



# СИСТЕМНЫЙ АНАЛИЗ

И.В. СЕРГИЕНКО, А.М. ГУПАЛ, А.В. ОСТРОВСКИЙ

УДК 519.217.2

## ИСПОЛЬЗОВАНИЕ ЕМ-АЛГОРИТМА ДЛЯ КЛАССИФИКАЦИИ ГЕНОВ

**Аннотация.** Рассмотрены ЕМ-алгоритм для задачи разделения смесей распределений, описанных цепями Маркова, и связанная с ней проблема максимизации взвешенного правдоподобия. Предложены вспомогательные алгоритмы для выбора начального приближения и оптимального числа компонентов смеси, а также метод аппроксимации смеси распределений на основе известных данных с помощью метода опорных векторов. Полученные результаты применены к задаче классификации фрагментов генов.

**Ключевые слова:** цепь Маркова, классификация, ген, биоинформатика, нуклеотид, экзон, инtron, правдоподобие.

### ВВЕДЕНИЕ

Проблема определения функциональных фрагментов генов с использованием методов машинного обучения в настоящее время остается одной из основных задач биоинформатики. Наиболее распространены методы ее решения на основе обобщенных моделей Маркова со скрытыми переменными [1], имеющие определенные допущения, затрудняющие применение моделей для других биологических видов. Как показано в [2], для нахождения фрагментов генов могут использоваться вероятностные модели, сочетающие обыкновенные скрытые модели Маркова и цепи Маркова высоких порядков. Для повышения качества классификации при рассмотрении геномов высших организмов эффективно применение композиций моделей с эксклюзивной компетентностью составляющих [3]. При этом разбиение множества генов на области компетентности проводится с помощью бинарных предикатов простого вида, зависящих от концентраций в генах отдельных нуклеотидов или их сочетаний; таким образом, генерируемое разбиение непосредственно не связано с выбранной вероятностной моделью.

В данной статье рассмотрен альтернативный подход: разбиение строится путем непосредственной максимизации правдоподобия для множества прецедентов, что позволяет точнее выявлять границы компетентности составляющих композиции. При этом применен итеративный алгоритм ожидания — максимизация (ЕМ-алгоритм), широко используемый в задачах машинного обучения, в частности, для кластеризации данных, распознавания образов и т.д. [4, 5].

### ПОСТАНОВКА ЗАДАЧИ

Пусть задан определенный набор строк  $X = \{x^i\}_{i=1}^n$  (прецеденты), которые имеют конечную длину и образованы из символов конечного алфавита  $Q$ :

$$\forall i = 1, \dots, n \quad x^i \in Q^* \equiv \bigcup_{s=1}^{\infty} Q^s;$$

другими словами,  $X \subset Q^*$ .

© И.В. Сергиенко, А.М. Гупал, А.В. Островский, 2015

Пусть плотность распределения вероятности на множестве  $R^*$  имеет вид смеси  $k$  распределений  $M_1, M_2, \dots, M_k$ :

$$\forall x \in R^* \quad P(x) = \sum_{j=1}^k w_j p(x | M_j), \quad w_j \geq 0, \quad \sum_{j=1}^k w_j = 1, \quad (1)$$

где  $p(x | M_j)$  — функция правдоподобия для  $j$ -го компонента смеси,  $w_j$  — ее априорная вероятность. Функции правдоподобия для всех компонентов имеют вид, соответствующий цепям Маркова  $l$ -го порядка

$$p(x | M_j) = \varphi_j(|x|) \pi_j(x_1 \dots x_l) \cdot \prod_{s=l+1}^{|x|} p_j(x_s | x_{s-l} \dots x_{s-1}), \quad (2)$$

где приняты следующие обозначения:

- $\varphi_j(d) \equiv P\{|x|=d | M_j\}$  — распределение вероятности длины строк, генерируемых компонентом  $M_j$ ;
- $\pi_j(u) \equiv P\{x_1 \dots x_l = u | M_j\}$  — распределение начальных вероятностей;
- $p_j(v | u) \equiv P\{x_s = v | x_{s-l} \dots x_{s-1} = u, M_j\}$  — распределение переходных вероятностей компонента  $M_j$ .

В качестве распределений  $\varphi$  рассмотрим функции, соответствующие усреднению эмпирических данных с шириной окна  $2r+1$ :

$$\varphi(d; F) = \frac{1}{2r+1} \sum_{s=d-r}^{d+r} F_s, \quad r < d < d_{\max} - r, \quad \sum_{s=0}^{d_{\max}} F_s = 1,$$

где граничная длина  $d_{\max}$  выбрана так, чтобы вместить все (или почти все) эмпирические данные. При вычислении  $\varphi$  для длины, расположенной вблизи границ отрезка  $[0, d_{\max}]$ , количество членов, по которым проводится усреднение, уменьшается; таким образом, в наиболее общем случае формула имеет вид

$$\varphi(d; F) = \frac{1}{b-a+1} \sum_{s=a}^b F_s, \quad a = \max(0, d-r), \quad b = \min(d_{\max}, d+r). \quad (3)$$

