ВАРИАЦИОННЫЕ ПРИБЛИЖЕНИЯ II

Сергей Николенко

СПбГУ — Санкт-Петербург
15 марта 2019 г.

Random facts:

- 15 марта — праздник Державной иконы Божией Матери; 2 (15) марта 1917 г. она была обретена в подвале Вознесенской церкви монаршего села Коломенского, и в тот же день Николай II подписал отречение в пользу Михаила Александровича; естественно, икона стала главной святыней российских монархистов
- В Японии 15 марта — Хонэн-мацури (праздник богатого года), синтоистский праздник плодородия; особо известно празднование в Комаки: по городу проходит парад с микоси, в котором подвешен гигантский (2.5 метра, 250 кг) деревянный фаллос; Хонэн-мацури — день почитания богини Тамахимэ-но микото, а фаллос символизирует её мужа, воина Такэ-ина-данэ, который навещает супругу
- 15 марта 1812 г. было основано первое русское поселение в Калифорнии, колония Росс; колония всегда оставалась убыточной для Российско-Американской компании и в 1841 году была продана Джону Саттеру за 42857 рублей серебром
- 15 марта 1985 г. был зарегистрирован первый домен в зоне .com, symbolics.com; сейчас по этому адресу расположен музей интернета

Вариационное приближение для гауссиана

Одномерный гауссиан

- И ещё пример: давайте найдём параметры одномерного гауссиана по точкам $\mathbf{X} = \{x_1, \dots, x_N\}$. Правдоподобие:

$$p(\mathbf{X} \mid \mu, \tau) = \left(\frac{\tau}{2\pi}\right)^{N/2} e^{-\frac{\tau}{2}\sum_{n=1}^{N}(x_n-\mu)^2}.$$

- Вводим сопряжённые априорные распределения:

$$p(\mu \mid \tau) = N(\mu \mid \mu_0, (\lambda_0\tau)^{-1}),$$
$$p(\tau) = \mathrm{Gamma}(\tau \mid a_0, b_0).$$

- Мы это только что подсчитали точно, но давайте приблизим теперь апостериорное распределение как

$$q(\mu, \tau) = q_\mu(\mu) q_\tau(\tau).$$

- На самом деле так не раскладывается!
- Это то, что мы делали для $q(\mathbf{Z}) = \prod_{i=1}^{M} q_i(\mathbf{Z}_i)$. Посчитаем...

Одномерный гауссиан

- ...$q_\mu(\mu)$ – гауссиан с параметрами

$$\mu_N = \frac{\lambda_0\mu_0 + N\bar{x}}{\lambda_0 + N}, \quad \lambda_N = (\lambda_0 + N)\mathrm{E}[\tau].$$

- А $q_\tau(\tau)$ – гамма-распределение с параметрами

$$a_N = a_0 + \frac{N}{2}, \quad b_N = b_0 + \frac{1}{2}\mathrm{E}_\mu\left[\sum_n (x_n - \mu)^2 + \lambda_0(\mu - \mu_0)^2\right].$$

- Всё получилось как надо, но без предположений о форме q_τ и q_μ.

Одномерный гауссиан

- Вот такой вывод в пространстве (μ, τ):

