

# *Introduzione ai metodi informazionali in biologia (Infogenomics)*

**Vincenzo Manca**  
Università di Verona

Infolife – CINI  
Roma 9 Giugno 2015

# *Ringraziamenti*

- Infolife/Infogenomics (Mondello meeting)
- My group (2009 → coll., post-doc, Phd, ~ 10/15)
  - *Vincenzo Bonnici* (Post-doc VR)
  - *Giuditta Franco* (Ric. VR)
  - *Alberto Castellini* (Post-doc Berlin (Potsdam), Max Plank)

La vita è *informazione rappresentata ed elaborata a livello molecolare*.

... “nasce” quando sono disponibili molecole in grado di rappresentare informazione e processi informativi (**polimeri e membrane**).

Il **calcolo simbolico** (*versus calcolo numerico/algebrico*) è emerso nel 20° secolo per l’elaborazione formale (e poi automatica) dell’informazione (Logica matematica e Calcolabilità). Due le scoperte fondamentali:

1) L’esistenza di processi matematicamente definibili, ma non calcolabili. **LIMITI DEL CALCOLO**

2) L’esistenza di macchine di calcolo universali, ovvero capaci di realizzare qualsiasi processo di calcolo.

**POTENZA DEL CALCOLO**

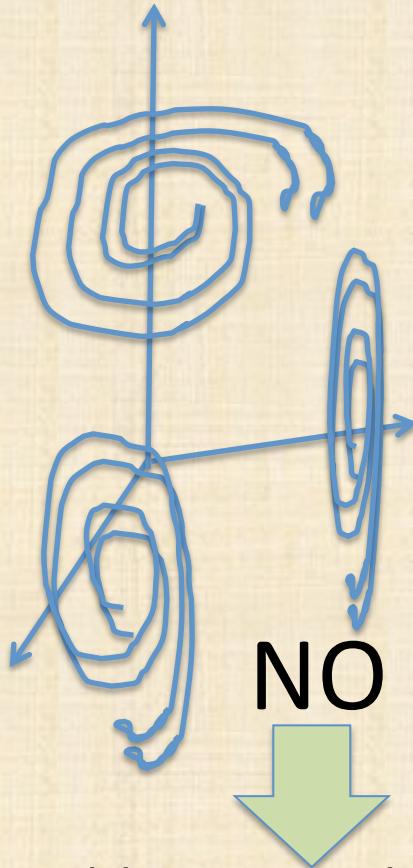
# Riproduzione e Universalità

- L'esistenza di macchine di calcolo “universali” è basata su algoritmi **di duplicazione simbolica** (un programma è il “mirror” di una machina entro un'altra). Analogamente, la **riproduzione biologica** postula meccanismi di duplicazione (ds DNA).

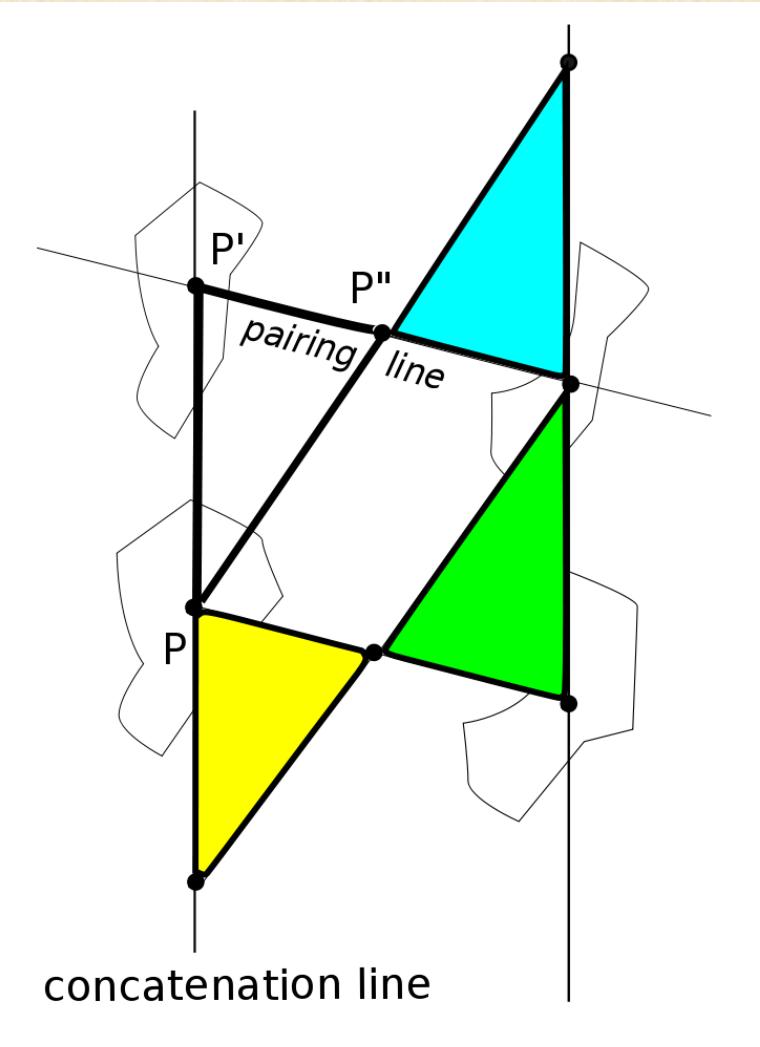
# DNA “more geometrico demonstratus”

- La duplicazione template-driven è realizzabile in tempo lineare.
- Una struttura bilineare rende la duplicazione template-driven più affidabile e veloce.

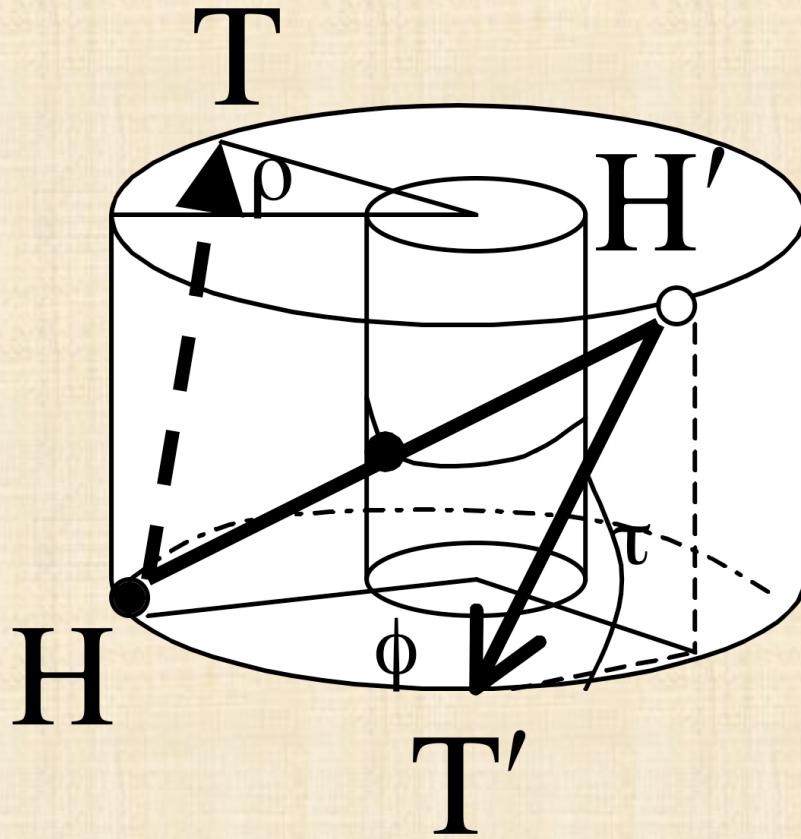
# Un polimero bilineare è astrattamente una sequenza di monomeri triangolari



Si avrebbero angoli concatenativi diversi a meno di non usare spirali logaritmiche



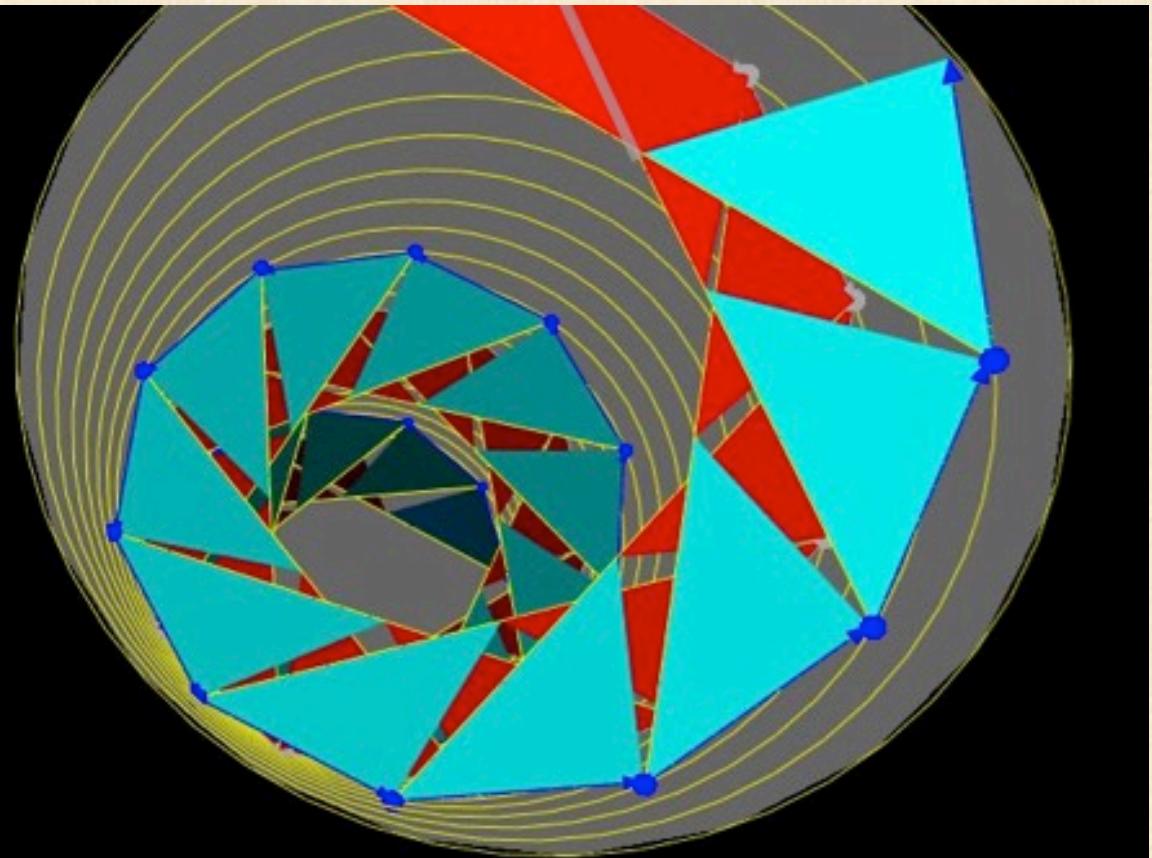
Non può rimanere su un piano

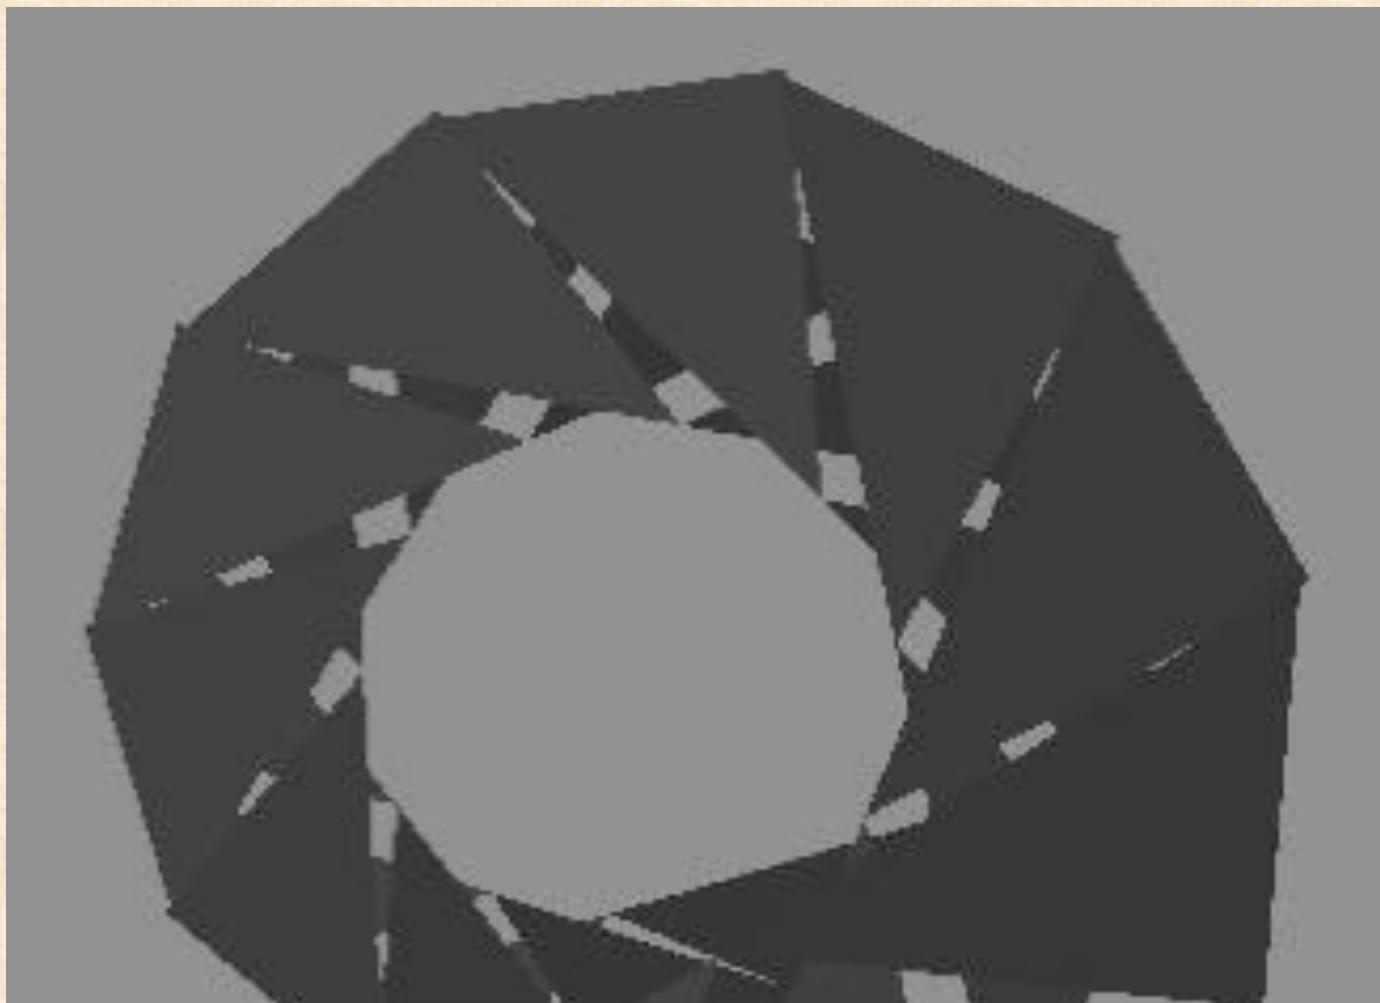


Il parallelismo sarebbe possibile solo avendo molecole di **chiralità diversa**, ma questo complicherebbe notevolmente il processo di copia.

