

## Смеси экспертов

Грабовой Андрей Валериевич

Московский физико-технический институт

МФТИ, г. Долгопрудный

- ① EM–алгоритм:
  - Классический,
  - Вариационный,
- ② Смесь моделей:
  - Постановка задачи,
  - Итерационные формулы полученные при помощи вариационного EM–алгоритма,
  - Иллюстрация сходимости,
- ③ Смесь экспертов
  - Постановка задачи,
  - Итерационные формулы полученные при помощи вариационного EM–алгоритма,
  - Иллюстрация сходимости,

Максимизация обоснованности:

$$\Theta = \arg \max_{\Theta} p(\mathbf{y}|\mathbf{X}, \Theta) \quad (1)$$

ELBO:

$$\begin{aligned} \mathcal{L}(q(\mathbf{Z}), \Theta) &= \int q(\mathbf{Z}) \log \frac{p(\mathbf{y}, \mathbf{Z}|\Theta, \mathbf{X})}{q(\mathbf{Z})} d\mathbf{Z} \\ &= p(\mathbf{y}|\mathbf{X}, \Theta) - D_{KL}(q(\mathbf{Z})||p(\mathbf{Z}|\mathbf{y}, \mathbf{X}, \Theta)) \end{aligned} \quad (2)$$

EM-алгоритм:

① E-шаг:

$$q^s(\mathbf{Z}) = \arg \max_{q(\mathbf{Z}) \in \mathcal{Q}} \mathcal{L}(q(\mathbf{Z}), \Theta^{s-1}) \quad (3)$$

② M-шаг:

$$\Theta^s = \arg \max_{\Theta} \mathcal{L}(q^s(\mathbf{Z}), \Theta) \quad (4)$$

Вариационный EM-алгоритм (Mean Field Approximation<sup>1</sup>):

① E-шаг:

$$\log q(\mathbf{Z}_k^s) \propto \mathbb{E}_{q/k} \log p(\mathbf{y}, \mathbf{Z}|\mathbf{X}, \Theta^{s-1}) \quad (5)$$

② M-шаг:

$$\Theta^s = \arg \max_{\Theta} \mathbb{E}_{q^s} \log p(\mathbf{y}, \mathbf{Z}|\mathbf{X}, \Theta) \quad (6)$$

<sup>1</sup><https://github.com/andriygav/EMprior/blob/master/Lecture/Grabovoy2019MeanField.pdf>

## Definition

Смесь моделей — мультимодель, ответы которой представляют собой взвешенную сумму ответов всех задействованных моделей независимо от объекта.

$$\hat{\mathbf{f}} = \sum_{k=1}^K \pi_k \mathbf{f}_k, \quad \pi_k = \text{const}, \quad \sum_{k=1}^K \pi_k = 1, \quad (7)$$

где  $\mathbf{f}$  — мультимодель, а  $\mathbf{f}_k$  — локальная модель.

## Пример 1:

- ❶ Веса моделей в смеси  $\boldsymbol{\pi}$  получены из априорного распределения

$$p(\boldsymbol{\pi}|\mu); \quad (8)$$

- ❷ Вектора параметров  $\mathbf{w}_k$  получены из нормального распределения

$$p(\mathbf{w}_k|\mathbf{A}_k) = \mathcal{N}(\mathbf{w}_k|\mathbf{0}, \mathbf{A}_k), \quad k = 1, \dots, K; \quad (9)$$

- ❸ Для каждого объекта  $\mathbf{x}_i$  существует модель  $\mathbf{f}_{k_i}$ , которой он описывается, причем  $p(k_i = k) = \pi_k$ ;

- ❹ Для каждого объекта  $\mathbf{x}_i$  класс  $y_i$  определен в соответствии с моделью

$$\mathbf{f}_{k_i} : y_i \sim \mathcal{N}(\mathbf{w}_{k_i}^\top \mathbf{x}_i + b_k, \beta^{-1}) \quad (10)$$

Правдоподобие модели:

$$p(\mathbf{y}, \mathbf{W}, \boldsymbol{\pi} | \mathbf{X}, \mathbf{A}, \beta, \boldsymbol{\mu}) = \text{Dir}(\boldsymbol{\pi} | \boldsymbol{\mu}) \prod_{k=1}^K N(\mathbf{w}_k | \mathbf{0}, \mathbf{A}_k) \prod_{i=1}^N \left( \sum_{k=1}^K \pi_k \mathcal{N}(y_i | \mathbf{w}_k^T \mathbf{x}_i, \beta^{-1}) \right) \quad (11)$$

Введем скрытые переменные  $\mathbf{Z} = \{z_{ik}\}$ , где  $z_{ik} = 1 \Leftrightarrow k_i = k$ :

$$p(\mathbf{y}, \mathbf{W}, \boldsymbol{\pi}, \mathbf{Z} | \mathbf{X}, \mathbf{A}, \beta, \boldsymbol{\mu}) = \text{Dir}(\boldsymbol{\pi} | \boldsymbol{\mu}) \prod_{k=1}^K N(\mathbf{w}_k | \mathbf{0}, \mathbf{A}_k) \prod_{i=1}^N \prod_{k=1}^K \left( \pi_k \mathcal{N}(y_i | \mathbf{w}_k^T \mathbf{x}_i, \beta^{-1}) \right)^{z_{ik}} \quad (12)$$

