

Проверка обоснованности обучаемых моделей зависимостей. Обобщенный линейный подход

Моттль Вадим Вячеславович

Вычислительный центр РАН

Левдик Павел Владимирович

Московский физико-технический институт

Красоткина Ольга Вячеславовна

Московский государственный университет

Типовая задача восстановления закономерности на множестве объектов реального мира

Некоторое множество реально существующих объектов $\omega \in \Omega$.

Некоторое множество значений скрытой характеристики объектов $y \in \mathbb{Y}$.

Типовая задача восстановления закономерности на множестве объектов реального мира

Некоторое множество реально существующих объектов $\omega \in \Omega$.

Некоторое множество значений скрытой характеристики объектов $y \in \mathbb{Y}$.

Природа выбирает пару $(\omega, y) \in \Omega \times \mathbb{Y}$, где наблюдателю недоступно значение $y \in \mathbb{Y}$

Желание наблюдателя:

Иметь инструмент оценивания скрытой характеристики для реальных объектов

$\hat{y}(\omega) : \Omega \rightarrow \mathbb{Y}$; $\hat{y}(\omega) \neq y(\omega)$ – ошибка.

Типовая задача восстановления закономерности на множестве объектов реального мира

Некоторое множество реально существующих объектов $\omega \in \Omega$.

Некоторое множество значений скрытой характеристики объектов $y \in \mathbb{Y}$.

Природа выбирает пару $(\omega, y) \in \Omega \times \mathbb{Y}$, где наблюдателю недоступно значение $y \in \mathbb{Y}$

Желание наблюдателя:

Иметь инструмент оценивания скрытой характеристики для реальных объектов

$\hat{y}(\omega) : \Omega \rightarrow \mathbb{Y}$; $\hat{y}(\omega) \neq y(\omega)$ – ошибка.

Обучение по прецедентам:

Подмножество наблюдаемых объектов $\Omega^* \subset \Omega$, для которых измерено значение целевой характеристики $(\omega \in \Omega^*, y)$:

$\{(\omega_j, y_j), j = 1, \dots, N\}$ – обучающая совокупность.

Типовая задача восстановления закономерности на множестве объектов реального мира

Некоторое множество реально существующих объектов $\omega \in \Omega$.

Некоторое множество значений скрытой характеристики объектов $y \in \mathbb{Y}$.

Природа выбирает пару $(\omega, y) \in \Omega \times \mathbb{Y}$, где наблюдателю недоступно значение $y \in \mathbb{Y}$

Желание наблюдателя:

Иметь инструмент оценивания скрытой характеристики для реальных объектов

$\hat{y}(\omega) : \Omega \rightarrow \mathbb{Y}$; $\hat{y}(\omega) \neq y(\omega)$ – ошибка.

Обучение по прецедентам:

Подмножество наблюдаемых объектов $\Omega^* \subset \Omega$, для которых измерено значение целевой характеристики $(\omega \in \Omega^*, y)$:

$\{(\omega_j, y_j), j = 1, \dots, N\}$ – обучающая совокупность.

Задача: Выбрать функцию $\hat{y}(\omega)$, определенную на всем множестве Ω , так чтобы можно было в дальнейшем оценивать значение рассматриваемой характеристики для новых объектов $\omega \in \Omega \setminus \Omega^*$.

Типовая задача восстановления закономерности на множестве объектов реального мира

Некоторое множество реально существующих объектов $\omega \in \Omega$.

Некоторое множество значений скрытой характеристики объектов $y \in \mathbb{Y}$.

Природа выбирает пару $(\omega, y) \in \Omega \times \mathbb{Y}$, где наблюдателю недоступно значение $y \in \mathbb{Y}$

Желание наблюдателя:

Иметь инструмент оценивания скрытой характеристики для реальных объектов

$\hat{y}(\omega) : \Omega \rightarrow \mathbb{Y}$; $\hat{y}(\omega) \neq y(\omega)$ – ошибка.

Типовые случаи:

Задача обучения распознаванию образов

$\mathbb{Y} = \{y_1, \dots, y_m\}$ – конечное неупорядоченное множество; в частности $\mathbb{Y} = \{-1, 1\}$.