Параметрами функции правдоподобия (3) являются  $(d_{\max} + 1)$  величин  $\{F_d\}_{d=0}^{d_{\max}}, |\mathcal{Q}|^l$  значений начальных вероятностей  $\{\pi(u) | u \in \mathcal{Q}^l\}$ , а также  $|\mathcal{Q}|^{l+1}$  переходных вероятностей  $\{p(v | u) | u \in \mathcal{Q}^l, v \in \mathcal{Q}\}$ . Совокупность этих параметров для компонентов смеси  $M_j$  обозначим  $\theta_j$ . Задача определения оптимальной смеси распределений с учетом введенных обозначений сводится к нахождению набора величин  $\Theta \equiv \{w_1, w_2, \dots, w_k; \theta_1, \theta_2, \dots, \theta_k\}$ , при котором согласно принципу максимума правдоподобия вероятность порождения множества прецедентов является максимальной

$$P(X) = \prod_{i=1}^n P(x^i) = \prod_{i=1}^n \sum_{j=1}^k w_j p(x^i | \theta_j) \rightarrow \max_{\Theta}. \quad (4)$$

После перехода к логарифму правдоподобия (4) сводится к задаче

$$\mathcal{Q}(\Theta; X) = \sum_{i=1}^n \ln \sum_{j=1}^k w_j p(x^i | \theta_j) \rightarrow \max_{\Theta}, \quad \sum_{j=1}^k w_j = 1. \quad (5)$$

Функция Лагранжа для (5) имеет вид

$$L(\Theta; X) = \sum_{i=1}^n \ln \sum_{j=1}^k w_j p(x^i | \theta_j) - \lambda \left( \sum_{j=1}^k w_j - 1 \right).$$

Приравнивая частные производные этой функции по переменным  $w_j$  к нулю, получаем [6]

$$w_j = \frac{1}{n} \sum_{i=1}^n g_{ij}, \quad (6)$$

где  $g_{ij}$  — апостериорная вероятность генерации  $i$ -й строки выборки  $j$ -м компонентом смеси; согласно формуле Байеса для полной вероятности

$$g_{ij} = P\{\theta_j | x^i\} = \frac{w_j p(x^i | \theta_j)}{\sum_{s=1}^k w_s p(x^i | \theta_s)}. \quad (7)$$

Кроме этого, равенства  $\forall j=1, \dots, k \partial L / \partial \theta_j = 0$  эквивалентны  $k$  независимым задачам максимизации взвешенного правдоподобия

$$\sum_{i=1}^n g_{ij} \ln p(x^i | \theta_j) \rightarrow \max_{\theta_j}, \quad (8)$$

где  $G_j = \{g_{ij}\}_{i=1}^n$ . Таким образом, ЕМ-алгоритм оптимизации выражения (5) сводится к выполнению следующих шагов.

**Шаг 1.** Определить начальное приближение параметров  $\Theta$ .

**Шаг 2** (Е-шаг — ожидание). Вычислить апостериорные вероятности  $g_{ij}$  согласно формуле (7), пользуясь имеющимися в данный момент параметрами  $\Theta$ .

**Шаг 3** (М-шаг — максимизация). Решить задачи вида (8) для всех компонентов смеси, получив новые значения  $\theta_1, \theta_2, \dots, \theta_k$ ; вычислить веса компонентов  $w_j$  по формуле (6).

**Шаг 4.** Если выполнен критерий останова (например, достигнуто максимальное число итераций либо стабилизированы значения параметров), возвратить  $\Theta$ ; иначе перейти к шагу 2.

#### ЗАДАЧА МАКСИМИЗАЦИИ ВЗВЕШЕННОГО ПРАВДОПОДОБИЯ

Для выполнения шага максимизации ЕМ-алгоритма необходимо построить алгоритм, решающий задачи вида (6)

$$WM(X, g) = \arg \max_{\theta} \sum_{i=1}^n g_i \ln p(x^i | \theta), \quad X = (Q^*)^n, \quad g \in R^n,$$

при ограничениях на вектор параметров  $\theta \equiv (F, \pi, p)$  в виде равенств

$$\sum_{d=0}^{d_{\max}} F_d = 1, \quad \sum_{|u|=l} \pi(u) = 1, \quad \forall u \in Q^l \quad \sum_{|v|=1} p(v | u) = 1.$$

Здесь и далее при суммировании по строкам полагается, что они состоят из символов алфавита  $Q$ .

