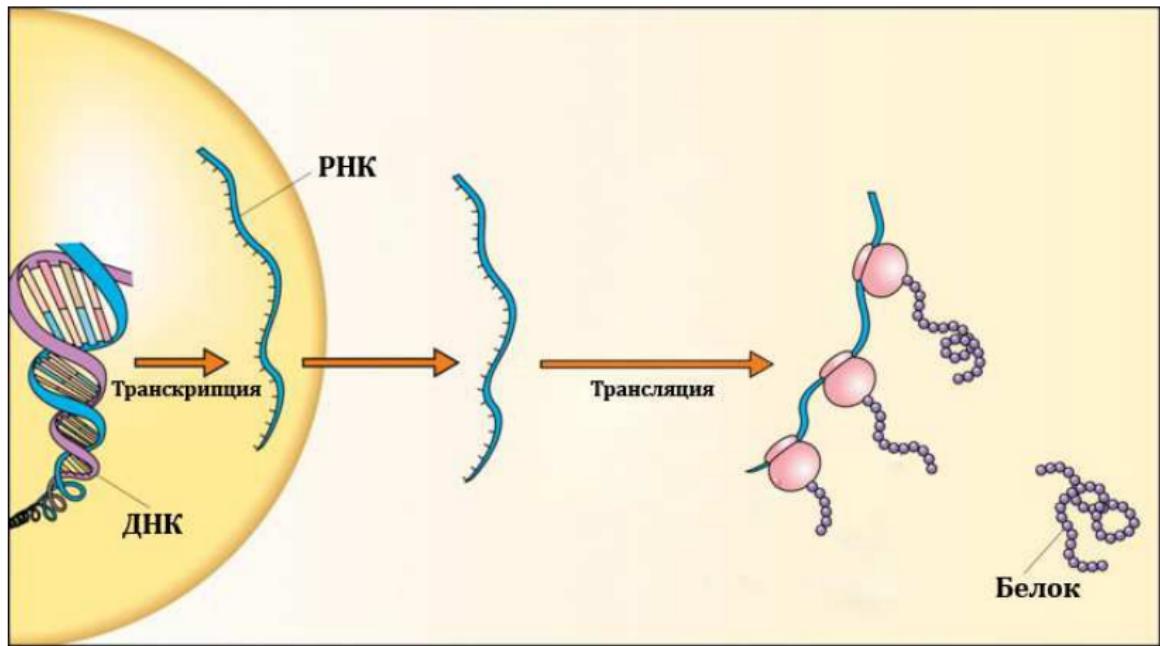


## Оптимизационные методы решения некорректно поставленных задач анализа данных ДНК-микрочипов

Рябенко Евгений, аспирант ВМК МГУ  
научный руководитель д.ф.-м.н., К.В. Воронцов

Семинар отдела Интеллектуальных систем  
ВЦ РАН • 12 сентября 2012 г.

# Центральная догма молекулярной биологии



## Базовые понятия

**ДНК** — молекула, содержащая информацию, необходимую для функционирования клетки.

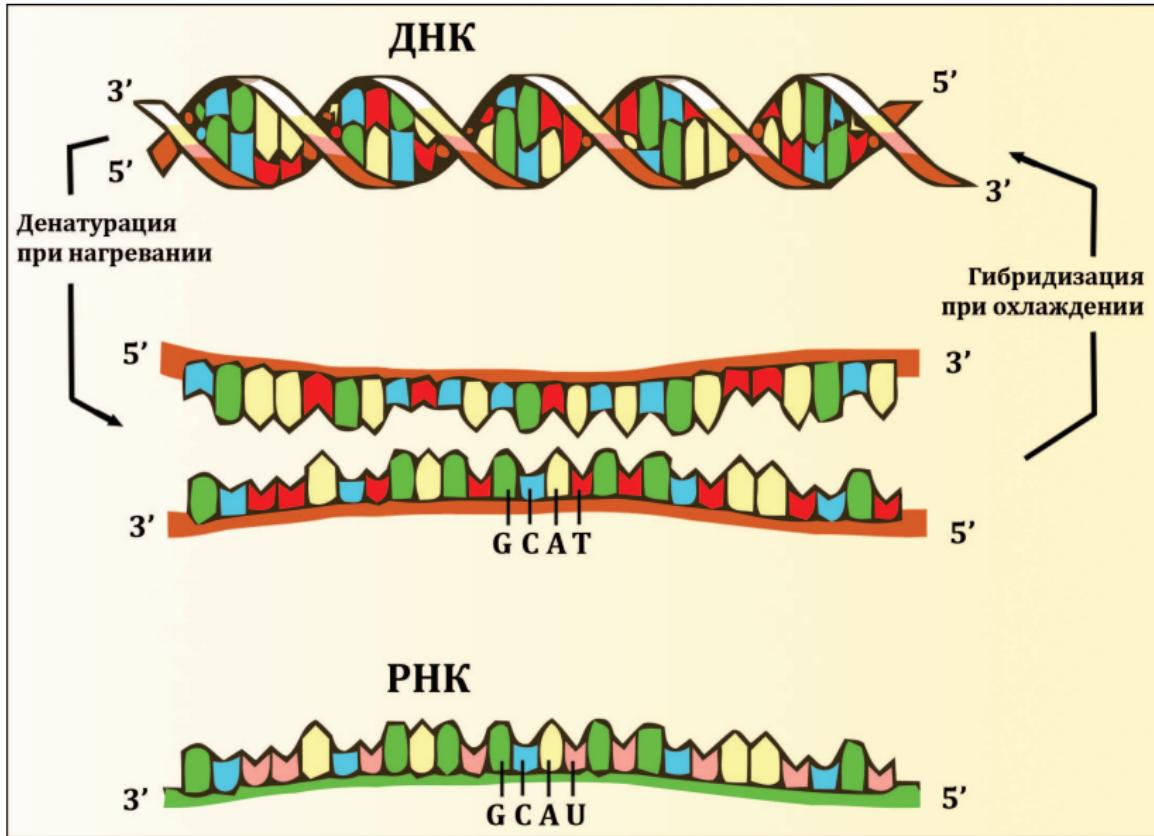
**Ген** — участок ДНК, несущий какую-либо целостную функциональную информацию.

