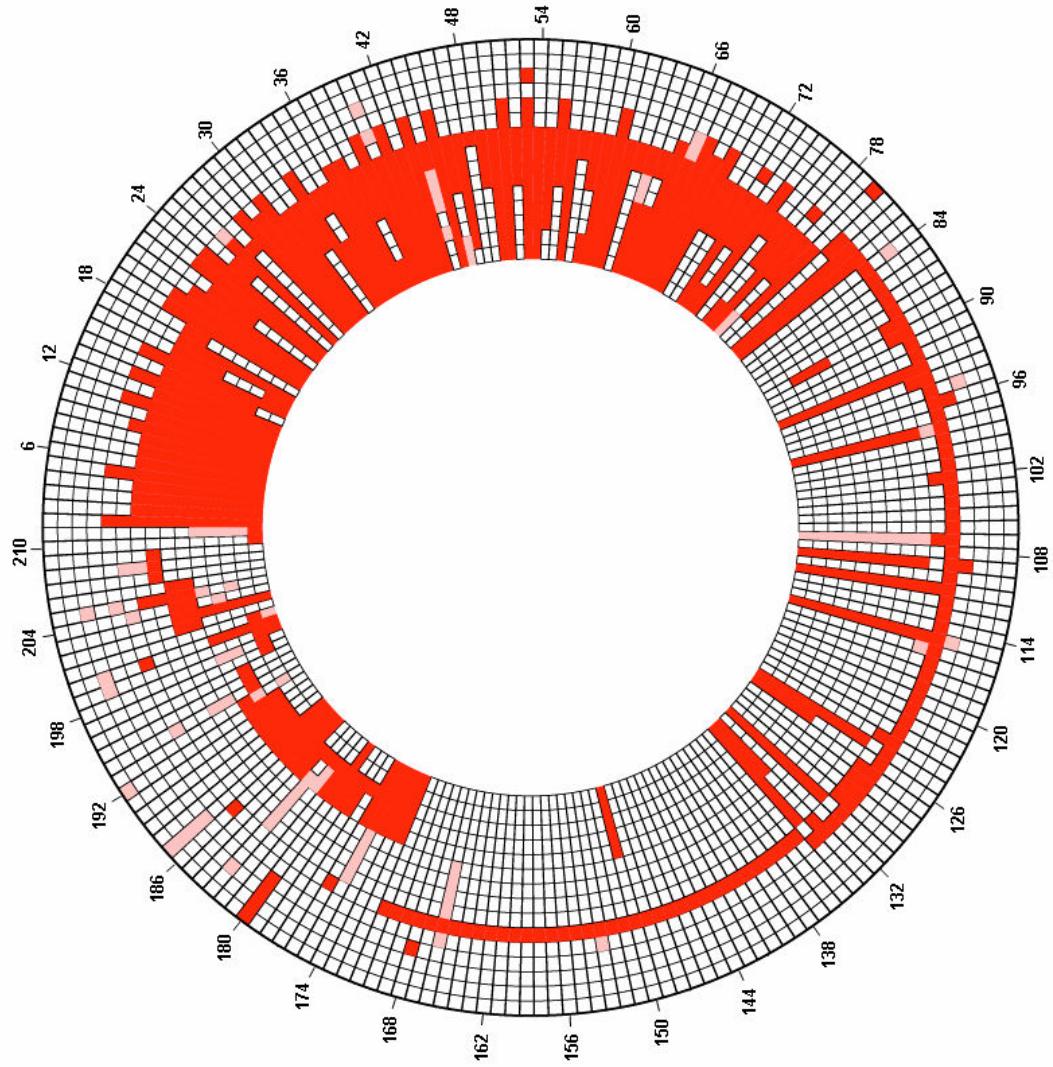
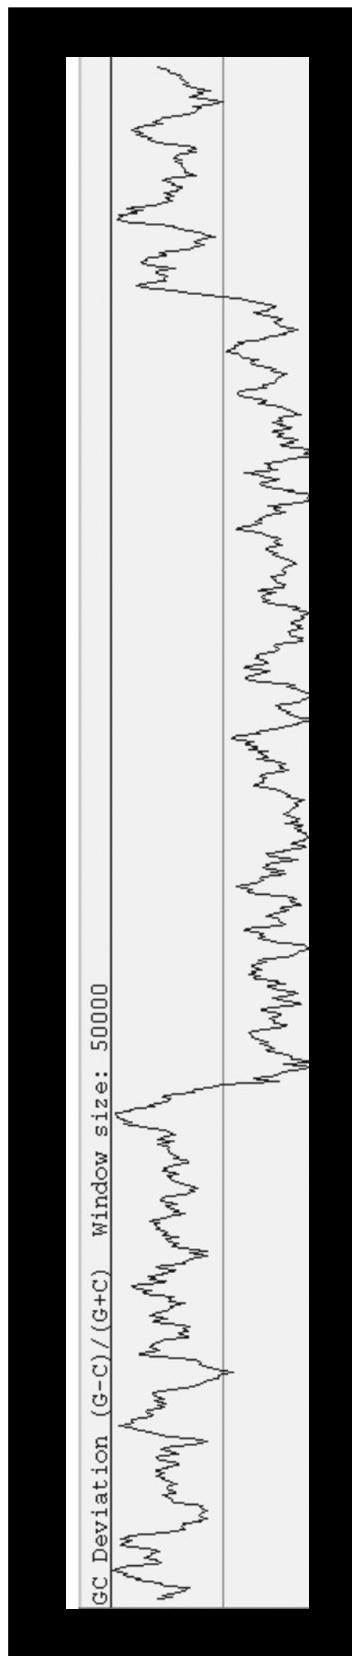


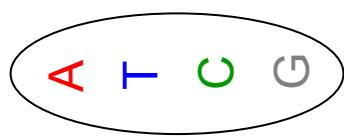
# Γονιδιωματική Ρευστότητα σε Μικροβιακούς Οργανισμούς (Επαναπροσδιορίζοντας τον ορισμό του βιολογικού είδους)



# *Noukλεοπιδική Σύσταση DNA... Τι μπορεί να μας πει?*

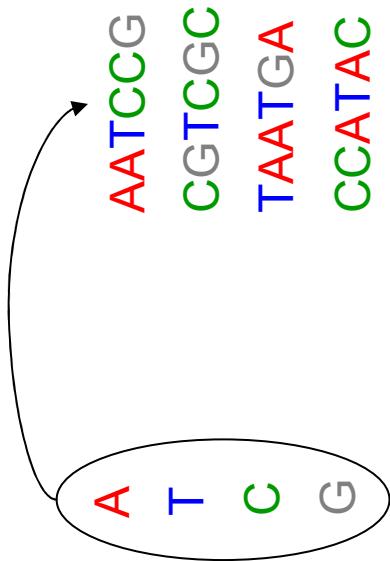


# *Noukλεοτιδική Σύσταση DNA*

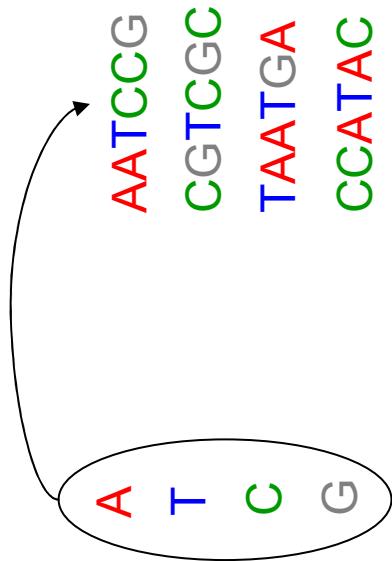


A   T   C   G

# *Noukλεοπιδική Σύσταση DNA*



# Noukλεστιδική Σύσταση DNA



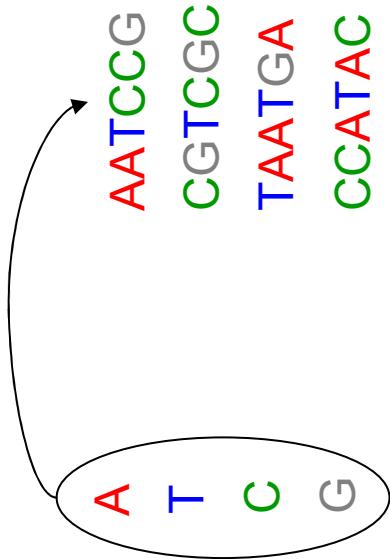
$$B^1 = \{A, T, C, G\}$$

$$B^2 = \{AA, AT, AC, AG, TA, TT, TC, TG, CA, CT, CC, CG, GA, GT, GC, GG\}$$

$$B^3 = \{AAA, AAT, AAC, AAG, \dots, GGA, GGT, GGC, GGG\}$$

$$B^k = \{\dots\}$$

# Noukλεστιδική Σύσταση DNA



$$B^1 = \{A, T, C, G\}$$

$$B^2 = \{AA, AT, AC, AG, TA, TT, TC, TG, CA, CT, CC, CG, GA, GT, GC, GG\}$$

$$B^3 = \{AAA, AAT, AAC, AAG, \dots, GGA, GGT, GGC, GGG\}$$

$$B^k = \{\dots\}$$

$$|B|^1 = 4$$

$$|B|^2 = 16$$

$$|B|^3 = 64$$

$$|B|^4 = 256$$

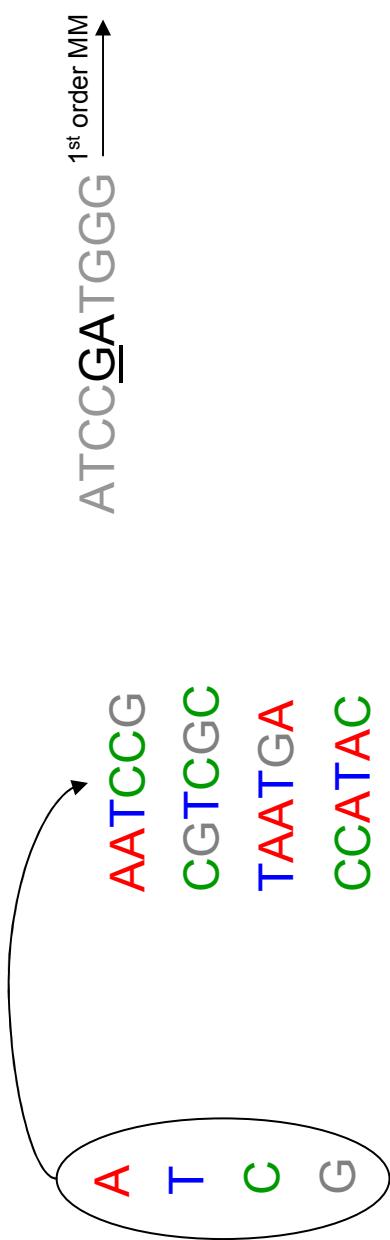
$$|B|^5 = 1024$$

$$|B|^6 = 4096$$

$$|B|^7 = 16384$$

$$|B|^8 = 65536$$

# Noukλεστιδική Σύσταση DNA



$$B^1 = \{A, T, C, G\}$$

$$B^2 = \{AA, AT, AC, AG, TA, TT, TC, TG, CA, CT, CC, CG, GA, GT, GC, GG\}$$

$$B^3 = \{AAA, AAT, AAC, AAG, \dots, GGA, GGT, GGC, GGG\}$$

$$B^k = \{\dots\}$$

$$|B|^1 = 4$$

$$|B|^2 = 16$$

$$|B|^3 = 64$$

$$|B|^4 = 256$$

$$|B|^5 = 1024$$

$$|B|^6 = 4096$$

$$|B|^7 = 16384$$

$$|B|^8 = 65536$$

# Noukλεστιδική Σύσταση DNA



$$B^1 = \{A, T, C, G\}$$

$$B^2 = \{AA, AT, AC, AG, TA, TT, TC, TG, CA, CT, CC, CG, GA, GT, GC, GG\}$$

$$B^3 = \{AAA, AAT, AAC, AAG, \dots, GGA, GGT, GGC, GGG\}$$

$$B^k = \{\dots\}$$

$$|B|^1 = 4$$

$$|B|^2 = 16$$

$$|B|^3 = 64$$

$$|B|^4 = 256$$

$$|B|^5 = 1024$$

$$|B|^6 = 4096$$

$$|B|^7 = 16384$$

$$|B|^8 = 65536$$

# Noukλεστιδική Σύσταση DNA



$B^1 = \{A, T, C, G\}$   
 $B^2 = \{AA, AT, AC, AG, TA, TT, TC, TG, CA, CT, CC, CG, GA, GT, GC, GG\}$   
 $B^3 = \{AAA, AAT, AAC, AAG, \dots, GGA, GGT, GGC, GGG\}$   
 $B^k = \{\dots\}$

$$|B|^1 = 4$$

$$|B|^2 = 16$$

$$|B|^3 = 64$$

$$|B|^4 = 256$$

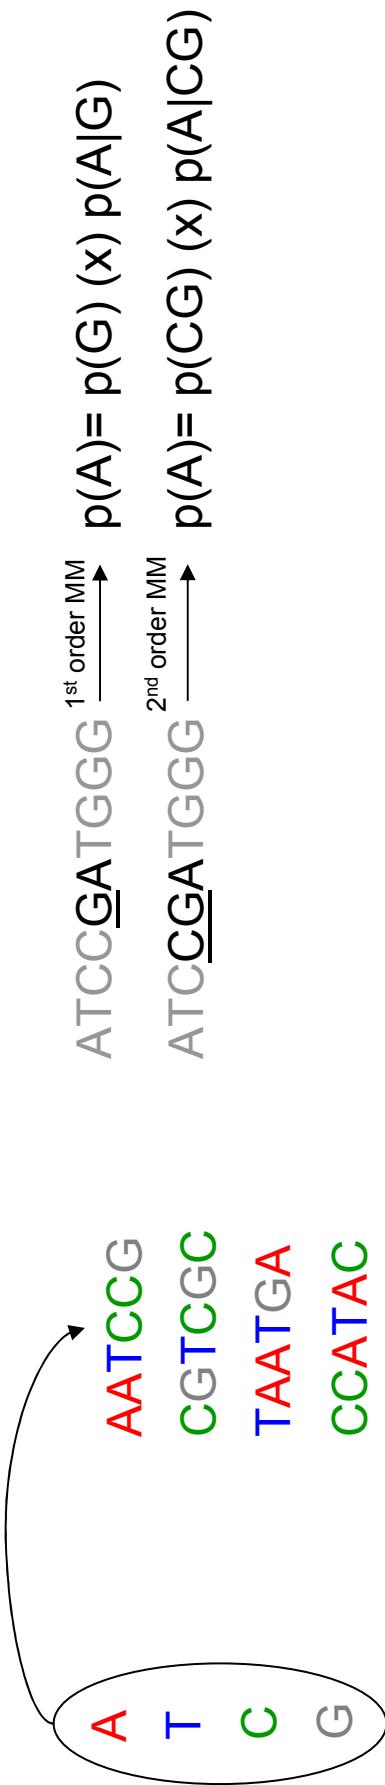
$$|B|^5 = 1024$$

$$|B|^6 = 4096$$

$$|B|^7 = 16384$$

$$|B|^8 = 65536$$

# Noukλεστιδική Σύσταση DNA



$B^1 = \{A, T, C, G\}$   
 $B^2 = \{AA, AT, AC, AG, TA, TT, TC, TG, CA, CT, CC, CG, GA, GT, GC, GG\}$   
 $B^3 = \{AAA, AAT, AAC, AAG, \dots, GGA, GGT, GGC, GGG\}$   
 $B^k = \{\dots\}$

