

БИОИНФОРМАТИКА

УДК 577.113.3:57.087.1

## ОСОБЕННОСТИ НУКЛЕОТИДНЫХ ПОСЛЕДОВАТЕЛЬНОСТЕЙ ЗРЕЛЫХ микроРНК МОГУТ ВЛИЯТЬ НА СРОДСТВО К БЕЛКАМ AGO2 И AGO3 ЧЕЛОВЕКА

© 2011 г. Н. А. Омельянчук<sup>1</sup>, П. М. Пономаренко<sup>1, 2</sup>, М. П. Пономаренко<sup>1\*</sup>

<sup>1</sup>Институт цитологии и генетики Сибирского отделения Российской академии наук, Новосибирск, 630090

<sup>2</sup>Новосибирский государственный университет, Новосибирск, 630090

Поступила в редакцию 25.03.2010 г.

Принята к печати 12.07.2010 г.

Зрелые микроРНК (miРНК) длиной от 20 до 24 н. относят к эндогенным малым некодирующими РНК. miРНК определяют взаимодействие комплекса белков (RISC), связывание которого с miРНК программирует способность RISC подавлять трансляцию мРНК, которые содержат сайты, комплементарные miРНК. Это взаимодействие приводит к ингибиции трансляции с мРНК, если в этот комплекс входит белок Ago3, в случае Ago2 возможно также разрезание мРНК в центре гетеродуплекса мРНК/miРНК. С помощью созданной нами ранее компьютерной системы ACTIVITY мы проанализировали литературные данные о сродстве последовательностей зрелых miРНК человека к белкам Ago2 и Ago3. Обнаружено, что сродство miРНК к обоим белкам тем выше, чем больше содержание тетрануклеотидов YRHB вблизи 3'-конца miРНК ( $r = 0.613$ ,  $\alpha < 0.025$ ), и связывание miРНК с Ago2 по сравнению с Ago3 растет с увеличением содержания тетрануклеотидов RHHK вблизи центра miРНК ( $r = 0.501$ ,  $\alpha < 0.05$ ). На основе этих двух закономерностей мы вывели формулы для прогноза величин сродства зрелых miРНК к белкам Ago2 и Ago3 и достоверно на независимых данных предсказали сродство к каждому из них для канонических ( $\alpha < 0.00025$ ) и неканонических miРНК ( $\alpha < 0.05$ ).

**Ключевые слова:** микроРНК, нуклеотидная последовательность, RISC, белки Ago, сродство, прогноз.

THE NUCLEOTIDE SEQUENCE FEATURES OF THE MATURE microRNA SEEM TO BE RESPONSIBLE FOR THE AFFINITY TO HUMAN AGO2 AND AGO3 PROTEINS, by N. A. Omelyanchuk<sup>1</sup>, P. M. Ponomarenko<sup>2</sup>, M. P. Ponomarenko<sup>1,\*</sup> (<sup>1</sup>Institute of Cytology and Genetics, Siberian Division, Russian Academy of Sciences, Novosibirsk, 630090 Russia; <sup>2</sup>Novosibirsk State University, Novosibirsk, 630090 Russia; \*e-mail: pon@bionet.nsc.ru). Mature miRNA of 20–24 nt in length are the endogenous sncRNAs. They programs RISC to regulate functioning of mRNA with complimentary sites for these miRNAs. In case of Ago3 protein present in human RISC miRNAs direct inhibition of translation, whereas in case of Ago2 is in RISC, than mRNA cleavage in the middle of miRNA/mRNA heteroduplex is also possible. Using ACTIVITY system, that we developed earlier, we analyzed published data on miRNA affinity to human Ago2 and Ago3 proteins. We found increase in miRNA affinity to both Ago2 and Ago3 with the increase of the YRHB tetranucleotide abundance near 3'-end of these miRNAs ( $r = 0.613$ ,  $\alpha < 0.025$ ). We also found that miRNA tendency to bind Ago2 in favor of Ago3 increases with the RHHK tetranucleotide abundance near miRNA center ( $r = 0.501$ ,  $\alpha < 0.05$ ). Using these two findings we proposed two formulas to predict miRNA affinity to Ago2 and Ago3 proteins based on the YRHB and RHHK abundances within this arbitrary miRNA. Thereby we made reliable predictions of miRNA affinity to these proteins in RISC for both canonical ( $\alpha < 0.00025$ ) and non-canonical ( $\alpha < 0.05$ ) miRNAs in comparison with independent experimental data.

**Keywords:** microRNA, nucleotide sequence, RISC, argonaute proteins (Ago), affinity, prediction.

Принятые сокращения: miРНК – микроРНК; миРНК – малая некодирующая РНК; мРНК – матричная РНК; н. – нуклеотид (в качестве единицы длины нуклеотидной последовательности РНК); RISC – комплекс белков, связывание которого с miРНК программирует его биологическую активность на ингибирование трансляции мРНК-мишеней (сокращение от “RNA-Induced Silencing Complex”); MPSS – метод измерения содержания РНК в клетке (сокращение от “Massively Parallel Signature Sequencing”).

\* Эл. почта: pon@bionet.nsc.ru

## ВВЕДЕНИЕ

МикроРНК (miРНК) относят к эндогенным малым некодирующему РНК. Сначала РНК-полимераза II транскрибирует ген miРНК с образованием первичного транскрипта, из которого затем вырезается предшественник и, наконец, получается зрелая miРНК длиной 20–24 н. [1, 2]. Зрелая miРНК человека взаимодействует с белками Ago1, Ago2, Ago3 или Ago4 семейства Argonaute [3] в составе комплекса белков (RISC), связывание которого с miРНК определяет его способность ингибировать трансляцию мРНК-мишеней и способность препятствовать трансляции тех мРНК, в которых есть сайт, комплементарный этой miРНК [1, 2]. Если в состав RISC входит Ago3, то ингибируется сам процесс трансляции, если вместо Ago3 включен Ago2, то возможно также разрезание мРНК в центре miРНК/мРНК-гетеродуплекса [4, 5]. В известной пространственной структуре комплекса мРНК/мнкРНК/Ago *Pyrococcus furiosus* [6] белок Ago связывает 3'-конец мнкРНК (малая некодирующая РНК) [6].

Зрелая miРНК в клетке может быть представлена ее основной последовательностью (“каноническая форма”) и модификациями этой канонической формы за счет замен, делеций и/или вставок нуклеотидов (“неканонические формы”) [5]. В клетках присутствует многократно больше копий канонических miРНК, чем неканонических. Неканонические формы miРНК общепринято ассоциировать с ошибками биогенеза и с биохимическими модификациями зрелой канонической miРНК. Итогом секвенирования библиотек зрелых miРНК, специфичных для Ago2 или для Ago3, стало обнаружение как неразличимо равного сродства к обоим этим белкам в случае большинства miРНК, так и достоверного предпочтения одного из этих белков перед другим в случае остальных miРНК [5].

В этой работе мы применили созданную ранее компьютерную систему ACTIVITY [7] для анализа парных данных “последовательность нуклеотидов, количественная величина”. С ее помощью мы ранее выявляли достоверные особенности контекста, например, TATA-бокса эукариот [8], филамента RecA/ДНК [9], горячих точек мутаций ДНК и сайтов 3'-разрезания пре-мРНК [10], мишней мобильных элементов [11], сайтов регуляции транскрипции [12] и полиморфизмов, ассоциированных с болезнями человека [13]. Показана возможность адаптации прогнозов ACTIVITY к условиям различных опытов [14] и совместимость этих прогнозов с другими источниками [15].