Задача восстановления числовой регрессии, т.е. оценивания числовой функции

$\mathbb{Y} = \mathbb{R}$ – множество действительных чисел.

Задача восстановления ранговой регрессии

$\mathbb{Y} = \{y_1 < \dots < y_m\}$ – конечное множество с отношением линейного порядка.

Представление объектов в виде, допускающем ввод данных в компьютер

Непосредственно построить оценочную функцию $\hat{y}(\omega)$ невозможно, поскольку объект реального мира $\omega \in \Omega$ не может быть явно представлен в компьютере.

1. Индивидуальное представление объектов.

$$\mathbf{x}(\omega) = (x_1(\omega) \cdots x_n(\omega))^T : \Omega \rightarrow \mathbb{R}^n$$

Простейшая ситуация:
вектор из n числовых признаков

Обучающая совокупность: $\left\{ (\mathbf{x}_j = \mathbf{x}(\omega_j), y_j = y(\omega_j)), j = 1, \dots, N \right\}$.

2. Сравнительное числовое представление объектов.

Объекты могут быть восприняты компьютером только через их попарное сравнение.

$S(\omega', \omega'') : \Omega \times \Omega \rightarrow \mathbb{R}$ – числовая функция, выражающая некоторое сравнительное свойство пар объектов.

Базисная совокупность $\{\omega_i^0, i = 1, \dots, n\} \subset \Omega$	Нет значений целевой характеристики, есть только матрица парных сравнений $[S(\omega_i, \omega_k), i, k = 1, \dots, n]$
$\mathbf{x}(\omega) = (x_i(\omega) = S(\omega_i, \omega), i = 1, \dots, n) \in \mathbb{R}^n$	Вектор вторичных признаков объекта $\omega \in \Omega$ относительно базисной совокупности
Обучающая совокупность (часть базисной совокупности) $\{\omega_j, j = 1, \dots, N\} \subset \Omega$	Известны значения целевой характеристики $\left\{ (\mathbf{x}_j = \mathbf{x}(\omega_j), y_j = y(\omega_j)), j = 1, \dots, N \right\}$

Обобщенная линейная модель зависимости

Вектор вторичных признаков объекта

$$\mathbf{x}(\omega) = (x_i(\omega) = S(\omega_i, \omega), i = 1, \dots, n) \in \mathbb{R}^n$$

Функция парного сравнения

$$S(\omega', \omega''): \Omega \times \Omega \rightarrow \mathbb{R} \text{ – фантазия наблюдателя}$$

Параметры модели

зависимости (\mathbf{a}, b)

$$\begin{cases} \mathbf{a} \in \mathbb{R}^n \text{ – направляющий вектор} \\ b \in \mathbb{R} \text{ – сдвиг модели} \end{cases}$$

Обобщенный линейный признак объекта $z(\mathbf{x}, \mathbf{a}, b) = \mathbf{a}^T \mathbf{x} + b: \mathbb{R}^n \xrightarrow{(\mathbf{a}, b)} \mathbb{R}$

Целевая характеристика объекта $y(\omega) \in \mathbb{Y}$ – задана природой

Функция связи (link function),

обычно выпуклая по z

$$q(y, z): \mathbb{Y} \times \mathbb{R} \rightarrow \mathbb{R}^+ \text{ – фантазия наблюдателя}$$

Параметрическая функция потерь $q(y, \mathbf{x}, \mathbf{a}, b) = q(y, z(\mathbf{x}, \mathbf{a}, b)): \mathbb{Y} \times \mathbb{R}^n \xrightarrow{(\mathbf{a}, b)} \mathbb{R}^+$

Решающее правило $\hat{y}(\mathbf{x} | \mathbf{a}, b) = \operatorname{argmin}_{y \in \mathbb{Y}} q(y, \mathbf{x}, \mathbf{a}, b): \mathbb{X} \xrightarrow{(\mathbf{a}, b)} \mathbb{Y}$

Обучающая совокупность $(\mathbf{X}, \mathbf{Y}) = \left\{ (\mathbf{x}(\omega_j), y(\omega_j)) = (\mathbf{x}_j, y_j), j = 1, \dots, N \right\}$