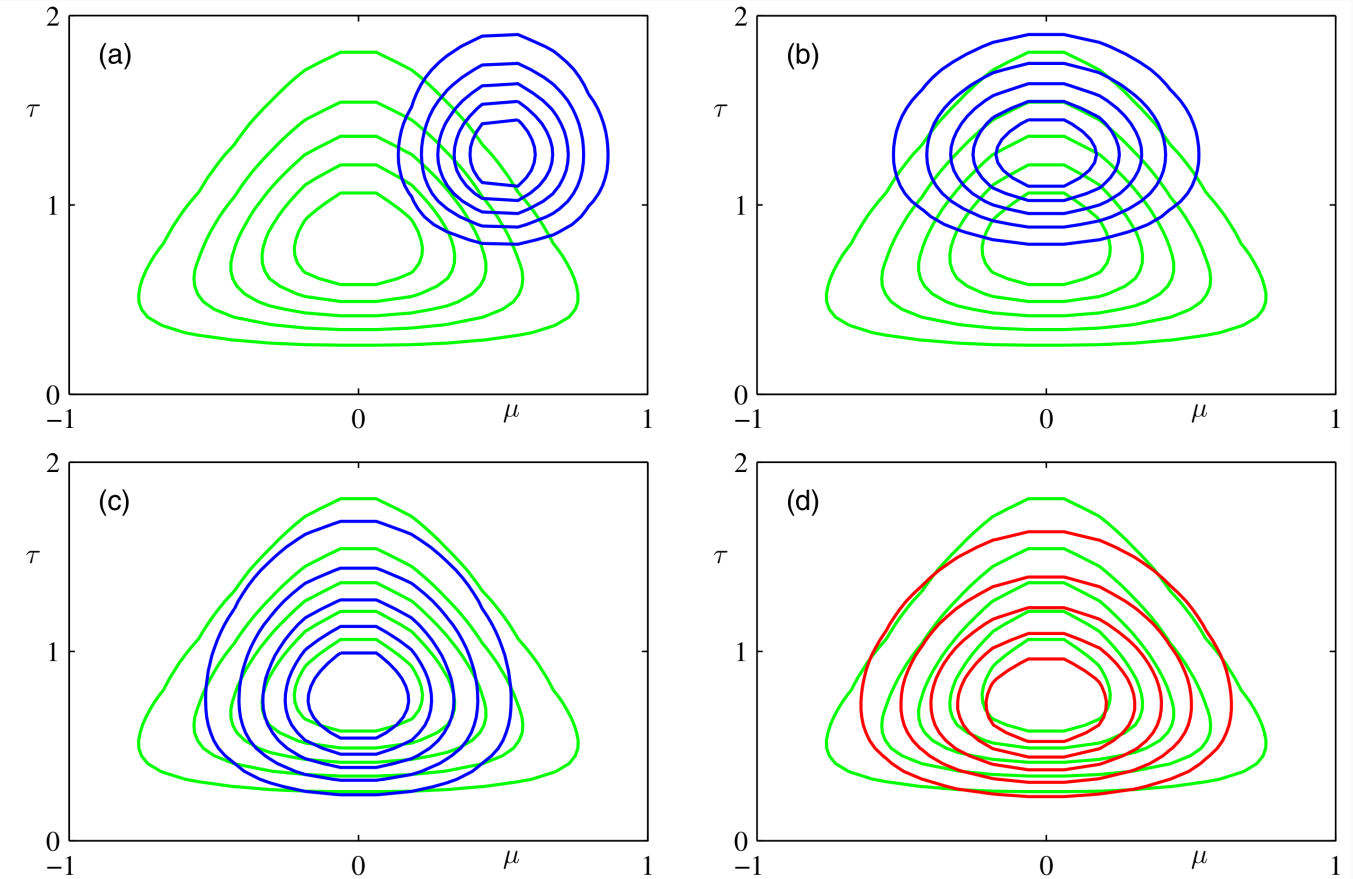

- А для $\mu_0 = a_0 = b_0 = \lambda_0 = 0$ (non-informative priors) можно и точно посчитать...

Одномерный гауссиан

- Получатся моменты для μ

$$\mathrm{E}[\mu] = \bar{x}, \quad \mathrm{E}[\mu^2] = \bar{x}^2 + \frac{1}{N\mathrm{E}[\tau]}.$$

- Это можно подставить и найти $\mathrm{E}[\tau]$:

$$\frac{1}{\mathrm{E}[\tau]} = \frac{1}{N-1}\sum_{n=1}^{N}(x_n - \bar{x})^2.$$

- Автоматически получили несмещённую оценку дисперсии!

Вариационное приближение для смеси гауссианов

Смесь гауссианов

- Смесь гауссианов: $\mathbf{X} = \{\mathbf{x}_1, \dots, \mathbf{x}_n\}$, $\mathbf{Z} = \{\mathbf{z}_1, \dots, \mathbf{z}_n\}$,

$$p(\mathbf{Z} \mid \pi) = \prod_{n=1}^{N} \prod_{k=1}^{K} \pi_k^{z_{nk}},$$

$$p(\mathbf{X} \mid \mathbf{Z}, \mu, \Lambda) = \prod_{n=1}^{N} \prod_{k=1}^{K} N\left(\mathbf{x}_n \mid \mu_k, \Lambda_k^{-1}\right).$$

- Выберем сопряжённые априорные распределения:

$$p(\pi) = \mathrm{Dir}(\pi \mid \alpha_0) = C(\alpha_0) \prod_{k=1}^{K} \pi_k^{\alpha_0 - 1},$$

$$\begin{aligned} p(\mu, \Lambda) &= p(\mu \mid \Lambda) p(\Lambda) \\ &= \prod_{k=1}^{K} N\left(\mu_k \mid \mathbf{m}_0, (\beta_0 \Lambda_k)^{-1}\right) W(\Lambda_k \mid W_0, \nu_0). \end{aligned}$$

