

# Комбинаторная теория переобучения

К. В. Воронцов

([vokov@forecsys.ru](mailto:vokov@forecsys.ru), <http://www.ccas.ru/voron>)

Вычислительный Центр им. А. А. Дородницына РАН

Математические методы распознавания образов, ММРО-14  
21–25 сентября 2009  
г. Суздаль

## Содержание

- 1 Задача оценивания вероятности переобучения**
  - Задача обучения по прецедентам
  - Простейший частный случай: один алгоритм
  - VC-теория и проблема завышенности оценок
- 2 Эксперименты: поиски нового подхода**
  - Эксперимент 1: причины завышенности VC-оценок
  - Эксперимент 2: цепочки алгоритмов
- 3 Точные оценки вероятности переобучения**
  - Порождающие и запрещающие объекты
  - Модельные семейства алгоритмов
  - Рекуррентное вычисление оценок
  - Оценки по профилю расслоения и сходства

## Основные понятия и обозначения

Объекты  $\mathbb{X} = \{x_1, \dots, x_L\}$ ; алгоритмы  $A = \{a_1, \dots, a_D\}$ ;

$I(a, x) = [\text{алгоритм } a \text{ ошибается на объекте } x]$ ;

$\vec{a} = (I(a, x_i))_{i=1}^L$  — вектор ошибок алгоритма  $a \in A$ ;

	$a_1$	$a_2$	$a_3$	$a_4$	$a_5$	$a_6$	$a_7$	$\dots$	$a_D$	
$x_1$	1	1	0	0	0	1	1	$\dots$	1	X, обучение
$x_2$	0	0	0	0	1	1	1	$\dots$	1	
$x_3$	0	0	1	0	0	0	0	$\dots$	0	
$x_4$	0	0	0	1	1	1	1	$\dots$	0	$\bar{X}$ , контроль
$x_5$	0	0	0	1	0	0	0	$\dots$	1	
$x_L$	0	1	1	1	1	1	0	$\dots$	0	

$n(a, X) = \sum_{x_j \in X} I(a, x_j)$  — число ошибок  $a$  на выборке  $X \subset \mathbb{X}$ ;

**Задача:** зная только  $X$ , выбрать алгоритм с малым  $n(a, \mathbb{X})$ .

## Постановка задачи

Метод обучения  $\mu$  — минимизация эмпирического риска:

$$\mu X = \arg \min_{a \in A} n(a, X).$$

Переобученность метода  $\mu$  при разбиении  $X \sqcup \bar{X} = \mathbb{X}$ :

$$\delta_\mu(X) = \frac{1}{|\bar{X}|} n(\mu X, \bar{X}) - \frac{1}{|X|} n(\mu X, X).$$

### Аксиома (слабая вероятностная аксиоматика)

Все  $C_L^\ell$  разбиений  $X \sqcup \bar{X} = \mathbb{X}$  равновероятны, где

$X$  — наблюдаемая обучающая выборка длины  $\ell = |X|$ ;

$\bar{X}$  — скрытая контрольная выборка длины  $k = |\bar{X}| = L - \ell$ ;

Основная задача — оценить **вероятность** переобучения:

$$Q_\varepsilon(\mu, \mathbb{X}) = \mathbf{P}[\delta_\mu(X) \geq \varepsilon] = \frac{1}{C_L^\ell} \sum_{X \sqcup \bar{X}} [\delta_\mu(X) \geq \varepsilon].$$

## Простейший частный случай: один алгоритм

Пусть  $\mu X = a$  для всех  $X \in \mathbb{X}$ .

Обозначим  $m = n(a, \mathbb{X})$ ,  $s = n(a, X)$ .

### Теорема (точная оценка)

Вероятность большого уклонения частот описывается гипергеометрической функцией распределения:


$$Q_\varepsilon(a, \mathbb{X}) = H_L^{\ell, m} \left( \frac{\ell}{L} (m - \varepsilon k) \right),$$

где  $H_L^{\ell, m}(z) = \sum_{s=0}^{\lfloor z \rfloor} \frac{C_m^s C_{L-m}^{\ell-s}}{C_L^\ell}$  — левый «хвост» распределения.


**Вывод:** одно лишь предположение независимости объектов ( $\Leftrightarrow$  равной вероятности разбиений) обеспечивает возможность предсказания скрытого  $n(a, \bar{X})$  по наблюдаемому  $n(a, X)$ .

