico de *folding*,  $\tau$ , é necessariamente maior do que o tempo para formação dos elementos estruturais. Em geral,  $\tau_\alpha < \tau_\beta$ ;  $\tau_\alpha < \tau_{\alpha\beta}$  (para proteínas de tamanhos comparáveis)

Disordered loop



$$\tau_{\text{loop}} \sim (0.07 - 0.4) \mu\text{s}$$

 $\alpha$  Helix

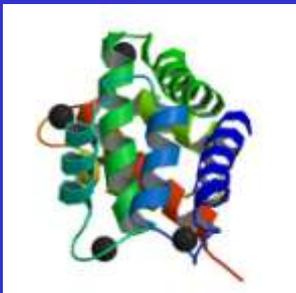
$$\tau_\alpha \sim 0.5 \mu\text{s} \quad (\text{peptídeos ricos em alanina})$$

 $\beta$  Hairpin

$$\tau_\beta \sim 6 \mu\text{s}$$

Oito ordens de grandeza!

Proteínas  
Globulares



(Calgranulina)

$$\tau \sim (10^{-5} - 10^3) \text{ s}$$

# Simulação do processo de *folding*

## Dinâmica Molecular

Principal dificuldade - tempo de máquina para simular 1  $\mu\text{s}$  é ainda muito grande: para se determinar o tempo característico de *folding* de proteínas de tamanho relativamente pequeno,  $N \sim 100$  amino ácidos, o tempo de máquina pode ser de semanas de CPU nas mais rápidas máquinas disponíveis na atualidade.

Solução (precária, mas disponível): computação distribuída:

Se a evolução do número  $M$  de proteínas enoveladas evolui exponencialmente, isto é,  $M_N(t) = M_0[1 - \exp(-t/\tau)]$ , então para tempos  $t$  pequenos em comparação a  $\tau$ , a razão  $M(t)/M_0 \cong (-t/\tau)$ , isto é: ao final de um tempo  $t$ , temos que o número esperado de proteínas enoveladas será

$$M(t) \cong (M_0 / \tau) t.$$

Assim, se  $\tau$  for da ordem de 1  $\mu\text{s}$ ,  $M_0 = 100$  *jobs* independentes submetidos em  $M_0$  computadores diferentes, ao cabo de  $t = 0,1\mu\text{s}$  (tempo real de simulação) teremos  $M(t) \sim 10$  simulações bem sucedidas!

# Alternativa

## Simulação Monte Carlo (algoritmo de Metropolis)

Vantagens: varredura rápida do espaço conformacional

Desvantagens:

- 1- perda de detalhes (modelos minimalistas);
- 2- retenção do processo em armadilhas energéticas (mínimos locais).

Remédio para a dificuldade 2

Mecânica Estatística não Extensiva:  $\exp(-\beta\Delta E) \rightarrow \exp_q(-\beta\Delta E)$

onde

$$\exp_q(-\beta\Delta E) = [1-(1-q)\beta\Delta E]^{1/(1-q)}.$$

Demonstra-se que



é uma média do fator de Boltzmann,  $\exp(-\beta\Delta E)$ , ponderada pela distribuição  $\chi$ -quadrado  $f(\beta)$ . Isto significa que  $\exp_q(-\beta_0\Delta E)$  leva em conta as flutuações locais da temperatura.

## 2. Robustez do processo de *folding*

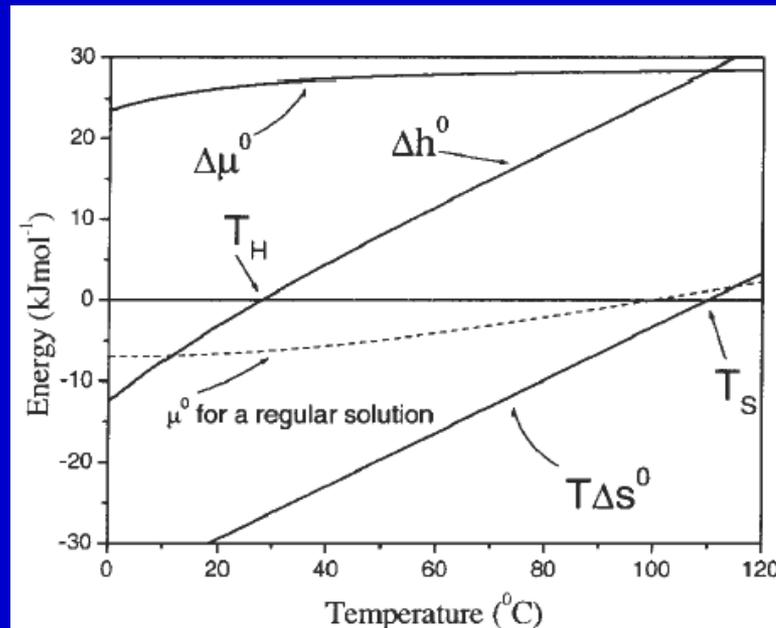
O *folding* de proteínas ocorre em ambientes **extremos** (temperatura, pressão pH), além de ambientes menos radicais.