**Экспрессия гена** — преобразование информации, содержащейся в гене, в функциональный продукт.

**РНК** — молекула-посредник, передающий информацию о гене структурам клетки, отвечающим за синтез белка.

Количество молекул РНК в клетке служит мерой активности гена (оценкой экспрессии).

# ДНК и РНК



## Ход эксперимента

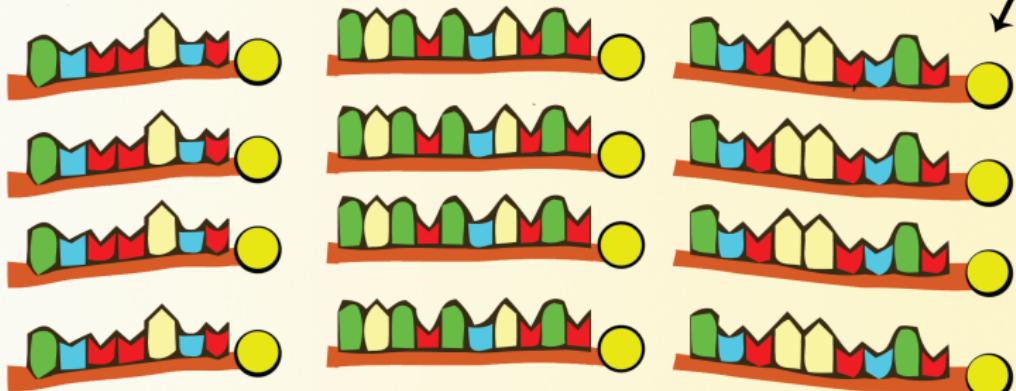
### РНК



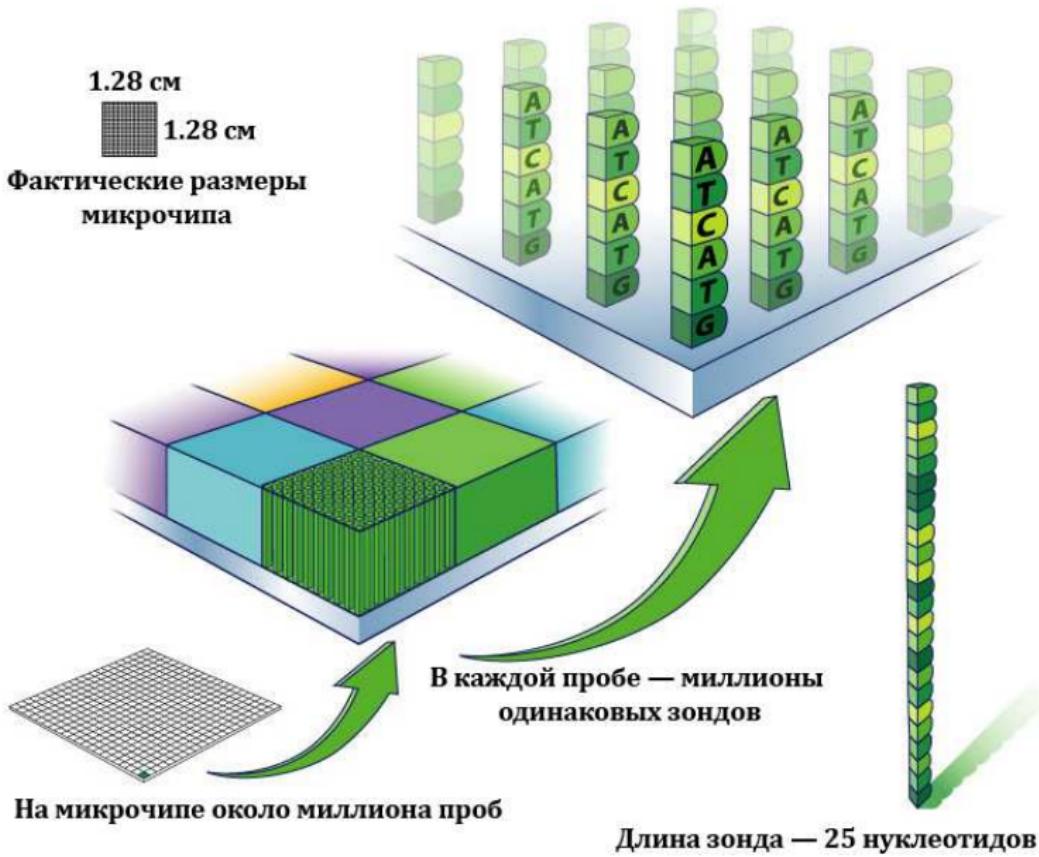
одноцепочечная ДНК



помеченные фрагменты

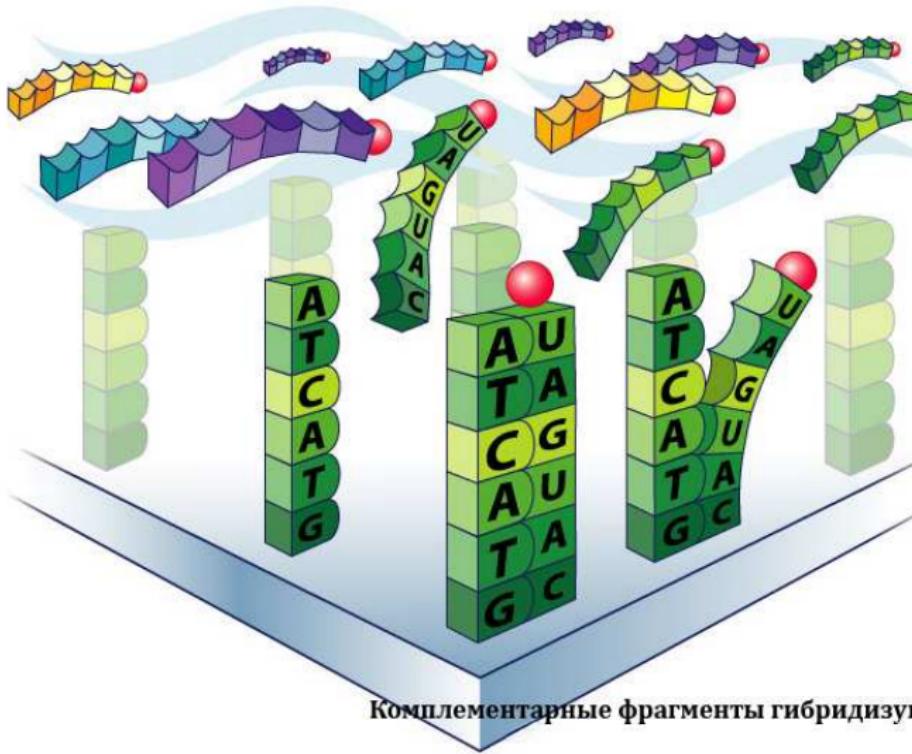


## Вид микрочипа



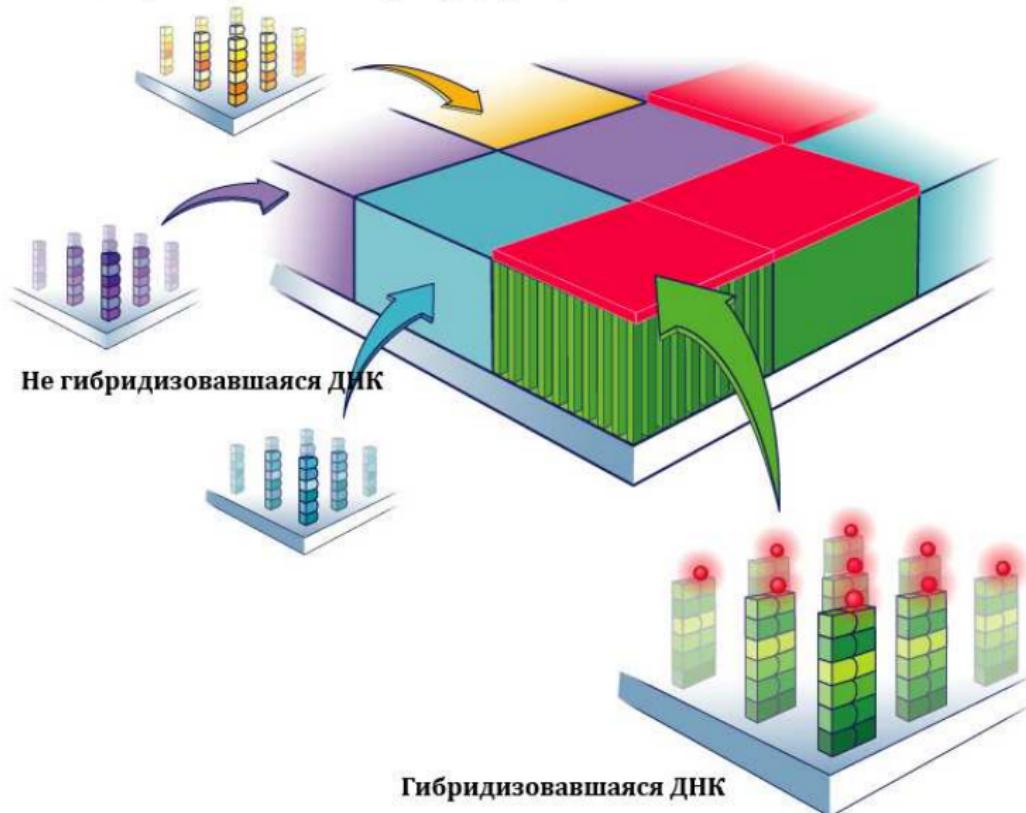
# Гибридизация

Помеченные фрагменты одноцепочечной ДНК наносятся на чип