Функция Лагранжа для поставленной задачи вычисляется следующим образом:

$$L_w(\theta; X, g) = \sum_{i=1}^n g_i \left[ \ln \varphi(|x^i|) + \ln \pi(x_1^i \dots x_l^i) + \sum_{s=l+1}^{|x^i|} \ln p(x_s^i | x_{s-l}^i \dots x_{s-1}^i) \right] - \\ - \lambda_F \left( \sum_{s=0}^{d_{\max}} F_s - 1 \right) - \lambda_{\pi} \left( \sum_{|u|=l} \pi(u) - 1 \right) - \sum_{|u|=l} \lambda_u \left( \sum_{|v|=1} p(v | u) - 1 \right).$$

В силу сложности непосредственного нахождения параметров  $\{F_d\}_{d=0}^{d_{\max}}$  из уравнений  $\partial L_w / \partial F_d = 0, d = 0, \dots, d_{\max}$ , определим их, исходя из эвристических

соображений, как взвешенные эмпирические вероятности наблюдения строки соответствующей длины

$$F_d = \frac{\sum_{i=1}^n g_i [|\boldsymbol{x}^i| = d]}{\sum_{i=1}^n g_i}. \quad (9)$$

При таком подходе в случае задачи с одинаковыми весами всех прецедентов, как и ожидается, величины  $F_d$  определяются эмпирическими вероятностями:

$$F_d = \frac{|\{|\boldsymbol{x}^i| = d \mid i = 1, \dots, n\}|}{n}.$$

Члены функции  $L_w$ , соответствующие начальным и переходным вероятностям, допускают перегруппировку, позволяющую избавиться от суммирования по прецедентам

$$\begin{aligned} L_w(\theta; X, g) = & \sum_{|u|=l} N_{st}^w(u) \ln \pi(u) + \sum_{|u|=l} \sum_{|v|=1} N^w(uv) \ln p(v \mid u) - \\ & - \lambda_\pi \left( \sum_{|u|=l} \pi(u) - 1 \right) - \sum_{|u|=l} \lambda_u \left( \sum_{|v|=1} p(v \mid u) - 1 \right) + \text{const}(\pi, p), \end{aligned}$$

где введены следующие обозначения:

- $N_{st}^w(u) = \sum_{i=1}^n g_i [x_1^i \dots x_l^i = u]$  — взвешенное количество строк множества  $X$ ,

начинающихся с определенной последовательности;

- $N^w(u) = \sum_{i=1}^n \sum_{j=1}^{|x^i|-|u|} g_i [x_j^i \dots x_{j+|u|-1}^i = u]$  — взвешенное число вхождений последовательности  $u$  во все строки из  $X$ .

Из равенств

$$\forall u \in Q^l \quad \frac{\partial L_w}{\partial \pi(u)} = \frac{N_{st}^w(u)}{\pi(u)} - \lambda_\pi = 0 \Leftrightarrow N_{st}^w(u) = \lambda_\pi \pi(u)$$

после суммирования по всем строкам длины  $l$  следует

$$\lambda_\pi \sum_{|u|=l} \pi(u) = \lambda_\pi = \sum_{|u|=l} N_{st}^w(u) = \sum_{i=1}^n g_i,$$

откуда

$$\pi(u) = \frac{N_{st}^w(u)}{\sum_{i=1}^n g_i}. \quad (10)$$

Аналогично суммированием равенств

$$\frac{\partial L_w}{\partial p(v \mid u)} = \frac{N^w(uv)}{p(v \mid u)} - \lambda_u = 0$$

по строкам  $v \in Q$  получаются оптимальные значения переходных вероятностей

$$p(v \mid u) = \frac{N^w(uv)}{\sum_{|z|=1} N^w(uz)} = \frac{N^w(uv)}{N^w(u)} \quad (11)$$

при условии, что  $N^w(u) > 0$ . Если  $N^w(u) = 0$ , что возможно тогда и только тогда, когда последовательность  $u \in Q^l$  не входит ни в одну строку из множества  $X$ ,

нельзя определить оптимальные значения переходных вероятностей вида  $p(v | u)$ . Это обстоятельство обуславливает ограничение порядка цепей Маркова  $l$  сверху.

### ЭВРИСТИКИ И МОДИФИКАЦИИ

**Вычисление вероятностей.** Вследствие достаточно сложной структуры компонентов смеси при вычислении вероятностей вида  $p(x^i | \theta_j)$  возникает проблема потери точности; в связи с этим эффективнее вычислять логарифмы вероятности

$$z_{ij} \equiv \ln p(x^i | \theta_j) = \ln \varphi_j(|x^i|) + \ln \pi_j(x_1^i \dots x_l^i) + \sum_{s=l+1}^{|x^i|} \ln p_j(x_s^i | x_{s-l}^i \dots x_{s-1}^i). \quad (12)$$

Апостериорные вероятности  $g_{ij}$  при таком подходе вычисляются как

$$g_{ij} = \frac{w_j \exp(z_{ij})}{\sum_{s=1}^k w_s \exp(z_{is})} = \frac{w_j}{\sum_{s=1}^k w_s \exp(z_{is} - z_{ij})};$$

критерий качества (5) преобразуется к виду

$$Q(\Theta; X) = \sum_{i=1}^n \ln \sum_{j=1}^k w_j \exp(z_{ij}) = \sum_{i=1}^n z_i^{\max} + \sum_{i=1}^n \ln \left( \sum_{j=1}^k w_j \exp(z_{ij} - z_i^{\max}) \right),$$

где  $z_i^{\max} = \max_{j=1, \dots, k} z_{ij}$ .

