

普通の勾配法

$$\min f(\mathbf{x}) \quad \nabla = \left(\frac{\partial}{\partial x_1}, \frac{\partial}{\partial x_2}, \dots, \frac{\partial}{\partial x_n} \right)^T$$

更新式 $\mathbf{x}^{k+1} \leftarrow \mathbf{x}^k - \alpha \nabla f(\mathbf{x}^k)$

\uparrow
学習率

右辺 $\mathbf{x}^k - \alpha \nabla f(\mathbf{x}^k)$ は次のように書き直せる。

$$\mathbf{x}^k - \nabla f(\mathbf{x}^k) = \underset{\mathbf{x}}{\operatorname{argmin}} Q(\mathbf{x}, \mathbf{x}^k)$$

ここで関数 $Q(\mathbf{x}, \mathbf{x}^k)$ は次で定義する。

$$Q(\mathbf{x}, \mathbf{x}^k) = f(\mathbf{x}^k) + \underbrace{\langle \nabla f(\mathbf{x}^k), \mathbf{x} - \mathbf{x}^k \rangle}_{f(\mathbf{x}) の \mathbf{x} = \mathbf{x}^k まわり の 1 次展開} + \frac{1}{2\alpha} \underbrace{\|\mathbf{x} - \mathbf{x}^k\|_2^2}_{\text{正則化}}$$

つまり、 $f(\mathbf{x}^k)$ の最適化のために、各行列ーションで関数 $Q(\mathbf{x}, \mathbf{x}^k)$ を最適化している。

このことは、 $\nabla Q(\mathbf{x}, \mathbf{x}^k) = 0$ を \mathbf{x} について解くと更新式 $\mathbf{x}^{k+1} \leftarrow \mathbf{x}^k - \nabla f(\mathbf{x}^k)$ が得られることが確実である。

$$\nabla Q(\mathbf{x}, \mathbf{x}^k)$$

$$= \nabla \left\{ f(\mathbf{x}^k) + \langle \nabla f(\mathbf{x}^k), \mathbf{x} - \mathbf{x}^k \rangle + \frac{1}{2\alpha} \| \mathbf{x} - \mathbf{x}^k \|_2^2 \right\}$$

$$= \nabla \langle f(\mathbf{x}^k), \mathbf{x} \rangle + \frac{1}{\alpha} (\mathbf{x} - \mathbf{x}^k)$$

$$= \nabla f(\mathbf{x}^k) + \frac{1}{\alpha} (\mathbf{x} - \mathbf{x}^k)$$

これを \mathbf{x} について解いて

$$\mathbf{x} = \mathbf{x}^k - \alpha \nabla f(\mathbf{x}^k)$$


鏡像下降法は、 $\|x - x^k\|_2^2$ を
Bregman divergence に置き換えたもの。

1. Bregman divergence とは。

任意の凸関数 $\phi(x)$ は、定義から

$$\phi(x) \geq \phi(y) + \underbrace{\langle \nabla \phi(y), x - y \rangle}_{y \text{ の接線の傾き}}$$

を満たす。つまり、任意の点 y の接線よりも常に上側に値がある。



凸関数 ϕ の Bregman divergence B_ϕ は.

$$B_\phi(x, y) = \phi(x) - \phi(y) - \langle \nabla \phi(y), x - y \rangle$$

で定義する.

例. $\phi(x) = \sum_i x_i \log x_i$ とすると

$B_\phi(x, y)$ は、KL 情報量となる.

2. 鏡像降下法

普通の勾配法の $\|x - x^k\|_2^2$ を

$B_\phi(x, x^k)$ で置き換えて、更新式を得る。

$$\mathbf{x}^{k+1}$$

$$= \operatorname{argmin}_{\mathbf{x}} \left\{ f(\mathbf{x}^k) + \langle \nabla f(\mathbf{x}^k), \mathbf{x} - \mathbf{x}^k \rangle + \frac{1}{\alpha} B \phi(\mathbf{x}, \mathbf{x}^k) \right\}$$

$$= \operatorname{argmin}_{\mathbf{x}} \left\{ f(\mathbf{x}^k) + \langle \nabla f(\mathbf{x}^k), \mathbf{x} - \mathbf{x}^k \rangle \right.$$

$$\left. + \frac{1}{\alpha} (\phi(\mathbf{x}) - \phi(\mathbf{x}^k) - \langle \nabla \phi(\mathbf{x}^k), \mathbf{x} \rangle) \right\}$$

