

УДК 519.767.6:577

ВЫЯВЛЕНИЕ ИНФОРМАТИВНЫХ ПРИЗНАКОВ В ЗАДАЧАХ  
РАСПОЗНАВАНИЯ СИМВОЛЬНЫХ ПОСЛЕДОВАТЕЛЬНОСТЕЙ  
(на примере генетических текстов)

Т.Н.Титкова

При анализе генетических текстов (первичных структур ДНК-молекул простейших микроорганизмов) возникает задача автоматического выделения внутри текста участков с различным функциональным назначением (генов, знаков пунктуации и т.д.). Роль знаков пунктуации играют подпоследовательности длиной от трех до нескольких десятков символов.

Важным классом знаков пунктуации являются промоторы-участки генома (текста), ответственные за начало процесса транскрипции. Их длина порядка 50-70 нуклеотидов. В настоящее время расшифровано уже несколько десятков промоторов, т.е. установлена их первичная структура и доказано (молекулярно-биологическим анализом), что соответствующие последовательности нуклеотидов выполняют роль инициаторов транскрипции. Совокупность этих последовательностей может рассматриваться как обучающая выборка по промоторам в задаче классификации "промотор-не промотор". Для элементов этой выборки существует реальное опознающее устройство - РНК-полимераза. Обучающая выборка по "не промоторам" может быть получена из текстов уже расшифрованных геномов с исключенными промоторными зонами.

Удачное решение задачи классификации формальными методами (т.е. прямо по виду символьной последовательности) может сильно упростить и ускорить весьма трудоемкую процедуру выявления генетической структуры генома.

В основу построения решающего правила кладется различие в характеристиках элементов первого и второго образов, выявляемое

при анализе обучающих выборок. Исследовалась возможность использования для этой цели 1-граммных характеристик [1,2], показывающих, какие 1-граммы (связные подпоследовательности из 1 символов,  $l = 1, 2, 3, \dots$ ) и в каком количестве входят в анализируемые последовательности. Поскольку промоторы имеют довольно большую длину при малом алфавите ( $n = 4$ ), почти все из  $n^l$  возможных комбинаций нуклеотидов при  $l = 1, 2, 3$  присутствуют в обучающей выборке промоторов. Естественно было поэтому искать различия между промоторами и "не промоторами" на уровне длинных 1-грамм ( $l \geq 7$ ).

Назовем 1-грамму типичной для промоторов, если она встречается как минимум в двух промоторах и не встречается у "не промоторов". Методика выявления типичных 1-грамм такова. Составим конкатенацию  $T_n = T_1 \sqcup T_2 \sqcup T_3 \sqcup \dots \sqcup T_m$ , где  $T_i$  ( $1 \leq i \leq m$ ) - текст, описывающий  $i$ -й промотор,  $m$  - число промоторов,  $\sqcup$  - разделитель между каждой парой промоторов (символ, не содержащийся ни в одном из  $T_i$ ). Получим полный частотный спектр текста  $T_n$  и определим параметр  $l_{\max}(T_n)$ , т.е. минимальное  $l$ , начиная с которого в тексте  $T_n$  уже отсутствуют повторяющиеся 1-граммы. Аналогичную операцию сделаем с текстом  $T_H$ , содержащим последовательность "не промоторов".

Рассмотрим множество кратных 1-грамм из  $T_n$  длины  $(l_{\max}(T_n) - l)$ , не содержащих разделителя, не встретившихся в  $T_H$  и оказавшихся в разных промоторах. Составим таблицу из нулей и единиц, где каждая строка соответствует "типичной" 1-грамме, а каждый столбец - одному из промоторов. На пересечении соответствующей строки и столбца ставится единица, если данная 1-грамма присутствует в рассматриваемом промоторе. Проверяем, обеспечивает ли выделенное множество  $(l_{\max} - l)$ -грамм полное покрытие всех промоторов из обучающей выборки. Если да, то процесс выбора "информативных" для классификации "промотор-не промотор" признаков (1-грамм) заканчивается. В противном случае дополняем уже отобранное множество  $(l_{\max}(T_n) - l)$ -грамм кратными 1-граммами длиной на единицу меньше и удовлетворяющими тем же трём условиям и одному дополнительному: новые 1-граммы не должны быть подпоследовательностями уже выписанных ранее 1-грамм. Исключение делается лишь для тех 1-грамм, которые имеют большую частоту, чем содержащая их  $(l+1)$ -грамма. Это означает, что данная 1-грамма встретила еще в одном или нескольких промоторах.

