

Курс «Введение в машинное обучение»

Метод стохастического градиента и линейные модели

Воронцов Константин Вячеславович

k.v.vorontsov@phystech.edu

<http://www.MachineLearning.ru/wiki?title=User:Vokov>

Этот курс доступен на странице вики-ресурса

<http://www.MachineLearning.ru/wiki>

«Введение в машинное обучение (курс лекций, К.В.Воронцов)»

1 Градиентная оптимизация в машинном обучении

- Оптимационная постановка задачи
- Метод стохастического градиента
- Ускорение сходимости и другие эвристики

2 Основные типы задач обучения с учителем

- Задачи регрессии
- Задачи классификации
- Задачи ранжирования

3 Линейные модели

- Линейный классификатор и логистическая регрессия
- Мультиколлинеарность и регуляризация
- Пример. Задача кредитного scoringа

Общая постановка большинства задач машинного обучения

Дано: X — пространство объектов

$X^\ell = \{x_1, \dots, x_\ell\} \subset X$ — обучающая выборка (training sample)
 $a(x, w)$, $a: X \times W \rightarrow Y$ — параметрическая модель, гипотеза

Найти $w \in W \subseteq \mathbb{R}^N$ — вектор параметров модели $a(x, w)$

Критерий минимизации эмпирического риска
(empirical risk minimization, ERM):

$$Q(w) = \frac{1}{\ell} \sum_{i=1}^{\ell} \mathcal{L}(w, x_i) + \tau \mathcal{R}(w) \rightarrow \min_w$$

$\mathcal{L}(w, x)$ — функция потерь (loss function),
тем больше, чем хуже ответ модели $a(x, w)$ на объекте x

$\mathcal{R}(w)$ — регуляризатор для формализации дополнительных требований к модели, τ — коэффициент регуляризации

Градиентный метод численной оптимизации


$$Q(w) = \frac{1}{\ell} \sum_{i=1}^{\ell} \mathcal{L}(w, x_i) + \tau \mathcal{R}(w) \rightarrow \min_w$$

Метод градиентного спуска:

$$w^{(0)} := \text{начальное приближение}; \\ w^{(t+1)} := w^{(t)} - h \nabla Q(w^{(t)})$$

где $\nabla Q(w) = \left(\frac{\partial Q(w)}{\partial w_j}\right)_{j=1}^N$ — вектор градиента,

h — градиентный шаг, называемый также темпом обучения



$$w^{(t+1)} := w^{(t)} - h \frac{1}{\ell} \sum_{i=1}^{\ell} \nabla \left(\mathcal{L}(w^{(t)}, x_i) + \tau \mathcal{R}(w) \right)$$

Идея ускорения сходимости:

брать объекты x_i по одному и сразу обновлять вектор весов

Метод стохастического градиента SG (Stochastic Gradient)

Задача ERM: $Q(w) = \frac{1}{\ell} \sum_{i=1}^{\ell} \mathcal{L}(w, x_i) + \tau \mathcal{R}(w) \rightarrow \min_w$

Вход: выборка X^ℓ , параметры h, τ, λ ;

Выход: вектор весов w ;

- 1 инициализировать веса $w_j, j = 1, \dots, N$;
- 2 инициализировать оценку $Q(w)$ по небольшой подвыборке;
- 3 **повторять**
- 4 | объект x_i выбрать из X^ℓ случайным образом;
- 5 | потеря: $\varepsilon_i := \mathcal{L}(w, x_i)$;
- 6 | градиентный шаг: $w := w - h \nabla \mathcal{L}(w, x_i) - h\tau \nabla \mathcal{R}(w)$;
- 7 | рекуррентная оценка критерия: $Q := \lambda \varepsilon_i + (1 - \lambda)Q$;
- 8 **пока** значение Q и/или веса w не сойдутся;

H. Robbins, S. Monro. A stochastic approximation method. 1951.

Откуда взялась такая рекуррентная оценка функционала?

