

Слайды для презентации к докладу

# **КЛАСТЕРИЗАЦИЯ ОРГАНИЗМОВ ПО ХАРАКТЕРИСТИКАМ СТРОЯ ИХ ДНК**

Поздниченко Н.Н.

# План доклада

- Средства исследования – вероятностно-информационные методы, анализ строя цепи
- Объект исследования – генетические тексты
- Цели исследования – кластеризация организмов, численное описание свойств строя генетического текста, выделение «естественных» информационных единиц в таких текстах

# Методы анализа структуры СИМВОЛЬНЫХ ПОСЛЕДОВАТЕЛЬНОСТЕЙ

1. Методы, учитывающие только состав последовательности
2. Методы, учитывающие состав и косвенно – взаимное расположение элементов
3. Метод непосредственного исследования взаимного расположения элементов – анализ строя цепи

# Строй цепи

N	M	M	N	V	M	V	V	N	M	N	V
A	L	L	A	B	L	B	B	A	L	A	B
F	G	G	F	H	G	H	H	F	G	F	H
1	2	2	1	3	2	3	3	1	2	1	3
1	-	-	1	-	-	-	-	1	-	1	-
$\Delta_{11}$			$\Delta_{12}$					$\Delta_{13}$		$\Delta_{14}$	

где  $\Delta_{ji}$  интервал между  $i$ -м и  $i+1$  вхождением элемента  $j$ -ой однородной цепи

# Декомпозиция строки неоднородной знаковой цепи на однородные

V	N	A	B	J	K	T	T	B	T	A	A	T	V	T	A	B	знаковая цепь	матрица				
1	2	3	4	5	6	7	7	4	7	3	3	7	1	7	3	4	строки цепи	интервалов				
1													1				однородные цепи и соответствующие им цепи интервалов	0	0	0	13	4
	2																	0	0	0	0	16
		3								3	3				3			0	8	1	4	2
			4					4								4		0	0	5	8	1
				5														0	0	0	0	13
					6													0	0	0	0	12
						7	7		7			7		7				1	2	3	2	3

# Используемые в работе числовые характеристики строа

$$g = \log_2 \Delta_g = \frac{1}{n} \sum_{j=1}^m \sum_{i=1}^{n_j} \log_2 \Delta_{ij}$$

$$r = \frac{\Delta_g}{D}$$

где  $m$  – мощность алфавита,

$n_j$  – число вхождений  $j$ -го элемента,

$D$  – максисмальный средний геометрический интервал

# Некоторые понятия генетики


*Нуклеотиды* – являются элементарными компонентами нуклеиновых кислот, таких как ДНК и РНК.

*Кодон , триплет* – единица генетического кода, тройка нуклеотидных остатков в ДНК или РНК, кодирующая включение одной аминокислоты.

*Аминокислоты* – органические молекулы, являющиеся элементарными компонентами белков.

*Белки* – высокомолекулярные органические вещества, состоящие из соединённых в цепочку пептидной связью аминокислот.


# Структурные уровни организации белков




# Классификация, основные понятия

- *Таксономия* — задача разбиения заданной выборки объектов (ситуаций) на подмножества, называемые таксонами (классами), так, чтобы каждый класс состоял из схожих объектов, а объекты разных таксонов существенно отличались.
- *Мерономия* – разделение объектов, позволяющее определить степень сходства между ними. Вычленение частей, образующих структуру объекта.
- *Классификация* – метод познания в котором результатом является представление знаний в виде некоторой классификационной схемы. В ней изучаемые объекты группируются в классы с помощью целесообразно выбранных признаков – оснований классификации.


