

Вариационный подход как приближенный способ байесовского вывода

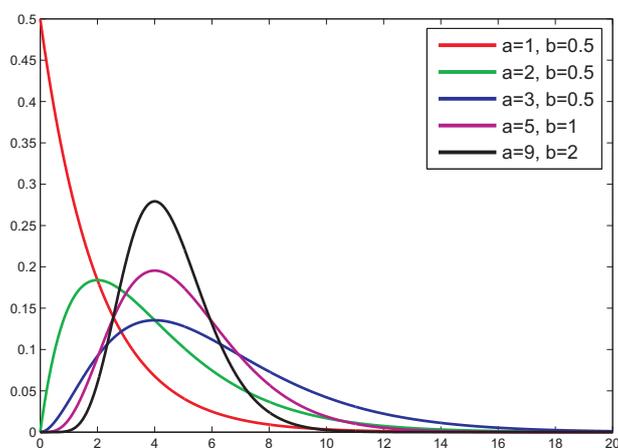
Дата: 9 ноября 2011

Ликбез: Гамма-распределение

Гамма-распределение является вероятностным распределением для действительной положительной переменной λ и имеет плотность:

$$\mathcal{G}(\lambda|a, b) = \frac{b^a}{\Gamma(a)} \lambda^{a-1} \exp(-b\lambda), \quad a, b > 0.$$

Здесь $\Gamma(a)$ – гамма-функция. Различные виды гамма-распределения:



С помощью гамма-распределения можно задать широкий спектр унимодальных несимметричных распределений на положительной полуоси. Часто гамма-распределение используются в качестве априорного распределения для параметра масштаба (например, параметра α в линейной и логистической регрессии). Гамма-распределение является сопряженным для параметра точности в нормальном распределении:

$$\mathcal{N}(x|\mu, \lambda^{-1}) = \sqrt{\frac{\lambda}{2\pi}} \exp\left(-\frac{\lambda}{2}(x - \mu)^2\right).$$

Статистики гамма-распределения:

$$\begin{aligned} \mathbb{E}\lambda &= \frac{a}{b}, \\ \mathbb{D}\lambda &= \frac{a}{b^2}, \\ \mathbb{E} \log \lambda &= \Psi(a) - \log b. \end{aligned}$$

Здесь $\Psi(a) = \frac{d}{da} \log \Gamma(a)$ – дигамма функция.

Вывод в вероятностных моделях

Пусть имеется некоторая вероятностная модель, задаваемая совместным распределением $p(X, T, Z)$. Здесь X – известные переменные, T – оцениваемые переменные, Z – неизвестные переменные, которые не требуется оценивать. Тогда задача вывода в вероятностной модели соответствует вычислению апостериорного распределения

$$p(T|X) = \frac{p(T, X)}{p(X)} = \frac{\int p(X, T, Z) dZ}{\int p(X, \tilde{T}, Z) d\tilde{T} dZ}.$$

В том случае, если нас интересуют точечные оценки, то тогда берется, как правило, мат.ожидание или мода апостериорного распределения:

$$\hat{T} = \arg \max_T p(T|X),$$

$$\hat{T} = \mathbb{E}[T|X].$$

Интегралы, возникающие при получении апостериорного распределения, часто не вычисляются аналитически. Следовательно, для осуществления байесовского вывода требуются приближенные методы. Первый класс методов приближенного байесовского вывода – это методы Монте Карло с марковскими цепями. Другой класс методов – вариационный подход.

Примеры вероятностных моделей

Линейная регрессия.

$$p(\mathbf{t}, \mathbf{w}, \alpha, \beta | X) = \prod_{n=1}^N p(t_n | \mathbf{w}, \beta, \mathbf{x}_n) p(\mathbf{w} | \alpha) p(\alpha) p(\beta),$$

$$p(t_n | \mathbf{w}, \beta, \mathbf{x}_n) = \mathcal{N}\left(t_n \mid \sum_{j=1}^M w_j \phi_j(\mathbf{x}_n), \beta^{-1}\right),$$

$$p(\mathbf{w} | \alpha) = \mathcal{N}(\mathbf{w} | \mathbf{0}, \alpha^{-1} I),$$

$$p(\alpha) = \mathcal{G}(\alpha | a_0, b_0),$$

$$p(\beta) = \mathcal{G}(\beta | c_0, d_0).$$

Задача вывода ($X - (\mathbf{t}, X, \mathbf{x}_{new}), Z - (\mathbf{w}, \beta, \alpha), T - t_{new}$):

$$p(t_{new} | \mathbf{x}_{new}, \mathbf{t}, X) = \int p(t_{new} | \mathbf{w}, \beta, \mathbf{x}_{new}) p(\mathbf{w}, \beta, \alpha | \mathbf{t}, X) d\mathbf{w} d\beta d\alpha.$$