# Chiocciola di triangoli monomerici

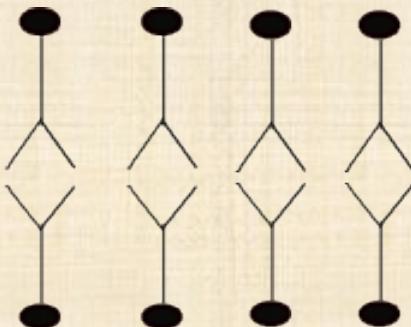
```
CALC. VALUES:  
f = 68.059787  
a = 58.941505  
p = 173.205081  
b = 176.516384  
r = 50.000000  
h = 34.029894  
n = 10.501750  
theta = 0.500000  
chi = 11.115419  
beta = 120.000000  
delta = 42.860000  
alpha = 30.000000
```



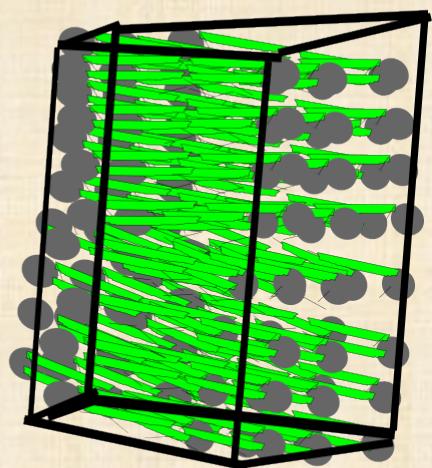
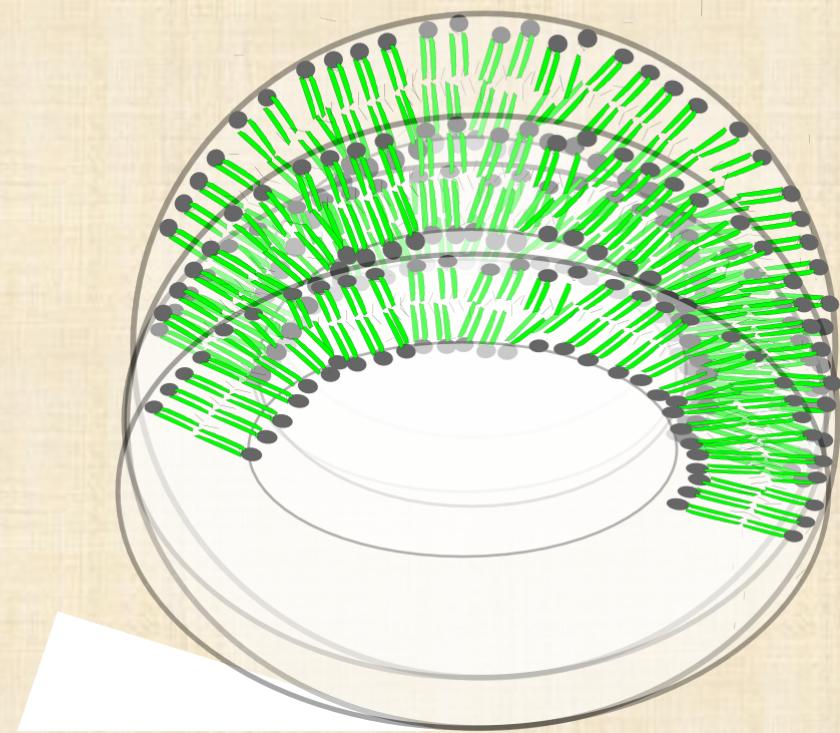
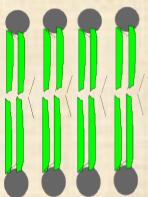


Phospho-lipidic and Phospho-diesteric  
Two forms of Bilinearity (based on chirality)

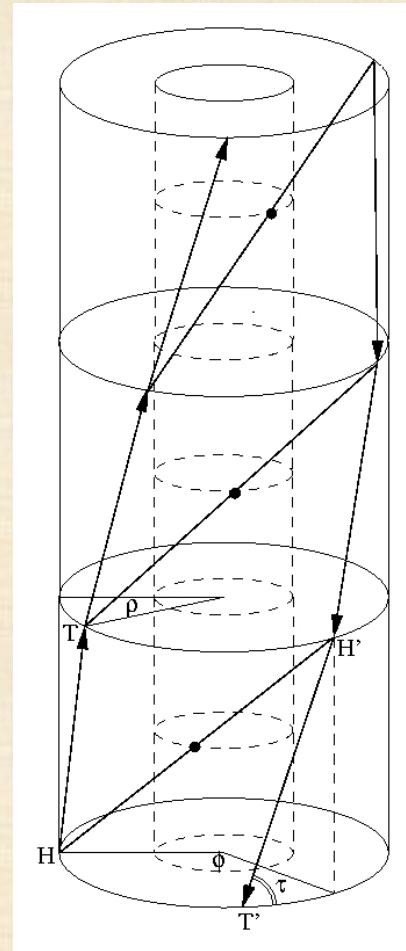
**lines of pairs and pairs of lines**



# La sfera



# Il cilindro



Manca – The logic of bilinear forms, Fundamenta Informaticae, 2005

\*\*\*\*\*

# Probabilità e informazione

- Shannon 1948: l'informazione di un evento è funzione della sua probabilità.
- La probabilità è distribuzione (spazio di eventi).
- L'informazione si determina analizzando (opportune) distribuzioni di grandezze in una popolazione di fenomeni.

# Probabilità

*cruciale in tutte le scienze a partire dal 20° secolo*

- **Cardano e Galileo** : De ludo aleae
- **Pascal e Fermat** : Chevalier de Merè
- **Jacob Bernoulli** : urna e processo bernoulliano (Ars Conjectandi)
- **De Moivre, Laplace e Bayes** : gaussiana e inversione del condizionamento
- **Gauss** : leggi del caso
- **Francesi, Russi, Italiani** (Poisson, Cauchy, Borel, Chebicev, Kolmogorov, Cantelli, De Finetti): distribuzioni, leggi dei grandi numeri, misura
- **Boltzmann** (fisica statistica)
- **Inglesi** (Galton, Pearson, Student, Fisher): leggi della statistica

# Insidie probabilistiche

- Se un pilota ha il 2% di essere abbattuto in ciascuna missione, qual è la probabilità di abbattimento entro 50 missioni?
- Totale perché  $2\% \times 50 = 100\%$  **ERRATO !**
- Stesso errore del gioco sottoposto a Pascal da Chevalier de Meré
- E' abbattuto alla n-esima sse sopravvive a tutte le precedenti e viene abbattuto durante quella. Sommando questi casi esclusivi da 1 a 50 si ha, con  $p = 0,02$

$$p + (1-p)p + (1-p)^2p + \dots + (1-p)^{49}p = 1 - (1-p)^{50} = 0,64$$

$(1-p)^{50}$  è la probabilità di sopravvivere alla 50° missione

# Modus essendi / Modus conjectandi

- Which way **things** are?
- Which is **the probability** that things are in a given way?

# Information Theory

- **Communication** (Hartley, Nyquist, Shannon)
- **Coding Theory** (Fano, Hamming, Reed, Solomon)
- **Cryptography** (Hellman, Rivest, Shamir, Adleman)
- **Complexity** (Kolmogorov, Chaitin) **Computation, Chaos**
- **Cybernetics** (Wiener, von Neumann, Langton)
- **Foundations** (Brillouin, Bennett, Landauer)
- **Canonical Quantum Gravity** (Wheeler, De-Witt)
- **Metabiology** (Conrad, Chaitin)  
*Unification via Information* (Carlo Rovelli's books)

Universe's ultimate mechanism for existence might be  
Information: "it from bit" (Wheeler's last speculation)

# Distribuzione - Informazione

- X variabile che assume valori con molteplicità:  
 $x_1, x_2, x_3, \dots, n_1, n_2, n_3, \dots$
- Se  $n = n_1 + n_2 + n_3, \dots$
- $= n_1/n, n_2/n, n_3/n, \dots$  sono frequenze
- $p_1, p_2, p_3, \dots$  sono probabilità (misure di possibilità di occorrere)
- Shannon chiama  $(X, p)$  **Sorgente di Informazione**
- $-\lg p_e$  è la misura di informazione dell' evento **e** di probabilità  $p_e$

# Information Paradoxes

**Choice, Uncertainty, Information ???**

Section 6 of Shannon's booklet  
(compare to: Learning/Ignorance/Knowledge)

It is intrinsic to the notion of Event  
(something that happens).

The **uncertainty** of E, before it happens, corresponds to the loss of uncertainty, that is, its **information**, when it happened. Both of them correspond to the number of events among which it was **chosen** to happen.

# Shannon's Approach (Al Kindi's intuition)

The meaning of a letter in a text is given by its frequency (Caesar Encoding breakdown)

Shannon – The Mathematical Theory of Communication  
(shannon48.pdf)

Cover & Thomas - Information Theory , Wiley, 1991

# Boltzmann's Tomb

## The epochal formula



# Entropia Termodinamica

## Teorema di Carnot

Una macchina termica che lavora tra due sorgenti Termiche una M (serbatoio) a temperatura T e una  $M_o$  (condensatore) a temperatura  $T_o$  con  $T > T_o$  prelevando calore da M e restituendolo ad  $M_o$ , non può restituire meno calore di  $Sx(T/T_o)$ , ovvero:

$S = Q/T$  detta **entropia** è il **minimo calore che una macchina (termica) può rilasciare** ad un condensatore a temperatura  $T_o$  quando  $T_o$  è assunta come misura di unità termica.

(dimostrazione: via macchine reversibili, teoria degli automi).  
Limite all'efficienza delle macchine termiche

# L'irreversibilità temporale come conseguenza probabilistica della complessità

**Boltzmann:** L'entropia termodinamica di Carnot **S** è proporzionale al **logaritmo** del numero **W** di microstati associati al macrostato termodinamico del sistema.

Sia  $n$  il numero di particelle e  $k$  le classi delle velocità delle particelle di gas:

$$n = n_1 + n_2 + \dots + n_k$$

$$S = k \lg W$$

- $W = n! / n_1! n_2! \dots n_k!$

$n_i$  = numero di particelle con velocità compresa nell'intervallo i-esimo

- Per la formula di Stirling  $\lg n! \approx n \lg n$

- $\lg W \approx n \lg n - (n_1 \lg n_1 + n_2 \lg n_2 + \dots + n_k \lg n_k)$

- $S = A - k(n_1 \lg n_1 + n_2 \lg n_2 + \dots + n_k \lg n_k)$

# Il teorema impossibile

H di Boltzmann

$$H = \sum_i n_i \lg n_i$$

H è la versione microscopica dell'entropia termodinamica, cambiata di segno (a meno di costanti additive e moltiplicative).

**Teorema H (1872)** In un sistema isolato:

$$H(t) \geq H(t+1)$$

# Da Boltzmann a Shannon

$$H_s = - \sum_i p_i \lg p_i$$

Shannon 1948

Entropy Th.  $H_s$  è univocamente individuata dalle 3 condizioni:

**Continuità** in  $p_i$ , **Massimo** in  $1/n \times n$ , **Additività** delle scelte:

$$H(1/2, 1/2) + 1/2 H(2/3, 1/3) = H(1/2, 1/3, 1/6)$$

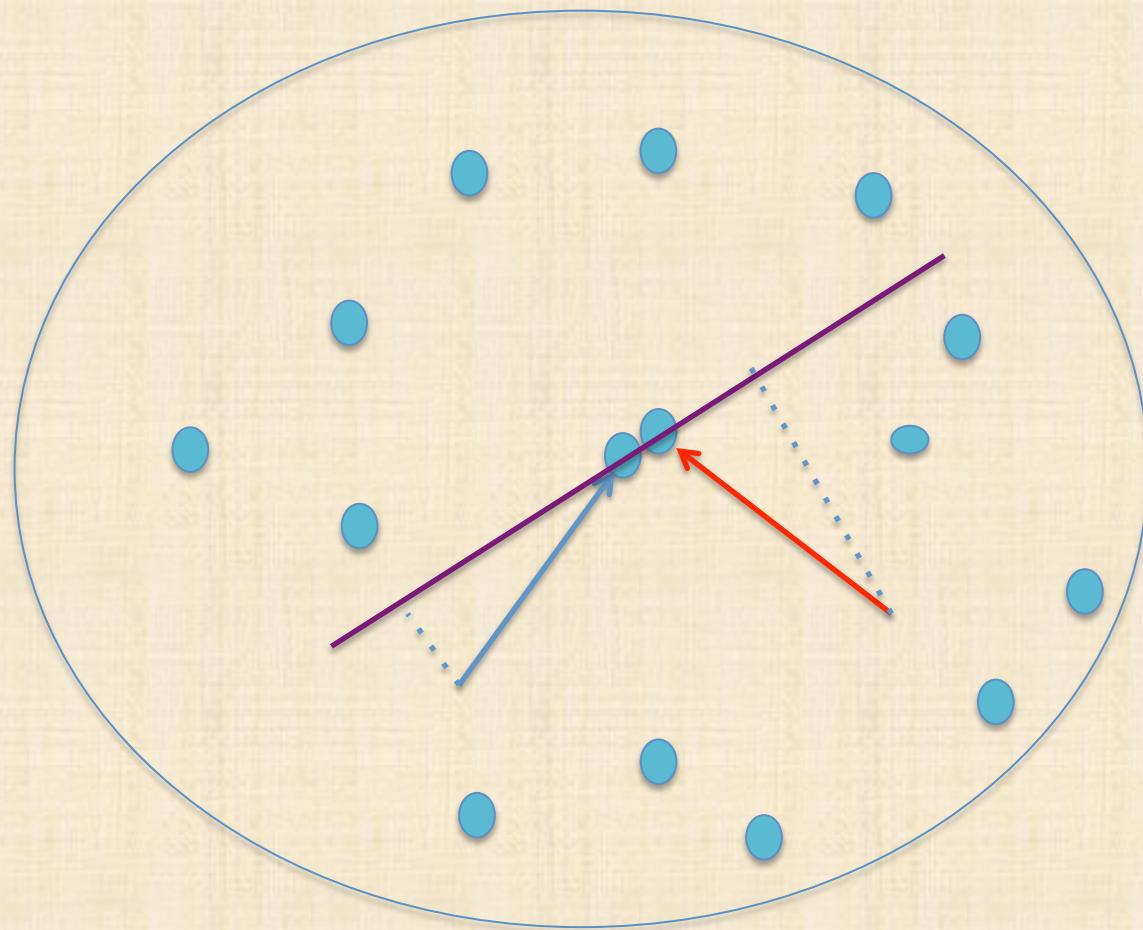
- $H$  e  $H_s$  sono la stessa cosa a meno di costanti additive e moltiplicative (von Neumann: “*avrai successo. Pochi sanno veramente cosa sia*”). Entropos (verso interno)
- Da  $\inf_i = -\lg p_i$  segue che:
- $H_s$  è l’ informazione media della sorgente informativa  $S = (X, P)$