# $\lambda$ -KRAB



ΠΓ



KHΠ



$\lambda$ -KHΠ


id	название	g
1	<i>M.musculus</i> - мышь	1,417414581
2	<i>C.crocodylus</i> - Крокодил	1,418643679
3	<i>C.familiaris</i> - Собака	1,427959968
4	<i>G.gallus</i> - курица	1,428402795
5	<i>Sus scrofa</i> - Кабан	1,440507111
6	<i>A.calva</i> - рыба	1,440937027
7	<i>H.s</i> - человек	1,442946531
8	<i>Th.thermophilus</i> - микроорганизм	1,448283347
9	<i>Th.thermarum</i> - микроорганизм	1,448292643
10	<i>Gallus gallus</i> - Банкивская джунглевая курица	1,455663685
11	<i>Bos taurus</i> 18S ribosomal RNA gene - Дикий бык	1,460651525
12	<i>Erinaceus europaeus</i> - Обыкновенный ёж	1,463618632
13	<i>Homo sapiens</i> - Человек разумный	1,463758914
14	<i>Mus musculus</i> - Домовая мышь	1,46560513
15	<i>Cricetulus griseus</i> - серый хомячок	1,468230019
16	<i>Rattus norvegicus</i> - Серая крыса	1,470291648
17	<i>Crocodylus niloticus</i> - Нильский крокодил	1,478396611
18	<i>I.persulcatus</i> - Искодовые клещи	1,483028363
19	<i>Zebrias zebra</i> - Рыба	1,490709799
20	<i>Kareius bicoloratus</i> - двухцветная камбала	1,49358883
21	<i>O.toubata</i> - клещи	1,495843469
22	<i>P.humanus cap</i> - блоха	1,503112618
23	<i>M.domestica</i> - муха	1,510952625
24	<i>S.pyogenes</i> - Стрептококк	1,51643989
25	<i>B.anthraxis</i> - Сибирская язва	1,522106822
26	<i>B.burgdorferi</i> - боррелиоз	1,522174205
27	<i>Candidatus N.m</i> - бактерия	1,523941071
28	<i>M.pneumoniae</i> - атипичная пневмония	1,532855504
29	<i>N.g</i> - гонорея	1,535260296

На числовой оси организмы расположены в соответствии со значениями характеристики  $g$  – средней удаленности элементов в нуклеотидной цепи.

Эукариоты (позвоночные) - слева на оси, наименьшие значения  $g$ .

Прокариоты (бактерии) - справа на оси, наибольшие значения  $g$ .


Эукариоты (беспозвоночные) примыкают к бактериям.



id	Название	номер кластера
469	Candidatus N.m - бактерия	1
466	B.burgdorferi - боррелиоз	1
465	B.anthraxis - Сибирская язва	1
479	S.pyogenes - Стрептококк	1
478	P.humanus cap - блоха	1
476	N.g гонорея	1
475	M.pneumoniae - Атипичная пневмония	1
473	M.domestica - муха	1
468	C.crocodylus - Крокодил	2
467	C.familiaris - Собака	2
464	A.calva - рыба	2
504	Zebrias zebra - Рыба	2
503	Sus scrofa - Кабан	2
502	Rattus norvegicus - Серая крыса	2
501	Mus musculus - Домовая мышь	2
500	Kareius bicoloratus - двухцветная камбала	2
499	Homo sapiens - Человек разумный	2
498	Gallus gallus - Банкивская джунглевая курица	2
497	Erinaceus europaeus - Обыкновенный ёж	2
496	Crocodylus niloticus - Нильский крокодил	2
495	Cricetulus griseus - серый хомячок	2
494	Bos taurus 18S ribosomal RNA gene - Дикий бык	2
481	Th.thermophilus - микроорганизм	2
480	Th.thermarum - микроорганизм	2
477	O.moubata - клещи	2
474	M.musculus - мышь	2
472	I.persulcatus - Искодовые клещи	2
471	H.s - человек	2
470	G.gallus - курица	2

# Классификация

$$g = \log_2 \Delta_g = \frac{1}{n} \sum_{j=1}^m \sum_{i=1}^{n_j} \log_2 \Delta_{ij}$$



id	Название	номер кластера
469	Candidatus N.m – бактерия	1
466	B.burgdorferi – боррелиоз	1
465	B.anthraxis - Сибирская язва	1
479	S.pyogenes – Стрептококк	1
478	P.humanus cap – блоха	1
476	N.g гонорея	1
475	M.pneumoniae - Атипичная пневмония	1
473	M.domestica – муха	1
468	C.crocodylus – Крокодил	2
467	C.familiaris – Собака	2
464	A.calva – рыба	2
504	Zebrias zebra – Рыба	2
502	Rattus norvegicus - Серая крыса	2
501	Mus musculus - Домовая мышь	2
500	Kareius bicoloratus - двухцветная камбала	2
499	Homo sapiens - Человек разумный	2
498	Gallus gallus - Банкивская джунглевая курица	2
497	Echinaceus europaeus - Обыкновенный ёж	2
496	Crocodylus niloticus - Нильский крокодил	2
495	Cricetulus griseus - серый хомячок	2
494	Bos taurus 18S ribosomal RNA gene - Дикий бык	2
477	O.moubata – клещи	2
474	M.musculus – мышь	2
472	I.persulcatus - Искодовые клещи	2
471	H.s – человек	2
470	G.gallus – курица	2
481	Th.thermophilus - микроорганизм	3
480	Th.thermarum - микроорганизм	3

# Классификация

$$r = \frac{\Delta_{\infty}}{D}$$

◆ Кластер 1    ◆ Кластер 2    ◆ Кластер 3

