

Машинное обучение на основе минимизации сглаженных оценок средних, нечувствительных к выбросам

Э. М. Шибзухов

«МАТЕМАТИЧЕСКИЕ МЕТОДЫ РАСПОЗНАВАНИЯ ОБРАЗОВ» (ММРО – 2019)

Принцип экстремума средних арифметических

Многие задачи машинного обучения сводятся к задаче минимизации среднего арифметического от конечного набора параметризованных функций:

$$\mathbf{w}^* \in \arg \min_{\mathbf{w}} Q(\mathbf{w}),$$

$$Q(\mathbf{w}) = \frac{1}{N} \sum_{k=1}^N \ell_k(\mathbf{w}) + \tau R(\mathbf{w}).$$

Здесь

- $\ell_1(\mathbf{w}), \dots, \ell_N(\mathbf{w})$ – набор неотрицательных параметризованных функций;
- $R(\mathbf{w})$ – регуляризатор, τ – параметр регуляризации.

- Эмпирическое распределение $\ell_{(1)}(\mathbf{w}), \dots, \ell_{(N)}(\mathbf{w})$ может содержать выбросы:
 - существенные искажения или ошибки в исходных данных;
 - неадекватность модели на части исходных данных.
- Среднее арифметическое не является устойчивой оценкой среднего значения по отношению к выбросам.
- Поэтому выбросы могут приводить к существенному искажению значений целевой функции.
- В свою очередь, это приводит к существенному искажению значений искомых параметров.

Как разрешить проблему выбросов?

- Конечно, можно было бы перейти к взвешенному среднему арифметическому:

$$Q(\mathbf{w}) = \sum_{k=1}^N v_k \ell_k(\mathbf{w}) + \tau R(\mathbf{w}),$$

где $v_k \geq 0$ и $v_1 + \dots + v_N = 1$.

- Веса элементов выборки v_1, \dots, v_N должны быть способны **подавить** или **существенно ослабить** влияние выбросов на значения \mathbf{w}^* .
- Вопрос: **как** их выбрать?

Классический метод преодоления влияния выбросов

- Выбирается функция $\varrho(r)$, такая что
 - $\varrho(r)$ монотонно возрастает;
 - $\varrho'(r)$ не возрастает.

- **При этом:**

$$\{\ell_1(\mathbf{w}), \dots, \ell_N(\mathbf{w})\} \longrightarrow \{\varrho(\ell_1(\mathbf{w})), \dots, \varrho(\ell_N(\mathbf{w}))\},$$

так чтобы выбросы были бы выражены в существенно меньшей степени.

- Целевая функция:

$$Q(\mathbf{w}) = \frac{1}{N} \sum_{k=1}^N \varrho(\ell_k(\mathbf{w})) + \tau R(\mathbf{w}).$$

- Задача минимизации $Q(\mathbf{w})$ сводится к решению системы уравнений:

$$\sum_{k=1}^N \varrho'(\ell_k(\mathbf{w})) \nabla \ell_k(\mathbf{w}) + \tau \nabla R(\mathbf{w}) = 0$$

Метод итеративного перевзвешивания:

$$\mathbf{w}_{t+1} = \arg \min_{\mathbf{w}} \sum_{k=1}^N v_k \ell_k(\mathbf{w}) + \tau R(\mathbf{w}),$$

где $v_k = \varrho'(\ell_k(\mathbf{w}_t))$.

Если

$$\mathbf{w}^* = \arg \min_{\mathbf{w}} \sum_{k=1}^N v_k \ell_k(\mathbf{w}) + \tau R(\mathbf{w}),$$

при $v_k = \varrho'(\ell_k(\mathbf{w}^*))$, то \mathbf{w}^* – искомое решение.