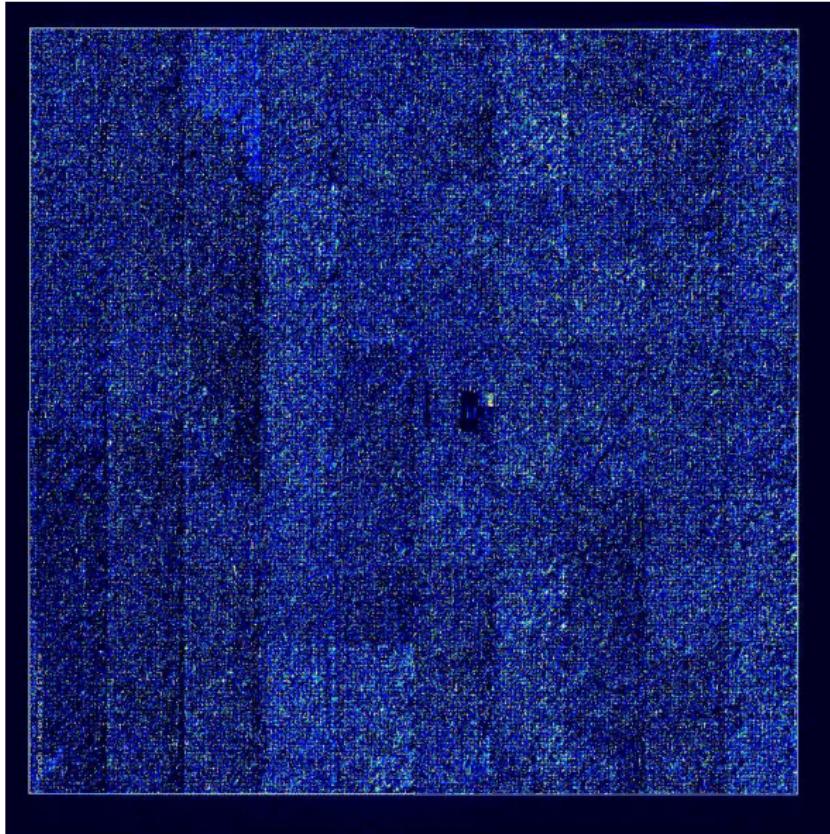


# Сканирование

При облучении лазером флуоресцентные метки светятся



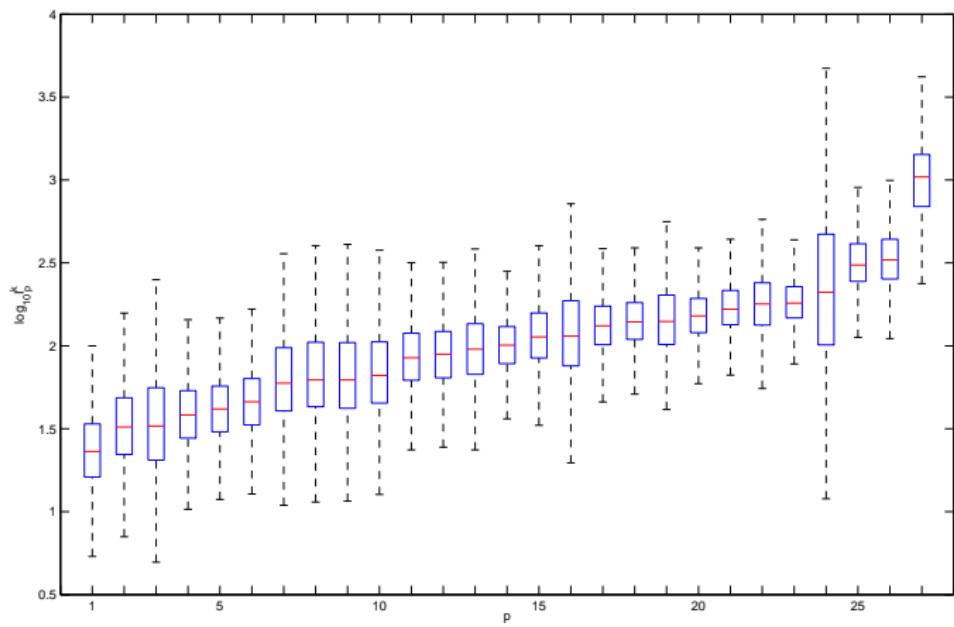
## Результат сканирования



## Получение оценок экспрессии

- ➊ Изображение со сканера оцифровывается, получаем вектор значений интенсивности флуоресценции проб.
- ➋ Проводится предобработка интенсивностей:
  - ➌ фоновая поправка;
  - ➌ нормализация.
- ➌ Значения предобработанных интенсивностей всех проб каждого гена **усредняются** (median polish), давая оценку экспрессии.