Проблема: вычисление оценки Q по всей выборке x_1, \dots, x_ℓ намного больше градиентного шага по одному объекту x_i .

Решение: использовать приближённую рекуррентную формулу.

Среднее арифметическое:

$$\bar{Q}_m = \frac{1}{m}\varepsilon_m + \frac{1}{m}\varepsilon_{m-1} + \frac{1}{m}\varepsilon_{m-2} + \dots$$

$$\bar{Q}_m = \frac{1}{m}\varepsilon_m + (1 - \frac{1}{m})\bar{Q}_{m-1}$$

Экспоненциальное скользящее среднее (ЭСС):

$$\bar{Q}_m = \lambda\varepsilon_m + (1 - \lambda)\lambda\varepsilon_{m-1} + (1 - \lambda)^2\lambda\varepsilon_{m-2} + \dots$$

$$\bar{Q}_m = \lambda\varepsilon_m + (1 - \lambda)\bar{Q}_{m-1}$$


Параметр λ (порядка $\frac{1}{m}$) — темп забывания предыстории ряда.

Метод накопления инерции (momentum)

Momentum — экспоненциальное скользящее среднее градиента по последним $\approx \frac{1}{1-\gamma}$ итерациям [Б.Т.Поляк, 1964]:

$$v := \gamma v + (1-\gamma) \nabla \mathcal{L}(w, x_i)$$



$$w := w - hv$$



NAG (Nesterov's accelerated gradient) — стохастический градиент с инерцией [Ю.Е.Нестеров, 1983]:

$$v := \gamma v + (1-\gamma) \nabla \mathcal{L}(w - h\gamma v, x_i)$$

$$w := w - hv$$



Эвристики

- ❶ инициализация параметров w :
случайная, по корреляции, комбинированная, ...
- ❷ порядок предъявления объектов:
чем больше ε_i , тем выше вероятность выбрать x_i
- ❸ выбор градиентного шага: *метод скорейшего спуска*
основан на поиске оптимального адаптивного шага h^* :

$$\mathcal{L}(w - h \nabla \mathcal{L}(w, x_i), x_i) \rightarrow \min_h$$

- ❹ метод Ньютона-Рафсона (второго порядка сходимости):
 $w := w - h(\mathcal{L}''(w, x_i))^{-1} \nabla \mathcal{L}(w, x_i)$, \mathcal{L}'' — матрица Гессе
(в частности, диагональный метод Левенберга-Марквардта)
- ❺ мультистарт: многократные запуски из разных случайных начальных приближений и выбор лучшего решения

Метод SG: Достоинства и недостатки

Достоинства:

- ❶ **простота:** относительно легко реализуется
- ❷ **универсальность:** для любых $a(x, w)$, $\mathcal{L}(w, x)$, $\mathcal{R}(w)$
- ❸ **поточность:** возможность обучения на потоке данных
- ❹ **подходит для обработки больших данных:**
 - можно получить неплохое решение, успев обработать лишь малую часть объектов
 - часто оказывается быстрее и лучше более сложных и ресурсоёмких методов второго порядка

Недостатки:

- ❶ подбор комплекса эвристик является искусством
(не забыть про переобучение, застrevание, расходимость)

Оптимизационная задача обучения модели регрессии


Дано: обучающая выборка $(x_i, y_i)_{i=1}^{\ell}$ с ответами $y_i \in \mathbb{R}$

Найти: вектор параметров w модели регрессии $a(x, w)$

Критерий: минимум эмпирического риска

$$\sum_{i=1}^{\ell} L(a(x_i, w) - y_i) \rightarrow \min_w$$

Унимодальные функции потерь $L(\varepsilon)$ от невязки $\varepsilon = a(x, w) - y$:



Пример. Задача прогнозирования объемов продаж


Объект — тройка \langle товар, магазин, день \rangle .

Примеры признаков:

- бинарные: выходной день, праздник, промоакция, и т. д.
- количественные: объемы продаж в предшествующие дни.

