

Неявный стохастический градиент

Владислав Чабаненко

Факультет ВМК
МГУ им. М. В. Ломоносова

14 ноября 2014 г.

Спецсеминар "Байесовские методы машинного обучения"

Содержание

Интуиция неявных методов

Метод стохастического градиентного спуска

Статистический анализ явного и неявного методов стохастического градиента

Эксперименты

Интуиция неявных методов

В численных методах для решения дифференциальных уравнений используются *явные* и *неявные* методы.

- ▶ Следующее приближение для *явного* метода вычисляется явно через предыдущее:

$$y_{t+1} = f(y_t)$$

- ▶ Для нахождения следующего приближения в *неявном* методе требуется решить уравнение:

$$F(y_t, y_{t+1}) = 0$$

Motivating example: метод Эйлера

- ▶ Рассмотрим задачу Коши:

$$y'(t) = f(t, y), t \geq 0, y(0) = y_0.$$

- ▶ Итерация прямого (явного) метода Эйлера:


$$y_{k+1} = y_k + h \cdot f(t_k, y_k)$$

- ▶ Итерация обратного (неявного) метода Эйлера:

$$y_{k+1} = y_k + h \cdot f(t_{k+1}, y_{k+1})$$

- ▶ h называется *шагом* метода

Motivating example: метод Эйлера



Градиентный спуск

- ▶ Пусть X — вектор реализаций случайной величины, $X_i \sim Pr(x|\theta)$.
- ▶ Наша задача — по данной выборке X оценить параметр распределения θ .
- ▶ Один из способов решения задачи — **градиентный метод**, где в качестве максимизируемого функционала выступает логарифм правдоподобия

$$\log \mathcal{L}(\theta|X) = \sum_i \log Pr(X_i|\theta) \rightarrow \max_{\theta}$$

- ▶ Итерационный процесс:

θ_0 — начальное приближение

$$\theta_t = \theta_{t-1} + \gamma_t \nabla \mathcal{L}(\theta_{t-1}|X),$$

где γ_t — шаг градиента для каждой итерации.

Стохастический градиентный спуск

- ▶ **Метод стохастического градиента** вычисляет градиент только на одном сэмпле и сразу изменяет оценку θ .
- ▶ Итерационная схема:

θ_0 – начальное приближение

получаем сэмпл x_t

$$\theta_t = \theta_{t-1} + \gamma_t \nabla_{x_t} \mathcal{L}(\theta_{t-1} | x_t),$$

- ▶ Плюсы стохастического градиента:
 - ▶ Если выборка большая, то мы можем выбирать на каждом шаге случайный элемент из выборки и считать градиент только по нему
 - ▶ Можем онлайн решать задачу оценки параметра модели, если нам подается по одному сэмплу

Неявный метод стохастического градиента

- ▶ Явный метод стохастического градиента очень чувствителен к шагу градиента
- ▶ Итерационная схема для неявного метода:

θ_0 – начальное приближение

получаем сэмпл x_t

$$\theta_t = \theta_{t-1} + \gamma_t \nabla_{x_t} \mathcal{L}(\theta_t | x_t).$$

- ▶ Далее будем сравнивать явный и неявный методы стохастического градиента

Generalized linear model

- ▶ Авторы статьи исследовали методы стохастического градиентного спуска на примере GLM
- ▶ GLM (generalized linear model) — обобщение обычной линейной регрессии на случай, если шум имеет не нормальное распределение
- ▶ Обычная линейная регрессия

$$y \sim \mathcal{N}(\theta^T x, \sigma^2)$$

- ▶ Каноническое представление распределений GLM

$$p_{\text{glm}}(y|\theta, x) = c(y, \phi) \exp\left(\frac{\theta^T x y - b(\theta^T x)}{\phi}\right),$$

ϕ — фиксированный дисперсионный параметр.

- ▶ Отметим, что распределения семейства GLM являются членами экспоненциального семейства

$$p_{\text{exp}}(y|\theta) = c(y) \exp(\theta^T u(y) - b(\theta))$$

Примеры распределений семейства GLM 1

$$p_{\text{glm}}(y|\theta, x) = c(y, \phi) \exp\left(\frac{\theta^T xy - b(\theta^T x)}{\phi}\right)$$

Семейство включает такие распределения как

- ▶ Нормальное

$$y \sim \mathcal{N}(\mu, \sigma^2)$$

Сведем его к каноническому виду:

$$\begin{aligned} p(y|\mu, \sigma^2) &= \frac{1}{\sqrt{2\pi}\sigma} \exp\left(-\frac{(y-\mu)^2}{2\sigma^2}\right) \\ &= \frac{1}{\sqrt{2\pi}\sigma} \exp\left(-\frac{y^2}{2\sigma^2}\right) \exp\left(-\frac{\mu^2}{2\sigma^2}\right) \exp\left(\frac{\mu y}{\sigma^2}\right) \\ &= \left[\frac{1}{\sqrt{2\pi}\sigma} \exp\left(-\frac{y^2}{2\sigma^2}\right) \right] \exp\left(\frac{\mu y - \mu^2/2}{\sigma^2}\right) \end{aligned}$$