Вариационный EM-алгоритм  $q(\mathbf{Z}, \mathbf{W}, \boldsymbol{\pi}) = q(\mathbf{Z}) q(\mathbf{W}) q(\boldsymbol{\pi})$ :

① E-шаг:

$$\begin{aligned} \log q(\mathbf{Z}^s) &\propto \mathbf{E}_{q/\mathbf{Z}} \log p(\mathbf{y}, \mathbf{W}, \boldsymbol{\pi}, \mathbf{Z} | \mathbf{X}, \mathbf{A}^{s-1}, \beta^{s-1}, \boldsymbol{\mu}) \\ \log q(\mathbf{W}^s) &\propto \mathbf{E}_{q/\mathbf{W}} \log p(\mathbf{y}, \mathbf{W}, \boldsymbol{\pi}, \mathbf{Z} | \mathbf{X}, \mathbf{A}^{s-1}, \beta^{s-1}, \boldsymbol{\mu}) \\ \log q(\boldsymbol{\pi}^s) &\propto \mathbf{E}_{q/\boldsymbol{\pi}} \log p(\mathbf{y}, \mathbf{W}, \boldsymbol{\pi}, \mathbf{Z} | \mathbf{X}, \mathbf{A}^{s-1}, \beta^{s-1}, \boldsymbol{\mu}) \end{aligned} \quad (13)$$

② M-шаг:

$$\mathbf{A}^s, \beta^s = \arg \max_{\mathbf{A}, \beta} \mathbf{E}_{q^s} \log p(\mathbf{y}, \mathbf{W}, \boldsymbol{\pi}, \mathbf{Z} | \mathbf{X}, \mathbf{A}, \beta, \boldsymbol{\mu}) \quad (14)$$

Итерационные формулы EM-алгоритма<sup>1</sup>:

① E-шаг:

$$p(z_{ik} = 1) = \frac{\exp(\mathbf{E} \log \pi_k - \frac{\beta}{2} [y_i^2 - 2y_i \mathbf{x}_i^\top \mathbf{E} \mathbf{w}_k + \mathbf{x}_i^\top (\mathbf{E} \mathbf{w}_k \mathbf{w}_k^\top) \mathbf{x}_i])}{\sum_k p(z_{ik} = 1)},$$

$$q(\boldsymbol{\pi}) = \text{Dir}(\boldsymbol{\pi} | \boldsymbol{\mu} + \boldsymbol{\gamma}), \quad q(\mathbf{w}_k) = \mathcal{N}(\mathbf{w}_k | \mathbf{m}_k, \mathbf{B}_k),$$

$$\gamma_k = \sum_{i=1}^N \mathbf{E} z_{ik}, \quad \mathbf{m}_k = \beta \mathbf{B}_k \left( \sum_{i=1}^N \mathbf{x}_i y_i \mathbf{E} z_{ik} \right), \quad \mathbf{B}_k = \left( \mathbf{A}_k^{-1} + \beta \sum_{i=1}^N \mathbf{x}_i \mathbf{x}_i^\top \mathbf{E} z_{ik} \right)^{-1}. \quad (15)$$

② M-шаг:

$$\begin{aligned} \mathbf{A}_k &= \mathbf{E} \mathbf{w}_k \mathbf{w}_k^\top \\ \frac{1}{\beta} &= \frac{\sum \sum [y_i^2 - 2y_i \mathbf{x}_i^\top \mathbf{E} \mathbf{w}_k + \mathbf{x}_i^\top \mathbf{E} \mathbf{w}_k \mathbf{w}_k^\top \mathbf{x}_i] \mathbf{E} z_{ik}}{\sum \sum \mathbf{E} z_{ik}} \end{aligned} \quad (16)$$


Некоторые математические ожидания:

①  $\mathbf{E} z_{ik} = p(z_{ik} = 1),$


②  $\mathbf{E} \log \pi_k = \psi^0(\mu_k + \gamma_k) - \psi^0(K\mu_k + N),$

③  $\mathbf{E} \mathbf{w}_k \mathbf{w}_k^\top = \mathbf{B}_k + \mathbf{m}_k \mathbf{m}_k^\top.$

<sup>1</sup><https://github.com/andriygav/EMprior/blob/master/paper/Grabovoy2019Draft.pdf>



(a)



(b)

На рис показано, что в случае смеси моделей, предсказать то, какую модель использовать в каждой точке нельзя.

На рис. показана зависимость векторов  $\mathbf{w}_k$  — параметры локальных моделей в процессе обучения.