# Pythagorean Recombination Game confirms Boltzmann's claim

Start with a population P of **random** numbers

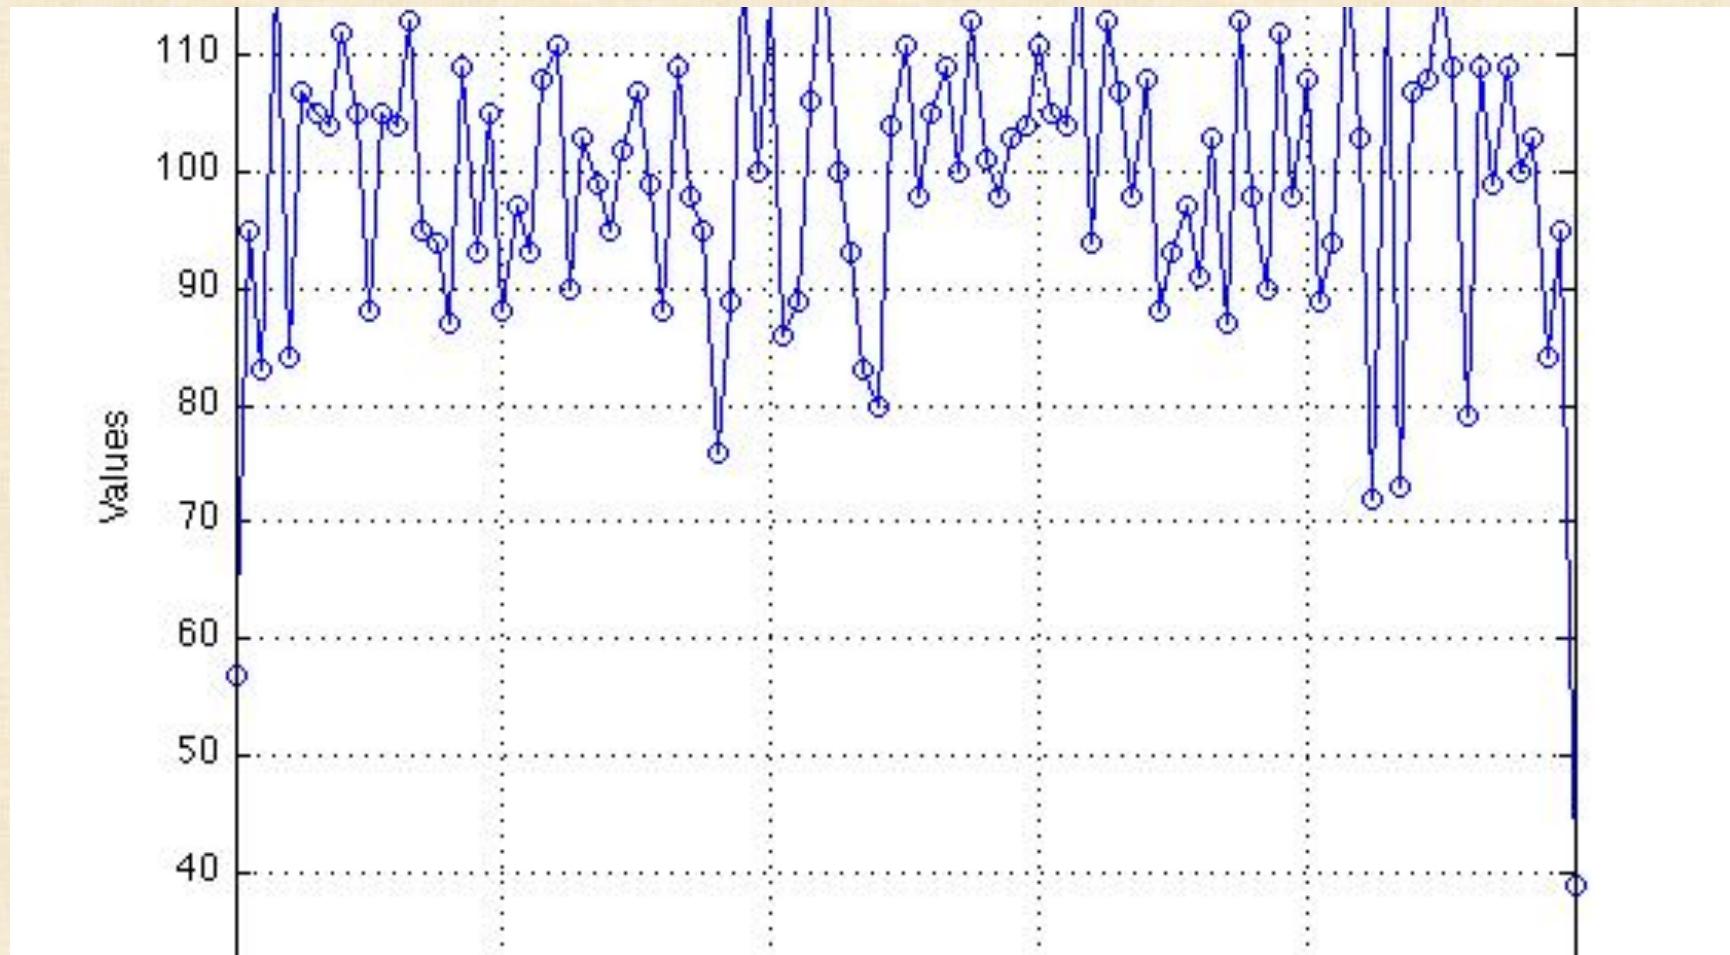
- **For N steps do**
  - Choose **randomly** a, b in P
  - Choose **randomly** a number  $a_1 \leq a$  and split a into  $a_1$  and  $a_2 = \text{sqr}(a^2 - a_1^2)$ , that is,  $a = \text{sqr}(a_1^2 + a_2^2)$
  - Choose **randomly** a number  $b_1 \leq b$  and split b into  $b_1$  and  $b_2 = \text{sqr}(b^2 - b_1^2)$ , that is,  $b = \text{sqr}(b_1^2 + b_2^2)$
- Replace in P numbers a, b with:  
$$a' = \text{sqr}(a_1^2 - b_2^2), \quad b' = \text{sqr}(b_1^2 - a_2^2).$$

# 2D Gas

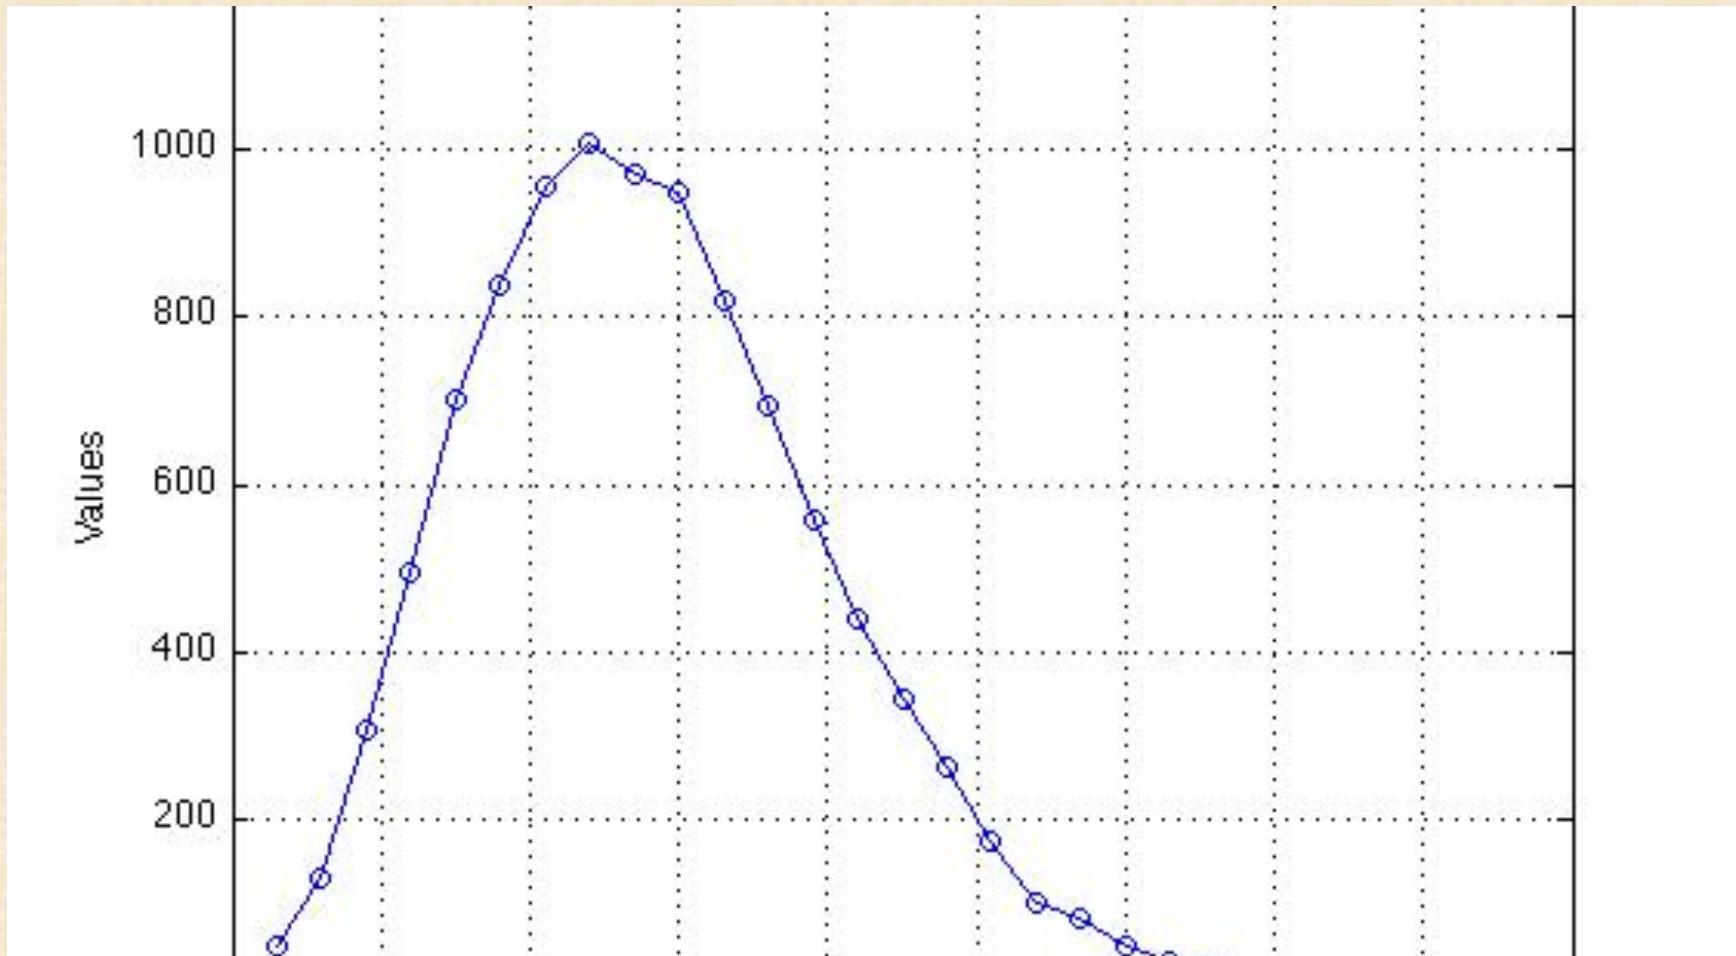


NOTA BENE: l'elasticità degli urti equivale alla conservazione della varianza nella distribuzione delle velocità

# A Population of 1000 random numbers

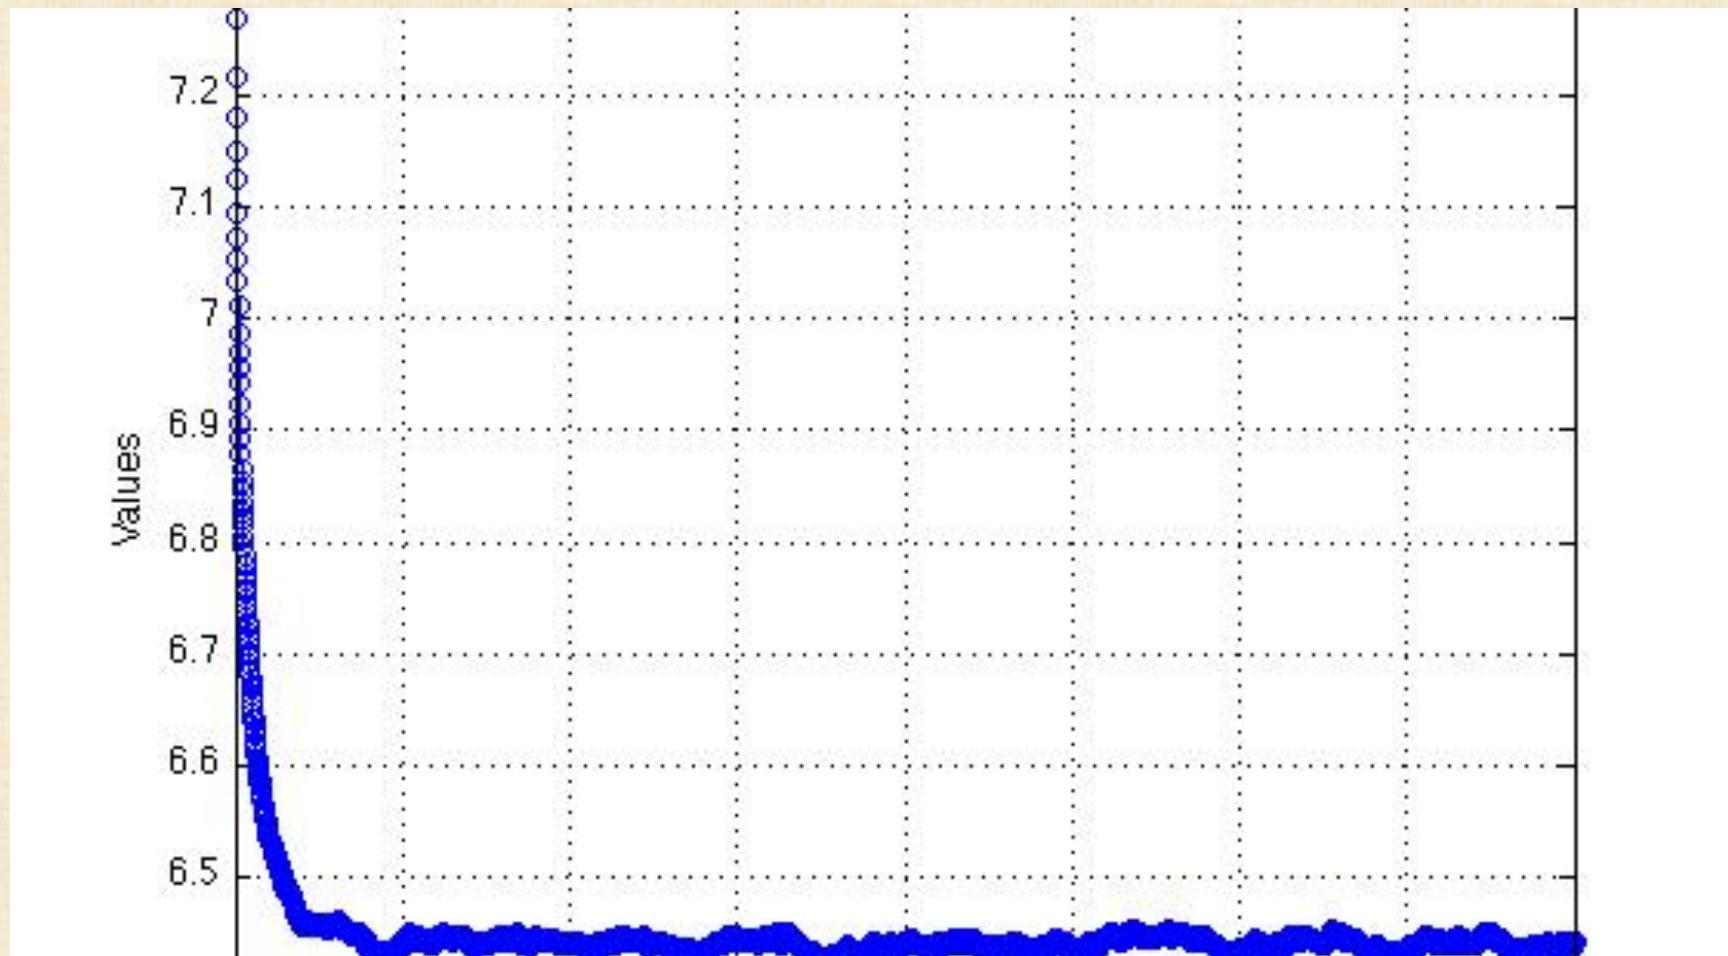


# H after 4000 steps 200 collisions/step



Chi = sqrt of a sum of squares normally distributed

# H after 4000 steps 200 collisions/step



# Cosa è avvenuto?

- Il sistema si “complessifica”: le sue parti diventano interdipendenti;
- le cause si “normalizzano” le distribuzioni di velocità seguono le leggi casuali dei grandi numeri;
- aumenta l’informazione media perché la velocità di ogni particella dipende da tutte quelle che ha incontrato nella storia delle sue collisioni;
- aumenta l’entropia informativa.