Таким образом,

$$\mathbb{E}(y|\mu, \sigma^2) = \mu = \theta^T x, \phi = \sigma^2, b(\theta^T x) = (\theta^T x)^2/2.$$

Примеры распределений семейства GLM 2

$$p_{\text{glm}}(y|\theta, x) = c(y, \phi) \exp\left(\frac{\theta^T xy - b(\theta^T x)}{\phi}\right)$$

- ▶ Распределение Пуассона

$$y \sim \text{Poi}(\lambda)$$

Сведем его к каноническому виду:

$$\begin{aligned} p(y|\lambda) &= \frac{e^{-\lambda} \lambda^y}{y!} = \frac{e^{-\lambda} e^{y \log \lambda}}{y!} \\ &= \left[\frac{1}{y!} \right] \exp\left(\frac{\log \lambda y - e^{\log \lambda}}{1}\right) \end{aligned}$$

Таким образом, $\mathbb{E}(y|\lambda) = \lambda = e^{\theta^T x}$, $\phi = 1$, $b(\theta^T x) = e^{\theta^T x}$.

Примеры распределений семейства GLM 3

$$p_{\text{glm}}(y|\theta, x) = c(y, \phi) \exp\left(\frac{\theta^T xy - b(\theta^T x)}{\phi}\right)$$

- ▶ Гамма-распределение

$$y \sim \text{Ga}(\alpha, \beta),$$

$$\mathbb{E}(y|\alpha, \beta) = \frac{\alpha}{\beta} = \frac{1}{\theta^T x}, \phi = \frac{1}{\alpha}, b(\theta^T x) = -\frac{1}{(\theta^T x)^2}$$

Постановка задачи для GLM

- ▶ Нам онлайн подаются признаки $x \in \mathbb{R}^p$ и отклик $y \in \mathbb{R}$ модели. Мы хотим оценить параметр $\theta^* \in \mathbb{R}^p$ для модели.
- ▶ Будем максимизировать логарифм правдоподобия для GLM методом стохастического градиентного спуска

$$\log \mathcal{L}(\theta | Y, X) = \sum_i \left(\frac{1}{\phi} (\theta^T x_i y_i - b(\theta^T x_i)) \right) + \text{const}$$

Итерационная схема для GLM

$$\log \mathcal{L}(\theta | Y, X) = \sum_i \left(\frac{1}{\phi} (\theta^T x_i y_i - b(\theta^T x_i)) \right) + \text{const}$$

- ▶ Можно показать, что для GLM итерационная схема будет записываться в следующем виде
- ▶ Для явного метода:

$$\theta_n = \theta_{n-1} + \gamma_n (y_n - h(\theta_{n-1}^T x_n)) x_n,$$

- ▶ для неявного метода:

$$\theta_n = \theta_{n-1} + \gamma_n (y_n - h(\theta_n^T x_n)) x_n,$$

- ▶ где $h(\theta^T x) = \mathbb{E}(y | \theta, x)$, а $1/\phi$ мы внесли в шаг γ_n .
- ▶ Для канонической формы распределений семейства GLM функция $h(\cdot)$ гладкая и **монотонная**

Случай неявного пересчета 1

Требуется решить уравнение относительно θ_n

$$\theta_n = \theta_{n-1} + \gamma_n (y_n - \mathbf{h}(\theta_n^T \mathbf{x}_n)) \mathbf{x}_n,$$

- ▶ Отметим, что сложно найти θ_n в общем случае из-за того, что функция h произвольная
- ▶ К тому же θ_n — вектор, а $h(\theta_n^T \mathbf{x}_n)$ — число, и нам нужно решать уравнение одновременно для всех измерений
- ▶ На самом деле, это облегчает задачу

Случай неявного пересчета 2

Требуется решить уравнение относительно θ_n

$$\theta_n = \theta_{n-1} + \gamma_n (y_n - \mathbf{h}(\theta_n^T \mathbf{x}_n)) \mathbf{x}_n,$$

но для вычисления θ_n достаточно знать только $\mathbf{h}(\theta_n^T \mathbf{x}_n)$.

- ▶ Применим операцию транспонирования к обеим частям нашего уравнения и домножим скалярно справа на x_n :

$$\theta_n^T \mathbf{x}_n = \theta_{n-1}^T x_n + \gamma_n (y_n - \mathbf{h}(\theta_n^T \mathbf{x}_n)) \|\mathbf{x}_n\|^2$$

- ▶ Теперь к обеим частям уравнения применим функцию $h(\cdot)$ как к числу:

$$\mathbf{h}(\theta_n^T \mathbf{x}_n) = h(\theta_{n-1}^T x_n + \gamma_n (y_n - \mathbf{h}(\theta_n^T \mathbf{x}_n)) \|\mathbf{x}_n\|^2)$$

