

УДК 577.3

АНАЛИЗ ТОНКОЙ СрG СТРУКТУРЫ ПОСЛЕДОВАТЕЛЬНОСТЕЙ ДНК

Д. Р. Дуплій, Ю. Г. Шкорбатов

Харківський національний університет ім. М. Н. Каразіна

пл. Свободи, 4, Харків 61077, Україна

E-mails: duplijd@mail.ru, Yury.G.Shekorbato@univer.kharkov.ua.

Поступила в редакцію 5 марта 2003 г.

Предложены методы описания распределения **CpG** сайтов в последовательностях ДНК с помощью числовых характеристик и графически. Нормализация кривой графика на длину последовательности позволяет сравнивать последовательности по характеру накопления **CpG** и классифицировать их по подобию накопления, а не только по частоте встречаемости. С помощью введенных числовых характеристик и принципа подобия показано существование различий в накоплении **CpG** сайтов в ДНК генов организмов, отличающихся по эволюционному положению и наличию системы метилирования ДНК. Для видов, у которых метилирование ДНК не имеет регуляторного значения в процессах импринтинга и клеточной памяти, характерно случайное распределение **CpG** сайтов.

КЛЮЧЕВІ СЛОВА: метилирование ДНК, **CpG** сайты, метилцитозин, изохоры, гистоновые белки, CG островки, инtron, экзон.

Характерной особенностью генома человека является крайне неравномерное распределение частот нуклеотидов и динуклеотидов **CG** и **AT** как вдоль хромосом, так и между комплементарными цепями [1, 2, 3]. При дифференциальном окрашивании (акрихином или модифицированными методиками Гимза) хромосом млекопитающих выявляется специфическая исчерченность. Различное средство к красителям связано с нуклеотидным составом ДНК и позволяет различать **AT** и **CG** богатые сегменты [4]. Экзоны характеризуются большей стабильностью по отношению к мутациям, чем межгенные области, что связано с ограничениями, налагаемыми естественным отбором [5]. Таким образом, цепь ДНК находится в компромиссе между мутационным давлением и естественным отбором. На примере бактериального генома было показано, что содержание каждого нуклеотида в геноме пропорционально времени, необходимому для замены половины нуклеотидов данного типа [6].

Для описания областей ДНК с преобладанием **CG** или **AT** пар G. Bernardi ввел понятие изохор, то есть "имеющих одинаковый объем". Изохоры - это области ДНК длиной более 300 тыс. пар нуклеотидов, близкие по уровню содержания гуанина и цитозина [7], а геном млекопитающих представляется мозаикой изохор. Различают **CG**-бедные изохоры, находящиеся в 62% генома и содержащие 34% генов; **CG**-богатые изохоры — 31% генома, 38% генов; и **CG** обогащенные изохоры, составляющие 3% генома с 28% генов [8]. Таким образом, имеется зависимость между составом изохор и количеством генов: плотность генов в **CG** обогащенных изохорах в 10 раз выше, чем в **CG** бедных областях [9].

Следует отметить, что обычно, говоря о **CG** содержании, подразумевают частоту содержания комплементарной пары **CG**, в то время как особый интерес представляет содержание динуклеотидов 5'-**CpG**-3' в одной цепи. Особое значение **CpG** сайтов связано со способностью цитозина в этом динуклеотиде служить мишенью при метилировании с образованием 5-метилдезоксицитидина [10], который играет важную роль в экспрессии генов. Но 5-метилцитозин - относительно неустойчивое основание, которое в результате спонтанного дезаминирования и последующей замены аминогруппы на оксигруппу превращается в тимин, что приводит к обеднению ДНК парами **CpG**, так как при первом же раунде репликации гуанин в комплементарной цепи заменяется на аденин. Таким образом, вследствие метилирования цитозина в комплементарных цепях ДНК происходит замена **CG** пар на **TA** [11]. В ДНК позвоночных 5'-**CpG**-3' встречается в пять раз реже, чем 5'-**GpC**-3' [10]. Частота встречаемости 5'-**CpG**-3' и 5'-**GpC**-3' в ДНК прокариот почти одинакова и близка к случайной, как и частоты встречаемости других динуклеотидов, например 5'-**GpA**-3' и 5'-**ApG**-3'. Известно, что у беспозвоночных, в частности, у бактерий, дрозофилы и

нематоды уровень метилирования цитозина в **CpG** сайтах очень низок, и, по-видимому, метилирование ДНК у этих организмов не является механизмом регуляции генной экспрессии [12]. У дрозофилы имеется фермент метилтрансфераза-За, который метилирует **CpG** сайты в ДНК эмбриональных клеток, но неактивен в клетках соматических тканей. Этот фермент также метилирует цитозин в сайтах **CpA** и **CpT** [13].