## Гипергеометрическое распределение $h(s|m) = C_m^s C_{L-m}^{\ell-s} / C_L^\ell$

$s$   $h(s|m)$  при  $m=50$



$s$  Гипергеометрическое распределение  $h(s|m)$  при  $L=200, k=100$



Предсказание  $n(a, \bar{X})$  по  $n(a, X)$  возможно благодаря узости гипергеометрического пика (концентрации вероятности).

Закон больших чисел:  $\frac{1}{\ell} n(a, X), \frac{1}{k} n(a, \bar{X}) \rightarrow \frac{1}{L} n(a, \mathbb{X})$  при  $\ell, k \rightarrow \infty$ .

## Теория Вапника-Червоненкиса

### Теорема (VC-оценка, 1971)

Для любых  $\mathbb{X}$ ,  $\mu$ ,  $\varepsilon \in (0, 1)$

$$P[\delta_\mu(X) \geq \varepsilon] \leq \Delta^A(\mathbb{X}) \max_{m=0..L} H_L^{\ell, m} \left( \frac{\ell}{L} (m - \varepsilon k) \right).$$

где  $\Delta^A(\mathbb{X}) = \#\{\vec{a} \mid a \in A\}$  — коэффициент разнообразия (shatter coefficient) множества алгоритмов  $A$ .

**Экспериментальное измерение завышенности VC-оценки:**

$\Delta^A(\mathbb{X}) \sim 10^6 - 10^{12}$  — коэффициент разнообразия (КР);

$\hat{\Delta}^A(\mathbb{X}) \sim 10^1 - 10^2$  — эффективный локальный КР (ЭЛКР)

---

Vorontsov K. V. Combinatorial probability and the tightness of generalization bounds // Pattern Recognition and Image Analysis. MAIK Nauka. No 2, Vol. 18, 2008, Pp. 243–259.

## Эксперимент 1: Выявление причин завышенности VC-оценок

- Эксперименты по оцениванию отдельных причин завышенности:
- логические алгоритмы классификации (Forecsys LogicPro);
  - 7 реальных задач классификации из репозитория UCI;
  - удалось отдельно оценить 4 фактора завышенности.

Основные факторы завышенности:

- **не учитывается *расслоение семейства алгоритмов***:  
чем выше  $m = n(a, \mathbb{X})$ , тем меньше  $P[\mu X = a]$   
(фактор завышенности — в  $10^2$ – $10^5$  раз);
- **не учитывается *связность семейства алгоритмов***:  
чем больше схожих алгоритмов, тем меньше разнообразие  
(фактор завышенности — в  $10^3$ – $10^4$  раз).

---

Vorontsov K. V. Combinatorial probability and the tightness of generalization bounds // Pattern Recognition and Image Analysis. MAIK Nauka. No 2, Vol. 18, 2008, Pp. 243–259.



## Эксперимент 2: Цепочки алгоритмов

**Цель эксперимента:** на простом примере продемонстрировать влияние связности и расслоения на вероятность переобучения.

**Цепочка с расслоением:**

	$a_0$	$a_1$	$a_2$	$a_3$	$a_4$	$a_5$	$a_6$
$x_1$	1	1	1	1	1	1	1
$x_2$	$0 \rightarrow 1$	1	1	1	1	1	1
$x_3$	0	$0 \rightarrow 1$	1	1	1	1	1
$x_4$	0	0	$0 \rightarrow 1$	1	1	1	1
$x_5$	0	0	0	$0 \rightarrow 1$	1	1	1
$x_6$	0	0	0	0	$0 \rightarrow 1$	1	1
$x_7$	0	0	0	0	0	$0 \rightarrow 1$	1


**Цепочка без расслоения:**

	$a_0$	$a_1$	$a_2$	$a_3$	$a_4$	$a_5$	$a_6$
$x_1$	1	$1 \rightarrow 0$	0	0	0	0	0
$x_2$	$0 \rightarrow 1$	1	$1 \rightarrow 0$	0	0	0	0
$x_3$	0	0	$0 \rightarrow 1$	1	$1 \rightarrow 0$	0	0
$x_4$	0	0	0	0	$0 \rightarrow 1$	1	1
$x_5$	0	0	0	0	0	0	0
$x_6$	0	0	0	0	0	0	0
$x_7$	0	0	0	0	0	0	0

Для каждой цепочки генерируется *не-цепочка* путём случайной перестановки единиц в каждом столбце — чтобы устранить свойство связности в семействе.