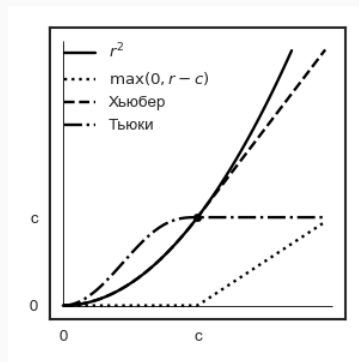
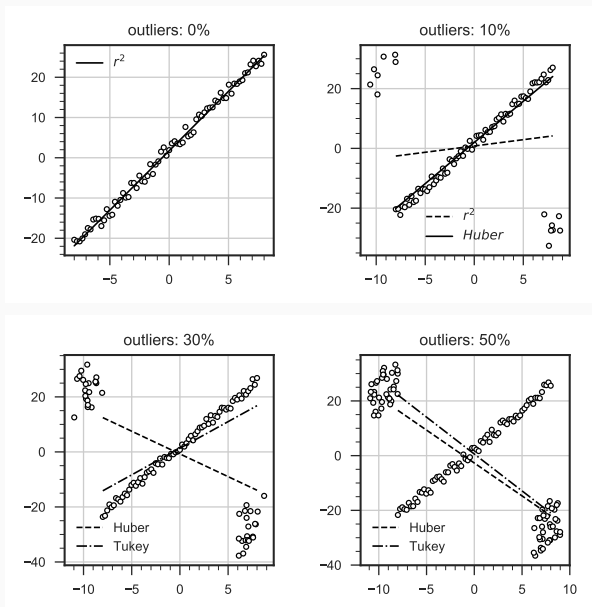
P.S.: Одновременно получаем веса: $v_k^* = \varrho'(\ell_k(\mathbf{w}^*))$.

Классический метод подавления влияния выбросов

- Этот метод работает, когда
 - выбросов **немного** или
 - они **невелики**
- Однако, **этот метод не работает** если
 - выбросов **много** (30–50%) или
 - они **велики** (например, превосходят на порядок).

Иллюстративный пример

$$\mathbf{w}^* = \arg \min_{\mathbf{w}} \frac{1}{N} \sum_{k=1}^N \underbrace{\rho(f(\tilde{\mathbf{x}}_k, \mathbf{w}) - \tilde{y}_k)}_{\ell_k(\mathbf{w})}$$



Как преодолеть проблему выбросов?

- Нужно использовать эмпирические оценки среднего значения, нечувствительные или малочувствительные к выбросам, вместо среднего арифметического!
- Медиана, квантили... **Однако**,
 - производные сильно разрывные;
 - градиентные процедуры не применимы.
- Цензурированное среднее арифметическое?


$$M_u\{z_1, \dots, z_N\} = \frac{1}{N} \sum_{k=1}^N \min\{z_k, u\}$$

Однако,

- как выбрать u ?
- квантиль z_1, \dots, z_N ?
- Нужны дифференцируемые оценки среднего значения, нечувствительные к выбросам.

Функция несходства

- $\rho(r) \geq 0$
- $\rho(0) = 0$
- $\rho(r)$ – (строго) выпуклая функция



$$\bar{z}_\rho = M_\rho\{z_1, \dots, z_N\} = \arg \min_u \sum_{k=1}^N \rho(z_k - u)$$

$M\{z_1, \dots, z_N\}$ – усредняющая агрегирующая функция:

- $z'_1 \leq z''_1, \dots, z'_N \leq z''_N \rightarrow M\{z'_1, \dots, z'_N\} \leq M\{z''_1, \dots, z''_N\}$
- $\min\{z_1, \dots, z_N\} \leq M\{z_1, \dots, z_N\} \leq \max\{z_1, \dots, z_N\}$

- Если существует $\rho'(u) \rightarrow$ метод градиентного спуска
- Если существует $\rho''(u) \rightarrow$ метод Ньютона

Итерационная процедура

$$u_{t+1} = \frac{\sum_{k=1}^N \varphi(z_k - u_t) z_k}{\sum_{k=1}^N \varphi(z_k - u_t)}, \quad \varphi(u) = \frac{\rho'(u)}{u}$$

Достаточное условие сходимости

$$\left| \sum_{k=1}^N \varphi'(z_k - \bar{z}_\rho) (z_k - \bar{z}_\rho) \right| < \left| \sum_{k=1}^N \varphi(z_k - \bar{z}_\rho) \right|.$$

Если существует $\rho''(u)$:

$$\frac{\partial M_\rho\{z_1, \dots, z_N\}}{\partial z_k} = \frac{\rho''(z_k - \bar{z}_\rho)}{\rho''(z_1 - \bar{z}_\rho) + \dots + \rho''(z_N - \bar{z}_\rho)}$$

$$\bar{z}_\rho = M_\rho\{z_1, \dots, z_N\}$$


$$\frac{\partial M_\rho}{\partial z_1} + \dots + \frac{\partial M_\rho}{\partial z_N} = 1$$

$$\frac{\partial M_\rho\{z_1, \dots, z_N\}}{\partial z_k} \geq 0$$

Сглаженная версия медианы

- $\lim_{\varepsilon \rightarrow 0} \rho_\varepsilon(r) = |r|$
- $\lim_{\varepsilon \rightarrow 0} \rho'_\varepsilon(r) = \text{sign } r$
- $\lim_{\varepsilon \rightarrow 0} \rho''_\varepsilon(r) = \begin{cases} +\infty, & \text{если } r = 0 \\ 0, & \text{если } r \neq 0 \end{cases}$