<sup>1</sup><https://github.com/andriygav/MixtureLib>

## Definition

Смесь экспертов — мультимодель, определяющая правдоподобие веса  $\pi_k$  каждой локальной модели  $\mathbf{f}_k$  на признаковом описании объекта  $\mathbf{x}$ .

$$\hat{\mathbf{f}} = \sum_{k=1}^K \pi_k \mathbf{f}_k, \quad \pi_k(\mathbf{x}, \mathbf{V}) : \mathbb{R}^{n \times |\mathbf{V}|} \rightarrow [0, 1], \quad \sum_{k=1}^K \pi_k(\mathbf{x}, \mathbf{V}) = 1 \quad (17)$$

где  $\hat{\mathbf{f}}$  — мультимодель, а  $\mathbf{f}_k$  является некоторой моделью,  $\pi_k$  — параметрическая модель,  $\mathbf{w}_k$  — параметры  $k$ -й локальной модели,  $\mathbf{V}$  — параметры шлюзовой функции.

## Пример 2:

- 1 Правдоподобие  $k$ -й локальной модели  $p_k(y_i | \mathbf{w}_k, \mathbf{x}_i) = \mathcal{N}(y_i | \mathbf{w}_k^T \mathbf{x}_i, \beta^{-1})$ ,
- 2 Априорное распределение параметров  $k$ -й локальной модели  $p^k(\mathbf{w}_k) = \mathcal{N}(\mathbf{w}_k | \mathbf{w}_k^0, \mathbf{A}_k)$ ,
- 3 Шлюзовая функция  $\pi(\mathbf{x}, \mathbf{V}) = \text{softmax}(\mathbf{V}_1^T \sigma(\mathbf{V}_2^T \mathbf{x}))$ .



Правдоподобие модели:

$$p(\mathbf{y}, \mathbf{W} | \mathbf{X}, \mathbf{V}, \mathbf{A}, \mathbf{W}^0, \beta) = \prod_{k=1}^K \mathcal{N}(\mathbf{w}_k | \mathbf{w}_k^0, \mathbf{A}_k) \prod_{i=1}^N \left( \sum_{k=1}^K \pi_k \mathcal{N}(y_i | \mathbf{w}_k^\top \mathbf{x}_i, \beta^{-1}) \right). \quad (18)$$

Введем скрытые переменные  $\mathbf{Z} = \{z_{ik}\}$ , где  $z_{ik} = 1 \Leftrightarrow k_i = k$ :

$$p(\mathbf{y}, \mathbf{Z}, \mathbf{W} | \mathbf{X}, \mathbf{V}, \mathbf{A}, \mathbf{W}^0, \beta) = \prod_{k=1}^K \mathcal{N}(\mathbf{w}_k | \mathbf{w}_k^0, \mathbf{A}_k) \prod_{i=1}^N \prod_{k=1}^K \left( \pi_k \mathcal{N}(y_i | \mathbf{w}_k^\top \mathbf{x}_i, \beta^{-1}) \right)^{z_{ik}}. \quad (19)$$

Вариационный EM-алгоритм  $q(\mathbf{Z}, \mathbf{W}) = q(\mathbf{Z}) q(\mathbf{W})$ :

① E-шаг:

$$\begin{aligned} \log q(\mathbf{Z}^s) &\propto \mathbf{E}_{q/\mathbf{Z}} \log p(\mathbf{y}, \mathbf{Z}, \mathbf{W} | \mathbf{X}, \mathbf{V}^{s-1}, \mathbf{A}^{s-1}, \mathbf{W}^{0,s-1}, \beta^{s-1}) \\ \log q(\mathbf{W}^s) &\propto \mathbf{E}_{q/\mathbf{W}} \log p(\mathbf{y}, \mathbf{Z}, \mathbf{W} | \mathbf{X}, \mathbf{V}^{s-1}, \mathbf{A}^{s-1}, \mathbf{W}^{0,s-1}, \beta^{s-1}) \end{aligned} \quad (20)$$

② M-шаг:

$$\mathbf{W}^{0,s}, \mathbf{A}^s, \beta^s = \arg \max_{\mathbf{W}^0, \mathbf{A}, \beta} \mathbf{E}_{q^s} \log p(\mathbf{y}, \mathbf{Z}, \mathbf{W} | \mathbf{X}, \mathbf{V}, \mathbf{A}, \mathbf{W}^0, \beta) \quad (21)$$

Итерационные формулы EM-алгоритма<sup>1</sup>:

① E-шаг:

$$p(z_{ik} = 1) = \frac{\exp(\log \pi_k(\mathbf{x}_i, \mathbf{V}) - \frac{\beta}{2}(\mathbf{x}_i^\top \mathbf{E} \mathbf{w}_k \mathbf{w}_k^\top \mathbf{x}_i - \mathbf{x}_i^\top \mathbf{E} \mathbf{w}_k))}{\sum_{k'=1}^K \exp(\log \pi_{k'}(\mathbf{x}_i, \mathbf{V}) - \frac{\beta}{2}(\mathbf{x}_i^\top \mathbf{E} \mathbf{w}_{k'} \mathbf{w}_{k'}^\top \mathbf{x}_i - \mathbf{x}_i^\top \mathbf{E} \mathbf{w}_{k'}))},$$

$$q(\mathbf{w}_k) = \mathcal{N}(\mathbf{w}_k | \mathbf{m}_k, \mathbf{B}_k),$$

$$\mathbf{m}_k = \mathbf{B}_k \left( \mathbf{A}_k^{-1} \mathbf{w}_k^0 + \beta \sum_{i=1}^N \mathbf{x}_i y_i \mathbf{E} z_{ik} \right), \quad \mathbf{B}_k = \left( \mathbf{A}_k^{-1} + \beta \sum_{i=1}^N \mathbf{x}_i \mathbf{x}_i^\top \mathbf{E} z_{ik} \right)^{-1}.$$
(22)