Случай неявного пересчета 3

$$\mathbf{h}(\boldsymbol{\theta}_n^T \mathbf{x}_n) = h(\boldsymbol{\theta}_{n-1}^T \mathbf{x}_n + \gamma_n(y_n - \mathbf{h}(\boldsymbol{\theta}_n^T \mathbf{x}_n))\|\mathbf{x}_n\|^2)$$

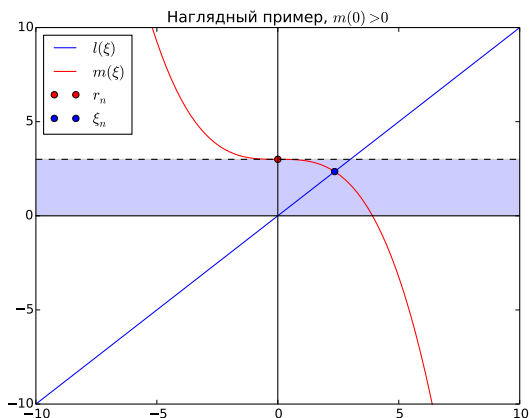
- ▶ Мы получили **одномерное** уравнение относительно $\xi_n = \mathbf{h}(\boldsymbol{\theta}_n^T \mathbf{x}_n)$:

$$\xi_n = h(\boldsymbol{\theta}_{n-1}^T \mathbf{x}_n + \gamma_n(y_n - \xi_n)\|\mathbf{x}_n\|^2)$$

- ▶ Если $h(\cdot)$ — монотонно возрастающая (как в случае нормального и пуассоновского распределений), то выражение справа будет монотонно убывать. Тогда полученное уравнение мы можем решать с помощью методов оптимизаций для одномерных уравнений (метод секущей, метод дихотомии) на некотором отрезке.
- ▶ Если $h(\cdot)$ — монотонно убывающая (например, для гамма распределения), то в общем случае не гарантируется даже существования решения. Оставим этот случай для дальнейших исследований.
- ▶ Далее будем работать с монотонно возрастающими $h(\cdot)$

Границы поиска 1

$$\xi_n = h(\theta_{n-1}^T x_n + \gamma_n(y_n - \xi_n) \|x_n\|^2)$$




$$l(\xi) = \xi, \quad m(\xi) = h(\theta_{n-1}^T x_n + \gamma_n(y_n - \xi) \|x_n\|^2)$$

$$m(0) = h(\theta_{n-1}^T x_n + \gamma_n y_n \|x_n\|^2) = r_n$$

Границы поиска 2

$$\xi_n = h(\theta_{n-1}^T x_n + \gamma_n(y_n - \xi_n) \|x_n\|^2)$$



$$l(\xi) = \xi, \quad m(\xi) = h(\theta_{n-1}^T x_n + \gamma_n(y_n - \xi) \|x_n\|^2)$$

$$m(0) = h(\theta_{n-1}^T x_n + \gamma_n y_n \|x_n\|^2) = r_n$$

Алгоритм для неявного метода

Получаем алгоритм для нахождения θ_n для неявной итерации:

for $n = 1, 2, \dots$ **do**

$$r_n \leftarrow h(\theta_{n-1}^T x_n + \gamma_n y_n \|x_n\|^2)$$

Решаем численно уравнение на отрезке $[0, r_n]$ относительно ξ_n :

$$\xi_n = h(\theta_{n-1}^T x_n + \gamma_n (y_n - \xi_n) \|x_n\|^2)$$

$$\theta_n \leftarrow \theta_{n-1} + \gamma_n (y_n - \xi_n) x_n$$

end

Теорема 1

Пусть $\gamma_n > 0$ — убывающая последовательность, такая что $\sum_{i=1}^{\infty} \gamma_i = \infty$ и $\sum_{i=1}^{\infty} \gamma_i^2 < \infty$, тогда

- ▶ смещенность явного метода стохастического градиента удовлетворяет:

$$\mathbb{E}(\theta_n^{\text{sgd}} - \theta^*) = (I - \gamma_n \phi \mathcal{I}(\theta^*)) \mathbb{E}(\theta_{n-1}^{\text{sgd}} - \theta^*) + \mathbb{E}(\mathcal{O} \|\theta_{n-1}^{\text{sgd}} - \theta^*\|^2) x_n,$$

- ▶ смещенность неявного метода стохастического градиента удовлетворяет:

$$\mathbb{E}(\theta_n^{\text{im}} - \theta^*) = (I + \gamma_n \phi \mathcal{I}(\theta^*))^{-1} (\mathbb{E}(\theta_{n-1}^{\text{im}} - \theta^*) + \mathbb{E}(\mathcal{O} \|\theta_{n-1}^{\text{im}} - \theta^*\|^2) x_n),$$

- ▶ где $\mathcal{I}(\theta^*) = \text{Cov}(\nabla_{\theta} \log \mathcal{L}(\theta^* | y, x))$ — матрица информации Фишера, **симметричная положительно определенная матрица**

Доказательство

Докажем для явного пересчета.