Alguns organismos como bactérias, *archaea* e mesmo animais superiores (Verme de Pompéia), são termófilos, podendo se desenvolver, em alguns casos, em temperaturas acima de 100° C.

Outros organismos são psicrófilos (bactérias, fungos e algas), existindo casos em que se desenvolvem em temperaturas abaixo de 0° C.



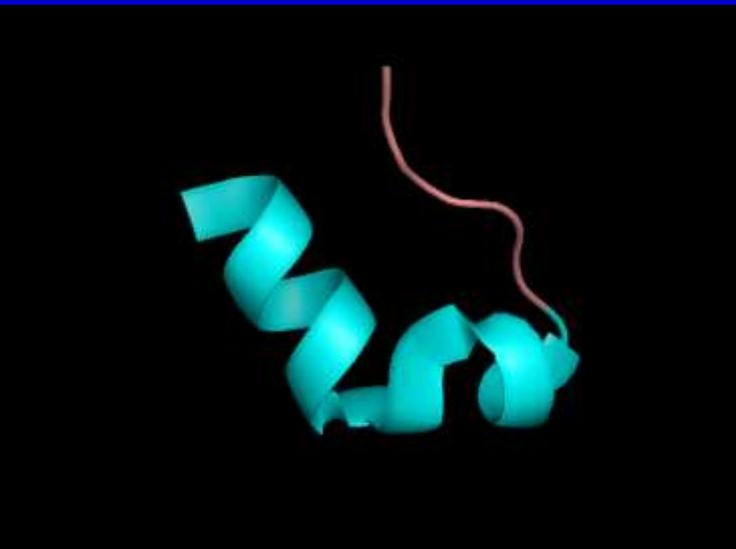
Bactérias: Yellowstone



Tardigrada

### 3. Proteína: uma nano-máquina

Proteínas globulares apresentam diferentes tamanhos, que pode variar de ~ 1 a 20 nm (de um a 30.000 aminoácidos, o que equivale; tipicamente, de 1 a 3.000 Kdaltons). Nesta escala espacial, forças locais não-balanceadas agitam e deformam sistematicamente o glóbulo protéico. Como flutuações térmicas locais poderiam afetar o processo de *folding*?



Trp-Cage: 20 aa - designed



Prolina - a menor  
proteína: < 1 nm



Titin: 30.000 aa ~ 20 nm

# Propriedades



# 3 premissas

1. O processo de *folding* é composto de dois estágios mecânicamente e temporalmente independentes; efeito hidrofóbico governa o primeiro estágio do *folding*.
2. Para proteínas globulares de dois estados e um único domínio, a instrução codificada em sua sequência de amino ácidos provê uma cinética do processo de *folding* tão rápido quanto possível.
3. Flutuações térmicas locais emergem como atributo intrínseco do sistema proteína-solvente, promovendo um processo de *folding* eficiente.

**Desafio:** incorporação destas premissas num MODELO

## JUSTIFICATIVA:

A energética do processo de *folding* é ainda pobremente compreendida: continua sendo muito controverso, pois ainda produz resultados teóricos e experimentais diametralmente opostos.

Assim, concentrar-se em algumas questões específicas é imperativo. E uma questão recorrente, no tocante à simulação computacional, é:

Teria a água papel determinante no processo de *folding*?

A resposta tem importantes consequências na elaboração de modelos minimalistas; e estes ainda são indispensáveis para se obter *insights* sobre o processo de *folding*.



MODELO ESTEREOQUÍMICO

# Modelo Estereoquímico: Uma cadeia protéica embebida numa rede cúbica infinita

## Efeito do solvente incluído

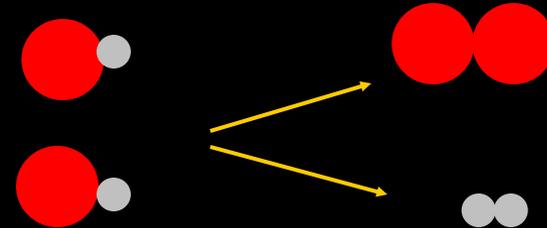
$$e_{i,j} = (h_i + h_j) + c_{i,j}$$

Cadeia “27-mer” e alfabeto de 10-letras: pares de restrições espaciais  $\{c_{i,j}\}$  e níveis de hidrofobicidade  $\{h_i\}$