$$= \operatorname{argmin}_{\mathbf{x}} \left\{ \langle \nabla f(\mathbf{x}^k), \mathbf{x} \rangle + \frac{1}{\alpha} (\phi(\mathbf{x}) - \langle \nabla \phi(\mathbf{x}^k), \mathbf{x} \rangle) \right\}$$

$$= \operatorname{argmin}_{\mathbf{x}} \left\{ \langle \nabla f(\mathbf{x}^k) - \frac{1}{\alpha} \phi(\mathbf{x}^k), \mathbf{x} \rangle + \frac{1}{\alpha} \phi(\mathbf{x}) \right\}$$

ここで閾数 $P(\mathbf{x}, \mathbf{x}^k)$ を次のように定義する。

$$P(\mathbf{x}, \mathbf{x}^k) = \langle \nabla f(\mathbf{x}^k) - \frac{1}{\alpha} \phi(\mathbf{x}^k), \mathbf{x} \rangle + \frac{1}{\alpha} \phi(\mathbf{x})$$

$\nabla P(\mathbf{x}, \mathbf{x}^k) = ①$ を計算すように \mathbf{x} を更新。

$$\nabla P(x, x^k)$$

$$= \nabla \langle \nabla f(x^k) - \frac{1}{\alpha} \phi(x^k), x \rangle + \frac{1}{\alpha} \nabla \phi(x)$$

$$= \nabla f(x^k) - \frac{1}{\alpha} \nabla \phi(x^k) + \frac{1}{\alpha} \nabla \phi(x)$$

これは

$$\nabla \phi(x^{k+1}) = \nabla \phi(x^k) - \alpha \nabla f(x^k)$$

のとまに ① になる。ここで、 $\nabla \phi$ の逆関数を用いれば、 x^{k+1} について、解くことができる

x を ① とがめて、 $y = \nabla \phi(\theta)$ と定義すれば。
更新式はまよしく

$$y^{k+1} \leftarrow y^{k+1} - \alpha \nabla f(\theta)$$

ただし、 θ も情報幾何である

例. $\phi(x) = \sum_i x_i \log x_i$ とする

$$\nabla \phi(x) = 1 + \log x \text{ であるから}$$

$$1 + \log x^{k+1} = 1 + \log x^k - \alpha \nabla f(x^k) \text{ は}$$


$$x^{k+1} = x^k \exp(-\alpha \nabla f(x^k))$$

である。

補足：

このままで、 \tilde{x} には拘束条件はないが、た。
でも、 \tilde{x} に拘束条件がある場合はどうする？

行列ーランを進めて、 \tilde{x} が拘束条件をやがて
しお、たり、拘束条件を満たす x の集合の中から、
最も近い点に更新する。



つまり、 $\min_{x \in C} f(x)$ では

$$\tilde{x}^{k+1} \leftarrow P_C (x^k - \alpha \nabla f(x^k))$$

普通の勾配法なら P_c は 2-次元射影.

鏡像降下法では、Bregman divergence の意味での射影を考えよ。(Bregman projection)

例えば、 $C = \Delta^d = \{x \mid x_d \geq 0, \sum_d x_d = 1\}$

とし、 $\phi(x) = \sum_i x_i \log x_i$ とする。勾束条件を

満たす \tilde{x}^{t+1} が、 Δ^d 中、最も近い点は

規格化されていない。

$$\hat{x}^{t+1} = \underset{x \in \Delta^d}{\operatorname{argmin}} B\phi(\tilde{x}^{t+1}, x)$$

$$= \underset{x \in \Delta^d}{\operatorname{argmin}} \sum_i \tilde{x}_i^{t+1} \log \frac{\hat{x}_i^{t+1}}{x_i}$$

$$- \sum_i x_i - \sum_i \hat{x}_i^{t+1}$$

を解くとして求まる。

ラグランジン関数を用いて $\sum_i x_i = 1$ を満たすが

最適な \tilde{x}^{t+1} を求めると、次を得る。

$$x_i^{t+1} = \frac{\tilde{x}_i^{t+1}}{\sum_i \tilde{x}_i^{t+1}}$$

以上より、 $\min_{\mathbf{x} \in \Delta^n} f(\mathbf{x})$ を $\phi(\mathbf{x}) = \sum_i x_i \log x_i$

の鏡像降下法で更新するとアルゴリズムは...