$ B ^1 = 4$
$ B ^2 = 16$
$ B ^3 = 64$
$ B ^4 = 256$
$ B ^5 = 1024$
$ B ^6 = 4096$
$ B ^7 = 16384$
$ B ^8 = 65536$

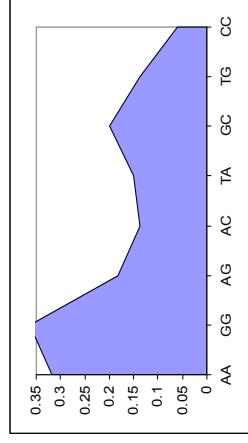
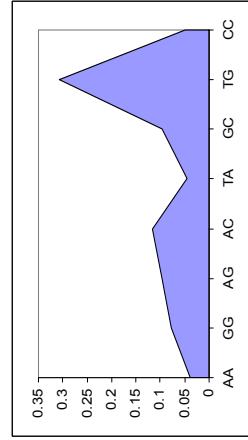
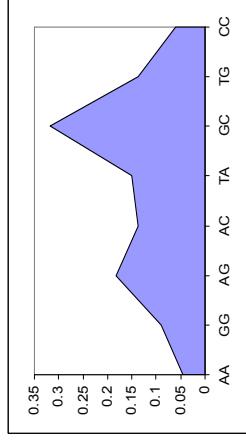
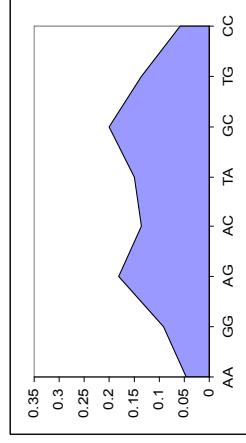
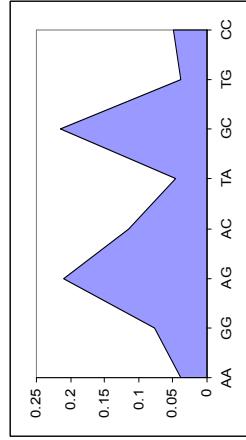
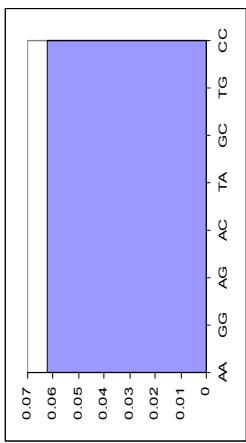
# Codon Usage

*Salmonella enterica subsp. enterica serovar Typhi str. CT18 [gb|bct]: 368 CDS's (89135 codons)*

fields: [triplet] [amino acid] [fraction] [frequency: per thousand] ([number])

UUU	F	0.51	20.3	(	1811)	UCU	S	0.17	11.7	(	1043)	UAU	Y	0.51	16.2	(	1440)	UGU	C	0.43	5.5	(	491)
UUC	F	0.49	19.7	(	1759)	UCC	S	0.15	10.8	(	964)	UAC	Y	0.49	15.7	(	1399)	UGC	C	0.57	7.3	(	648)
UUA	L	0.11	10.7	(	954)	UCA	S	0.19	13.3	(	1186)	UAA	*	0.50	2.1	(	184)	UGA	*	0.38	1.6	(	140)
UUG	L	0.13	12.5	(	1114)	UCG	S	0.13	9.5	(	844)	UAG	*	0.12	0.5	(	44)	UGG	W	1.00	12.4	(	1105)
<b>CUU</b>	I	0.16	15.2	(	1356)	CCU	P	0.24	9.5	(	849)	CAU	H	0.53	11.2	(	994)	GGU	R	0.26	14.7	(	1310)
<b>CUC</b>	I	0.14	12.8	(	1144)	CCC	P	0.15	6.0	(	533)	CAC	H	0.47	9.7	(	865)	GGC	R	0.31	17.1	(	1523)
<b>CUA</b>	I	0.06	5.4	(	483)	CCA	P	0.25	9.9	(	880)	CAA	Q	0.33	12.4	(	1105)	GGA	R	0.12	6.7	(	598)
<b>CUG</b>	I	0.39	36.6	(	3263)	CCG	P	0.37	14.8	(	1316)	CAG	Q	0.67	25.0	(	2230)	GGG	R	0.14	7.8	(	696)
AUU	I	0.43	24.8	(	2212)	<b>AQU</b>	T	0.23	13.1	(	1171)	AAU	N	0.48	21.4	(	1910)	AGU	S	0.15	10.7	(	951)
AUC	I	0.43	24.5	(	2182)	<b>ACC</b>	T	0.31	17.8	(	1591)	AAC	N	0.52	23.1	(	2060)	AGC	S	0.21	15.0	(	1333)
AUA	I	0.14	8.0	(	713)	<b>ACA</b>	T	0.21	12.1	(	1078)	AAA	K	0.59	34.5	(	3074)	AGA	R	0.10	5.6	(	503)
<b>AUG</b>	M	1.00	27.4	(	2438)	<b>ACG</b>	T	0.26	15.2	(	1351)	AAG	K	0.41	23.7	(	2116)	GGG	R	0.07	4.1	(	363)
GUU	V	0.31	20.7	(	1847)	GCU	A	0.22	18.1	(	1613)	GAU	D	0.56	31.1	(	2772)	GGU	G	0.29	18.2	(	1625)
GUC	V	0.24	16.2	(	1447)	GCC	A	0.28	23.1	(	2062)	GAC	D	0.44	24.8	(	2214)	GGC	G	0.35	22.6	(	2012)
GUA	V	0.17	11.6	(	1033)	GCA	A	0.25	20.3	(	1813)	GAA	E	0.57	37.7	(	3356)	GGA	G	0.17	11.0	(	982)
GUG	V	0.28	18.6	(	1657)	GCG	A	0.25	20.5	(	1828)	GAG	E	0.43	28.0	(	2497)	GGG	G	0.19	11.9	(	1060)

# *Compositional Distributions*



# G+C% content

- ✓ Έυρος: 25-75%: 72.1% *Streptomyces coelicolor*, 26.5% *Wigglesworthia glossinidia*
- ✓ Βακτήρια του εδάφους: 49%, υποχρεωτικά παράσιτα: 38%
- ✓ GTP και CTP: ενεργειακά πιο δαπανηρά από ATP και UTP
- ✓ Κεντρικός ρόλος ATP μεταβολισμό: μεγαλύτερη διαθεσιμότητα
- ✓ Περιορισμένη διαθεσιμότητα θρεπτικών: υψηλό AT
- ✓ Επιδιόρθωση DNA: μικρά γονιδιώματα – συσσώρευση μεταλλάξεων
- ✓ Η πιο συχνή μετάλλαξη: C → T ( $G \rightarrow A$ )

# **G+C% content**

**GC content καταμήκος του γονιδιώματος δεν ακολουθεί ομοιόμορφη κατανομή:**

1. Μικρό μέγεθος γονιδιώματος, πλούσιο σε AT:
  - a. Μεταξύ γονιδίων (intergenic)
  - b. Μη κωδικές περιοχές (non-coding)
  - c. 3<sup>η</sup> θέση μέσα στο κωδικόν (3<sup>rd</sup> codon position)
- d. Ακολουθίες υποκινητών πριν από τα γονίδια (υπερελίκωση, ξεδιπλώνεται πιο εύκολα)
- e. Μερικές εκαποντάδες βάσεις γύρω από την περιοχή της έναρξης της αντιγραφής του DNA (origin of replication)

# **G+C% content**

**GC content κατανήκος του γονιδίωματος δεν ακολουθεί ομοιόμορφη κατανομή:**

2. Σε επίπεδο ολόκληρου γονιδίωματος: Μικρή προπίεση για GC προς την έναρξη και ΑΤπρος την λήξη πης αντιγραφής του DNA. Αυτό μπορεί να οφείλεται σε δομικούς περιορισμούς του μορίου του DNA ή στη φυσική και λειτουργική διαμερισματοποίηση του χρωμοσώματος.
3. Λόγω εκφυλισμού του γενετικού κώδικα, πρότιμη για AT στην 3η θέση του κωδικονιου είναι λιγότερο πιθανό να οδηγήσει σε αλλαγή του αμινοξέος που κωδικοποιεί

# **G+C% content**

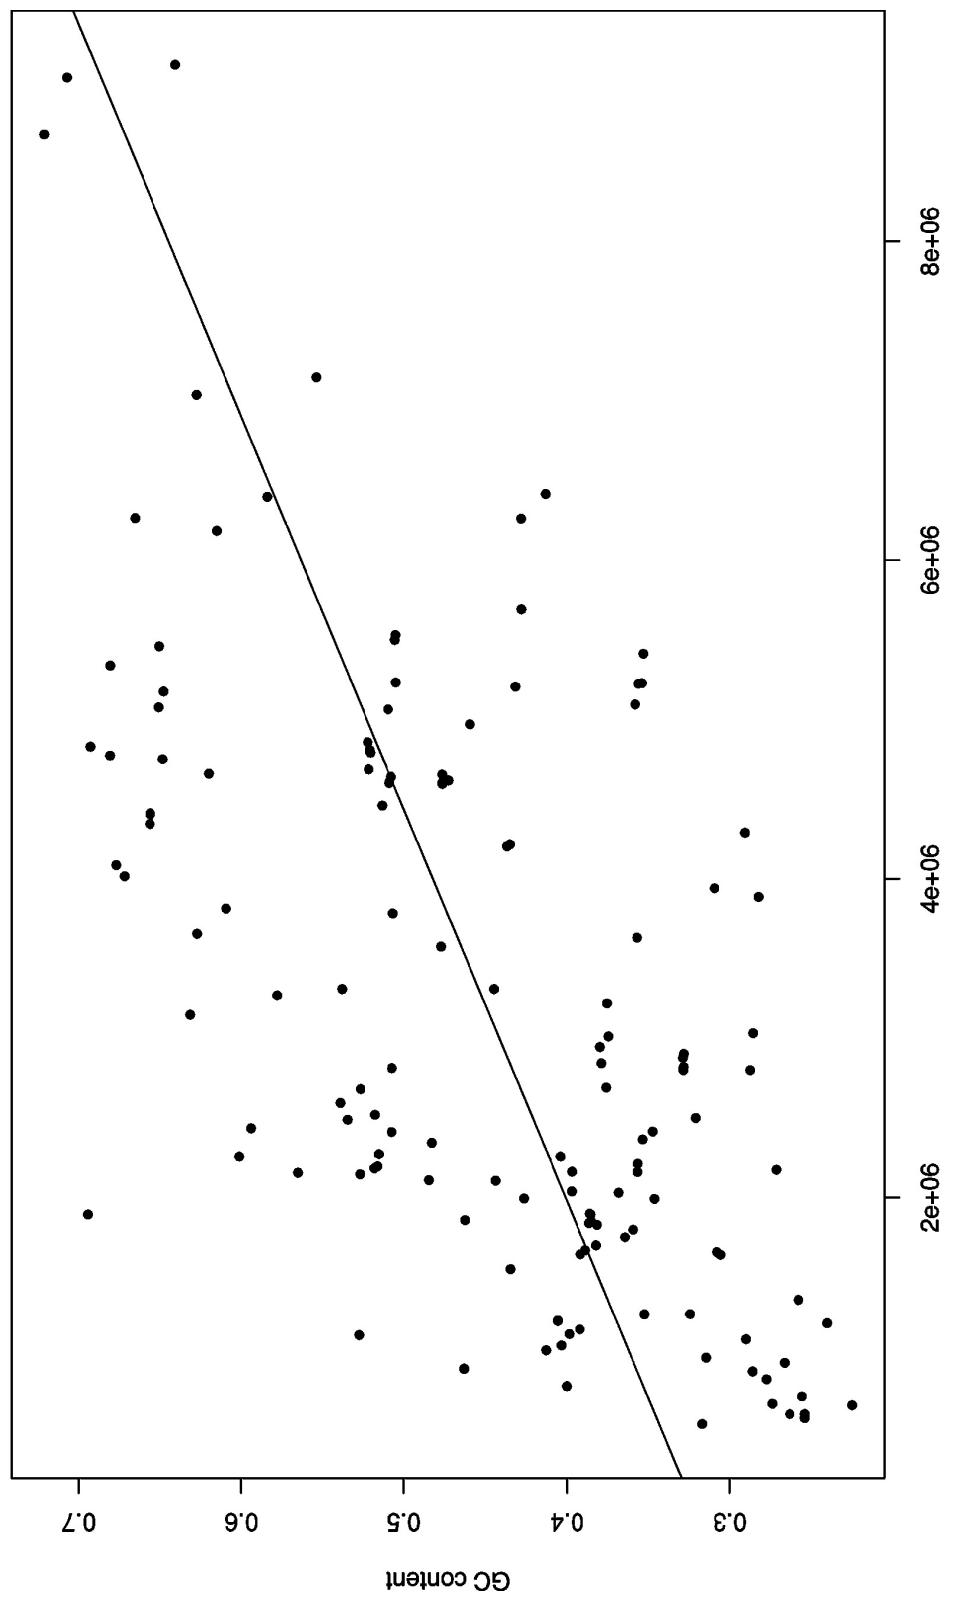
GC content καταμήκος του γονιδιώματος δεν ακολουθεί ομοιόμορφη κατανομή:

4. G-C/G + C στην + και την – αλυσίδα του DNA (GC skew). Στους προκαρυωτικούς υπάρχει προτίμηση για G και όχι για C στην + αλυσίδα του DNA που δημιουργεί ένα διφασικό πρότυπο κατά μήκος του γονιδιώματος το οποίο είναι χρήσιμο για τον εντοπισμό του σημείου της έναρξης και της λήξης της αντιγραφής του DNA.

# G+C% content

(D)

G+C content versus Genome Length (n=146)



Genome Length

8e+06

6e+06

4e+06

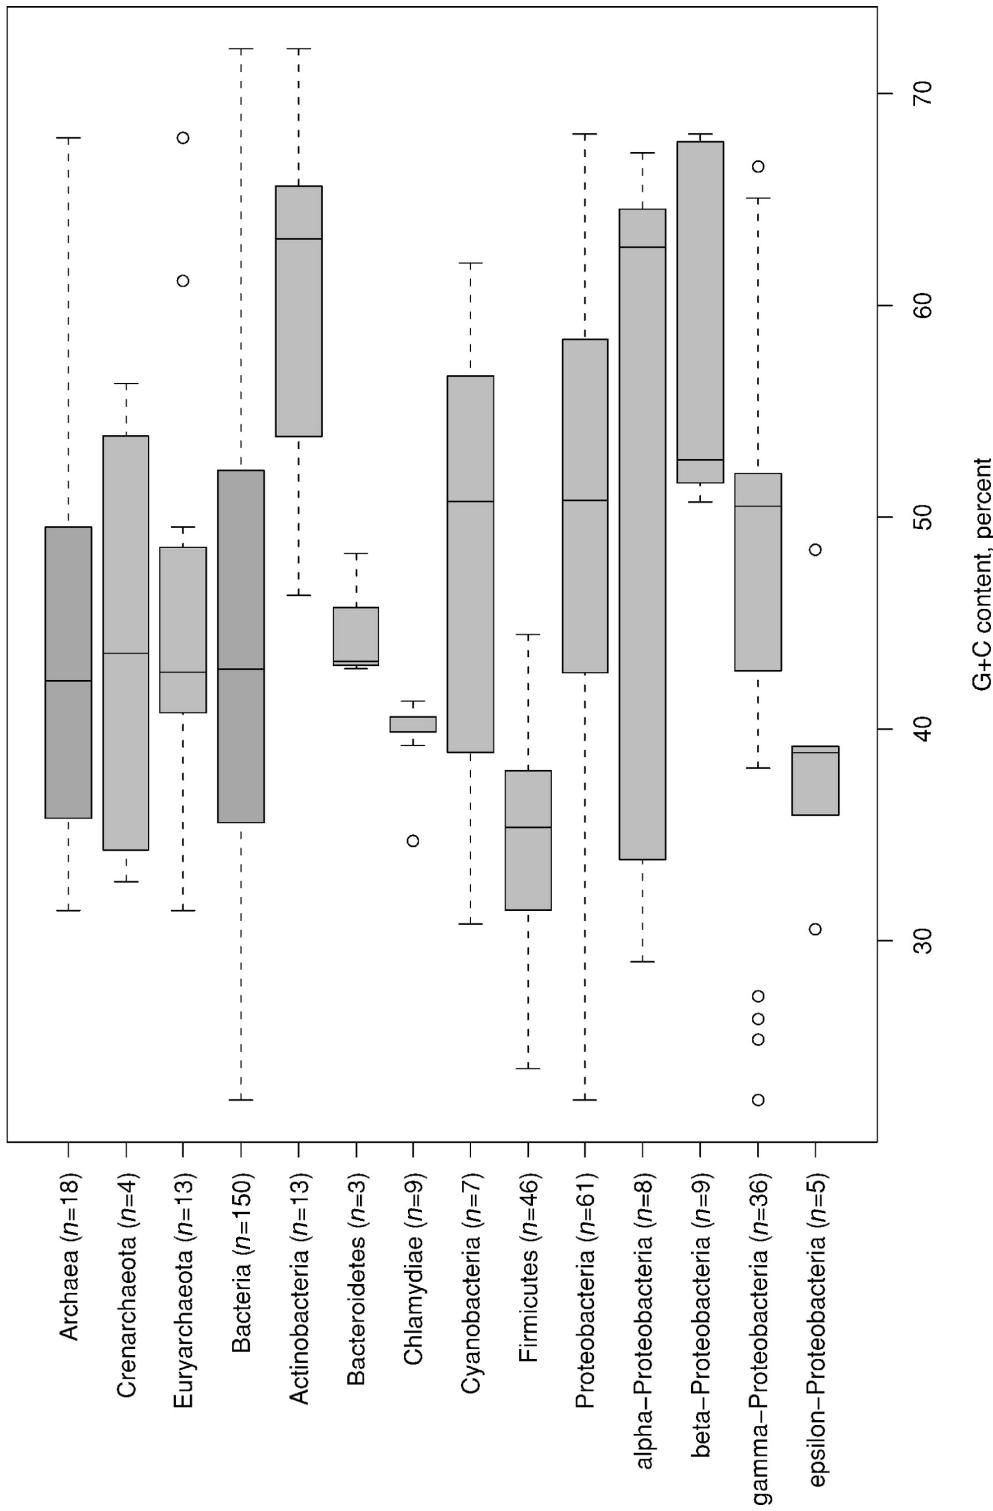
2e+06

Bentley 2004

# G+C% content

(C)