## Распределения интенсивностей проб



# Линейная модель, учитывающая степени сродства проб с геном

**Известные данные:**

$I_p^k$  — интенсивность свечения пробы  $p$  на микрочипе  $k$ ;  
 $g(p)$  — номер гена, для которого пробы  $p$  специфична  
(определен конструкцией микрочипа).

**Неизвестные параметры:**

$c_g^k$  — концентрация РНК гена  $g$  на микрочипе  $k$ ;  
 $a_p$  — коэффициент сродства (affinity) пробы  $p$  гену  $g(p)$ .

$$\hat{I}_p^k = a_p c_{g(p)}^k.$$

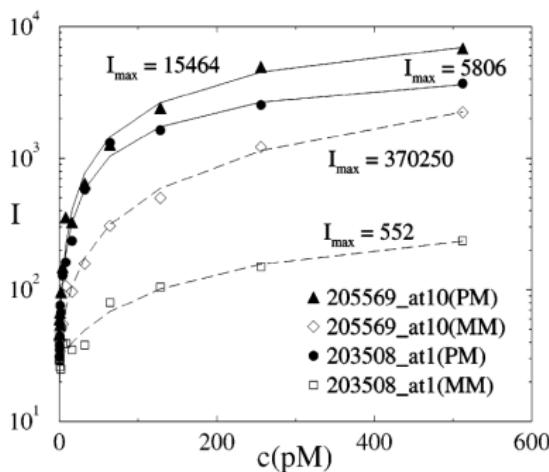
- ограничений = проб × чипов.  
735 497
- неизвестных = проб + (генов) × чипов.  
735 497      26 902

Необходимо иметь хотя бы два микрочипа.