В предыдущей работе [16] с помощью ACTIVITY мы нашли корреляцию между микрочип-измерениями [17] содержания зрелых канонических miРНК *Arabidopsis thaliana* и тетрануклеотидов WRHW, DRYD (номенклатура IUPAC-IUB, [18]) в этих miРНК. Прогноз содержания miРНК в клетках на основе этой корреляции [16] был в достоверном со-

гласии с независимыми результатами метода измерения содержания РНК в клетке (MPSS) [19]. Этим мы впервые показали, что, несмотря на очень малую длину ≈20 н., miРНК способны нести биологические значимые контекстные мотивы (DRYD вблизи 3'-конца, WRHW вблизи центра), положение и количество которых в последовательности miРНК достоверно коррелируют с содержанием этой miРНК в клетке. Контекстные характеристики могут определять и другие аспекты функционирования miРНК, например, в работе [20] на клетках HeLa по различию зрелых miРНК miR-29a и miR-29b человека также нашли два контекстных мотива (U в центральной позиции 10 и 3'-конец AGUGUU), определяющих преимущественную локализацию miR-29b в ядре клетки.

Общепринято, что все стадии процессинга miРНК (транскрипция → биогенез → диссоциация miРНК/RISC → деградация miРНК) влияют на содержание miРНК в клетке. Однако в последнее время накапливается все больше и больше данных, что во многих случаях лимитирующим звеном в этой цепи может быть диссоциация miРНК/RISC [20–24]. Так, при овуляции в клетках яичника мыши за кратковременным импульсным приростом уровня лютеинизирующего гормона наблюдали такие же импульсные появления первичных транскриптов с генов miРНК *Mirn132* и *Mirn212* [21]. В свою очередь, зрелые miРНК с этих транскриптов регистрировали на высоком уровне долгое время спустя после исчезновения их предшественников. Время полужизни некоторых зрелых miРНК может достигать 14 дней [22], тогда как биогенез от первичного транскрипта до зрелой miРНК может протекать настолько быстро, что промежуточные продукты не всегда можно зарегистрировать [2]. Таким образом, в клетке зрелые miРНК большую часть их жизни связаны с RISC. Комплекс мнкРНК с RISC обладает высокой стабильностью [23]. Освобождение miРНК от RISC приводит к немедленной деградации этой miРНК и регулируется наличием ее мРНК-мишени [24]. Если же лимитирующая стадия накопления miРНК в клетке – диссоциация miРНК/RISC [20–24], то из найденной нами ранее достоверной корреляции между контекстом и содержанием miРНК в клетке [16] с необходимостью следует корреляция между контекстом miРНК и сродством miРНК/RISC. В предлагаемой статье мы проверяем именно это следствие нашей предыдущей работы.

С помощью ACTIVITY мы проанализировали величины сродства miРНК к белкам Ago2 и Ago3 из RISC человека [5]. В результате мы обнаружили увеличение сродства miРНК к обоим Ago2 и Ago3 при увеличении содержания YRHB [18] вблизи 3'-конца зрелой miРНК ( $r = 0.613$ ,  $\alpha < 0.025$ ). Нами также показано, что предпочтение miРНК к Ago2 перед Ago3 растет с увеличением количества RHНK вблизи центра miРНК ( $r = 0.501$ ,  $\alpha < 0.05$ ). Используя эти закономерности, мы вывели формулы прогноза срод-

ства последовательностей зрелых miPHK к белкам Ago2 и Ago3 по содержанию YRHB и RHHK в определенных районах этих последовательностей. С помощью этих формул мы впервые достоверно предсказали сродство канонических ( $\alpha < 0.00025$ ) и неканонических ( $\alpha < 0.05$ ) miPHK к белкам Ago2 и Ago3 на независимых данных из работы [5].

## ЭКСПЕРИМЕНТАЛЬНАЯ ЧАСТЬ

### *Исследуемые литературные данные о сродстве miPHK к белкам Ago2 и Ago3 человека*

Мы анализировали для 28 зрелых канонических (табл. 1) и 48 неканонических (табл. 2) miPHK, опубликованных в работе [5, дополнение], последовательности  $S = \{s_1 \dots s_{22}\}$  длины 22 н., где  $s_{22}$  – 3'-конец miPHK. Поскольку последовательности зрелых канонических miPHK имели длину не менее 22 н., то мы игнорировали нуклеотиды 5'-конца канонических miPHK длиннее 22 н. и неканонические miPHK короче 22 н. Величины  $A_2$  и  $A_3$  сродства miPHK к белкам Ago2 и Ago3 человека соответственно, изменяющиеся в пределах от 2.30 до 9.43 натуральных логарифмических ( $\ln$ ) единиц для всех  $28 + 48 = 76$  miPHK, брали из дополнения к работе [5]. Всего мы проанализировали 76 наборов  $\{S_n, A_{2,n}, A_{3,n}\}_{1 \leq n \leq 76}$ , для каждой  $n$ -й зрелой miPHK: ее последовательность длиной 22 н. от 3'-конца и две величины сродства, к Ago2 и к Ago3.

### *Поиск корреляций между контекстами особенностями последовательностей зрелых miPHK и величинами их сродства к Ago2 и Ago3 белкам*

Мы искали корреляции порядка  $S = \{s_1 \dots s_i \dots s_{22}\}$  нуклеотидов  $s_i \in \{A, U, G, C\}$  в miPHK с величинами  $A_2$  и  $A_3$  ее сродства к Ago2 и Ago3, соответственно, с помощью ACTIVITY [7]. Ранее мы описали важные различия в применении системы ACTIVITY в случае анализа экспериментальных данных о связывании ДНК/белок [8], филаментации [9], мутагенезе [10], мишени мобильного элемента [11], сайтах регуляции транскрипции [12], точечном полиморфизме [13], *in vitro* селекции аптамеров ДНК [14], многошаговых процессах [15] и содержании miPHK в клетке [16]. Новшеством этой работы стали три важные особенности применения ACTIVITY [7–16] в случае дивергенции гомологичных белков от их общего предка ( $\text{Ago2} \leftarrow \text{предок} \rightarrow \text{Ago3}$  [3]) с использованием величин их сродства к зрелым miPHK [5].

Во-первых, для анализа обоих Ago2 и Ago3 одновременно мы заменили независимые измерения  $A_2$  и  $A_3$  [5] двумя вспомогательными оценками ( $\Sigma = (A_2 + A_3)/2$  и  $\Delta = (A_2 - A_3)/2$ ) на их основе. Мы эвристически ассоциировали оценку  $\Sigma$  с ко-адаптацией контекстов древних miPHK и общего предка белков Ago2 и Ago3 на ранних этапах их ко-эволюции,

оценку  $\Delta$  – с ко-адаптацией контекстов потомков этих древних miPHK при эволюционной дивергенции Ago2 и Ago3. Благодаря филогенетической инерции [25], сохранение современными miPHK этих двух разных особенностей их контекста соответствует одному из выводов статьи [5], данные которой мы использовали для нашего анализа: большинство miPHK имеют неразличимо равное сродство к обоим Ago2 и Ago3, тогда как остальные имеют значимое предпочтение к одному из этих белков перед другим.

Во-вторых, поскольку исходные экспериментальные данные содержали как близкородственные miPHK (например, табл. 1: № 24–26: hs-miR-19a, hs-miR-19b-1 и hs-miR-19b-2), так и отдаленные, то для преодоления этой естественной их несбалансированности мы сформировали репрезентативный набор их представителей для анализа с помощью ACTIVITY. Из указанных авторами работы [5] самых надежных случаев № 1–20 (табл. 1) мы выбрали лишь случаи минимальных и максимальных величин  $A_2$ ,  $A_3$ ,  $\Sigma$ ,  $\Delta$  и частот нуклеотидов A, U, G, C, W, R, M в miPHK (табл. 1, № 1–12). Поэтому набор данных для анализа представлял диапазоны исследуемых величин и контекстное разнообразие канонических miPHK [5], а не естественную гетерогенность результатов измерений. Система ACTIVITY не анализировала канонические miPHK № 13–28 и неканонические miPHK.