**Проблема локальных максимумов.** Определенные сложности при вычислении апостериорных вероятностей возникают, когда по крайней мере для одного набора параметров  $\theta_j$  выполняется равенство  $p(x^i | \theta_j) = 0$ , что означает невозможность порождения строки  $x^i$  соответствующей цепью Маркова. В таком случае  $g_{ij} = 0$ , т.е. прецедент  $x^i$  не учитывается при решении задачи максимизации взвешенного правдоподобия на M-шаге ЕМ-алгоритма. При некоторых обстоятельствах этого может быть достаточно, чтобы равенство  $g_{ij} = 0$  выполнялось для всех последующих итераций (например, если  $x^i$  содержит подстроку длины  $l+1$ , не встречающуюся в других прецедентах), что приводит к «зацикливанию» алгоритма оптимизации вблизи точки локального максимума. Для решения этой проблемы при вычислении логарифмов правдоподобия (12) вместо функций  $\varphi_j$ ,  $\pi_j$ ,  $p_j$ , вычисляемых по формулам (3), (9)–(11), будут использоваться их приближения, ограниченные снизу:

$$\hat{\varphi}(d) = \max(\varphi(d), \varepsilon_\varphi); \quad \hat{\pi}(u) = \max(\pi(u), \varepsilon_\pi); \quad \hat{p}(v | u) = \max(p(v | u), \varepsilon_p),$$

где положительные величины  $\varepsilon_\varphi$ ,  $\varepsilon_\pi$  и  $\varepsilon_p$  достаточно малы, чтобы не исказить результатов вычислений.

Аналогичная цель — «выбивание» алгоритма из точек локальных максимумов, и для модификации ЕМ-алгоритма, изложенной в [7], согласно которой векторы весов прецедентов  $G_j$ , используемые на шаге максимизации, определяются вероятностным образом:  $\hat{G}_j = \{[\xi_{ij} \leq g_{ij}] | i=1, \dots, n\}$ , где  $\xi_{ij}$  — независимые случайные величины, равномерно распределенные на единичном отрезке.

**Выбор начального приближения и числа компонентов.** Скорость сходимости ЕМ-алгоритма сильно зависит от выбора начального набора параметров  $\Theta$ . В данной работе рассмотрены два хорошо зарекомендовавших себя способа выбора параметров и регулировки количества цепей Маркова в смеси:

- последовательное наращивание числа компонентов;
- последовательное удаление компонентов.

При использовании первого способа начальное приближение состоит из единственного компонента  $\Theta = \{w_1; \theta_1\}$ , где  $w_1 = 1$ ,  $\theta_1 = WM(X, \{1\}_{i=1}^n)$ .

Алгоритм построения смеси заключается в циклическом выполнении следующих шагов вплоть до достижения желаемого числа компонентов.

**Шаг 1.** Найти строки из множества прецедентов  $X$ , которые плохо описываются смесью

$$X_b := \left\{ x \in X \mid P(x) \equiv \sum_{j=1}^k w_j p(x | \theta_j) < \delta \right\},$$

где  $k$  — текущее число цепей Маркова в смеси,  $\delta$  — пороговая вероятность, определяемая как среднее значение вероятности строк выборки

$$\delta := \frac{1}{n} \sum_{j=1}^n P(x^j).$$

**Шаг 2.** Образовать из строк  $X_b$  новый компонент

$$w_{k+1} := \frac{|X_b|}{n}; \quad \theta_{k+1} := WM(X, \{[x^i \in X_b]\}_{i=1}^n); \quad \Theta := \Theta \cup \{w_{k+1}; \theta_{k+1}\},$$

откорректировав веса остальных компонентов  $\forall j = 1, \dots, k \quad w_j := w_j (1 - w_{k+1})$ .

**Шаг 3.** Выполнить ЕМ-алгоритм, используя  $\Theta$  в качестве начального набора параметров.

Для упрощения расчетов при выделении компонентов на шаге вместо вероятностей  $P(x^i)$  можно использовать определенные ранее величины  $z_i^{\max}$ , которые приблизительно равны  $\log P(x^i)$ . При этом, как и в случае применения самих вероятностей, отдается предпочтение более длинным строкам; для более равномерного распределения строк по длинам в  $X_b$  величины  $z_i^{\max}$  следует нормировать на длину  $|x^i|$ :

$$X_b := \left\{ x^i \mid i = 1, \dots, n, \frac{z_i^{\max}}{|x^i|} < \frac{1}{n} \sum_{j=1}^n \frac{z_j^{\max}}{|x^j|} \right\}.$$

При последовательном удалении компонентов начальное приближение состоит из  $K$  цепей Маркова, где  $K$  заведомо превышает возможное число компонентов смеси. Параметры для каждой цепи получаются путем обучения на частях множества прецедентов, полученных разбиением  $X$  на приблизительно равные части случайным образом. Более формально

$$\forall j = 1, \dots, K \quad w_j := \frac{1}{n} \sum_{i=1}^n [\xi_i = j], \quad \theta_j := WM(X, \{[\xi_i = j]\}_{i=1}^n),$$

где независимые случайные величины  $\xi_i$  равномерно распределены на множестве целых чисел  $\{1, 2, \dots, k\}$ .