Эмпирический риск

$$Q(v, b | \mathbf{X}, \mathbf{Y}) = \frac{1}{N} \sum_{j=1}^N q(y_j, \mathbf{x}_j, v, b)$$

Обучение – выбор $(\mathbf{a} \in \mathbb{R}^n, b \in \mathbb{R})$:

Минимизация

эмпирического риска

$$\begin{aligned} \sum_{j=1}^N q(y_j, z(\mathbf{x}_j, \mathbf{a}, b)) &\rightarrow \min(\mathbf{a}, b), \\ z(\mathbf{x}_j, \mathbf{a}, b) &= \mathbf{a}^T \mathbf{x}_j + b \end{aligned}$$

Обобщенная линейная модель зависимости

Вектор вторичных признаков объекта $\mathbf{x}(\omega) = (x_i(\omega) = S(\omega_i, \omega | \alpha), i = 1, \dots, n) \in \mathbb{R}^n$ Параметрическое семейство функций сравнения $S(\omega', \omega'' | \alpha): \Omega \times \Omega \rightarrow \mathbb{R}$ – фантазия наблюдателя

Параметры модели зависимости (\mathbf{a}, b) $\begin{cases} \mathbf{a} \in \mathbb{R}^n & \text{– направляющий вектор} \\ b \in \mathbb{R} & \text{– сдвиг модели} \end{cases}$

Обобщенный линейный признак объекта $z(\mathbf{x}, \mathbf{a}, b) = \mathbf{a}^T \mathbf{x} + b: \mathbb{R}^n \xrightarrow{(\mathbf{a}, b)} \mathbb{R}$

Целевая характеристика объекта $y(\omega) \in \mathbb{Y}$ – задана природой

Функция связи (link function), обычно выпуклая по z $q(y, z): \mathbb{Y} \times \mathbb{R} \rightarrow \mathbb{R}^+ \text{ – фантазия наблюдателя}$

Параметрическая функция потерь $q(y, \mathbf{x}, \mathbf{a}, b) = q(y, z(\mathbf{x}, \mathbf{a}, b)): \mathbb{Y} \times \mathbb{R}^n \xrightarrow{(\mathbf{a}, b)} \mathbb{R}^+$

Решающее правило $\hat{y}(\mathbf{x} | \mathbf{a}, b) = \operatorname{argmin}_{y \in \mathbb{Y}} q(y, \mathbf{x}, \mathbf{a}, b): \mathbb{X} \xrightarrow{(\mathbf{a}, b)} \mathbb{Y}$

Обучающая совокупность $(\mathbf{X}, \mathbf{Y}) = \left\{ (\mathbf{x}(\omega_j), y(\omega_j)) = (\mathbf{x}_j, y_j), j = 1, \dots, N \right\}$

Семейство выпуклых регуляризующих функций $V(\mathbf{a} | \mu): \mathbb{R}^n \xrightarrow{\mu} \mathbb{R}^+ \text{ – еще одна фантазия наблюдателя}$

Обучение – выбор $(\mathbf{a} \in \mathbb{R}^n, b \in \mathbb{R})$:
Минимизация регуляризованного эмпирического риска

$$V(\mathbf{a} | \mu) + c \sum_{j=1}^N q(y_j, z(\mathbf{x}_j, \mathbf{a}, b)) \rightarrow \min(v, b),$$

$$z(\mathbf{x}_j, \mathbf{a}, b) = K(\mathbf{x}_j, v) + b$$

Критерий выпуклый, если регуляризующая функция $V(\mathbf{a} | \mu)$ и функция связи $q(y, z)$ выпуклы по $\mathbf{a} \in \mathbb{R}^n$ и $z \in \mathbb{R}$.

Вероятностная интерпретация минимизации регуляризованного эмпирического риска

**Обучение: Минимизация
регуляризованного эмпирического риска**
на обучающей совокупности

$$(X, Y) = \left\{ \left(x(\omega_j), y(\omega_j) \right) = (x_j, y_j), j = 1, \dots, N \right\}$$

$$V(\mathbf{a} | \mu) + c \sum_{j=1}^N q\left(y_j, z(\mathbf{x}_j, \mathbf{a}, b)\right) \rightarrow \min(\mathbf{a}, b),$$

$$z(\mathbf{x}_j, \mathbf{a}, b) = K(\mathbf{x}_j, \mathbf{a}) + b$$

Регуляризирующая функция $V(\mathbf{a} | \mu)$ и функция связи $q(y, z)$ выпуклы по $\mathbf{a} \in \mathbb{R}^n$ и $z \in \mathbb{R}$.