- ▶ Запишем итерационную формулу:

$$\theta_n = \theta_{n-1} + \gamma_n(y_n - h(\theta_{n-1}^T x_n))x_n$$

- ▶ Вычтем θ^* из обеих частей и возьмем матожидание:

$$\mathbb{E}(\theta_n - \theta^*) = \mathbb{E}(\theta_{n-1} - \theta^*) + \mathbb{E}\gamma_n y_n x_n - \mathbb{E}\gamma_n h(\theta_{n-1}^T x_n)x_n$$

$$\mathbb{E}(\theta_n - \theta^*) = \mathbb{E}(\theta_{n-1} - \theta^*) + \mathbb{E}\gamma_n h(\theta^{*T} x_n)x_n - \mathbb{E}\gamma_n h(\theta_{n-1}^T x_n)x_n$$

- ▶ Разложим $h(\theta_{n-1}^T x_n)$ по Тейлору в точке θ^* следующим образом:

$$h(\theta_{n-1}^T x_n) = h(\theta^{*T} x_n) + h'(\theta^{*T} x_n)(\theta_{n-1} - \theta^*)^T x_n + \mathcal{O}(\|\theta_{n-1} - \theta^*\|^2)$$

- ▶ Тогда равенство выше преобразуется в

$$\begin{aligned} \mathbb{E}(\theta_n - \theta^*) &= \mathbb{E}(\theta_{n-1} - \theta^*) + \mathbb{E}\gamma_n h(\theta^{*T} x_n)x_n - \mathbb{E}\gamma_n h(\theta_{n-1}^T x_n)x_n - \\ &\quad \mathbb{E}\gamma_n h'(\theta^{*T} x_n)x_n(\theta_{n-1} - \theta^*)^T x_n - \mathbb{E}(\mathcal{O}\|\theta_{n-1} - \theta^*\|^2)x_n \end{aligned}$$

Доказательство

- ▶ Упрощая выражение, получим:

$$\mathbb{E}(\theta_n - \theta^*) = (I - \gamma_n h'(\theta^{*T} x_n) x_n x_n^T) \mathbb{E}(\theta_{n-1} - \theta^*) + \mathbb{E}(\mathcal{O} \|\theta_{n-1} - \theta^*\|^2) x_n$$

- ▶ Можно показать, что

$$\mathcal{I}(\theta^*) = \frac{1}{\phi} h'(\theta^{*T} x_n) x_n x_n^T,$$

- ▶ тогда получим окончательное выражение:

$$\mathbb{E}(\theta_n - \theta^*) = (I - \gamma_n \phi \mathcal{I}(\theta^*)) \mathbb{E}(\theta_{n-1} - \theta^*) + \mathbb{E}(\mathcal{O} \|\theta_{n-1} - \theta^*\|^2) x_n$$

- ▶ Для неявного метода можно проделать аналогичные преобразования над итерационной формулой и получить требуемое равенство.

Стабильность

- ▶ Теперь исследуем методы на *стабильность*, то есть на ожидаемую смещенность оценок при малом количестве итераций.
- ▶ Упростим формулу для асимптотической смещенности из Теоремы 1, отбросив остаточный член.
- ▶ Для явного метода

$$\mathbb{E}(\theta_n^{\text{sgd}} - \theta^*) = (I - \gamma_n \phi \mathcal{I}(\theta^*)) \mathbb{E}(\theta_{n-1}^{\text{sgd}} - \theta^*) = P_1^n b_0,$$

$$P_1^n = \prod_{i=1}^n (I - \gamma_i \phi \mathcal{I}(\theta^*))$$

- ▶ Для неявного метода

$$\mathbb{E}(\theta_n^{\text{im}} - \theta^*) = (I + \gamma_n \phi \mathcal{I}(\theta^*))^{-1} (\mathbb{E}(\theta_{n-1}^{\text{im}} - \theta^*)) = Q_1^n b_0,$$

$$Q_1^n = \prod_{i=1}^n (I + \gamma_i \phi \mathcal{I}(\theta^*))^{-1}$$

- ▶ b_0 — это смещенность обоих методов для начальной оценки θ_0

Рассуждения о стабильности

$$P_1^n = \prod_{i=1}^n (I - \gamma_i \phi \mathcal{I})$$

$$Q_1^n = \prod_{i=1}^n (I + \gamma_i \phi \mathcal{I})^{-1}$$

- ▶ Оценим векторы $P_1^n b_0$ и $Q_1^n b_0$ по евклидовой норме
- ▶ P_1^n и Q_1^n — симметричные матрицы, тогда

$$\|P_1^n b_0\| \leq |\lambda|_{\max}^{P_1^n} \|b_0\|,$$

$$\|Q_1^n b_0\| \leq |\lambda|_{\max}^{Q_1^n} \|b_0\|$$

- ▶ Скорость сходимости методов зависит от $|\lambda|_{\max}^{P_1^n}$ и $|\lambda|_{\max}^{Q_1^n}$