Логистическая регрессия.

$$p(\mathbf{t}, \mathbf{w}, \alpha | X) = \prod_{n=1}^N p(t_n | \mathbf{w}, \mathbf{x}_n) p(\mathbf{w} | \alpha) p(\alpha),$$

$$p(t_n | \mathbf{w}, \mathbf{x}_n) = \frac{1}{1 + \exp(-t_n \sum_{j=1}^M w_j \phi_j(\mathbf{x}_n))},$$

$$p(\mathbf{w} | \alpha) = \mathcal{N}(\mathbf{w} | \mathbf{0}, \alpha^{-1} I),$$

$$p(\alpha) = \mathcal{G}(\alpha | a_0, b_0).$$

Задача вывода ($X - (\mathbf{t}, X, \mathbf{x}_{new}), Z - (\mathbf{w}, \alpha), T - t_{new}$):

$$p(t_{new} | \mathbf{x}_{new}, \mathbf{t}, X) = \int p(t_{new} | \mathbf{w}, \mathbf{x}_{new}) p(\mathbf{w}, \alpha | \mathbf{t}, X) d\mathbf{w} d\alpha.$$

Смесь нормальных распределений.

$$p(X, T, \boldsymbol{\pi}, \boldsymbol{\mu}, \Sigma) = \prod_{n=1}^N p(\mathbf{x}_n | \mathbf{t}_n, \boldsymbol{\mu}, \Sigma) p(\mathbf{t}_n | \boldsymbol{\pi}) p(\boldsymbol{\pi}, \boldsymbol{\mu}, \Sigma),$$

$$p(\mathbf{x}_n | \mathbf{t}_n, \boldsymbol{\mu}, \Sigma) = \prod_{k=1}^K [\mathcal{N}(\mathbf{x}_n | \boldsymbol{\mu}_k, \Sigma_k)]^{t_{nk}},$$

$$p(\mathbf{t}_n | \boldsymbol{\pi}) = \prod_{k=1}^K \pi_k^{t_{nk}},$$

$$p(\boldsymbol{\pi}, \boldsymbol{\mu}, \Sigma) = \text{const.}$$

Задача вывода ($X - X, Z - T, T - (\boldsymbol{\pi}, \boldsymbol{\mu}, \Sigma)$):

$$p(\boldsymbol{\pi}, \boldsymbol{\mu}, \Sigma | X) \propto p(X | \boldsymbol{\pi}, \boldsymbol{\mu}, \Sigma) \rightarrow \max_{\boldsymbol{\pi}, \boldsymbol{\mu}, \Sigma}.$$

Нижняя оценка обоснованности

Пусть имеется вероятностная модель $p(X, T)$ и некоторое произвольное распределение $q(T)$. Тогда:

$$\log p(X) = \underbrace{\int \log \frac{p(X, T)}{q(T)} q(T) dT}_{\mathcal{L}(q)} - \underbrace{\int \log \frac{p(T|X)}{q(T)} q(T) dT}_{\text{KL}(q||p(T|X))}.$$

На это равенство можно смотреть с нескольких точек зрения. Допустим, что апостериорное распределение $p(T|X)$ не поддается вычислению (не вычисляется нормировочная константа) и мы хотим найти приближение $q(T)$ для распределения $p(T|X)$. Будем искать это приближение путем минимизации КЛ-дивергенции между распределением $q(T)$ и $p(T|X)$ в некотором семействе распределений $q(T)$. Тогда из равенства выше следует, что

$$\text{KL}(q||p(T|X)) \rightarrow \min_q \Leftrightarrow \mathcal{L}(q) \rightarrow \max_q.$$

Теперь задача минимизации, которая зависит от недоступного для вычисления распределения $p(T|X)$, сведена к задаче максимизации функционала $\mathcal{L}(q)$, который зависит от известного полного совместного распределения модели $p(X, T)$.