	-2.1	-2.0	-1.9	-1.2	-1.1	-0.9	-1.0	-0.9	-0.8	+0.8
	$\Gamma_0$	$\Gamma_{1,1}$	$\Gamma_{1,2}$	$\Gamma_{2,1}$	$\Gamma_{2,2}$	$\Gamma_{2,3}$	$\Gamma_{2,4}$	$\Gamma_{2,5}$	$\Gamma_{2,6}$	$\Gamma_3$
$\Gamma_0$	Black	Dark Gray	Dark Gray	White	White	White	White	White	White	White
$\Gamma_{1,1}$	Dark Gray	Black	Dark Gray	Dark Gray	Dark Gray	Dark Gray	White	White	White	White
$\Gamma_{1,2}$	Dark Gray	Dark Gray	Black	White	White	White	White	White	White	White
$\Gamma_{2,1}$	White	Dark Gray	White	Black	Dark Gray	Dark Gray	Dark Gray	Dark Gray	White	White
$\Gamma_{2,2}$	White	Dark Gray	Dark Gray	Dark Gray	Black	Dark Gray	Dark Gray	Dark Gray	Dark Gray	White
$\Gamma_{2,3}$	White	Dark Gray	White	White	Dark Gray	Black	Dark Gray	Dark Gray	Dark Gray	White
$\Gamma_{2,4}$	White	Dark Gray	Black	Dark Gray	Dark Gray	White				
$\Gamma_{2,5}$	White	Dark Gray	White	White	Dark Gray	Dark Gray	Dark Gray	Black	Dark Gray	White
$\Gamma_{2,6}$	White	Dark Gray	White	White	Dark Gray	Dark Gray	Dark Gray	Dark Gray	Black	White
$\Gamma_3$	White	Dark Gray	White	White	Dark Gray	Black				

$h_i \equiv$  nível de hidrofobicidade do resíduo “i”

O princípio da segregação, a saber,  $2h_{ij} \geq (h_{ii} + h_{jj})$ , é marginalmente satisfeito pelo potencial hidrofóbico,  $h_{ij} = h_i + h_j$ , isto é:  $2h_{ij} = (h_{ii} + h_{jj})$ .

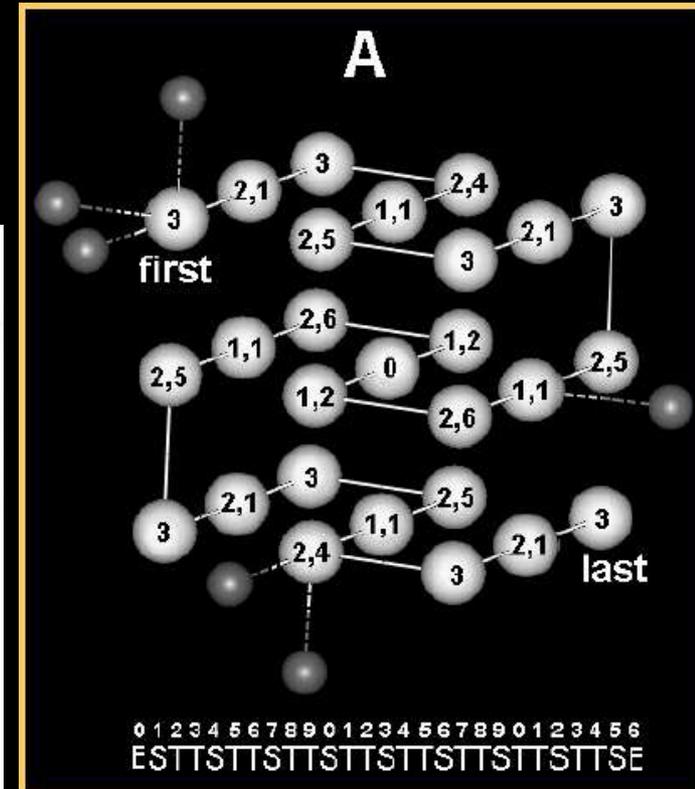
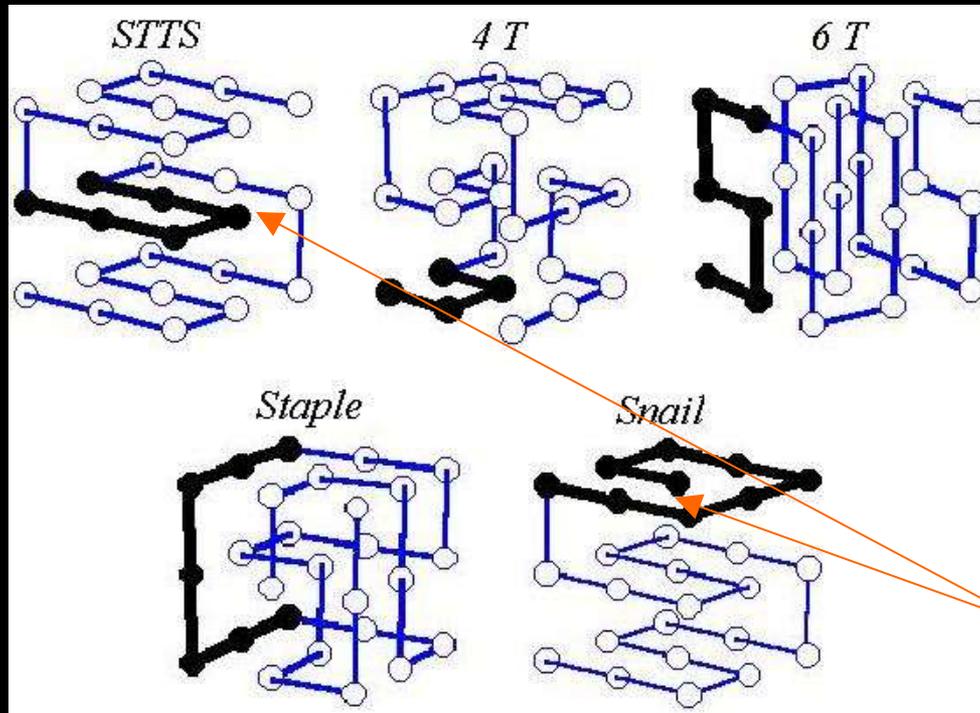