Смесь гауссианов

- Вот такая графическая модель:

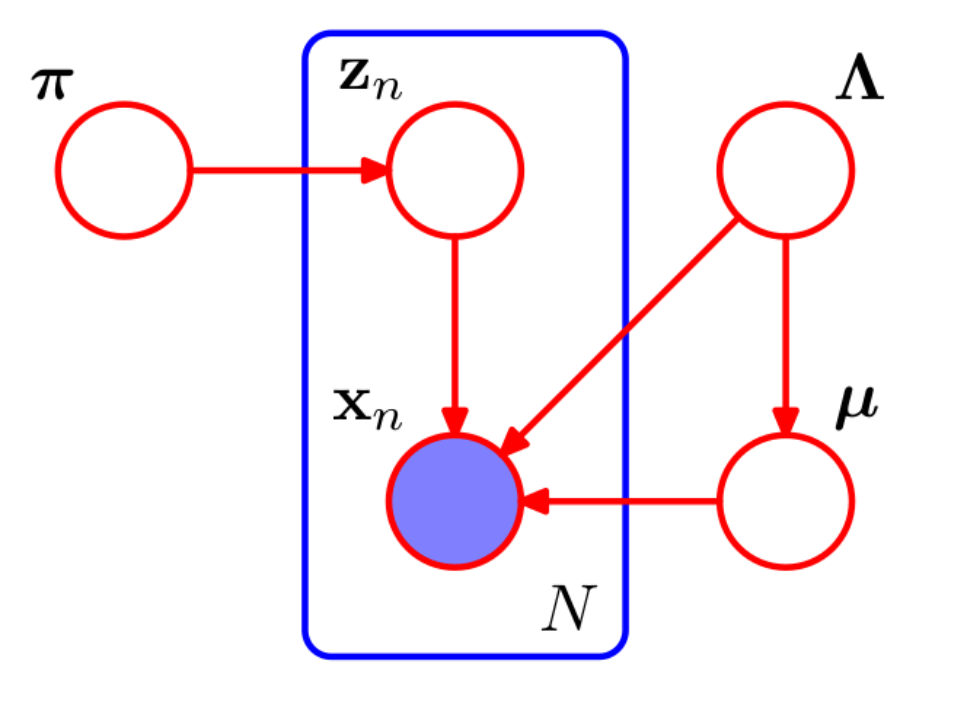

- Распределение Дирихле пусть будет симметричное для простоты; часто ещё $\mathbf{m}_0 = 0$.
- Заметьте разницу между латентными переменными и параметрами модели.

Вариационное приближение

- Теперь вариационное приближение. Сначала сама факторизация:

$$p(\mathbf{X}, \mathbf{Z}, \pi, \mu, \Lambda) = p(\mathbf{X} \mid \mathbf{Z}, \mu, \Lambda)p(\mathbf{Z} \mid \pi)p(\pi)p(\mu \mid \Lambda)p(\Lambda).$$

- Мы наблюдаем только $\mathbf{X}$, остальное всё надо как-то оценить.
- Интересно, что единственное предположение про наше вариационное приближение выглядит так:

$$q(\mathbf{Z}, \pi, \mu, \Lambda) = q(\mathbf{Z})q(\pi, \mu, \Lambda).$$

- И всё! Дальше всё само собой получится. Но не сразу...

Вариационное приближение

- Сначала $q^*(\mathbf{Z})$:

$$\begin{aligned}\ln q^*(\mathbf{Z}) &= \mathrm{E}_{\pi,\mu,\Lambda}\left[\ln p(\mathbf{X},\mathbf{Z},\pi,\mu,\Lambda)\right] + \mathrm{const}\\ &= \mathrm{E}_{\pi,\mu,\Lambda}\left[\ln p(\mathbf{Z}\mid\pi)\right] + \mathrm{E}_{\mu,\Lambda}\left[\ln p(\mathbf{X}\mid\mathbf{Z},\mu,\Lambda)\right] + \mathrm{const}\\ &= \ldots = \sum_{n=1}^{N}\sum_{k=1}^{K} z_{nk}\ln\rho_{nk} + \mathrm{const},\end{aligned}$$

где $\ln\rho_{nk} = \mathrm{E}[\ln\pi_k] + \frac{1}{2}\mathrm{E}[\ln|\Lambda_k|] - \frac{D}{2}\ln(2\pi) -$

$$- \frac{1}{2}\mathrm{E}_{\mu_k,\Lambda_k}\left[(\mathbf{x}_n-\mu_k)^\top\Lambda_k(\mathbf{x}_n-\mu_k)\right].$$

