

Alternating Direction Method of Multipliers (ADMM)

Илья Трофимов

13.10.2016

Машинное обучение и большие данные
ФИБТ, осень 2016

Задача условной оптимизации

$$x^* = \underset{x}{\operatorname{argmin}} f(x)$$

при ограничении $Ax = b$

$$x \in \mathbb{R}^n, A \in \mathbb{R}^{p \times n}, b \in \mathbb{R}^p$$

Задача условной оптимизации

$$x^* = \underset{x}{\operatorname{argmin}} f(x)$$

при ограничении $Ax = b$

$$x \in \mathbb{R}^n, A \in \mathbb{R}^{p \times n}, b \in \mathbb{R}^p$$

Построим Лагранжиан

$$L(x, y) = f(x) + y^T (Ax - b)$$

$y \in \mathbb{R}^p$ - множители Лагранжа

Двойственная задача

$$y^* = \operatorname{argmax}_y g(y)$$

$$g(y) = \inf_x L(x, y)$$

Двойственная задача

$$y^* = \operatorname{argmax}_y g(y)$$

$$g(y) = \inf_x L(x, y)$$

Условная оптимизация сводится к безусловной

$$x^* = \operatorname{argmin}_x L(x, y^*)$$

Dual Ascent

Идея: делать шаги по градиенту u

Dual Ascent

Идея: делать шаги по градиенту y

$$x^+(y) = \operatorname{argmin}_x L(x, y)$$

$$g(y) = L(x^+(y), y)$$

$$\begin{aligned}\nabla g(y) &= \frac{\partial L}{\partial x}(x^+(y), y) \frac{dx^+}{dy} & + & \frac{\partial L}{\partial y}(x^+(y), y) \\ &= 0 & + & Ax^+(y) - b \\ &= Ax^+(y) - b\end{aligned}$$

Dual Ascent

Идея: делать шаги по градиенту y

$$x^+(y) = \operatorname{argmin}_x L(x, y)$$

$$g(y) = L(x^+(y), y)$$

$$\begin{aligned}\nabla g(y) &= \frac{\partial L}{\partial x}(x^+(y), y) \frac{dx^+}{dy} &+& \frac{\partial L}{\partial y}(x^+(y), y) \\ &= 0 &+& Ax^+(y) - b \\ &= Ax^+(y) - b\end{aligned}$$

Итерация алгоритма Dual Ascent:

$$x^{k+1} \leftarrow \operatorname{argmin}_x L(x, y^k)$$

$$y^{k+1} \leftarrow y^k + \alpha_k (Ax^{k+1} - b)$$

Dual Decomposition

Если $f(\cdot)$ сепарабельная

$$f(x) = \sum_{i=1}^N f_i(x_i), \quad x = (x_1, \dots, x_N)$$

то Лагранжиан тоже сепарабелен

$$L(x, y) = \sum_{i=1}^N L(x_i, y) - y^T b$$

$$L_i(x_i, y) = \sum_{i=1}^N f_i(x_i) + y^T (A_i x_i - b)$$

Dual Decomposition

Если $f(\cdot)$ сепарабельная

$$f(x) = \sum_{i=1}^N f_i(x_i), \quad x = (x_1, \dots, x_N)$$

то Лагранжиан тоже сепарабелен

$$L(x, y) = \sum_{i=1}^N L(x_i, y) - y^T b$$

$$L_i(x_i, y) = \sum_{i=1}^N f_i(x_i) + y^T (A_i x_i - b)$$

Итерация алгоритма Dual decomposition:

$$x_i^{k+1} \leftarrow \underset{x_i}{\operatorname{argmin}} L_i(x_i, y^k), \quad i = 1, \dots, N$$

$$y^{k+1} \leftarrow y^k + \alpha_k \left(\sum_{i=1}^N A_i x_i^{k+1} - b \right)$$

Method of Multipliers

На практике лучше работает обобщенный Лагранжиан

$$L_{\rho}(x, y) = f(x) + y^T(Ax - b) + (\rho/2)\|Ax - b\|^2$$

Method of Multipliers

На практике лучше работает обобщенный Лагранжиан

$$L_{\rho}(x, y) = f(x) + y^T(Ax - b) + (\rho/2)\|Ax - b\|^2$$

Который является "обычным Лагранжианом" для задачи

$$x^* = \underset{x}{\operatorname{argmin}} (f(x) + (\rho/2)\|Ax - b\|^2)$$

при ограничении $Ax = b$

$$x \in \mathbb{R}^n, A \in \mathbb{R}^{p \times n}, b \in \mathbb{R}^p$$

Method of Multipliers

На практике лучше работает обобщенный Лагранжиан

$$L_\rho(x, y) = f(x) + y^T(Ax - b) + (\rho/2)\|Ax - b\|^2$$

Который является "обычным Лагранжианом" для задачи

$$x^* = \underset{x}{\operatorname{argmin}} (f(x) + (\rho/2)\|Ax - b\|^2)$$

при ограничении $Ax = b$

$$x \in \mathbb{R}^n, A \in \mathbb{R}^{p \times n}, b \in \mathbb{R}^p$$

Итерация алгоритма Method of Multipliers:

$$x^{k+1} \leftarrow \underset{x}{\operatorname{argmin}} L_\rho(x, y^k)$$

$$y^{k+1} \leftarrow y^k + \rho(Ax^{k+1} - b)$$

Почему $\alpha_k = \rho$?

Method of Multipliers

Почему $\alpha_k = \rho$?

Для решения (x^*, y^*) должно выполняться

$$Ax^* - b = 0 \quad \nabla f(x^*) + A^T y^* = 0$$

Method of Multipliers

Почему $\alpha_k = \rho$?

Для решения (x^*, y^*) должно выполняться

$$Ax^* - b = 0 \quad \nabla f(x^*) + A^T y^* = 0$$

$$\begin{aligned} 0 &= \nabla_x L_\rho(x^{k+1}, y^k) \\ &= \nabla f(x^{k+1}) + A^T(y^k + \rho(Ax^{k+1} - b)) \\ &= \nabla f(x^{k+1}) + A^T y^{k+1} \end{aligned}$$

Задача условной оптимизации

$$\operatorname{argmin}_{x,z} (f(x) + g(z))$$

при ограничении $Ax + Bz = c$

$$x \in \mathbb{R}^n, z \in \mathbb{R}^m, A \in \mathbb{R}^{p \times n}, B \in \mathbb{R}^{p \times m}, c \in \mathbb{R}^p$$

Построим обобщенный Лагранжиан

$$L_\rho(x, z, y) = f(x) + g(z) + y^T (Ax + Bz - c) + (\rho/2) \|Ax + Bz - c\|^2$$

$y \in \mathbb{R}^p$ - множители Лагранжа

Итерация алгоритма ADMM:

$$x^{k+1} \leftarrow \underset{x}{\operatorname{argmin}} L_\rho(x, z^k, y^k)$$

$$z^{k+1} \leftarrow \underset{z}{\operatorname{argmin}} L_\rho(x^{k+1}, z, y^k)$$

$$y^{k+1} \leftarrow y^k + \rho(Ax^{k+1} + Bz^{k+1} - c)$$

Нормированная форма ADMM

Введем обозначение для невязки $r = Ax + Bz - c$

$$\begin{aligned} y^T + (\rho/2)\|r\|^2 &= (\rho/2)\|r + (1/\rho)y\|^2 - (1/2\rho)\|y\|^2 \\ &= (\rho/2)\|r + u\|^2 - (\rho/2)\|u\|^2 \end{aligned}$$

где $u = (1/\rho)y$ - нормированный множитель Лагранжа

Нормированная форма ADMM

Введем обозначение для невязки $r = Ax + Bz - c$

$$\begin{aligned} y^T + (\rho/2)\|r\|^2 &= (\rho/2)\|r + (1/\rho)y\|^2 - (1/2\rho)\|y\|^2 \\ &= (\rho/2)\|r + u\|^2 - (\rho/2)\|u\|^2 \end{aligned}$$

где $u = (1/\rho)y$ - нормированный множитель Лагранжа

Итерация алгоритма ADMM, нормированная форма:

$$\begin{aligned} x^{k+1} &\leftarrow \operatorname{argmin}_x \left(f(x) + (\rho/2)\|Ax + Bz^k - c + u^k\|^2 \right) \\ z^{k+1} &\leftarrow \operatorname{argmin}_z \left(g(z) + (\rho/2)\|Ax^{k+1} + Bz - c + u^k\|^2 \right) \\ u^{k+1} &\leftarrow u^k + Ax^{k+1} + Bz^{k+1} - c \end{aligned}$$

Сходимость ADMM

При выполнении условий:

- 1 Функции f , g - собственные выпуклые функции, а также для каждого $\alpha \in \mathbb{R}$, множество $\{x \in \text{dom}(f) \mid f(x) \leq \alpha\}$ замкнуто
- 2 У Лагранжиана существует седловая точка
$$L_0(x^*, z^*, y) \leq L_0(x^*, z^*, y^*) \leq L_0(x, z, y^*)$$