$$\rho(r) = \sqrt{\varepsilon^2 + r^2} - \varepsilon$$




Сглаженная версия квантиля

α -квантиль:

$$\bar{z}_\alpha = \arg \min_u \sum_{k=1}^N |z_k - u|_\alpha$$

$$|r|_\alpha = \begin{cases} \alpha r, & \text{если } r > 0 \\ 0, & \text{если } r = 0 \\ (\alpha - 1)r, & \text{если } r < 0 \end{cases}$$

$$\rho_{\alpha,\varepsilon}(r) = \begin{cases} \alpha \rho_\varepsilon(r), & \text{если } r > 0 \\ \frac{\alpha}{2} \rho'_\varepsilon(0^+) + \frac{1-\alpha}{2} \rho'_\varepsilon(0^-), & \text{если } r = 0 \\ (1 - \alpha) \rho_\varepsilon(r), & \text{если } r < 0 \end{cases}$$



По следам функции Хьюбера

Функция Хьюбера (расширенная):


$$H(r) = \begin{cases} \frac{1}{2}r^2, & \text{если } |r| \leq c \\ \gamma cr - (\gamma - \frac{1}{2})c^2, & \text{если } |r| > c \end{cases} \quad 0 < \gamma \leq 1$$

$$c = \bar{z}_{\rho_\alpha} = M_{\rho_\alpha}\{z_1, \dots, z_N\}.$$

$$M_H\{z_1, \dots, z_N\} = \frac{1}{N-m} \sum_{z_k \leq \bar{z}_{\rho_\alpha}} z_k + \frac{\gamma m}{N-m} \bar{z}_{\rho_\alpha},$$

где m — число $z_k > \bar{z}_{\rho_\alpha}$.

$$\frac{\partial M_H}{\partial z_k} = \begin{cases} \frac{1}{N-m} + \frac{\gamma m}{N-m} \frac{\partial M_{\rho_\alpha}}{\partial z_k}, & \text{if } k \leq m \\ \frac{\gamma m}{N-m} \frac{\partial M_{\rho_\alpha}}{\partial z_k}, & \text{if } k > m \end{cases}$$



Цензурированное среднее арифметическое


Цензурированное среднее арифметическое:

$$M_u\{z_1, \dots, z_N\} = \frac{1}{N} \sum_{k=1}^N C(z, u),$$

где $C(z, u)$ – цензурирующая функция.

Например:

- $C(z, u) = \min\{z, u\}$
- $C(z, u) = \frac{1}{2}(z_k + u - \rho(z_k - u))$



Параметр цензуры $u = \bar{z}_{\rho_\alpha}$ – значение сглаженного варианта α -квантиля.

Цензурированное среднее арифметическое

- Градиент для $\min(z, \bar{z}_{\rho\alpha})$:

$$\frac{\partial M_{\bar{z}_{\rho\alpha}}}{\partial z_k} = \begin{cases} \frac{1}{N} + \frac{m}{N} \frac{\partial M_{\rho\alpha}}{\partial z_k}, & \text{if } k \leq m \\ \frac{m}{N} \frac{\partial M_{\rho\alpha}}{\partial z_k}, & \text{if } k > m \end{cases}$$

- Градиент для $\frac{1}{2}(z_k + \bar{z}_{\rho\alpha} - \rho(z_k - \bar{z}_{\rho\alpha}))$:

$$\frac{\partial M_{\bar{z}_{\rho\alpha}}}{\partial z_k} = \frac{1}{2N} (1 - \rho'_{\alpha}(z_k - \bar{z}_{\rho\alpha})) + \frac{1}{2} \frac{\partial M_{\rho\alpha}}{\partial z_k}$$

$$\frac{\partial M_{\bar{z}_{\rho\alpha}}}{\partial z_1} + \dots + \frac{\partial M_{\bar{z}_{\rho\alpha}}}{\partial z_N} = 1$$

Принцип минимизации робастной дифференцируемой оценки среднего

- Используем дифференцируемую оценку для среднего значения, нечувствительную или малочувствительную к выбросам.
- Определяем целевую функцию:

$$Q(\mathbf{w}) = M\{\ell_1(\mathbf{w}), \dots, \ell_N(\mathbf{w})\}$$

- Ищем параметры модели, минимизирующие целевую функцию с регуляризатором:

$$\mathbf{w}^* \in \arg \min_{\mathbf{w}} \{Q(\mathbf{w}) + \tau R(\mathbf{w})\}$$