② M-шаг:


$$\mathbf{A}_k = \mathbf{E} \mathbf{w}_k \mathbf{w}_k^\top - \mathbf{w}_k^0 \mathbf{E} \mathbf{w}_k^\top - \mathbf{E} \mathbf{w}_k \mathbf{w}_k^{0\top} + \mathbf{w}_k^0 \mathbf{w}_k^{0\top},$$

$$\frac{1}{\beta} = \frac{1}{N} \sum_{i=1}^N \sum_{k=1}^K \left[ y_i^2 - 2y_i \mathbf{x}_i^\top \mathbf{E} \mathbf{w}_k + \mathbf{x}_i^\top \mathbf{E} \mathbf{w}_k \mathbf{w}_k^\top \mathbf{x}_i \right] \mathbf{E} z_{ik},$$
(23)


$$\mathbf{w}_k^0 = \mathbf{E} \mathbf{w}_k,$$

$$\mathbf{V} = \arg \max_{\mathbf{V}} \mathbf{E}_{q^s} \log p(\mathbf{y}, \mathbf{Z}, \mathbf{W} | \mathbf{X}, \mathbf{V}, \mathbf{A}, \mathbf{W}^0, \beta).$$

<sup>1</sup><https://github.com/andriygav/EMprior/blob/master/paper/Grabovoy2019MixtureOfExpert.pdf>



(c)




(d)


На рис. показано, что в случае смеси экспертов гипермодель предсказывает к какому классу относится каждая точка в пространстве объектов.

На рис. показана зависимость векторов  $w_k$  — параметры локальных моделей в процессе обучения.


<sup>1</sup><https://github.com/andriygav/MixtureLib>




(e) Смесь Моделей



(f) Смесь Моделей



(g) Смесь Экспертов



(h) Смесь Экспертов

<sup>1</sup><https://github.com/andriygav/MixtureLib>

# Постановка задачи нахождения параметров окружностей

Задано бинарное изображение:

$$\mathbf{M} \in \{0, 1\}^{m_1 \times m_2},$$

где 1 — черная точка, 0 — белая точка фона.

По изображению  $\mathbf{M}$  строится выборка  $\mathbf{C}$ :

$$\mathbf{C} \in \mathbb{R}^{N \times 2},$$

где  $N$  — число черных точек на изображении  $\mathbf{M}$ .

Пусть  $x_0, y_0$  — центр окружности, которую требуется найти, а  $r$  ее радиус.

Точки  $(x_i, y_i) \in \mathbf{C}$  должны удовлетворять уравнению окружности:


$$(x_i - x_0)^2 + (y_i - y_0)^2 = r^2 \Rightarrow (2x_0) \cdot x_i + (2y_0) \cdot y_i + (r^2 - x_0^2 - y_0^2) \cdot 1 = x_i^2 + y_i^2.$$

Задачу линейной регрессии для нахождения окружности:

$$\mathbf{X}\mathbf{w} \approx \mathbf{y}, \quad \mathbf{X} = [\mathbf{C}, \mathbf{1}], \quad \mathbf{y} = [x_1^2 + y_1^2, x_2^2 + y_2^2, \dots, x_N^2 + y_N^2]^\top,$$

где найденные оптимальные параметры линейной регрессии  $\mathbf{w} = [w_1, w_2, w_3]^\top$  восстанавливают параметры окружности:

$$x_0 = \frac{w_1}{2}, \quad y_0 = \frac{w_2}{2}, \quad r = \sqrt{w_3 + x_0^2 + y_0^2}.$$



Задана выборка:

$$\mathbf{X} \in \mathbb{R}^{N \times n},$$

где  $N$  — число объектов в выборке, а  $n$  — размерность признакового пространства.

## Definition

Смесь экспертов — мультимодель, определяющая правдоподобие веса  $\pi_k$  каждой локальной модели  $\mathbf{f}_k$  на признаковом описании объекта  $\mathbf{x}$ .

$$\hat{\mathbf{f}} = \sum_{k=1}^K \pi_k \mathbf{f}_k, \quad \pi_k(\mathbf{x}, \mathbf{V}) : \mathbb{R}^{n \times |\mathbf{V}|} \rightarrow [0, 1], \quad \sum_{k=1}^K \pi_k(\mathbf{x}, \mathbf{V}) = 1,$$

где  $\hat{\mathbf{f}}$  — мультимодель, а  $\mathbf{f}_k$  является локальной моделью,  $\pi_k$  — шлюзовая функция,  $\mathbf{w}_k$  — параметры  $k$ -й локальной модели,  $\mathbf{V}$  — параметры шлюзовой функции.