## Цепочки и не-цепочки; с расслоением и без

Условия эксперимента:  $D=1000$ ,  $\ell=k=100$ ,  $\varepsilon=0.05$ ,  $n(a_0, \mathbb{X})=10$ .




1. **Связность** приводит к замедлению роста  $Q_\varepsilon(D)$ .
2. **Расслоение** понижает уровень горизонтальной асимптоты.
3. **Без расслоения и связности**  $Q_\varepsilon = \frac{1}{2}$  при  $D \approx 20 \Rightarrow$   
 $\Rightarrow$  реальные семейства и расслоены, и связны.

## Гипотеза о порождающих и запрещающих объектах

### Гипотеза (1)

Для каждого  $a \in A$  можно указать пару непересекающихся подмножеств объектов  $X_a \subset \mathbb{X}$ ,  $X'_a \subset \mathbb{X}$  такую, что:

$$(\mu X = a) \Leftrightarrow (X_a \subseteq X) \text{ и } (X'_a \subseteq \bar{X}), \quad \forall X \subset \mathbb{X}.$$



Опр.  $X_a$  — множество объектов, **порождающих** алгоритм  $a$ .

Опр.  $X'_a$  — множество объектов, **запрещающих** алгоритм  $a$ .

Опр.  $\mathbb{X} \setminus (X_a \cup X'_a)$  — множество объектов, **нейтральных** для  $a$ .

## Обозначения и основная лемма

Введём для каждого  $a \in A$  следующие обозначения:

$L_a = L - |X_a| - |X'_a|$  — число нейтральных объектов;

$\ell_a = \ell - |X_a|$  — число нейтральных обучающих объектов;

### Лемма (о вероятности получения алгоритма)

*Если гипотеза (1) справедлива, то вероятность получить в результате обучения алгоритм  $a$  равна доле разбиений, при которых объекты из  $X_a$  и  $X'_a$  остаются на своих местах:*

$$P_a = P[\mu X = a] = \frac{C_{L_a}^{\ell_a}}{C_L^{\ell}}.$$

## Ещё обозначения и основная теорема

$$m_a = n(a, \mathbb{X}) - n(a, X_a) - n(a, X'_a)$$

— число ошибок алгоритма  $a$  на нейтральных объектах;

$$s_a(\varepsilon) = \frac{\ell}{L} (n(a, \mathbb{X}) - \varepsilon k) - n(a, X_a)$$

— наибольшее число ошибок алгоритма  $a$  на нейтральных обучающих объектах  $X \setminus X_a$ , при котором  $\delta(a, X) \geq \varepsilon$ .

### Теорема (точная оценка вероятности переобучения)

Если гипотеза (1) справедлива, то

$$P[\delta_\mu(X) \geq \varepsilon] = \sum_{a \in A} P_a H_{L_a}^{\ell_a, m_a}(s_a(\varepsilon)).$$

## Нестрогое доказательство основной теоремы

Для каждого вектора ошибок  $a$  из  $A$  известна:

1) вероятность получить  $a$  в результате обучения:

$$P_a = P[\mu X = a] = C_{L_a}^{\ell_a} / C_L^{\ell};$$

2) условная вероятность большого отклонения, если получен  $a$ :

$$P[\delta(a, X) \geq \varepsilon \mid \mu X = a] = H_{L_a}^{\ell_a, m_a}(s_a(\varepsilon)).$$

Тогда, по формуле полной вероятности

$$\begin{aligned} Q_\varepsilon &= \sum_{a \in A} P[\mu X = a] P[\delta(a, X) \geq \varepsilon \mid \mu X = a]. \\ &= \sum_{a \in A} \frac{C_{L_a}^{\ell_a}}{C_L^{\ell}} \cdot H_{L_a}^{\ell_a, m_a}(s_a(\varepsilon)). \end{aligned}$$

## Обобщение основной гипотезы

### Гипотеза (2)

Для каждого  $a \in A$  можно указать такой набор пар непересекающихся подмножеств объектов  $X_{av}, X'_{av} \subset \mathbb{X}$ ,  $v \in V_a$  и такой коэффициент  $c_{av} \in \mathbb{R}$ , что

$$[\mu X = a] = \sum_{v \in V_a} c_{av} [X_{av} \subseteq X] [X'_{av} \subseteq \bar{X}].$$