Система метилирования ДНК у бактерий важна при защите клеток от чужеродной ДНК, например, транспозонной или вирусной [14]. Система рестриктаз-метилаз бактерий содержит метилтрансферазы, метилирующие нуклеотиды в специфических сайтах. Функция метилирования ДНК у бактерий заключается в защите собственной ДНК от действия рестриктаз, расщепляющих чужеродную ДНК. У бактерий метилазы, специфически метилирующие цитозин в последовательности **CC(A/T)GG** и аденин в последовательности **GATC**, участвуют в клеточной регуляции и связаны с вирулентностью болезнетворных бактерий [14]. Имеются сведения о метилировании и других нуклеозидов, так, в составе ДНК эукариот встречается N-6 метиладенозин [4], а, например, метилгуанозин в сайте **CpG** является горячей точкой, то есть местом повышенной частоты мутирования в гене p53 при развитии рака легких у курильщиков [15]. Но все же 95% метильных групп в ДНК позвоночных содержится именно в остатках цитозина динуклеотидов 5'-**CG**-3', и больше половины таких динуклеотидов метилировано по 5' положению остатков цитозина. У растений можно обнаружить метилирование цитозина в тринуклеотиде 5'-**CNG**-3', где N=A, T, C [10].

При расщеплении ДНК эндонуклеазой НраС, имеющей сродство к неметилированной последовательности 5'-**CCGG**-3', образуются низкомолекулярные фрагменты. Использование таких фрагментов в качестве зондов для блот-гибридизации с геномной ДНК выявило наличие "островков" внутри **CG** обогащенных изохор, содержащих неметилированные динуклеотиды **CpG**, называемые **CG** или **HTF** (НраС tiny fragments) островками длиной 1000-2000 п.н.[16, 17, 18]. Существуют более строгие определения, полученные с использованием статистических методов, согласно которым **CpG**-островками считают:

1) последовательности ДНК длиной более 200 п.н., содержащие более 50% **C+G**, при этом отношение наблюдаемой частоты **GC** к ожидаемой (случайной) больше, либо равно 0.6 [19],

2) последовательности от 500 до 2000 п.н., содержащие 60% **C+G**, а также неметилированные **CpG** динуклеотиды и **G/C** боксы - участки, родственные сайту узнавания фактора транскрипции **Sp1-G4CG4C** [7].

CpG-островки располагаются в начале транскрибуемых генов и могут выступать маркерами конкретных структурных генов. Отмечено предпочтительное расположение **CpG** островков в первых кодирующих экзонах [20]. Островки наблюдаются в большинстве генов "домашнего хозяйства" в 5' фланкирующей последовательности и у 40% тканеспецифичных генов [21]. Экспериментально обнаружено от 30 000 до 45 000 **CpG**-островков в геноме человека [16, 17, 22]. Большое их количество находится также в теломерных участках хромосом 1, 9, 15-17, 19, 20 [21].

Метилированные области ДНК, связываясь с определенными белками, становятся недоступными для действия ряда факторов транскрипции, вследствие чего снижается экспрессия генов [9]. Эффективность генной экспрессии при наличии метилированных групп уменьшается, а активное состояние генов сочетается с гипометилированием в тех же сайтах [20]. Замечено, что метилирование в двух цепях (симметричное) более стабильно и может сохраняться в течение нескольких клеточных поколений, в то время, как метилирование в одной цепи (асимметричное), менее стабильно и подвержено деметилированию [23]. Метилирование **CpG**-островков связано с явлением геномного импринтинга, который установлен в 15, 11, 14 и 7 хромосомах [24]. Геномным импринтингом называется механизм, обеспечивающий избирательную экспрессию признаков, унаследованных от одного из родителей. Отцовский импринтинг означает, что фенотипической экспрессии аллеля не происходит при передаче его от отца, а материнский импринтинг соответственно — при передаче аллеля от матери. Геномному импринтингу подвержена небольшая доля генов млекопитающих (по различным оценкам, от 100 до 300), эти гены вовлечены в регуляцию эмбрионального развития, причастны к онкогенезу [25]. У человека некоторые импринтируемые гены связаны с наследственной патологией, что прослеживается на примере ряда моно- и полигенных заболеваний. В частности, хорошо изучены такие патологии, передающиеся исключительно или в большей степени от матери, как синдром Беквита-Видемана (ген локализован в хромосоме 11p), нейрофиброматоз II (22q). Преимущественно от отцов передаются такие наследственные патологии, как

Анализ тонкой CpG структуры последовательностей ДНК

HLA-связанный сахарный диабет (*6q*), синдром Прадера-Вилли (кластер импринтированных генов *15q11-q13*) [26]

Механизмы, связанные с метилированием ДНК, обеспечивают инактивацию одной из X хромосом в геноме самок млекопитающих. Инактивации в данном случае подвергается хромосома, полученная либо от отца, либо от матери. Инактивированная хромосома, ДНК которой подвергается дополнительному метилированию, находится в конденсированном, гетерохроматинизированном состоянии. В неактивной хромосоме обнаружены так называемые “центры инактивации”, в которых процесс инактивации начинается и от которых затем распространяется вдоль хромосомы [27].

