IA : Machine (Deep) Learning

Réseaux de neurones et Deep Learning

A. Zemmari

LaBRI - Université de Bordeaux

Jan. 16, 2017

Outline

Outline

Quelques dates et quelques noms

- 1943 : (Mc Culloch (neuro-physiologiste) et Pitts (logicien)) proposent les premières notions de neurone formel.
- 1959 : (Rosenblatt) définit un réseau de neurones avec une couche d'entrée et une sortie.
- 1960 : (Widrow et Hoff) ADALINE
- 1969 : (Minsky, Papert) Problème XOR
- 1986 : (Rumelhart et. al) MLP et backpropagation
- 1992 : (Vapnik et. al) SVM
- 1998 : (LeCun et. al) LeNet
- 2010 : (Hinton et. al) Deep Neural Networks
- 2012 : (Krizhevsky, Hinton et. al) AlexNet, ILSVRC'2012, GPU - 8 couches 2014 GoogleNet - 22 couches
- 2015 : Inception (Google) - Deep Dream
- 2016 : ResidualNet (Microsoft/Facebook) - 152 couches

Outline

D'abords il y a le neurone

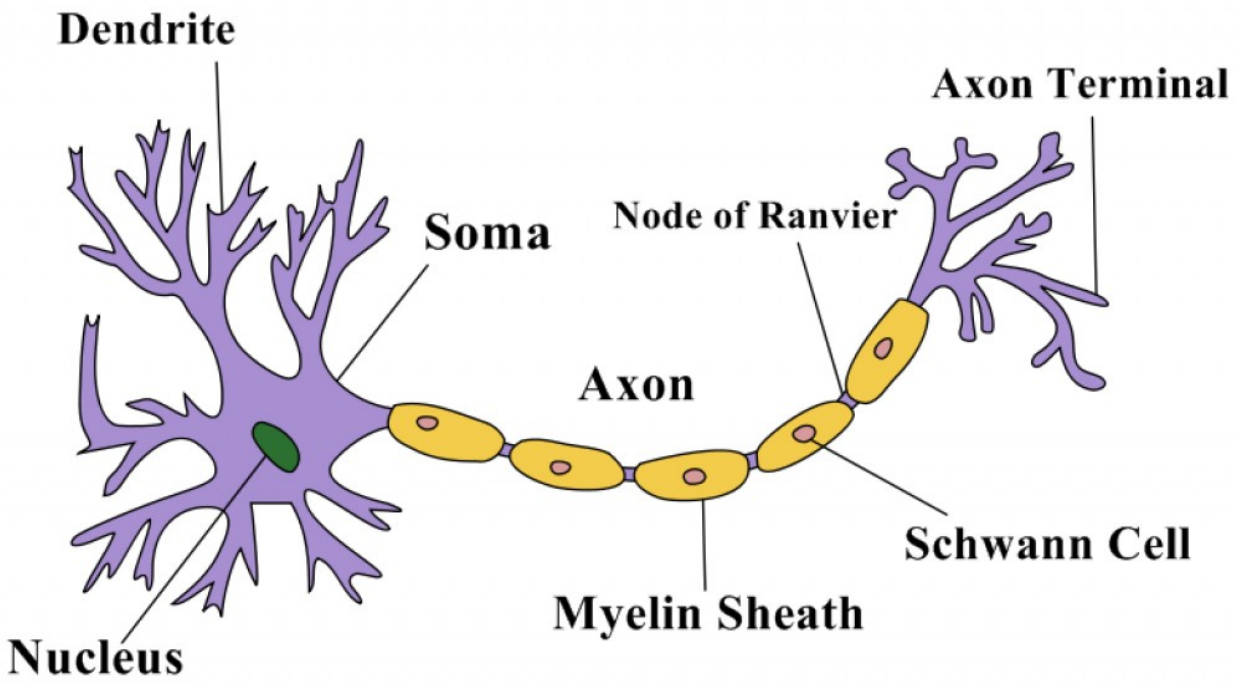

D'abords il y a le neurone

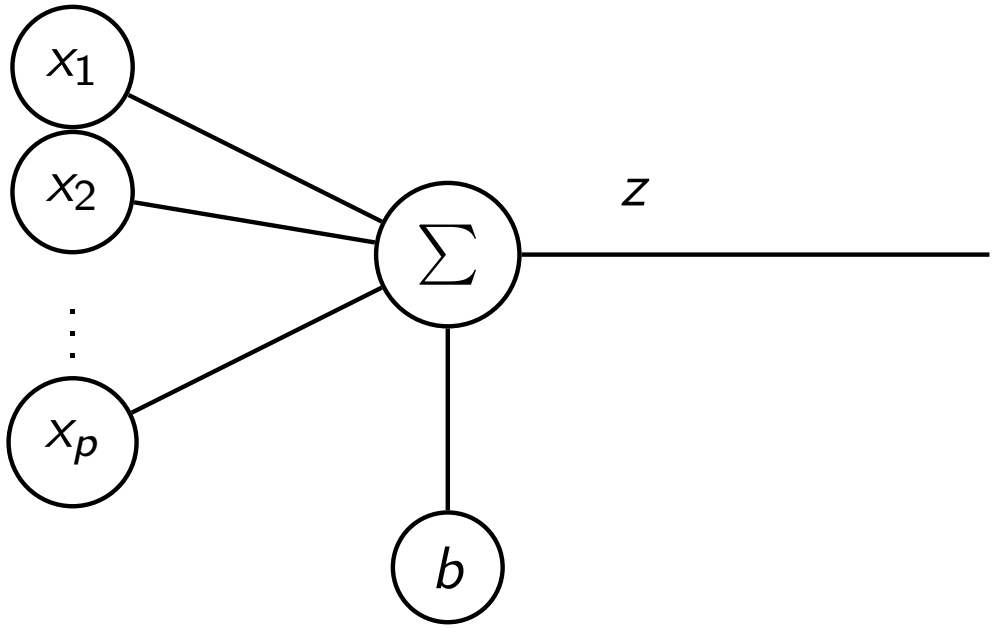

Figure: Un neurone formel.

D'abords il y a le neurone

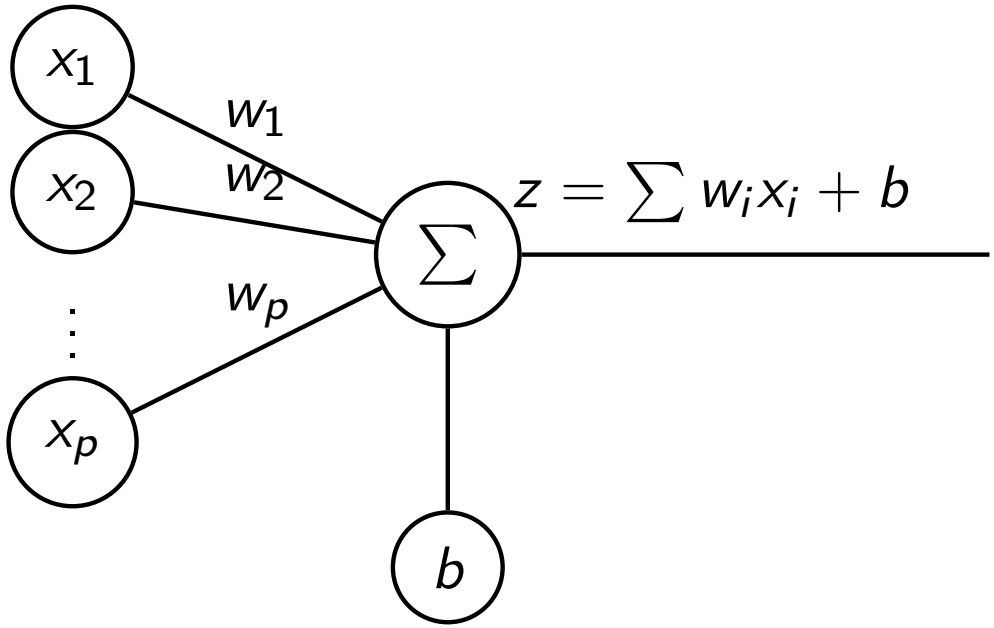

Figure: Un neurone formel.