As restrições espaciais  $\{c_{i,j}\}$  reduzem a flexibilidade da cadeia e aumentam a especificidade intra-cadeia

O modelo também provê a “sintaxe” para o *design* da sequência, dada qualquer estrutura 3-D

Energia livre configuracional

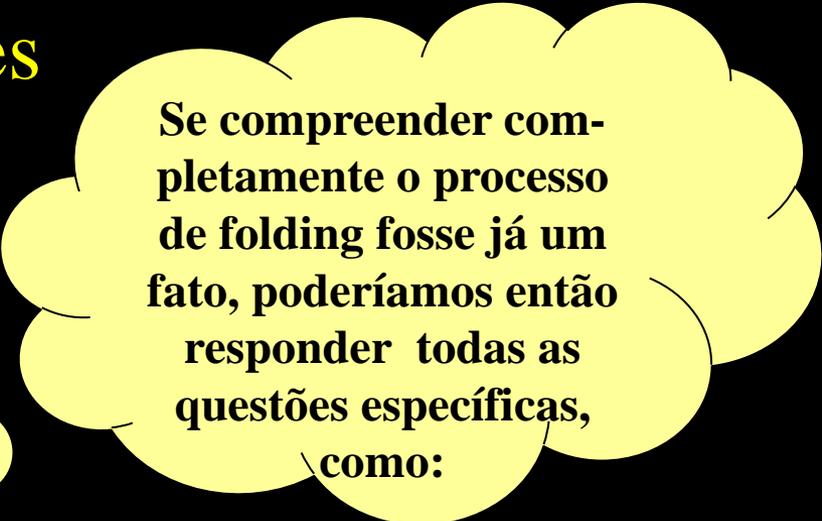
$$G(\{k,l\}) \propto \sum_{\text{all}\{i,j\}} (h_{i,j} + c_{i,j}) \delta_{(i,j),\{k,l\}}$$



Detalhes configuracionais importantes das  $\cong 50.000$  CSA configurações.

Estruturas Nativas são representadas por configurações *Compact Self Avoiding* (CSA) – formando “cubos” 3 3 3

# Questões específicas decorrentes



Se compreender completamente o processo de folding fosse já um fato, poderíamos então responder todas as questões específicas, como:

1. Dada uma sequência de aminoácidos, sob especificadas condições (pH, temperatura, pressão, ...), qual a sua estrutura 3-D correspondente?
2. Alternativamente, conhecida a estrutura de uma proteína, qual seria(m) a(s) possível(is) sequência(s) de amino ácidos correspondentes?
3. Ou ainda, conhecida a sequência e/ou a estrutura nativa de uma proteína, qual seria o tempo característico de *folding* da mesma?

# Simulação Monte Carlo

sistema, parâmetros, objetivo, método

1. Rede cúbica infinita;
2. Cadeia de 27 monômeros {← repertório de 10 # resíduos};
3. Estrutura alvo: uma das CSA;
4. Sequência: desenhada a partir da configuração CSA selecionada;
5. Condição Inicial: cadeia aberta (sem contatos topológicos);
6. Temperatura: fixa;
7. Objetivo: obtenção do tempo característico de *folding* (tempo de primeira passagem pela Nativa -configuração CSA escolhida);
8. Método: Metrópolis com peso de Boltzmann generalizado.