G+C content of sequenced prokaryotic genomes

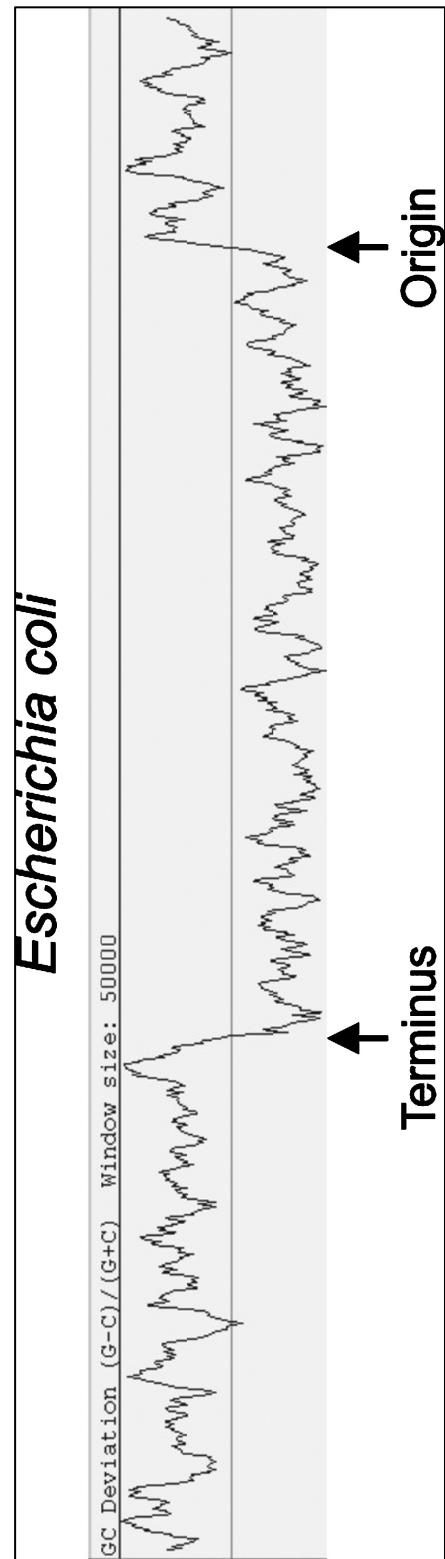


Bentley 2004

## G+C content ~ phylogeny

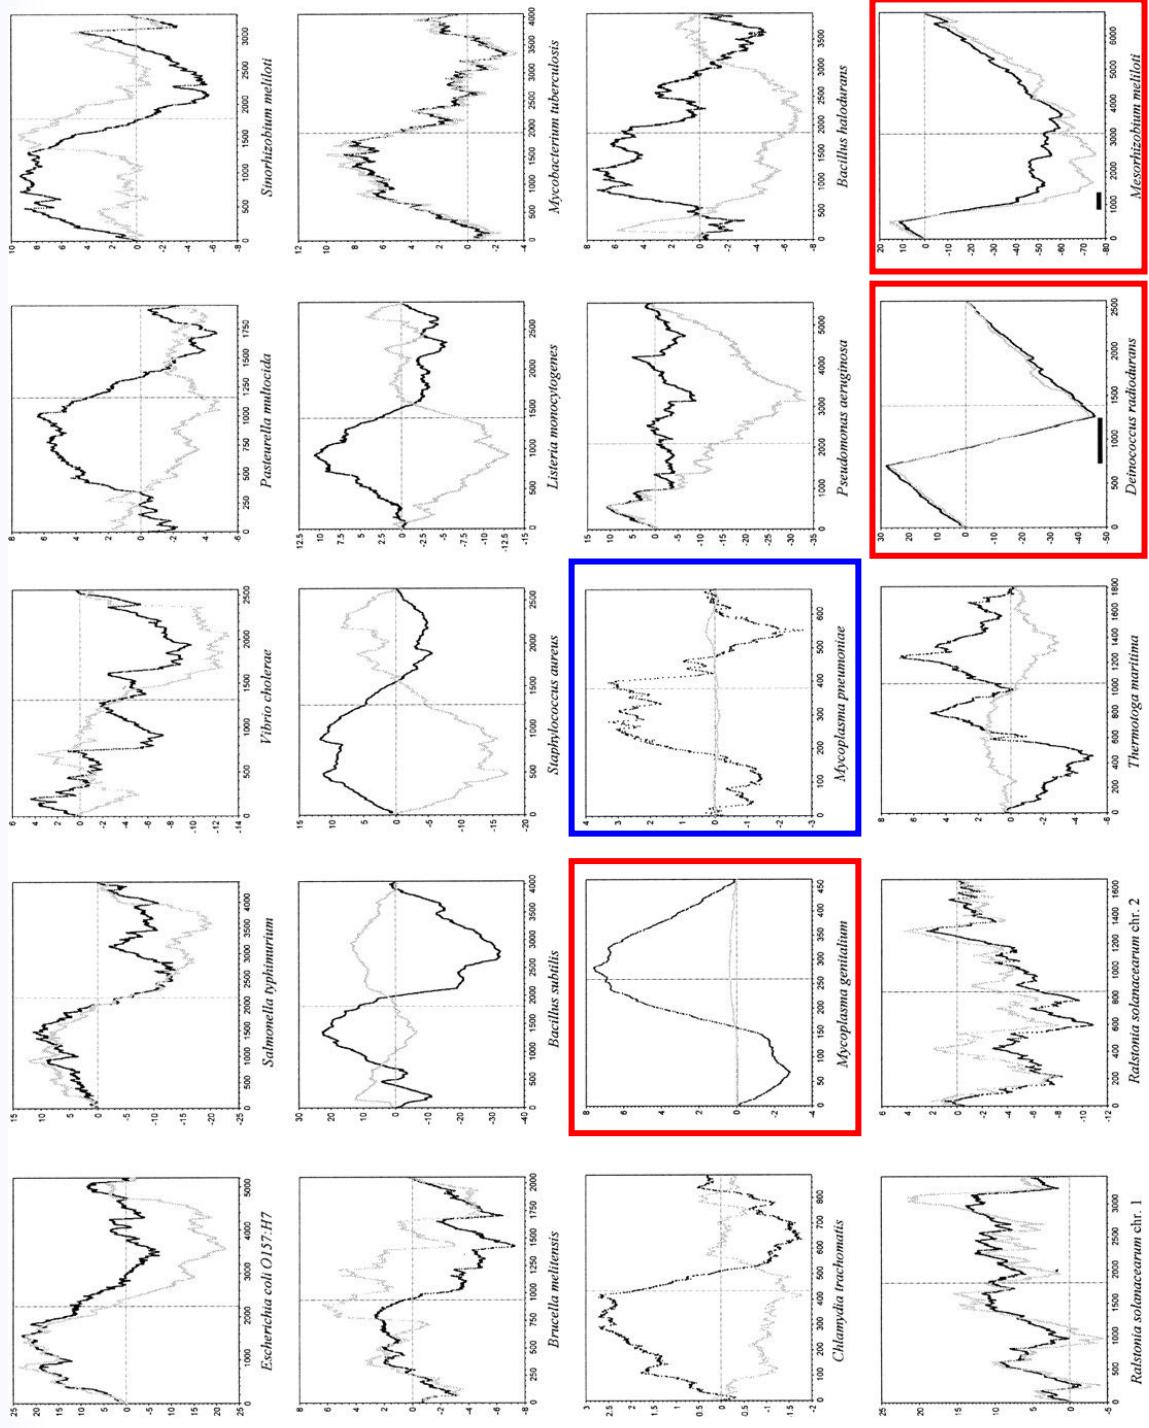
- ✓ *E. coli*: 50%
- ✓ *Shigella*: 51%
- ✓ *Salmonella*: 52%
- ✓ *Staphylococcus*: 33%
- ✓ *Streptococcus*: 38%

# G+C% content



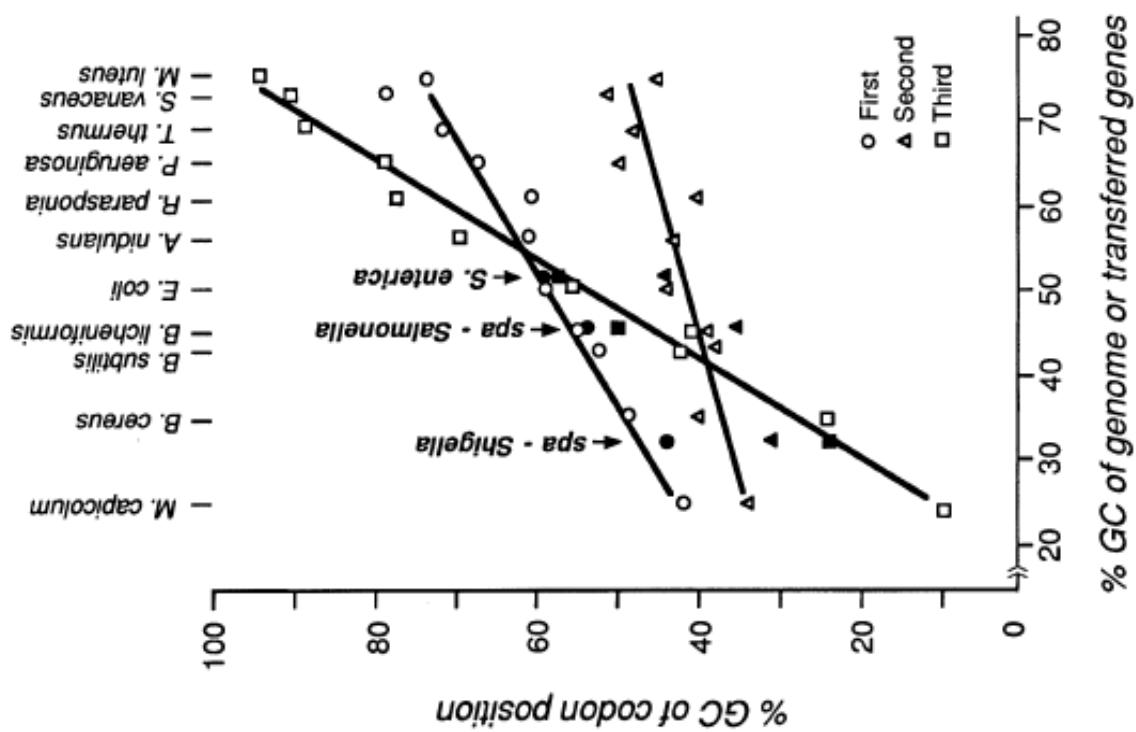
Bentley 2004

# G+C<sub>3</sub> & CAI



Cumulative G+C<sub>3</sub>  
(black curve) and CAI  
(gray curve)

Daubin 2003



# G+C<sub>1,2,3</sub> vs G+C

# Μέγεθος Γονιδιώματος

1. Εύρος: 12X
2. Επικάλυψη: Μεγάλοι ιοί - βακτήρια- μικροί ευκαρυωτικοί
3. Μεγάλο εύρος διακύμανσης ακόμα και μέσα στο ίδιο είδος:  
*Escherichia coli, Prochlorococcus marinus, και Streptomyces coelicolor*  
ποικίλουν ~ 1,000,000 bp

# Μέγεθος Γονιδιώματος

4. Μωσαϊκά πολλαπλών γενετικών γεγονότων: διπλασιασμός γονιδίων (gene duplication), οριζόντια μεταφορά (horizontal acquisition), απώλεια γονιδίων (gene loss), (ανασυνδιασμός) recombination -> καλός δείκτης της εξελικτικής μονάδας (evolutionary lineage)
5. minimal και maximal γονιδιώματα
6. Συσχετίζεται με:  
χρόνο διαίρεσης του κυττάρου, ρυθμό αντιγραφής DNA, διαθεσιμότητα ενέργειας, φυσικός χώρος μέσα στο κύτταρο

# Μέγεθος Γονιδιώματος

7. Οικοσυστήματα σταθερών συνθηκών: μικρά γονιδιώματα
8. Οικοσυστήματα μεταβλητών συνθηκών: μεγάλα γονιδιώματα
9. 0,5Mb Nanoarchaeum equitans
10. 9Mb Bradyrhizobium japonicum
11. Κωδική πυκνότητα (coding density): 1 γονιδιο/kb. Μεγαλύτερα γονιδιώματα → περισσότερα γονίδια (δεν ισχύει για ευκαρυωτικούς)

# Μέγεθος Γονιδιώματος

12. Περισσότερες οικογένειες πρωτεινών ή περισσότερα μέλη σε υπάρχουσες οικογένειες?
13. Ανεξαρτήτου μεγέθους:  
μετάφραση, δομή ριβοσάματος, και βιογένεση πρωτεινών
14. Εξαρτώμενο από το μέγεθος:  
Κυτταρικός μεταβολισμός (γραμμικά)  
Ρύθμιση γονιδιακής έκφρασης (μη-γραμμικά)