Случай явного метода

$$P_1^n = \prod_{i=1}^n (I - \gamma_i \phi \mathcal{I})$$

- ▶ Можно показать, что $|\lambda|_{\max}^{P_1^n} = \prod_{i=1}^n |\lambda|_{\max}^{I - \gamma_i \phi \mathcal{I}}$
- ▶ Если $\gamma_1 \phi \lambda_{\max}^{\mathcal{I}} < 2$, тогда $|\lambda|_{\max}^{I - \gamma_1 \phi \mathcal{I}} < 1$ и $|\lambda|_{\max}^{P_1^n}$ убывает
- ▶ Но может быть $\gamma_1 \phi \lambda_{\max}^{\mathcal{I}} > 2$, тогда максимальным по модулю собственным значением матрицы $I - \gamma_i \phi \mathcal{I}$ на первых итерациях будет $|1 - \gamma_i \phi \lambda_{\max}^{\mathcal{I}}| > 1$, пока будет выполняться условие $\gamma_i \phi \lambda_{\max}^{\mathcal{I}} > 2$
- ▶ Тогда на этих первых итерациях отклонение оценки явного метода будет сильно возрастать

Проблемы со стабильностью явного метода

$$P_1^n = \prod_{i=1}^n (I - \gamma_i \phi \mathcal{I})$$

- ▶ В то же время на достаточно большой итерации будет выполняться $\gamma_i \phi \lambda_{\max}^{\mathcal{I}} < 1$ и $|\lambda|_{\max}^{P_1^n}$ будет соответствовать минимальным собственным значениям матриц $\gamma_i \phi \mathcal{I}$
- ▶ Значит скорость сходимости будет лучшей, когда $\gamma_i \phi \lambda_{\min}^{\mathcal{I}}$ близко к 1 $\Rightarrow \lambda_{\max}^{P_1^n}$ будет близко к 0
- ▶ В итоге получаем:
 - ▶ Для стабильности нужно, чтобы $\gamma_1 \phi \lambda_{\max}^{\mathcal{I}} < 2$
 - ▶ Для быстрой сходимости — $\gamma_i \phi \lambda_{\min}^{\mathcal{I}} \approx 1$ на достаточно больших итерациях
- ▶ Невозможно удовлетворить сразу эти оба требования
- ▶ Напротив, для неявного метода такой проблемы не возникает
- ▶ Подтвердим наши наблюдения следующей леммой

Лемма

- ▶ Пусть $\lambda_{\max} = \max \text{eig}(\phi \mathcal{I}(\theta^*))$
- ▶ Пусть $\gamma_n = \alpha/n$ и $\alpha \lambda_{\max} > 2$, тогда максимально возможное собственное значение
- ▶ матрицы P_1^n удовлетворяет:

$$\max_{n>0} \max \text{eig}(P_1^n) = \Theta \left(\frac{2^{\alpha \lambda_{\max}}}{\sqrt{\alpha \lambda_{\max}}} \right),$$

- ▶ матрицы Q_1^n неявного метода удовлетворяет:

$$\max_{n>0} \max \text{eig}(Q_1^n) < 1.$$

Докажем вспомогательное утверждение

$$M = \max_{n>0} \left| \prod_{i=1}^n \left(1 - \frac{b}{i} \right) \right| \approx \begin{cases} |1-b|, & 0 < b < 2 \\ \frac{2^b}{\sqrt{2\pi b}}, & b > 2 \end{cases}$$

- ▶ Для $0 < b < 2$ получаем $|(1-b)(1-\frac{b}{2})\dots| \leq |1-b|$.
- ▶ Теперь пусть $b > 2$. Без ограничения общности будем считать, что b — натуральное четное, тогда:

$$M = (b-1) \left(\frac{b}{2} - 1 \right) \dots \left(\frac{b}{b/2} - 1 \right) = \frac{1}{2} \frac{b!}{(b/2)!(b/2)!}$$

Вспомним формулу Стирлинга:

$$n! \approx \left(\frac{n}{e} \right)^n \sqrt{2\pi n}$$

и применим ее к нашему выражению:

$$M = \frac{1}{2} \frac{b!}{(b/2)!(b/2)!} \approx \frac{1}{2} \frac{\left(\frac{b}{e} \right)^b \sqrt{2\pi b}}{\left(\frac{b}{2e} \right)^b \pi b} = \frac{2^b}{\sqrt{2\pi b}}$$

Доказательство леммы

Вспомним выражения для матриц явного и неявного методов для смещенности.

- ▶ Для явного метода $P_1^n = \prod_{i=1}^n (I - \gamma_i \phi \mathcal{I}(\theta^*))$, тогда

$$\max_{n>0} \max \text{eig}(P_1^n) = \max_{n>0} \left| \prod_{i=1}^n \left(1 - \frac{\alpha \lambda_{\max}}{i} \right) \right| \approx \frac{2^{\alpha \lambda_{\max}}}{\sqrt{2\pi \alpha \lambda_{\max}}},$$

так как из условия теоремы $\alpha \lambda_{\max} > 2$.