В качестве локальных моделей  $\mathbf{f}_k$  и шлюзовой функции  $\pi$  рассматриваются следующие функции:

$$\mathbf{f}_k(\mathbf{x}) = \mathbf{w}_k^T \mathbf{x}, \quad \pi(\mathbf{x}, \mathbf{V}) = \text{softmax}(\mathbf{V}_1^T \boldsymbol{\sigma}(\mathbf{V}_2^T \mathbf{x})),$$

где  $\mathbf{V} = \{\mathbf{V}_1, \mathbf{V}_2\}$  — параметры шлюзовой функции.

Параметры локальных моделей оптимизируются согласно принципу максимального правдоподобия модели:

$$p(\mathbf{y}, \mathbf{W} | \mathbf{X}, \mathbf{V}) = \prod_{k=1}^K p^k(\mathbf{w}_k) \prod_{i=1}^N \left( \sum_{k=1}^K \pi_k p_k(y_i | \mathbf{w}_k, \mathbf{x}_i) \right),$$

где  $\mathbf{W} = [\mathbf{w}_1, \mathbf{w}_2, \dots, \mathbf{w}_K]^T$ .

Задача оптимизации параметров локальных моделей и параметров смеси:

$$\hat{\mathbf{W}}, \hat{\mathbf{V}} = \arg \max_{\mathbf{W}, \mathbf{V}} p(\mathbf{y}, \mathbf{W} | \mathbf{X}, \mathbf{V}).$$

Рассматривается вероятностная постановка задачи:

- 1) правдоподобие выборки  $p_k(y_i | \mathbf{w}_k, \mathbf{x}_i) = \mathcal{N}(y_i | \mathbf{w}_k^T \mathbf{x}_i, \beta^{-1})$ , где  $\beta$  уровень шума,
- 2) априорное распределение параметров  $p^k(\mathbf{w}_k) = \mathcal{N}(\mathbf{w}_k | \mathbf{w}_k^0, \mathbf{A}_k)$ , где  $\mathbf{w}_k^0$  — вектор размера  $n \times 1$ ,  $\mathbf{A}_k$  — ковариационная матрица параметров,
- 3) регуляризация априорного распределения  $p(\boldsymbol{\varepsilon}_{k,k'} | \boldsymbol{\alpha}) = \mathcal{N}(\boldsymbol{\varepsilon}_{k,k'} | \mathbf{0}, \boldsymbol{\Xi})$ , где  $\boldsymbol{\Xi}$  — ковариационная матрица общего вида,  $\boldsymbol{\varepsilon}_{k,k'} = \mathbf{w}_k^0 - \mathbf{w}_{k'}^0$ .

Правдоподобие модели включает правдоподобие выборки, априорное распределение параметров, а также их регуляризацию

$$p(\mathbf{y}, \mathbf{W} | \mathbf{X}, \mathbf{V}, \mathbf{A}, \mathbf{W}^0, \Xi, \beta) = \prod_{k,k'=1}^K \mathcal{N}(\varepsilon_{k,k'} | \mathbf{0}, \Xi) \cdot \prod_{k=1}^K \mathcal{N}(\mathbf{w}_k | \mathbf{w}_k^0, \mathbf{A}_k) \prod_{i=1}^N \left( \sum_{k=1}^K \pi_k \mathcal{N}(y_i | \mathbf{w}_k^\top \mathbf{x}_i, \beta^{-1}) \right),$$

где  $\mathbf{A} = \{\mathbf{A}_1, \dots, \mathbf{A}_K\}$ . Введем скрытые переменные  $\mathbf{Z} = [z_{ik}]$ , где  $z_{ik} = 1$  тогда и только тогда, когда  $k_i = k$ :

$$\begin{aligned} \log p(\mathbf{y}, \mathbf{Z}, \mathbf{W} | \mathbf{X}, \mathbf{V}, \mathbf{A}, \mathbf{W}^0, \Xi, \beta) = & \\ & \sum_{i=1}^N \sum_{k=1}^K z_{ik} \left[ \log \pi_k(\mathbf{x}_i, \mathbf{V}) - \frac{\beta}{2} (y_i - \mathbf{w}_k^\top \mathbf{x}_i)^2 + \frac{1}{2} \log \frac{\beta}{2\pi} \right] + \\ & + \sum_{k=1}^K \left[ -\frac{1}{2} (\mathbf{w}_k - \mathbf{w}_k^0)^\top \mathbf{A}_k^{-1} (\mathbf{w}_k - \mathbf{w}_k^0) + \frac{1}{2} \log \det \mathbf{A}_k^{-1} - \frac{n}{2} \log 2\pi \right] + \\ & + \sum_{k=1}^K \sum_{k'=1}^K \left[ -\frac{1}{2} (\mathbf{w}_k^0 - \mathbf{w}_{k'}^0)^\top \hat{\alpha}^{-1} (\mathbf{w}_k^0 - \mathbf{w}_{k'}^0) + \frac{1}{2} \log \det \Xi - \frac{n}{2} \log 2\pi \right]. \end{aligned}$$