С другой точки зрения, нас может интересовать значение маргинального распределения $p(X)$ (нормировочной константы для распределения $p(T|X)$). Так как $\text{KL}(q||p(T|X)) \geq 0$, то значение функционала $\mathcal{L}(q)$ является нижней границей для $\log p(X)$. Таким образом, решая задачу максимизации функционала $\mathcal{L}(q)$ в некотором семействе распределений $q(T)$, мы одновременно получаем аналитическое приближение апостериорного распределения $p(T|X)$ и нижнюю границу для обоснованности $\log p(X)$.

Рассмотренные выше рассуждения справедливы также и для случая, когда требуется оценить произвольное распределение, известное с точностью до константы. Пусть имеется некоторое распределение

$$p(T) = \frac{1}{Z} \tilde{p}(T),$$

в котором мы умеем вычислять $\tilde{p}(T)$ для произвольного T , но нормировочная константа Z является недоступной. Тогда максимизация функционала

$$\mathcal{L}(q) = \int \log \frac{\tilde{p}(T)}{q(T)} q(T) dT \rightarrow \max_q$$

позволяет найти приближение $q(T)$ для распределения $p(T)$, а также оценить значение нормировочной константы $\log Z \geq \mathcal{L}(q)$.

Минимизация в семействе факторизованных распределений

Рассмотрим задачу приближения апостериорного распределения $p(T|X)$ в семействе т.н. факторизованных распределений:

$$q(T) = \prod_{j=1}^J q_j(T_j).$$

Здесь множество переменных T разбито на непересекающиеся подмножества T_j , причем $\cup_j T_j = T$, а $q_j(T_j)$ – произвольное распределение в пространстве переменных T_j . Таким образом, мы приходим к следующей задаче оптимизации:

$$\mathcal{L}(q) = \int \log \frac{p(X, T)}{\prod_j q_j(T_j)} \prod_j q_j(T_j) dT_j \rightarrow \max_{q_1, \dots, q_J}.$$

Рассмотрим решение этой задачи оптимизации с помощью покоординатного подъема, т.е. зафиксируем все компоненты распределения q , кроме q_i , и рассмотрим оптимизацию $\mathcal{L}(q)$ по отдельной

компоненте $q_i(T_i)$. Оказывается, что решение такой (вариационной) задачи оптимизации можно получить аналитически:

$$\begin{aligned} \mathcal{L}(q) &= \int \log p(X, T) \prod_j q_j(T_j) dT_j - \sum_{j=1}^J \int \log q_j(T_j) q_j(T_j) dT_j = \\ &= \int \left(\int \log p(X, T) \prod_{j \neq i} q_j(T_j) dT_j \right) q_i(T_i) dT_i - \int \log q_i(T_i) q_i(T_i) dT_i + \text{const}. \end{aligned}$$

Рассмотрим следующее распределение $r(T_i)$:

$$r(T_i) = \frac{1}{Z} \exp \left(\int \log p(X, T) \prod_{j \neq i} q_j(T_j) dT_j \right),$$

где Z – нормировочная константа распределения, не зависящая от $q_i(T_i)$. Тогда $\log r(T_i) + \log Z = \int \log p(X, T) \prod_{j \neq i} q_j(T_j) dT_j$. Подставляя этот результат в выражение для $\mathcal{L}(q)$, получаем:

$$\begin{aligned} \mathcal{L}(q) &= \int \log r(T_i) q_i(T_i) dT_i - \int \log q_i(T_i) q_i(T_i) dT_i + \text{const} = \\ &= \int \log \frac{r(T_i)}{q_i(T_i)} q_i(T_i) dT_i + \text{const} = -\text{KL}(q_i || r) + \text{const}. \end{aligned}$$

Таким образом, максимизация $\mathcal{L}(q)$ в данном случае эквивалентна минимизации $\text{KL}(q_i || r)$ по распределению $q_i(T_i)$. Однако, известно, что минимум КЛ-дивергенции достигается в случае тождественных распределений, т.е.