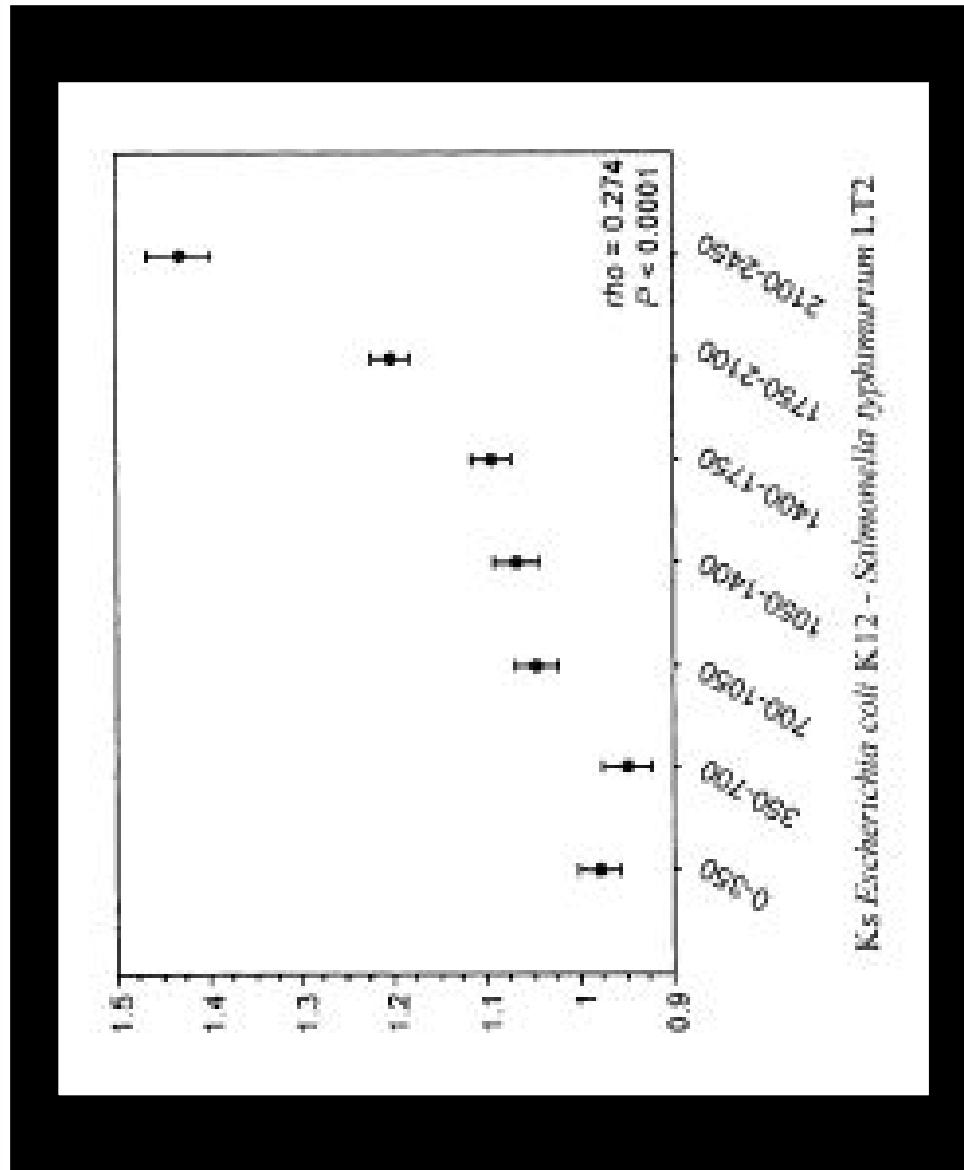
# Τοπολογία γονιδίων

1. Τοπολογία στη φορά της αντιγραφής του DNA, μεταγραφόμενα μακριά από το σημείο της έναρξης της αντιγραφής
2. Ελαχιστοποιηση του αριθμού των συγκρούσεων μεταξύ των συμπλόκων αντιγραφής και μεταγραφής καθώς αυτά κινούνται καταψήκος του DNA. Τέτοιες συγκρούσεις σταματούν την αντιγραφή και διακόπτουν ή ακυρώνουν τη μεταγραφή

# Τοπολογία γονιδίων

3. Συσχετίζεται με τα επίπεδα έκφρασης έτσι ώστε γονίδια με υψηλά επίπεδα έκφρασης να είναι τοποθετημένα στην οδηγό αλυσίδα του DNA το οποίο συμφωνεί με την συστηματική παρουσία του rDNA και των οπερονίων των ριβοσωμάτων πρωτεινών στην ίδια αλυσίδα
4. (Πιο πρόσφατα) πιθανά η τοπολογία να συσχετίζεται με το εάν τα γονίδια είναι βασικά ή βιοηθητικά. Η πλειοψηφία των πρώτων βρίσκεται μακριά από το σημείο έναρξης της αντιγραφής (σχετίζεται πιθανό με την τοξικότητα των κουτσουρεμένων προϊόντων μετάφρασης των βασικών γονιδίων σε περίπτωση λάθους)
5. Γονίδια κοντά στο σημείο λήξης της αντιγραφής (αυηλό AT) εξελίσσονται πιο γρήγορα, ενώ γονίδια στο σημείο έναρξης είναι πιο συντηρημένα μεταξύ των ειδών

*Τοπολογία γονιδίων*



Daubin 2003 Bentley 2004

Δείκτες	Περιγραφή
Codon Adaptation Index (CAI)	Ποσοτικοποιεί την σχετική προσαρμοστικότητα της χρήσης κωδικονίων προς την χρήση κωδικονίων που απαντούν σε γονίδια με υψηλά επίπεδα έκφρασης
Frequency of Optimal codons (Op)	Ο λόγος των άριστων προς τα συνώνυμα κωδικονία
Codon Bias Index (CBI)	Ποσοτικοποιεί τον βαθμό στον οποίο ένα γονίδιο χρησιμοποιεί ένα σετ από άριστα κωδικονία
Effective number of codons (NC)	Ποσοτικοποιεί το πόσο μακριά βρίσκεται η χρήση κωδικονίων από την ομοιόμορφη χρήση συνώνυμων κωδικονίων. Ένα γονίδιο με ένα κωδικόνιο για κάθε αμινοξύ έχει τη μεγαλύτερη πόλωση και την μικρότερη πημή (20) αυτού του δείκτη. Γονίδιο με ομοιόμορφη χρήση κωδικονίων έχει πημή 61.
GC content	Ποσοτικοποιεί τη συχνότητα γουανίνης ή κυτοσινής
GC <sub>1</sub> and GC <sub>3</sub> content	Ποσοτικοποιεί τη συχνότητα γουανίνης ή κυτοσινής στην 1 <sup>η</sup> και 3 <sup>η</sup> θέση του κωδικονίου
δ* difference	Είναι η μέση, απόλυτη διαφορά της σχετικής αφθονίας των δινουκλεοτίδων μεταξύ δύο ακολουθιών. Υπολογίζεται από τη συχνότητα των δινουκλεοτίδων ομαλοποιημένη με το γνόμενο της συχνότητας των μονο-γουκλεοτίδων που απαρτίζουνται
Codon usage contrasts	Συγκρίνει πολώνσεις (biases) στη χρήση κωδικονίων ενός γονιδίου με τη μέση πόλωση
Amino acid contrasts	Συγκρίνει πολώνσεις στη χρήση αμινοξέων μιας πρωτεΐνης με τη μέση πόλωση
High order motifs	Συγκρίνει τη συχνότητα «λέξεων» μετέθουσις κενός κυλιόμενου παραθύρου με την αντίστοιχη συχνότητα τους μετα σε ολόκληρο το γονιδίωμα
Translational efficiency (P2)	Το ποσοστό των κωδικονίων που συμμορφώνονται με την ενδιαμεση ενέργεια αλληλεπιδρασης κωδικωνιών-αντικωδικονιών με βάση τον κανόνα Grosjean και Fiers.
Intrinsic codon bias index (ICDI)	Εκτιμάει πολώνσεις στη χρήση κωδικονίων για γονίδια που ανήκουν σε γονίδιαμετα που δεν γνωρίζουμε τα άριστα κωδικόνια. Σχετίζεται πολύ με το CBI, NC
Scaled Chi-square	Ποσοτικοποιεί το μέγεθος της παραπρούμενης πόλωσης από την ομοιόμορφη χρήση συνώνυμων κωδικονίων, χρησιμοποιώντας ως εκτιμήσεις την ομοιόμορφη χρήση. Το αποτέλεσμα ομαλοποιείται διαφράντας με τον αριθμό των κωδικονίων ενός γονίδιου

# ΔΙΚΤΕΣ ΒΟΥΚΥΖΟΤΙΩΝΤΑΣ

# **$\delta^*$ , codon usage and aminoacid contrasts**

$$\left\{ \rho_{xy}^* = f_{xy}^* / f_x^* f_y^* \right\} \quad (1)$$

$$\delta^*(f,g) = \frac{1}{16} \sum | \rho_{xy}^*(f) - \rho_{xy}^*(g) | \quad (2)$$

$$\sum_{(x,y,z)=a} g(x,y,z) = 1 \quad (3)$$

$$B(F/G) = \sum_a p_a(F) \left[ \sum_{(x,y,z)=a} | f(x,y,z) - g(x,y,z) | \right] \quad (4)$$

$$A(F/G) = (1/20) \sum_{i=1}^{20} | a_i(F) - a_i(G) | \quad (5)$$

# Codon Adaptation Index

$$w_{aa,i}(G) = \frac{f_{aa,i}(G)}{f_{aa,\max}(G)} \quad (1)$$

The **relative adaptiveness** of a codon is defined as its frequency relative to the most often used synonymous codon, where  $\mathcal{G}$  is a set of highly expressed genes. ( $0 \leq w \leq 1$ )

$$CAI_g = \prod_{i=1}^N w_i^{1/N} \quad (2)$$

The **CAI** of a gene  $g$  is then simply the geometric average of the relative adaptiveness of all codons in a gene sequence.

$$CAI_g = \prod_{k=1}^{61} w_k^{X_{k,g}} \quad (3)$$

$$X_{k,g} = \frac{C_{k,g}}{\sum_{i=1}^{61} C_{i,g}} \quad (4)$$

## Effective Number of Codons

$$\hat{f} = \frac{\left( n \sum_{i=1}^k p_i^2 \right) - 1}{n - 1} \quad (1)$$

$$\hat{Nc} = \frac{1}{\hat{F}_{aa}} \quad (2)$$

*Codon homozygosity:* between 20 and 61 and tells to what degree the codon usage in a gene is biased, i.e., it approaches 20 codons for the **extremely biased** genes, and approaches 61 for the genes where **all possible codons are used** with no preference.

$$\hat{Nc} = 2 + \frac{9}{\hat{F}_2} + \frac{1}{\hat{F}_3} + \frac{5}{\hat{F}_4} + \frac{3}{\hat{F}_6} \quad (3)$$

where **F2** is the average homozygosity for the amino acids having a degeneracy of **two** (histidine, glutamine, etc.) and so on.

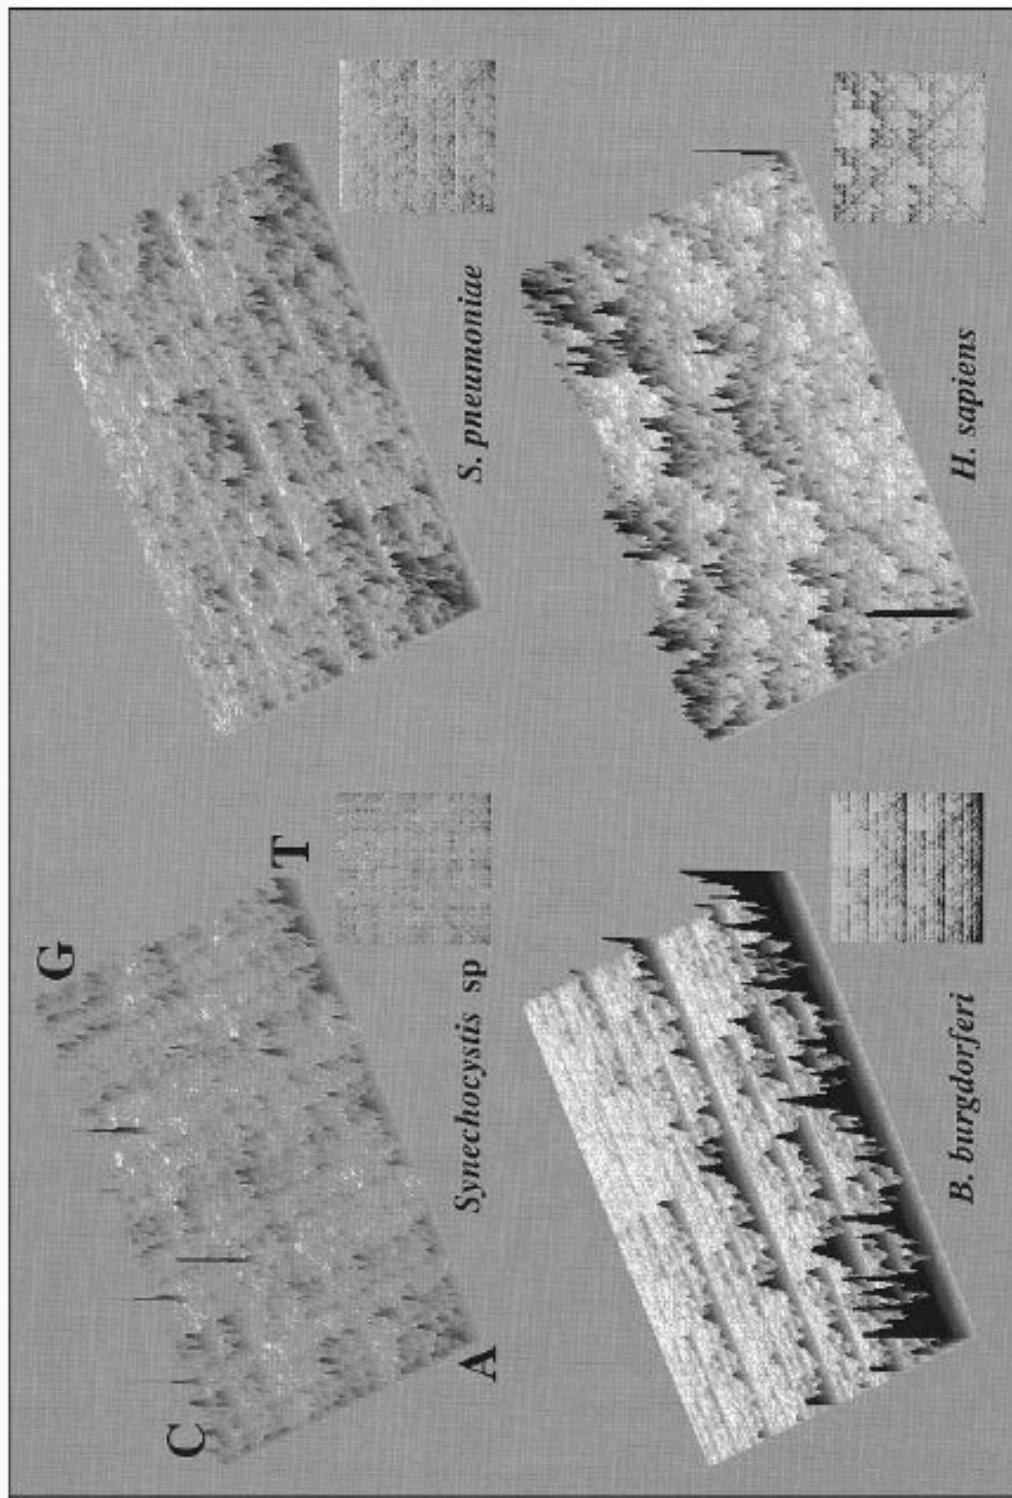
# Effective Number of Codons

*Salmonella enterica subsp. enterica serovar Typhi str. CT18 [gb|bct]: 368 CDS's (89135 codons)*

fields: [triplet] [amino acid] [fraction] [frequency: per thousand] ([number])