V. Manca – Infobiotics: information in biotic systems,  
Springer, 2013

## H theorem is an information theory theorem

- 1) Maxwell already proved that velocities reach normal Distribution (as a consequence of cause normalization).
- 2) Elastic collisions guarantee that variance of speed distribution remains constant  
(Pythagorean game keeps variance distribution constant).
- 3) The Gaussian curve is the distribution having maximum Entropy within the class of distributions with a given variance.

# Deterministic Chaos

## Algorithmic Generation of randomness

It is the basis of Pseudo-Random Numbers  
(on which random genomes are based)

Nothing is more difficult than reproduce a real  
random process. BUT

$\pi$  digits, Bernoulli Shifts, Lehmer generators,  
Logistic Maps, ... are algorithmic ways to  
generate processes that appear as truly random  
processes ( $\sim 1950 \rightarrow \dots$ )

# Poisson, Geometric, Exponential

Il caso è sempre un **urna** (con una dea bendata) p frazione di palline bianche (successo) e 1-p di nere (insuccesso):

$$\binom{n}{k} p^k (1-p)^{n-k}$$

è la probabilità di avere k successi in n estrazioni. Se la media in n estrazioni è  $\lambda$  :

$$\binom{n}{k} (\lambda/n)^k (1-\lambda/n)^{n-k}$$

per  $n$  molto grande ( $p$  molto piccola) è  
la legge degli **eventi (casuali) rari**:

$$\binom{n}{k} \left(\frac{\lambda^k}{n^k}\right) e^{-\lambda}$$

$$n(n-1)(n-2)\dots/k! \left(\frac{\lambda^k}{n^k}\right) e^{-\lambda}$$


$$n(n-1)(n-2)\dots/n^k \left(\frac{\lambda^k}{k!}\right) e^{-\lambda} \approx e^{-\lambda} \lambda^k / k!$$

success waiting time probability  $\approx \lambda e^{-\lambda k}$

$$(1-p)^k p = p (1-p)^{pk/p} \approx p e^{-pk}$$

\*\*\*\*\*

# Symbolic Sequences (over an alphabet A)

- Alphabet = finite set of symbols (physical objects)
- Sequences, subsequences, strings
- $\alpha, \beta, \gamma, \delta, \eta, \dots \lambda$   $\alpha(i), \alpha[i], \alpha[i, j], |\alpha|$
- $\alpha\beta$  concatenation (monoid)  
 $(\alpha\beta)\gamma=\alpha(\beta\gamma), \alpha\lambda=\lambda\alpha=\alpha$   
 $\alpha_{[k]}\beta$  k-overlap concatenation  
 $\alpha_{[]} \beta$  maximal-overlap concatenation

A formal Language  $L$  on  $A$  is a set of strings on  $A$

$$L \subseteq A^*$$

- Operations :  $+, /, \cdot, *, \cap, [ ]$   $A^* \leftrightarrow N$

# Patterns and Transformations

- $G = (A, T, S, R)$  Chomsky Grammar  
Alphabet, Terminals, Start symbol, Rules
- $aB \rightarrow aaB$
- $Ba \rightarrow co$
- $aBaco \rightarrow aaBaco \rightarrow aaaBaco \rightarrow aaacoco$

# Universal Rewriting Schemata

- Replacement (Chomsky 1957)
- 2-Replacement (Kuroda 1964)
- Prefix-Suffix rotation-replacement (Post 1945)
- Concatenation, Split, Prefix/Suffix Deletion
- Copy-dislocate, Mutation (Transposons) \*\*\*

# A symbolic example of emergence

## The Tri-somatic Grammar

Alphabet = {a,b,c, S,B}

Terminals = {a,b,c}

Start = S

Rules =

- $S \rightarrow aSBc$
- $S \rightarrow bc$
- $cB \rightarrow Bc$
- $Bb \rightarrow bb$

$$L(G) = \{a^n b^n c^n \mid n > 0\}$$

Salomaa – Formal Language theory, Wiley, 1973

\*\*\*\*\*

*Infogenomics*  
*An Informational Approach analogous to*  
*ENCODE*

Representations of long symbolic sequences

- Positions → Symbols
- symbol → set of positions where it occurs  
(symbol spectra)
- Elongation Sequences
- Elongation trees
- (01)-walks (CGR - Chaos Game Representation)
- Auto-similarity distances
- k-RDD

# Dizionari genomici

- $D(G) = \{G[i,j] \mid 1 \leq i \leq j \leq |G|\}$  (dim. quadratica w.r.t.  $|G|$ )
- $D_k(G) = D(G) \cap \Gamma^k$
- Un dizionario incluso in  $D(G)$  dicesi dizionario di  $G$
- $D^\square$  è la chiusura di  $D$  per **maximal overlap concatenation**,  
 $\text{over}(\alpha, D) = \{\beta \text{ in } D \mid \alpha[]\beta \neq \lambda\}$ ,  $|\text{over}(\alpha, D)| \leq |\alpha|$ ,  $D[]D' = \dots$
- Una posizione  $p$  di  $G$  è  $m$ -coperta in  $D$  se vi sono  $m$  parole di  $D$  del tipo  $G[i,j]$  con  $i \leq p \leq j$
- $D$  copre  $G$  se ogni posizione di  $G$  è 1-coperta da  $D$  (se  $D^\square$  include  $D(G)$ )
- $D$  copre minimalmente  $G$  se  $D$  copre  $G$  e non include nessun  $D'$  che copre  $G$
- $G$  è (esattamente)  $D$ -fattorizzabile se  $G$  appartiene a  $D^*$

# Sequenziamento Genomico

- Dato un dizionario  $D$  incluso in  $D(G)$  è possibile determinare univocamente  $G$  a partire da  $D$ ?
- In genere no. Ma sotto ipotesi opportune sul coverage e sulla distanza relativa di coppie di parole è possibile farlo con probabilità molto alta.
- Che caratteristiche deve avere un dizionario di  $D$  perché  $G$  possa essere univocamente determinato da esso?

# Basic Genomic Indexes

- ***Ln*** Length
- ***kls*** k-Lexical selectivity  $|D_k(G)|/4^k$
- ***mfl*** Maximal Forbidden Length
- ***3-mult*** Codon multiplicity/frequency (k-mer with  $k \leq mfl$ )
- ***mrl*** Maximum Repeat length (+1 = all-hapax ***lub*** least upper bound)
- ***mhl*** Minimum Hapax Length (-1 = all-repeat ***glb*** greatest lower bound)
- ***arl , ahl*** Average (repeat/hapax) Length (also frequency weighted)
- ***alh , alr*** Almost Repeat/hapax Length (95% of length L are repeat/hapax )
- ***cov, pcov*** The percentage of G covered by D, and the average positional coverage
- ***E<sub>k</sub>(G) , EE<sub>k</sub>(G)*** Empirical k-Entropy , Excess Empirical k-Entropy

# Distribuzioni genomiche

- Molteplicità (rispetto a un dizionario D)
- Co-Molteplicità (rispetto a D)
- k-occorrenza (rispetto a D e unit-intervals)
- RDD (di una parola) \*\*\*
- Seq-Coverage (di una parola/dizionario rispetto a G)
- Pos-Coverage (di una posizione di G rispetto a D)
- Length-repeats

# Minimal k-RDD

Let  $\alpha \in D(G)$  such that:

--- $\alpha$ --- $d_1$ --- $\alpha$ --- $d_2$ --- $\alpha$ --- $d_1$ --- $\alpha$ --- $d_3$ --- $\alpha$ ---

where between two consecutive  $\alpha$  no  $\alpha$  occurs

$K\text{-RDD}(\alpha, G) = d_1 \rightarrow n_1, d_2 \rightarrow n_2, d_3 \rightarrow n_3, \dots$

If  $G$  is random, for  $\alpha$  “not too short, but long enough”,  
 $K\text{-RDD}(\alpha, G)$  is geometric/exponential, according to  
probability theory.