$$q_i(T_i) = \frac{\exp \left(\int \log p(X, T) \prod_{j \neq i} q_j(T_j) dT_j \right)}{\int \exp \left(\int \log p(X, T) \prod_{j \neq i} q_j(T_j) dT_j \right) dT_i}. \quad (1)$$

Последняя формула является основным результатом вариационного подхода. Заметим, что оптимальное распределение $q_i(T_i)$ зависит от всех остальных распределений $q_j(T_j)$ для $j \neq i$. Поэтому при применении вариационного подхода возникает итерационная схема, в которой последовательно пересчитываются отдельные компоненты факторизованного распределения $q(T)$. При этом на каждом шаге итерации происходит монотонное увеличение нижней границы $\mathcal{L}(q)$ для обоснованности $\log p(X)$, и итерационная оптимизация происходит до сходимости по значению $\mathcal{L}(q)$. Заметим также, что в построениях выше не накладывалось никаких ограничений на семейство распределений $q(T)$, кроме факторизации.

В вариационном подходе требуется уметь усреднять логарифм совместного распределения $\log p(X, T)$ по всем компонентам $q(T)$, кроме одного, $\exp \left(\int \log p(X, T) \prod_{j \neq i} q_j(T_j) dT_j \right)$, вычислять нормировочную константу для очередного распределения $\int \exp \left(\int \log p(X, T) \prod_{j \neq i} q_j(T_j) dT_j \right) dT_i$, а также нижнюю границу $\mathcal{L}(q) = \int \log p(X, T) q(T) dT - \int \log q(T) q(T) dT$. Заметим, что все эти величины требуют интегрирования по пространству переменных T . Здесь может создаться впечатление, что вариационный подход никак не облегчает исходную задачу поиска $p(X)$, т.к. $p(X)$ также представляет собой схожий интеграл по пространству T $\int p(X, T) dT$. Тем не менее, во многих реальных вероятностных моделях вариационный подход действительно позволяет решить поставленную задачу. Это связано с тем, что в вариационном подходе происходит интегрирование логарифма совместного распределения $\log p(X, T)$, а не самого исходного распределения $p(X, T)$. Кроме того, интегрирование также облегчает предположение о факторизации $q(T)$, т.е. интеграл часто удается разбить на произведение интегралов от подмножеств переменных T . Конкретные примеры применения вариационного подхода будут рассмотрены ниже.

Заметим, что в общей задаче байесовского вывода (см. пункт 2) мы имеем дело с тремя группами переменных X, T, Z , где X – наблюдаемые переменные, T – переменные, подлежащие оцениванию, и Z – остальные ненаблюдаемые переменные. При применении вариационного подхода происходит

поиск приближения апостериорного распределения $p(T, Z|X)$ в семействе факторизованных распределений $q(T, Z) = q_T(T)q_Z(Z)$. Затем

$$p(T|X) = \int p(T, Z|X)dZ \simeq \int q_T(T)q_Z(Z)dZ = q_T(T).$$

Пример применения вариационного подхода для модели линейной регрессии

Рассмотрим задачу регрессии. Пусть имеется некоторая выборка $(\mathbf{t}, X) = \{t_n, \mathbf{x}_n\}_{n=1}^N$, состоящая из N объектов, где каждый объект представлен своим вектором признаков $\mathbf{x}_n \in \mathbb{R}^d$ и значением регрессионной переменной $t_n \in \mathbb{R}$. Задача состоит в прогнозе регрессионной компоненты t_{new} для объекта, представленного только своим вектором признаков \mathbf{x}_{new} .

Для решения этой задачи воспользуемся байесовской моделью линейной регрессии:

$$\begin{aligned} p(\mathbf{t}, t_{new}, \mathbf{w}, \alpha, \beta | X, \mathbf{x}_{new}) &= \prod_{n=1}^N p(t_n | \mathbf{w}, \beta, \mathbf{x}_n) p(t_{new} | \mathbf{w}, \beta, \mathbf{x}_{new}) p(\mathbf{w} | \alpha) p(\alpha) p(\beta), \\ p(t_n | \mathbf{w}, \sigma, \mathbf{x}_n) &= \mathcal{N}\left(t_n \left| \sum_{j=1}^M w_j \phi_j(\mathbf{x}_n), \beta^{-1} \right.\right), \\ p(\mathbf{w} | \alpha) &= \mathcal{N}(\mathbf{w} | \mathbf{0}, \alpha^{-1} I), \\ p(\alpha) &= \mathcal{G}(\alpha | a_0, b_0), \\ p(\beta) &= \mathcal{G}(\beta | c_0, d_0). \end{aligned}$$