- ▶ Для неявного метода $Q_1^n = \prod_{i=1}^n (I + \gamma_i \phi \mathcal{I}(\theta^*))^{-1}$, но собственные значения матриц $(I + \gamma_i \phi \mathcal{I}(\theta^*))^{-1}$ меньше единицы, следовательно

$$\max_{n>0} \max \text{eig}(Q_1^n) = \max_{n>0} \left| \prod_{i=1}^n \left(1 + \frac{\alpha \lambda_{\max}}{i} \right)^{-1} \right| < 1.$$

Итог

$$\|P_1^n b_0\| \leq |\lambda|_{\max}^{P_1^n} \|b_0\|, \quad \|Q_1^n b_0\| \leq |\lambda|_{\max}^{Q_1^n} \|b_0\|$$

Из теоремы следует, что

- ▶ в явной процедуре стохастического градиента эффект начальной смещенности экспоненциально возрастает, прежде чем начать убывать, в случае если шаг градиента $\alpha > 2/\lambda_{\max}$,
 $\lambda_{\max} = \max \text{eig}(\phi \mathcal{I}(\theta^*)),$
- ▶ неявная процедура стохастического градиента не зависит от шага градиента, и зависимость от начальной смещенности убывает при каждой следующей итерации алгоритма.

В экспериментах мы хотим проверить, что

- ▶ Если α большое ($\alpha \lambda_{\max} > 2$), то явный метод дает плохую оценку, а неявный хорошую
- ▶ Если α достаточно малое ($\alpha \lambda_{\min} \ll 1$), то оба метода медленно сходятся

Эксперимент №1

Постановка эксперимента: на примере двумерного распределения Пуассона мы

- ▶ оценим параметр модели явным и неявным методами
- ▶ убедимся в стабильности неявного метода и нестабильности явного при большом шаге градиента
- ▶ исследуем, каким должен быть шаг градиента для более надежной работы явного метода

Эксперимент №1

- ▶ Имеется модель:

$$y_n \sim \text{Poi}(e^{\theta^{*T} x_n}),$$

- ▶ Оптимизируемый функционал выглядит:

$$\log \mathcal{L}(\theta | X, Y) = \sum_i \left(\theta^T x_i y_i - e^{\theta^T x_i} \right) + \text{const}$$

- ▶ Обучать будем онлайн, получая на каждой итерации x_i, y_i . Генерировать данные будем следующим образом:
 - ▶ x_n принимает значения $(0, 0)^T, (1, 0)^T, (0, 1)^T$ с вероятностями 0.6, 0.2 и 0.2 соответственно,
 - ▶ y_n — из модели.
- ▶ Положим $\theta^* = (\log 2, \log 4)^T$
- ▶ Шаг градиента положим соответствующим случаю $\alpha \lambda_{\max} > 2$
 $\gamma_n = 10/3n, \alpha = 10/3$
- ▶ Будем выполнять $N = 20000$ итераций для $m = 100$ различных начальных оценок
- ▶ Начальные оценки будем генерировать из двумерного стандартного нормального распределения $\mathcal{N}_2(0, I)$

Эксперимент №1: Оценка параметра

Запустим оба метода. Всего у нас имеется $m = 100$ итоговых оценок параметра θ^* . Выберем несколько случайных оценок для каждого метода

- ▶ Для *явного*: $(0.709, -\mathbf{24.382})^T$, $(0.71, 1.4)^T$, $(-\mathbf{9.14}, 1.39)^T$,
 $(0.694, -\mathbf{284563.14})^T$, $(0.712, 1.386)^T$
- ▶ Для *неявного*: $(0.695, 1.384)^T$, $(0.688, 1.403)^T$, $(0.697, 1.368)^T$,
 $(0.679, 1.41)^T$, $(0.693, 1.392)^T$
- ▶ *Реальное* значение параметра: $(0.693, 1.386)^T$

Заметим сильное отклонение некоторых оценок явного метода.

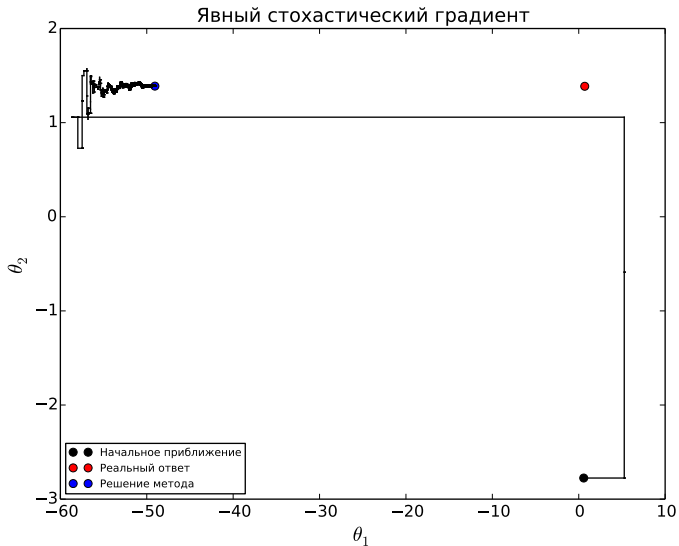


Рис. : Пример плохой сходимости явного метода




Рис. : Пример хорошей сходимости явного метода




Рис. : Неявный метод работает обычно так

Эксперимент №1: Стабильность

Сравним отклонения оценок явного и неявного методов от реального значения параметра для разных квантилей.