Особенности задачи:

- функция потерь не квадратична и даже не симметрична;
- разреженные данные.



Вероятностная постановка задачи обучения регрессии

Модель данных с некоррелированным гауссовским шумом:

$$y_i = a(x_i, w) + \varepsilon_i, \quad \varepsilon_i \sim \mathcal{N}(0, \sigma_i^2), \quad i = 1, \dots, \ell$$

Метод максимума правдоподобия (ММП, MLE): при каком w плотность совместного распределения данных максимальна:

$$\begin{aligned} p(\varepsilon_1, \dots, \varepsilon_\ell) &= \prod_{i=1}^{\ell} \frac{1}{\sigma_i \sqrt{2\pi}} \exp\left(-\frac{1}{2\sigma_i^2} \varepsilon_i^2\right) \rightarrow \max_w \\ -\ln p(\varepsilon_1, \dots, \varepsilon_\ell) &= C + \frac{1}{2} \sum_{i=1}^{\ell} \frac{1}{\sigma_i^2} (a(x_i, w) - y_i)^2 \rightarrow \min_w \end{aligned}$$

- Постановки задачи МНК и ММП, совпадают, причём веса объектов связаны с дисперсией шума, $w_i = \sigma_i^{-2}$
- Использование неквадратичных функций потерь равносильно гипотезе о негауссовском распределении шума

Задача обучения модели двухклассовой классификации


Дано: обучающая выборка $(x_i, y_i)_{i=1}^{\ell}$, $y_i \in \{-1, +1\}$

Найти: вектор w модели классификации $a(x, w) = \text{sign } g(x, w)$

Критерий: \min аппроксимированного эмпирического риска

$$\sum_{i=1}^{\ell} [g(x_i, w)y_i < 0] \leq \sum_{i=1}^{\ell} L(g(x_i, w)y_i) \rightarrow \min_w$$

Убывающие функции потерь $L(M)$ от отступа $M = g(x, w)y$:



Бинарный разделяющий классификатор (margin-based classifier)

Бинарный классификатор: $a(x, w) = \text{sign } g(x, w)$, $Y = \{-1, +1\}$


$g(x, w)$ — разделяющая (дискриминантная) функция

$x: g(x, w) = 0$ — разделяющая поверхность между классами

$M_i(w) = g(x_i, w)y_i$ — отступ (margin) объекта x_i

$M_i(w) < 0 \iff$ модель $a(x, w)$ ошибается на x_i

Ранжирование объектов по возрастанию отступов $M_i(w)$:



Задача многоклассовой классификации (multiclass classification)

Дано: обучающая выборка $(x_i, y_i)_{i=1}^{\ell}$, $y_i \in Y$, $|Y| < \infty$

Найти: вектор $w = (w_y : y \in Y)$ модели классификации

$$a(x, w) = \arg \max_{y \in Y} g_y(x, w_y)$$

Критерий: \min аппроксимированного эмпирического риска

$$\begin{aligned} Q(w) &= \sum_{i=1}^{\ell} \sum_{y \neq y_i} [g_{y_i}(x_i, w_{y_i}) < g_y(x_i, w_y)] \leqslant \\ &\leqslant \sum_{i=1}^{\ell} \sum_{y \neq y_i} L(\underbrace{g_{y_i}(x_i, w_{y_i}) - g_y(x_i, w_y)}_{M_{iy}(w)}) \rightarrow \min_w \end{aligned}$$

$L(M)$ — убывающая функция отступа $M_{iy}(w)$ по классу y

$M_i(w) = \min_{y \neq y_i} M_{iy}(w)$ — отступ (margin) объекта x_i ;

$M_i(w) < 0 \iff$ модель $a(x, w)$ ошибается на x_i

Вероятностная постановка задачи классификации

Дано: простая (i.i.d.) выборка $(x_i, y_i)_{i=1}^{\ell} \sim p(x, y)$,
порождаемая в.п. $X \times Y$ с неизвестной плотностью $p(x, y)$