Целевая функция:

$$Q(\mathbf{w}) = M\{\ell_1(\mathbf{w}), \dots, \ell_N(\mathbf{w})\}$$

Градиент целевой функции:

$$\nabla Q(\mathbf{w}) = \sum_{k=1}^N v_k(\mathbf{w}) \nabla \ell_k(\mathbf{w}),$$

$$\sum_{k=1}^N v_k(\mathbf{w}) = 1, \quad v_k(\mathbf{w}) \geq 0$$

$$v_k(\mathbf{w}) = \frac{\partial M\{\ell_1(\mathbf{w}), \dots, \ell_N(\mathbf{w})\}}{\partial z_k}$$

Оптимальный набор параметров \mathbf{w}^* является решением системы:

$$\left\{ \begin{array}{l} z_k = \ell_k(\mathbf{w}), \quad k = 1, \dots, N \\ v_k = \frac{\partial M\{z_1, \dots, z_N\}}{\partial z_k}, \quad k = 1, \dots, N \\ \sum_{k=1}^N v_k \nabla \ell_k(\mathbf{w}) + \tau \nabla R(\mathbf{w}) = 0 \quad (*) \end{array} \right.$$

Для его решения применяется метод итеративного перевзвешивания.

P.S.: если v_k – числовые константы, то (*) соответствует решению задачи

$$\arg \min_{\mathbf{w}} \sum_{k=1}^N v_k \ell_k(\mathbf{w}) + \tau R(\mathbf{w})$$

Метод итеративно перевзвешенного эмпирического среднего

procedure IR-EM(\mathbf{w}_0)

$t \leftarrow 0$

repeat

$z_1, \dots, z_N \leftarrow \ell_1(\mathbf{w}_t), \dots, \ell_N(\mathbf{w}_t)$

$(v_1, \dots, v_N) = \nabla M\{z_1, \dots, z_N\}$

$\mathbf{w}_{t+1} \leftarrow \arg \min_{\mathbf{w}} \sum_{k=1}^N v_k \ell_k(\mathbf{w}) + \tau R(\mathbf{w})$

$t \leftarrow t + 1$

until $\{u_t\}$ не сконцентрируется около минимума

end procedure

Классическая робастная М-регрессия

данные: $\tilde{\mathbf{X}} = \{\tilde{\mathbf{x}}_1, \dots, \tilde{\mathbf{x}}_N\}$, $\tilde{\mathbf{Y}} = \{\tilde{y}_1, \dots, \tilde{y}_N\}$

невязка: $r_k(\mathbf{w}) = f(\tilde{\mathbf{x}}_k, \mathbf{w}) - \tilde{y}_k$

потери: $\ell_k(\mathbf{w}) = \varrho(r_k(\mathbf{w}))$

функция влияния: $\varrho(r)$


Принцип минимизации эмпирического риска:

$$\mathbf{w}^* = \arg \min_{\mathbf{w}} \frac{1}{N} \sum_{k=1}^N \varrho(r_k(\mathbf{w})) + \tau R(\mathbf{w})$$

Алгоритм **IRLS** (Iteratively Reweighted Least Squares):

$$\mathbf{w}_{t+1} \in \arg \min_{\mathbf{w}} \sum_{k=1}^N v_k r_k(\mathbf{w})^2 + \tau R(\mathbf{w}),$$

где $v_k = \psi(r_k(\mathbf{w}_t))$, $\psi(r) = \varrho'(r)/r$.



Робастная регрессия

Принцип минимизации робастного эмпирического риска

$$\mathbf{w}^* = \arg \min_{\mathbf{w}} M\{\varrho(r_1(\mathbf{w})), \dots, \varrho(r_N(\mathbf{w}))\} + \tau R(\mathbf{w})$$

Алгоритм **IR-ERM** (Iteratively Reweighted Empirical Risk Minimization):

$$\mathbf{w}_{t+1} = \arg \min_{\mathbf{w}} \sum_{k=1}^N v_k r_k(\mathbf{w})^2 + \tau R(\mathbf{w}),$$

$$v_k = \frac{\partial M\{z_1, \dots, z_k\}}{\partial z_k} \psi(r_k(\mathbf{w}_t))$$

$$\psi(r) = \frac{\varrho'(r)}{r}$$

$$z_k = \varrho(r_k(\mathbf{w}_t))$$

Сглаженная
медиана (квантиль):

$$\frac{\partial M_\rho}{\partial z_N} = \frac{\rho''(z_k - \bar{z}_\rho)}{\rho''(z_1 - \bar{z}_\rho) + \dots + \rho''(z_N - \bar{z}_\rho)}$$