**chr22.3bit**

Start      Refresh      clone

k      3

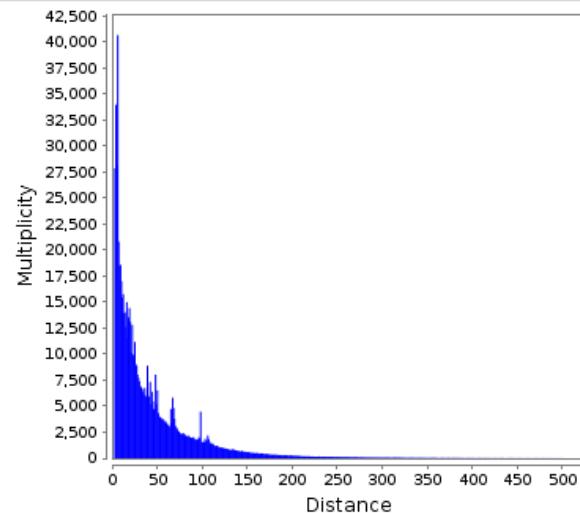
go AGG  
prev lock next

k      3

go AGG  
prev lock next

max distance 500

log Y log Y

**chr22.3bit**

Start      Refresh      clone

k      6

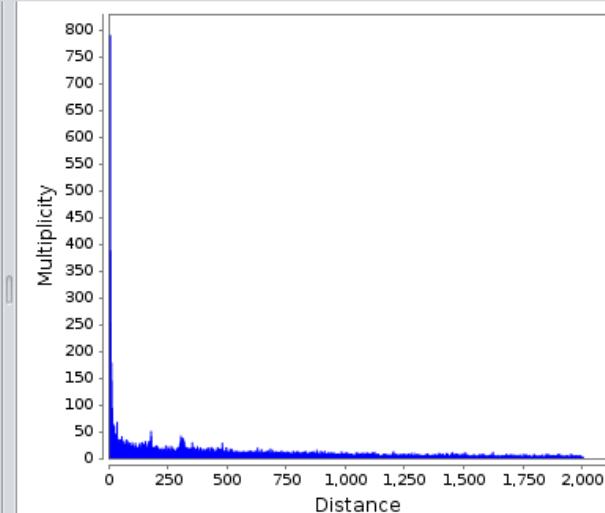
go AAAAGA  
prev lock next

k      6

go AAAAGA  
prev lock next

max distance 2000

log Y log Y

**ecoli\_536.3bit**

Start      Refresh      clone

k      3

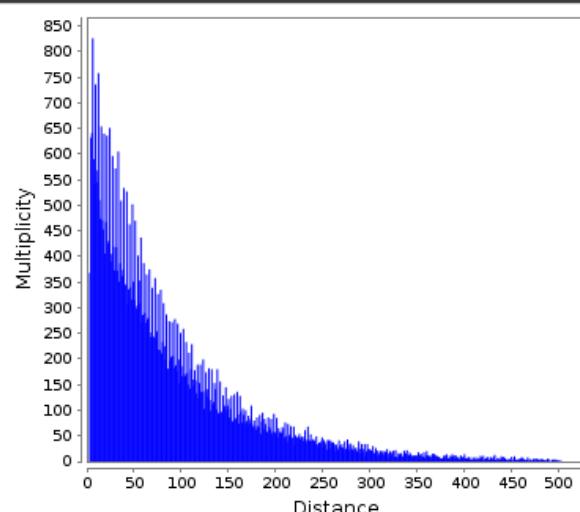
go AGG  
prev lock next

k      3

go AGG  
prev lock next

max distance 500

log Y log Y

**ecoli\_536.3bit**

Start      Refresh      clone

k      6

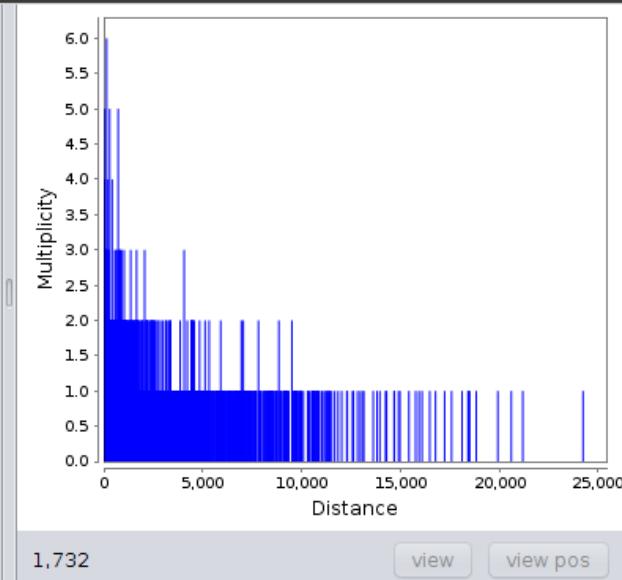
go AAAAGA  
prev lock next

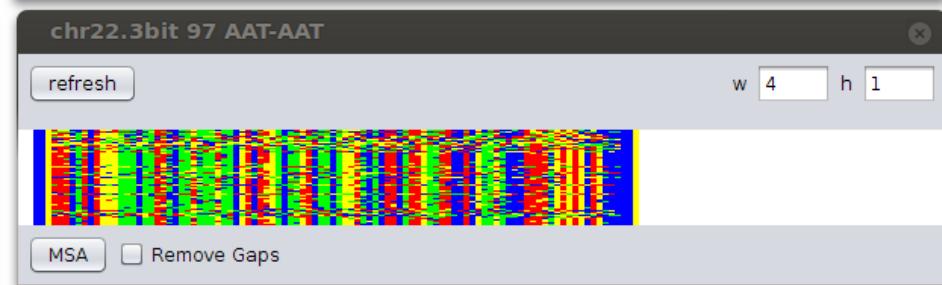
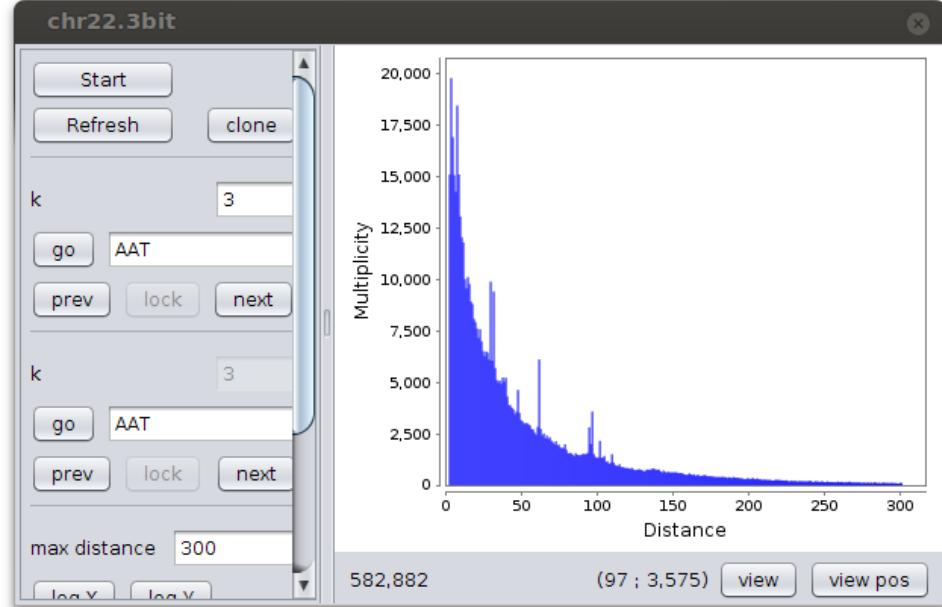
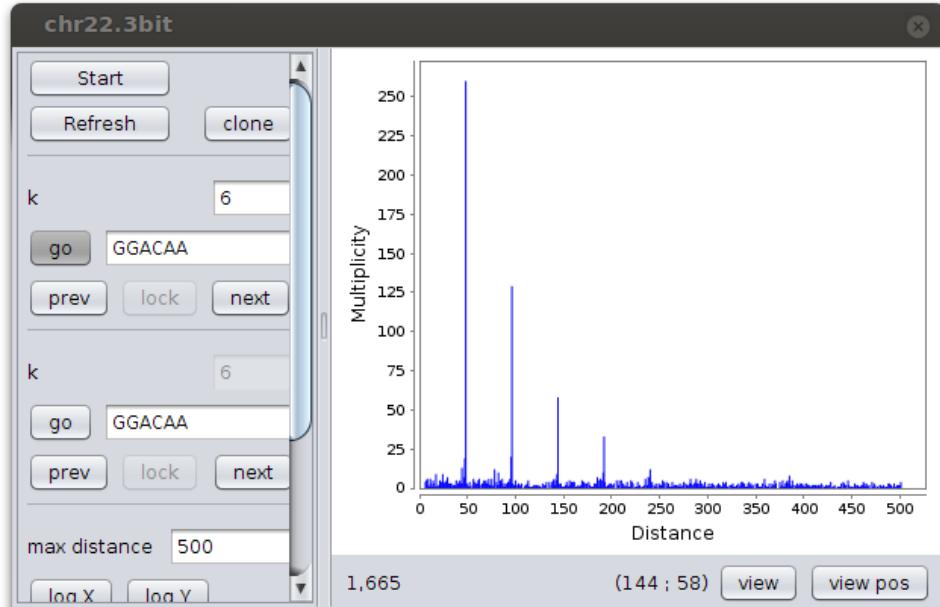
k      3

go AAAAGA  
prev lock next

max distance

log Y log Y





# Information Correlation and RDD in Genomes

- Trifonof et al. : DNA correlation periodicities, 1980
- Shepherd : DNA periodicities in coding regions, 1981
- Eigen et al. : periodicity in Transfer-RNA, 1981
- Fickett :1982 non min. RDD periodicity in coding regions, 1982
- Li : Mutual information in DNA Strings, 1990
- Herzel et al. : Measuring DNA correlations, 1990
- Li internal correlation in DNA, 1997
- Herzel-Weiss-Trifonof : 10-11 Periodicity, 1999
- Afreixo : 1-RDD min. 2009
- Bastos : 2-RDD min. 2011
- Carpena et al. RDD in keywords finding (non DNA), 2009-2013
- Computational Chemistry 2014

\*\*\*\*\*

# Recurrence Distance Distribution

- Peak 3-periodicity, for  $k=1, 2, \dots$  in coding regions
- Double exponential distributions
- ncRNA peak 3-periodicity
- Average RDD for  $k > 3$
- $C_3$  coefficients of coding propensity
- Anti 3-periodicity
- Extra peaks and repetitiveness

Bonnici's IG-Tools investigation about new periodicity phenomena revealing sequence functions

# Codici

funzione :  $C \rightarrow D$  surgettiva (copre  $D$ )

$C$  stringhe su un alfabeto (codifiche)

$D$  insieme di dati

ad ogni **codifica** corrisponde uno ed **un solo dato**  
(una codifica non può corrispondere a due dati distinti)

due codifiche distinte possono codificare uno stesso dato  
(come nel codice genetico). Il codice è *ridondante* se ciò vale  
(*non ridondante* altrimenti)

# Tipi basilari di codici

- Codici **univoci**: ogni stringa è fattorizzabile con codifiche in al più un unico modo
- Codici **istantanei**: nessuna codifica è prefisso di un'altra codifica
- Codici **autodelimitanti**: la codifica specifica la propria lunghezza
- Codici a **lunghezza fissa**
- Norma di Kraft nel caso binario  $|C| = \sum_{x \in C} 2^{-|x|}$
- Th. McMillan : C univoco sse  $|C| \leq 1$
- Th. C univoco  $\rightarrow \exists C' \text{ istantaneo t. c. } |C|=|C'|$

# Entropic Divergence

$$DIV_{KL}(P, Q) = \sum_{x \in P, y \in Q} p(x) \lg [p(x) / q(y)]$$

Mean information difference between distributions  
(Kullback , Leibler 1951).

Many other divergences were elaborated, based  
on different approaches.

# Mutual information

$$I(P, Q) = D((P, Q), P \cdot Q)$$

Sender X    ==Channel==> Receiver Y

Noise alters data along the channel

What is the information amount that can pass correctly?

**Mutual Information Th**  $I(X, Y) = H(X) - H(X | Y)$

**Shannon's 2° Th.** Provides conditions to transmit with error probability going to zero (autocorrecting codes).

# Mutual Information in genomes

$$I_{\alpha,\beta}(G) = \sum_d p_{\alpha,\beta}(G,d) \log [p_{\alpha,\beta}(G,d)/p_{\alpha}(G)p_{\beta}(G)]$$

$$I_d(G) = \sum_{\alpha,\beta} p_{\alpha,\beta}(G,d) \log [p_{\alpha,\beta}(G,d)/p_{\alpha}(G)p_{\beta}(G)]$$

[Li, 1990, Herzel-Grosse 1995]

\*\*\*\*\*

# Genomic Dictionaries

Sets of words (of length 10-100) with relevant recurrence properties.

Carpena et alii's Approach

Carpena et al. – C index  
Phys. Rev. E - 2009

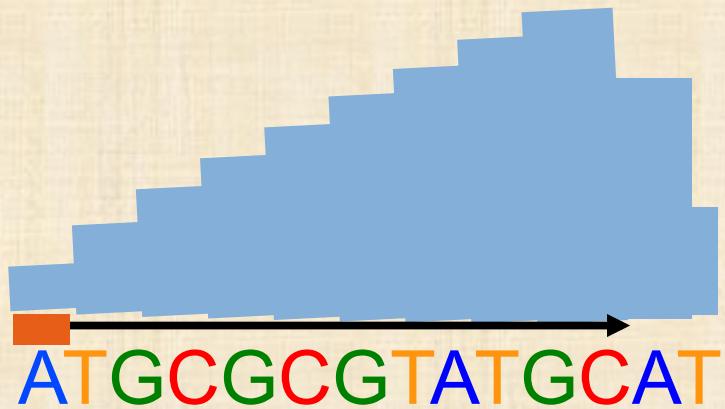
1. Distance word recurrence distribution  $d(\alpha)$
2. Standard dev. of  $d(\alpha)$  and mean normalization  $\sigma(\alpha)$
3. Geometric distributions  $p^{d-1}(1-p)$  with  $p = n/L$
4. Geometric Normalization  $\sigma_{\text{nor}}(\alpha)$
5. Random Normalization  $\sigma_{\text{nor}}(\alpha, n)$
6. Index of clusterization  $C(\alpha)$
7. Selection of words by elongation from initial seeds by means of stability w.r.t. the word relevance indexe C.

# A New Word Selection Algorithm based on EXP/KL

## INGREDIENTS

- Word Recurrence distance distribution  $\text{RDD}(\alpha)$
- Waiting time exponential law (in random genomes)
- “Entropic distances” between distributions
- Words extraction by elongation-monotonicity
- Maximal elongations
- Word filtering by different tests