# Peso de Tsallis

$$\exp_q(-\beta_0 \varepsilon) = \int_0^\infty \exp(-\beta \varepsilon) f(\beta) d\beta,$$

onde  $f(\beta) = \frac{1}{\Gamma(n/2)} \left( \frac{n}{2\beta_0} \right)^{n/2} \beta^{-1+n/2} \exp\left(-\frac{\beta}{2\beta_0} n\right),$

e impondo que a média da temperatura,  $\langle \beta^{-1} \rangle = \int_0^\infty \beta^{-1} f(\beta) d\beta$ , coincida com a temperatura do reservatório  $\beta_0^{-1}$ , obtemos

$$\exp_q(-\beta_0 \varepsilon) = 1 - (1-q)\beta_0 \varepsilon^{\frac{1}{1-q}}, \quad \text{onde}$$

$q = 1 + 2/n$ , e  $n$  é o número de graus de liberdade da distribuição  $\chi^2$ ,  $f(\beta)$ , isto é,  $n$  é o número de variáveis independentes que especifica completamente o sistema.

# Parâmetro entrópico $q$ como uma variável

O índice entrópico  $q$  está associado com o número de graus de liberdade da distribuição:  $q = 1 + 2/n$ . Desta forma, como  $q$  estaria relacionado com os graus de liberdade do sistema físico?

Esta questão se impõe pelo fato do índice entrópico  $q$  ser usualmente introduzido “à mão” –*fitting*; mas este não é o nosso caso.

Ensaio numéricos indicaram que:

1. existe  $q = q^* > 1$  que minimiza o tempo característico  $\tau$  de *folding*;  $q^*$  é diferente para cada estrutura alvo escolhida (CSA);
2. associando  $n$  (e então  $q$ ) ao grau de compactação do glóbulo ( $q = a/R_G^2$ ) foi possível estabelecer um valor máximo para  $q$ , a saber,  $q_{\max} = 1 + 2/6$ , de tal forma que  $\tau$  é minimizado: então obtemos  $q = 1 + 2(q_{\max} - 1)/R_G^2$ . O mínimo de  $R_G^2 = 2$ , que para o caso,  $q = q_{\max}$
3. a média  $\langle q \rangle$  da distribuição de  $q$  coincide com  $q^*$ .

Este resultado satisfaz a primeira característica do processo de *folding*: Rapidez – *folding* é um processo geral e muito rápido.

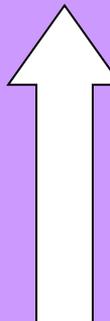
# O índice entrópico $q$ como uma variável

Assim, o valor de  $q$  varia ao longo da simulação, sendo que  $q_{min} = 1$ , correspondendo a  $n \rightarrow \infty$  (cadeia aberta, número máximo de graus de liberdade, e  $q_{max} = 4/3$ , correspondendo a  $n \rightarrow 6$ . Mas, por que  $n = 6$ ?

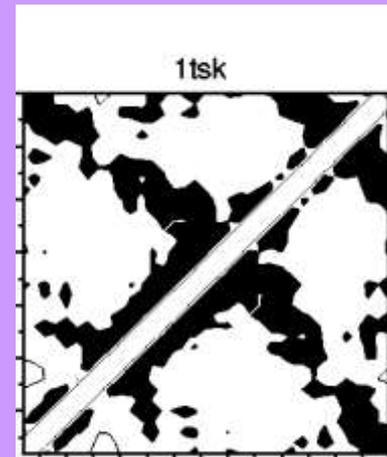
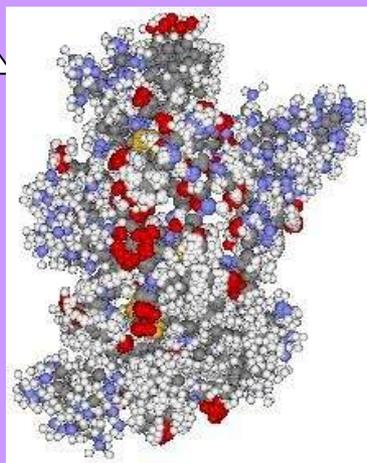


# Representação de uma proteína

DETALHES

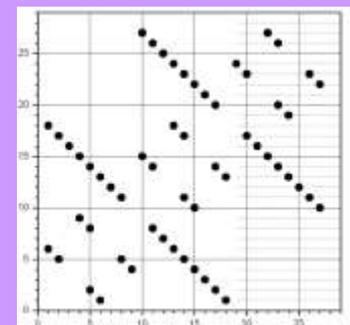
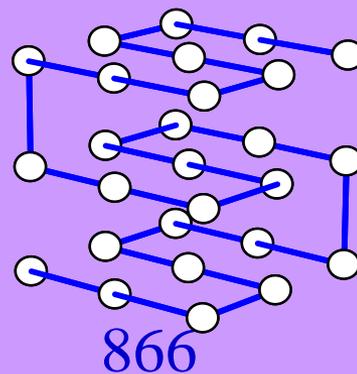
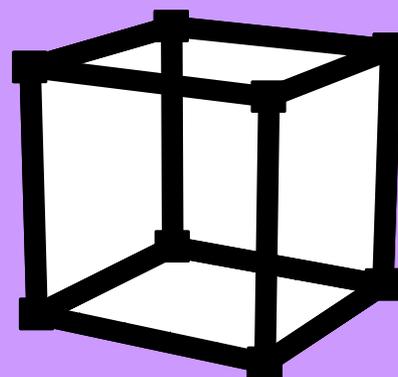