В-третьих, поскольку мы проверяли следствие найденной нами ранее [16] корреляции между содержанием miPHK в *A. thaliana* и содержанием WRHW и DRYD в miPHK, то здесь ACTIVITY вновь анализировала все возможные тетрануклеотиды  $z_1 z_2 z_3 z_4$ , ядра нуклеации гетеродуплекса miPHK/mPHK [26], вычисляя для каждого из  $15^4 = 50625$  тетрануклеотидов взвешенные содержания [16]:

$$[z_1 z_2 z_3 z_4]_F(s_1 \dots s_i \dots s_{22}) = \sum_{i=1}^{19} F(i) \prod_{k=1}^4 \delta(s_{i+k-1} \in z_k), \quad (1)$$

здесь:  $z_k \in \{A, U, G, C, W, R, M, K, Y, S, B, V, H, D, N\}$  [18];  $F(i)$  – вес  $z_1 z_2 z_3 z_4$  в  $i$ -ой позиции miPHK, линейно-аддитивная аппроксимация его вклада в сродство miPHK к белку на основе эвристического правила: “чем выше  $F(i)$ , тем больше вклад”;  $\delta(\text{истина}) = 1$ ,  $\delta(\text{ложь}) = 0$ .

В качестве примера наибольшего вклада центра miPHK в сродство к белкам Ago на рис. 1 разрывной линией показан Л-образная весовая функция  $F(i)$ . Непрерывной V-образной линией показан пример функции взвешивания для случая наибольшего влияния 3'-конца miPHK на ее сродство к белкам Ago. Всего ACTIVITY [7–16] анализировала 90 V- и 90 Л-образных  $F(i)$  с одним пиком. При этом положение, ширину и степень асимметрии пика изменяли, что привело к  $2 \times 90 \times 15^4 \approx 10^7$  вариантам  $[z_1 z_2 z_3 z_4]_F$ .

**Таблица 1.** Средство канонических miРНК к белкам Ago2 и Ago3 человека [5],  $\Delta_2$  и  $\Delta_3$ , и результаты его анализа с помощью ACTIVITY [7]

№	код miРНК	Исходные экспериментальные данные из работы [5, дополнение]	Анализ (№ 1–12) и независимый контроль (№ 13–28)				<i>In silico</i> прогноз	
			$A_2$	$A_3$	$\Delta = (A_2 - A_3)/2$	[RHHK] $_{\Lambda}$	$\Sigma = + (A_2 + A_3)/2$	[YRHB] $_{\Lambda}$
1	hs-miR-342	последовательность miРНК*	7.81	4.85	1.48	1.95	6.33	0.77
2	hs-miR-21	uCUCACACAGAAAUCGCACCCGU	8.34	7.24	0.55	1.59	7.79	1.45
3	hs-miR-378	UAGCUUAUCAGACUGAUGUUGA	4.97	5.89	-0.46	1.26	5.43	0.00
4	hs-miR-629	ACUGGACULUGGAGUCAGAACGGC	5.28	7.98	-1.35	0.91	6.63	0.37
5	hs-miR-92b	GUUCUCCCACCGUAAGGCCAGC	6.48	8.98	-1.25	0.22	7.73	1.06
6	hs-miR-221	UAUUGCACUCGUCCCCGGCCUCC	6.08	5.26	0.41	2.37	5.67	0.50
7	hs-miR-29c	AGCUACAUUGUCUGCUGGGUUU	6.08	6.05	0.02	1.36	6.06	0.42
8	hs-miR-210	UAGCACCAUUUGAAAUUCGGGUUA	6.08	7.96	-0.57	0.59	7.38	1.32
9	hs-let-7d	CUGUGCGUGUGACAGCGGGCGUA	6.81	7.96	-0.57	0.59	7.38	1.32
10	hs-miR-99b	CUAUACGACCUGCUGCCUUUCU	6.49	6.46	0.01	1.53	6.47	1.00
11	hs-miR-191	CACCCGUAGAACCGACCUUGCG	8.55	6.70	0.92	1.43	7.62	2.09
12	hs-miR-425	CAACGGAAUCCAAAAGCAGCU	6.40	7.47	-0.53	1.05	6.94	0.82
13	hs-miR-93	aAUGACACGAUCACUCCGUUGA	7.33	8.50	-0.59	0.10	7.92	1.99
14	hs-miR-532	aCUGCUGAGCUAGCACUTCCCCA	5.69	6.62	-0.46	0.38	6.16	1.13
15	hs-miR-28	CAUGCCUUGAGGUAGGGACCGU	7.21	8.45	-0.62	0.71	7.83	1.40
16	hs-miR-25	CAUUGCACUUGUCUGCUGGUCUGA	6.56	6.15	0.20	1.69	6.36	1.06
17	hs-miR-29a	CAUAGCAUUCUGAAAUCGGUUUA	6.05	5.89	0.08	1.36	5.97	0.42
18	hs-miR-23a	UACACAUUGCCAGGGAUUUCCA	5.49	6.05	-0.28	1.15	5.77	0.30
19	hs-miR-26a-1	UUCAAGUAUCCAGGAUAGGCCU	5.35	6.05	-0.35	0.11	5.70	0.58
20	hs-miR-26a-2	UUCAAGUAUCCAGGAUAGGCCU	5.35	6.05	-0.35	0.11	5.70	0.58
21	hs-miR-92a-1	UAUUGCACUUGUCGGGGCCUGU	7.95	8.03	-0.04	1.01	7.99	1.06
22	hs-miR-92a-2	UAUUGCACUUGUCGGGGCCUGU	7.94	8.03	-0.04	1.01	7.98	1.06
23	hs-miR-484	UCAGGGCUCAGGUCCCCUCCGAU	7.69	7.58	0.06	0.00	7.63	1.00
24	hs-miR-19a	uGUGCAAAUUCUAUGCAAACUGA	5.72	5.30	0.21	1.42	5.51	0.10
25	hs-miR-19b-1	uGUGCAAAUCCAUUGCAAACUGA	5.71	5.29	0.21	0.63	5.50	0.10
26	hs-miR-19b-2	uGUGCAAAUCCAUUGCAAACUGA	5.72	5.29	0.22	0.63	5.50	0.10
27	hs-miR-501	AAUGCACCCGGCAAGGAUUCUC	5.68	5.57	0.05	0.20	5.62	0.47
28	hs-miR-150	UCUCCCAACCCUUUGUACCAGUG	8.79	9.43	-0.32	0.00	9.11	0.73

Коэффициент линейной корреляции,  $r$  (№ miРНК или все)

Статистическая значимость,  $\alpha < (№$  miРНК или все)

\* Анализ — заглавные буквы.