Таким образом, закономерности распределения **CpG** динуклеотидов внутри областей ДНК связаны с регуляцией активности генома, поэтому изучение распределения **CpG** является актуальной проблемой.

МАТЕРИАЛЫ И МЕТОДЫ

Анализируемые последовательности ДНК

Нуклеотидные последовательности были взяты из общедоступной базы данных Американского Национального Центра Биотехнологической Информации (NCBI). Рассматривались последовательности из следующих таксономических групп: бактерий – *Thermoplasma acidophilum*, *Thermotoga maritima*, *Methanococcus jannaschii*, нематод – *Caenorhabditis elegans*, насекомых – *Drosophila melanogaster*, костищих рыб подотряда нототениевидных, обитающих в Антарктике – *Dissostichus mawsoni*, *Harpagifer antarcticus*, *Notothenia coriiceps*, *Pagothenia borchgrevinki*, а также нуклеотидные последовательности человека, кодирующие функционально различные белки, в частности, цитохромы, локус гистосовместимости, семейство гистоновых белков.

Для работы отбирались области ДНК с экспериментально установленными функциями, которые отражены в соответствующих описаниях протоколов GENBANK. Гены, локализованные в комплементарной цепи, а также предположительно некодирующие области не рассматривались. Геномы бактерий анализировались полностью.

Из начального набора последовательностей были выбраны гены метаболических ферментов бактерий, гены антифризовых гликопротеидов костищих рыб, у человека гены цитохромов и семейство генов гистоновых белков (человека и нематоды), а также 24 **CpG**-островка в спайсерных районах, расположенных в **C+G** богатой области хромосомы *6p21.3-22.3*. Причем, распределение **CpG** пар вычислялось отдельно для всего гена, его первичного транскрипта РНК, и кодирующей части (с удаленными инtronами, если такие были).

Характеристики содержания CpG сайтов

Для изучения распределения **CpG** пар вдоль одной цепи ДНК, введем следующие количественные характеристики: плотность оснований **C** и **G** равна

$$\frac{N_C + N_G}{L} \cdot 100\%,$$

где $N_C + N_G$ — абсолютное количество оснований **C** и **G** в последовательности длиной L , выражаящейся числом нуклеотидов. Плотность **CpG** пар есть $\frac{N_{CpG}}{L} \cdot 100\%$

Очевидно, что при равномерном распределении всех четырех нуклеотидов плотность ($N_C + N_G$) будет равна 50 %. При этом в создании **CpG** пар будет участвовать $\frac{1}{4}$ всего цитозина, который также пойдет на образование других динуклеотидов **CT**, **CA**, **CC**. Но в реальности имеет место неравномерное распределение нуклеотидов, особенно на коротких отрезках. Допустим, что ни один цитозин не вовлечен в образование пар **CpG**, тогда число пар на этом участке будет равно 0. Предельно возможному количеству **CpG** пар соответствует случай, когда весь цитозин связывается только с гуанином, после цитозина в одиночной цепи всегда стоит гуанин, тогда количество таких пар будет определяться меньшим из N_C или N_G .

“Вовлеченность **CpG** пар” показывает, какая доля цитозина и гуанина участвует в образовании **CpG** пар

$$\frac{N_{CpG} \text{ наблюданное}}{(N_C + N_G)} 100\%.$$

“Эффективность образования **CpG** пар”

$$\frac{N_{CpG} \text{ наблюданное}}{N \text{ предельно возможное}} 100\%,$$

где “предельно возможное” число пар определяется меньшим из чисел N_C или N_G .

Введенные нами величины позволяют количественно характеризовать **CpG**-свойства нуклеотидной последовательности. В силу неравномерного распределения нуклеотидов вдоль одной цепи, вероятно, что эти свойства будут отличаться в функционально и эволюционно различных последовательностях ДНК. Таким образом, плотность **CpG** пар, вовлеченность и эффективность могут быть использованы в качестве характеристик нуклеотидных последовательностей, связанных с их эволюционным происхождением.

Графическое изображение **CpG** распределения

Ранее описание распределения **CpG** сайтов проводилось либо во всей последовательности в целом [5, 28], либо с помощью “скользящего окна”,двигающегося вдоль анализируемой последовательности.