P  
E  
R  
F  
E  
I  
Ç  
Ã  
O



Ana Paula Arósio

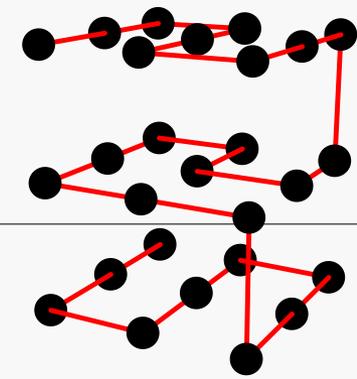
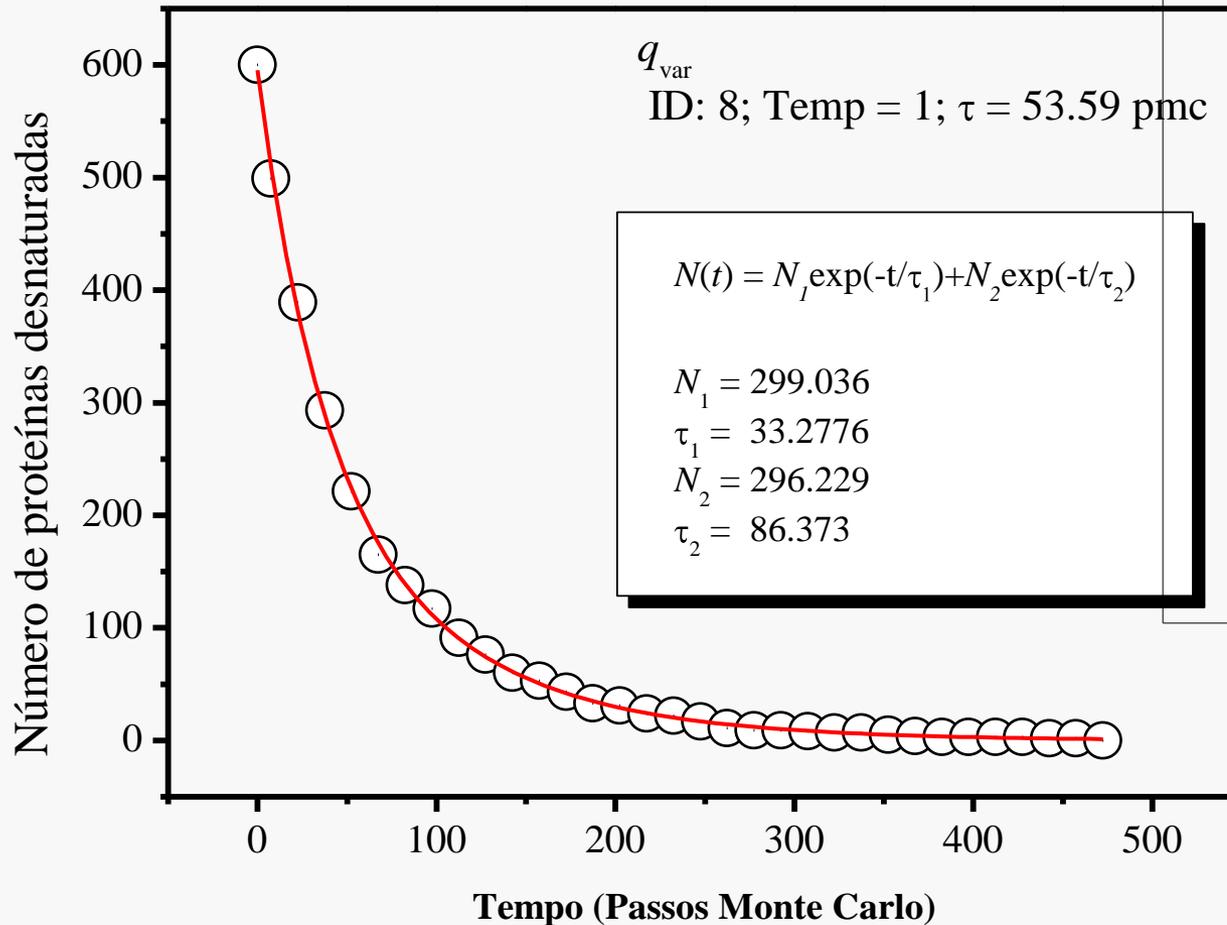
1TSK