Обозначения: для каждого  $a \in A$  и каждого  $v \in V_a$

$$\begin{aligned}L_{av} &= \ell_{av} + k_{av}; & \ell_{av} &= \ell - |X_{av}|; \\m_{av} &= n(a, \mathbb{X}) - n(a, X_{av}) - n(a, X'_{av}); \\s_{av}(\varepsilon) &= \frac{\ell}{L} (n(a, \mathbb{X}) - \varepsilon k) - n(a, X_{av}).\end{aligned}$$

## Обобщение: лемма и основная теорема

### Лемма (о вероятностях получения алгоритмов)

Если гипотеза (2) справедлива, то вероятность получить в результате обучения алгоритм с вектором ошибок  $a$

$$P[\mu X=a] = \sum_{v \in V_a} c_{av} P_{av}; \quad P_{av} = \frac{C_{L_{av}}^{\ell_{av}}}{C_L^{\ell}}.$$

### Теорема (точная оценка вероятности переобучения)

Если гипотеза (2) справедлива, то

$$Q_\varepsilon = \sum_{a \in A} \sum_{v \in V_a} c_{av} P_{av} H_{L_{av}}^{\ell_{av}, m_{av}}(s_{av}(\varepsilon)).$$



## Сильное ли ограничение накладывает гипотеза (2)?

Оказывается, почти не накладывает.

**Это общий случай!**

### Теорема

*Пусть векторы ошибок алгоритмов  $a_1, \dots, a_D$  попарно различны и метод  $\mu$  минимизирует эмпирический риск.*

*Тогда справедлива гипотеза (2), причём  $c_{av} = 1$ .*

Доказательство конструктивно, но «тавтологично» — по матрице ошибок строится система подмножеств  $\mathbb{S}(a) = (X, \bar{X})_{\mu X=a}$ .

**НО система подмножеств  $\mathbb{S}(a)$  может быть не единственна.**

**Открытая проблема:**

Как искать системы подмножеств с наименьшими  $|X_{av}|, |X'_{av}|$ ?

## Связные семейства и цепочки

**Опр. 1.** Семейство  $A$  *связное*, если  $\forall a \in A \exists a' \in A: \rho(a, a') = 1$ .

$\rho(a, a')$  — хэммингово расстояние между векторами ошибок:

$$\rho(a, a') = \sum_{i=1}^L |I(a, x_i) - I(a', x_i)|, \quad \forall a, a' \in A.$$

**Опр. 2.** *Цепочка алгоритмов* — последовательность  $a_0, a_1, \dots, a_D$  такая, что  $\rho(a_{d-1}, a_d) = 1$  для всех  $d = 1, \dots, D$ .

**Опр. 3.** *Цепочка алгоритмов монотонная*, если  $I(a_{d-1}, x) \leq I(a_d, x)$  для всех  $x \in \mathbb{X}$  и  $d = 1, \dots, D$ .

Пример:

	$a_1$	$a_2$	$a_3$	$a_4$	$\dots$	$a_D$
$x_1$	0	1	1	1	1	1
$x_2$	0	0	1	1	1	1
$x_3$	0	0	0	1	1	1
$\dots$	0	0	0	0	1	1
$x_L$	0	0	0	0	0	1

## Вероятность переобучения монотонной цепочки

Пусть  $\mu$  — *пессимистичная минимизация эмпирического риска* (выбор алгоритма по принципу «худший из лучших»):

$$A(X) = \operatorname{Arg} \min_{a \in A} n(a, X); \quad \mu X = \arg \max_{a \in A(X)} n(a, \mathbb{X}).$$

### Теорема (точная верхняя оценка)

Пусть  $a_0, a_1, \dots, a_D$  — монотонная цепочка,  $n(a_0, \mathbb{X}) = m$ ,  $k \leq D \leq L - m$ . Тогда

$$P_d = P[\mu X = a] = \frac{C_{L-d-1}^{\ell-1}}{C_L^\ell};$$
$$P[\delta_\mu(X) \geq \varepsilon] = \sum_{d=0}^k P_d H_{L-d-1}^{\ell-1, m} \left( \frac{\ell}{L} (m + d - \varepsilon k) \right).$$

## Идея доказательства

Перенумеруем объекты так, чтобы  $a_d$  ошибался на  $x_1, \dots, x_d$ .