Найти: модель плотности $p(x, y; w) = P(y|x, w)p(x)$, где
 $P(y|x, w)$ — модель условной вероятности класса с параметром w
 $p(x)$ — неизвестное и непараметризуемое распределение на X

Критерий: максимум правдоподобия, т.е. \max плотности
совместного распределения всей выборки данных:

$$\prod_{i=1}^{\ell} p(x_i, y_i; w) = \prod_{i=1}^{\ell} P(y_i|x_i, w) \cancel{p(x_i)} \rightarrow \max_w$$

Логарифм правдоподобия (log-likelihood, log-loss):

$$Q(w) = - \sum_{i=1}^{\ell} \log P(y_i|x_i, w) \rightarrow \min_w$$

Связь правдоподобия и аппроксимации эмпирического риска

Максимизация логарифма правдоподобия,

$P(y|x, w)$ — модель условной вероятности класса:

$$Q(w) = - \sum_{i=1}^{\ell} \log P(y_i|x_i, w) \rightarrow \min_w$$

Минимизация аппроксимированного эмпирического риска,
 $g(x, w)$ — модель разделяющей поверхности, $Y = \{\pm 1\}$:

$$Q(w) = \sum_{i=1}^{\ell} \mathcal{L}(y_i g(x_i, w)) \rightarrow \min_w;$$

Эти два принципа эквивалентны, если положить

$$-\log P(y_i|x_i, w) = \mathcal{L}(y_i g(x_i, w)).$$

$$\boxed{\text{модель } P(y|x, w)} \Leftrightarrow \boxed{\text{модель } g(x, w) \text{ и } \mathcal{L}(M)}.$$

Анализ ошибок классификации

Задача классификации на два класса: y_i , $a(x_i) \in \{-1, +1\}$.

	модель классификации	учитель
TP, True Positive	$a(x_i) = +1$	$y_i = +1$
TN, True Negative	$a(x_i) = -1$	$y_i = -1$
FP, False Positive	$a(x_i) = +1$	$y_i = -1$
FN, False Negative	$a(x_i) = -1$	$y_i = +1$

FP: ложноположительно, ошибка I рода, «ложная тревога»

FN: ложноотрицательно, ошибка II рода, «пропуск цели»

Правильность классификации (чем больше, тем лучше):

$$\text{Accuracy} = \frac{1}{\ell} \sum_{i=1}^{\ell} [a(x_i) = y_i] = \frac{\text{TP} + \text{TN}}{\text{FP} + \text{FN} + \text{TP} + \text{TN}}$$

Недостаток: не учитывается дисбаланс численности классов, а также различие ценности ошибки I и II рода.

Определение ROC-кривой (Receiver Operating Characteristic)

Введём порог w_0 в модель: $a(x; w, w_0) = \text{sign}(g(x, w) - w_0)$
(чем больше w_0 , тем больше x_i , на которых $a(x_i) = -1$)

- по оси X: доля ошибочных положительных классификаций (FPR — false positive rate):

$$\text{FPR} = \frac{\text{FP}}{\text{FP} + \text{TN}} = \frac{\sum_{i=1}^{\ell} [y_i = +1] [a(x_i; w, w_0) = -1]}{\sum_{i=1}^{\ell} [y_i = +1]}$$


$1 - \text{FPR}$ называется специфичностью алгоритма a

- по оси Y: доля правильных положительных классификаций (TPR — true positive rate):

$$\text{TPR} = \frac{\text{TP}}{\text{TP} + \text{FN}} = \frac{\sum_{i=1}^{\ell} [y_i = -1] [a(x_i; w, w_0) = -1]}{\sum_{i=1}^{\ell} [y_i = -1]}$$

TPR называется также чувствительностью алгоритма a

ROC-кривая и площадь под кривой AUC (Area Under Curve)