D'abords il y a le neurone

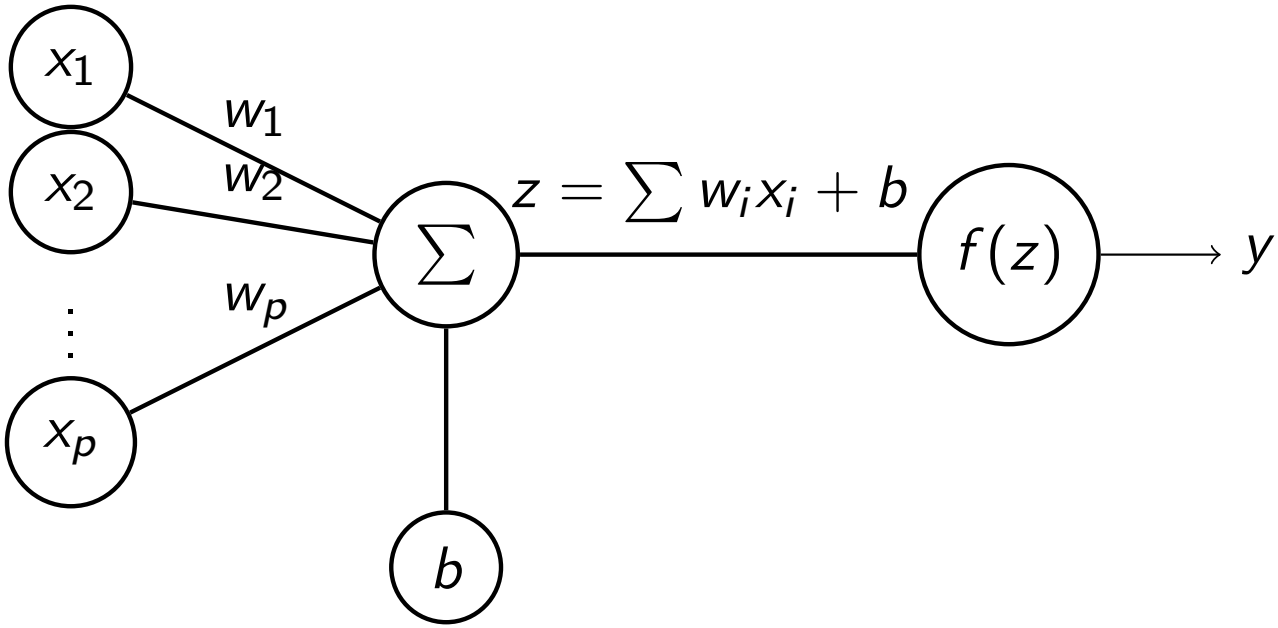

Figure: Un neurone formel.