Вероятностные эвристики наблюдателя

1) Чем меньше параметрическая функция потерь $q(y, z(\mathbf{x}, \mathbf{a}, b))$, тем более вероятно появление объекта с характеристиками (\mathbf{x}, y) .

Предполагаемое параметрическое семейство совместных распределений $\varphi(\mathbf{x}, y | \mathbf{a}, b, c) \propto \exp\{-cq(y, z(\mathbf{x}, \mathbf{a}, b))\}$.

2) Чем меньше регуляризирующая функция $V(\mathbf{a} | \mu)$, тем более априори вероятно значение параметра $\mathbf{a} \in \mathbb{R}^n$; предположений о b нет.

Предполагаемое параметрическое семейство априорных распределений $\psi(\mathbf{a}, b | \mu) \propto \psi(\mathbf{a} | \mu) \propto \exp\{-c'V(\mathbf{a} | \mu)\}$.

Байесовский принцип обучения:
максимизации апостериорной плотности
на обучающей совокупности

$$(X, Y) = \left\{ \left(\mathbf{x}(\omega_j), y(\omega_j) \right) = (\mathbf{x}_j, y_j), j = 1, \dots, N \right\}$$

$$P(\mathbf{a}, b | X, Y, \mu, c) \propto$$

$$\psi(\mathbf{a} | \mu) \Phi(X, Y | \mathbf{a}, b, c) \rightarrow \max(\mathbf{a}, b),$$

$$\Phi(X, Y | \mathbf{a}, b, c) = \prod_{j=1}^N \varphi(\mathbf{x}_j, y_j | \mathbf{a}, b, c).$$

Вероятностная интерпретация минимизации регуляризованного эмпирического риска

Обучение: Минимизация
регуляризованного эмпирического риска
на обучающей совокупности

$$(X, Y) = \left\{ (x(\omega_j), y(\omega_j)) = (x_j, y_j), j = 1, \dots, N \right\}$$

$$V(\mathbf{a} | \mu) + c \sum_{j=1}^N q(y_j, z(\mathbf{x}_j, \mathbf{a}, b)) \rightarrow \min(\mathbf{a}, b),$$

$$z(\mathbf{x}_j, \mathbf{a}, b) = K(\mathbf{x}_j, \mathbf{a}) + b$$

Регуляризирующая функция $V(\mathbf{a} | \mu)$ и функция связи $q(y, z)$ выпуклы по $\mathbf{a} \in \mathbb{R}^n$ и $z \in \mathbb{R}$.

Вероятностные эвристики наблюдателя

1) Чем меньше параметрическая функция потерь $q(y, z(\mathbf{x}, \mathbf{a}, b))$, тем более вероятно появление объекта с характеристиками (\mathbf{x}, y) .

Предполагаемое параметрическое семейство совместных распределений $\varphi(\mathbf{x}, y | \mathbf{a}, b, c) \propto \exp\{-cq(y, z(\mathbf{x}, \mathbf{a}, b))\}$.

2) Чем меньше регуляризирующая функция $V(\mathbf{a} | \mu)$, тем более априори вероятно значение параметра $\mathbf{a} \in \mathbb{R}^n$.

Предполагаемое параметрическое семейство априорных распределений $\Psi(\mathbf{a} | \mu) \propto \exp\{-V(\mathbf{a} | \mu)\}$.