Метод скользящего окна представляет содержание **CpG** сайтов в длинных последовательностях ДНК в виде кривой, пики которой соответствуют наблюдаемым частотам внутри сканирующего окна длиной, например, 500 нуклеотидов и шагом продвижения 10 нуклеотидов [29]. Этот метод не дает информации о характере распределения **CpG** сайтов внутри этого довольно большого окна и о положении **CpG** сайтов относительно границ функционально различных областей.

Нами предложен метод, который позволяет наглядно отобразить характер расположения **CpG** динуклеотидов внутри выбранного отрезка. По оси абсцисс откладывается порядковый номер нуклеотида в последовательности, а по оси ординат - суммарное количество встреченных **CpG** к данному моменту. Такое построение позволяет визуализировать динамику появления пар вдоль последовательности, то есть, тонкую **CpG** структуру. Угол наклона ступенчатой кривой может быть охарактеризован величиной, которую назовем плотностью накопления **CpG** пар. В нашей модели экстремальному случаю, когда последовательность состоит только из CGCGCGCG... соответствует угол наклона 45^0 . Если последовательность не содержит ни одного динуклеотида **CpG**, график представляется горизонтальной прямой, следовательно, угол наклона равен нулю. Все остальные графики располагаются в секторе от 0 до 45^0 . Графики были нормализованы на длину последовательности, что позволило их сравнивать по подобию.

РЕЗУЛЬТАТЫ

Проведенный анализ выявил различия в характере накопления **CpG** пар в генах разных белков разных организмов. Среди 997 генов *Thermotoga maritima* и 767 генов *Thermoplasma acidophilum* (в основном, это гены метаболических ферментов) содержание ($N_C + N_G$) больше 50% наблюдалось только у некоторых: в 70 (7,02%) генах *Thermotoga maritima* и в 51 (6,64%) генах *Thermoplasma acidophilum*. В среднем, ($N_C + N_G$) состав генов бактерий составлял около 46%, из которых вовлечено в образование **CpG** пар только 10,28% цитозина и гуанина. Содержание **CpG** сайтов у *Thermotoga maritima* – 4,9% что составляет почти четверть (24%) от максимально возможного числа **CpG** пар при данном наборе нуклеотидов – эффективность образования **CpG** пар (см. табл. 1). В 855 генах *Methanococcus jannaschii* G+C содержание не более 40%, из которых в 27 генах (3,16%) **CpG** пар вообще не было. Среднее содержание ($N_C + N_G$) составило 31,8%, вовлеченность 22,5%, а эффективность - 64,83%. Примечательно, что у бактерий соотношения нуклеотидов внутри кодирующих частей такие же, как и во всем геноме, чего нельзя сказать о других более высокоорганизованных видах.

При низком содержании **CpG** график накопления пар **CpG** в генах бактерий представляет беспорядочный набор точек. Графики последовательностей, в которых число **CpG** сайтов менее 10 на ген, не классифицировались. Например, область ДНК архебактерии (*Methanococcus jannaschii*) для гистонов A3 и A2 содержит всего 2-4 **CpG** пары, при длинах областей 250 -300 нуклеотидов, соответственно.

Местонахождение первой пары **CpG** у всех бактерий не показало никакой корреляции относительно начала гена, в то время как в генах человека имелось четкое предпочтение первой парой 5'- конца гена, независимо от его длины.

Таблица 1. Усредненные величины содержания **CpG** сайтов в проанализированных нуклеотидных последовательностях

Организм	CG%	C+G%	вовл.	эфф.	N генов	C+G% геном
<i>Thermotoga maritima</i>	4,90	45,93	10,66	24,40	997	46,25
<i>Thermoplasma acidophilum</i>	4,83	46,41	10,40	23,21	767	45,99
<i>Methanococcus jannaschii</i>	4,85	31,8	11,86	26,20	855	31,41
C. elegans II хромосома	3,11	34,81	8,93	18,28	5	34,82
кодирующая часть II хр.	4,82	45,55	10,5	23,40	5	-
гены II хр.	3,5	38,13	9,18	19,41	5	-
Drosophila melanog. III хр.	4,34	41,85	10,38	20,96	36	41,85
кодирующая часть	5,37	46,24	11,61	26,20	36	-
гены Dros.	5,59	48,41	11,54	23,77	36	-
mRNA Dros.	5,59	48,41	11,39	25,84	36	-
Dros. митохондр геном	0,68	17,85	3,79	8,92	14	17,84
тРНК митох. дроз.	0,42	20	2,1	4,12	14	-
Harpagifer antarcticus	2,43	55,48	4,37	9,57	4	
Pagothenia borchgrevinki	2,25	55,59	4,06	9,13	1	
Dissostichus.mawsoni	2,38	45,13	5,27	10,46	7	
Notothenia corriceps	2,61	55,67	4,69	10,53	2	
Homo sapiens VI хромосома	2,51	43,75	5,74	12,98	-	43,10
гистоновые гены	8,62	61,52	13,99	29,06	9	-
CG островки	7,79	62,14	12,54	26,89	24	-
локус гистосовместимости	5,23	60,61	8,65	22,73	16	-
цитохром P450	1,00	46,50	2,15	4,35	-	-