С помощью вариационного подхода будет искать приближение для апостериорного распределения $p(\mathbf{w}, \alpha, \beta | \mathbf{t}, X)$ в семействе факторизованных распределений $q_{\mathbf{w}}(\mathbf{w})q_{\alpha}(\alpha)q_{\beta}(\beta)$. Для этого воспользуемся общим результатом (1) и рассмотрим применение этой формулы для каждой компоненты распределения $q_{\mathbf{w}}(\mathbf{w})$, $q_{\alpha}(\alpha)$ и $q_{\beta}(\beta)$.

Компонента $q_{\mathbf{w}}(\mathbf{w})$.

$$\begin{aligned} \log q_{\mathbf{w}}(\mathbf{w}) &= \int \log p(\mathbf{t}, \mathbf{w}, \alpha, \beta | X) q_{\alpha}(\alpha) q_{\beta}(\beta) d\alpha d\beta + \text{const} = \\ &= \underbrace{\frac{N}{2}(\log \beta - \log 2\pi)}_{\text{не зависит от } \mathbf{w}} - \frac{\mathbb{E}\beta}{2} \sum_{n=1}^N (t_n - \mathbf{w}^T \phi(\mathbf{x}_n))^2 + \underbrace{\frac{M}{2}(\log \alpha - \log 2\pi)}_{\text{не зависит от } \mathbf{w}} - \frac{\mathbb{E}\alpha}{2} \mathbf{w}^T \mathbf{w} + \\ &+ \underbrace{\log \mathcal{G}(\alpha | a_0, b_0) + \log \mathcal{G}(\beta | c_0, d_0)}_{\text{не зависит от } \mathbf{w}} + \text{const} = -\frac{\mathbb{E}\beta}{2} \sum_{n=1}^N (t_n - \mathbf{w}^T \phi(\mathbf{x}_n))^2 - \frac{\mathbb{E}\alpha}{2} \mathbf{w}^T \mathbf{w} + \text{const}. \quad (2) \end{aligned}$$

Здесь под $\mathbb{E}\beta$ понимается мат. ожидание по распределению $q_{\beta}(\beta)$, а под $\mathbb{E}\alpha$ – мат.ожидание по распределению $q_{\alpha}(\alpha)$. Выражение (2) как функция от \mathbf{w} представляет собой квадратичную функцию. Следовательно, распределение $q_{\mathbf{w}}(\mathbf{w})$ является нормальным распределением со следующими параметрами:

$$\Sigma = \left(\text{diag}(\mathbb{E}\alpha) + \mathbb{E}\beta \sum_n \phi(\mathbf{x}_n) \phi(\mathbf{x}_n)^T \right)^{-1}, \quad (3)$$

$$\boldsymbol{\mu} = \Sigma \left(\sum_n \mathbb{E}\beta t_n \phi(\mathbf{x}_n) \right). \quad (4)$$

Компонента $q_{\alpha}(\alpha)$.

$$\begin{aligned} \log q_{\alpha}(\alpha) &= \int \log p(\mathbf{t}, \mathbf{w}, \alpha, \beta | X) q_{\mathbf{w}}(\mathbf{w}) q_{\beta}(\beta) d\mathbf{w} d\beta + \text{const} = \\ &= \frac{M}{2} \log \alpha + \frac{\alpha}{2} \mathbb{E} \mathbf{w}^T \mathbf{w} + (a_0 - 1) \log \alpha - b_0 \alpha + \text{const}. \end{aligned}$$

В этом выражении легко узнается логарифм гамма-распределения с параметрами:

$$a = a_0 + \frac{M}{2}, \quad (5)$$

$$b = b_0 + \mathbb{E}\mathbf{w}^T\mathbf{w}. \quad (6)$$

Компонента $q_\beta(\beta)$.