Алгоритм построения оптимальной композиции заключается в циклическом выполнении приведенных далее шагов.

**Шаг 1.** Удалить из смеси компонент с наименьшим весом, откорректировав веса остальных компонентов

$$t := \arg \min_{j=1, \dots, k} w_j, \quad \Theta := \Theta \setminus \{w_t; \theta_t\}, \quad \forall j \neq t \quad w_j := \frac{w_j}{1 - w_t}.$$

**Шаг 2.** Выполнить ЕМ-алгоритм с начальным приближением  $\Theta$ .

Критерием останова, как и в предыдущем случае, является достижение требуемого числа компонентов в смеси.

## РАСПОЗНАВАНИЕ ФРАГМЕНТОВ ГЕНОВ

Для предсказания функциональной структуры генов можно применять описанный ранее подход. Гены всех живых организмов представляют собой последовательности, состоящие из четырех нуклеотидов: аденина  $A$ , цитозина  $C$ , гуанина  $G$  и тимина  $T$  [8]. Основными функциональными фрагментами генов являются чередующиеся один за другим экзоны — участки, кодирующие белки, и интроны — участки, не принимающие участия в синтезе белка. Таким образом, алфавит, позволяющий кодировать информацию о нуклеотидах генов и их распределении по функциональным участкам, состоит из восьми символов:  $Q = \{A, C, G, T, a, c, g, t\}$ , где заглавными буквами обозначены нуклеотиды, входящие в состав экзонов, строчными — интронные нуклеотиды. Множество прецедентов  $X \subset Q^*$  совпадает с геном — набором всех генов определенного биологического вида.

Задача нахождения структуры гена сводится к определению строки  $x \in Q^*$  по известной последовательности нуклеотидов гена  $s = \text{Pr}_s(x) \in \{A, C, G, T\}^* \equiv O^*$ , где функция  $\text{Pr}_s$  определена как  $\text{Pr}_s: (A, C, G, T, a, c, g, t) \rightarrow (A, C, G, T, A, C, G, T)$ .

Для ее решения можно использовать вероятностные модели на основе цепей Маркова [2]

$$x = \arg \max_{z \in Q^*} P(z)[\text{Pr}_s(z) = s], \quad (13)$$

где  $P(z)$  рассчитывается по формуле (2). Этот подход эффективен для определения структуры генов простых организмов (например, растений и насекомых); вместе с тем для генов высших организмов (например, млекопитающих) он приводит к неудовлетворительному качеству классификации. Для повышения качества можно использовать композиции алгоритмов с эксклюзивной компетентностью компонентов [3], для которых функция плотности вероятности аналогична (1)

$$P(x) = \sum_{j=1}^k w_j P(x | \theta_j)[\text{Pr}_s(x) \in G_j], \quad (14)$$

где  $\{G_j\}_{j=1}^k$  — покрытие множества  $O^*$ .

Итак, EM-алгоритм можно использовать непосредственно для построения оптимальных композиций, однако при этом возникают определенные затруднения:

- высокий порядок цепей Маркова, необходимый для удовлетворительного качества классификации, приводит к сильному переобучению при выделении компонентов;
- задача максимизации (13) при использовании плотности распределения вероятности (1) существенно сложнее, чем при использовании функции плотности (14), для решения которой, как и в случае одной цепи Маркова, можно использовать алгоритм Виттерби.

Пусть  $j^*(x)$  — номер наиболее вероятной цепи Маркова из композиции для строки  $x$ :

$$j^*(x) = \arg \max_{j=1, \dots, k} w_j p(x | \theta_j) = \arg \max_{j=1, \dots, k} P(\theta_j | x).$$

Если композиция эффективно разделяет множество прецедентов, выполняются неравенства  $\forall j \neq j^*(x) P(\theta_j | x) < P(\theta_{j^*} | x)$ , откуда

$$P(x) \approx w_{j^*(x)} P(x | \theta_{j^*(x)}), \quad (15)$$

что совпадает с выражением (14). При этом решается проблема максимизации и вторая из упомянутых ранее проблем: значения  $j^*(x)$ , полученные при построении композиции с низким порядком цепей Маркова  $l$ , можно использо-

вать для разделения обучающей выборки на части  $\{x \in X \mid j^*(x) = s\}_{s=1}^k$  и обучения на этих частях цепей более высокого порядка.