Интересно заметить, что внутри генов транспортной РНК бактерий содержание ($N_C + N_G$) и **GpC** было значительно выше, чем в других генах (см. табл. 1), в то время как **CpG** пары в 14 генах транспортной РНК *Drosophila melanogaster* не наблюдались, кроме одной тРНК для аргинина, содержащей 2 таких пары. Среднее содержание **G+C** было около 20%. Графики распределения **CpG** сайтов в последовательностях генов коллагена и 3 хромосомы нематоды (*Caenorhabditis elegans*) в общем случае аппроксимировались линейной функцией, хотя на коротких участках можно заметить уплотнение содержания пар **CpG** (Рис. 1). Среди 36 генов L плеча хромосомы 3 *Drosophila melanogaster* среднее **G+C** отмечалось несколько выше 48,41%, чем во всей хромосоме (41,85%). При этом доля **GpC** сайтов 5,59%, вовлеченность 11,39%, а эффективность 23,77%. В то время, как в митохондриальном геноме дрозофилы наблюдается низкое содержание **G+C**, всего лишь - 17,84%.

В проанализированных нами геномах бактерий нематоды и дрозофилы не отмечалось выраженной неоднородности в распределении **CpG**. Графики накопления **CpG** сайтов в последовательностях ДНК бактерий, дрозофилы и нематоды аппроксимированы линейной функцией, то есть появление **CpG** сайтов в анализируемой последовательности происходит случайно вне связи **CpG** сайта с положением относительно начала и конца гена (Рис. 2).

У позвоночных, в частности у человека, графики располагаются над или под прямой, связывающей максимальное количество **CpG** сайтов в конце анализируемой последовательности с началом координат, и выглядят выпуклыми (Рис. 3) или вогнутыми (Рис. 4) кривыми, что дает возможность систематизировать последовательности по подобию кривых и наглядно видеть распределение **CpG** пар относительно границ гена, кодирующих или сигнальных областей.




Рис. 1. График накопления CpG сайтов в гене гистонового белка H1 (*C. elegans*). На всех графиках: ось абсцисс — позиция в последовательности, ось ординат — кумулятивное количество CpG пар, первая строка — оригинальное название последовательности из GENBANK, а — угол наклона аппроксимирующей прямой, S — среднеквадратичное отклонение, К — коэффициент корреляции.




Рис. 2. Типичный график накопления CpG сайтов для бактериальных генов *Thermotoga maritima*.




Рис. 3. График накопления CpG сайтов в гене главного комплекса гистосовместимости класса I, B (*Homo sapiens*). Заметно повышение частоты встречаемости CpG в средней части гена.




Рис. 4. График распределения CpG сайтов в гене цитохрома с оксидазой человека

Проанализировано 14 генов 4 видов антарктических рыб, в том числе 4 гена антифризовых белков. В генах всех четырех видов отмечается невысокое среднее содержание **CpG** пар 3,55%, низкая вовлеченность – 5,52% и эффективность – 13,24%. Гены антифризовых гликопротеинов *Notothenia corriceps* и *Dissostichus mawsoni* содержат по одному инtronу, которые бедны в отношении **C+G** – 39,02% и 36%, **CpG** – 1,69% и 2,41%, соответственно, эффективность 15% и 14%, а вовлеченность 9% и 6%. Кодирующие части генов рыб содержат больше **C+G**, чем их полный ген и соответствующая ему мРНК в среднем на 6-15%, плотность **CpG** также увеличивается на 0,08 – 2,42%, вовлеченность и эффективность примерно постоянна в экзонах, генах и мРНК, но ниже, чем в интранах в 2 раза (см. табл. 1). График накопления **CpG** пар имеет характерную кривизну (Рис. 5.).