Falcão

# Resultados: tempo característico de *folding* $\tau$

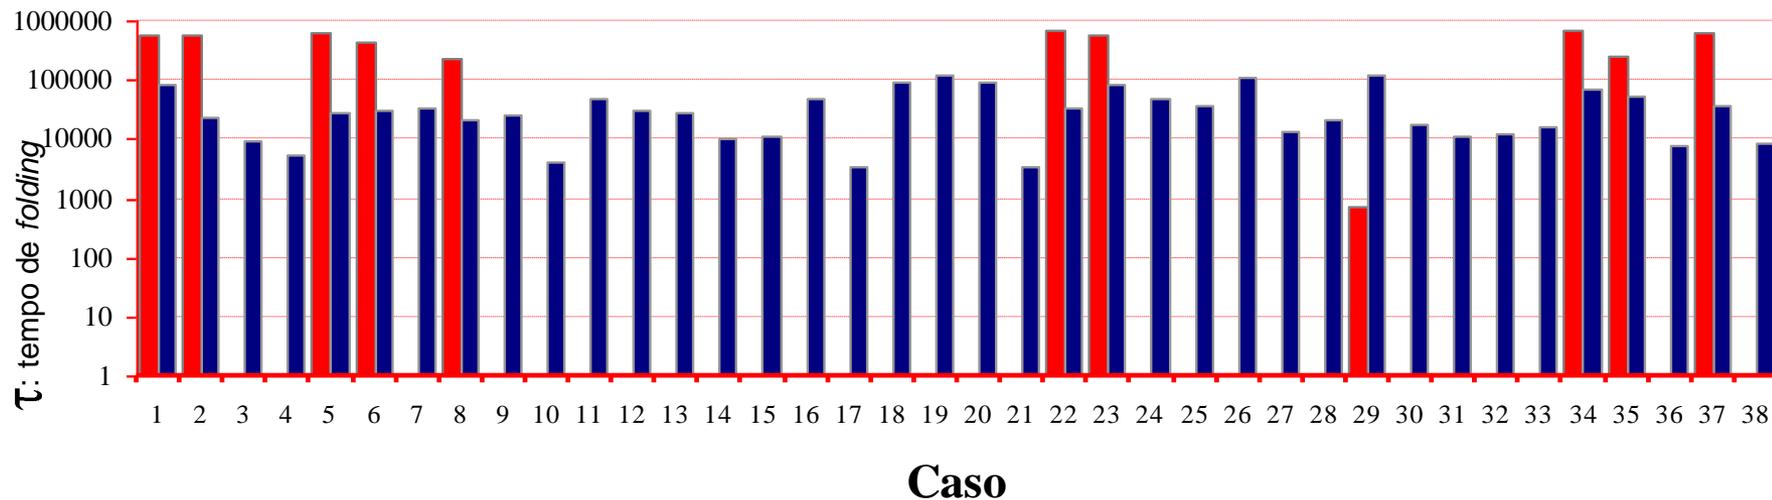
600 simulações independentes



# Comparação

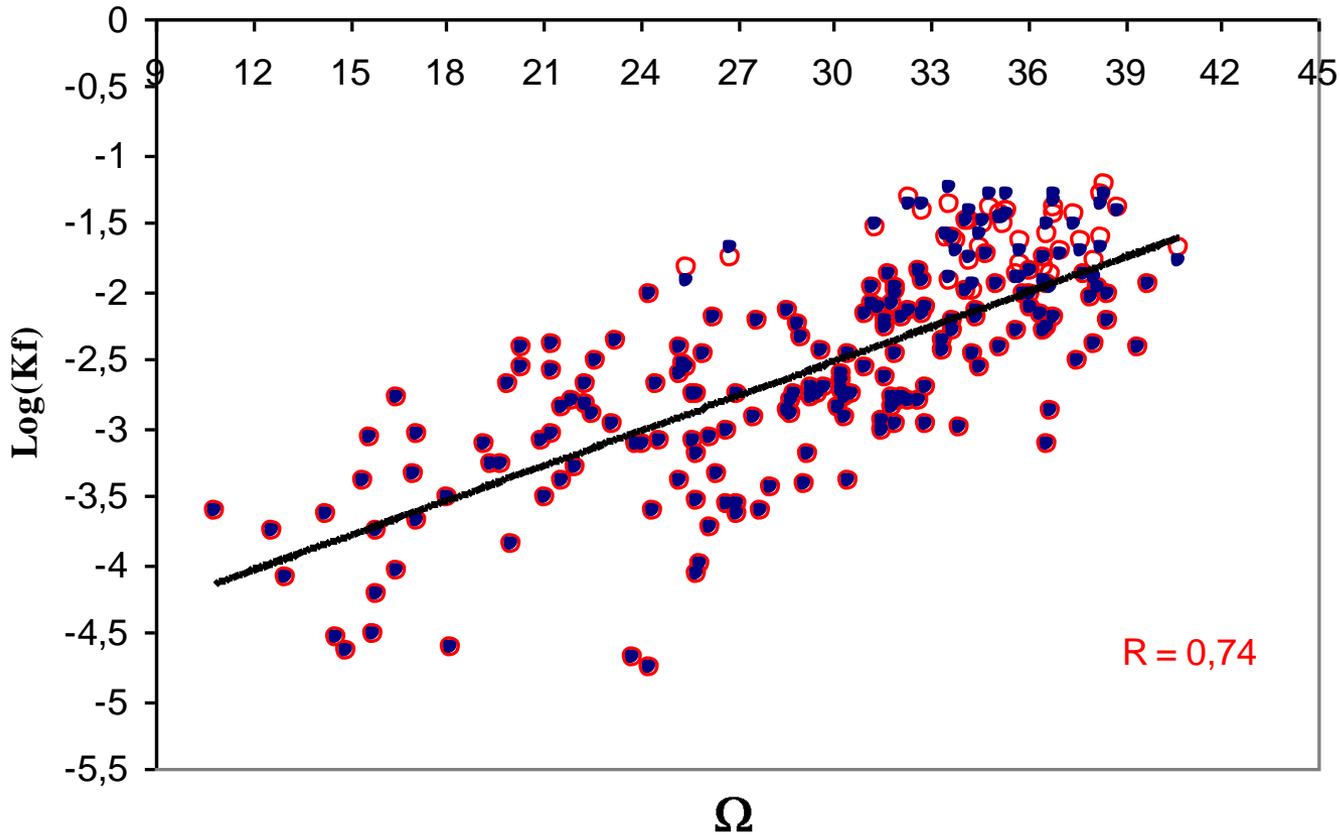
## Comparação entre tempos de *folding*

IDs: 51168 ( Boltzmann; Tsallis ) - Sucesso: 29%; 100%

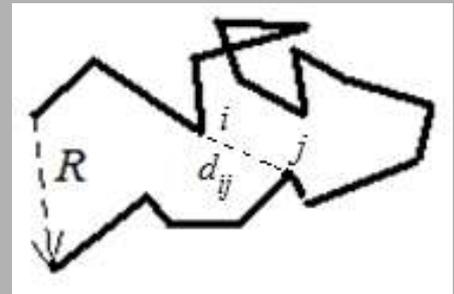


Barras (vermelhas) ausentes correspondem aos casos de insucesso na busca pela estrutura nativa, na janela de tempo estipulada ( $\sim 8 \times 10^8$  passos MC).

Taxa de folding ( $K_f = 1/\tau$ )  