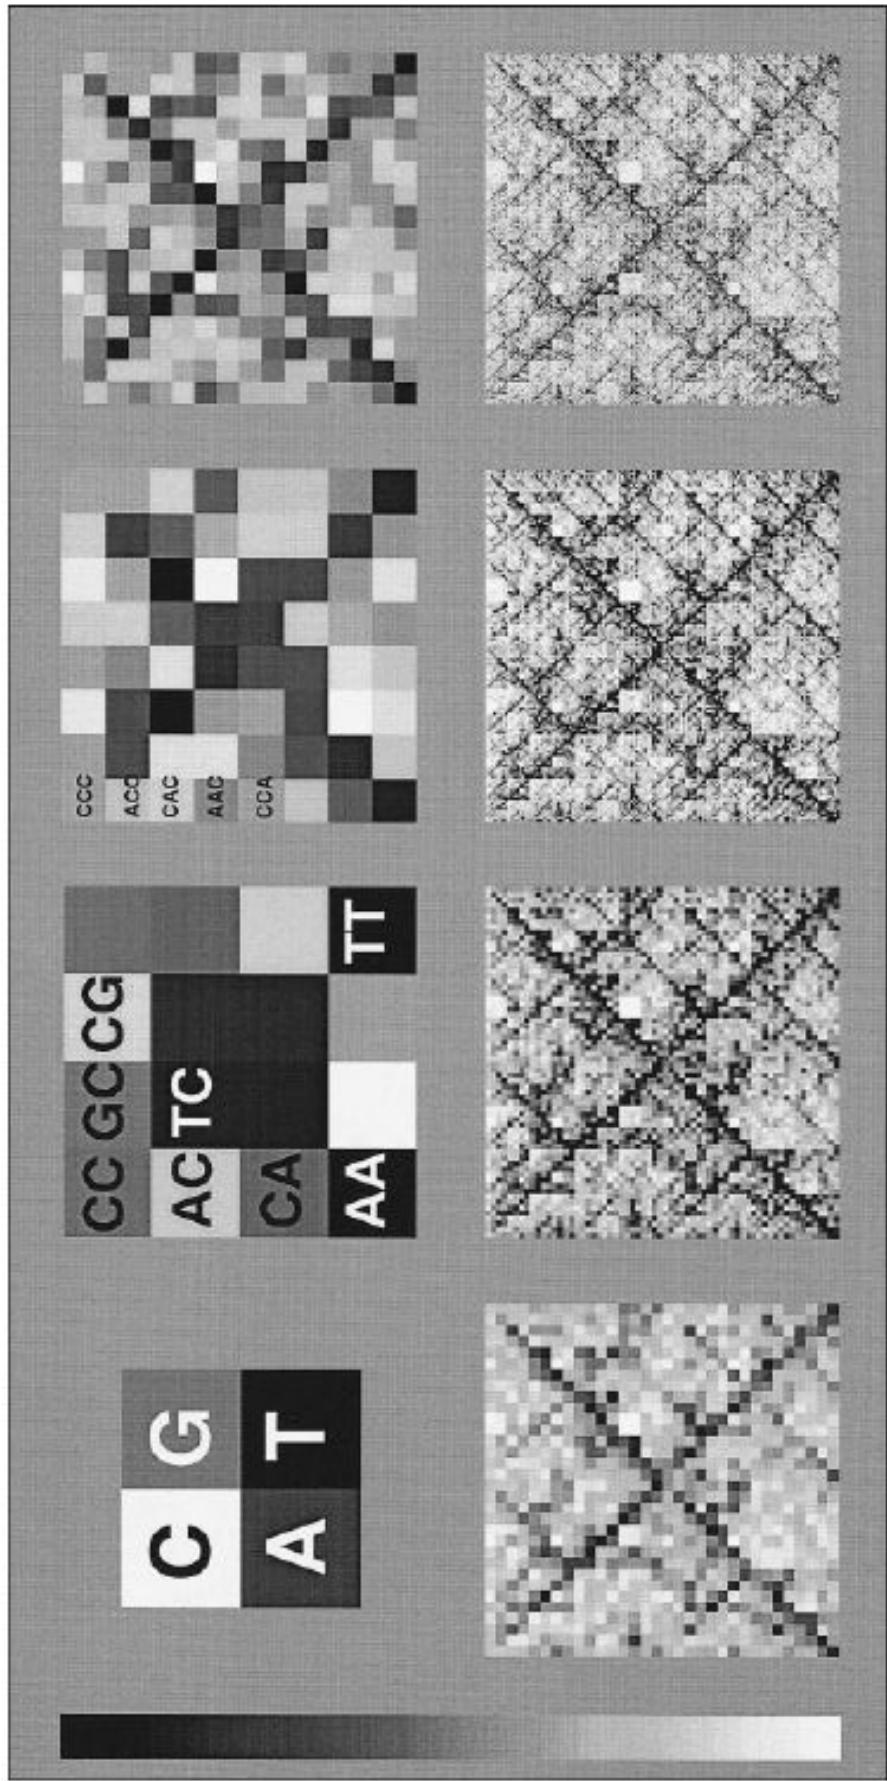
UUU F 0.51 20.3 (	1811)	UCU S 0.17 11.7 (	1043)	UAU Y 0.51 16.2 (	1440)	UGU C 0.43 5.5 (	491)
UUC F 0.49 19.7 (	1759)	UCC S 0.15 10.8 (	964)	UAC Y 0.49 15.7 (	1399)	UGC C 0.57 7.3 (	648)
UUA L 0.11 10.7 (	954)	UCA S 0.19 13.3 (	1186)	UAA * 0.50 2.1 (	184)	UGA * 0.38 1.6 (	140)
UUG L 0.13 12.5 (	1114)	UCG S 0.13 9.5 (	844)	UAG * 0.12 0.5 (	44)	UGG W 1.00 12.4 (	1105)
CUU L 0.16 15.2 (	1356)	CCU P 0.24 9.5 (	849)	CAU H 0.53 11.2 (	994)	CGU R 0.26 14.7 (	1310)
CUC L 0.14 12.8 (	1144)	CCC P 0.15 6.0 (	533)	CAC H 0.47 9.7 (	865)	CGC R 0.31 17.1 (	1523)
CUA L 0.06 5.4 (	483)	CCA P 0.25 9.9 (	880)	CAA Q 0.33 12.4 (	1105)	CGA R 0.12 6.7 (	598)
CUG L 0.39 36.6 (	3263)	CCG P 0.37 14.8 (	1316)	CAG Q 0.67 25.0 (	2230)	CGG R 0.14 7.8 (	696)
AUU I 0.43 24.8 (	2212)	ACU T 0.23 13.1 (	1171)	AAU N 0.48 21.4 (	1910)	AGU S 0.15 10.7 (	951)
AUC I 0.43 24.5 (	2182)	ACC T 0.31 17.8 (	1591)	AAC N 0.52 23.1 (	2060)	AGC S 0.21 15.0 (	1333)
AUA I 0.14 8.0 (	713)	ACA T 0.21 12.1 (	1078)	AAA K 0.59 34.5 (	3074)	AGA R 0.10 5.6 (	503)
AUG M 1.00 27.4 (	2438)	ACG T 0.26 15.2 (	1351)	AAG K 0.41 23.7 (	2116)	AGG R 0.07 4.1 (	363)
GUU V 0.31 20.7 (	1847)	GCU A 0.22 18.1 (	1613)	GAU D 0.56 31.1 (	2772)	GGU G 0.29 18.2 (	1625)
GUC V 0.24 16.2 (	1447)	GCC A 0.28 23.1 (	2062)	GAC D 0.44 24.8 (	2214)	GGC G 0.35 22.6 (	2012)
GUA V 0.17 11.6 (	1033)	GCA A 0.25 20.3 (	1813)	GAA E 0.57 37.7 (	3356)	GGA G 0.17 11.0 (	982)
GUG V 0.28 18.6 (	1657)	GCG A 0.25 20.5 (	1828)	GAG E 0.43 28.0 (	2497)	GGG G 0.19 11.9 (	1060)

# *Chaos Game Representation*



Deschavanne 1999

# *Chaos Game Representation*



Deschavanne 1999

*Oι ακολουθίες DNA δεν είναι αυτό που βλέπουμε*

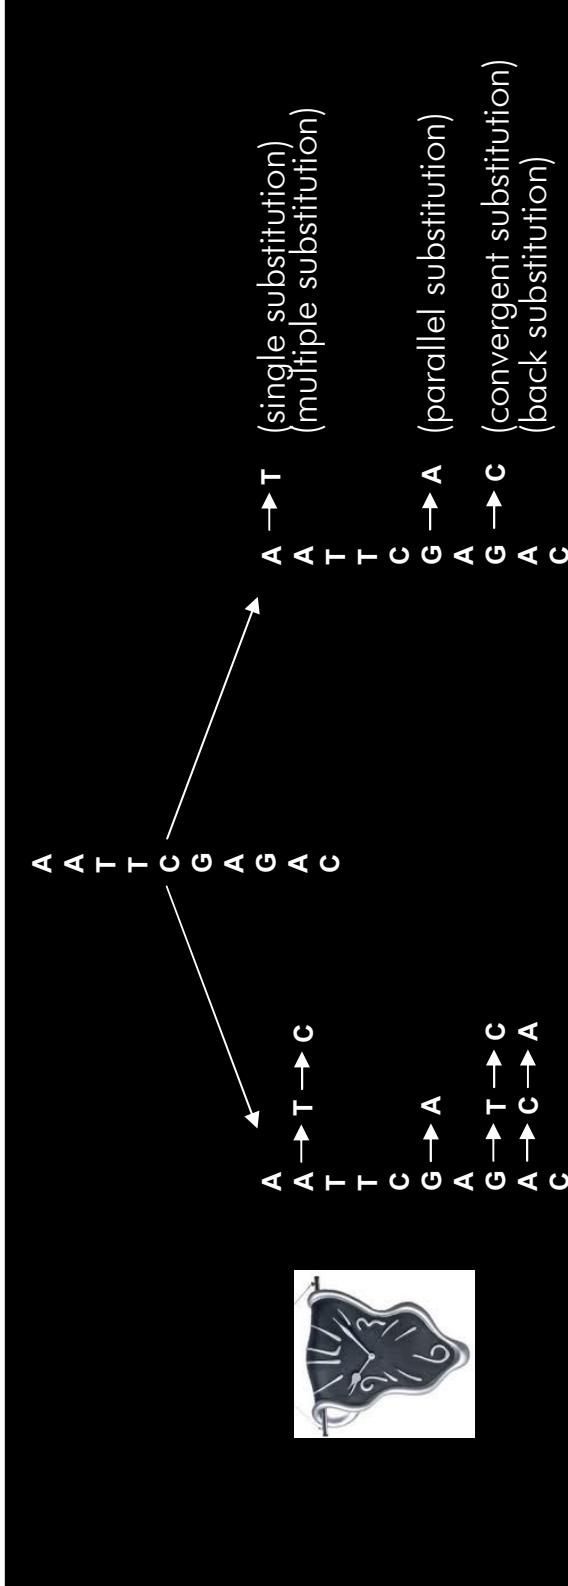
A A T T C G A G A C

*Oι ακολουθίες DNA δεν είναι αυτό που βλέπουμε*

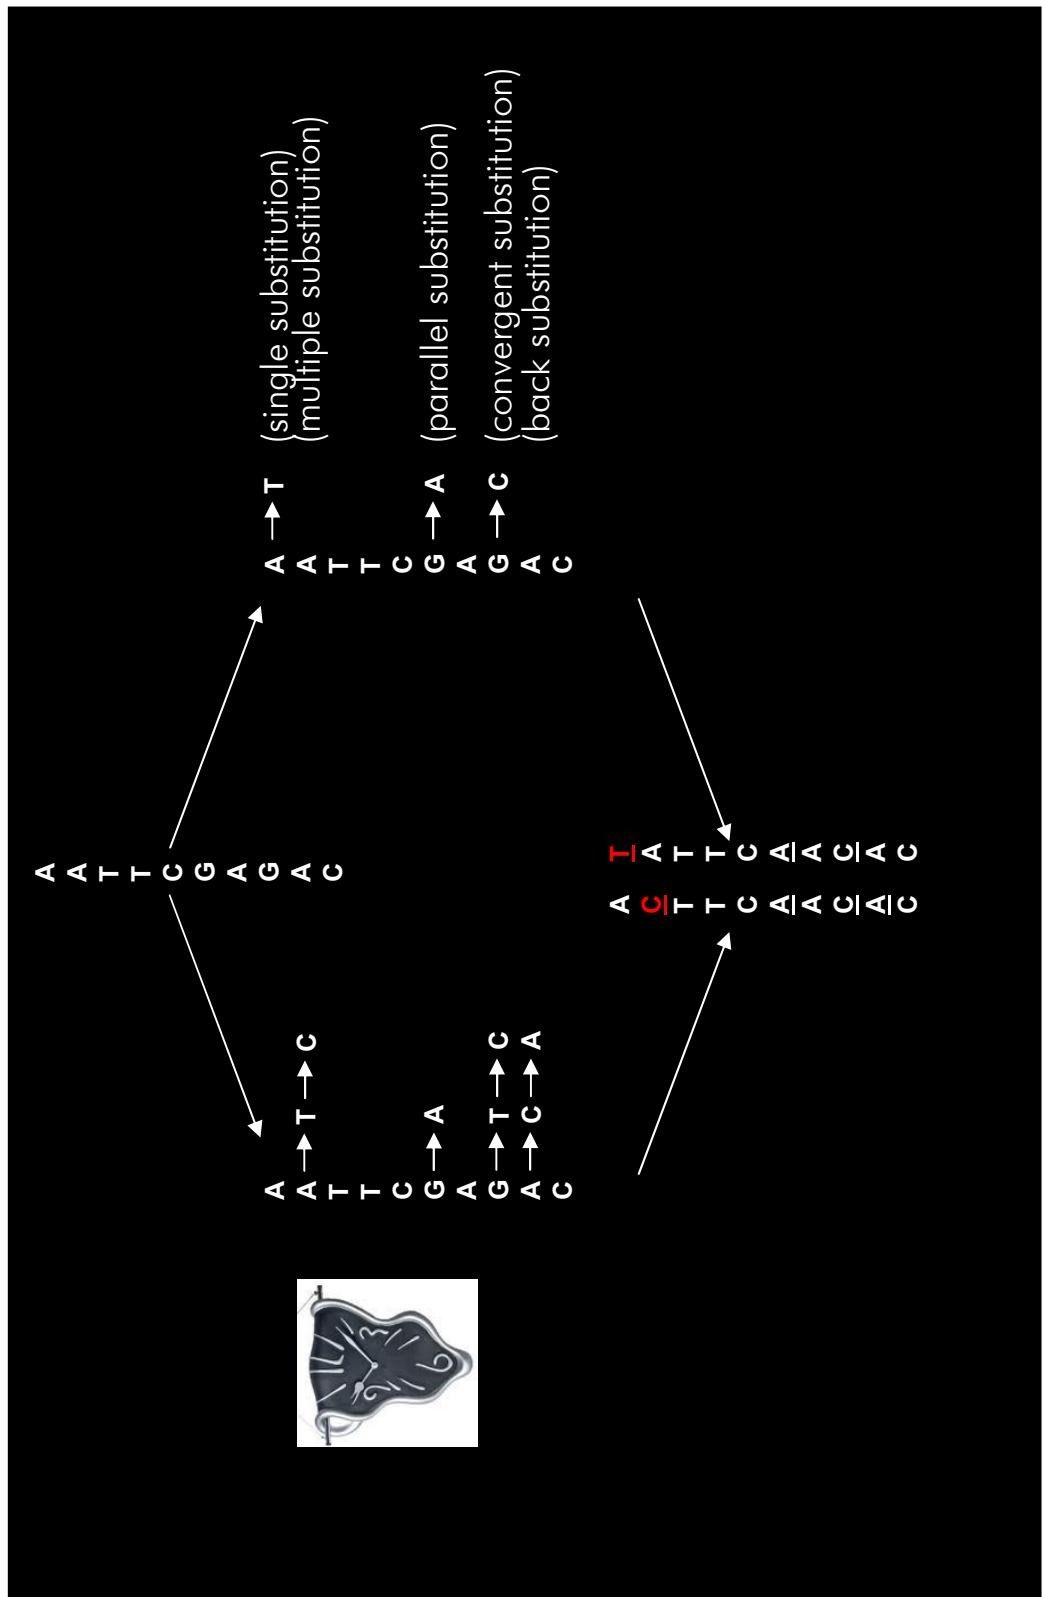
A A T T C G A G A C  
A A T T C G A G A C  
A A T T C G A G A C