## Недостатки стандартных методов

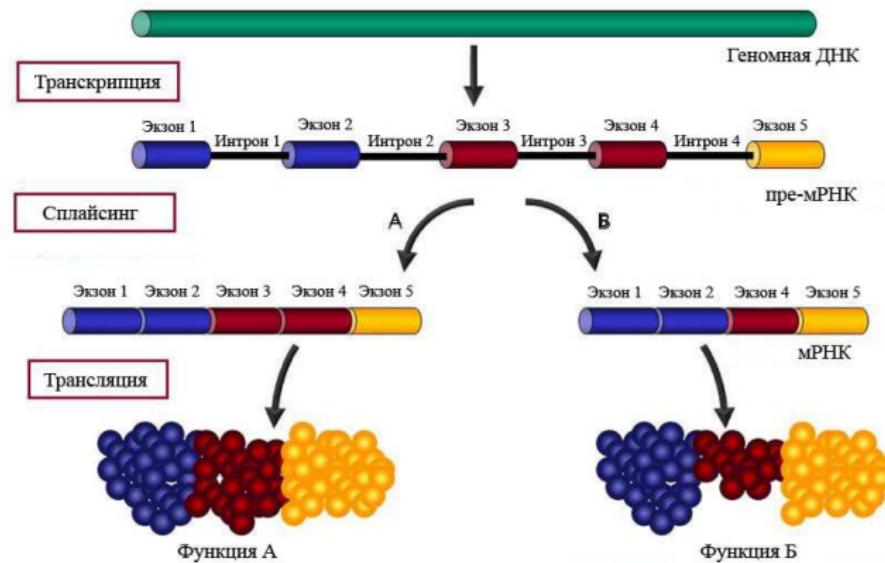
- Коэффициенты средства не фиксированы, а определяются по анализируемой выборке.
- Зависимость интенсивностей свечения от концентраций РНК гена лучше описывается функцией Лэнгмюра:

$$\hat{I}_p^k = \frac{a_p c_{g(p)}^k}{1 + b_p c_{g(p)}^k}$$

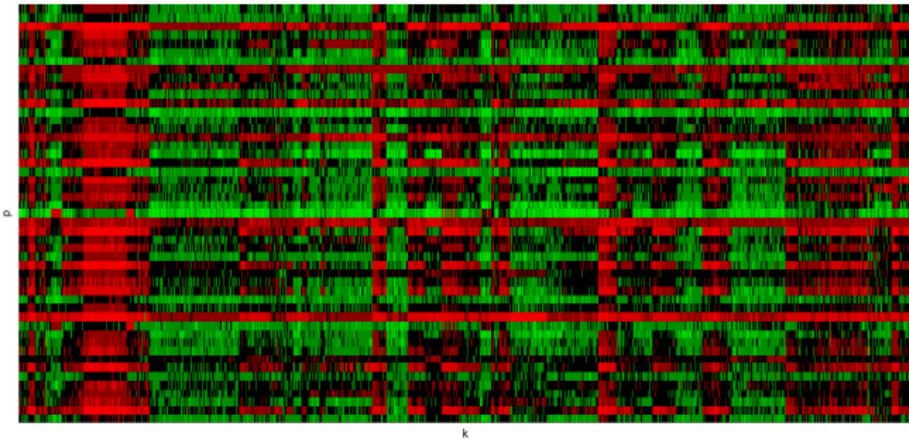


# Недостатки стандартных методов

- Не учитывается эффект альтернативного сплайсинга.



## Эффект альтернативного сплайсинга



## Постановка задачи

**Задача:** построить метод настройки параметров нелинейной модели Лэнгмюра с учётом альтернативного сплайсинга.

**Имеющиеся данные:** интенсивности флуоресценции 735497 проб на 3459 микрочипах Affymetrix Human Gene 1.0 ST; данные взяты из общедоступной базы данных NCBI Gene Expression Omnibus.

Параметры модели будем находить как результат минимизации некоторой функции потерь

$$D \left( I, \frac{ac}{1 + bc} \right) \rightarrow \min_{a,b,c} .$$

# Функция потерь

Варианты выбора функции потерь:

- норма Фробениуса (оптимальна для аддитивного гауссовского шума)

$$D(P, Q) = \sum_{i,j} (p_{ij} - q_{ij})^2;$$

- норма  $l_1$  (устойчива к выбросам, оптимальна для аддитивного лапласовского шума)