В реальных задачах, когда структура гена  $x$  неизвестна, для оценки  $j^*(x)$  можно использовать какой-либо метод классификации, основанный на числовых признаках, полученных из известной нуклеотидной записи  $s = \text{Pr}_s(x)$ . Один из возможных наборов признаков — эмпирические оценки переходных вероятностей  $m$ -го порядка для строки  $s$ :

$$\hat{p}_m(v \mid u) = \frac{\sum_i [s_i \dots s_{i+m-1} = u]}{\sum_i [s_i \dots s_{i+m-1} = v]}, \quad u \in O^m, \quad v \in O; \quad (16)$$

в этом случае каждой строке  $s$  соответствует вектор из  $4^{m+1}$  чисел, расположенных на отрезке  $[0, 1]$ . В качестве алгоритма классификации в настоящей работе рассмотрен метод опорных векторов (SVM) [9], адаптированный для задачи классификации с произвольным количеством классов путем построения отдельных классификаторов для каждой пары классов [10].

#### ВЫЧИСЛИТЕЛЬНЫЙ ЭКСПЕРИМЕНТ

Для проверки эффективности построения смесей вероятностных распределений с помощью ЕМ-алгоритма рассматривались геномы шести видов, доступные в репозитории NCBI [11]: *Homo sapiens* (человек), *Gallus gallus* (курица), *Mus musculus* (мышь), *Rattus norvegicus* (крыса), *Papio anubis* (павиан) и *Sus scrofa* (свинья). Принимались во внимание гены, для которых полностью известна нуклеотидная запись; для генов человека и мыши для ускорения вычислений вводилось ограничение на длину: не более 40000 нуклеотидов.

Эффективность оптимизации ЕМ-алгоритмом оценивалась с помощью функционала (5), для удобства нормализованного на количество строк во множестве прецедентов  $X$ :

$$Q_n(\Theta; X) = \frac{1}{|X|} Q(\Theta; X).$$

При работе алгоритма использовались следующие параметры:

- порядок цепей Маркова  $l = 5$ ;
- полуширина окна усреднения для распределения строк по длинам  $\varphi = 50$ ;
- максимальная длина строк в этом же распределении  $d_{\max} = 20000$ ;
- нижние пороги вероятностей  $\varepsilon_\varphi = 10^{-7}$ ,  $\varepsilon_\pi = \varepsilon_p = 10^{-4}$ ;
- критерий остановки алгоритма — выполнение 20 итераций.

Результаты оптимизации при использовании последовательного добавления и удаления компонентов смеси отображены на рис. 1 и 2 соответственно. Здесь  $\Delta Q = Q_n(k) - Q_n(1)$  и  $\Delta Q = Q(k) - Q_n(5)$  — приращения функционала качества (5);  $k$  — число классов.

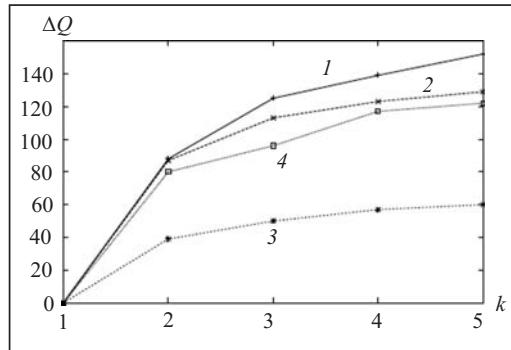


Рис. 1. Функционал качества для алгоритма последовательного добавления компонентов смеси для геномов: *Homo sapiens* — кривая 1; *Gallus gallus* — 2; *Mus musculus* — 3; *Papio anubis* — 4

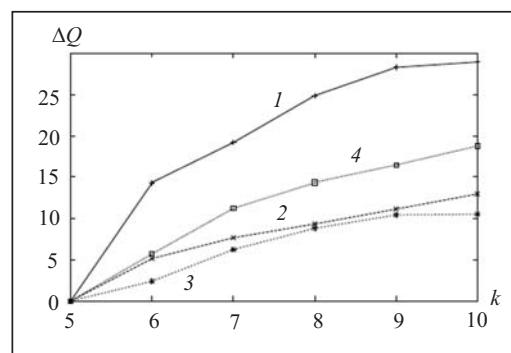


Рис. 2. Функционал качества для алгоритма последовательного удаления компонентов смеси для геномов: *Homo sapiens* — кривая 1; *Gallus gallus* — 2; *Mus musculus* — 3; *Sus scrofa* — 4.