$$\begin{aligned} \log q_\beta(\beta) &= \int \log p(\mathbf{t}, \mathbf{w}, \alpha, \beta | X) q_{\mathbf{w}}(\mathbf{w}) q_\alpha(\alpha) d\mathbf{w} d\alpha + \text{const} = \\ &= \frac{N}{2} \log \beta - \frac{\beta}{2} \sum_{n=1}^N \mathbb{E}(t_n - \mathbf{w}^T \phi(\mathbf{x}_n))^2 + (c_0 - 1) \log \beta - d_0 \beta + \text{const}. \end{aligned}$$

В этом выражении также узнается логарифм гамма-распределения с параметрами:

$$c = c_0 + \frac{N}{2}, \quad (7)$$

$$d = d_0 + \frac{1}{2} \sum_n \mathbb{E}(t_n - \mathbf{w}^T \phi(\mathbf{x}_n))^2. \quad (8)$$

Итоговый алгоритм.

Таким образом, на каждой итерации вариационного алгоритма компоненты факторизованного распределения $q(\mathbf{w}, \alpha, \beta)$ представляют собой

$$q_{\mathbf{w}}(\mathbf{w}) = \mathcal{N}(\mathbf{w} | \boldsymbol{\mu}, \Sigma), \quad (9)$$

$$q_\alpha(\alpha) = \mathcal{G}(\alpha | a, b), \quad (10)$$

$$q_\beta(\beta) = \mathcal{G}(\beta | c, d), \quad (11)$$

где соответствующие параметры распределений пересчитываются по формулам (3)-(4), (5)-(6) и (7)-(8). При этом необходимые статистики распределений для формул пересчета выглядят следующим образом:

$$\mathbb{E}\alpha = \frac{a}{b},$$

$$\mathbb{E}\beta = \frac{c}{d},$$

$$\mathbb{E}\mathbf{w}^T\mathbf{w} = \text{tr}\mathbb{E}(\mathbf{w}\mathbf{w}^T),$$

$$\mathbb{E}(t_n - \mathbf{w}^T \phi(\mathbf{x}_n))^2 = t_n^2 - 2\mathbb{E}\mathbf{w}^T \phi(\mathbf{x}_n) + \phi(\mathbf{x}_n)^T \mathbb{E}\mathbf{w}\mathbf{w}^T \phi(\mathbf{x}_n),$$

$$\mathbb{E}\mathbf{w} = \boldsymbol{\mu},$$

$$\mathbb{E}\mathbf{w}\mathbf{w}^T = \Sigma + \boldsymbol{\mu}\boldsymbol{\mu}^T.$$

Заметим, что по аналогии со схемой Гиббса в вариационном подходе все компоненты распределения пересчитываются последовательно. Сначала фиксируются начальные приближения для всех параметров распределений $\boldsymbol{\mu}, \Sigma, a, b, c, d$. Затем, новые значения $\boldsymbol{\mu}$ и Σ вычисляются по формулам (3)-(4). Эти значения используются для вычисления необходимых статистик распределения $\mathbb{E}\mathbf{w}$, $\mathbb{E}\mathbf{w}\mathbf{w}^T$ и др. После этого находят новые значения a и b по формулам (5)-(6) и новые статистики $\mathbb{E}\alpha$ и $\mathbb{E}\log \alpha$. И так далее.

Как уже было отмечено выше, в вариационном подходе помимо приближения апостериорного распределения $p(\mathbf{w}, \alpha, \beta | \mathbf{t}, X) \simeq q_{\mathbf{w}}(\mathbf{w}) q_\alpha(\alpha) q_\beta(\beta)$ мы можем получить также нижнюю границу на обоснованность $\log p(\mathbf{t} | X)$:

$$\log p(\mathbf{t} | X) \geq \mathcal{L}(q) = \mathbb{E} \log p(\mathbf{t}, \mathbf{w}, \alpha, \beta | X) - \mathbb{E} \log q_{\mathbf{w}}(\mathbf{w}) - \mathbb{E} \log q_\alpha(\alpha) - \mathbb{E} \log q_\beta(\beta).$$