ABCDE — положения порога w_0 на оси значений функции g

Задача максимизации площади под кривой ROC-AUC

Модель классификации: $a(x_i, w, w_0) = \text{sign}(g(x_i, w) - w_0)$

AUC — это доля правильно упорядоченных пар (x_i, x_j) :

$$\begin{aligned} \text{AUC}(w) &= \frac{1}{\ell_-} \sum_{i=1}^{\ell} [y_i = -1] \text{TPR}_i = \\ &= \frac{1}{\ell_- \ell_+} \sum_{i=1}^{\ell} \sum_{j=1}^{\ell} [y_i < y_j] [g(x_i, w) < g(x_j, w)] \rightarrow \max_w \end{aligned}$$

Критерий: максимум аппроксимированного AUC:

$$1 - \text{AUC}(w) \leq Q(w) = \sum_{i,j: y_i < y_j} L(\underbrace{g(x_j, w) - g(x_i, w)}_{M_{ij}(w)}) \rightarrow \min_w$$

где $L(M)$ — убывающая функция попарного отступа $M_{ij}(w)$

SG: градиентные шаги по парам объектов (x_i, x_j) : $y_i < y_j$

Задача обучения ранжированию

Дано: обучающая выборка (x_1, \dots, x_ℓ) ,

$i \prec j$ — отношение « x_j лучше, чем x_i » между объектами из X^ℓ

Найти: параметры w модели ранжирования $a(x, w)$,
восстанавливающей правильное отношение порядка:

$$i \prec j \Rightarrow a(x_i, w) < a(x_j, w)$$

Критерий: число неверно ранжированных пар объектов

$$\begin{aligned} Q(w) &= \sum_{i \prec j} \left[\underbrace{a(x_j, w) - a(x_i, w)}_{M_{ij}(w)} < 0 \right] \\ &\leq \sum_{i \prec j} L(a(x_j, w) - a(x_i, w)) \rightarrow \min_w \end{aligned}$$

где $L(M)$ — убывающая функция попарного отступа $M_{ij}(w)$

SG: градиентные шаги по парам объектов (x_i, x_j) : $i \prec j$

Максимизация AUC сводится к бинарному ранжированию!

Примеры задач ранжирования

Ранжирование (Learning to Rank, LtR, L2R, LETOR) нужно в системах человека-машиинного принятия решений, когда пользователь выбирает из ранжированного списка вариантов



- ранжирование выдачи поисковой системы
- ранжирование рекомендаций пользователям (книги, фильмы, музыка, товары интернет-магазина, и т.п.)
- ранжирование вариантов автоматического завершения запроса (Query Auto Completion, auto-suggest)
- ранжирование возможных ответов в диалоговых системах (Question Answering Systems)
- ранжирование вариантов перевода в системах машинного перевода (Machine Translation)

Линейный классификатор — математическая модель нейрона

Линейная модель нейрона МакКаллока-Питтса [1943]:

$$a(x, w) = \sigma \left(\sum_{j=1}^n w_j f_j(x) - w_0 \right) = \sigma(\langle w, x \rangle - w_0),$$

$\sigma(z)$ — функция активации (например, sign, th или $\frac{1}{1+e^{-z}}$),
 w_j — весовые коэффициенты синаптических связей,
 w_0 — порог активации



Двухклассовая логистическая регрессия

Линейная модель классификации для двух классов $Y = \{-1, 1\}$:

$$a(x, w) = \text{sign}\langle w, x \rangle, \quad x, w \in \mathbb{R}^n$$

Отступ $M = \langle w, x \rangle_y$



Логарифмическая функция потерь:

$$L(M) = \log(1 + e^{-M})$$

Модель условной вероятности:

$$P(y|x, w) = \sigma(M) = \frac{1}{1+e^{-M}},$$

где $\sigma(M)$ — сигмоидная функция,
важное свойство: $\sigma(-M) = 1 - \sigma(M)$