- Нормируем:

$$q^*(\mathbf{Z}) = \prod_{n=1}^{N}\prod_{k=1}^{K} r_{nk}^{z_{nk}}, \text{ где } r_{nk} = \frac{\rho_{nk}}{\sum_{j=1}^{K}\rho_{nj}}.$$

Вариационное приближение

- Теперь $\mathrm{E}[z_{nk}] = r_{nk}$, т.е. r_{nk} – то, насколько точка $\mathbf{x}_n$ принадлежит кластеру k.
- Можно определить статистики с их учётом, как обычно:

$$N_k = \sum_{n=1}^{N} r_{nk},$$

$$\bar{\mathbf{x}}_k = \frac{1}{N_k} \sum_{n=1}^{N} r_{nk} \mathbf{x}_n,$$

$$S_k = \frac{1}{N_k} \sum_{n=1}^{N} r_{nk} (\mathbf{x}_n - \bar{\mathbf{x}}_k)(\mathbf{x}_n - \bar{\mathbf{x}}_k)^\top.$$

- То же самое происходило и в EM-алгоритме.

Вариационное приближение

- Теперь $q^*(\pi, \mu, \Lambda)$:

$$\ln q^*(\pi, \mu, \Lambda) = \ln p(\pi) + \sum_{k=1}^{K} \ln p(\mu_k, \Lambda_k) + \mathrm{E}_{\mathbf{Z}}[\ln p(\mathbf{Z} \mid \pi)]$$
$$+ \sum_{k=1}^{K} \sum_{n=1}^{N} \mathrm{E}[z_{nk}] \ln N(\mathbf{x}_n \mid \mu_k \Lambda_k^{-1}) + \mathrm{const}.$$

- Вот уже получилось, что $q^*(\pi, \mu, \Lambda)$ раскладывается в $q^*(\pi) q^*(\mu, \Lambda)$, опять же без предположений.
- Более того, $q^*(\mu, \Lambda) = \prod_{k=1}^{K} q(\mu_k, \Lambda_k)$.
- И теперь можно по отдельности посчитать (упражнение), получится типичный М-шаг.
- Причём распределения останутся той же формы (т.к. были сопряжённые).

Вариационное приближение

- Теперь даже model selection автоматически получается, просто у некоторых компонент $N_k \approx 0$:

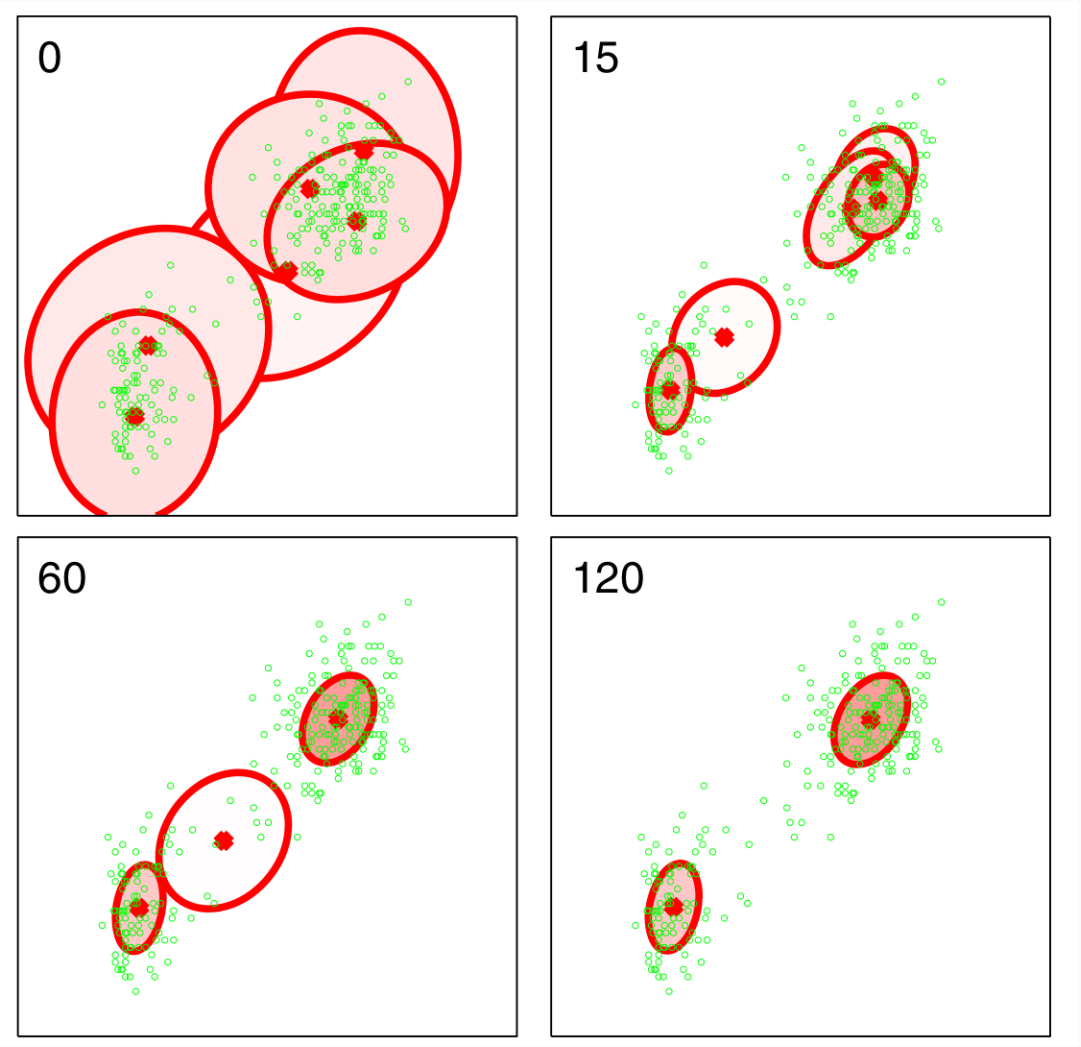

- Никакого оверфиттинга или коллапса компонент.

Другие примеры

- Есть другие примеры вариационных приближений.
- Обращение матриц; например, для линейной регрессии надо посчитать $\beta^* = C^{-1}\mathbf{b}$:

$$J(\beta) = \frac{1}{2}(\beta^* - \beta)^\top C(\beta^* - \beta) = \ldots = \text{Const} - \beta^\top \mathbf{b} + \frac{1}{2}\beta^\top C\beta,$$

  и теперь можно решать такую задачу выпуклой оптимизации.
- Метод конечных элементов – для уравнения Пуассона $-u''(x) = f(x)$, $x \in (a, b)$:

$$J(u) = \frac{1}{2}\int_a^b \left(u'(x) - u^{*\prime}(x)\right)^2 \mathrm{d}x = \ldots = \text{Const} - \int_a^b u(x)f(x)\mathrm{d}x + \frac{1}{2}\int_a^b u'(x)^2\mathrm{d}x,$$

  и если ищем в подпространстве $\tilde{u}(x) = \sum_{i=1}^k \alpha_i \phi_i(x)$, то опять

$$\tilde{J}(\alpha) = \alpha^\top \mathbf{b} + \frac{1}{2}\alpha^\top C\alpha.$$

В графических моделях

- В графических моделях – теория среднего поля (mean field theory). Пусть дано $p(\mathbf{x})$, $\mathbf{x} = (\mathbf{x}_v, \mathbf{x}_h)$, и надо найти

$$\log p(\mathbf{x}_v) = \log \sum_{\mathbf{x}_h} p(\mathbf{x}_v, \mathbf{x}_h), \quad p(\mathbf{x}_h \mid \mathbf{x}_v) = p(\mathbf{x}_h, \mathbf{x}_v)/p(\mathbf{x}_v).$$

- Опять делаем тот же трюк:

$$J(q) = \log p(\mathbf{x}_v) - \mathrm{KL}(q_{\mathbf{x}_h} \| p_{\mathbf{x}_h|\mathbf{x}_v}) = \log p(\mathbf{x}_v) - \sum_{\mathbf{x}_h} q(\mathbf{x}_h) \log \frac{q(\mathbf{x}_h)}{p(\mathbf{x}_h \mid \mathbf{x}_v)}$$

$$\ldots = H(q) + \mathbb{E}_q \left[\log p(\mathbf{x}_h, \mathbf{x}_v)\right] = H(q) + \sum_{C \in C} \sum_{\mathbf{x}_{C \cap h}} q(\mathbf{x}_{C \cap h}) \log \Psi_C(\mathbf{x}_C),$$

где $q(\mathbf{x}_{C \cap h})$ – маргинальная вероятность по скрытым переменным из клики C.

- Теория среднего поля – это когда $q(\mathbf{x}_h) = \prod_{i \in h} q_i(x_i)$.

Спасибо!

Спасибо за внимание!