D'abords il y a le neurone

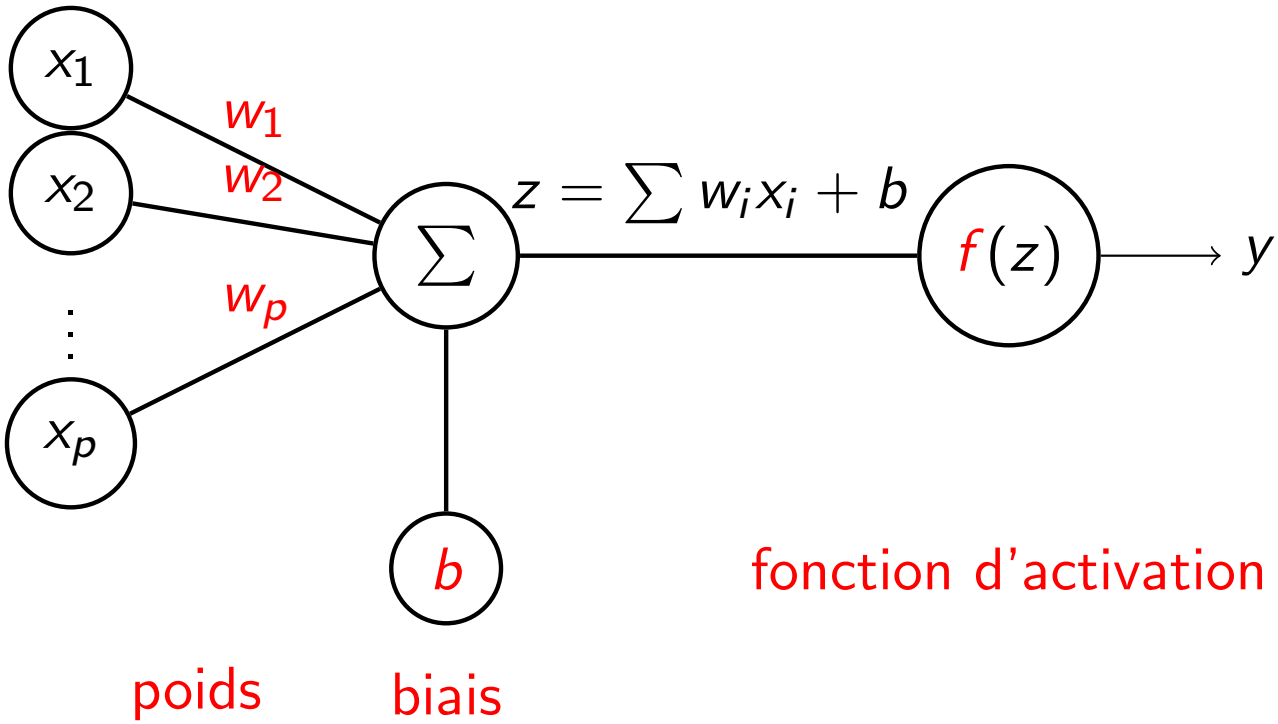

Figure: Un neurone formel.

D'abords il y a le neurone

Exemple de fonction d'activation : sigmoïd

$$f(z) = \frac{1}{1 + e^{-z}}.$$

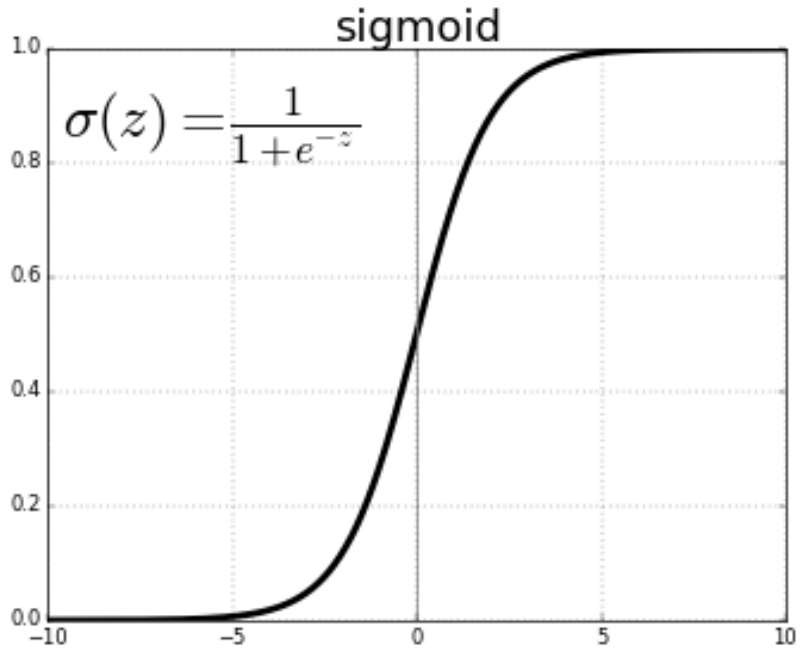

D'abords il y a le neurone

Autres fonctions d'activation :

- fonction linéaire : f est la fonction identité,
- seuil : $f(z) = \mathbb{1}_{[0,\infty[}(z)$,
- ReLU : $f(z) = \max(0, z)$ (rectified linear unit),
- radiale : $f(z) = \sqrt{1/2\pi}e^{(-z^2/2)}$,
- stochastique : $f() = 1$ avec la probabilité $1/(1 + e^{-z/H})$, 0 sinon (H intervient comme une température dans un algorithme de recuit simulé),
- ...

D'abords il y a le neurone

De manière compacte :

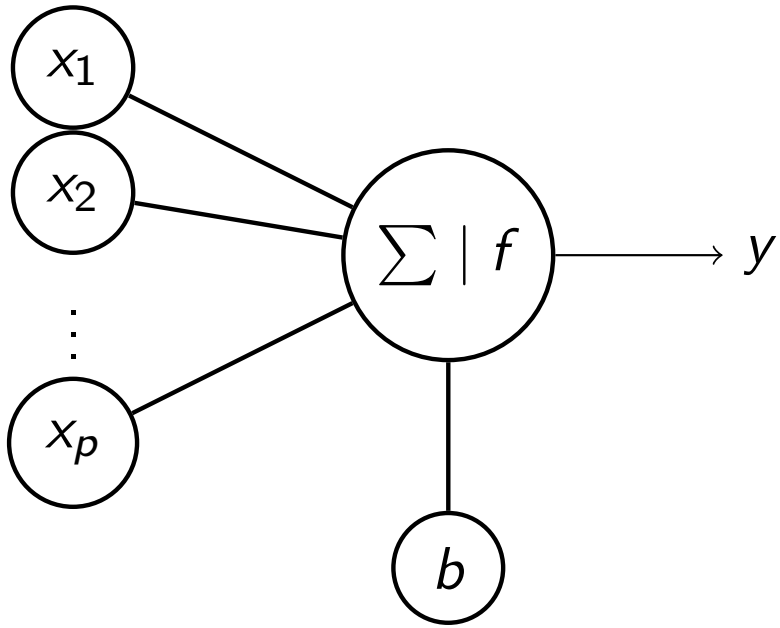

Figure: Un neurone formel.