**Таблица 2.** Сродство неканонических miPHK к Ago2 и к Ago3 [5] и его прогноз (формулы (4), (5))

Каноническая miPHK	Неканоническая miPHK*	Ago2, A <sub>2</sub>		Ago3, A <sub>3</sub>		(A <sub>2</sub> + A <sub>3</sub> )/2		A <sub>2</sub> – A <sub>3</sub>	
		[5]	(4)	[5]	(5)	[5]	(4),(5)	[5]	(4),(5)
hs-miR-150	CUCCCAACCCUUGUACCAGUGU	2.64	5.80	2.56	6.94	2.60	6.37	0.07	-1.14
	UCUCCCACCCUUGUACCAGUGU	6.27	5.80	6.63	6.94	6.45	6.37	-0.35	-1.14
	UCUCCCACCCUUGUACCAGUGA	5.89	5.80	6.50	6.94	6.20	6.37	-0.61	-1.14
	UCUCCCACCCUUGUACCAGUGC	4.95	5.80	5.57	6.94	5.26	6.37	-0.62	-1.14
	UCUCCCACCCUUUUACCAGUG	3.85	5.96	3.40	7.10	3.63	6.53	0.45	-1.14
	UCUCCCACCCUUGUACCAGUU	3.43	5.96	2.56	7.10	3.00	6.53	0.87	-1.14
	UCUCCCACCCUUGUACCAGUA	3.14	5.96	4.26	7.10	3.70	6.53	-1.13	-1.14
	UCUCCCACCCUUGCACCAGUG	2.89	5.96	2.77	7.10	2.83	6.53	0.12	-1.14
	UCUCCCACCCUCGUACCAGUG	2.48	5.96	3.14	7.10	2.81	6.53	-0.65	-1.14
	uGUCUCCCACCCUUGUACCAGU	2.40	6.21	2.30	7.24	2.35	6.73	0.10	-1.03
hs-miR-92a	UAUUGCACUUGUCCCCGGCUUU	4.28	6.93	3.56	7.01	3.92	6.97	0.72	-0.08
	UAUUGCACUUGUCCCCGGCCUGA	3.74	6.93	4.20	7.01	3.97	6.97	-0.47	-0.08
	UAUUGCACUUGUCCCCGGCCUGA	3.61	5.80	4.17	6.08	3.89	5.94	-0.56	-0.28
	UAUUGCAUUGUCCCCGGCCUGU	3.58	7.15	3.18	6.78	3.38	6.97	0.41	0.37
	UAUUGCACUUUUCCCGGCCUGU	3.26	6.79	3.40	6.87	3.33	6.83	-0.14	-0.08
	UAUUGCACUUGUCCCCGGCCUCU	2.83	6.93	2.77	7.01	2.80	6.97	0.06	-0.08
hs-miR-484	UAUUGCACUUGUCCCCGGCCUGUU	2.48	7.15	3.85	7.42	3.17	7.29	-1.37	-0.27
	UCAGGCUCAGUCCCCUCCCGUU	3.53	6.31	4.08	7.45	3.81	6.88	-0.55	-1.14
	uCAGGCUCAGUCCCCUCCCGAUU	4.92	6.33	6.41	7.36	5.67	6.85	-1.49	-1.03
	UCAGGCUCAGUCCCCUCCCGAA	3.33	4.97	4.39	6.10	3.86	5.54	-1.06	-1.13
hs-miR-425	uCAGGCUCAGUCCCCUCCCGAAA	2.89	4.97	4.28	6.10	3.59	5.54	-1.39	-1.13
	uCAGGCUCAGUCCCCUCCCGAUA	2.64	6.28	4.96	7.42	3.80	6.85	-2.32	-1.14
	AaAUGACACGAUCACUCCCGUUGA	2.30	7.71	3.50	8.74	2.90	8.23	-1.19	-1.03
	AUGACACGAUCACUCCCGUUGA	4.42	7.71	5.19	8.74	4.81	8.23	-0.77	-1.03
hs-miR-532	AAUGACACGAUCACUCCCGUUG.	5.96	7.59	4.57	8.51	5.27	8.05	1.38	-0.92
	AAUGACACUAUCACUCCCGUUGA	3.64	7.70	4.65	8.73	4.15	8.22	-1.02	-1.03
	AAUGACACGAUCACUCCCUUUGA	3.00	6.44	2.40	7.58	2.70	7.01	0.60	-1.14
	CAUGCCUUGAGUGUAGGACCGA	2.83	7.23	3.47	7.63	3.15	7.43	-0.63	-0.40
hs-miR-210	cAUGCCUUGAGUGUAGGACCGUA	3.09	6.41	4.52	6.74	3.81	6.58	-1.43	-0.33
	CAUGCCUUGAGUGUAGUACCGU	2.71	8.45	2.83	8.84	2.77	8.65	-0.13	-0.39
	cAUGCCUUGAGUGUAGGACCGUU	2.64	7.76	2.64	8.09	2.64	7.93	0.00	-0.33
	CAUGCCUUGAGUGUAGACCGU	2.40	8.84	2.83	9.23	2.62	9.04	-0.44	-0.39
hs-miR-92b	CUGUGCGUGUGACAGCGGCUGAU	3.09	9.03	3.61	9.35	3.35	9.19	-0.52	-0.32
	CUGUGCGUGUGACAGCGGCUGAA	2.71	7.68	3.43	8.00	3.07	7.84	-0.73	-0.32
	CUGUGCGUGUGACAUCGGCUGU	2.64	7.06	2.83	7.58	2.74	7.32	-0.19	-0.52
	CUGUGCGUGUGACAUCGGCUGA	2.56	7.53	2.94	7.83	2.75	7.68	-0.38	-0.30
hs-miR-21	UAUUGCACUCGUCCCCGGCCUCA	3.37	6.52	6.08	7.42	4.73	6.97	-2.72	-0.90
	UAUUGCACUCGUCCCCGGCCUCU	2.77	6.52	5.35	7.42	4.06	6.97	-2.58	-0.90
	uAUUGCACUCGUCCCCGGCCUCCU	2.30	5.48	5.81	6.40	4.06	5.94	-3.51	-0.92
	UAGCUUAUCAGACUGAUGUUGAC	7.34	9.00	4.13	8.11	5.74	8.56	3.21	0.89
hs-miR-93*	UAGCUUAUCAGACUGAUGUUGAA	2.94	7.65	3.43	6.77	3.19	7.21	-0.49	0.88
	ACUGCUGAGCUAGCACUCCCG	4.66	6.64	5.58	7.23	5.12	6.94	-0.92	-0.59
hs-miR-29c	aCUGCUGAGCUAGCACUCCCGU	3.50	6.70	3.56	7.43	3.53	7.07	-0.06	-0.73
	UAGCACCAUCUGAAAUCGGUUA	4.30	6.25	4.36	5.97	4.33	6.11	-0.05	0.28
hs-miR-191	CAACGGAAUCCCAAAGCAGCUG	5.15	5.53	4.98	5.54	5.07	5.54	0.17	-0.01
hs-miR-221	AGCUACAUUGUCUGCUGGGUUUC	4.51	6.78	3.22	5.58	3.87	6.18	1.29	1.20
hs-miR-99b	CACCCGUAGAACCGGACCUUGCGA	5.04	7.29	3.00	6.89	4.02	7.09	2.05	0.40
hs-let-7d	CUAUACGACCUGCUGGCCUUUCA	2.64	7.11	2.64	6.66	2.64	6.89	0.00	0.45
Линейная корреляция, $r(\alpha)$		-0.01 (>0.9)		-0.1 (>0.3)		-0.18 (>0.2)		0.468 (<0.001)	
Ранговая корреляция Кендалла, $\tau(\alpha)$		-0.11 (>0.2)		-0.1 (>0.3)		-0.17 (>0.09)		0.222 (<0.05)	

\* Отличие от канонической – заглавные буквы.

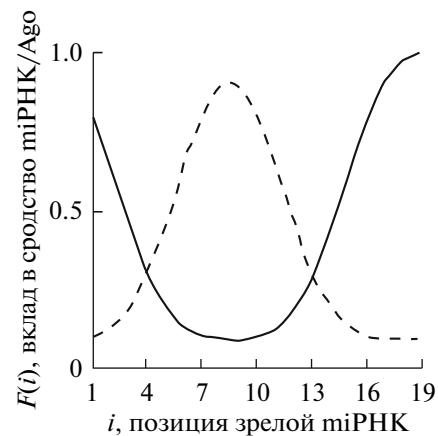
Итак, с помощью автоматического режима ACTIVITY мы проверили каждый из  $\approx 10^7$  вариантов  $[z_1 z_2 z_3 z_4]_F$ , рассчитывая каждый вариант независимо от других при каждом из двух наборов “входных данных” для этой системы,  $\{S_n, \Sigma_n = (A_{2,n} + A_{3,n})/2\}_{1 \leq n \leq 12}$  и  $\{S_n, \Delta_n = (A_{2,n} - A_{3,n})/2\}_{1 \leq n \leq 12}$ .