При анализе ДНК последовательностей генов человека были установлены следующие закономерности. Гены соматического цитохрома **c**, и убиквитинол-цитохром **c** редуктазы, в отличие от цитохрома P450, не содержат интранов. По сравнению с генами человека гены цитохромов мыши имеют в 2 раза меньший процент **CpG** пар. Гены цитохромов в локусе 22q12 расположены в относительно **CG** бедных областях – **C+G** 39 – 46%, хотя в экзонах цитохрома P450, в локусе 15q21.2 процент **C+G** больше – 59%. В указанных генах цитохромов отмечается низкая вовлеченность 2,8% и эффективность – 6,7%. Ген субъединицы 2 митохондриальной цитохром-оксидазы человека содержит мало гуанина, но отличается высокой эффективностью – 28 %. График накопления **CpG** пар гена цитохрома P450 имеет сложную форму, что, возможно, связано с интран-экзонной структурой.

Девять генов семейства гистоновых белков в локусе 6p21.3 (H1, H2AFN, H2AFI, H2AFD, H2AFE, H2B, H3FJ, H3FF, H4), относительно короткие – 354 - 487 нуклеотидов (кроме гена H1, длина которого в два раза больше – 856 нуклеотидов), не содержат интранов, имеют содержание ($N_C + N_G$) 58-60%. Кодирующие части генов имеют меньшую длину, чем мРНК, в среднем, на 50-100 нуклеотидов, за счет фланкирующих последовательностей, причем в мРНК этого типа генов отсутствуют 3'-poly(A)-концы. Вовлеченность общего количества ($N_C + N_G$) в образование пар в генах гистонов выше, чем в генах цитохромов – 13,99%, а эффективность образования пар 26%. Абсолютное число **CpG** пар в кодирующей области примерно такое же, как в мРНК, а плотности ($N_C + N_G$) содержания и **CpG** пар выше, чем в гене в среднем на 2,4% и на 2% соответственно, вовлеченность примерно одинакова в обоих случаях. Таким образом, пары **CpG** преимущественно находятся не в сигнальных и терминальных областях, а внутри транскрибуируемой последовательности.

Последовательность ДНК гистонового гена H1 отличается от других генов локуса по следующим параметрам. При наибольших длине гена и абсолютном количестве **CpG** пар плотность **CpG** пар наименьшая – 5,61%, как и вовлеченность ниже остальных – в среднем, на 4,5%.

Графики накопления **CpG** пар семейства восьми генов гистоновых белков аппроксимировались линейной функцией, а график гена гистона H1 отличается от остальных и имеет два всплеска повышения содержания **CpG** пар (Рис.6.). У нематоды *C. elegans* и дрозофилы *D. melanogaster*, ДНК которых не подвергается значительному метилированию, график накопления **CpG** сайтов для H1 также имеет линейную форму.

В **CG** островках наблюдаются довольно высокие показатели вовлеченности 12,66% и эффективности 26,89%. Графики накопления **CpG** пар в **CG** островках, как правило, имели слабо выраженный всплеск – увеличение плотности на 5' конце или в середине последовательности. Все островки имеют высокую плотность **C+G** содержания более 60% и плотность **CpG** пар 5,50 - 10,40 %, причем в 75% случаев первая пара находилась ближе двадцатого нуклеотида.

ОБСУЖДЕНИЕ

При условии случайного распределение пар график накопления **CpG** представляет собой линейную функцию. Наш анализ показал, что распределение **CpG** сайтов близко к случайному у бактерий и дрозофилы. Содержание ($N_C + N_G$) и частоты **CpG** сайтов внутри кодирующих областей генов бактерий не отличаются от усредненных частот по геному. Графики генов бактерий не имеют всплесков и аппроксимируются линейной функцией. Аналогичное распределение можно наблюдать в генах дрозофилы, а у нематоды и антарктических рыб определяются короткие всплески повышенного накопления **CpG** пар (Рис. 5.).

Гены антифризовых гликопротеинов обладают специфическими свойствами, например, они

Анализ тонкой CpG структуры последовательностей ДНК




Рис. 5. Распределение CpG сайтов в гене антифризового гликопротеина костицкой рыбы *Dissostichus mawsoni*.




Рис. 6. График накопления CpG сайтов в гене гистона H1 человека.

синтезируют большое число копий пептидов, а сами гликопептиды претерпевают посттрансляционные изменения [30]. В областях, объединяющих интроны и экзоны, наблюдается разный характер накопления **CpG** сайтов. Линейную аппроксимацию распределения **CpG** сайтов в ДНК бактерий и дрозофилы можно объяснить отсутствием механизма регуляции экспрессии генов путем метилирования цитозина в положении перед гуанином по 5-му атому и отсутствием (либо малой активностью, в случае дрозофилы) специфической ДНК метилазы в клетках указанных видов.