	$a_0$	$a_1$	$a_2$	$a_3$	$\dots$	$a_D$
$x_1$	0	1	1	1	1	1
$x_2$	0	0	1	1	1	1
$x_3$	0	0	0	1	1	1
$x_4$	0	0	0	0	1	1
$\dots$	0	0	0	0	0	1
$\dots$	0	0	0	0	0	0
$\dots$	0	0	0	0	0	0
$\dots$	1	1	1	1	1	1
$x_L$	1	1	1	1	1	1

Тогда:

$$(\mu X = a_d) \Leftrightarrow (x_{d+1} \in X) \text{ и } (x_1, \dots, x_d \in \bar{X}), \text{ при } d \leq k;$$

$(\mu X = a_d)$  невозможно, при  $d > k$ .

## Другие модельные семейства

Семейства, для которых к настоящему времени получены точные оценки вероятности переобучения:

- монотонная цепочка;
- унимодальная цепочка (применяется Гипотеза (2));
- единичная окрестность лучшего алгоритма;
- семейства из небольшого числа алгоритмов  $(2, 3, \dots)$ ;
- монотонная и унимодальная  $h$ -мерные сетки [П. Ботов];
- некоторые симметричные семейства [А. Фрей];
- конъюнкции пороговых предикатов [А. Ивахненко];
- связные семейства общего вида [Д. Кочедыков].

## Постановка задачи рекуррентного вычисления $Q_\varepsilon$

$\mathbb{S}(a) = \langle X_{av}, X'_{av}, c_{av} \rangle_{v \in V_a}$  — информация об алгоритме  $a \in A$ , необходимая для вычисления вероятности переобучения  $Q_\varepsilon$ .

Пусть  $n(a_0, \mathbb{X}) \leq n(a_1, \mathbb{X}) \leq \dots \leq n(a_D, \mathbb{X})$ .

Пусть  $\mu_d$  — пессимистичный метод обучения, выбирающий алгоритмы только из подмножества  $A_d = \{a_0, \dots, a_d\}$ .

### Задача (пересчёт $Q_\varepsilon$ при добавлении алгоритма $a_d$ )

*Известна информация  $\mathbb{S}(a_t)$  относительно метода  $\mu_{d-1}$  для всех алгоритмов  $a_t$ ,  $t \leq d-1$ .*

*Вычислить информацию  $\mathbb{S}(a_t)$ ,  $t \leq d$  относительно метода  $\mu_d$ .*

**Дополнительное предположение:  $n(a_0, \mathbb{X}) = 0$ .**

## Теоремы о рекуррентном вычислении $Q_\varepsilon$

### Теорема (об информации $\mathbb{S}(a_d)$ )

$$[\mu_d X = a_d] = [X'_d \subseteq \bar{X}], \quad X'_d = \{x_i \in \mathbb{X} : I(a_d, x_i) = 1\}.$$

### Теорема (о коррекции информации $\mathbb{S}(a_t)$ , $t < d$ )

Для каждого  $v \in V_t$  такого, что  $X_{tv} \cap X'_d = \emptyset$

- 1) если  $X'_d \setminus X'_{tv} = \{x_i\}$  — одноэлементное множество, то присоединить  $x_i$  к  $X_{tv}$ ;
- 2) если  $|X'_d \setminus X'_{tv}| > 1$ , то добавить в  $V_t$  индекс  $w$ , положив  $c_{tw} = -c_{tv}$ ,  $X_{tw} = X_{tv}$ ,  $X'_{tw} = X'_{tv} \cup X'_d$ ;
- 3) если  $|X'_d \setminus X'_{tv}| = 0$ , то удалить из  $V_t$  индекс  $v$ .

## Упрощённое рекуррентное вычисление $Q_\varepsilon$

### Теорема (О рекуррентной верхней оценке)

Если иногда пропускать шаг 2) при  $c_{tv} = 1$ ,  
то вычисляемое значение  $Q_\varepsilon$  может только увеличиться.

### Теорема

Если всегда пропускать шаг 2),  
то вычисляемое значение  $Q_\varepsilon$  может только увеличиться.  
При этом условия шага 3) не будут выполняться никогда.

Рекуррентное вычисление  $Q_\varepsilon$  может занять время  $O(L2^D)$ .  
Упрощённое рекуррентное вычисление  $Q_\varepsilon$  занимает  $O(LD^2)$ .  
Его можно сократить до  $O(LD)$  и даже до  $O(L)$ .