Поскольку алгоритм ACTIVITY описан много-кратно [7–16], отметим коротко самое важное. Всего для каждого из  $\approx 10^7$  вариантов  $[z_1 z_2 z_3 z_4]_F$  оценивали пять типов корреляций. Прежде всего, проверяли наличие линейной корреляции между  $[z_1 z_2 z_3 z_4]_F$  и  $\Psi$  (здесь и далее:  $\Psi \in \{\Sigma, \Delta\}$ ), поскольку она дает самый ценный количественный прогноз. Поскольку этот прогноз не устойчив к неоднородности данных, то с помощью критериев  $\chi^2$  и Фишера дополнительно оценивали корреляции между знаками отклонений  $[z_1 z_2 z_3 z_4]_F$  и  $\Psi$  от их среднеарифметических значений, обеспечивающие самый устойчивый малооцененный прогноз “выше/ниже среднего”. Наконец, оценивали ранговые корреляции Спирмена и Кендалла, промежуточные по балансу между ценностью и устойчивостью прогнозов. Совместный учет разных типов корреляций компенсирует недостатки одних из них достоинствами других.

ACTIVITY также дополнительно проверяла 6 критериев однородности данных: равномерность распределений  $[z_1 z_2 z_3 z_4]_F$  и  $\Psi$ ; нормальность отклонений  $\Psi$  от ее простой регрессии  $\Psi([z_1 z_2 z_3 z_4]_F = \zeta_0 + \zeta_1 [z_1 z_2 z_3 z_4]_F)$  и отклонений  $[z_1 z_2 z_3 z_4]_F$  от сопряженной простой регрессии  $[z_1 z_2 z_3 z_4]_F(\Psi) = \zeta_0 + \zeta_1 \Psi$ ; независимость знаков отклонений  $\{\Psi - (\xi_0 + \xi_1 [z_1 z_2 z_3 z_4]_F)\}$  и  $\{[z_1 z_2 z_3 z_4]_F - (\zeta_0 + \zeta_1 \Psi)\}$ . Итак, всего анализировали  $5 + 6 = 11$  статистических критериев.

С той же целью ACTIVITY применяла метод bootstrap [27] для оценки каждого из 11 статистических критериев на 7 наборах данных: на всем введенном наборе экспериментальные данные (табл. 1: miРНК № 1–12) и на каждом из шести его поднаборов 50%-ного объема (по 6 из 12 miРНК № 1–12) с наибольшими, наименьшими и ближайшими к среднеарифметическим значениям независимо для случаев величин  $\Psi$  и  $[z_1 z_2 z_3 z_4]_F$ .

В результате проверки 11 критериев ( $m$ ) на 7 наборах данных ( $n$ ) получали  $11 \times 7 = 77$  уровней значимости  $\alpha_{m,n}$ . С помощью нечеткой логики Задэ [28] ACTIVITY отображала каждый  $\alpha_{m,n}$  на единую шкалу  $[-1; 1]$ , позитивные оценки  $q_{m,n}$  которой означают достоверное выполнение  $m$ -ого критерия на  $n$ -ом наборе данных ( $\alpha_{m,n} < 0.05$ ), негативные – недостоверное ( $\alpha_{m,n} > 0.05$ ), “0” шкалы соответствует общепринятым порогу достоверности ( $\alpha_{m,n} = 0.05$ ):



**Рис. 1.** Линейно-аддитивная аппроксимация (формула 1) вклада  $F(i)$  тетрануклеотида  $z_1 z_2 z_3 z_4$  с началом в  $i$ -ой позиции miРНК,  $\{s_i \in z_1, s_{i+1} \in z_2, s_{i+2} \in z_3, s_{i+3} \in z_4\}$ , в средство этой miРНК к Ago-белкам с помощью эвристического правила: “чем выше  $F(i)$ , тем больше вклад”. Иллюстративные примеры: А-образный пунктир – наибольший вклад центрального района miРНК в ее средство к белкам (всего 90 вариантов с разными положениями, шириной и степенью асимметрии пика), V-образная линия – наибольший вклад 3'-конца miРНК (всего 90 вариантов).

$$q_{m,n}([z_1 z_2 z_3 z_4]_F; \Psi) = \begin{cases} 1 & \text{если } \alpha_{m,n} \leq 0.01; \\ 1.3 - 28.3\alpha_{m,n} + 55.6\alpha_{m,n}^2 & \text{если } 0.01 \leq \alpha_{m,n} \leq 0.1; \\ -1 & \text{если } \alpha_{m,n} \geq 0.1. \end{cases} \quad (2)$$

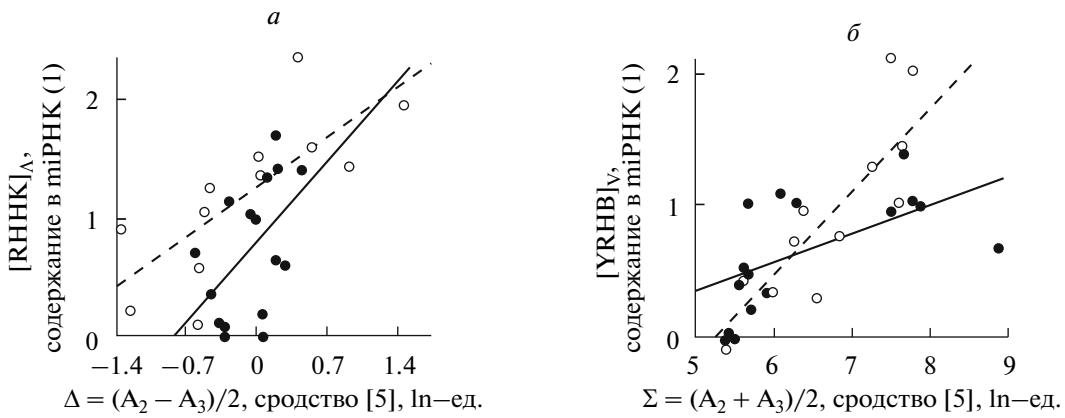
Шкала (2) задана параболой по трем  $(-1; 0.1)$ ,  $(0; 0.05)$  и  $(1; 0.01)$  ее точкам  $(q; \alpha)$ . Так все  $[z_1 z_2 z_3 z_4]_F$  получили по 77 частных оценок  $q_{m,n}([z_1 z_2 z_3 z_4]_F; \Psi)$  выполнения 11 критериев на 7 наборах данных [28]. В терминах теории полезности для принятия решений [29] оценку полезности учета  $[z_1 z_2 z_3 z_4]_F$  в прогнозе  $\Psi$  дало среднеарифметическое этих частных оценок:

$$Q([z_1 z_2 z_3 z_4]_F; \Psi) = \frac{\sum_{m=1}^{11} \sum_{n=1}^7 q_{m,n}([z_1 z_2 z_3 z_4]_F; \Psi)}{11 \times 7}. \quad (3)$$

Наибольшая позитивная  $Q([z_1 z_2 z_3 z_4]_F; \Psi)$  указала на тот тетрануклеотид  $z_1 z_2 z_3 z_4$  и с тем его линейно-аддитивным вкладом  $F$  в средство miРНК к Ago2 и Ago3,  $\Psi$ , которым нашлись самые однородные данные с самым большим количеством самых достоверных корреляций.

#### Проверка найденных особенностей контекста miРНК с помощью независимых данных

Сначала для найденных ACTIVITY по  $\{S_n; \Sigma_n\}_{1 \leq n \leq 12}$  и  $\{S_n; \Delta_n\}_{1 \leq n \leq 12}$  лучших  $Q([\xi_1 \xi_2 \xi_3 \xi_4]_F; \Sigma)$  и



**Рис. 2.** Результаты автоматического анализа экспериментальных данных [5] с помощью ACTIVITY: анализируемая выборка miPHK № 1–12 из табл. 1 (○, пунктир) и контрольная выборка miPHK № 13–28 (●, линия). *а* – Достоверная линейная корреляция между полуразностью  $\Delta = (A_2 - A_3)/2$  величин  $A_2$  и  $A_3$  сродство miPHK к Ago2 и Ago3, соответственно, и содержанием  $[RHHK]_\Delta$  тетрануклеотида RHHR вблизи центра miPHK (формула (1), рис. 1: пунктире); *б* – достоверная линейная корреляция между полусуммой  $\Sigma = (A_2 + A_3)/2$  и содержанием  $[YRHB]_V$  тетрануклеотида YRHB вблизи 3'-конца miPHK (рис. 1, линия).