Метод	25%	50%	75%	85%	95%	100%
Явный	0.01	0.03	215.5	1660.3	$\approx 10^5$	$\approx 10^8$
Неявный	0.00	0.01	0.02	0.02	0.03	0.04

Таблица : Квантили для полных 20000 итераций

В таблице взяты квантили отклонений по $m = 100$ оценкам для обоих методов.

Вывод: явный метод дает оценку с погрешностью в 0.03 всего в 50% случаев, неявный метод стабилен и показывает хорошую точность в 100% случаев.

Эксперимент №1: шаг градиента 1

- ▶ Вычислим матрицу Фишера

$$\mathcal{I}(\theta^*) = \begin{pmatrix} 0.4 & 0 \\ 0 & 0.8 \end{pmatrix}$$

- ▶ Все это время мы работали с плохим шагом для явного метода. Ведь $\alpha \lambda_{\max} = 10/3 \times 8/10 = 8/3 > 2$, где $\lambda_{\max} = \max \text{eig } \mathcal{I}(\theta^*)$
- ▶ Из доказательства Леммы можно предположить, что если $\alpha \lambda_{\max} < 2$, то явный метод будет получать близкие к реальному значению параметра оценки. Проверим, так ли это
- ▶ Рассмотрим $\alpha = \frac{10}{3}, \frac{10}{5}, \frac{10}{7}, 1$
- ▶ Еще проверим, будет ли явный метод работать лучше при очень малых α

Эксперимент №1: шаг градиента 2

Здесь $10/3 \times \lambda_{\max} = 8/3 > 2$, а $10/5 \times \lambda_{\max} = 8/5 < 2$

Метод	25%	50%	75%	85%	95%	100%
Явный	0.01	0.03	215.5	1660.3	$\approx 10^5$	$\approx 10^8$
Неявный	0.00	0.01	0.02	0.02	0.03	0.04

Таблица : $\alpha = 10/3$

Метод	25%	50%	75%	85%	95%	100%
Явный	0.01	0.02	0.06	36.6	143.9	$\approx 10^5$
Неявный	0.01	0.01	0.02	0.02	0.03	0.04

Таблица : $\alpha = 10/5$

Видим, что для меньшего шага явный метод дает теперь хорошую точность в 75% случаях, но все же не всегда. Неявный метод стабилен.

Эксперимент №1: шаг градиента 3

Здесь $10/5 \times \lambda_{\max} = 8/5 < 2$, $10/7 \times \lambda_{\max} = 8/7 < 2$

Метод	25%	50%	75%	85%	95%	100%
Явный	0.01	0.02	0.06	36.6	143.9	$\approx 10^5$
Неявный	0.01	0.01	0.02	0.02	0.03	0.04

Таблица : $\alpha = 10/5$

Метод	25%	50%	75%	85%	95%	100%
Явный	0.01	0.02	0.07	0.4	130.1	$\approx 10^3$
Неявный	0.01	0.02	0.03	0.04	0.07	0.1

Таблица : $\alpha = 10/7$

При шаге $\alpha = 10/7$ у явного метода неплохая точность получается уже с вероятностью 85%. Заметим, что неявный метод стал давать оценку чуть хуже, чем раньше.

Эксперимент №1: шаг градиента 4

Здесь $10/7 \times \lambda_{\max} = 8/7 > 1$, $1 \times \lambda_{\max} = 8/10 < 1$

Метод	25%	50%	75%	85%	95%	100%
Явный	0.01	0.02	0.07	0.4	130.1	$\approx 10^3$
Неявный	0.01	0.02	0.03	0.04	0.07	0.1

Таблица : $\alpha = 10/7$

Метод	25%	50%	75%	85%	95%	100%
Явный	0.02	0.04	0.1	0.18	2.9	76.8
Неявный	0.02	0.03	0.07	0.1	0.27	0.82

Таблица : $\alpha = 1$

При шаге $\alpha = 1$ в принципе явный метод с большой вероятностью хорошо оценит наш параметр θ^* . И опять заметим, что неявный метода стал давать еще хуже оценку, чем раньше.

Эксперимент №1: шаг градиента 5

Что будет, если взять α еще меньше?

Метод	25%	50%	75%	85%	95%	100%
Явный	0.02	0.04	0.1	0.18	2.9	76.8
Неявный	0.02	0.03	0.07	0.1	0.27	0.82

Таблица : $\alpha = 1$

Метод	25%	50%	75%	85%	95%	100%
Явный	0.80	1.20	1.85	2.10	2.76	3.42
Неявный	0.82	1.22	1.85	2.09	2.76	3.42

Таблица : $\alpha = 1/10$

Видим, что при $\alpha = 1/10$ методы сравнялись по точности. Шаг стал очень маленьким, и теперь оба метода медленно сходятся, им не хватает 20 тысяч итераций.

Отметим, что явный метод теперь в 100% случаев дает хоть и не точную оценку, но более близкую, чем могла быть при больших α .