# Elongation cases (by V. Bonnici)



seed

Seed extension → Elongation extension



Seed extension → Elongation identity



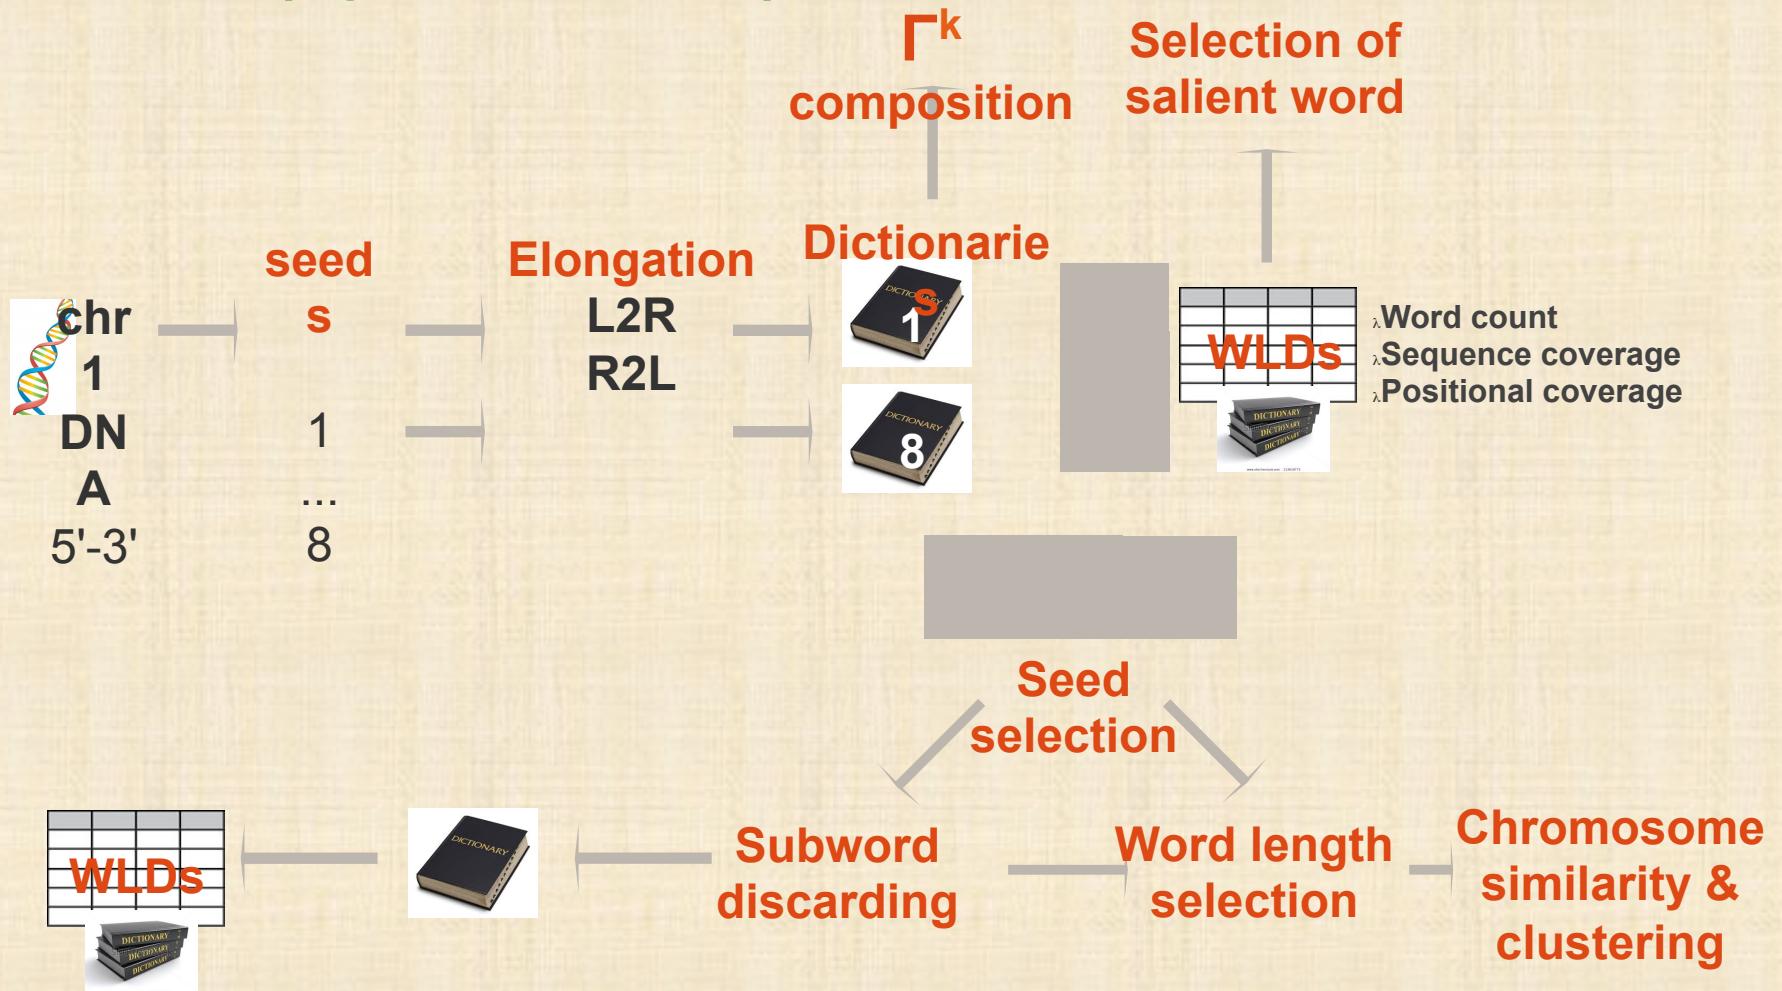
Seed inclusion → Elongation inclusion



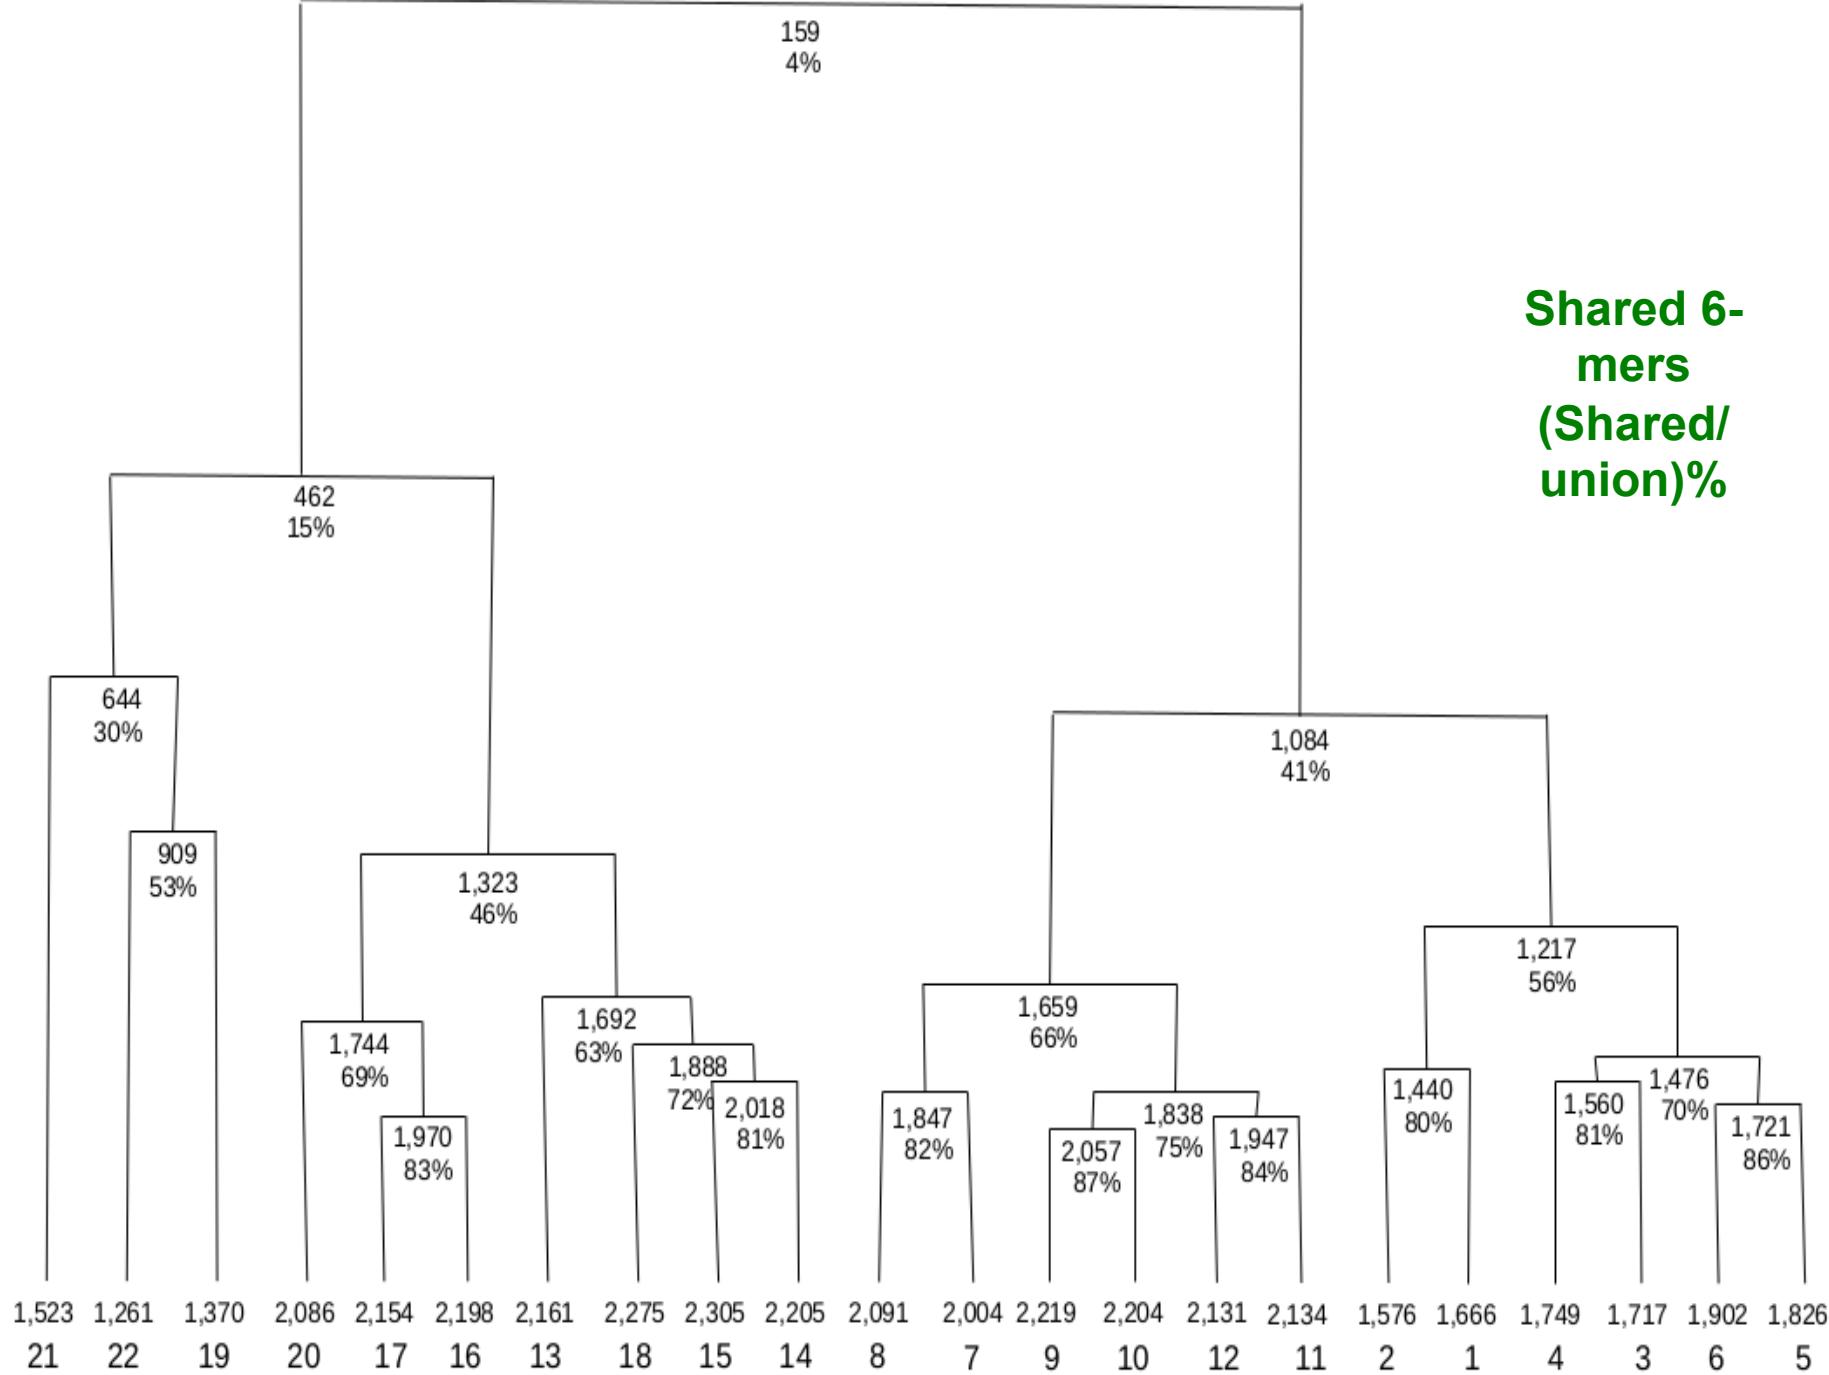
## The power of hexamers

	5	5	5
6	1,666	<b>0.8426</b>	<b>2.7715</b>
7	<b>2,310</b>	0.7691	2.5877
8	593	0.1384	1.5184
9	811	0.0615	<b>1.8791</b>
10	<b>2,140</b>	0.0206	1.1926
11	2,115	<b>0.0127</b>	<b>1.7829</b>
12	1,363	0.0089	1.1809
13	579	0.0065	1.3769
14	145	0.0065	1.2244
15	33	0.0052	1.1739
16	17	0.0017	1.2539
17	6	0.0013	<b>1.3957</b>
18	1	0.0006	1.0000

# Informational Analysis Pipeline (by V. Bonnici)



## Shared 6-mers (Shared/union)%



# A jewel in word extraction (chr. 1 hg. 19)

Discarding extracted subwords and partitioning

Radicals and Maximal Morphemes

	5	5	5	5	5	5	5	5	5	5	
6	1,666	0.843	2.772		1,632	0.841	2.728		34	0.039	1.057
7	2,310	0.769	2.588		1,446	0.646	1.922		864	0.464	1.615
8	593	0.138	1.518		186	0.074	1.297		407	0.086	1.327
9	811	0.061	1.879		71	0.016	1.288		740	0.054	1.740
10	2,140	0.021	1.193		63	0.010	1.138		2,077	0.012	1.073
11	2,115	0.013	1.783		22	0.007	1.320		2,093	0.006	2.269
12	1,363	0.009	1.181		13	0.006	1.228		1,350	0.003	1.093
13	579	0.007	1.377		11	0.005	1.459		568	0.001	1.012
14	145	0.006	1.224		8	0.006	1.253		137	0.001	1.055
15	33	0.005	1.174		3	0.003	1.134		30	0.003	1.000
16	17	0.002	1.254		2	0.001	1.502		15	0.001	1.000
17	6	0.001	1.396		2	0.001	1.768		4	0.001	1.000
18	1	0.001	1.000						1	0.001	1.000
All	11,779	0.994	4.764		3,459	0.979	3.778		8,320	0.587	1.767

Radicals: ca, sa, le



Maximal morphemes: casale

# Dictionary Validation

Words extracted by informational methods are informationally relevant, but what about their biological meaning?  
(Infogenomics is analogous to ENCODE)

Words are pieces on which genomes were built.  
Which categories emerge?

**Words** are, in this perspective, *iper-dense information units*

How defining and discovering biological significance?  
Can information tell us deep biological mechanisms?

\*\*\*\*\*

$$\text{Inf}_2(w) = -\log_2(\text{prob}(w))$$

$$E_k(G) = - \sum_{w \in D(G), |w|=k} \text{prob}(w) \text{Inf}(w)$$

Entropy is the mean information of a genome as information source of k-mers.

We computed Empirical Entropy  
for any word length, and for all Human chr.  
( $k=18, E_k \approx 24$  ;  $k=200 E_k \approx 25 !!!$ )