$Q([\zeta_1 \zeta_2 \zeta_3 \zeta_4; \Delta]; \Delta)$  мы проверили линейные корреляции между  $\Sigma$  и  $[\xi_1 \xi_2 \xi_3 \xi_4]_\Phi$ ,  $\Delta$  и  $[\zeta_1 \zeta_2 \zeta_3 \zeta_4; \Delta]_\Omega$  на независимых контрольных данных  $\{S_n; \Sigma_n; \Delta_n\}_{1 \leq n \leq 28}$ .

Затем мы провели стандартный тест пермутаций [30]. В каждом из 100 независимых однотипных испытаний перемешивали случайным образом элементы обучающих наборов  $\{S_n; A_{2,n}; A_{3,n}\}_{1 \leq n \leq 12}$  и каждую полученную смесь анализировали с помощью ACTIVITY [7].

Наконец, на всех  $\{S_n; \Sigma_n; \Delta_n\}_{1 \leq n \leq 28}$  канонических miPHK без оптимизации нашли простые регрессии  $\Sigma = \gamma_0 + \gamma_1 [\xi_1 \xi_2 \xi_3 \xi_4]_\Phi$  и  $\Delta = \psi_0 + \psi_1 [\zeta_1 \zeta_2 \zeta_3 \zeta_4; \Delta]_\Omega$  (линейные сдвиг и масштаб) и, вновь без оптимизации, преобразовали их обратно в  $A_2(S) = \Sigma(S) + \Delta(S)$  и  $A_3(S) = \Sigma(S) - \Delta(S)$ . Проверяли выведенные таким путем  $A_2(S_n)$  и  $A_3(S_n)$  линейные корреляции между ними и соответственно  $A_{2,n}$  и  $A_{3,n}$  из  $\{S_n; A_{2,n}; A_{3,n}\}_{1 \leq n \leq 28}$ . В выведенных формулах  $A_2(S) = \Sigma(S) + \Delta(S)$  и  $A_3(S) = \Sigma(S) - \Delta(S)$  также оценили значимость их линейных корреляций с множественными регрессиями  $A_{2,n}$  и  $A_{3,n}$  по обеим  $[\xi_1 \xi_2 \xi_3 \xi_4]_\Phi$  и  $[\zeta_1 \zeta_2 \zeta_3 \zeta_4; \Delta]_\Omega$ , оптимизированным на  $\{S_n; A_{2,n}; A_{3,n}\}_{1 \leq n \leq 28}$ .

В заключение предсказали на основе выведенных формул сродство 48 неканонических miPHK к Ago2 и к Ago3, оценив значимость ( $\alpha$ ) линейной ( $r$ ) и ранговой Кендалла ( $\tau$ ) корреляций между этими прогнозами и соответствующими измерениями из работы [5].

## РЕЗУЛЬТАТЫ ИССЛЕДОВАНИЯ

### Результаты автоматического анализа данных с помощью ACTIVITY и их контроль

Обучающие выборки  $\{S_n, \Sigma_n\}_{1 \leq n \leq 12}$  и  $\{S_n, \Delta_n\}_{1 \leq n \leq 12}$  независимо проанализированы ACTIVITY в автома-

тическом режиме, как описано выше. В итоге, найдена самая высокая оценка  $Q([RHHK]_\Delta; \Delta) = 0.363$  (формула 3) в случае анализа выборки  $\{S_n, \Delta_n\}_{1 \leq n \leq 12}$ . Так для предпочтения miPHK к Ago2 перед Ago3 самым важным оказался тетрануклеотид RHHR [18] с его наибольшим линейно-аддитивным вкладом  $F(i)$  в сродство к белкам Ago в центре miPHK (рис. 1: Л-образный пункт). Величины  $[RHHK]_\Delta$  для всех 28 miPHK даны в табл. 1. На рис. 2 $a$  показана значимая ( $r = 0.501, \alpha < 0.05$ ) линейная корреляция между  $\Delta$  и  $[RHHK]_\Delta$  также для независимых контрольных данных (miPHK № 13–28). Следующая по величине  $Q([RHHK]_\Delta; \Delta) = 0.343$  указала на тот же тетрануклеотид RHHR с более узким пиком  $F(i)$  в центре зрелых miPHK. Важность последовательности центра зрелой miPHK для различия между Ago2 и Ago3 по их сродству к ней согласуется с различием биологических функций этих белков: в случае Ago2 возможно разрезание мРНК в центре ее гетеродуплекса с miPHK, в случае Ago3 – нет [5]. Итак, коадаптацией контекста miPHK и белков Argonaute при дивергенции “Ago2 ← предок → Ago3” [3] была, по-видимому, их селекция на многовариантность способов регуляции трансляции: ингибировать трансляцию (Ago2 и Ago3) и/или необратимо предотвратить ее посредством разрезания мРНК (Ago2).

По выборке  $\{S_n, \Sigma_n\}_{1 \leq n \leq 12}$  ACTIVITY нашла наибольшую  $Q([YRHB]_V; \Sigma) = 0.358$  для тетрануклеотида YRHB [18] с наибольшим линейно-аддитивным вкладом  $F(i)$  в сродство к обоим Ago2 и Ago3 на 3'-конце miPHK (рис. 1, линия). Это согласуется с пространственной структурой комплекса мРНК/mнкРНК/Ago из *Pyrococcus furiosus* [6], где Ago действительно связывает 3'-конец мнкРНК. По-аналогии с этим известным контактом между Ago и 3'-концом мнкРНК из *Pyrococcus furiosus* [6],

коадаптацией контекстов предков миРНК и предков Ago2 и Ago3 человека на сродство между ними могла быть селекция 3'-концевых районов зрелых миРНК. Величины  $[YRHB]_V$  для всех 28 зрелых канонических миРНК [5] представлены в табл. 1. Оценки  $[YRHB]_V$  и  $\Delta$  коррелируют достоверно для независимой контрольной выборки миРНК № 13–28 (рис. 2б:  $r = 0.613$ ,  $\alpha < 0.025$ ).

В стандартном испытании пермутаций [30] для каждой взятой из обучающих данных  $\{S_n; A_{2;n}; A_{3;n}\}_{1 \leq n \leq 12}$  случайной миРНК  $S_n^*$  независимо один от другого брали случайные  $A_2^*$  и  $A_3^*$ , строили  $\{S_n^*\}$ ;  $S_n^* = (A_{2;n}^* + A_{3;n}^*)/2\}_{1 \leq n \leq 12}$  и  $\{S_n^*\}; \Delta_n^* = (A_{2;n}^* - A_{3;n}^*)/2\}_{1 \leq n \leq 12}$ , которые анализировали с помощью системы ACTIVITY. Всего проведено 100 таких испытаний, ни в одном из которых никакие сочетания RHNK- и YRHB-подобных тетрануклеотидов  $z_1 z_2 z_3 z_4$  ни с какими V-или Л-образными весовыми функциями  $F(i)$  не получили позитивных оценок формулы (3).

При априорно ожидаемой частоте  $P_0 = 0.05$  иного исхода по случайным причинам и при допущении его в 101-ом испытании закон бинома дает оценку вероятности  $p = 0.036$  такого результата теста пермутаций [30]. Это означает, что соответствие между обучающими данными  $\{S_n; A_{2;n}; A_{3;n}\}_{1 \leq n \leq 12}$  [5] и найденными по ним содержаниями тетрануклеотидов  $[RHNK]_\Lambda$  и  $[YRHB]_V$  в зрелых канонических миРНК оказалось достоверным ( $\alpha < 0.05$ ).

