

Algorithmes de Newton en streaming

A. Godichon-Baggioni

Algorithmes de gradient en streaming

DONNÉES EN STREAMING

- ▶ Au temps $t + 1$: $X_{t+1,1}, \dots, X_{t+1,n_{t+1}}$ données i.i.d.
- ▶ Mise à jour des estimateurs :

$$m_{t+1} = m_t - \gamma_{t+1} \frac{1}{n_{t+1}} \sum_{i=1}^{n_{t+1}} \nabla g(X_{t+1,i}, m_t)$$

- ▶ Conditions sur les pas :

$$\sum_{t \geq 1} \gamma_t = +\infty \quad \text{et} \quad \sum_{t \geq 1} \frac{\gamma_t^2}{n_t} < +\infty$$

$\implies m_t$ converge p.s vers m .

VERSION MOYENNÉE

- ▶ Estimateurs moyennés :

$$\bar{m}_t = \frac{1}{N_t} \sum_{k=0}^{t-1} n_{k+1} m_k$$

où $N_t = \sum_{k=1}^t n_k$.

- ▶ Mise à jour récursive :

$$\bar{m}_{t+1} = \frac{N_t}{N_{t+1}} \bar{m}_t + \frac{n_{t+1}}{N_{t+1}} m_t$$

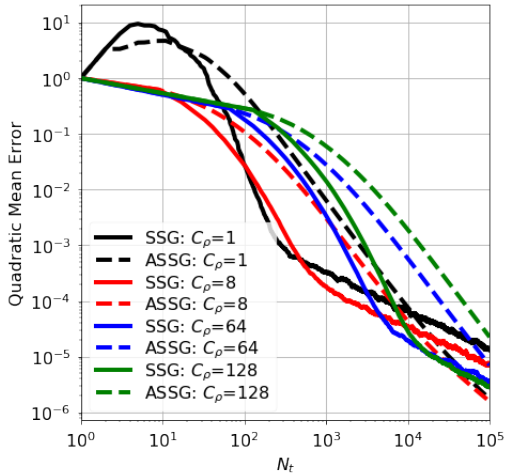
- ▶ Si $n_t = t$, on peut prendre

$$\bar{m}_{t+1} = \frac{t}{t+1} \bar{m}_t + \frac{1}{t+1} m_{t+1}.$$

- ▶ Convergence : sous certaines hypothèses

$$\sqrt{N_t} (\bar{m}_t - m) \xrightarrow[t \rightarrow +\infty]{\mathcal{L}} \mathcal{N}(0, H^{-1} \Sigma H^{-1}).$$

EXEMPLE



Algorithmes de Newton en streaming

ALGORITHMES DE NEWTON EN STREAMING

- ▶ On fixe $n_t = n$.
- ▶ On suppose

$$\nabla^2 G(m) = \mathbb{E} \left[\alpha(X, m) \Phi(X, m) \Phi(X, m)^T \right]$$

- ▶ Algorithme de Newton en streaming :

$$m_{t+1} = m_t - \frac{1}{t+1} \bar{H}_t^{-1} \nabla g(\mathbf{X}_{t+1}, m_t)$$

avec $\nabla g(\mathbf{X}_{t+1}, m_t) = \frac{1}{n} \sum_{i=1}^n \nabla g(X_{t+1,i}, m_t)$.

- ▶ Estimateur de la Hessienne :

$$\bar{H}_t = \frac{1}{N_t + 1} \left(H_0 + \sum_{k=1}^t \sum_{i=1}^n \alpha_{k,i} \Phi_{k,i} \Phi_{k,i}^T \right)$$

avec $\alpha_{k,i} = \alpha(X_{k,i}, m_{k-1})$ et $\Phi_{k,i} = \Phi(X_{k,i}, m_{k-1})$.

MISE À JOUR DE \bar{H}_t^{-1}

- ▶ On note $H_t = (N_t + 1)\bar{H}_t$ et

$$H_{t+1} = H_t + \sum_{i=1}^n \alpha_{t+1,i} \Phi_{t+1,i} \Phi_{t+1,i}^T$$

- ▶ Mise à jour de H_t^{-1} .

$$H_{t,i} = H_{t,i-1} + \alpha_{t+1,i} \Phi_{t+1,i} \Phi_{t+1,i}^T$$

avec $H_{t,0} = H_t$ et $H_{t,n} = H_{t+1}$.