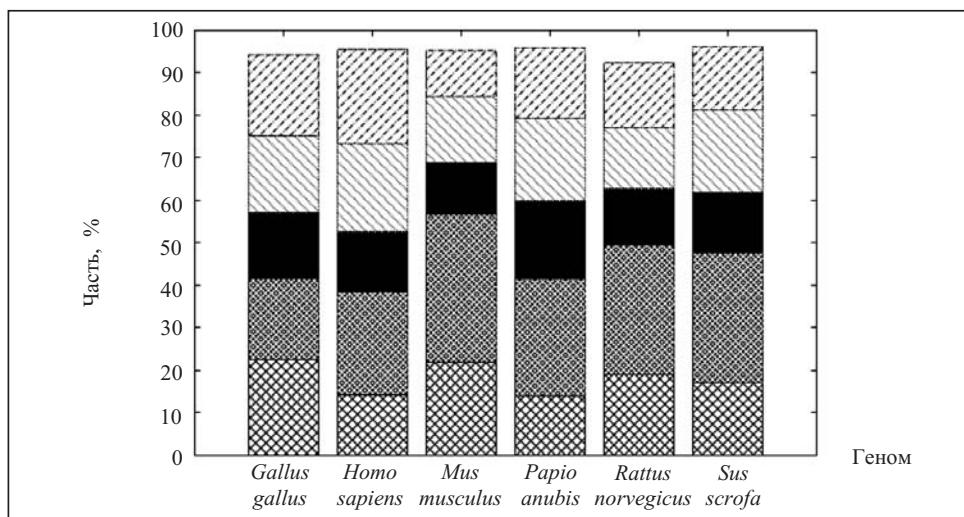


Рис. 3. Распределение генов исследуемых видов по пяти компонентам

**Таблица 1.** Функционал подобия (17) смесей из четырех компонентов для различных видов

Композиция $X$	Значения функционала для пары $X$ и $Y$					
	Композиция $Y$					
	<i>Gallus gallus</i>	<i>Homo sapiens</i>	<i>Mus musculus</i>	<i>Papio anubis</i>	<i>Sus scrofa</i>	<i>Rattus norvegicus</i>
<i>Gallus gallus</i>	0,0	409,2	176,4	256,5	349,8	148,9
<i>Homo sapiens</i>	359,1	0,0	132,6	9,5	356,7	128,1
<i>Mus musculus</i>	259,5	300,8	0,0	187,1	314,9	22,1
<i>Papio anubis</i>	305,1	14,4	123,2	0,0	330,0	115,6
<i>Sus scrofa</i>	319,5	375,7	169,3	239,9	0,0	141,8
<i>Rattus norvegicus</i>	250,3	323,0	24,3	198,1	305,4	0,0

На рис. 3 показан график распределения генов по наиболее вероятным компонентам  $j^*(x)$  при ограничении значений апостериорной вероятности  $\max_j P(x|\theta_j) > 0,95$ . Как видно, гены распределены по составляющим смеси достаточно равномерно; количество генов, для которых ни одна апостериорная вероятность не превышает 0,95, пренебрежимо мало (около 5% для каждого вида), что обосновывает возможность перехода (15).

Несмотря на сложность смесей (1) по сравнению с деревьями разбиений, описанными в [3], их можно эффективно использовать для классификации других геномов. Подобие смесей двух геномов:  $X$  и  $Y$ , рассчитывалось по формуле

$$Q_n(\Theta(X); X) - Q_n(\Theta(X); Y), \quad (17)$$

т.е. равнялось снижению функционала качества смеси, полученной с помощью ЕМ-алгоритма на генах  $X$ , при вычислении на другом геноме. Для двухкомпонентных смесей величины (17) для всех пар  $(X, Y)$  приблизительно равны нулю. Последнее означает, что они почти подобны. При увеличении числа компонентов различия между композициями становятся более явными, за исключением пар похожих организмов: мыши и крысы, человека и павиана (табл. 1).

Для аппроксимации значений  $j^*(x)$  использовались переходные вероятности (16) четвертого порядка, дающие  $4^5 = 1024$  признака на каждую строку. При-

**Таблица 2.** Точность аппроксимации разбиений геномов методом опорных векторов

Геном	Точность аппроксимации разбиений (%) для числа классов			
	2	3	4	5
<i>Gallus gallus</i>	94,73	91,49	86,09	81,61
<i>Homo sapiens</i>	96,25	92,78	89,79	87,30
<i>Mus musculus</i>	95,46	90,21	86,67	81,96
<i>Papio anubis</i>	95,45	88,99	87,68	84,10
<i>Sus scrofa</i>	96,17	91,44	86,01	83,85
<i>Rattus norvegicus</i>	95,09	89,63	84,08	80,74

**Таблица 3.** Качество классификации фрагментов генов при использовании смесей и их аппроксимаций

Геном	Число алгоритмов	Значения меры качества, %					
		<i>NSp</i>	<i>NSn</i>	<i>CC</i>	<i>ACP</i>	<i>ESp</i>	<i>ESn</i>
<i>Gallus gallus</i>	1	54,41	64,65	56,06	78,12	47,39	32,03
	3	69,11	65,51	64,97	82,50	52,72	37,58
	3.SVM	69,66	64,55	64,76	82,40	52,97	37,63
<i>Homo sapiens</i>	1	35,58	89,56	49,48	76,45	27,64	31,11
	5	57,04	86,75	66,39	83,73	44,95	48,91
	5.SVM	57,48	86,15	66,42	83,71	45,19	49,70
<i>Mus musculus</i>	1	59,97	85,32	67,20	83,97	42,22	40,39
	5	76,00	81,49	75,77	87,90	53,38	47,62
	5.SVM	76,28	81,58	75,96	87,99	53,47	47,87
<i>Papio anubis</i>	1	39,91	86,65	52,28	77,45	30,41	31,42
	5	68,52	81,59	71,51	85,86	50,62	49,17
	5.SVM	68,23	81,13	71,09	85,65	50,78	49,74
<i>Sus scrofa</i>	1	33,24	85,66	47,60	75,75	24,87	26,64
	5	57,92	78,85	64,31	82,46	41,05	41,01
	5.SVM	55,41	78,20	62,31	81,53	40,77	41,86
<i>Rattus norvegicus</i>	1	61,73	83,59	67,47	84,01	40,75	36,49
	4	76,45	78,20	74,10	87,05	48,55	40,28
	4.SVM	76,30	78,34	74,00	87,00	48,85	40,63