Для последовательностей генов белков человека показано наличие отклонений от случайного распределения **CpG** сайтов вдоль анализируемой последовательности ДНК. Различия в графиках распределения **CpG** сайтов для генов гистоновых белков можно было бы объяснить кодонной избирательностью (предпочтением **CG** содержащих кодонов) при похожем аминокислотном составе. Например, увеличение плотности **CpG** пар на графике – “всплеск”, может обусловлено расположением подряд идущих кодонов для аргинина, который, как известно, кодируется шестью кодонами, четыре из которых содержат **CpG**: **CGA, CGU, CGG, CGC, AGA AGG**. Но аргинином богаты белки Н2, Н3, Н4, а у Н1 аргинин встречается всего 3 (1,23%) раза на 242 аминокислоты. Таким образом, “всплеск” **CpG** пар, определяемый на графике, нельзя объяснить скоплением в этом месте кодонов для аргинина. Белок Н1 содержит аланин в 59 позициях, (из четырех кодонов которого **CpG** есть только у одного — **GCG, GCA, GCU, GCC**), а лизин в 65 позициях, кодоны которого вообще не содержат **CpG**. Другие аминокислоты в Н1 представлены глицином в 16 позициях, серином - 13, валином - 10. У нематоды белок Н1 (190 аминокислот) также богат аланином 37 и лизином 46, но, по сравнению с человеческим, богаче аргинином 4 (2,10%) и содержит серин в 11 позициях, а валин в 18. Из этого можно заключить, что всплески содержания **CpG** пар в гене белка Н1 являются не следствием избирательности **CpG** богатых кодонов, а возникают в силу каких-то других причин. То же можно сказать о белках локуса гистосовместимости, аминокислоты которого кодируются кодонами без **CpG** [31].

Последовательности для разных антигенов (класс I -HLA-G, HLA-C, HLA-B, HLA-Cw8.2, класс II антиген HLA-DRB4) имеют повышенную скорость накопления **CpG** сайтов на 5' конце и в середине, отчего графики этих генов имеют подобную друг другу выпуклую форму (Рис. 3.). В отличие от экзонов, интроны локуса HLA имеют повышенное содержание **CpG** сайтов на 3' конце. Если учесть, что гистоновые белки возникли в процессе эволюции еще в то время, когда процесс метилирования цитозина имел спонтанный характер и не имел функционального значения, тогда отсутствие закономерностей в метилировании ДНК коровых гистонов Н2А, Н2В, Н3 и Н4 можно объяснить их древним происхождением и консервативностью в эволюции. Причина отличия в характере распределения **CpG** сайтов (отражаемом на графике) для Н1, возможно, в том, что гистоновый белок Н1 эволюционно более молодой и приобрел черты, характерные для других белков. Остальные гистоны являются наиболее консервативными в эволюции белками и довольно сходны у разных видов [9].

ВЫВОДЫ

- Предложен метод количественного анализа и графического представления накопления **CpG** сайтов в последовательностях ДНК.
- С помощью введенных числовых характеристик и принципа подобия показано существование различий в накоплении **CpG** сайтов в ДНК генов организмов, отличающихся по эволюционному положению и наличию системы метилирования ДНК.
- Показано близкое к случайному распределение **CpG** сайтов в ДНК генов бактерий и дрозофилы, не обладающих системами метилирования ДНК, связанными с клеточной памятью.
- В ДНК генов нематоды и костистых рыб имеются короткие участки с повышенным содержанием **CpG** сайтов.
- Распределение **CpG** сайтов в ДНК генов человека отличается от случайного. Кодирующие области имеют большую плотность **CpG** сайтов, и относительно более значительная часть имеющегося в ДНК цитозина и гуанина участвует в образовании **CpG** пар, чем в генах и первичных транскриптах мРНК. Такая же тенденция отмечается у костистых рыб.
- Интроны антифризовидных белков костистых рыб содержат меньше **CpG** сайтов, чем их экзоны. У дрозофилы и нематоды плотности **CpG** сайтов внутри кодирующей части и в первичных транскриптах почти одинаковы. У бактерий плотность **CpG** сайтов внутри генов и в среднем по геному не отличаются. У человека интроны антигенов HLA локуса имеют увеличенную плот-

ность **CpG** сайтов на 3' конце. Имеется предпочтительное расположение **CpG** сайтов на 5' конце в генах локуса гистосовместимости, гена микрофибрillлярного белка, а также в **CpG** островках.

7. Гены гистоновых белков имеют высокую плотность **CpG** сайтов – 8–10%, при этом гены гистонов H2AFN, H2AFI, H2AFD, H2AFE, H2B, H3FJ, H3FF, H4 отличаются по характеру накопления **CpG** сайтов от гистона H1.

8. Распределение **CpG** сайтов ДНК у видов разных таксономических групп связано с действием мутационного процесса и естественного отбора. Графически можно выделить различные образцы накопления **CpG** сайтов. Для видов, у которых метилирование ДНК не имеет регуляторного значения в процессах импринтинга и клеточной памяти, характерно случайное распределение **CpG** сайтов.