Цензурированное
среднее арифметическое:

$$\frac{\partial M_{\bar{z}_\rho}}{\partial z_k} = \begin{cases} \frac{1}{N} + \frac{m}{N} \frac{\partial M_\rho}{\partial z_k}, & \text{if } k \leq m \\ \frac{m}{N} \frac{\partial M_\rho}{\partial z_k}, & \text{if } k > m \end{cases}$$

Принцип минимизации робастного эмпирического риска

$$\mathbf{w}^* = \arg \min_{\mathbf{w}} M_{\rho_\alpha} \{r_1(\mathbf{w})^2, \dots, r_N(\mathbf{w})^2\}$$

где M_{ρ_α} – сглаженная оценка α -квантиля,

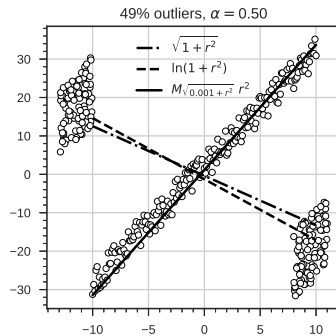
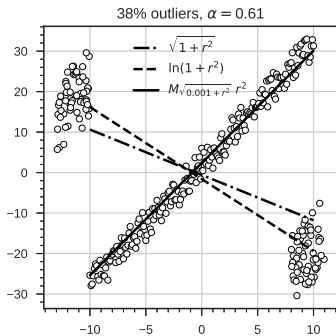

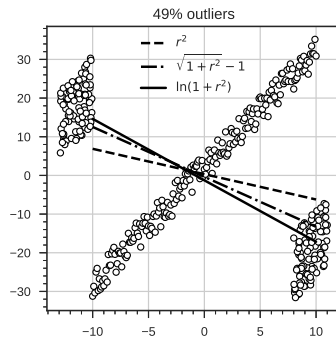
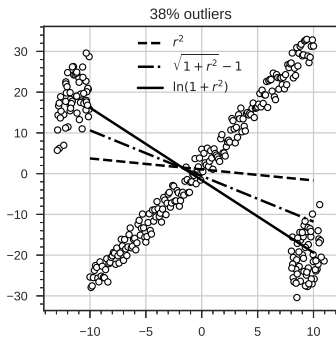

$$\rho_\alpha(r) = \begin{cases} \alpha\rho(r), & \text{if } r > 0 \\ \frac{\alpha}{2}\rho'(0^+) + \frac{1-\alpha}{2}\rho'(0^-), & \text{if } r = 0 \\ (1-\alpha)\rho(r), & \text{if } r < 0 \end{cases}$$

$$\rho(r) = \sqrt{\varepsilon^2 + r^2} - \varepsilon, \quad \varepsilon = 0.001$$

Для сравнения: M-регрессия с $\varrho(r)$:

- $\varrho(r) = \sqrt{\varepsilon^2 + r^2} - \varepsilon$
- $\varrho(r) = \ln(1 + r^2)$

Линейная регрессия



Классическая робастная SVM-классификация (2 класса)

- данные: $\tilde{\mathbf{X}} = \{\tilde{\mathbf{x}}_1, \dots, \tilde{\mathbf{x}}_N\}$, $\tilde{\mathbf{Y}} = \{\tilde{y}_1, \dots, \tilde{y}_N\}$
- отступ: $r_k(\mathbf{w}) = (-\tilde{y}_k f(\tilde{\mathbf{x}}_k, \mathbf{w}))_+$ (функция Хинжа от отступа)
- потери: $\ell_k(\mathbf{w}) = \varrho(r_k(\mathbf{w}))$ ϱ – убывающая функция влияния

Принцип минимизации эмпирического риска (потери от отрицательных отступов)

$$\mathbf{w}^* = \arg \min_{\mathbf{w}} \frac{1}{N} \sum_{k=1}^N \underbrace{\varrho(r_k(\mathbf{w}))}_{\ell_k(\mathbf{w})}$$

Алгоритм **IRHM** (Iteratively Reweighted Hinge Margins):

$$\mathbf{w}_{t+1} = \arg \min_{\mathbf{w}} \sum_{k=1}^N v_k r_k(\mathbf{w}),$$

где $v_k = \varrho'(r_k(\mathbf{w}_t))$.