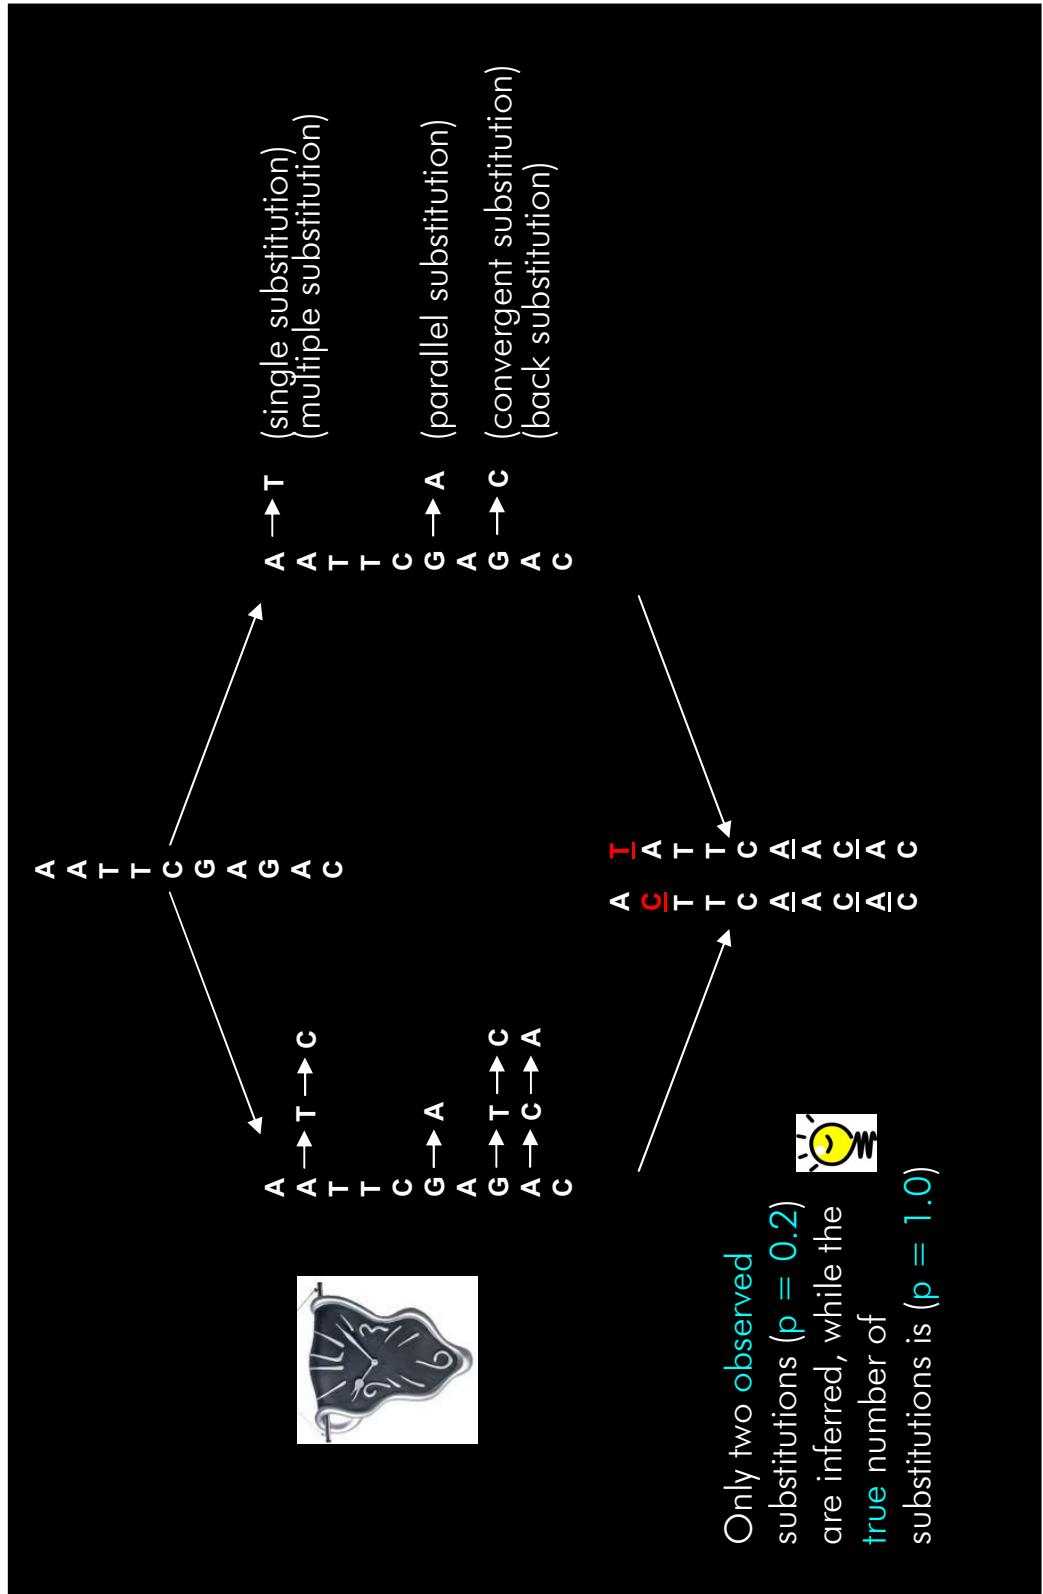
# Oι ακολουθίες DNA δεν είναι αυτό που βλέπουμε



# Oι ακολουθίες DNA δεν είναι αυτό που βλέπουμε



# Oι ακολουθίες DNA δεν είναι αυτό που βλέπουμε



# Μέγεθος αλφαριθμητου και συχνότητα εμφάνισης

k-mer	counts	$ 4 ^k$
GCCAGCGC	24	$4^8$
CCAGCGC	49	$4^7$
CAGCGC	116	$4^6$
AGCGC	238	$4^5$
GCGC	738	$4^4$
CGC	2452	$4^3$
GC	9784	$4^2$
C	33854	$4^1$

k-mer	counts	$ 4 ^k$
AAAACATG	1	$4^8$
AAACATG	6	$4^7$
AACATG	26	$4^6$
ACATG	81	$4^5$
CATG	474	$4^4$
ATG	2110	$4^3$
TG	9243	$4^2$
G	32499	$4^1$

## *Διαφορετικότητα*

**seq1:** G C C G C C C C G C G C G G

**seq2:** G C C G C C C G C C G C G C G G

## Διαφορετικότητα

**seq1:** **GCCCCGGGGGGG**

**seq2:** **GCCCCGGGGGGGG**

seq1

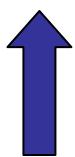
A	0
T	0
G	6
C	10

seq2

A	0
T	0
G	6
C	10

0<sup>th</sup> Order  
# states: 4

“typical”



## Διαφορετικότητα

**seq1:** GCCGCCGCCGGCGCG

**seq2:** GCCGCCGCCGGCGCG

seq1

A	0
T	0
G	6
C	10

0<sup>th</sup> Order  
# states: 4

seq2

A	0
T	0
G	6
C	10

1<sup>st</sup> order  
# states: 16

“typical”

GC	5
CC	5
CG	5

“typical”

# Διαφορετικότητα

**seq1:** **GCCCCGGGGGGGG**

**seq2:** **GCCCCGGGGGGGG**

**seq1**

A	0
T	0
G	6
C	10

0<sup>th</sup> Order  
# states: 4

**seq2**

A	0
T	0
G	6
C	10

“typical”

1<sup>st</sup> order  
# states: 16

GC	5
CC	5
CG	5

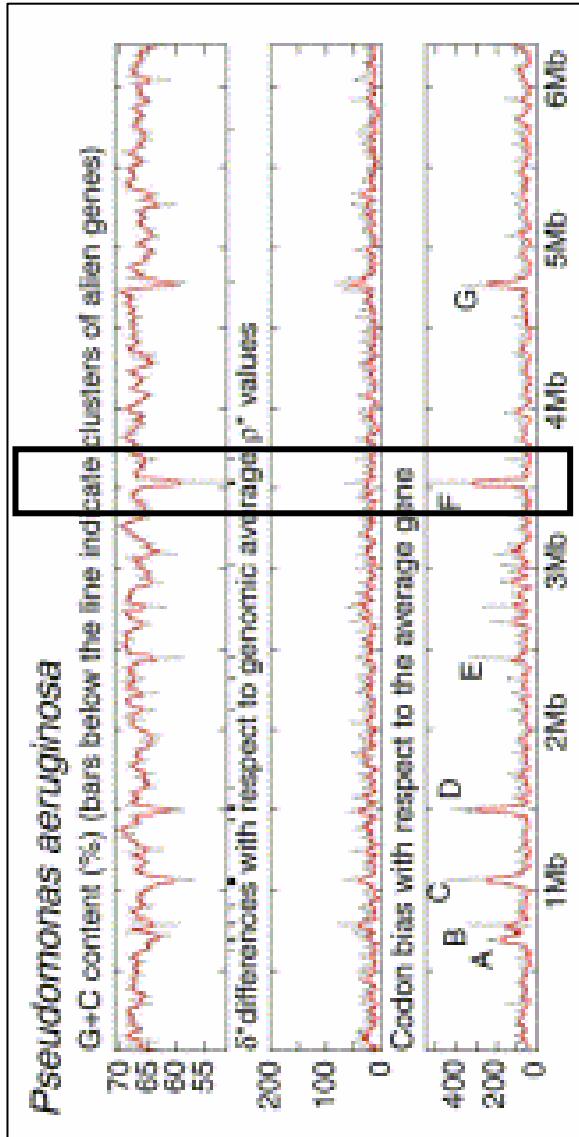
“typical”

2<sup>nd</sup> order  
# states: 64

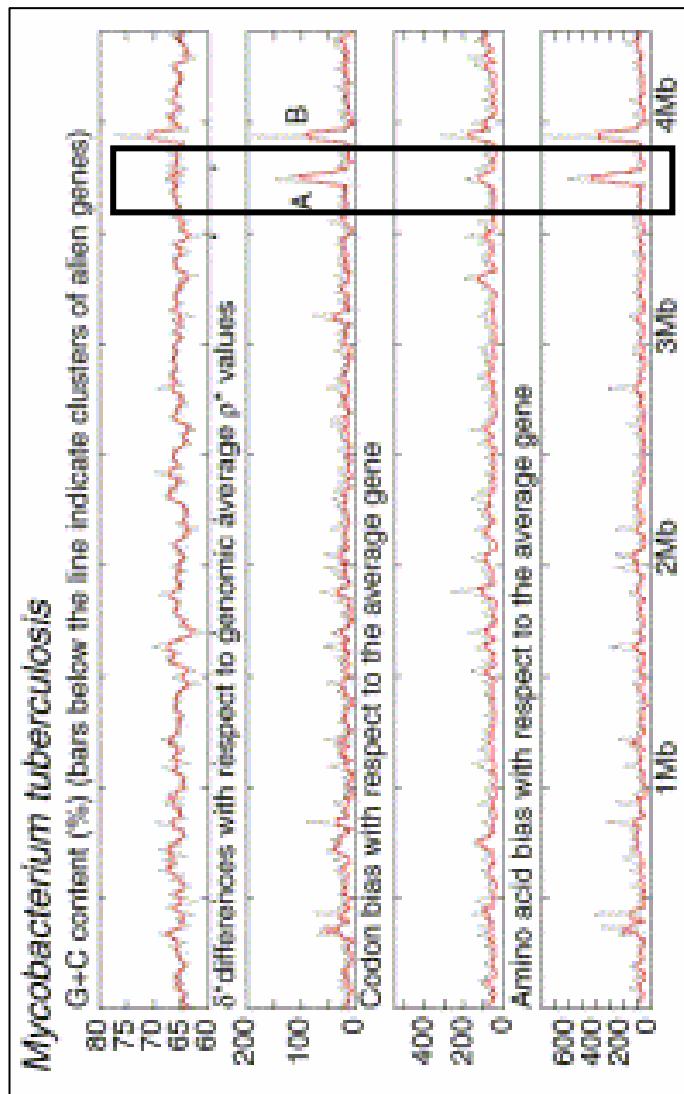
GCC	2
CCG	2
CGC	4
CCC	3
GCG	3

“atypical”

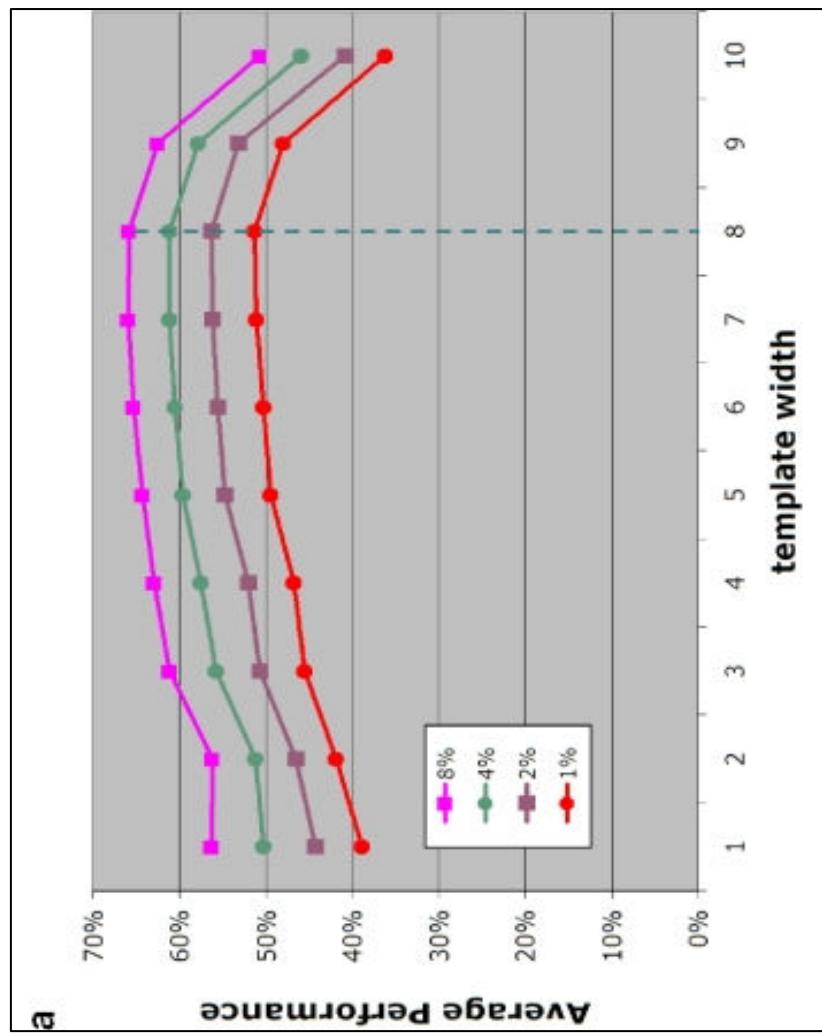
# Διαφορετικοί δείκτες – διαφορετικά αποτελέσματα



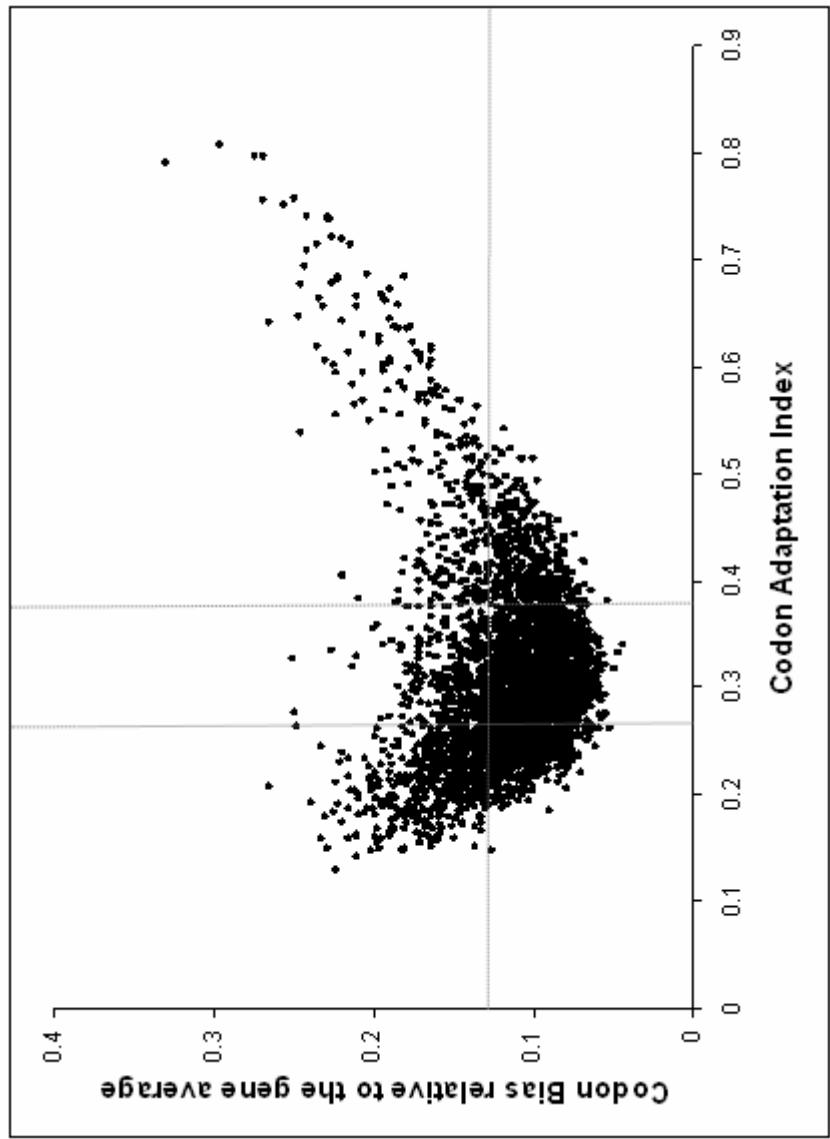
## **Διαφορετικοί δείκτες – διαφορετικά αποτελέσματα**