менялась реализация метода опорных векторов из библиотеки libsvm с радиально-базисными функциями и управляющим параметром  $C = 1$ . В результате пятикратной кросс-валидации было установлено, что SVM показывает достаточно высокое качество классификации, постепенно уменьшающееся при увеличении количества компонентов в смеси (табл. 2).

Вычислительный эксперимент завершился проверкой эффективности композиций вида (1) для классификации экзонов и инtronов. Для измерения качества использовалась пятикратная кросс-валидация с шестью метриками, описанными в [1]:

- метрики *NSp* (нуклеотидная специфичность), *NSn* (нуклеотидная чувствительность), *CC* (коэффициент корреляции), *ACP* (средняя условная вероятность) оценивают качество классификации отдельных оснований;
- меры *ESp* (экзонная специфичность) и *ESn* (экзонная чувствительность) измеряют качество определения границ между экзонами и инtronами.

В результате вычислений выяснено, что оптимальные смеси, которые строятся при кросс-валидации, порождаемые ими значения  $j^*(x)$  и их аппроксимации с помощью метода опорных векторов мало отличаются от соответствующих им

величин, построенных для полных выборок. В соответствии с этим, как и в работе [3], для ускорения вычислений использовались смеси распределений, полученные на целых геномах. Результаты для композиций цепей Маркова седьмого порядка приведены в табл. 3, где под 3.SVM подразумевается использование композиции из трех алгоритмов с аппроксимацией разбиения с помощью SVM. Как видно, применение смесей позволяет существенно повысить качество классификации; при этом для метода SVM метрики практически не меняются.

## ЗАКЛЮЧЕНИЕ

Рассмотрена общая постановка задачи разделения смеси распределений, представляющих собой цепи Маркова произвольного порядка. Для решения задачи предложен ЕМ-алгоритм с вспомогательными алгоритмами, используемыми для определения выбора начального приближения и оптимального числа компонентов смеси. Показано, как приведенные рассуждения можно применить для решения задачи определения фрагментов генов (экзонов и инtronов). Полученные композиции алгоритмов с эксплюзивной компетентностью позволяют ощутимо повысить качество классификации, что свидетельствует о возможности применения цепей Маркова высоких порядков для описания генов.

В качестве направлений для дальнейших исследований можно выделить:

- кластеризацию с помощью полученного математического аппарата интронов и экзонов;
- применение ЕМ-алгоритма для повышения качества классификации в других задачах биоинформатики, в частности, задачи определения вторичной структуры белков.

## СПИСОК ЛИТЕРАТУРЫ

1. Knapp K., Chen Y.-P. P. An evaluation of contemporary hidden Markov model genefinders with a predicted exon taxonomy // Nucleic Acids Research. — 2007. — 35. — P. 317–324.
2. Сергиенко И.В., Гупал А.М., Островский А.В. Распознавание фрагментов генов в ДНК с применением моделей Маркова со скрытыми переменными // Кибернетика и системный анализ. — 2012. — № 3. — С. 58–67.
3. Гупал А.М., Островский А.В. Использование композиций моделей Маркова для определения функциональных участков генов // Там же. — 2013. — № 5. — С. 61–68.
4. Шлезингер М.И. О самопроизвольном распознавании образов // Читающие автоматы. — К.: Наук. думка, 1965. — С. 38–45.
5. Dempster A.P., Laird N.M., Rubin D.B. Maximum likelihood from incomplete data via the EM algorithm // J. the Royal Statistical Society. Ser. B. — 1977. — 34. — P. 1–38.
6. Bishop C. Pattern recognition and machine learning. — Cambridge: Springer, 2006. — 749 p.
7. Айвазян С.А., Бухштабер В.М., Енюков И.С., Мешалкин Л.Д. Прикладная статистика: классификация и снижение размерности. — М.: Финансы и статистика, 1989. — 607 с.
8. Ридли М. Геном: автобиография вида в 23 главах. — М.: Эксмо, 2008. — 432 с.
9. Cortes C., Vapnik V. Support vector machines // Machine Learning. — 1995. — 20. — P. 273–293.
10. Knerr S., Pesonnaz L., Dreyfus G. Single-layer learning revisited: a stepwise procedure for building and training a neural network // Neurocomputing: Algorithms, Architectures and Applications / F.F. Soulie, J. Herald (Eds). — Berlin: Springer, 1990. — P. 41–50.
11. Национальный центр биотехнологической информации США. — <http://ncbi.nlm.nih.gov/>.

Поступила 08.04.2014