Задача оптимизации параметров локальных моделей и параметров смеси принимает следующий вид:

$$\mathbf{W}, \mathbf{Z}, \mathbf{V}, \mathbf{W}^0, \mathbf{A}, \beta = \arg \max_{\mathbf{W}, \mathbf{Z}, \mathbf{V}, \mathbf{W}^0, \mathbf{A}, \beta} \log p(\mathbf{y}, \mathbf{Z}, \mathbf{W} | \mathbf{X}, \mathbf{V}, \mathbf{A}, \mathbf{W}^0, \Xi, \beta).$$

Для оптимизации используется вариационный EM-алгоритм с аппроксимацией среднего поля  $q(\mathbf{Z}, \mathbf{W}) = q(\mathbf{Z})q(\mathbf{W})$ .

E и M шаги алгоритма имеют следующий вид:

① E-шаг:

$$\begin{aligned} \log q(\mathbf{Z}^s) &\propto E_{q/\mathbf{Z}} \log p(\mathbf{y}, \mathbf{Z}, \mathbf{W} | \mathbf{X}, \mathbf{V}^{s-1}, \mathbf{A}^{s-1}, \mathbf{W}^{0,s-1}, \Xi, \beta^{s-1}), \\ \log q(\mathbf{W}^s) &\propto E_{q/\mathbf{W}} \log p(\mathbf{y}, \mathbf{Z}, \mathbf{W} | \mathbf{X}, \mathbf{V}^{s-1}, \mathbf{A}^{s-1}, \mathbf{W}^{0,s-1}, \Xi, \beta^{s-1}), \end{aligned}$$

② M-шаг:

$$\mathbf{W}^{0,s}, \mathbf{A}^s, \mathbf{V}^s, \beta^s = \arg \max_{\mathbf{W}^0, \mathbf{A}, \mathbf{V}, \beta} E_{q^s} \log p(\mathbf{y}, \mathbf{Z}, \mathbf{W} | \mathbf{X}, \mathbf{V}, \mathbf{A}, \mathbf{W}^0, \Xi, \beta),$$

где  $s$  — номер итерации.

Итерационные формулы EM-алгоритма:

1 E-шаг:

$$p(z_{ik} = 1) = \frac{\exp(\log \pi_k(\mathbf{x}_i, \mathbf{V}) - \frac{\beta}{2}(\mathbf{x}_i^T \mathbf{E} \mathbf{w}_k \mathbf{w}_k^T \mathbf{x}_i - \mathbf{x}_i^T \mathbf{E} \mathbf{w}_k))}{\sum_{k'=1}^K \exp(\log \pi_{k'}(\mathbf{x}_i, \mathbf{V}) - \frac{\beta}{2}(\mathbf{x}_i^T \mathbf{E} \mathbf{w}_{k'} \mathbf{w}_{k'}^T \mathbf{x}_i - \mathbf{x}_i^T \mathbf{E} \mathbf{w}_{k'}))},$$

$$q(\mathbf{w}_k) = \mathcal{N}(\mathbf{w}_k | \mathbf{m}_k, \mathbf{B}_k),$$

$$\mathbf{m}_k = \mathbf{B}_k \left( \mathbf{A}_k^{-1} \mathbf{w}_k^0 + \beta \sum_{i=1}^N \mathbf{x}_i y_i \mathbf{E} z_{ik} \right), \quad \mathbf{B}_k = \left( \mathbf{A}_k^{-1} + \beta \sum_{i=1}^N \mathbf{x}_i \mathbf{x}_i^T \mathbf{E} z_{ik} \right)^{-1}.$$

2 M-шаг:

$$\mathbf{A}_k = \mathbf{E} \mathbf{w}_k \mathbf{w}_k^T - \mathbf{w}_k^0 \mathbf{E} \mathbf{w}_k^T - \mathbf{E} \mathbf{w}_k \mathbf{w}_k^{0T} + \mathbf{w}_k^0 \mathbf{w}_k^{0T},$$

$$\frac{1}{\beta} = \frac{1}{N} \sum_{i=1}^N \sum_{k=1}^K \left[ y_i^2 - 2y_i \mathbf{x}_i^T \mathbf{E} \mathbf{w}_k + \mathbf{x}_i^T \mathbf{E} \mathbf{w}_k \mathbf{w}_k^T \mathbf{x}_i \right] \mathbf{E} z_{ik},$$

$$\mathbf{w}_k^0 = [\mathbf{A}_k^{-1} + (K-1) \mathbf{\Xi}]^{-1} \left( \mathbf{A}_k^{-1} \mathbf{E} \mathbf{w}_k + \mathbf{\Xi} \sum_{k'=1, k' \neq k}^K \mathbf{w}_{k'}^0 \right),$$

$$\mathbf{V} = \arg \max_{\mathbf{V}} \mathbf{E}_{q^s} \log p(\mathbf{y}, \mathbf{Z}, \mathbf{W} | \mathbf{X}, \mathbf{V}, \mathbf{A}, \mathbf{W}^0, \mathbf{\Xi}, \beta).$$

Вычислительный эксперимент делится на следующие этапы:

- 1 Анализ синтетических данных с разным типом шума в изображении;
- 2 Анализ изменения параметров локальных моделей во время обучения;
- 3 Анализ мультимodelей в зависимости от уровня шума в изображении;
- 4 Анализ качества модели на реальных данные.