- ▶ Formule de Riccati, pour tout $i = 1, \dots, n$,

$$H_{t,i}^{-1} = H_{t,i}^{-1} - \alpha_{t+1,i} \frac{1}{\left(1 + \alpha_{t+1,i} \Phi_{t+1,i}^T H_{t,i-1}^{-1} \Phi_{t+1,i}\right)} H_{t,i-1}^{-1} \Phi_{t+1,i} \Phi_{t+1,i}^T H_{t,i-1}^{-1}$$

RÉSULTATS DE CONVERGENCE ET TEMPS DE CALCULS

Sous certaines hypothèses, on a

$$\sqrt{N_t} (m_t - m) \xrightarrow[t \rightarrow +\infty]{\mathcal{L}} \mathcal{N} (0, H^{-1} \Sigma H^{-1}).$$

Temps de calculs : on a N_t/n itérations avec

- ▶ Mise à jour du gradient : $O(nd)$ opérations
- ▶ Mise à jour de la Hessienne : $O(nd^2)$ opérations
- ▶ Mise à jours de m_t : $O(d^2)$ opérations.

Cout total :

$$\underbrace{O(N_t d)}_{\text{mise à jour du gradient}} + \underbrace{O(N_t d^2)}_{\text{mise à jour de la Hessienne}} + \underbrace{O\left(\frac{N_t}{n} d^2\right)}_{\text{mise à jour de } m_t}$$

ALGORITHME DE NEWTON AVEC $O(N_t d)$ OPÉRATIONS

- ▶ Idée : prendre $n = d$.
- ▶ Temps de calculs pour les mises à jour de m_t : $O(N_t d)$.
- ▶ Temps de calculs pour les mises à jour des gradients $O(N_t d)$.
- ▶ Objectif : réduire le temps de calcul pour la mise à jour de la Hessienne.

NOUVEL ESTIMATEUR DE LA HESSIENNE

- Nouvel estimateur :

$$H_{t+1} = H_t + \sum_{i=1}^n Z_{t+1,i} \alpha_{t+1,i} \Phi_{t+1,i} \Phi_{t+1,i}^T$$

avec $Z_{t+1,i} \sim \mathcal{B}(p)$ et $p \in (0, 1)$ et $\bar{H}_t = \frac{1}{1 + \sum_{k=1}^t \sum_{i=1}^n Z_{t,i}} H_t$.

- Mise à jour de H_t^{-1} : **si** $Z_{t+1,i} = 1$,

$$H_{t,i} = H_{t,i-1} + \alpha_{t+1,i} \Phi_{t+1,i} \Phi_{t+1,i}^T$$

avec $H_{t,0} = H_t$ et $H_{t,n} = H_{t+1}$.

- Formule de Riccati, pour tout $i = 1, \dots, n$, **si** $Z_{t+1,i} = 1$

$$H_{t,i}^{-1} = H_{t,i}^{-1} - \alpha_{t+1,i} \frac{1}{\left(1 + \alpha_{t+1,i} \Phi_{t+1,i}^T H_{t,i-1}^{-1} \Phi_{t+1,i}\right)} H_{t,i-1}^{-1} \Phi_{t+1,i} \Phi_{t+1,i}^T H_{t,i-1}^{-1}$$

TEMPS DE CALCUL ET CONVERGENCE

- ▶ Temps de calcul pour les mises à jours de la Hessienne : $O(N_t d^2 p)$ (en moyenne)
- ▶ Prendre $p = d^{-1}$.
- ▶ Temps de calcul total : $O(N_t d)$ (en moyenne).
- ▶ Convergence :

$$\sqrt{N_t} (m_t - m) \xrightarrow[t \rightarrow +\infty]{\mathcal{L}} \mathcal{N}(0, H^{-1} \Sigma H^{-1})$$