# Algorithmic basis of k-mer frequency computation

- Suffix trees ST
- Suffix arrays SA
- Enanchded SA ESA
- N-extended ESA NESA

Weiner 73

McCreight 76

Ukkonen 95

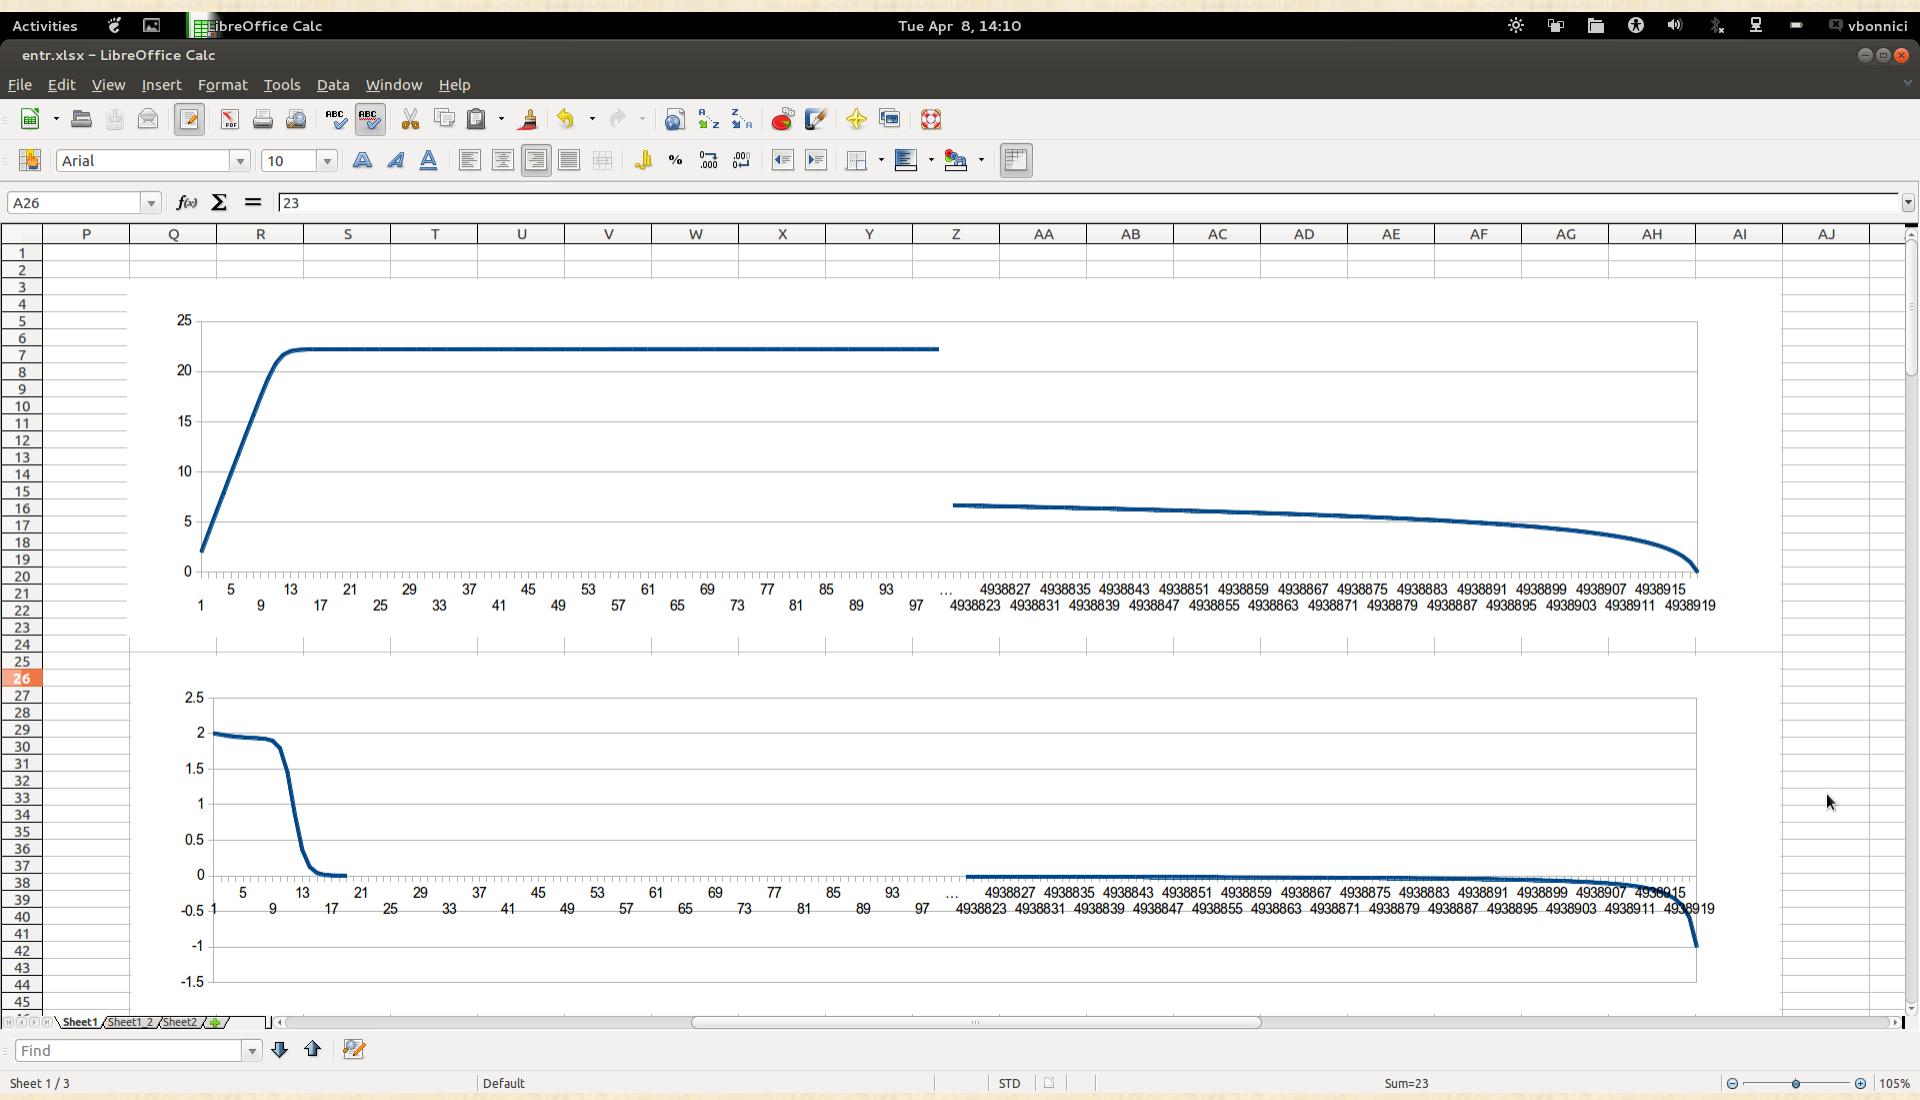
Farach 97

Manber & Myers 90

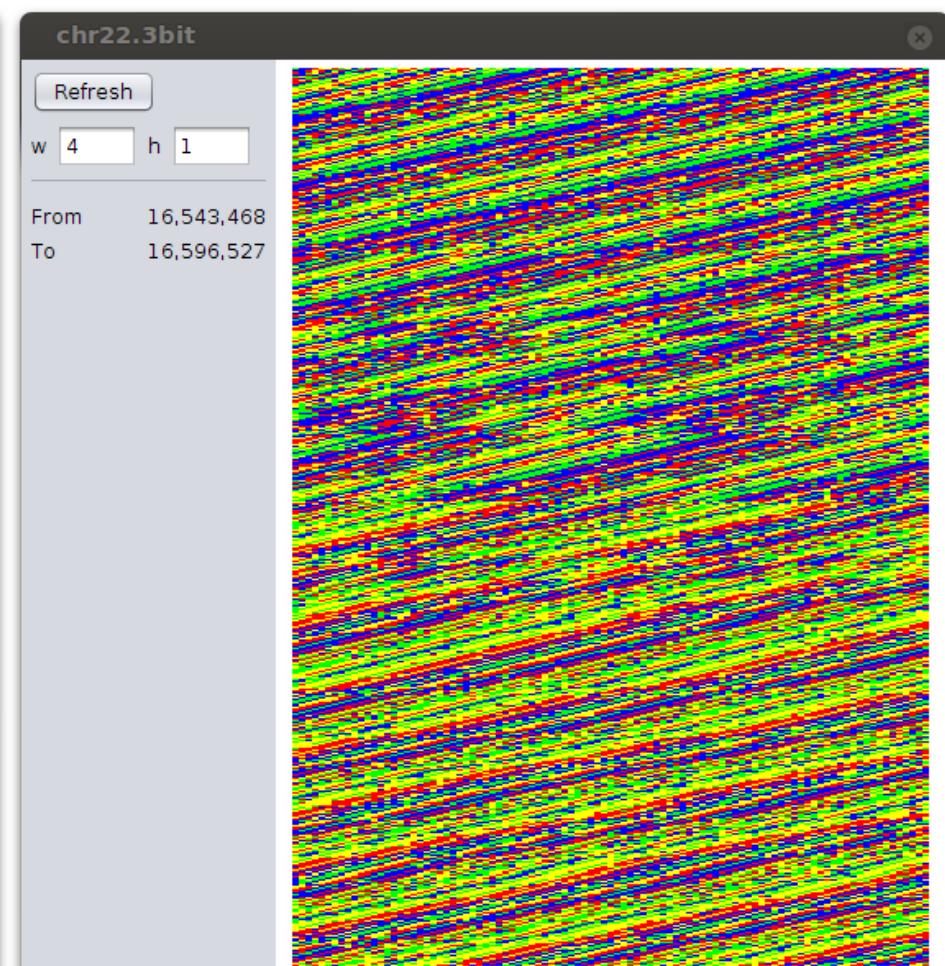
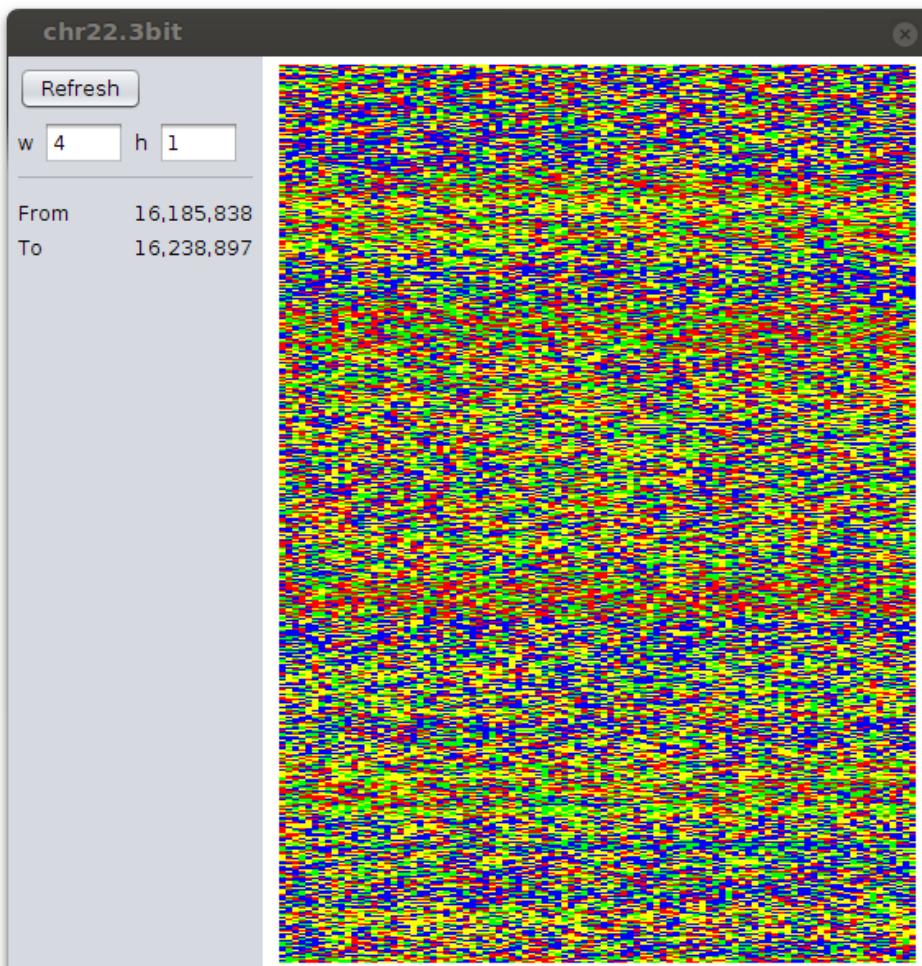
Abouelhoda, Kurtz, Ohlebusch 2004

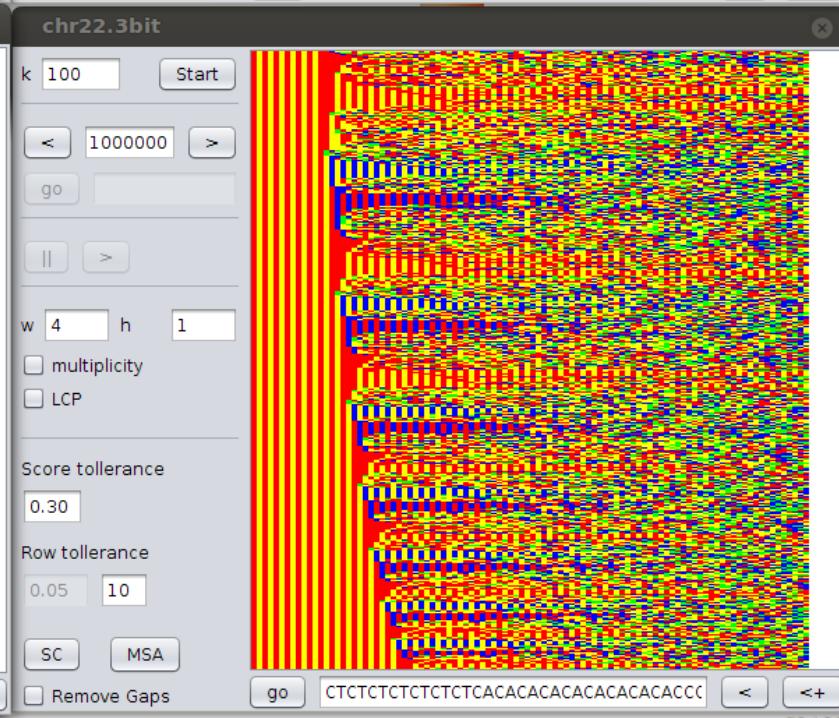
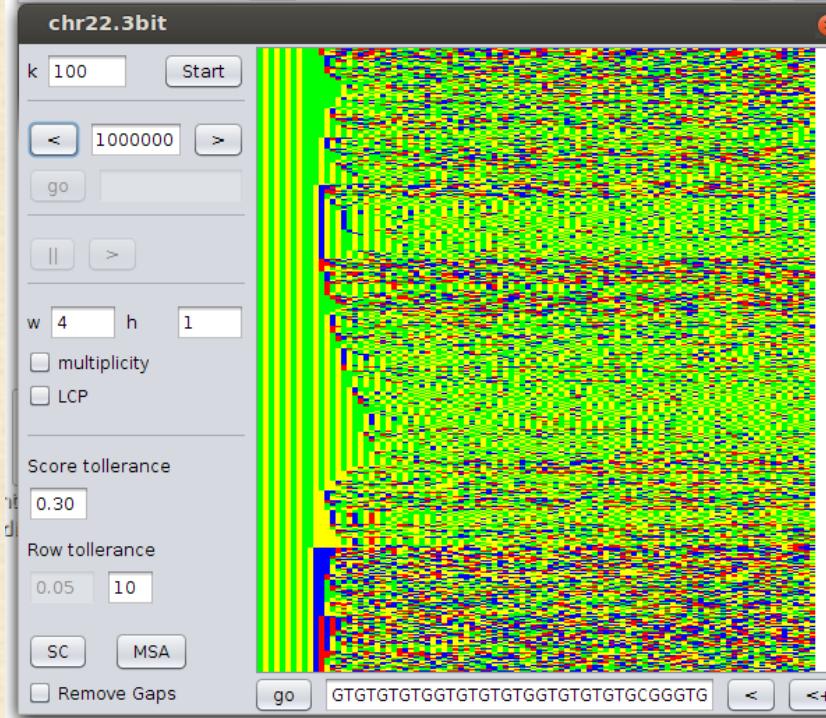
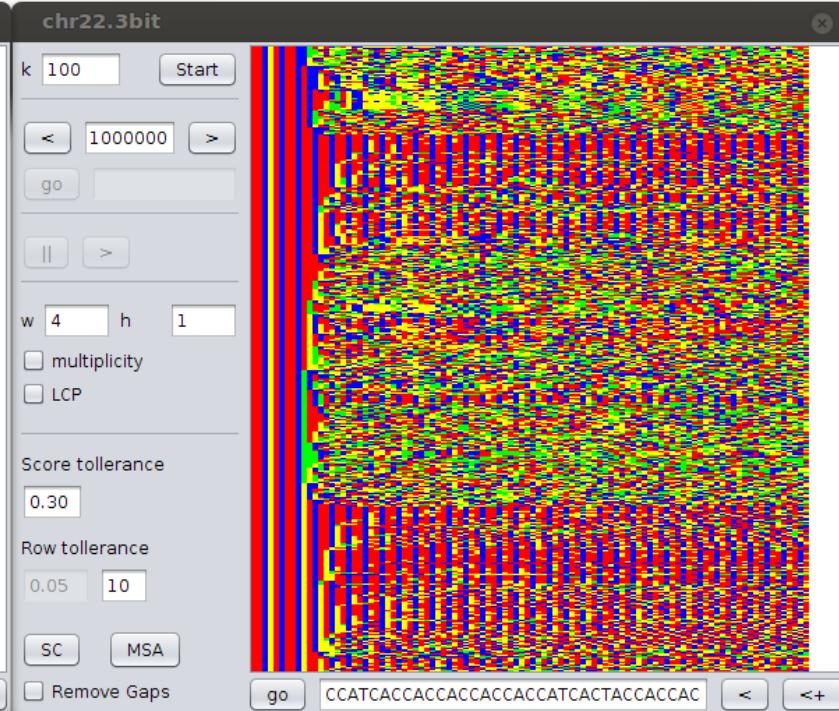
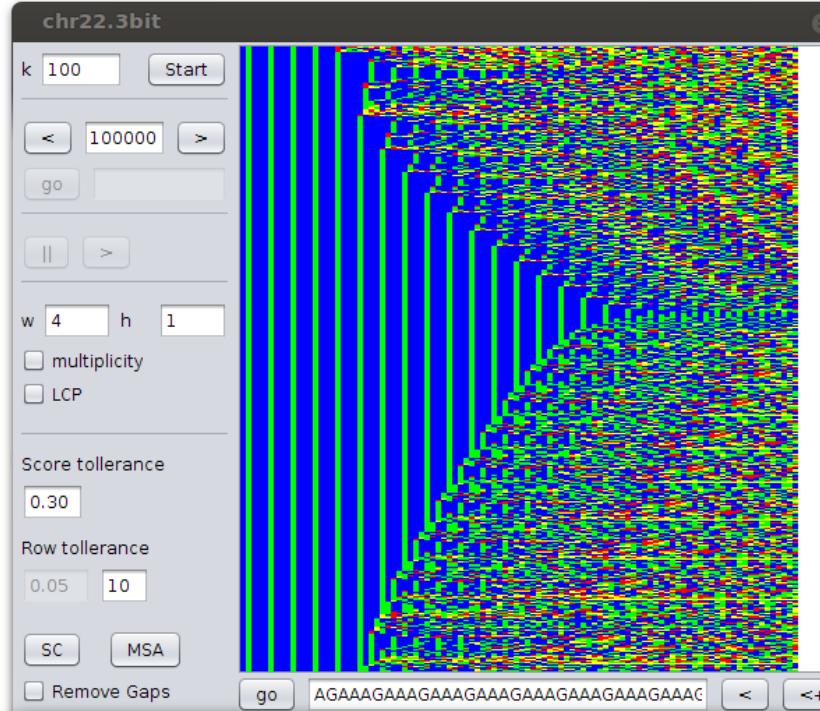
Kurtz et a. 2008