Выбор значений структурных параметров:
Максимизация полной функции
правдоподобия (Evidence Function) на
обучающей совокупности

$$F(X, Y | \mu, c) = \int_{\mathbb{R}} \int_{\mathbb{R}^n} [\Psi(\mathbf{a} | \mu) \Phi(X, Y | \mathbf{a}, b, c)] d\mathbf{a} db \rightarrow \max(\mu, c),$$

$$\Phi(X, Y | \mathbf{a}, b, c) = \prod_{j=1}^N \varphi(\mathbf{x}_j, y_j | \mathbf{a}, b, c).$$

Полная функция правдоподобия (Evidence Function)

Элементы вероятностной модели зависимости:

Априорная плотность распределения направляющего вектора и сдвига	$\Psi(\mathbf{a}, b \mu) \propto \exp\{-V(\mathbf{a} \mu)\}$
Условная плотность распределения характеристик случайного объекта	$\varphi(\mathbf{x}, y \mathbf{a}, b, c) \propto \exp\{-cq(y, z(\mathbf{x}, \mathbf{a}, b))\}$
Совместная условная плотность распределения случайной обучающей совокупности	$\Phi(\mathbf{X}, \mathbf{Y} \mathbf{a}, b, c) = \prod_{j=1}^N \varphi(\mathbf{x}_j, y_j \mathbf{a}, b, c)$
Структурные параметры обобщенной линейной модели зависимости	– параметр μ регуляр. функции, – параметр c модели наблюдения.

Маргинальная плотность распределения обучающей совокупности – непрерывная смесь условных распределений:

$F(\mathbf{X}, \mathbf{Y} \mu, c) = \int \int_{\mathbb{R} \mathbb{R}^n} \Phi(\mathbf{X}, \mathbf{Y} \mathbf{a}, b, c) \Psi(\mathbf{a}, b \mu) da db$	Функция правдоподобия для (μ, c) (Marginal Likelihood, Evidence Function)
--	--

Оценки максимального правдоподобия для структурных параметров:

$$(\hat{\mu}, \hat{c}) = \operatorname{argmax} F(\mathbf{X}, \mathbf{Y} | \mu, c)$$

Вычислить этот интеграл легко только для простейших составляющих модели:	– функции связи $q(y, z)$, – регуляризирующей функции $V(\mathbf{a} \mu)$.
--	---

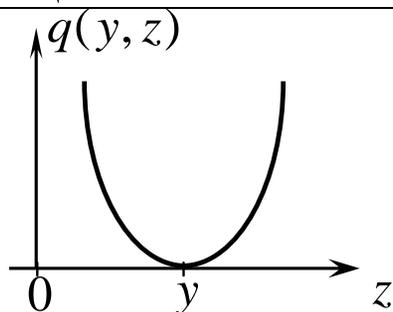
Нужен прямой алгоритм оптимизации, не требующий вычисления интеграла.

Некоторые функции связи

Числовая регрессия

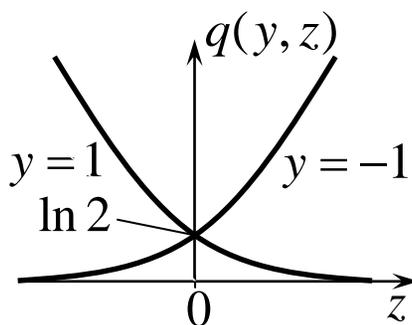
$$y \in \mathbb{Y} = \mathbb{R},$$

$$q(y, z) = (y - z)^2$$



Распознавание образов,
логистическая
регрессия

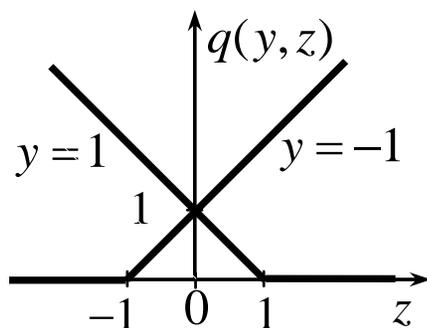
$$q(y, z) = \ln[1 + \exp(-y z)]$$



Распознавание образов,
метод опорных
векторов

$$q(y, z) = \max[0, 1 - yz] =$$

$$\begin{cases} 1 - yz, & 1 - yz > 0, \\ 0, & 1 - yz \leq 0. \end{cases}$$



Некоторые регуляризующие функции

Простейшая
квадратичная
регуляризация

$$V(\mathbf{a}) = \sum_{i=1}^n a_i^2$$

Квадратично-
модульная
регуляризация
(Elastic Net)

$$V(\mathbf{a} | \mu) = \sum_{i=1}^n a_i^2 + \mu \sum_{i=1}^n |a_i|$$

Другая
квадратично-
модульная
регуляризация

$$V(\mathbf{a} | \mu) = \sum_{i=1}^n \begin{cases} 2\mu |a_i|, & |a_i| \leq \mu, \\ \mu^2 + a_i^2, & |a_i| > \mu. \end{cases}$$