- ▶ Pondération :

$$H_{t+1} = H_t + \log(t+1)^w \sum_{i=1}^n Z_{t+1,i} \alpha_{t+1,i} \Phi_{t+1,i} \Phi_{t+1,i}^T$$

$$\text{et } \bar{H}_t = \frac{1}{1 + \sum_{k=0}^t \log(k+1)^w \sum_{i=1}^n Z_{t,i}} H_t.$$

Algorithmes de Newton moyennés pondérés

ALGORITHMES DE NEWTON MOYENNÉ

► L'algorithme

$$m_{t+1} = m_t - \gamma_{t+1} \bar{H}_t^{-1} \nabla g(X_{t+1}, m_t)$$
$$\bar{m}_{t+1} = m_t + \frac{\ln(t+1)^w}{\sum_{k=0}^t \log(k+1)^w} (m_{t+1} - \bar{m}_t)$$

avec $\gamma_{t+1} = c_\gamma t^{-\alpha}$ et $c_\gamma > 0$ et $\alpha \in (1/2, 1)$.

► Attention! Dans \bar{H}_t , on peut utiliser m_t ou \bar{m}_t .

► Convergence :

$$\sqrt{t} (\bar{m}_t - m) \xrightarrow[t \rightarrow +\infty]{\mathcal{L}} \mathcal{N}(0, H^{-1} \Sigma H^{-1}).$$

MODÈLE LINÉAIRE




FIGURE – Evolution de l'erreur quadratique moyenne pour différentes initialisations : $m_0 = m + rU$, où U suit une loi uniforme sur la sphère \mathbb{R}^d avec $r = 1$ (à gauche), $r = 2$ (au milieu) et $r = 5$ (à droite).

ALGORITHMES DE NEWTON MOYENNÉ EN STREAMING

- ▶ Algorithme de Newton moyenné en streaming :

$$m_{t+1} = m_t - \frac{1}{t+1} \bar{H}_t^{-1} \nabla g(\mathbf{X}_{t+1}, m_t)$$
$$\bar{m}_{t+1} = m_t + \frac{\ln(t+1)^w}{\sum_{k=0}^t \log(k+1)^w} (m_{t+1} - \bar{m}_t)$$

avec $\nabla g(\mathbf{X}_{t+1}, m_t) = \frac{1}{n} \sum_{i=1}^n \nabla g(X_{t+1,i}, m_t)$.

- ▶ Estimateur de la Hessienne :

$$\bar{H}_t = \frac{1}{1 + \sum_{k=1}^t \log(k+1)^{w'}} \sum_{i=1}^n Z_{k,i} \left(H_0 + \sum_{k=1}^t \log(k+1)^{w'} \sum_{i=1}^n Z_{k,i} \alpha_{k,i} \Phi_{k,i} \Phi_{k,i}^T \right)$$

avec $\alpha_{k,i} = \alpha(X_{k,i}, m_{k-1})$ et $\Phi_{k,i} = \Phi(X_{k,i}, m_{k-1})$.

MODÈLE LINÉAIRE




FIGURE – Evolution de l'erreur quadratique moyenne pour différentes initialisations : $m_0 = m + rU$, où U suit une loi uniforme sur la sphère \mathbb{R}^d avec $r = 1$ (à gauche) et $r = 5$ (à droite).

MODÈLE LINÉAIRE




FIGURE – Evolution de l'erreur quadratique moyenne pour différentes initialisations : $m_0 = m + rU$, où U suit une loi uniforme sur la sphère \mathbb{R}^d avec $r = 1$ (à gauche) et $r = 5$ (à droite).

RÉGRESSION LOGISTIQUE




FIGURE – Evolution de l'erreur quadratique moyenne pour différentes initialisations : $m_0 = m + rU$, où U suit une loi uniforme sur la sphère \mathbb{R}^d avec $r = 1$ (à gauche) et $r = 5$ (à droite).

RÉGRESSION LOGISTIQUE




FIGURE – Evolution de l'erreur quadratique moyenne pour différentes initialisations : $m_0 = m + rU$, où U suit une loi uniforme sur la sphère \mathbb{R}^d avec $r = 1$ (à gauche) et $r = 5$ (à droite).