Можно доказать результаты про сходимость:

- 1 Невязка стремится к нулю $r^k \rightarrow 0$
- 2 Целевая функции стремится к минимуму $f(x^k) + g(z^k) \rightarrow \min$
- 3 Двойственная переменная сходится $y^k \rightarrow y^*$

Пример. Условная оптимизация

$$x^* = \operatorname{argmin}_x f(x)$$

при ограничении $x \in \mathcal{C}$

Пример. Условная оптимизация

$$x^* = \operatorname{argmin}_x f(x)$$

при ограничении $x \in \mathcal{C}$

Индикаторная функция множества $\mathcal{C}$:

$$g(x) = 0, \text{ если } x \in \mathcal{C}, \text{ иначе } +\infty$$

Пример. Условная оптимизация

Итерация алгоритма ADMM, нормированная форма:

$$x^{k+1} \leftarrow \underset{x}{\operatorname{argmin}} \left(f(x) + (\rho/2) \|x - z^k + u^k\|^2 \right)$$

$$z^{k+1} \leftarrow \underset{z}{\operatorname{argmin}} \left(g(z) + (\rho/2) \|x^{k+1} - z + u^k\|^2 \right)$$

$$u^{k+1} \leftarrow u^k + x^{k+1} - z^{k+1}$$

Итерация алгоритма ADMM, нормированная форма:

$$x^{k+1} \leftarrow \operatorname{argmin}_x \left(f(x) + (\rho/2) \|x - z^k + u^k\|^2 \right)$$

$$z^{k+1} \leftarrow \operatorname{argmin}_z \left(g(z) + (\rho/2) \|x^{k+1} - z + u^k\|^2 \right)$$

$$u^{k+1} \leftarrow u^k + x^{k+1} - z^{k+1}$$

$$x^{k+1} \leftarrow \operatorname{argmin}_x \left(f(x) + (\rho/2) \|x - z^k + u^k\|^2 \right)$$

$$z^{k+1} \leftarrow \Pi_C(x^{k+1} + u^k) \quad /* \text{ операция проектирования } */$$

$$u^{k+1} \leftarrow u^k + x^{k+1} - z^{k+1}$$

Пример. Отбор признаков

$$x^* = \operatorname{argmin}_x \|Ax - b\|^2$$

при ограничении $\operatorname{card}(x) \leq c$

где $\operatorname{card}(x)$ - кол-во ненулевых компонент x .

Пример. Отбор признаков

$$x^* = \underset{x}{\operatorname{argmin}} \|Ax - b\|^2$$

при ограничении $\operatorname{card}(x) \leq c$

где $\operatorname{card}(x)$ - кол-во ненулевых компонент x .

$$x^{k+1} \leftarrow (A^T A + \rho I)^{-1} (A^T b + \rho(z^k - u^k))$$

$$z^{k+1} \leftarrow \Pi_C(x^{k+1} + u^k)$$

$$u^{k+1} \leftarrow u^k + x^{k+1} - z^{k+1}$$

Часто целевая функция аддитивна и состоит из нескольких компонент:

$$f(x) = \sum_{i=1}^N f_i(x)$$

Часто целевая функция аддитивна и состоит из нескольких компонент:

$$f(x) = \sum_{i=1}^N f_i(x)$$

Пример: функции эмпирического риска в машинном обучении

минимизировать по x, z
$$f(x) = \sum_{i=1}^N f_i(x_i)$$

при ограничениях $x_i - z = 0, \quad i = 1, \dots, N$

$$L_{\rho}(x_1, \dots, x_N, z, y) = \sum_{i=1}^N \left(f_i(x_i) + y_i^T (x_i - z) + \rho/2 \|x_i - z\|^2 \right)$$

Алгоритм:

$$x_i^{k+1} \leftarrow \underset{x_i}{\operatorname{argmin}} \left(f_i(x_i) + \rho/2 \|x_i - \bar{x}^k - (1/\rho)y_i^k\|^2 \right) \quad (1)$$

$$y_i^{k+1} \leftarrow y_i^k + \rho(x_i^{k+1} - \bar{x}^{k+1}) \quad (2)$$

$$z^{k+1} \leftarrow \bar{x}^{k+1} + (1/\rho)\bar{y}^k \quad (3)$$

где $\bar{x}^k = \sum_{i=1}^N x_i$, $\bar{y}^k = \sum_{i=1}^N y_i$

$$L_{\rho}(x_1, \dots, x_N, z, y) = \sum_{i=1}^N \left(f_i(x_i) + y_i^T (x_i - z) + \rho/2 \|x_i - z\|^2 \right)$$