Робастная классификация (SVC)

Принцип минимизации робастного эмпирического риска

$$\mathbf{w}^* = \arg \min_{\mathbf{w}} M_{\rho_{\alpha}} \{ \varrho(r_1(\mathbf{w})), \dots, \varrho(r_N(\mathbf{w})) \} + \tau R(\mathbf{w})$$







где $\varrho(r)$ – функция Хинжа, $M_{\rho_{\alpha}}$ – сглаженная оценка α -квантиля,

$$\rho_{\alpha}(r) = \begin{cases} \alpha \rho(r), & \text{if } r > 0 \\ \frac{\alpha}{2} \rho'(0^+) + \frac{1-\alpha}{2} \rho'(0^-), & \text{if } r = 0 \\ (1 - \alpha) \rho(r), & \text{if } r < 0 \end{cases}$$

$$\rho(r) = \sqrt{\varepsilon^2 + r^2} - \varepsilon, \quad \varepsilon = 0.001$$

Для сравнения: SVC

Робастная классификация (SVC)



Два примера обучения НС

- Аппроксимируем функцию $f(\mathbf{x})$, $\mathbf{x} \in \mathbb{R}^3$.
- Обучающая/контрольная выборка равномерно распределена на $[-2, 2]^3$.
- Количество точек в обучающей/контрольной выборках 1000/1000.
- Добавлен равномерно распределенный шум $\varepsilon \in [-0.2, 0.2]$.
- Для выбросов в обучающей выборке исходные значения заменены на значение 30.













Пример 1. $f(\mathbf{x}) = \|\mathbf{x}\|^{2/3}$.

($\max f(\mathbf{x}) < 3$ на $[-2, 2]^3$).

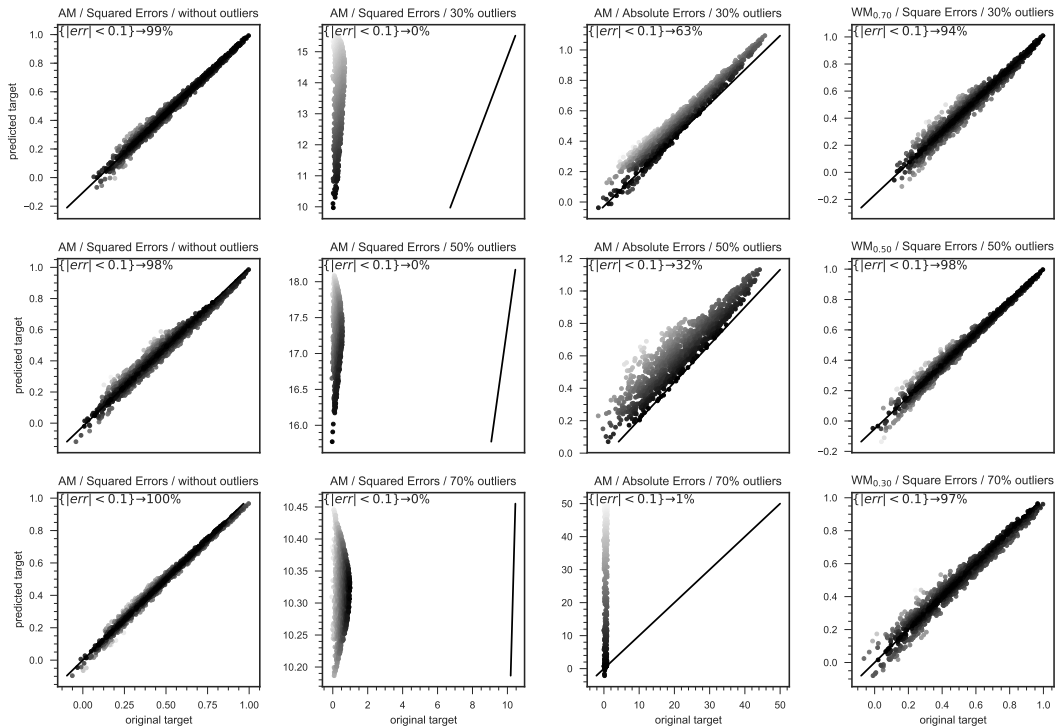
Пример 2. $f(\mathbf{x}) = \sin \|\mathbf{x}\| / (\|\mathbf{x}\| + 10^{-8})$.

($\max f(\mathbf{x}) < 1$ на $[-2, 2]^3$).