Альтернативная запись функции правдоподобия

Два эквивалентных выражения для совместная плотность распределения наблюдений, направляющего вектора и сдвига:

$$\underbrace{H(X, Y, a, b / \mu, c)}_{\text{совместное распределение}} = \underbrace{\Phi(X, Y / a, b, c)}_{\text{условное распределение}} \underbrace{\Psi(a, b | \mu)}_{\substack{\text{априорное} \\ \text{распределение} - \\ \text{функция} \\ \text{правдоподобия}}} = \underbrace{F(X, Y / \mu, c)}_{\text{маргинальное распределение}} \underbrace{P(a, b / X, Y, \mu, c)}_{\text{апостериорное распределение}}$$

Отсюда прямое выражение для функции правдоподобия:

$$\text{При любых значениях } (a, b) \quad F(X, Y / \mu, c) = \frac{\Phi(X, Y / a, b, c) \Psi(a, b | \mu)}{P(a, b / X, Y, \mu, c)}$$

Наиболее правдоподобные значения структурных параметров модели:

$$\ln F(X, Y / \mu, c) = \ln \Phi(X, Y / a, b, c) + \ln \Psi(a, b | \mu) - \ln P(a, b / X, Y, \mu, c) \rightarrow \max(\mu, c)$$

Допустим, что мы можем вычислить апостериорную плотность для некоторых значений $(\hat{\mu}_k, \hat{c}_k)$, рассматриваемых как очередное приближение к точке максимума.

Теорема: Функция правдоподобия допускает представление:

$$\ln F(X, Y / \mu, c) = \int \int_{\mathbb{R} \mathbb{R}^n} [\ln \Phi(X, Y / a, b, c)] P(a, b / X, Y, \hat{\mu}_k, \hat{c}_k) da db + \int \int_{\mathbb{R} \mathbb{R}^n} [\ln \Psi(a, b | \mu)] P(a, b / X, Y, \hat{\mu}_k, \hat{c}_k) da db - \underbrace{\int \int_{\mathbb{R} \mathbb{R}^n} \ln P(a, b / X, Y, \mu, c) P(a, b / X, Y, \hat{\mu}_k, \hat{c}_k) da db}_{}$$

Фундаментальное неравенство: $\leq \int \int_{\mathbb{R} \mathbb{R}^n} \ln P(a, b / X, Y, \hat{\mu}_k, \hat{c}_k) P(a, b / X, Y, \hat{\mu}_k, \hat{c}_k) da db$

EM-алгоритм максимизации функции правдоподобия

Допустим, что мы можем вычислить апостериорную плотность для некоторых значений $(\hat{\mu}_k, \hat{c}_k)$, рассматриваемых как очередное приближение к точке максимума.

$$\ln F(\mathbf{X}, \mathbf{Y} / \mu, c) = \int_{\mathbb{R}} \int_{\mathbb{R}^n} [\ln \Phi(\mathbf{X}, \mathbf{Y} / a, b, c)] P(a, b / \mathbf{X}, \mathbf{Y}, \hat{\mu}_k, \hat{c}_k) da db +$$

$$\int_{\mathbb{R}} \int_{\mathbb{R}^n} [\ln \Psi(a, b | \mu)] P(a, b / \mathbf{X}, \mathbf{Y}, \hat{\mu}_k, \hat{c}_k) da db - \underbrace{\int_{\mathbb{R}} \int_{\mathbb{R}^n} \ln P(a, b / \mathbf{X}, \mathbf{Y}, \mu, c) P(a, b / \mathbf{X}, \mathbf{Y}, \hat{\mu}_k, \hat{c}_k) da db}_{}$$

Фундаментальное неравенство: $\geq \int_{\mathbb{R}} \int_{\mathbb{R}^n} \ln P(a, b / \mathbf{X}, \mathbf{Y}, \hat{\mu}_k, \hat{c}_k) P(a, b / \mathbf{X}, \mathbf{Y}, \hat{\mu}_k, \hat{c}_k) da db$