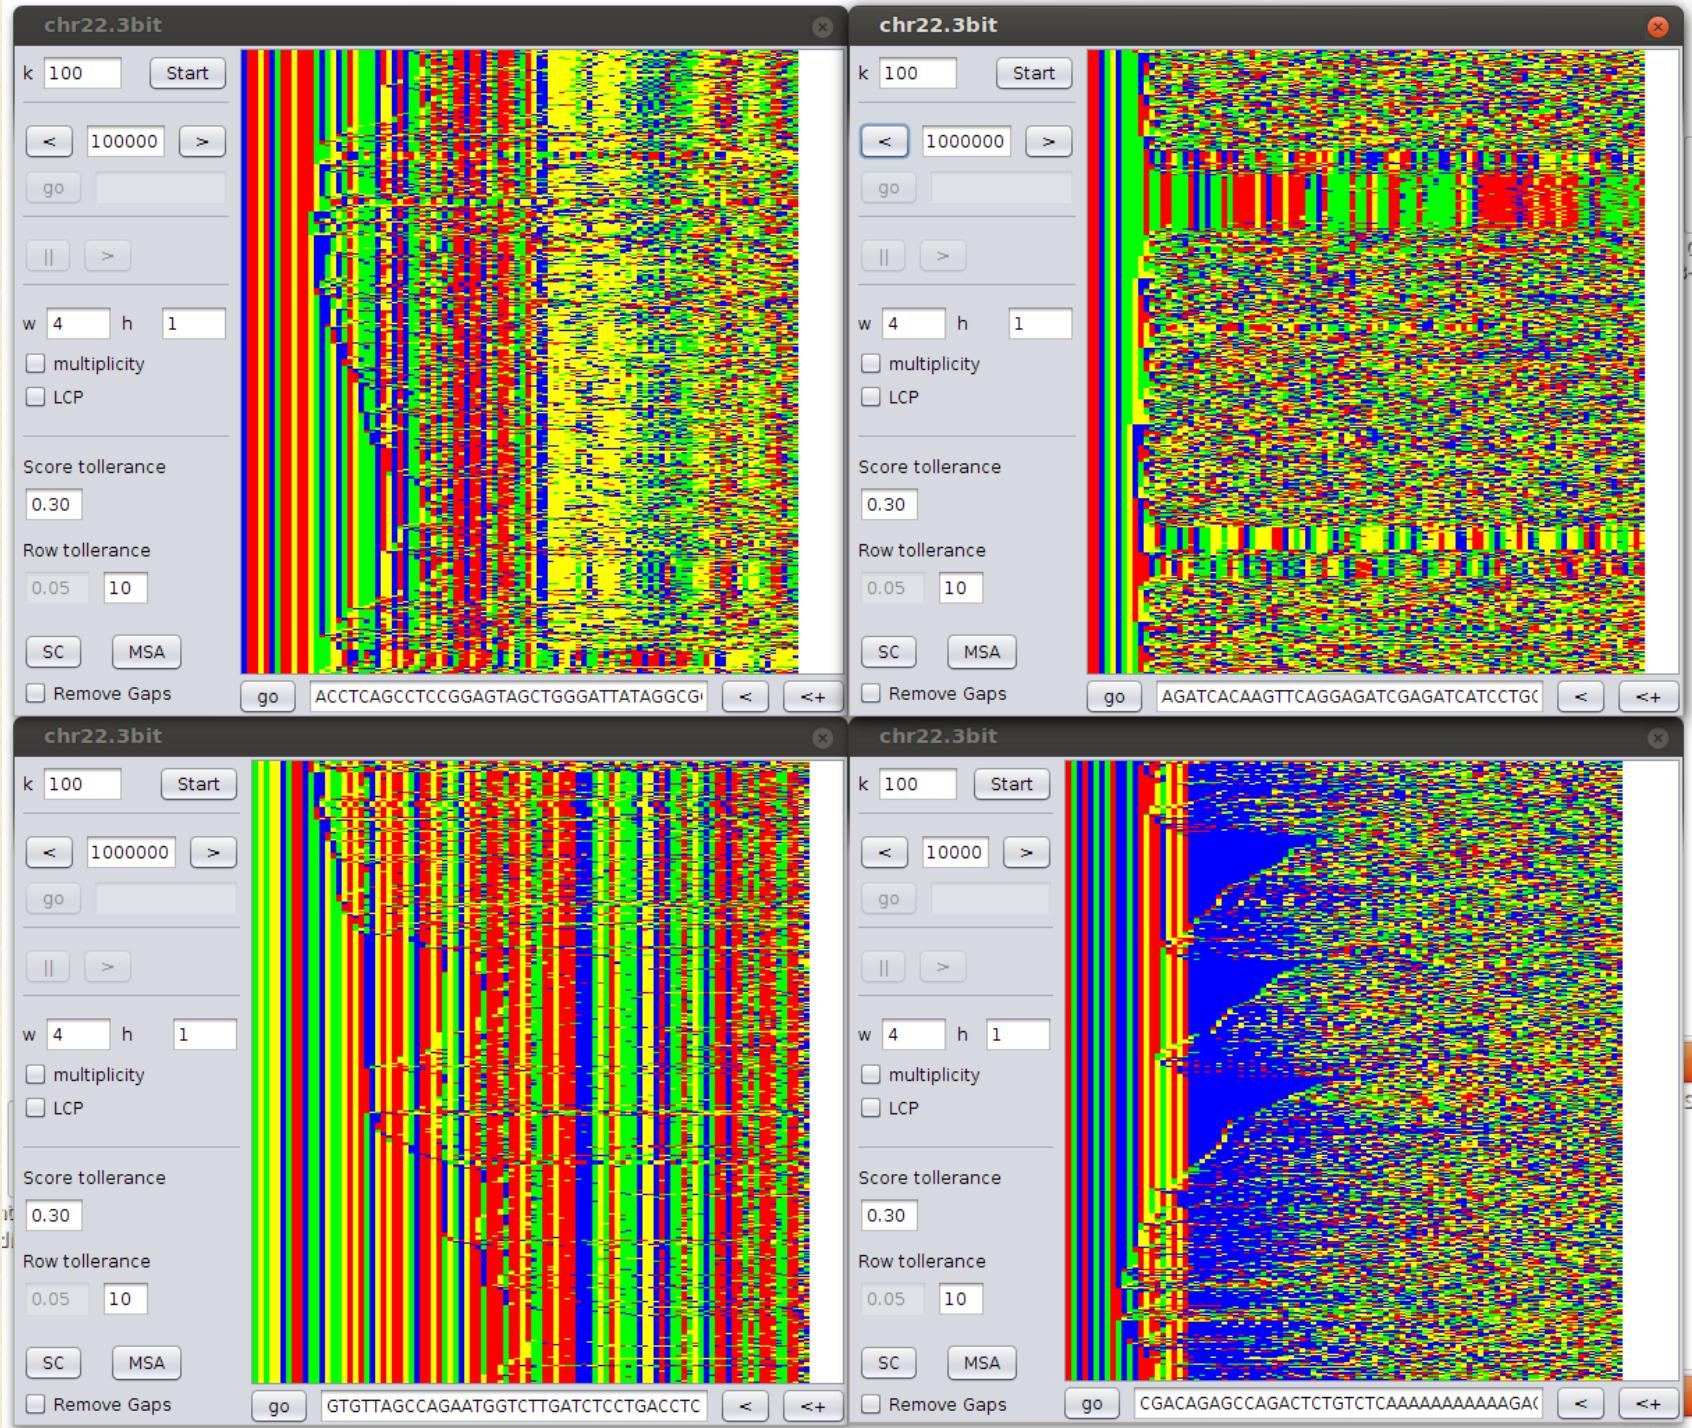
# Entropy and Excess Entropy (E. coli)



# Genomic Chromatic lines







# chr22.3bit



k 100

Start

&lt; 10000 &gt;

go

|| &gt;

w 4 h 1

 multiplicity LCP

Score tollerance

0.30

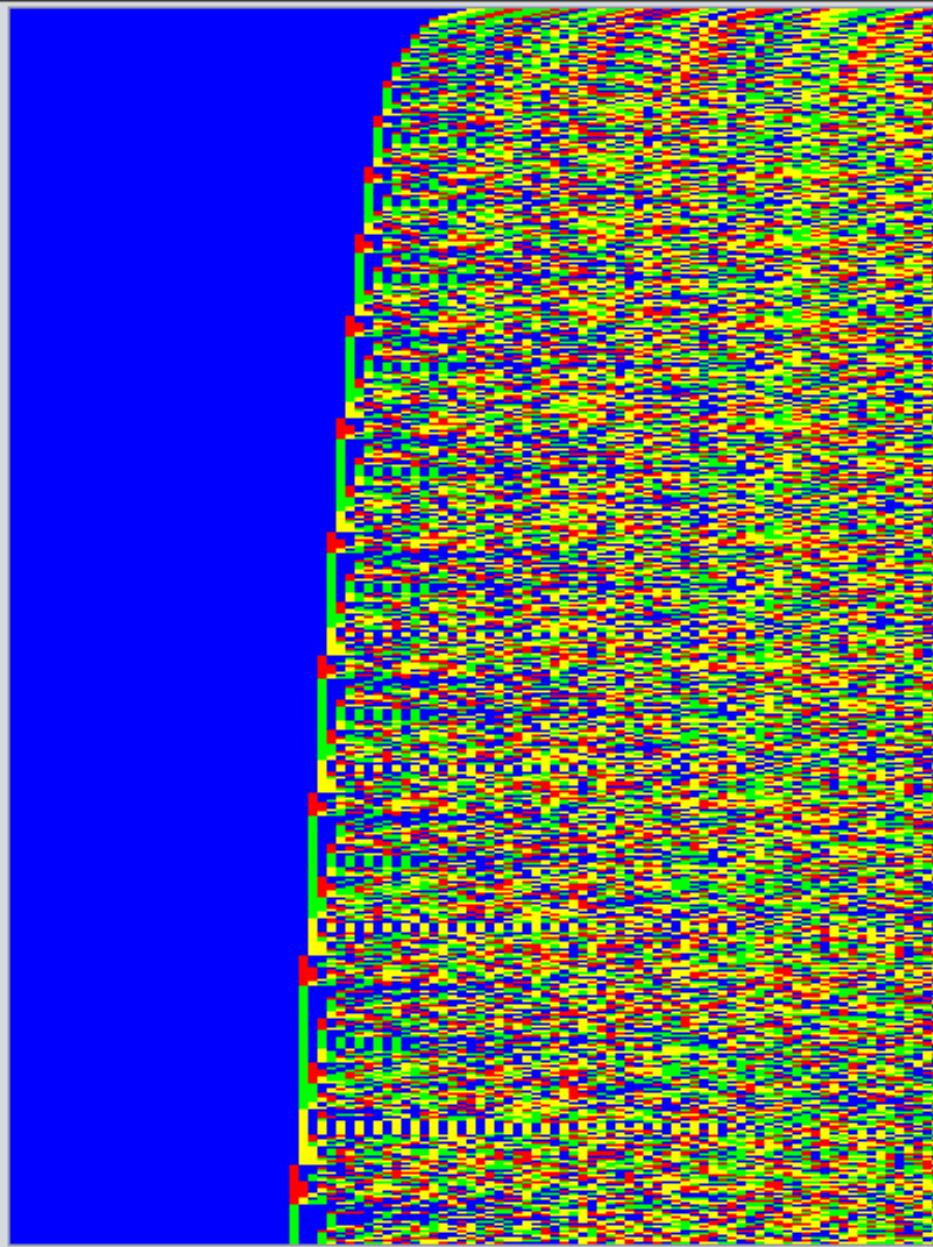
Row tollerance

0.05

10

SC

MSA

 Remove Gaps

go

&lt;

&lt;+

# Bio-bit: a measure of biological information

## **Bio-bit(G)**

provides a comparison between  $G$  and  $\text{Rand}_{|G|}$  by revealing the degree of anti-chaos present in  $G$ .

# Biobit

The information that, in the average m-words of G (for suitable m) gain in diverging from random genomes of the same length.

**Boltzmann&Shroedinger&Wiener's  
Neghentropy.**

# biobit( $G$ )

the formula is not simple to explain  
(empirical entropy, RND, KL divergence)

**It is related to the maximum of KL divergence  
between  $G$  and any  $R$  in  $\text{RND}_{|G|}$**

## Some biobit computations

Species	G	N%	CG%	Genes	Bb(G)
<i>Nanoarchaeum equitans</i>	0.49 Mb	0.00	31	585	0.011
<i>Candidatus Carsonella ruddii</i>	0.15 Mb	0.00	16	182	0.028
<i>Escherichia coli</i>	4.93 Mb	0.00	50	5k	0.038
<i>Mycoplasma genitalium</i>	0.58 Mb	0.00	31	558	0.042
<i>Cyanidioschyzon merolae</i>	14.9 Mb	0.00	55	6k	0.111
<i>Saccharomyces cerevisiae</i>	12.0 Mb	0.00	38	5k	0.145
<i>Trichomonas vaginalis</i>	0.58 Mb	0.36	32	60k	0.147
<i>Arabidopsis thaliana</i>	119 Mb	0.16	36	33k	0.176
<i>Caenorhabditis elegans</i>	100 Mb	0.00	35	46k	0.198
<i>Oryza brachyantha</i>	250 Mb	6.43	41	42k	0.274
<i>Drosophila melanogaster</i>	99 Mb	0.98	42	30k	0.281
<i>Oryza glaberrima</i>	285 Mb	4.00	41	60k	0.375
<i>Vitis vinifera</i>	426 Mb	2.35	35	26k	0.655
<i>Danio rerio</i>	1.34 Gb	0.14	36	40k	1.061
<i>Macaca mulatta</i>	2.88 Gb	11.21	42	30k	1.552
<i>Papio anubis</i>	2.72 Gb	1.54	42	36k	1.603
<i>Callithrix jacchus</i>	2.77 Gb	5.38	41	44k	1.617
<i>Nomascus leucogenys</i>	2.79 Gb	6.57	41	25k	1.721
<i>Sus scrofa</i>	2.59 Gb	10.52	42	34k	1.751
<i>Pongo abelii</i>	3.02 Gb	10.12	41	32k	1.762
<i>Homo sapiens GRCh37</i>	3.09 Gb	7.57	41	39k	1.768
<i>Monodelphis domestica</i>	3.60 Gb	2.88	38	34k	1.795
<i>Pan troglodytes</i>	3.17 Gb	13.33	42	35k	1.804
<i>Rattus norvegicus</i>	2.78 Gb	4.68	42	37k	1.824
<i>Homo sapiens GRCh38</i>	3.08 Gb	4.88	41	56k	1.886
<i>Mus musculus</i>	2.75 Gb	2.86	42	45k	2.151

**biobit** is an **anti-entropic**, rather than neghentropic, measure of **genome information**.

An upper bound for  $Bb(G)$ , say it  $BB(G)$ , is obtained by considering De Bruijn's sequences  $B(4,k)$  where  $|G| = 4^k + k - 1$  that is,  $k \approx \lg_2(|G|)$ . In these genomes only  $k$ -hapaxes occur.

# From Boltzmann to Carnot in cell state analysis

$$PV = nRT$$

Could you recover this law from the dynamical equations of the single particles colliding in the gas?

NO! So analogously, in the cell, we need to abstract from single biochemical molecule dynamics of about  $10^4$  different types (or macro-types) of molecules (which kind of distribution?)