Пример 1



Пример 2



Классический центр и корреляционная матрица

- $\mathbf{X} = \{\mathbf{x}_1, \dots, \mathbf{x}_N\} \subset \mathbb{R}^n$ – конечное множество точек
- $p(\mathbf{x}) \propto \frac{1}{\sqrt{|\mathbf{S}|}} e^{-\frac{1}{2}(\mathbf{x}-\mathbf{c})'\mathbf{S}^{-1}(\mathbf{x}-\mathbf{c})}$ – функция нормального распределения точек с центром \mathbf{c} и корреляционной матрицей \mathbf{S}
- $D(\mathbf{x}; \mathbf{c}, \mathbf{S}) = \ln |\mathbf{S}| + (\mathbf{x} - \mathbf{c})'\mathbf{S}^{-1}(\mathbf{x} - \mathbf{c})$ – расстояние Махаланобиса с учетом корреляционной матрицы \mathbf{S}

$$Q(\mathbf{c}, \mathbf{S}) = \ln |\mathbf{S}| + \frac{1}{N} \sum_{k=1}^N D(\mathbf{x}_k; \mathbf{c}, \mathbf{S}),$$

$$\begin{cases} \mathbf{c}^* = \frac{1}{N} \sum_{k=1}^N \mathbf{x}_k \\ \mathbf{S}^* = \frac{1}{N} \sum_{k=1}^N (\mathbf{x}_k - \mathbf{c})'(\mathbf{x}_k - \mathbf{c}). \end{cases}$$

M-эстиматор: центр и корреляционная матрица

Используется функция ρ , растущая медленнее линейной.

- $\rho(\mathbf{x}) \propto \frac{1}{\sqrt{|\mathbf{S}|}} e^{-\frac{1}{2}\rho((\mathbf{x}-\mathbf{c})'\mathbf{S}^{-1}(\mathbf{x}-\mathbf{c}))}$ – функция распределения точек с центром \mathbf{c} и корреляционной матрицей \mathbf{S}
- $D(\mathbf{x}; \mathbf{c}, \mathbf{S}) = \ln |\mathbf{S}| + \rho((\mathbf{x} - \mathbf{c})'\mathbf{S}^{-1}(\mathbf{x} - \mathbf{c}))$ – псевдо-расстояние

$$Q(\mathbf{c}, \mathbf{S}) = \ln |\mathbf{S}| + \frac{1}{N} \sum_{k=1}^N \rho(D(\mathbf{x}_k; \mathbf{c}, \mathbf{S})),$$

$$z_k = z_k(\mathbf{c}, \mathbf{S}) = D(\mathbf{x}_k; \mathbf{c}, \mathbf{S}).$$

$$\begin{cases} v_k = \rho'(z_k) \\ \mathbf{c}^* = \frac{1}{N} \sum_{k=1}^N v_k \mathbf{x}_k \\ \mathbf{S}^* = \frac{1}{N} \sum_{k=1}^N v_k (\mathbf{x}_k - \mathbf{c})' (\mathbf{x}_k - \mathbf{c}). \end{cases}$$

Принцип минимизации робастной оценки

- Используем робастное среднее для оценки эмпирического среднего:

$$Q(\mathbf{c}, \mathbf{S}) = M\{z_1(\mathbf{c}, \mathbf{S}), \dots, z_N(\mathbf{c}, \mathbf{S})\},$$

где $z_k = z_k(\mathbf{c}, \mathbf{S}) = \ln |\mathbf{S}| + D(\mathbf{x}_k; \mathbf{c}, \mathbf{S})$.

- Искомые значения центра и корреляционной матрицы – решения системы уравнений:

$$\begin{cases} \mathbf{v} = \nabla M\{z_1, \dots, z_N\} \\ 0 = \sum_{k=1}^N v_k(\mathbf{x}_k - \mathbf{c}) \\ \mathbf{S} = \sum_{k=1}^N v_k(\mathbf{x}_k - \mathbf{c})'(\mathbf{x}_k - \mathbf{c}). \end{cases}$$

- 1 На начальном шаге $t = 0$ выбираются начальные \mathbf{c}_0 и \mathbf{S}_0 .
- 2 На t -ом шаге последовательно решаются два уравнения:
 - 1 Сначала решается следующее уравнение для нахождения \mathbf{c}_{t+1} :

$$\mathbf{c} = \sum_{k=1}^N \frac{\partial M\{z_1, \dots, z_N\}}{\partial z_k} \mathbf{x}_k,$$

где $z_k = D(\mathbf{x}_k; \mathbf{c}, \mathbf{S}_t)$.