$$D(P, Q) = \sum_{i,j} |p_{ij} - q_{ij}|;$$

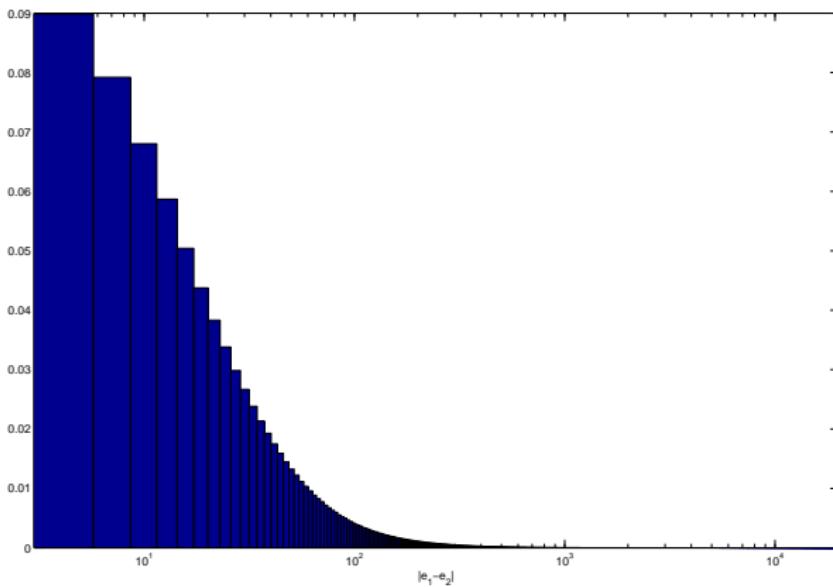
- М-оценки (устойчивы к выбросам)

$$D(P, Q) = \sum_{i,j} \rho(p_{ij} - q_{ij}),$$

$$\rho(x) = \begin{cases} \frac{x^2}{2}, & \text{если } |x| \leq 1.345, \\ 1.345 (|x| - 0.6725), & \text{если } |x| > 1.345; \end{cases}$$

$$\rho(x) = \frac{x^2}{2(1+x^2)}.$$

# Шум



Плотность распределения модулей разности интенсивностей свечения проб на технических репликах — микрочипах, на которые был нанесён один и тот же образец.

## Функция потерь

$$D_{AB}^{(\alpha,\beta)}(P, Q) = \sum_{i,j} d_{AB}^{(\alpha,\beta)}(p_{ij}, q_{ij}),$$
$$d_{AB}^{(\alpha,\beta)}(p, q) = \begin{cases} -\frac{1}{\alpha\beta} \left( p^\alpha q^\beta - \frac{\alpha}{\alpha+\beta} p^{\alpha+\beta} - \frac{\beta}{\alpha+\beta} q^{\alpha+\beta} \right), & \alpha, \beta, \alpha + \beta \neq 0, \\ \frac{1}{\alpha^2} \left( p^\alpha \ln \frac{p^\alpha}{q^\alpha} - p^\alpha + q^\alpha \right), & \alpha \neq 0, \beta = 0, \\ \frac{1}{\alpha^2} \left( \ln \frac{q^\alpha}{p^\alpha} + \left( \frac{q^\alpha}{p^\alpha} \right)^{-1} - 1 \right), & \alpha = -\beta \neq 0, \\ \frac{1}{\beta^2} \left( q^\beta \ln \frac{q^\beta}{p^\beta} - q^\beta + p^\beta \right), & \alpha = 0, \beta \neq 0, \\ \frac{1}{2} (\ln p - \ln q)^2, & \alpha = \beta = 0. \end{cases}$$

При различных значениях  $(\alpha, \beta)$  получаемые оценки — ОМП для разных видов распределения шума.

## Критерии качества

- Точность приближения:

$$fit(I, a, b, c) = \frac{\sum_{k=1}^K \sum_{p=1}^P I_p^k \left| I_p^k - \frac{a_p c_{g(p)}^k}{1+b_p c_{g(p)}^k} \right| W_p^k}{\sum_{k=1}^K \sum_{p=1}^P I_p^k W_p^k}$$

$W$  — бинарная матрица, в которой нули соответствуют пробам, не светящимся из-за альтернативного сплайсинга.

# Критерии качества

- Воспроизводимость параметров пробы:

$$rep_a = \frac{1}{P} \sum_{p=1}^P \left[ \frac{|a_{1p} - a_{2p}|}{a_{1p} + a_{2p}} > 0.5 \right],$$

$$rep_b = \frac{1}{P} \sum_{p=1}^P \left[ \frac{|b_{1p} - b_{2p}|}{b_{1p} + b_{2p}} > 0.5 \right].$$

Исходная выборка микрочипов разбивается на две части, по каждой из них восстанавливаются параметры проб  $a_1, b_1$  и  $a_2, b_2$ . Величины

$\frac{|a_{1p} - a_{2p}|}{a_{1p} + a_{2p}}$ ,  $\frac{|b_{1p} - b_{2p}|}{b_{1p} + b_{2p}}$  принимают значения на  $[0, 1]$ ; их распределение имеет два выраженных пика в нуле и единице, поэтому будем усреднять индикаторы  $[x > 0.5]$ .

## Критерии качества

- Воспроизводимость оценок экспрессии:

$$rep_c = \frac{1}{5GK} \sum_{k=1}^K \sum_{p=1}^P \sum_{i=1}^5 \frac{|c_g^k - c_{g,\bar{p}_i}^k|}{c_g^k + c_{g,\bar{p}_i}^k}$$

Для каждого гена  $g$  исключим из рассмотрения пробу  $p_i$  и оценим концентрацию РНК гена по множеству оставшихся проб  $P(g) \setminus p_i$ ;  $c_{g,\bar{p}_i}$  — полученный вектор оценок экспрессии. Мера воспроизводимости — расстояние между  $c_g$  и  $c_{g,\bar{p}_i}$ ; для большей устойчивости усредняется по пяти разным пробам  $p_i$ .