#### Выход формул прогноза сродства канонических миРНК к белкам Ago2 и Ago3 человека

По всем миРНК (№ 1–28, табл. 1) найдены простые регрессии вспомогательных оценок без их оптимизации (линейные сдвиг и масштаб):  $\Sigma = 5.54 + 1.35[YRHB]_V$  и  $\Delta = -0.57 + 0.52[RHNK]_\Lambda$ . Затем, мы преобразовали их вновь без оптимизации обратно к измеримым величинам [5],  $A_2 = \Sigma + \Delta$  и  $A_3 = \Sigma - \Delta$ , с помощью двух следующих формул:

$$A_2(S) = 4.97 + 1.35[YRHB]_V(S) + 0.52[RHNK]_\Lambda(S), \quad (4)$$

$$A_3(S) = 6.11 + 1.35[YRHB]_V(S) - 0.52[RHNK]_\Lambda(S). \quad (5)$$

Прогнозы формул (4) и (5) для всех 28 зрелых канонических миРНК представлены в табл. 1 и на рис. 3. Они достоверны:  $r = 0.661$  ( $\alpha < 0.00025$ ) и  $r = 0.664$  ( $\alpha < 0.00025$ ).

Также обнаружено достоверное согласие формул (4) и (5) с множественными линейными регрессиями  $A_2$  и  $A_3$  по  $[YRHB]_V$  и  $[RHNK]_\Lambda$ , соответственно  $r = 0.953$  и  $\alpha < 10^{-14}$ ,  $r = 0.963$  и  $\alpha < 10^{-15}$  (данные не показаны). В этих линейных регрессиях  $[RHNK]_\Lambda$  и

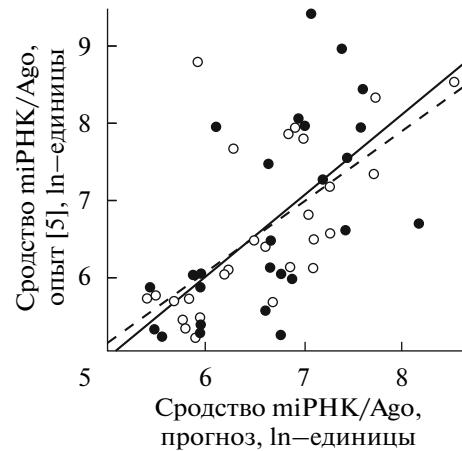


Рис. 3. Результаты измерения  $A_2$  и  $A_3$  [5] сродства зрелых канонических миРНК к белкам человека, соответственно Ago2 (○, пунктир) и Ago3 (●, линия), достоверно линейно коррелируют с прогнозами этого сродства по формулам (4) и (5) на основе нуклеотидных последовательностей зрелых миРНК.

$[YRHB]_V$  объясняли  $10 \pm 14\%$  и  $69 \pm 14\%$  вариансы сродства миРНК к Ago2 соответственно. В случае Ago3 эти показатели составляли  $44 \pm 15\%$  и  $50 \pm 15\%$ . В случае Ago2 вклад  $[RHNK]_\Lambda$ , эвристически ассоциированный нами с дивергенцией “Ago2 ← предок → Ago3” [3], оказался недостоверным, поскольку величина  $10\%$  этого вклада в вариансу измерений  $A_2$  [5] не превышает доверительного интервала  $\pm 14\%$  регрессионной оценки этой величины. В случае Ago3 вклады обоих  $[RHNK]_\Lambda$  и  $[YRHB]_V$  были, на-против, равнозначными: разность  $50 - 44 = 6\%$  между величинами их вкладов в вариансу измерения  $A_3$  [5] соответствует точности  $\pm 15\%$  регрессионной оценки каждого из этих вкладов. Это означает, что из двух гомологов Ago2 и Ago3, по сродству к миРНК белок Ago2 оказался более похож на их общего предка. Это согласуется с независимым результатом филогенетического анализа всех известных аминокислотных последовательностей белков семейства Argonaute [3].

#### ОБСУЖДЕНИЕ РЕЗУЛЬТАТОВ

Итак, стандартный тест пермутаций [30] указал на значимость соответствия, прежде всего, между данными  $\{S_n; A_{2;n}; A_{3;n}\}_{1 \leq n \leq 12}$  [5] и содержанием тетрануклеотидов  $[RHNK]_\Lambda$  и  $[YRHB]_V$  в зрелых канонических миРНК, полученного в результате анализа этих данных с помощью ACTIVITY. Кроме того, эти контекстные особенности зрелых канонических миРНК человека достоверно коррелируют с измерениями сродства миРНК к белкам Ago RISC человека как на подготовленных репрезентативных данных для их *in silico* анализа, так и на оставшихся неоднородных независимых данных из опыта [5]. Наконец,

они согласуются с известной пространственной структурой комплекса мРНК/мнкРНК/Ago из *Pyrococcus furiosus* [6], различием по воздействию RISC с содержанием Ago2 и Ago3 на мРНК-мишень (разрезание и/или ингибирование [5]) и филогенетическим древом всех известных аминокислотных последовательностей белков семейства Ago [3]. Существенно, что эти две закономерности выбраны из гигантского массива  $10^7$  однотипных с ними потенциальных закономерностей (1), каждую из которых подвергали 77 испытаниям при уровне значимости  $\alpha < 0.05$  [7] на малой выборке из 12 мРНК [5]. Поэтому нельзя совсем исключить случайность их выбора системой ACTIVITY. Однако вероятность случайного выбора можно оценить с помощью следующих расчетов.

Прежде всего, согласно распределению редких событий Пуассона следует ожидать не менее четырех ( $77 \times 0.05 \approx 4$ ) случайных положительных исходов в 77 испытаниях и верхнюю 5%-ную доверительную границу  $4 \times (1 + t_{\alpha < 0.05; v=77}) = 4 \times (1 + 1.6649) \approx 11$  их количества. Этой границе соответствует  $77 - 11 = 66$  негативных исходов, благодаря которым ( $11 \ll 66$ ) формула (3) дает в целом негативную оценку полезности  $Q < 0$ . Чтобы получить позитивную оценку необходимо 50% позитивных из 77 исходов при значимости  $\alpha < 0.05$ . Закон бинома оценивает вероятность этого величиной:

$$P(Q(\xi) > 0) = \\ = \sum_{n=38}^{77} C_{77}^n \times 0.05^n \times (1 - 0.05)^{77-n} < 10^{-28}.$$

Тогда неравенство Бонферрони ограничивает исключенную вероятность верхней оценкой:

$$P\{Q([z_1 z_2 z_3 z_4]_F; \Psi) > 0\} < P\{Q([z_1 z_2 z_3 z_4]_F; \Delta) > 0\} + \\ + P\{Q([z_1 z_2 z_3 z_4]_F; \Sigma) > 0\} < 2 \times 10^7 \times P\{Q(\xi) > 0\} < \\ < 2 \times 10^7 \times 10^{-28} < 10^{-20}.$$

В порядке дискуссии о возможных применениях формул (4) и (5), выведенных нами для канонических мРНК, мы предсказали с их помощью также средство 48 неканонических мРНК к белкам Ago2 и Ago3 и сравнили эти прогнозы с измерениями [5] (табл. 2). Видно, что для неканонических мРНК мы не нашли ни линейных ( $r$ ), ни ранговых ( $\tau$ ) корреляций ни для Ago2 ( $r = -0.01, \alpha > 0.9$  и  $\tau = -0.11, \alpha > 0.2$ ), ни для Ago3 ( $r = -0.1, \alpha > 0.3$  и  $\tau = -0.1, \alpha > 0.3$ ), ни для полу суммы их средства к мРНК, которую мы эвристически ассоциировали с их общим предком ( $r = -0.18, \alpha > 0.2$  и  $\tau = -0.17, \alpha > 0.09$ ). Это указывает на отсутствие какой-либо эволюционной селекции Ago2, Ago3 и их общего предка на средство к неканоническим мРНК. Действительно, содержание канонических мРНК в клетках много больше по сравнению с неканоническими мРНК, последние к то-

му же принято ассоциировать с ошибками биогенеза мРНК или их особыми модификациями [5].

