

Paysage

Thm (Le paysage des réseaux larges)

On suppose $\sigma \in C^1$ et que, pour tout $t \in \mathbb{R}$, $\sigma'(t) \neq 0$.

On suppose L est C^1 , à valeur dans \mathbb{R}^+ telle que $L(0) = 0$.

On suppose $\forall L(y) = 0 \Leftrightarrow y = 0$.

On considère $x \in \mathbb{R}^{n_0 \times n}$ et $A = \begin{pmatrix} x \\ x^T \\ n \end{pmatrix}$.

On suppose $\text{rk}(A) = n$

Soit θ un point critique du premier ordre de E tel que pour tout $h = 1, \dots, H$ $\text{rk}(w_h) = n_h$.

On a $E(\theta) = \hat{R}(\beta_\theta) = 0$.

θ est un minimiseur global.

preuve: On rappelle que pour tout $h \in \{1, \dots, H\}$, $i \in \{1, \dots, n_h\}$, $j \in \{1, \dots, n_{h-1}\}$ et $l \in \{1, \dots, n\}$, on a

$$\frac{\partial E}{\partial (w_h)_{ij}}(\theta) = \left[\beta_\theta^{h-1}(x^l) \right]_j \cdot \overline{\Delta}_i^h(x^l)$$

$$\frac{\partial E}{\partial (b_h)_i}(\theta) = \overline{\Delta}_i^h(x^l)$$

avec $\overline{\Delta}_i^h(x^l) = \sigma' \left(\left[w_h \beta_\theta^{h-1}(x^l) + b_h \right]_i \right) \Delta_i^l(x^l)$

et

$$\Delta^h(x^l) = \begin{cases} \nabla L(\beta_\theta(x^l) - y^l) & \text{si } h=0 \\ w_{h+1}^T \overline{\Delta}^{h+1}(x^l) & \text{si } h=0, \dots, H-1 \end{cases}$$

On va montrer par récurrence que pour tout $h=1, \dots, H$ et tout $l=1, \dots, n$ on a

$$\bar{\Delta}^h(x^l) = 0.$$

+ initialisation: $h=1$, pour $i \in \{1, \dots, m_1\}$ et $j \in \{1, \dots, m_0\}$ on a, comme θ est un point critique de E ,

$$(*) \begin{cases} 0 = \frac{\partial E}{\partial (w_{ij})}(\theta) = \sum_{l=1}^n \left[\cancel{\beta_{w,b}^0(x^l)} \right]_{j} \cdot x_j^l \cdot \bar{\Delta}^1(x^l)_i \\ 0 = \frac{\partial E}{\partial (b_{ij})}(\theta) = \sum_{l=1}^n \bar{\Delta}^1(x^l)_i \end{cases}$$

On a $\bar{\Delta}^1(x^l) \in \mathbb{R}^{m_1}$ pour tout $l \in \{1, \dots, n\}$

On note

$$\bar{\Delta}^1 = \left(\bar{\Delta}^1(x_1^1) \quad \dots \quad \bar{\Delta}^1(x_n^1) \right)^T = \begin{pmatrix} \bar{\Delta}^1(x_1^1)_1 & \dots & \bar{\Delta}^1(x_1^1)_{m_1} \\ \vdots & & \vdots \\ \bar{\Delta}^1(x_n^1)_1 & \dots & \bar{\Delta}^1(x_n^1)_{m_1} \end{pmatrix} \in \mathbb{R}^{n \times m_1}$$

$$\text{et } A = \begin{pmatrix} x_1^1 & \dots & x_1^n \\ \vdots & & \vdots \\ x_{m_0}^1 & \dots & x_{m_0}^n \\ 1 & \dots & 1 \end{pmatrix} \in \mathbb{R}^{(m_0+1) \times n}$$

Les équations (*) sont équivalentes à

$$A \bar{\Delta}^1 = 0 \in \mathbb{R}^{(m_0+1) \times m_1}$$

Comme on a supposé A de rang colonne plein ($\text{rk}(A) = n$)

l'équation $A \bar{\Delta}^1 = 0$ implique $\bar{\Delta}^1 = 0$.

(On multiplie à gauche par $(A^T A)^{-1} A^T$)

passage résolu large | 2/4

$\bar{\Delta}^1 = 0$ est équivalent à $\bar{\Delta}^1(x^l) = 0 \quad \forall l \in \{1, \dots, n\}$.

+ recurrence: Supposons que pour $h \in \{1, \dots, H-1\}$, on

ait $\bar{\Delta}^h(x^l) = 0 \quad \forall l \in \{1, \dots, n\}$.

Montrons ~~de~~ que $\bar{\Delta}^{h+1}(x^l) = 0 \quad \forall l \in \{1, \dots, n\}$.

Soit $l \in \{1, \dots, n\}$, on sait que pour tout $i \in \{1, \dots, n_h\}$

$$\bar{\Delta}_i^h(x^l) = \sigma'([w_h \beta_0^{h-1}(x^l) + b_h]_i) \Delta_i^h(x^l) = 0.$$

Comme on a supposé $\sigma'(t) \neq 0 \quad \forall t \in \mathbb{R}$, on a

donc $\Delta_i^h(x^l) = 0$ et donc $\Delta^h(x^l) = 0$.

On en déduit que $w_{h+1}^T \bar{\Delta}^{h+1}(x^l) = 0$

Comme on a supposé $\text{rk}(w_{h+1}) = n_{h+1}$, on

a $\text{rg}(w_{h+1}^T) = n_{h+1}$ et w_{h+1}^T est de rang

colonne plein. On en déduit que

$$\bar{\Delta}^{h+1}(x^l) = 0.$$

Cela conclut la récurrence et on a montré que $\forall h \in \{1, \dots, H\}$ et tout $l \in \{1, \dots, n\}$, $\bar{\Delta}^h(x^l) = 0$

On en déduit que

$$\bar{\Delta}^H(x^l)_i = \sigma'([w_H \beta_0^{H-1}(x^l) + b_H]_i) \Delta^H(x^l)_i = 0$$

et donc, comme $\sigma'(t) \neq 0 \quad \forall t$, que $\Delta^H(x^l)_i = 0$

paypage large | 3 / 4

On a donc $\nabla L (f_\theta(x^l) - y^l) = 0$

qui implique (voir hypothèse sur L) que

$$f_\theta(x^l) = y^l$$

On obtient finalement

$$L(f_\theta(x^l) - y^l) = 0 \quad \forall l \in \{1, \dots, m\}$$

et donc $E(\theta) = \sum_{l=1}^m L(f_\theta(x^l) - y^l) = 0$.

Comme $\forall \theta', E(\theta') \geq 0$, θ^* est

bien un minimiseur global. \square