Эксперимент №2

Постановка эксперимента: на примере многомерного нормального распределения мы

- ▶ оценим параметр модели явным и неявным методами
- ▶ исследуем отклонения оценок обоих методов при различных параметрах α
- ▶ убедимся, что неявный метод работает надежно при больших α , в то время как явный — сильно расходится
- ▶ покажем, что неявный метод дает меньшую дисперсию оценки с итерациями, чем явный

Эксперимент №2

- ▶ Имеется модель многомерного нормального распределения
- ▶ Оптимизируемый функционал имеет следующий вид:

$$\log \mathcal{L}(\theta|X, Y) = \sum_i (\theta^T x_i y_i - \theta^T x_i) + \text{const}$$

- ▶ Оптимизацию будем производить онлайн, на каждой итерации получая x_i, y_i . Генерировать их будем следующим образом:
 - ▶ $x_n \sim \mathcal{N}_p(0, V_x)$, где V_x — матрица ковариации такая, что ее собственные значения равномерно распределены на отрезке $[0.2, 1]$, а ее максимальное собственное значение порядка размера пространства: $\lambda_{\max}^{V_x} = 0.1p$
 - ▶ $y_n \sim \mathcal{N}(\theta^{*T} x_n, 1)$
- ▶ Положим $\theta^* = (1, 1, \dots, 1)^T, p = 20$
- ▶ Будем выполнять $N = 1000$ итераций для $m = 2000$ одинаковых начальных оценок
- ▶ Сразу отметим, что в нашем случае $\mathcal{I}(\theta^*) = V_x$

Эксперимент №2: оценка параметров

Запустим методы для $\alpha = 4/9$ (отметим, что $\alpha\lambda_{\max} < 1$) и получим $m = 2000$ оценок для каждого метода. Возьмем несколько оценок для первых 10 параметров (из 20)

- ▶ Для неявного метода:
(0.98 1.03 1.01 0.98 0.88 1.02 0.97 0.99 1.12 1.10),
(1.00 0.96 0.99 1.07 1.00 0.99 1.05 1.03 0.99 1.01),
(1.01 1.07 0.89 0.91 1.04 0.99 1.01 1.00 0.91 0.94)
- ▶ Для явного метода:
(0.86 **2.63** **2.24** 1.04 0.94 0.72 **2.06** 1.37 1.70 **2.21**),
(1.01 1.10 1.15 0.97 0.96 1.01 0.93 1.01 0.86 1.00),
(1.05 0.28 0.80 **-0.72** 0.78 0.85 0.61 0.13 0.64 0.61)
- ▶ Реальные значения:
(1.00 1.00 1.00 1.00 1.00 1.00 1.00 1.00 1.00 1.00)

Видно, что явный метод дает хуже результаты, чем неявный.

Эксперимент №2: визуализируем по итерациям




Рис. : Квантили 2% и 95% логарифмов отклонений

Рассмотрим получше предыдущий график




Рис. : Заметим возрастание 95% квантилей на первых итерациях

Попробуем меньшее $\alpha = 1/20$




Рис. : Квантили 2% и 95% логарифмов отклонений

Еще раз убеждаемся, что для малых α методы показывают похожие результаты.

Эксперимент №2: различные шаги градиента

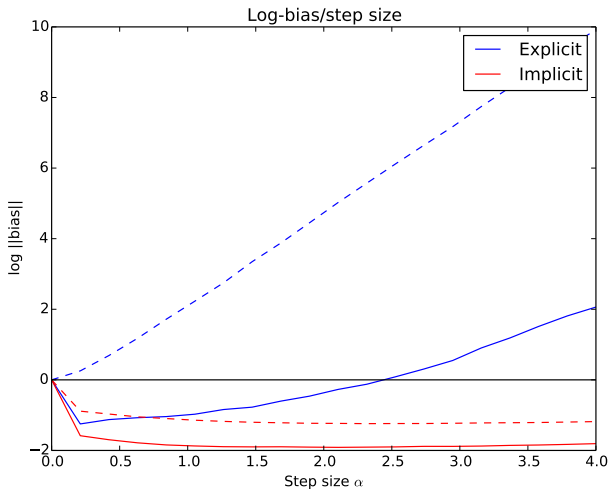


Рис. : Квантили 2% и 95% логарифмов отклонений при $\alpha = 4k/19, k = 0..19$

Эксперимент №2: Надежность

Покажем, что неявный метод дает более надежную оценку. То есть дисперсия оценок неявного метода с итерациями получается меньше, чем для явного.

Для этого будем на каждой итерации вычислять след матрицы ковариаций полученных оценок для обоих методов.








Рис. : Неявный метод показывает меньший разброс оценок

Литература

-  Panos Toulis, Edoardo M. Airolidi, "Statistical analysis of stochastic gradient methods for generalized linear models" , ICML, Beijing China, 2014
-  Robbins & Monro, "A Stochastic Approximation Method" , 1951
-  Nelder and Wedderbur "Generalized linear models" , 1972
-  Harold Kushner "Stochastic Approximation: A Survey" , Brown University, 2008