## Оптимизационная задача

$$\sum_{k=1}^K \sum_{p=1}^P d_{AB}^{(\alpha, \beta)} \left( I_p^k, \frac{a_p c_{g(p)}^k}{1 + b_p c_{g(p)}^k} \right) \rightarrow \min_{a, b, c},$$
$$a_p \geq 0, b_p \geq 0, \quad p = 1, \dots, P,$$
$$c_g^k \geq 0, \quad g = 1, \dots, G, \quad k = 1, \dots, K.$$

Благодаря сепарабельности функции потерь задача распадается на  $G$  независимых подзадач:

$$\sum_{k=1}^K \sum_{p \in P(g)} d_{AB}^{(\alpha, \beta)} \left( I_p^k, \frac{a_p c_g^k}{1 + b_p c_g^k} \right) \rightarrow \min_{a_g, b_g, c_g}, \quad (1)$$
$$a_p \geq 0, b_p \geq 0, \quad p \in P(g),$$
$$c_g^k \geq 0, \quad k = 1, \dots, K.$$

## Оптимизационная задача

Пусть  $a_g, b_g, c_g$  — решение задачи (1), тогда для произвольной константы  $C > 0$  векторы  $\frac{1}{C} \cdot a_g, \frac{1}{C} \cdot b_g, C \cdot c_g$  тоже будут являться решением.

Для однозначности решения добавим условие нормировки, используемое в стандартных методах обработки микрочиповых данных:

$$\prod_{p \in P(g)} a_p = 1, \quad g = 1, \dots, G.$$

Для обеспечения устойчивости оценок экспрессии добавим к функции потерь регуляризующее слагаемое

$$\frac{\alpha_c}{2} \sum_{k=1}^K \left( c_g^k \right)^2,$$

где  $\alpha_c$  — параметр регуляризации.

## Оптимизационная задача

$$f(I_g, a_g, b_g, c_g, \alpha_c) = \sum_{k=1}^K \sum_{p \in P(g)} d_{AB}^{(\alpha, \beta)} \left( I_p^k, \frac{a_p c_g^k}{1 + b_p c_g^k} \right) + \frac{\alpha_c}{2} \sum_{k=1}^K \left( c_g^k \right)^2 \rightarrow \min_{a_g, b_g, c_g},$$

$$\prod_{p \in P(g)} a_p = 1, \tag{2}$$

$$a_p \geq 0, b_p \geq 0, \quad p \in P(g),$$

$$c_g^k \geq 0, \quad k = 1, \dots, K.$$

Для простоты далее индекс  $g$  будем опускать.

## Решение оптимизационной задачи

Используем метод блочно-покоординатного спуска, делая шаги стандартного метода Ньютона с проецией на положительную область изменения параметров поочерёдно по  $a$ ,  $b$  и  $c$ ; благодаря сепарабельности функции потерь каждая из трёх задач минимизации распадается на независимые подзадачи:

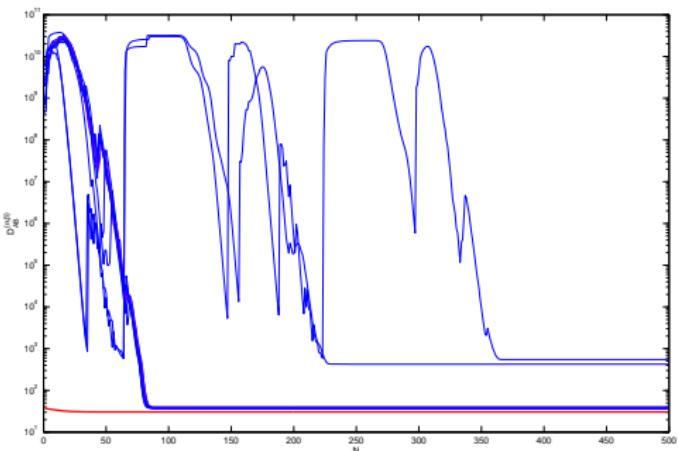
$$a_p = \max \left( 0, a_p - \frac{\partial f(I, a, b, c, \alpha_c)}{\partial a_p} \Bigg/ \frac{\partial^2 f(I, a, b, c, \alpha_c)}{\partial a_p^2} \right), \quad p \in P(g),$$

$$c^k = \max \left( 0, c^k - \frac{\partial f(I, a, b, c, \alpha_c)}{\partial c^k} \Bigg/ \frac{\partial^2 f(I, a, b, c, \alpha_c)}{\partial (c^k)^2} \right), \quad k = 1, \dots, K,$$

$$b_p = \max \left( 0, b_p - \frac{\partial f(I, a, b, c, \alpha_c)}{\partial b_p} \Bigg/ \frac{\partial^2 f(I, a, b, c, \alpha_c)}{\partial b_p^2} \right), \quad p \in P(g).$$

# Начальное приближение

Решение задачи (2) чувствительно к начальному приближению:



В качестве начального приближения для  $a$  и  $c$  будем брать решение оптимизационной задачи с линейной моделью  $\hat{I}_p^k = a_p c^k$ , а  $b$  инициализируем нулем. Решение находится при помощи мультипликативного алгоритма, предложенного в Cichocki A., Cruces S., Amari S. *Entropy*. 2011. № 13(1). Р. 134-170.