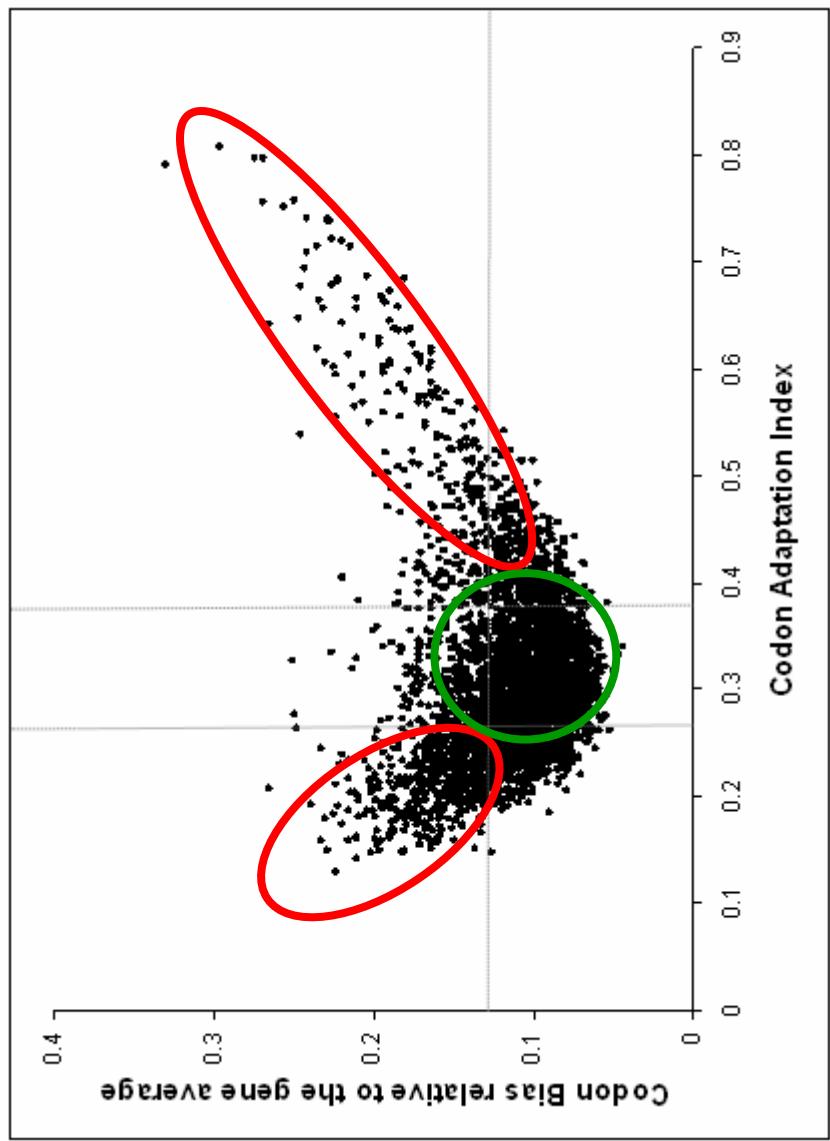
## Μέγεθος και απόδοση δεικτών



## Συνδυάζοντας δείκτες: "The rabbit-like plot"



# Συνδυάζοντας δείκτες: "The rabbit-like plot"



# *Interpolated Variable Order Motifs (IVOMs)*

1. Γραμμικός συνδυασμός πιθανοτήτων «λέξεων» διαφορετικής τάξης
2. Εξερευνεί δυναμικά μεγαλύτερο αλφάριθμο «λέξεων» όταν είναι δυνατό $\rightarrow$  μεγαλύτερη ακρίβεια
3. Σε περίπτωση «φτωχού» περιεχομένου «λέξεων» υψηλής τάξης  
εξερευνεί δυναμικά μικρότερο αλφάριθμο

# *Counts vs Dimensionality*

4. Συχνότητα εμφάνισης (**counts**)
5. Μέγεθος αλφαριθμητικής τάξης (**dimensionality**)

**Παράδειγμα**  
 $3mer \rightarrow \text{counts } \mathbf{128}$   
 $5mer \rightarrow \text{counts } \mathbf{8}$       }

"Ιδιο βαθμό αξιοποιητιας"

# *Interpolated Variable Order Motifs (IVOMS)*

$$B = \{a, t, c, g\} \quad (1)$$

$$P_m(S) = \frac{A_m(S)}{N - k + 1} \quad (2)$$

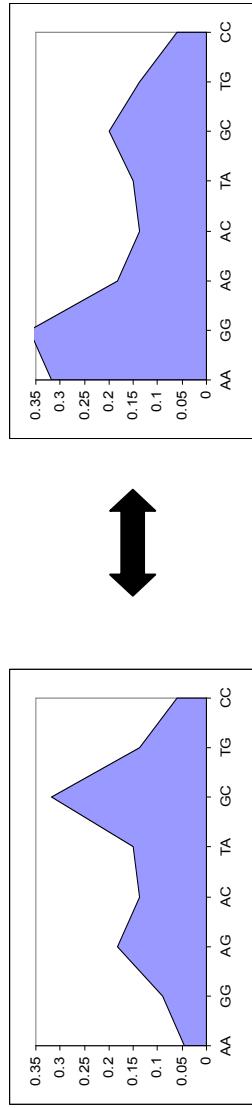
$$W_m(S) = \frac{A_m(S) \cdot |B|^k}{\sum_{j=1}^8 A_j(S) \cdot |B|^j} \quad (3)$$

$$\text{IVOM}(S, m) = \begin{cases} W_m(S) \cdot P_m(S) + [1 - W_m(S)] \cdot \text{IVOM}(S, m_{2,|m|}) & \text{if } |m| \geq 2 \\ W_m(S) \cdot P_m(S) & \text{if } |m| = 1 \end{cases} \quad (4)$$

# Παράδειγμα

8mer	Interpolated $k$ -mer	$A_m(S)$	$ B ^k$	$A_m(S) \times  B ^k$	$W_m(S)$
GCCAGGGC	GCCAGGGC	24	$4^8$	1572864	42.10
	CCAGCGC	49	$4^7$	802816	21.51
	CAGCGC	116	$4^6$	475136	12.73
	AGCGC	238	$4^5$	243712	6.53
	GCGC	738	$4^4$	188928	5.06
	CGC	2452	$4^3$	156928	4.20
	GC	9784	$4^2$	156544	4.19
	C	33854	$4^1$	135416	3.63
	AAACATG	1	$4^8$	65536	7.38
	AAACATG	6	$4^7$	98304	11.08
AAACATG	AACATG	26	$4^6$	106496	12.00
	ACATG	81	$4^5$	82944	9.35
	CATG	474	$4^4$	121344	13.67
	ATG	2110	$4^3$	135040	15.21
	TG	9243	$4^2$	147888	16.66
	G	32499	$4^1$	129996	14.65

# Relative Entropy



$$\overrightarrow{\text{IVOM}(S, m)} = \{\text{IVOM}(S, m) \mid m \in B^8\} \quad (5)$$

$$d_G(w) = \sum_{m \in B^8} \text{IVOM}(w, m) \log_2 \frac{\text{IVOM}(w, m)}{\text{IVOM}(G, m)} \quad (6)$$

# Score Threshold

**Algorithm:** K means clustering.

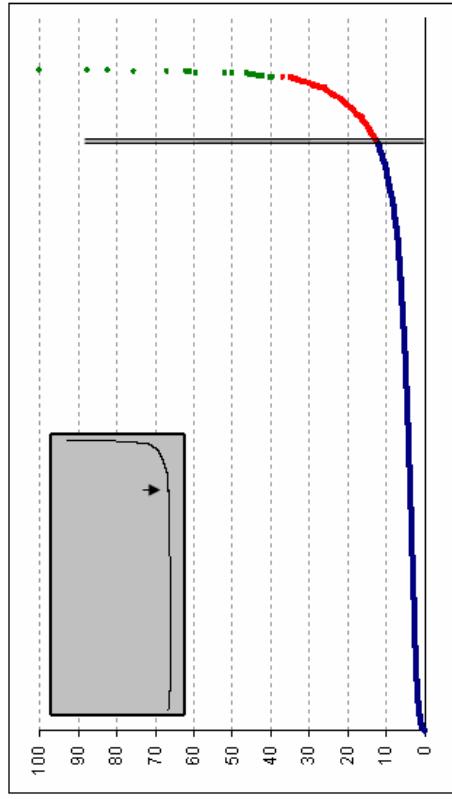
C: number of reinitializations.

F: objective function.

i=1.

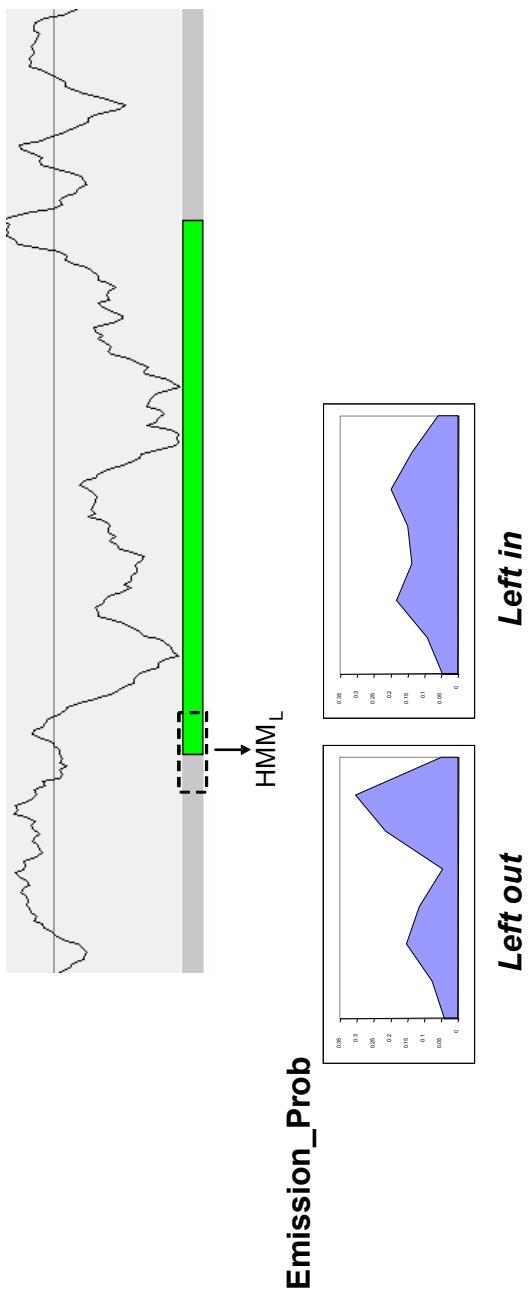
1. Determine the number of clusters, K = 3.
2. Initialize the value of the 3 centroids.
3. Assign each point to the cluster with the nearest centroid value.
4. When all points have been assigned to one of the 3 clusters, update the new centroid values.
5. Reiterate steps 3 and 4 until the 3 centroids do not change, convergence criteria: Last\_F<sub>i</sub> - Current\_F<sub>i</sub> < 0.1.
6. If i < C do  
    if F<sub>i</sub> > F<sub>i,max</sub> then F<sub>i,max</sub> = F<sub>i</sub>  
    i++  
    **Goto** step 2 re-initializing the 3 centroids with different values.
7. Set the score threshold to the value where the transition from cluster 1 → 2 occurs, for the iteration with F<sub>i,max</sub>.