Гиперпараметры заданы следующим образом:

- 1 Априорные распределения на параметры локальных моделей в эксперименте задано следующим образом:

$$p^1(\mathbf{w}_1) \sim \mathcal{N}(\mathbf{w}_1^0, \mathbf{I}), \quad p^2(\mathbf{w}_2) \sim \mathcal{N}(\mathbf{w}_2^0, \mathbf{I}),$$

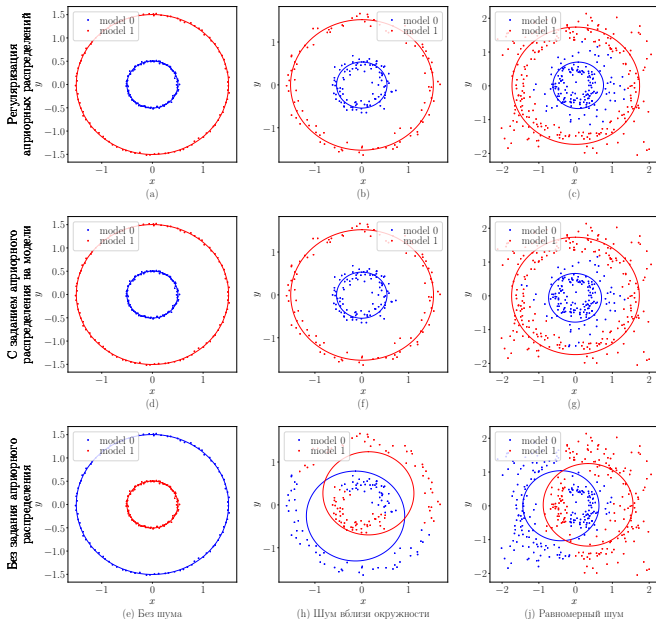
где  $\mathbf{w}_1^0 = [0, 0, 0.1]$ ,  $\mathbf{w}_2^0 = [0, 0, 2]$ .

- 2 Параметр регуляризации:

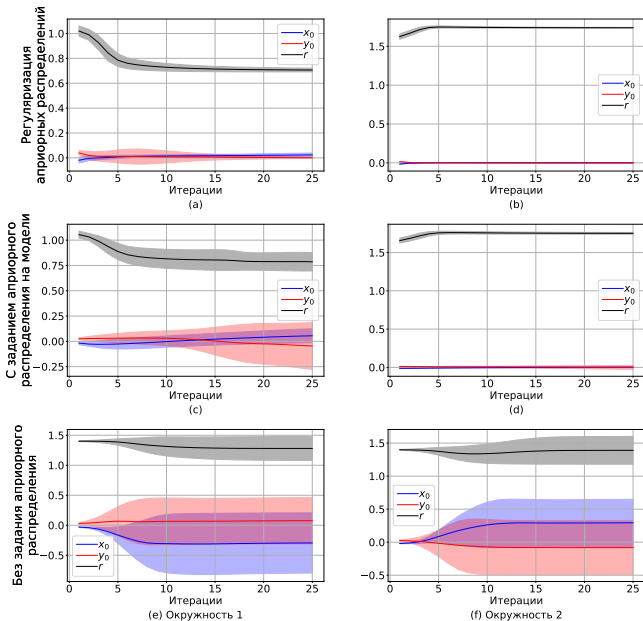
$$\Xi = \begin{bmatrix} 0.01 & 0 & 0 \\ 0 & 0.01 & 0 \\ 0 & 0 & 1 \end{bmatrix},$$

что указывает на концентричность окружностей.


# Синтетические данные с разным типом шума в изображении




# Параметры локальных моделей в процессе обучения




## Регуляризация априорных распределений










## С заданием априорного распределения на модели



## Без задания априорного распределения








(a) Исходное изображение

(b) Бинаризованное изображение




(c) Без задания априорного распределения

(d) С заданием априорного распределения на модели


(e) Регуляризация априорных распределений




## Регуляризация априорных распределений



## С заданием априорного распределения на модели



## Без задания априорного распределения



Пусть задано множество объектов  $\Omega$ , а также подмножество наблюдаемых объектов  $\Omega'$

$$\Omega' \subset \Omega,$$

где  $|\Omega'| = N$ . Пусть для  $\Omega$  задана некоторая экспертная информация  $E(\Omega)$ . На основе экспертной информации  $E(\Omega)$  введем отображения из множества объектов  $\Omega$ :

$$K_y^{E(\Omega)} : \Omega \rightarrow \mathbb{R}, \quad K_x^{E(\Omega)} : \Omega \rightarrow \mathbb{R}^n,$$