## Расслоение и связность

Расслоение множества алгоритмов  $A = \bigsqcup_{m=0}^L A_m$ , где  
 $A_m = \{a \in A: n(a, \mathbb{X}) = m\}$  —  $m$ -й слой множества алгоритмов.

Отношение частичного порядка на алгоритмах:

$$a \prec a' \Leftrightarrow (I(a, x) \leq I(a', x), \forall x \in \mathbb{X}).$$

Связность  $q(a)$  алгоритма  $a \in A$  — число сравнимых с ним алгоритмов в следующем слое:


$$q(a) = \#\left\{a': a \prec a' \text{ и } n(a, \mathbb{X}) + 1 = n(a', \mathbb{X})\right\}.$$

Граф связности множества алгоритмов  $A$ :


- вершины — алгоритмы,
- рёбра  $(a, a')$  — пары алгоритмов  $a \prec a'$  в соседних слоях.

## Пример. Граф расслоения и связности

Линейно разделимая выборка  
длины  $L = 10$



Граф связности семейства  
линейных классификаторов



## Оценка $Q_\varepsilon$ через профиль расслоения–связности

*Профиль расслоения–связности  $\Delta_{mq}$  — это число алгоритмов в  $m$ -м слое со связностью  $q$ .*

### Теорема

*Пусть векторы ошибок всех алгоритмов  $a \in A$  попарно различны, и в  $A$  есть корректный на  $\mathbb{X}$  алгоритм.  
Тогда справедлива верхняя оценка вероятности переобучения*


$$Q_\varepsilon \leq \sum_{m=\lceil \varepsilon k \rceil}^L \sum_{q=0}^{\ell} \Delta_{mq} \frac{C_{L-m-q}^{\ell-q}}{C_L^\ell}.$$

Как выглядят профили  $\Delta_{mq}$ ?


## Примеры профилей расслоения-связности

$\mathbb{X}$  — линейно разделимые 2D-выборки;  $A$  — линейные классификаторы.


$L = 20$




$L = 50$



$L = 100$



$L = 200$



## Две эмпирические гипотезы

### Гипотеза (о сепарабельности профилей)

$$\Delta_{mq} \approx \Delta_m \lambda_q,$$

где  $\Delta_m$  — коэффициент разнообразия  $m$ -го слоя,  
 $\lambda_q$  — доля алгоритмов  $m$ -го слоя со связностью  $q$ .

$(\Delta_m, m = 0, \dots, L)$  — профиль расслоения.

$(\lambda_q, q = 0 \dots, L)$  — профиль связности,  $\sum_{q=0}^L \lambda_q = 1$ .

### Гипотеза (о размерности пространства)

Положение пика в профиле  $\lambda_q$  приблизительно равно  
размерности пространства.

(для семейства линейных классификаторов это так)

## Оценка вероятности переобучения

### Теорема

*В условиях предыдущей теоремы и гипотезы сепарабельности*

$$Q_\varepsilon \leq \underbrace{\sum_{m=\lceil \varepsilon k \rceil}^k \Delta_m \frac{C_{L-m}^\ell}{C_L^\ell}}_{\text{VC-оценка}} \underbrace{\sum_{q=0}^L \lambda_q \left( \frac{\ell}{L-m} \right)^q}_{\text{поправка на связность}}.$$

При известных  $\Delta_m$ ,  $\lambda_q$  вычисления займут  $O(L)$ .

## Задачи и открытые проблемы

- 1 Обобщить на случай  $n(a_0, \mathbb{X}) > 0$ .
- 2 Как оценивать профиль связности реальных семейств?
- 3 Когда справедлива гипотеза сепарабельности?
- 4 Когда справедлива гипотеза размерности?
- 5 Возможно ли оценить характеристики нижних слоёв графа в тех случаях, когда метод обучения строит некоторое подмножество алгоритмов в явном виде?

## Задачи и открытые проблемы

[www.MachineLearning.ru/wiki](http://www.MachineLearning.ru/wiki)

Участник:Vokov

Страницы:

- Слабая вероятностная аксиоматика
- Расслоение и сходство алгоритмов  
(виртуальный семинар)
- **Теория надёжности обучения по прецедентам**  
(спецкурс каф. ММП ВМиК МГУ, К.В.Воронцов)

Сборник задач и открытых проблем:

[www.MachineLearning.ru/wiki/images/6/6b/Voron09problems.pdf](http://www.MachineLearning.ru/wiki/images/6/6b/Voron09problems.pdf)