Процесс понижения значений  $l$  продолжается до тех пор, пока не будет сформировано полное покрытие. Если по мере понижения  $l$  больше не находится 1-грамм, удовлетворяющих всем четырем условиям, некоторые из них могут быть ослаблены (например, можно допустить присутствие данной 1-граммы и в  $T_H$ , но с частотой существенно меньшей, чем в  $T_n$ ). Полученное покрытие может оказаться избыточным и при необходимости может быть минимизировано.

В нашем эксперименте обучающая выборка по промоторам содержала 24 последовательности. Обучающая выборка по "не промоторам" состояла из 4 геномов ( $\phi$ X174, MS2, G4, SV40) с исключенными промоторными зонами. Длина текста  $T_H$  в несколько раз превышала длину текста  $T_n$ .

Т а б л и ц а I

1-грамма	Промоторы, содержащие ее
ТГТТГАЦА АЦАЦТТТ	$\lambda$ -PL, E.coli-TRP, $\phi$ X174D, S, TYPH E.coli-LAC, E.coli-GAL, TRNK-TUP, E.coli K12-ARAC
ГЦГТТГАТА АТГТТТАЦА АГГАААТА ГАТАЦАААТЦ ААЦААААЦ ЦТГТАТТТГ АТТГАЦТТА ЦГЦТТТ	$\lambda$ -PL, $\lambda$ -PR, $\lambda$ -PRM $\phi$ X174B, SV40 $\phi$ X174A, C17 FD:G3, T7:A2 FD:G1, T7:A3 $\lambda$ -P <sub>0</sub> , $\lambda$ -IMM434 T7:A1, $\lambda$ -PR' FD:G2, E.coli K12-ARAC, E.coli K12-ARAB

По результатам эксперимента можно отметить следующее.

I. Покрытие для промоторов (см.табл.I) удалось сформировать из 1-грамм длиной  $\geq 8$  (за единственным исключением  $l=6$ ), причем все 1-граммы удовлетворяли четырем сформулированным

выше требованиям. Это означает, что гипотеза о наличии закономерных связей между промоторами в виде достаточно длинных совпадающих подпоследовательностей полностью подтвердилась.

2. Поскольку длина 1-граммы, общей для пары промоторов, характеризует силу связи, то все множество промоторов по степени их близости можно разбить на таксоны в этом смысле. Все исследованные группы промоторов в первом приближении разбиваются на два класса. Первый из них, куда входят группы T7 и  $\lambda$ , характеризуется, за некоторыми исключениями, сильной связью между промоторами внутри каждой группы. Второй класс, куда входят группы  $\phi$ X174, E.coli и FD, характеризуется слабой связью.

3. Анализ расположения характерных 1-грамм по позициям показал, что существуют "устойчивые" 1-граммы, расположенные примерно в одних и тех же позициях у разных промоторов. "Устойчивые" 1-граммы предлагается в первую очередь включать в покрытие. Однако существуют характерные 1-граммы, расположенные в промоторах довольно далеко друг от друга. Такая неустойчивость в расположении 1-грамм требует, по-видимому, особой трактовки в каждом отдельном случае.

#### Л и т е р а т у р а

1. ГУСЕВ В.Д., КОСАРЕВ Ю.Г., ТИТКОВА Т.Н. О задаче поиска повторяющихся отрезков текста. -В кн.: Вычислительные системы. Вып. 62. Ассоциативное кодирование. Новосибирск, 1975, с.49-71.

2. ГУСЕВ В.Д., КУЛИЧКОВ В.А., ТИТКОВА Т.Н. Анализ генетических текстов. I. 1-граммные характеристики. -В кн.: Эмпирическое предсказание и распознавание образов (Вычислительные системы, вып. 83). Новосибирск, 1980, с.11-33.

Поступила в ред.-изд.отд.  
14 апреля 1981 года