 Dados correspondentes a 200 CSA.



$$CO = (1/N_C) \sum_{\{i,j\}} d_{i,j}$$



$d_{i,j}$ : distância ao longo da cadeia

Cadeia Ideal:

$$P(R) = (3/2\pi Nl^2)^{3/2} \exp(-3R^2/2Nl^2)$$

Para  $R = 1$  (contato) e  $l = 1 \rightarrow$

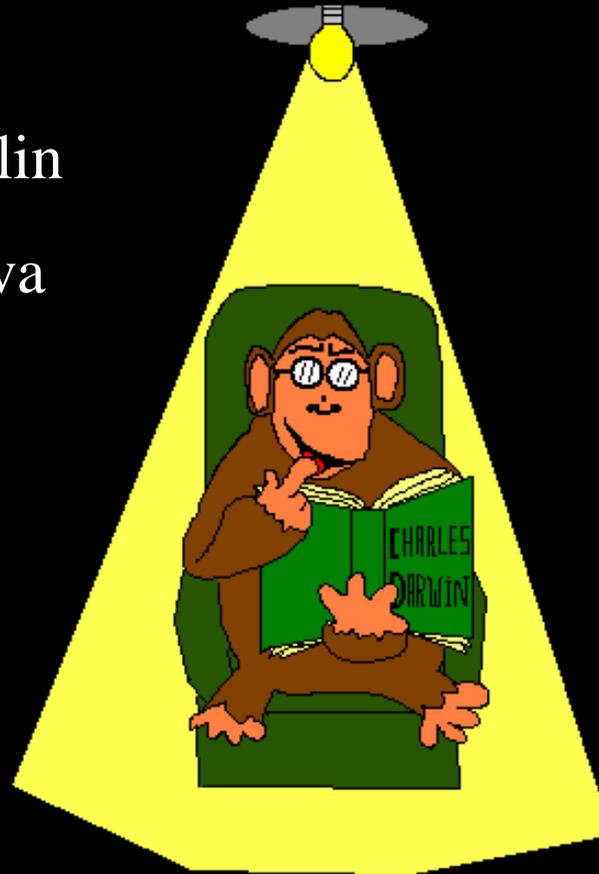
$$\Omega \propto \sum_{\{i,j\}} (L - d_{ij}) \frac{\exp(-3/2d_{ij}^2)}{d_{ij}^{3/2}}$$

FIM

Gradecimentos:

João Paulo Dal Molin

Marco A.A. Da Silva



Grupo de Física Biológica

Ref.: PHYSICAL REVIEW E 84, 041903 (2011)