Максимизация правдоподобия (log-loss):

$$Q(w) = - \sum_{i=1}^{\ell} \log(1 + \exp(-\langle w, x_i \rangle y_i)) \rightarrow \min_w$$

Многоклассовая логистическая регрессия

Линейный классификатор при произвольном числе классов $|Y|$:

$$a(x) = \arg \max_{y \in Y} \langle w_y, x \rangle, \quad x, w_y \in \mathbb{R}^n$$

Вероятность того, что объект x относится к классу y :

$$P(y|x, w) = \frac{\exp \langle w_y, x \rangle}{\sum_{z \in Y} \exp \langle w_z, x \rangle} = \text{SoftMax} \langle w_y, x \rangle,$$

функция SoftMax: $\mathbb{R}^Y \rightarrow \mathbb{R}^Y$ переводит произвольный вектор в нормированный вектор дискретного распределения.

Максимизация правдоподобия (log-loss):

$$Q(w) = - \sum_{i=1}^{\ell} \log P(y_i|x_i, w) \rightarrow \min_w$$

Мультиколлинеарность и переобучение в линейных моделях

Возможные причины переобучения:

- слишком мало объектов, слишком много признаков
- линейная зависимость (мультиколлинеарность) признаков:
 - пусть построен классификатор: $a(x, w) = \text{sign}\langle w, x \rangle$
 - мультиколлинеарность: $\exists u \in \mathbb{R}^n: \forall x \in X \quad \langle u, x \rangle = 0$
 - неединственность решения: $\forall \gamma \in \mathbb{R} \quad a(x, w + \gamma u, x)$

Проявления переобучения:

- слишком большие веса $|w_j|$ разных знаков
- неустойчивость дискриминантной функции $\langle w, x \rangle$
- $Q(X^\ell) \ll Q(X^k)$

Простой способ уменьшить переобучение:

- регуляризация $\|w\| \rightarrow \min$ (сокращение весов, weight decay)

Регуляризация (сокращение весов, weight decay)

Штраф за увеличение нормы вектора весов:

$$\mathcal{L}_\tau(w, x_i) = \mathcal{L}(w, x_i) + \frac{\tau}{2} \|w\|^2 = \mathcal{L}(w, x_i) + \frac{\tau}{2} \sum_{j=1}^n w_j^2 \rightarrow \min_w.$$

Градиент:

$$\nabla \mathcal{L}_\tau(w, x_i) = \nabla \mathcal{L}(w, x_i) + \tau w.$$

Модификация градиентного шага в методе SG:

$$w := w(1 - h\tau) - h\nabla \mathcal{L}(w, x_i).$$

Методы подбора коэффициента регуляризации τ :

- ① hold-out или скользящий контроль
- ② стохастическая адаптация

Вероятностный смысл регуляризации

$P(y|x, w)$ — вероятностная модель данных;

$p(w; \gamma)$ — априорное распределение параметров модели;

γ — вектор гиперпараметров;

Теперь не только появление выборки X^ℓ ,

но и появление модели w также полагается стохастическим.

Совместное правдоподобие данных и модели:

$$p(X^\ell, w) = p(X^\ell|w) \color{red}{p(w; \gamma)}.$$

Принцип максимума апостериорной вероятности

(Maximum a Posteriori Probability, MAP):

$$Q_{\text{MAP}}(w) = \ln p(X^\ell, w) = \underbrace{\sum_{i=1}^{\ell} \log P(y_i|x_i, w)}_{Q_{\text{MLE}}(w)} + \underbrace{\log p(w; \gamma)}_{\text{регуляризатор}} \rightarrow \max_w$$

Примеры: априорные распределения Гаусса и Лапласа

Пусть веса w_j независимы, $Ew_j = 0$, $Dw_j = C$.