Алгоритм:

$$x_i^{k+1} \leftarrow \underset{x_i}{\operatorname{argmin}} \left(f_i(x_i) + \rho/2 \|x_i - \bar{x}^k - (1/\rho)y_i^k\|^2 \right) \quad (1)$$

$$y_i^{k+1} \leftarrow y_i^k + \rho(x_i^{k+1} - \bar{x}^{k+1}) \quad (2)$$

$$z^{k+1} \leftarrow \bar{x}^{k+1} + (1/\rho)\bar{y}^k \quad (3)$$

где $\bar{x}^k = \sum_{i=1}^N x_i$, $\bar{y}^k = \sum_{i=1}^N y_i$

Шаги (1) и (2) **распараллеливаются**.

Пример:

Пример: многие функции эмпирического риска в машинном обучении

$$\begin{array}{ll} \text{минимизировать} & f(x) = \sum_{i=1}^N f_i(x_i) + g(z) \\ \text{при ограничениях} & x_i - z = 0, \quad i = 1, \dots, N \end{array}$$

Consensus + regularization

Пример: многие функции эмпирического риска в машинном обучении

$$\text{минимизировать} \quad f(x) = \sum_{i=1}^N f_i(x_i) + g(z)$$

$$\text{при ограничениях} \quad x_i - z = 0, \quad i = 1, \dots, N$$

$f_i(x_i)$ - эмпирический риск по обучающим примерам, лежащим на машине i

$g(z)$ - регуляризация

Алгоритм:

$$x_i^{k+1} \leftarrow \underset{x_i}{\operatorname{argmin}} \left(f_i(x_i) + \rho/2 \|x_i - z^k - (1/\rho)y_i^k\|^2 \right)$$

$$z^{k+1} \leftarrow \underset{z}{\operatorname{argmin}} \left(g(z) + \sum_{i=1}^N \left(-(y_i^k)^T z + (\rho/2) \|x_i^{k+1} - z\|^2 \right) \right)$$

$$y_i^{k+1} \leftarrow y_i^k + \rho(x_i^{k+1} - z^{k+1})$$

минимизировать $\sum_{i=1}^N f_i(x_i) + g(\sum_{i=1}^N x_i)$

где $x_i \in \mathbb{R}^n$.

$g(\cdot)$ - общая целевая функция

$f(\cdot)$ - индивидуальные штрафы

минимизировать
$$\sum_{i=1}^N f_i(x_i) + g\left(\sum_{i=1}^N x_i\right)$$

где $x_i \in \mathbb{R}^n$.

$g(\cdot)$ - общая целевая функция

$f(\cdot)$ - индивидуальные штрафы

В форме ADMM

минимизировать
$$\sum_{i=1}^N f_i(x_i) + g\left(\sum_{i=1}^N z_i\right)$$

при ограничениях $x_i - z_i = 0, \quad i = 1, \dots, N$

где $x_i \in \mathbb{R}^n, z_i \in \mathbb{R}^n$

Зачем это все нужно?

Зачем это все нужно?

Если размерность x велика, то

$$x = (1, \dots, 2, 7, \dots, 1, 3, \dots, 9)$$

$$x_1 = (1, \dots, 2, 0, \dots, 0, 0, \dots, 0)$$

$$x_2 = (0, \dots, 0, 7, \dots, 1, 0, \dots, 0)$$

$$x_3 = (0, \dots, 0, 0, \dots, 0, 3, \dots, 9)$$

$$x = x_1 + x_2 + x_3$$

Зачем это все нужно?

Если размерность x велика, то

$$x = (1, \dots, 2, 7, \dots, 1, 3, \dots, 9)$$

$$x_1 = (1, \dots, 2, 0, \dots, 0, 0, \dots, 0)$$

$$x_2 = (0, \dots, 0, 7, \dots, 1, 0, \dots, 0)$$

$$x_3 = (0, \dots, 0, 0, \dots, 0, 3, \dots, 9)$$

$$x = x_1 + x_2 + x_3$$

$g(x)$ - эмпирический риск

$f_i(x_i)$ - регуляризатор по подмножеству переменных
(блочно-сепарабельный)