С учетом результата (9)-(11) нижняя граница $\mathcal{L}(q)$ вычисляется аналитически:

$$\begin{aligned} \mathbb{E} \log p(\mathbf{t}, \mathbf{w}, \alpha, \beta | X) &= \frac{N}{2} (\mathbb{E} \log \beta - \log 2\pi) - \frac{\mathbb{E}\beta}{2} \sum_n \mathbb{E}(t_n - \mathbf{w}^T \phi(\mathbf{x}_n))^2 + \frac{M}{2} (\mathbb{E} \log \alpha - \log 2\pi) - \frac{\mathbb{E}\alpha}{2} \mathbb{E}\mathbf{w}^T\mathbf{w} + \\ &+ (a_0 - 1) \mathbb{E} \log \alpha - b_0 \mathbb{E}\alpha + a_0 \log b_0 - \log \Gamma(a_0) + (c_0 - 1) \mathbb{E} \log \beta - d_0 \mathbb{E}\beta + c_0 \log d_0 - \log \Gamma(c_0). \end{aligned}$$

$$\begin{aligned}\mathbb{E} \log q_{\mathbf{w}}(\mathbf{w}) &= -\frac{M}{2}(\log 2\pi + 1) - \frac{1}{2} \log \det \Sigma, \\ \mathbb{E} \log q_{\alpha}(\alpha) &= (a-1)\mathbb{E} \log \alpha - b\mathbb{E} \alpha + a \log b - \log \Gamma(a), \\ \mathbb{E} \log q_{\beta}(\beta) &= (c-1)\mathbb{E} \log \beta - d\mathbb{E} \beta + c \log d - \log \Gamma(c).\end{aligned}$$

Для вычисления этих выражений необходимо знать ряд дополнительных статистик распределений, которые вычисляются следующим образом (см. ликбез для гамма-распределения):

$$\begin{aligned}\mathbb{E} \log \alpha &= \Psi(a) - \log(b), \\ \mathbb{E} \log \beta &= \Psi(c) - \log(d).\end{aligned}$$

В ходе итерационного процесса значение $\mathcal{L}(q)$ не убывает. Итерационный процесс заканчивается, когда значение $\mathcal{L}(q)$ стабилизируется.

Для получения прогноза регрессионной компоненты t_{new} для объекта \mathbf{x}_{new} необходимо вычислить следующий интеграл:

$$p(t_{new} | \mathbf{x}_{new}, \mathbf{t}, X) = \int p(t_{new} | \mathbf{x}_{new}, \mathbf{w}, \beta) p(\mathbf{w}, \alpha, \beta | \mathbf{t}, X) d\mathbf{w} d\alpha d\beta.$$

Подставляя вместо апостериорного распределения $p(\mathbf{w}, \alpha, \beta | \mathbf{t}, X)$ его факторизованное приближение, получаем:

$$\begin{aligned}p(t_{new} | \mathbf{x}_{new}, \mathbf{t}, X) &\simeq \hat{p}(t_{new} | \mathbf{x}_{new}, \mathbf{t}, X) = \int p(t_{new} | \mathbf{x}_{new}, \mathbf{w}, \beta) q_{\mathbf{w}}(\mathbf{w}) q_{\beta}(\beta) d\mathbf{w} d\beta = \\ &= \int \left[\int \mathcal{N}(t_{new} | \mathbf{w}^T \boldsymbol{\phi}(\mathbf{x}_{new}), \beta^{-1}) \mathcal{N}(\mathbf{w} | \boldsymbol{\mu}, \Sigma) d\mathbf{w} \right] \mathcal{G}(\beta | c, d) d\beta = \\ &= \int \mathcal{N}(t_{new} | \boldsymbol{\mu}^T \boldsymbol{\phi}(\mathbf{x}_{new}), \beta^{-1} + \boldsymbol{\phi}(\mathbf{x}_{new})^T \Sigma \boldsymbol{\phi}(\mathbf{x}_{new})) \mathcal{G}(\beta | c, d) d\beta.\end{aligned}$$

Последний интеграл не берется аналитически. Однако, данный интеграл является одномерным и поэтому может быть эффективно оценен с помощью метода Монте Карло, т.к. мы можем легко получать выборку из гамма-распределения. Кроме того, можно показать, что $\mathbb{E}_{\hat{p}} t_{new} = \boldsymbol{\mu}^T \boldsymbol{\phi}(\mathbf{x}_{new})$, а $\mathbb{D}_{\hat{p}} t_{new} \simeq (\mathbb{E} \beta)^{-1} + \boldsymbol{\phi}(\mathbf{x}_{new})^T \Sigma \boldsymbol{\phi}(\mathbf{x}_{new})$.