Отсюда следует правило пересчета $(\hat{\mu}_k, \hat{c}_k) \rightarrow (\hat{\mu}_{k+1}, \hat{c}_{k+1})$, гарантирующее неубывание функции правдоподобия:

$$\hat{\mu}_{k+1} = \arg \max_{\mu} \int_{\mathbb{R}} \int_{\mathbb{R}^n} [\ln \Psi(a, b | \mu)] P(a, b / \mathbf{X}, \mathbf{Y}, \hat{\mu}_k, \hat{c}_k) da db,$$

$$\hat{c}_{k+1} = \underbrace{\arg \max_{\mu}}_{\text{maximization}} \underbrace{\int_{\mathbb{R}} \int_{\mathbb{R}^n} [\ln \Phi(\mathbf{X}, \mathbf{Y} / a, b, c)] P(a, b / \mathbf{X}, \mathbf{Y}, \hat{\mu}_k, \hat{c}_k) da db}_{\text{expectation}}.$$

Знаменитый **EM-алгоритм** максимизации функций правдоподобия.

Теорема: $\ln F(\mathbf{X}, \mathbf{Y} / \hat{\mu}_{k+1}, \hat{c}_{k+1}) \geq \ln F(\mathbf{X}, \mathbf{Y} / \hat{\mu}_k, \hat{c}_k)$,

$$\text{пока } \frac{\partial}{\partial \mu} \ln F(\mathbf{X}, \mathbf{Y} / \hat{\mu}_k, \hat{c}_k) \neq 0 \text{ либо } \frac{\partial}{\partial c} \ln F(\mathbf{X}, \mathbf{Y} / \hat{\mu}_k, \hat{c}_k) \neq 0.$$

Трудности реализации EM-алгоритма

EM-алгоритм:

$$\hat{\mu}_{k+1} = \arg \max_{\mu} \int \int_{\mathbb{R} \mathbb{R}^n} [\ln \Psi(\mathbf{a}, b | \mu)] P(\mathbf{a}, b | \mathbf{X}, \mathbf{Y}, \hat{\mu}_k, \hat{c}_k) d\mathbf{a} db,$$

$$\hat{c}_{k+1} = \arg \max_{\mu} \int \int_{\mathbb{R} \mathbb{R}^n} [\ln \Phi(\mathbf{X}, \mathbf{Y} | \mathbf{a}, b, c)] P(\mathbf{a}, b | \mathbf{X}, \mathbf{Y}, \hat{\mu}_k, \hat{c}_k) d\mathbf{a} db.$$

Апостериорное распределение направляющего вектора и сдвига:

$$P(\mathbf{a}, b | \mathbf{X}, \mathbf{Y}, \mu, c) \propto \Psi(\mathbf{a}, b | \mu) \Phi(\mathbf{X}, \mathbf{Y} | \mathbf{a}, b, c)$$

Напомним, что здесь

$$\Psi(\mathbf{a}, b | \mu) \propto \exp\{-V(\mathbf{a} | \mu)\}, \quad \Phi(\mathbf{X}, \mathbf{Y} | \mathbf{a}, b, c) \propto \exp\left\{-c \sum_{j=1}^N q(y_j, z(\mathbf{x}_j, \mathbf{a}, b))\right\}$$

Для многих регуляризирующих функций $V(\mathbf{a} | \mu)$ и функций связи $q(y, z)$ интегрирование по такой апостериорной плотности затруднительно.

В следующем докладе Павел Левдик расскажет, как можно обойти эту трудность путем нормальной аппроксимации апостериорной плотности распределения:

$$P(\mathbf{a}, b | \mathbf{X}, \mathbf{Y}, \mu, c) \cong \mathcal{N}(\mathbf{a} | \hat{\mathbf{a}}_{y, \mathbf{X}, \mu, c}, \mathbf{B}_{\mathbf{X}, c}) \mathcal{N}(b | \hat{b}_{y, \mathbf{X}, \mu, c}(\mathbf{a}), \hat{\sigma}_N^2).$$