**end**

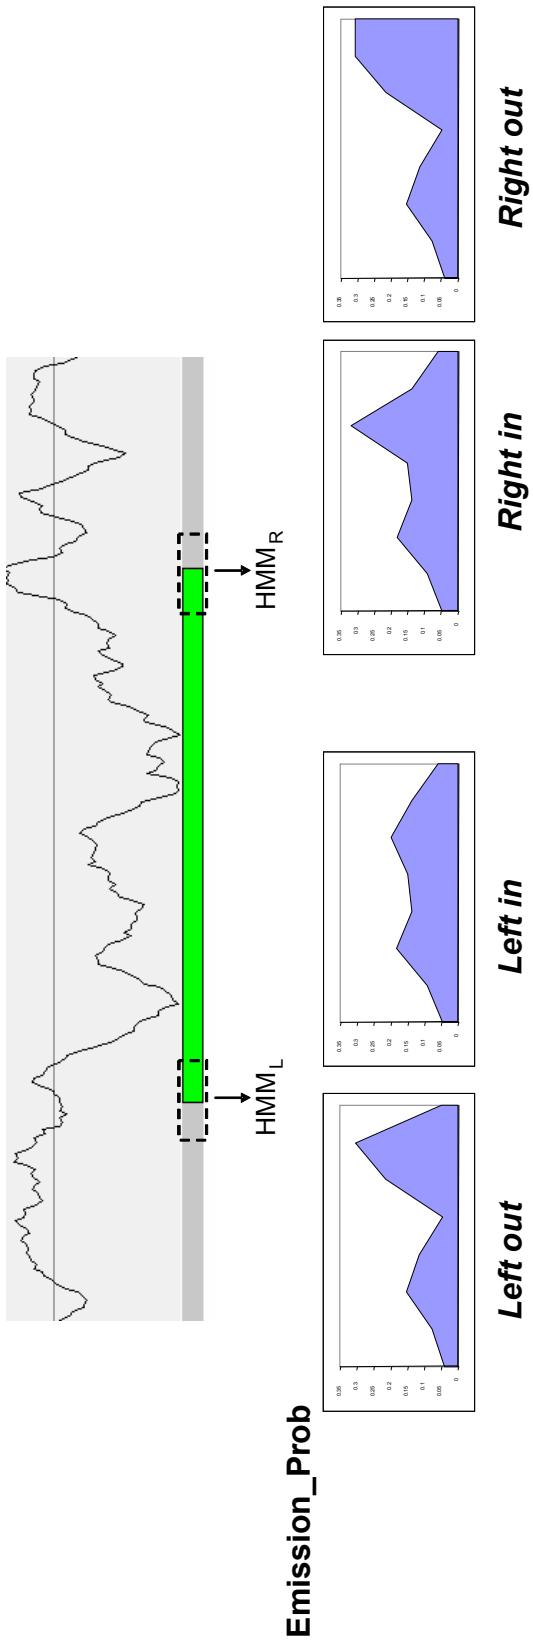


$$F = \sum_{j=1}^K \sum_{i=1}^n \|x_i - c_j\|^2 \quad (7)$$

# Change-point



# Change-point



**Algorithm:** Change-point detection.

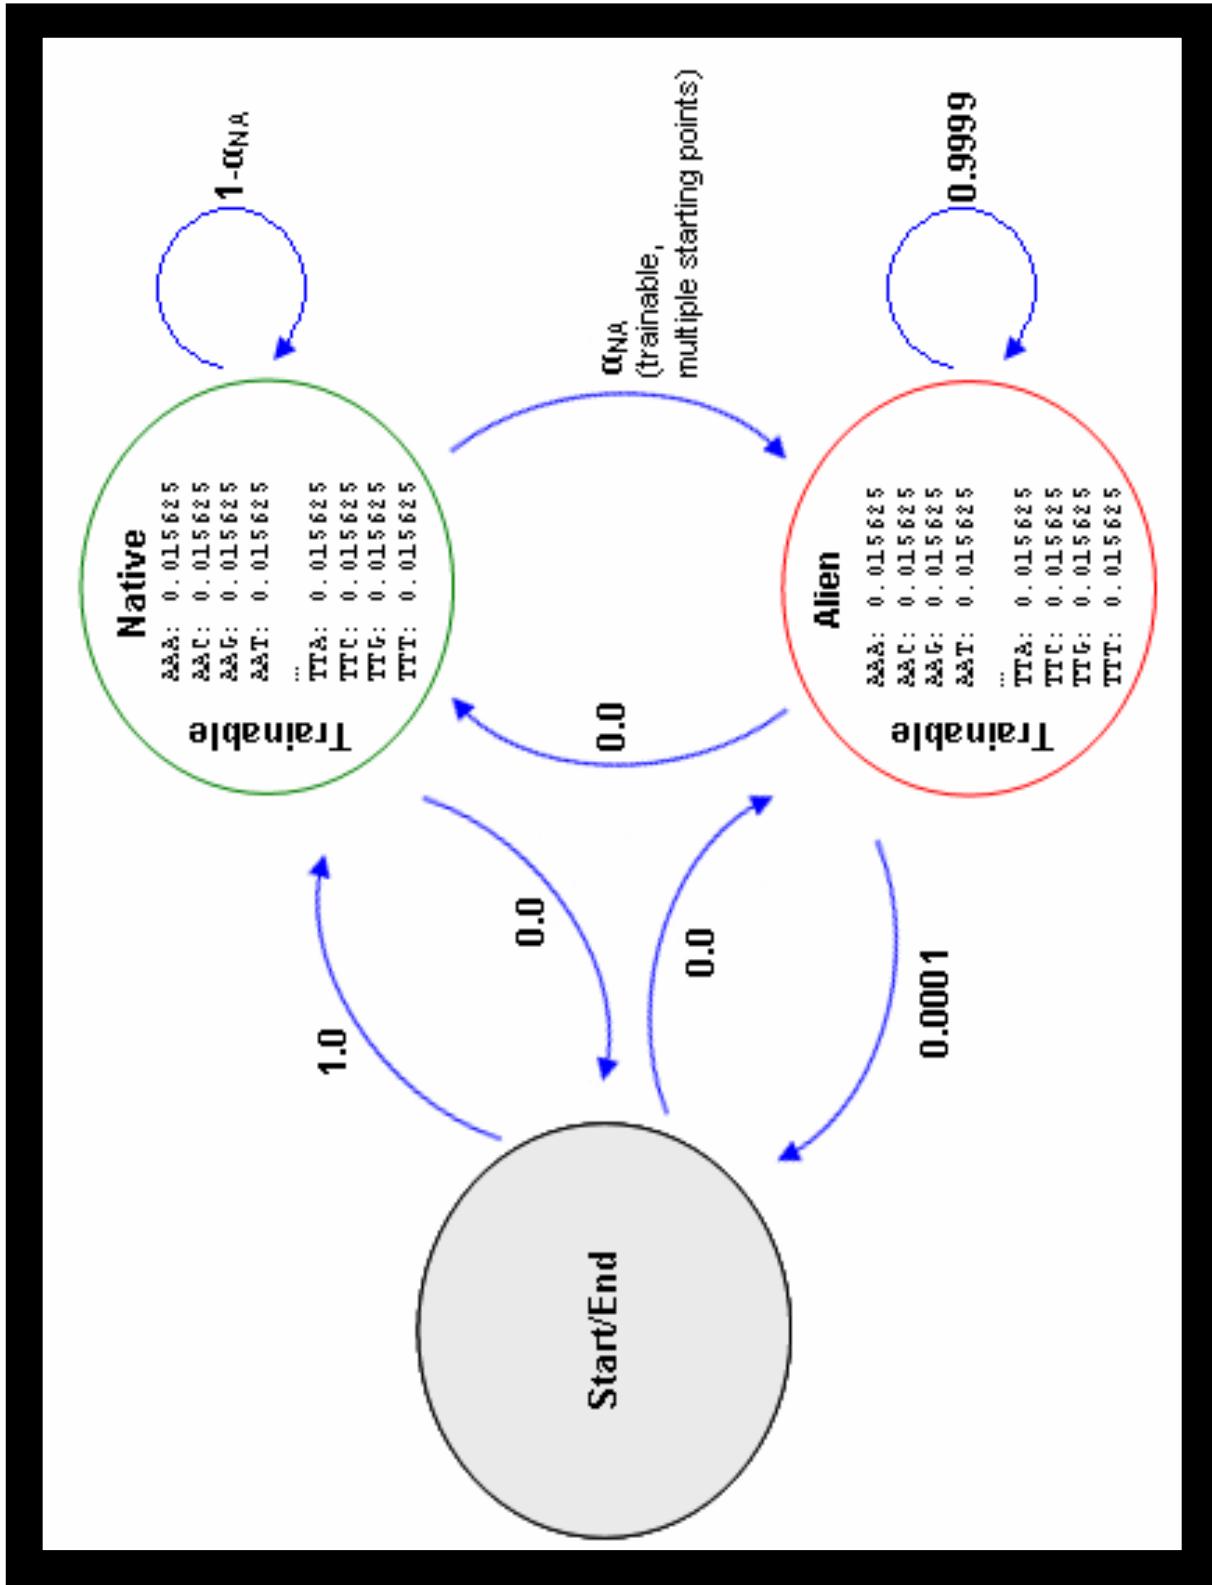
C: number of iterations

Init:  $i = 1$ ;

$\sigma' M A$  initial starting point for  $\sigma' M A$

1. extend the predictions upstream and downstream
2. set initial model:
  - 2.1. *prior* distribution for the emission probabilities:
    - 2.1.1. *N* state: trainable second order uniform ( $\epsilon_M$ ) distribution
    - 2.1.2. *A* state: trainable second order uniform ( $\epsilon_A$ ) distribution
  - 2.2. *prior* transition probabilities:
    - 2.2.1.  $\sigma' M A = \sigma' M A$  (multiple starting points - trainable)
    - 2.2.2.  $\sigma' A M = 0$  (untrainable)
3. BW training until convergence:
  - 3.1. stopping criteria:  $CurrentScore - LastScore < 0.001$
  - 3.2. updated-trained emission, transition probabilities
4. Viterbi: most probable path  $\pi^*$ , with score  $S_i$ 
  - 4.1.1. if  $S_i > S_{max}$  then  $S_{max} = S_i$
5. if  $i < C$  do
  - 5.1.1.  $i++$ ;
  - 5.1.2. new starting point  $\sigma' M A$
  - 5.1.3. **goto** step 2
6. report the path  $\pi^*$  with  $S_{max}$
7. set predicted boundary = transition point in the path  $\pi^*$  with  $S_{max}$   
**end**.

# Change-point



... HMM architecture  
Change-point

# *Change-point* ... *Viterbi*

iteration	score $S_i$ of path $\pi^*$	prior over $\alpha_{NA}$	change-point (bp)
1	-9643.868804	$500^{-1}$	1720
2	-9643.868873	$1000^{-1}$	1720
3	-9627.033373	$2000^{-1}$	4870
4	-9627.0333077	$2500^{-1}$	4870
5	-9627.033131	$3000^{-1}$	4870

```

import java.io.*;
import org.biojava.bio.symbol.*;
import org.biojava.bio.seq.*;
import org.biojava.bio.seq.io.*;
import org.biojava.bio.dp.*;
import org.biojava.bio.*;
import org.biojava.bio.seq.db.*;
import org.biojava.bio.seq.impl.*;
import org.biojava.bio.dist.*;
import org.biojava.utils.*;
import java.util.*;
}

class ChangepointLeft{

    public static SymbolList seqL;
    public static int order;
    public static int flatOrRandom;
    public static int trainOrUntrain;
    public static Distribution dist;
    public static int duration;
    public static ModelITrainer mt;
    public static int transition_point=0;
    public static int count=0;

    //make alphabets
    static FiniteAlphabet DnaAlphabet = DNATools.getDNA();

    public static void main (String args[]) throws Exception{

        if(args.length != 5) {
            throw new Exception("Use: sequence.fa order.int flatD.bin trainableTrans.bin duration.int");
        }

        try{

```

# Changepoint - BioJava

```

File seqFile = new File(args[0]);
order = Integer.parseInt(args[1]);
flatOrRandom = Integer.parseInt(args[2]);
trainOrUntrain = Integer.parseInt(args[3]);
duration = Integer.parseInt(args[4]);

if((flatOrRandom != 0) & (flatOrRandom != 1)) {
    throw new Exception("Use flatD.bin: only binary i.e. 0 or 1: . . . 1/0 . . .");
}
if((trainOrUntrain != 0) & (trainOrUntrain != 1)) {
    throw new Exception("Use trainableTrans.bin: only binary i.e. 0 or 1: . . . 1/0 . . .");
}

SymbolTokenization rParser = DnaAlphabet.getTokenization("token");

SequenceBuilderFactory sbFact = new FastaDescriptionLineParser.Factory(SimpleSequenceBuilder.FACTORY);
FastaFormat fFormat = new FastaFormat();

SequenceIterator seqI = new StreamReader(new FileInputStream(seqFile),
fFormat,
rParser,
sbFact);

seqI.hasNext();

Sequence seq2 = seqI.nextSequence();
SequenceDB seqs = new HashSequenceDB();
seqL = seq2;

MarkovModel island = createModel();
DP dp=DPFactory.DEFAULT.createDP(island);

Sequence seq = new SimpleSequence(
SymbolListViews.orderNSymbolList(seq2, order),
null,
seq2.getName() + "-o" + order,
Annotation.EMPTY_ANNOTATION
);

seqs.addSequence(seq);

```

## Change-point - BiJAVA

```

TrainingAlgorithm ta = new BaumWelchTrainer(dp);

ta.train(
    seqs,
    0.01,
    new StoppingCriteria() {
        public boolean isTrainingComplete(TrainingAlgorithm ta) {

            try {
                // XmlMarkovModel.writeModel(ta.getDP(), getModel(), System.out);
                //out2.write(ta.getCycle() + "\t" + ta.getCurrentScore() + "\n");
            }catch (Exception ex) {ex.printStackTrace();}

                //System.out.println(ta.getCycle() + "\t" + ta.getCurrentScore());
                //return (ta.getCycle() >=2);
            return Math.abs(ta.getLastScore() - ta.getCurrentScore()) < 0.001;
        }
    });

```

# Change-point - BiJava

```

//Viterbi

SymbolList [] rl = {SymbolListViews.orderNSymbolList(seq2, order)};

StatePath statePath = dp.viterbi(rl, ScoreType.PROBABILITY);

for(int i = 0; i <= statePath.length() / 60; i++) {

    for(int j = i*60; j < Math.min((i+1)*60, statePath.length()); j++) {
        //System.out.print(statePath.symbolAt(StatePath.STATEs, j+1).getName().charAt(0));
        char state=statePath.symbolAt(StatePath.STATEs, j+1).getName().charAt(0);
        count++;

        //it prints the states in binary mode for art user_graph
        if(state == 'a'){
            //out.write("0 1");
        }
        else{
            transition_point=count;
            //out.write("1 0");
        }
    }

    System.out.print(transition_point + " " + statePath.getScore());
}

catch (Exception e) {
    e.printStackTrace();
}
}

```

# Change-point - BiJava

```

//creates the model
public static MarkovModel createModel() {
    List<I> l = Collections.nCopies(order, DNATools.getDNA());
    Alphabet alpha = AlphabetManager.getCrossProductAlphabet(l);

    int [] advance = { 1 };
    Distribution typicalID;
    Distribution atypicalID;

    try{
        //check if higher order: else normal dist
        if(order > 1) {
            typicalID = OrderNDistributionFactory.DEFAULT.createDistribution(alpha);
            atypicalID = OrderNDistributionFactory.DEFAULT.createDistribution(alpha);
        }
        else{
            typicalID = DistributionFactory.DEFAULT.createDistribution(alpha);
            atypicalID = DistributionFactory.DEFAULT.createDistribution(alpha);
        }

        catch (Exception e){
            throw new AssertionFailure("Can't create distributions", e);
        }
    }
}

```

# Change-point - BiJAVA

```

EmissionState typicalS = new SimpleEmissionState("typical", Annotation.EMPTY_ANNOTATION, advance, typicalID);
EmissionState atypicalS = new SimpleEmissionState("atypical", Annotation.EMPTY_ANNOTATION, advance, atypicalID);

SimpleMarkovModel island = new SimpleMarkovModel(1, alpha, "Island");

try{
    island.addState(typicalS);
    island.addState(atypicalS);
} catch (Exception e){
    throw new AssertionFailure("Can't add states to model", e);
}

/set up transitions between states
try {
    island.createTransition(island.magicalState(),typicalS);
    island.createTransition(island.magicalState(),atypicalS);
    island.createTransition(typicalS,island.magicalState());
    island.createTransition(atypicalS,island.magicalState());
    island.createTransition(typicalS,atypicalS);
    island.createTransition(atypicalS,typicalS);
    island.createTransition(typicalS,typicalS);
    island.createTransition(atypicalS,atypicalS);
} catch (Exception e){
    throw new AssertionFailure("Can't create transitions", e);
}

```

# Change-point - BiJAVA

```

//set up emission probabilities
try {
    SymbolList highOrderSeq = SymbolListViews.orderNSymbolList (seqL, order);
    Hashtable symbol= new Hashtable();
    for (Iterator i = highOrderSeq.iterator(); i.hasNext(); ) {
        Symbol sym = (Symbol) i.next();
        if(!symbol.containsKey(sym)){
            //uniform weights for atypical emmision probs
            atypicalD.setWeight(sym,0.25);
            typicalD.setWeight(sym, 0.25);
            symbol.put(sym, new Integer(1));
        }
        if(flatOrRandom == 0){
            //it randomizes the atypical emission probs
            DistributionTools.randomizeDistribution(atypicalID);
            DistributionTools.randomizeDistribution(typicalID);
        }
    }
    catch (Exception e) {
        throw new AssertionFailure("Can't set emission probabilities", e);
    }
}

```

# Change-point - BiJava

```

//set up transition scores.

try {
    //if user option =1 then it trains ; if 0 then untrained
    if(trainOrUntrain ==0){
        //it keeps the transition probs untrainable
        dist = new UntrainableDistribution (island.transitionsFrom(island.magicalState()));
    }
    else{
        dist = island.getWeights(island.magicalState());
    }

    dist.setWeight(typicalS, 1.0);
    //since it will always start at start at state typicalS
    dist.setWeight(atypicalS, 0.0);
    island.setWeights(island.magicalState(), dist);
}

{
    // always trainable
    dist = island.getWeights(typicalS);
    float T_A = (float)1 / duration;
    float T_T = (float)1-T_A;
    //1/region = 1/7500
    dist.setWeight(atypicalS, T_A);
    //1-1/7500
    dist.setWeight(typicalS, T_T);
    //zero since it will always end at atypical
    dist.setWeight(island.magicalState(), 0.0);
    island.setWeights(typicalS, dist);
}

```

# Change-point - BiJava

# **Change-point - BiJAVA**

# Viterbi ...

## online DEMO



**Source:** <http://www.cs.umb.edu/~srevilak/viterbi/>

**Target sequence:** "ATGCATGCCATGGGCC"

**Alphabet:** [A, T, G ,C]

**# of states:** 2

**Transition:** There is 0.2 probability of switching from state1 to state2. There is 0.9 probability of switching from state2 to state1.

**Emission:** In state1 the frequency of observing A, T, G, C is their expected frequencies assuming a zero-th order alphabet. In state2  $P_A = P_T = 0.1$  and  $P_G = P_C$ .

**Initial probabilities:** The probability of the model starting in state1 is 0.6.

**Deliverables:**

- A. Build the model.
- B. Run the prediction.
- C. Record the most probable state path.
- D. Design the HMM architecture.