Например: $f_i(x_i) = \lambda \|x_i\|_p$

$$x_i^{k+1} \leftarrow \underset{x_i}{\operatorname{argmin}} \left(f_i(x_i) + (\rho/2) \|x_i - z_i^k + u_i^k\|^2 \right)$$

$$z_i^{k+1} \leftarrow \underset{z}{\operatorname{argmin}} \left(g\left(\sum_{i=1}^N z_i\right) + (\rho/2) \sum_{i=1}^N \|z_i - u_i^k - x_i^{k+1}\|^2 \right)$$

$$u_i^{k+1} \leftarrow u_i^k + x_i^{k+1} - z_i^{k+1}$$

Задача ADMM в постановке sharing является двойственной к consensus

Разделение обучающей выборки

- По обучающим примерам - consensus

Разделение обучающей выборки

- По обучающим примерам - consensus
- По переменным - sharing

Разделение обучающей выборки

- По обучающим примерам - consensus
- По переменным - sharing
- Одновременно по примерам и переменным (Parikh, Boyd, 2011).

Применения для задач машинного обучения:

- Линейная регрессия с L1/L2 регуляризацией
- Логистическая регрессия с L1/L2 регуляризацией
- Линейный SVM
- Group LASSO
- Graphical LASSO
- Можно применять для невыпуклых целевых функций (сходимость не гарантирована). Например, для non-negative matrix factorization

На **скорость сходимости** существенно влияет параметр ρ .

Варианты:

- 1 Подобрать оптимальное ρ , сделав несколько итераций
- 2 Адаптивно менять ρ в зависимости от невязки (можно доказать сверхлинейную сходимость, если $\rho^k \rightarrow +\infty$)
- 3 $\rho = 1$ часто работает неплохо

На **скорость сходимости** существенно влияет параметр ρ .

Варианты:

- 1 Подобрать оптимальное ρ , сделав несколько итераций
- 2 Адаптивно менять ρ в зависимости от невязки (можно доказать сверхлинейную сходимость, если $\rho^k \rightarrow +\infty$)
- 3 $\rho = 1$ часто работает неплохо

Алгоритм ADMM обладает неплохой начальной сходимостью, но медленно сходится к точному решению. В машинном обучении нам нужно не найти минимум целевой функции с точность 10^{-6} , а чтобы качество прогноза на тесте было высоким. Так что **ОК**.

Реализация ADMM на MPI

Algorithm 1 Global consensus ADMM in MPI.

initialize N processes, along with x_i, u_i, r_i, z .

repeat

1. Update $u_i := u_i + x_i - z$.
 2. Update $x_i := \operatorname{argmin}_x (f_i(x) + (\rho/2)\|x - z + u_i\|_2^2)$.
 3. Let $w := x_i + u_i$ and $t := \|r_i\|_2^2$.
 4. *Allreduce* w and t .
 5. Let $z^{\text{prev}} := z$ and update $z := \operatorname{prox}_{g, N\rho}(w/N)$.
 6. **exit if** $\rho\sqrt{N}\|z - z^{\text{prev}}\|_2 \leq \epsilon^{\text{conv}}$ and $\sqrt{t} \leq \epsilon^{\text{feas}}$.
 7. Update $r_i := x_i - z$.
-

Algorithm 2 An iteration of global consensus ADMM in Hadoop/ MapReduce.

function map(key i , dataset $\mathcal{D}_i$)

1. Read $(x_i, u_i, \hat{z})$ from HBase table.
2. Compute $z := \mathbf{prox}_{g, N\rho}((1/N)\hat{z})$.
3. Update $u_i := u_i + x_i - z$.
4. Update $x_i := \operatorname{argmin}_x (f_i(x) + (\rho/2)\|x - z + u_i\|_2^2)$.
5. *Emit* (key CENTRAL, record (x_i, u_i)).

function reduce(key CENTRAL, records $(x_1, u_1), \dots, (x_N, u_N)$)


1. Update $\hat{z} := \sum_{i=1}^N x_i + u_i$.
2. *Emit* (key j , record $(x_j, u_j, \hat{z})$) to HBase for $j = 1, \dots, N$.

Пример


Логистическая регрессия с L1-регуляризацией. Sharing + MPI.

Датасет "epsilon"

0.4×10^6 примеров, 2000 признаков, $N = 16$, $size = 16Gb$



Пример



- ADMM** S. Boyd, N. Parikh, E. Chu, B. Peleato, J. Eckstein.
Distributed Optimization and Statistical Learning via the
Alternating Direction Method of Multipliers, 2011.
- Block** Parikh, N., Boyd, S. (2011). Block Splitting for Large-Scale
Distributed Learning. Neural Information Processing Systems
(NIPS) Workshop on Big Learning.