- 2 Затем решается следующее уравнение для нахождения \mathbf{S}_{t+1} :

$$\mathbf{S} = \sum_{k=1}^N \frac{\partial M\{z_1, \dots, z_N\}}{\partial z_k} (\mathbf{x}_k - \mathbf{c}_{t+1})' (\mathbf{x}_k - \mathbf{c}_{t+1}),$$

где $z_k = D(\mathbf{x}_k; \mathbf{c}_{t+1}, \mathbf{S})$.

- 3 Шаг 2 повторяется до тех пор, пока $t < T$ (максимальное число итераций) или последовательность $\{\mathbf{Q}(\mathbf{c}_t, \mathbf{S}_t)\}$ не сконцентрируется вокруг своей точки сгущения.

- Для решения уравнения

$$\mathbf{c} = f(\mathbf{c})$$

используем итерационную схему

$$\mathbf{c}_{t+1} = (1 - h)\mathbf{c}_t + hf(\mathbf{c}_t)$$

- Для решения уравнения





$$\mathbf{S} = F(\mathbf{S})$$

используем итерационную схему







$$\mathbf{S}_{t+1} = (1 - h)\mathbf{S}_t + hF(\mathbf{S}_t),$$

$$0 < h < 1$$

Пример: stackloss, starCYG






Пример: wine



Пример: нормальное распределение

$N = 500$ точек, $n = 2, 10, 20$, $M = 400$

44% выбросов



Задача кластеризации

Классическая задача кластеризации (K классов):

$$\mathbf{c}_1^*, \dots, \mathbf{c}_K^* = \arg \min_{\mathbf{c}_1, \dots, \mathbf{c}_K} \frac{1}{N} \sum_{k=1}^N D(\mathbf{x}_k),$$

где

$$D(\mathbf{x}; \mathbf{c}_1, \dots, \mathbf{c}_K) = \min_{j=1, \dots, K} \|\mathbf{x} - \mathbf{c}_j\|^2$$

Итерационная процедура:

$$\mathbf{c}_{j,t+1} = \frac{1}{|\mathbf{I}_j|} \sum_{k \in \mathbf{I}_j} \mathbf{x}_k,$$

где $\mathbf{I}_j = \{k : j = j(\mathbf{x}_k)\}$ – индексы точек, попадающих в j -ый кластер,

$$j(\mathbf{x}; \mathbf{c}_1, \dots, \mathbf{c}_K) = \arg \min_{j=1, \dots, K} \|\mathbf{x} - \mathbf{c}_j\|^2.$$

Задача робастной кластеризации

Классическая задача кластеризации (K классов):

$$\mathbf{c}_1^*, \dots, \mathbf{c}_K^* = \arg \min_{\mathbf{c}_1, \dots, \mathbf{c}_K} M\{D(\mathbf{x}_1; \mathbf{c}_1, \dots, \mathbf{c}_K), \dots, D(\mathbf{x}_N; \mathbf{c}_1, \dots, \mathbf{c}_K)\},$$

Система уравнений:

$$\begin{cases} \mathbf{v} = \nabla M\{D(\mathbf{x}_1; \mathbf{c}_1, \dots, \mathbf{c}_K), \dots, D(\mathbf{x}_N; \mathbf{c}_1, \dots, \mathbf{c}_K)\} \\ \sum_{k \in I_j} v_k (\mathbf{x}_k - \mathbf{c}_j) = 0 \end{cases}$$

Итерационная процедура:


$$\mathbf{c}_{j,t+1} = \frac{1}{V_j} \sum_{k \in I_j} v_k \mathbf{x}_k,$$

где $V_j = \sum_{k \in I_j} v_k$,


$$\mathbf{v} = \nabla M\{D(\mathbf{x}_1; \mathbf{c}_{1,t}, \dots, \mathbf{c}_{K,t}), \dots, D(\mathbf{x}_N; \mathbf{c}_{1,t}, \dots, \mathbf{c}_{K,t})\}$$

Пример 1


IR-KMeans-M1, 33%




KMeans, 33%



IR-KMeans-M1, 50%




KMeans, 50%




Пример 2


2 clusters, $\alpha = 0.15$




3 clusters, $\alpha = 0.20$




4 clusters, $\alpha = 0.25$




5 clusters, $\alpha = 0.30$



6 clusters, $\alpha = 0.35$



7 clusters, $\alpha = 0.40$



Благодарю за внимание!