где  $n$  количество признаков, причем предполагаем, что  $n \ll N$ . Применив отображения  $K_x^{E(\Omega)}$  и  $K_y^{E(\Omega)}$  для множества наблюдаемых объектов  $\Omega'$  получаем выборку:

$$\mathcal{D}(\Omega', E(\Omega)) = \{(\mathbf{x}, y) \mid \mathbf{x} = K_x^{E(\Omega)}(\omega), y = K_y^{E(\Omega)}(\omega), \forall \omega \in \Omega'\}.$$

Предполагается, что существуют нетривиальные отображения  $K_y^{E(\Omega)}, K_x^{E(\Omega)}$ , и  $\mathbf{w} \in \mathbb{R}^n$ , такие, что:

$$y \approx \mathbf{x}^T \mathbf{w}, \quad \forall (\mathbf{x}, y) \in \mathcal{D}(\Omega', E(\Omega)),$$

то есть получаем выборку, которая является задачей линейной регрессии по нахождению неизвестного вектора  $\mathbf{w}$  (аналогично можно ввести задачу для логистической регрессии).

В случае, когда экспертная информация представляется в виде объединения нескольких экспертов:

$$E(\Omega) = E_0(\Omega) \cup E_1(\Omega_1) \cup E_2(\Omega_2) \cup \dots \cup E_K(\Omega_K), \quad \cup_{i=k}^K \Omega_k = \Omega$$

в этом случае будем говорить о задаче смеси  $K$  экспертов. Каждая информация  $E_k(\Omega_k)$  описывает локальную информацию о каком-то подмножестве объектов  $\Omega_k$  для всех  $k = \overline{1..K}$ . Информация эксперта  $E_0(\Omega)$  описывает глобальную информацию о всем множестве объектов  $\Omega$ .

В случае задачи смеси  $K$  экспертов вводятся отображения:

$$\begin{aligned} K_y^{E_1(\Omega_1)} : \Omega \rightarrow \mathbb{R}, \quad K_x^{E_1(\Omega_1)} : \Omega \rightarrow \mathbb{R}^{n_1}, \\ \dots \\ K_y^{E_K(\Omega_K)} : \Omega \rightarrow \mathbb{R}, \quad K_x^{E_K(\Omega_K)} : \Omega \rightarrow \mathbb{R}^{n_K}, \end{aligned}$$

где получаем множество отображений во множество локальных моделей, в которых учтены информации от каждого эксперта.

Также, как в и задаче одного эксперта вводятся предположения, что каждая локальная модель является линейной:

$$\forall k \in \{1, \dots, K\}, \quad y \approx \mathbf{x}^T \mathbf{w}_k, \quad \forall (\mathbf{x}, y) \in \mathcal{D}(\Omega'_k, E(\Omega_k)).$$

Заметим, что истинного разбиения  $\Omega$  на множества  $\{\Omega_k\}_{k=1}^K$  нету. Рассмотрим вектор функцию  $\pi$ :





$$\pi : \Omega \rightarrow \mathbb{R}^K, \quad \sum_{k=1}^K \pi_k(\omega) = 1, \quad \forall \omega \in \Omega,$$

где  $\pi$  назовем шлюзовой функцией.

Предположим, что все  $\left\{ \left( K_x^{E_k(\Omega_k)}, K_y^{E_k(\Omega_k)} \right) \right\}_{k=1}^K$  являются заданными отображениями. Используя локальные модели, построим глобальную мультимодель, которая описывает все множество объектов  $\Omega$ :

$$\sum_{\omega \in \Omega'} \sum_{k=1}^K \pi_k(\omega, \mathbf{V}) \left( K_y^{E_k(\Omega_k)}(\omega) - \mathbf{w}_k^\top K_x^{E_k(\Omega_k)}(\omega) \right)^2 + R(\mathbf{V}, \mathbf{W}, \mathbf{E}(\Omega)) \rightarrow \min_{\mathbf{V}, \mathbf{W}}$$

где  $\mathbf{W} = [\mathbf{w}_1^\top, \dots, \mathbf{w}_K^\top]$ , а  $R(\mathbf{V}, \mathbf{W}, \mathbf{E}(\Omega))$  является некоторой регуляризацией параметров, которая также основывается на экспертной информации,  $\mathbf{V}$  — параметры шлюзовой функции.



Произвольная кривая второго порядка, главная ось которой не параллельна оси ординат задается следующим выражением:


$$x^2 = B'xy + C'y^2 + D'x + E'y + F',$$

где на коэффициенты  $B', C'$  накладываются ограничения, которые зависят от вида кривой. Выражение принимает следующий вид:

$$K_x(\mathbf{c}_i) = [x_i y_i, y_i^2, x_i, y_i, 1], \quad K_y(\mathbf{c}_i) = x_i^2,$$

откуда получаем задачу линейной регрессии для восстановления параметров  $B', C', D', E', F'$  по составленной выборке.

# Задача поиска кривых второго порядка: результат аппроксимации



# Задача поиска кривых второго порядка: от уровня шума