Благодарности. Авторы выражают благодарность В. Калашникову за создание оригинальных компьютерных программ (Perl, C++) и проявленное терпение, Г. Ч. Курильному за полезные советы по статистическому анализу, Н. А. Чащину за интерес к работе, а также С. А. Дуплию за многочисленные обсуждения и дискуссии в течение всей работы, помочь в проведении и интерпретации числовых расчетов, оформление текста и общую поддержку.

СПИСОК ЛИТЕРАТУРЫ

1. Szczepanik D., Mackiewicz P., Kowalcuk M. // J. Mol. Evol. 2001. V. 52. P. 426–433.
2. Kowalcuk M., Mackiewicz P., Mackiewicz D. // J. Appl. Genet. 2001. V. 42. P. 553–577.
3. Cebrat S., Dudek M. R., Mackiewicz P. // Theory Biosci. 1998. V. 117. P. 78–89.
4. Сингер М., Берг П. Гены и геномы. Т. 1. М.: Мир, 1998. 373 с.
5. Bulmer M. // Mol. Biol. Evol. 1987. V. 4. P. 395–405.
6. Kowalcuk M., Mackiewicz P., Mackiewicz D., Nowicka A., Dudkiewicz M., Dudek M. R., Cebrat S. // BMC evolutionary biology. 2001. V. 17. P. 1–13.
7. Aissani B., Bernardi G. // Gene. 1991. V. 106. P. 173–183.
8. Mouchiroud D., D'Onofrio G., Aissani B., et al // Gene. 1991. V. 100. P. 181–187.
9. Глазко В. И., Шульга Е. В., Дымань Т., Глазко Г. В. ДНК технологии и биоинформатика в решении проблем биотехнологий млекопитающих. Белая Церковь: Белоцерк. гос. аграр. унив., 2001. 487 с.
10. Сингер М., Берг П. Гены и геномы. Т. 2. М.: Мир, 1998. 391 с.
11. Льюин Б. Гены. М.: Мир, 1987. 544 с.
12. Bird A. // Genes and Development. 2002. V. 16. P. 6–21.
13. Ramsahoye B., Biniszkiewicz D., Lyko F., Clark V., Bird A. P., Jaenisch R. // Proc. Natl. Acad. Sci. USA. 2000. V. 97. P. 5237–5242.
14. Low D. A., Weyand N. J., Mahan M. J. // Infection and Immunity. 2001. V. 69. P. 7197–7204.
15. Yoon J.-H., Smith L. E., Feng Z., Tang M.-S., All // Cancer research. 2001. V. 1. P. 7110–7117.
16. Bird A. P. // Nature. 1986. V. 321. P. 209–213.
17. Antequera F., Bird A. // Proc. Natl. Acad. Sci. U.S.A. 1993. V. 90. P. 11995–11999.
18. Bird A. P. // Nucleic acids research. 1980. V. 8. P. 1499–1504.
19. Gardiner-Garden M., Frommer M. // J. Mol. Biol. 1987. V. 196. P. 261.
20. Venter J. C., Adams M. D., Myers E. W., et al // Science. 2001. V. 291. P. 1304–1351.
21. Antonarakis S. E. // Genome linkage scanning: Systematic or intelligent? Nature Genet. 1994. V. 8. P. 211–212.
22. Cross S. H., et al // Mamm. Genome. 2000. V. 11. P. 373.
23. Vu T. H., Li T., Nguyen D., Nguyen B. T., Yao X.-M., Hu J.-F., Hoffman A. R. // Genomics. 2000. V. 64. P. 132–143.
24. Пузырев В. П., Степанов В. А. Патологическая анатомия генома человека. Новосибирск: Наука, 1997. 265 с.
25. Nakao M., Sasaki H. // J. Biochem. 1996. V. 120. P. 467–473.
26. Зерова Т. Е., Бужієвська Т. І // Генетика і селекція в Україні на межі тисячоліть. Київ. Логос, 2001. С. 482–493.
27. Lyon M. F. // Cytogenet. Cell Genet. 1998. V. 80. P. 133–137.
28. Kanaya S., Yamada Y., Kinouchi M., Kudo Y., Ikemura T. // J. Mol. Evol. 2001. V. 53. P. 290–298.
29. Shimizu T. S., Takahashi K., Tomita M. // Gene. 1997. V. 205. P. 103–107.
30. Hsiao K., Cheng C.-H. C., Fernandes I. E. // Proc. Natl. Acad. Sci. USA. 1990. V. 87. P. 9265–9269.
31. Tykosinski M. L., Max E. E. // Nucl. Acids Res. 1984. V. 12. P. 4385–4396.