Распределение Гаусса и квадратичный (L_2) регуляризатор:

$$p(w; C) = \frac{1}{(2\pi C)^{n/2}} \exp\left(-\frac{\|w\|^2}{2C}\right), \quad \|w\|^2 = \sum_{j=1}^n w_j^2,$$

$$-\ln p(w; C) = \frac{1}{2C} \|w\|^2 + \text{const}$$

Распределение Лапласа и абсолютный (L_1) регуляризатор:

$$p(w; C) = \frac{1}{(2C)^n} \exp\left(-\frac{\|w\|}{C}\right), \quad \|w\| = \sum_{j=1}^n |w_j|,$$


$$-\ln p(w; C) = \frac{1}{C} \|w\| + \text{const}$$

C — гиперпараметр, $\tau = \frac{1}{C}$ — коэффициент регуляризации.

Регуляризация по L_1 -норме для отбора признаков


LASSO — Least Absolute Shrinkage and Selection Operator

$$Q(w) + \tau \sum_{j=1}^n |w_j| \rightarrow \min_w \quad \iff \quad \begin{cases} Q(w) \rightarrow \min_w; \\ \sum_{j=1}^n |w_j| \leq \kappa; \end{cases}$$



Сравнение L_2 и L_1 регуляризации


Зависимость весов w_j от параметра селективности τ



В LASSO с увеличением τ усиливается отбор признаков

Геометрическая интерпретация отбора признаков

Сравнение регуляризаторов по различным L_p -нормам:



Пример. Бинаризация признаков и scoringая карта

Задача кредитного scoringа:

- x_i — заемщики
- $y_i = -1$ (bad), $+1$ (good)

Бинаризация признаков $f_j(x)$:

$$b_{jk}(x) = [f_j(x) \text{ из } k\text{-го интервала}]$$

Линейная модель классификации:

$$a(x, w) = \operatorname{sign} \sum_{j,k} w_{jk} b_{jk}(x).$$


Вес признака w_{jk} равен его вкладу в общую сумму баллов (score).

признак j	интервал k	w_{jk}
Возраст	до 25	5
	25 - 40	10
	40 - 50	15
	50 и больше	10
Собственность	владелец	20
	совладелец	15
	съемщик	10
	другое	5
Работа	руководитель	15
	менеджер среднего звена	10
	служащий	5
	другое	0
Стаж	1/безработный	0
	1..3	5
	3..10	10
	10 и больше	15
Работа_мужа /жены	нет/домохозяйка	0
	руководитель	10
	менеджер среднего звена	5
	служащий	1

Оценивание рисков в scoringе

Логистическая регрессия не только определяет веса w , но и оценивает апостериорные вероятности классов

$$P(y|x, w) = \frac{1}{1 + e^{-\langle w, x \rangle y}}$$



Оценка риска (математического ожидания) потерь объекта x :

$$R(x) = \sum_{y \in Y} D_{xy} P(y|x, w),$$

где D_{xy} — величина потери для объекта x с исходом y .


Оценка говорит о том, сколько мы потеряем в среднем.
Но сколько мы потеряем в худшем случае?

Методика VaR (Value at Risk)

Стохастическое моделирование: $N = 10^4$ раз

- для каждого x_i разыгрывается исход $y_i \sim P(y|x_i)$;
- вычисляется сумма потерь по портфелю $V = \sum_{i=1}^{\ell} D_{x_i y_i}$;

99%-квантиль эмпирического распределения потерь
определяет величину резервируемого капитала



Резюме в конце лекции

- Метод стохастического градиента (SG)
 - подходит для любых моделей и функций потерь
 - подходит для обучения по большим данным
- Аппроксимация пороговой функции потерь $L(M)$
 - общий приём для классификации, ранжирования
 - позволяет использовать градиентную оптимизацию в задачах с исходно дискретнозначными критериями
- Регуляризация снижает переобучение, возникающее в линейных моделях из-за мультиколлинеарности
- Логистическая регрессия — метод классификации, оценивающий условные вероятности классов $P(y|x)$
- AUC — мера качества классификации, не зависящая от соотношения штрафов и численности классов