## Учёт альтернативного сплайсинга

- ❶  $W = \mathbf{1}^{P(g) \times K},$
- ❷ for iter = 1:maxIter do

$$[a, b, c] = \arg \min_{a, b, c} f(I, a, b, c, \alpha_c, W),$$

$$E = \frac{1}{I} \cdot \left( \frac{ac}{1 + bc} \right) \cdot c;$$

$$W = [E \leq q_{0.95}(E)];$$

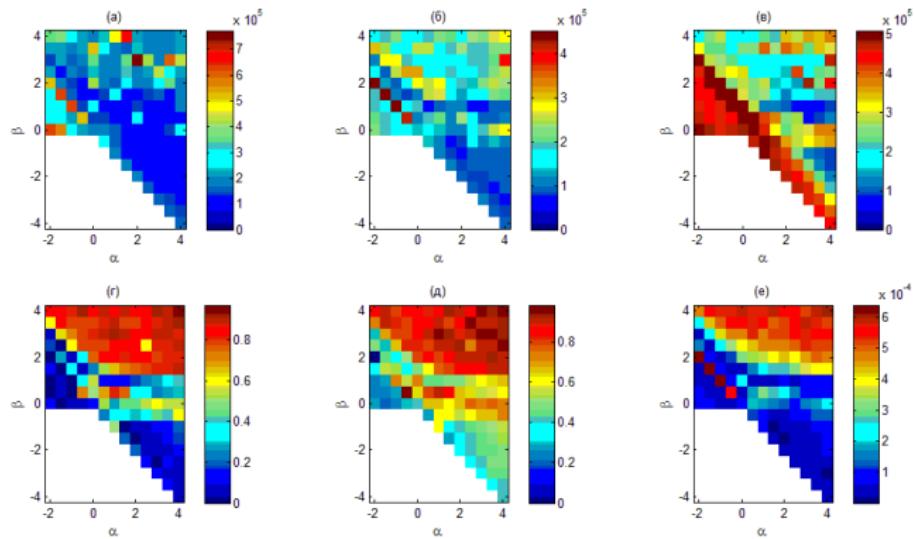
- ❸ end for

$$\text{❹ } err = \frac{\sum_{k=1}^K \sum_{p=1}^P I_p^k \left| I_p^k - \frac{a_p c_{g(p)}^k}{1 + b_p c_{g(p)}^k} \right| W_p^k}{\sum_{k=1}^K \sum_{p=1}^P I_p^k W_p^k}$$

## Схема решения

- на обучающей выборке настраиваем параметры  $a, b, c$ ;
- зафиксировав  $a, b, c$ , на валидационной выборке подбираем оптимальное значение параметра регуляризации  $\alpha_c$ ;
- на тестовой выборке с фиксированными  $a, b, c, \alpha_c$  вычисляем значения критериев качества.

## Результат

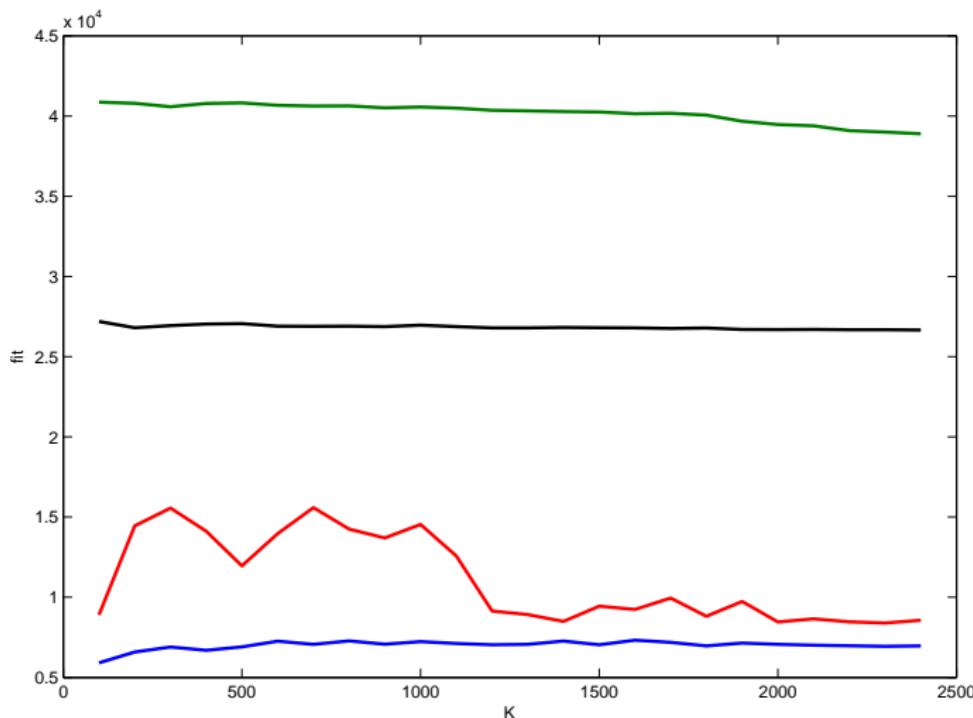


Верхний ряд: точность приближения, (а) — на обучающей выборке, (б) — на валидационной, (в) — на тестовой; нижний ряд: воспроизводимость, (г) — коэффициентов  $a$ , (д) — коэффициентов  $b$ , (е) — концентраций.

# Результат

Для дальнейших экспериментов выбраны  $\alpha = 2, \beta = 1$ .

Зависимость точности приближения от размера выборки:



- Разработан оптимизационный метод, позволяющий настроить нелинейную модель интенсивности флуоресценции проб на ДНК-микрочипе.
- На основе настроенной модели создан метод оценивания концентрации РНК генов по микрочиповым данным, позволяющий учесть эффекты насыщения и альтернативного сплайсинга.
- Предложенный метод позволяет точнее объяснить наблюдаемые интенсивности флуоресценции проб, а получаемые с его помощью оценки экспрессии более обладают большей устойчивостью.