Тем не менее, прогноз разности величин средства мРНК/Ago2 и мРНК/Ago3 оказался достоверным в случае обоих типов корреляций ( $r = 0.488, \alpha < 0.001$  и  $\tau = 0.222, \alpha < 0.05$ ). Это означает, что все копии определенной неканонической мРНК распределены между ее комплексами с белками Ago2 или Ago3 пропорционально предсказанным с помощью формул (4) и (5) величинам средства этой мРНК к Ago2 и к Ago3.

Итак, прогнозы формул (4) и (5) для канонических и неканонических мРНК в целом соответствуют общепринятым представлениям о взаимодействии и эволюции макромолекул. Поэтому они могут быть полезны для конструирования мРНК-подобных регуляторов генов.

Работа частично поддержана Интеграционным проектом Сибирского отделения РАН № 119 “Постгеномная биоинформатика: компьютерный анализ и моделирование молекулярно-генетических систем” и Программами РАН № 21 “Фундаментальные науки – медицине” (проект 26 “Информационно-компьютерные подходы к поиску оптимальных фармакологических стратегий коррекции патологических состояний организма”), № 22 “Молекулярная и клеточная биология” (проект 8 “Системная биология: компьютерно-экспериментальные подходы”) и № 23 “Биоинформатика генетической изменчивости: исследование влияния мутаций на молекулярно-генетические системы организмов”).

## СПИСОК ЛИТЕРАТУРЫ

- Lee R.C., Ambros V. 2001. An extensive class of small RNAs in *Caenorhabditis elegans*. *Science*. **294**, 862–864.
- Bartel D. 2004. MicroRNAs: Genomics, biogenesis, mechanism, and function. *Cell*. **116**, 281–297.
- Murphy D., Dancis B., Brown J.R. 2008. The evolution of core proteins involved in microRNA biogenesis. *BMC Evol. Biol.* **8**, 92.
- Meister G., Landthaler M., Patkaniowska A., et al. 2004. Human Argonaute2 mediates RNA cleavage targeted by miRNAs and siRNAs. *Mol. Cell*. **15**, 185–197.
- Azuma-Mukai A., Oguri H., Mituyama T., et al. 2008. Characterization of endogenous human Argonautes and their miRNA partners in RNA silencing. *Proc. Natl. Acad. Sci. USA*. **105**, 7964–7969.
- Song J.J., Smith S.K., Hannon G.J., et al. 2004. Crystal structure of Argonaute and its implications for RISC slicer activity. *Science*. **305**, 1434–1437.
- Roponarenko M.P., Kolchanova A.N., Kolchanov N.A. 1997. Generating programs for predicting the activity of functional sites. *J. Comput. Biol.* **4**, 83–90.
- Пономаренко М.П., Савинкова Л.К., Кель А.Э., Колчанов Н.А. 1997. Компьютерное моделирование последовательностей ТАТА-боксов промоторов эукариот. *ДАН*. **355**, 557–561.

9. Пономаренко М.П., Пономаренко Ю.В., Титов И.И. и др. 1998. Предпочтительность RecA-филамента к последовательностям ДНК коррелирует с генетическим кодом. *ДАН.* **363**, 122–125.
10. Колчанов Н.А., Пономаренко М.П., Пономаренко Ю.В. и др. 1998. Функциональные сайты геномов про- и эукариот: компьютерное моделирование и предсказание активности *Молекуляр. биология*. **32**, 255–267.
11. Пономаренко М.П., Пономаренко Ю.В., Колчанов Н.А. 1999. Вклад сигналов и анти-сигналов в мутационный спектр сайта встраивания td-интранона. *Биофизика*. **44**, 655–663.
12. Ponomarenko M.P., Ponomarenko J.V., Frolov A.S., et al. 1999. Identification of sequence-dependent features correlating to activity of DNA sites interacting with proteins. *Bioinformatics*. **15**, 687–703.
13. Васильев Г.В., Меркулов В.М., Кобзев В.Ф. и др. 2000. Точковые мутации в районе 663–666 п.н. интранона 6 гена триптофаноксигеназы, связанные с рядом психических расстройств, разрушают сайт связывания фактора транскрипции YY1. *Молекуляр. биология*. **34**, 214–222.
14. Ponomarenko J.V., Furman D.P., Frolov A.S., et al. 2001. ACTIVITY: a database on DNA/RNA sites activity adapted to apply sequence-activity relationships from one system to another. *Nucleic Acids Res.* **29**, 284–287.
15. Пономаренко П.М., Савинкова Л.К., Драчкова И.А. и др. 2008. Пошаговая модель связывания ТВР/ТАТА бокса позволяет предсказать наследственные заболевания человека по точечным полиморфизмам. *ДАН.* **419**, 828–832.
16. Пономаренко М.П., Омельянчук Н.А., Катохин А.В., Колчанов Н.А. 2006. Содержание микроРНК в *Arabidopsis thaliana* коррелирует с встречаемостью тетрануклеотидов WRHW и DRYD. *Инф. Вестн. ВОГиС*. **10**, 304–311.
17. Axtell M., Bartel D. 2005. Antiquity of microRNAs and their targets in land plants. *Plant Cell*. **17**, 1658–1673.
18. IUPAC-IUB commission on biochemical nomenclature (CBN) 1971. Abbreviations and symbols for nucleic acids, polynucleotides and their constituents. *J. Mol. Biol.* **55**, 299–310.
19. Lu C., Tej S.S., Luo S., Haudenschild C.D., Meyers B.C., Green P.J. 2005. Elucidation of the small RNA component of the transcriptome. *Science*. **309**, 1567–1569.
20. Hwang H.W., Wentzel E.A., Mendell J.T. 2007. A hexanucleotide element directs microRNA nuclear import. *Science*. **315**, 97–100.
21. Fiedler S.D., Carletti M.Z., Hong X., Christenson L.K. 2008. Hormonal regulation of MicroRNA expression in periovulatory mouse mural granulosa cells. *Biol. Reprod.* **79**, 1030–1037.
22. van Rooij E., Olson E.N. 2007. MicroRNAs: powerful new regulators of heart disease and provocative therapeutic targets. *J. Clin. Invest.* **117**, 2369–2376.
23. Martinez J., Tuschl T. 2004. RISC is a 5' phosphomonoester-producing RNA endonuclease. *Genes Dev.* **18**, 975–980.
24. Chatterjee S., Grosshans H. 2009. Active turnover modulates mature microRNA activity in *Caenorhabditis elegans*. *Nature*. **461**, 546–549.
25. Sakamoto M., Lloyd G.T., Benton M.J. 2010. Phylogenetically structured variance in felid bite force: the role of phylogeny in the evolution of biting performance. *J. Evol. Biol.* **23**, 463–478.
26. Porschke D., Eigen M. 1971. Co-operative non-enzymic base recognition. 3. Kinetics of the helix-coil transition of the oligoribouridylic–oligoriboadenylic acid system and of oligoriboadenylic acid alone at acidic pH. *J. Mol. Biol.* **62**, 361–381.
27. Hayes K.G., Perl M.L., Efron B. 1989. Application of the bootstrap statistical method to the tau-decay-mode problem. *Phys. Rev. D. Part. Fields*. **39**, 274–279.
28. Zadeh L.A. 1965. Fuzzy sets. *Inform. Control.* **8**, 338–353.
29. Fishburn P.C. 1970. *Utility theory for decision making*. N.Y. John Wiley & Sons, 227 p.
30. Sohn I., Owzar K., George S.L., Kim S., Jung S.H. 2009. A permutation-based multiple testing method for time-course microarray experiments. *BMC Bioinformatics*. **10**, 336.