Outline

Réseau de neurones

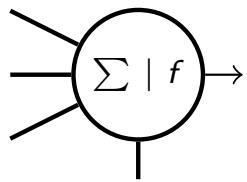

Figure: Un réseau de neurones.

Réseau de neurones

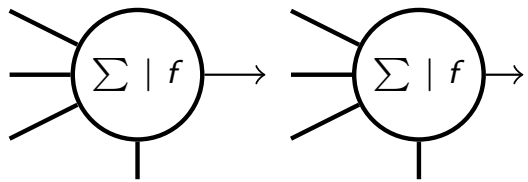

Figure: Un réseau de neurones.

Réseau de neurones

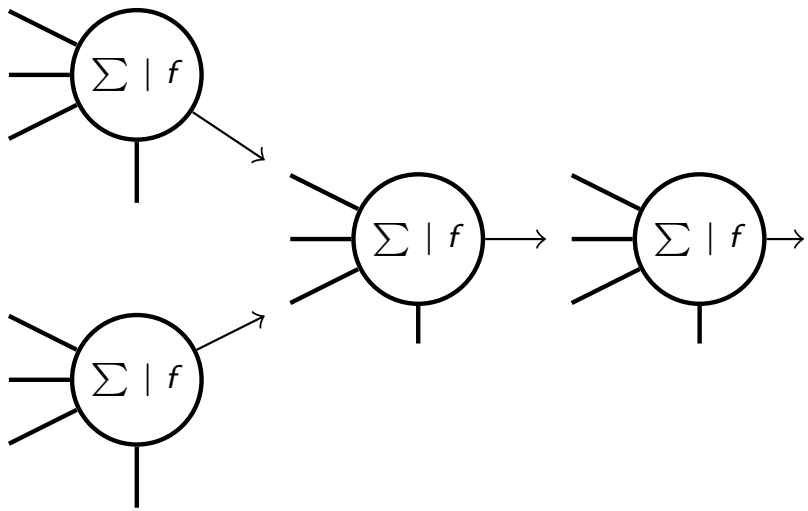

Figure: Un réseau de neurones.

- Les neurones ont chacun leurs propres poids et biais,
- Les paramètres du réseau sont alors les différents poids et les différents biais. On note tous ces paramètres θ.

Réseau de neurones

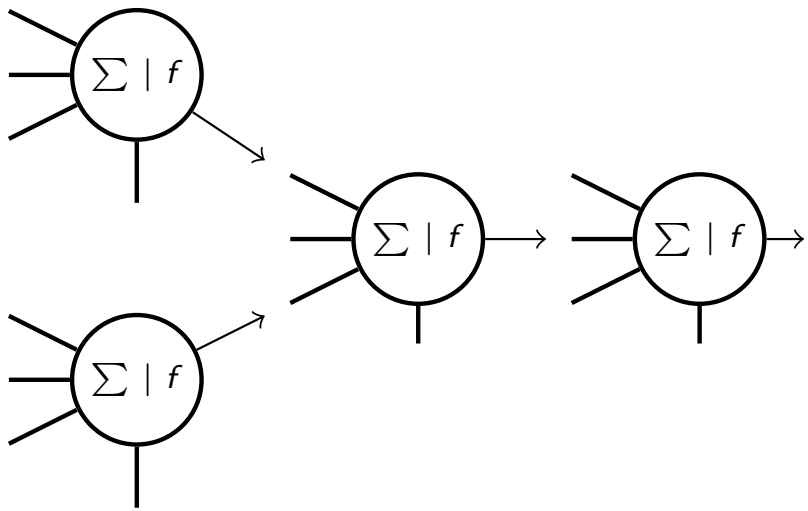

Figure: Un réseau de neurones.

- Les neurones ont chacun leurs propres poids et biais,
- Les paramètres du réseau sont alors les différents poids et les différents biais. On note tous ces paramètres θ.

Réseau de neurones

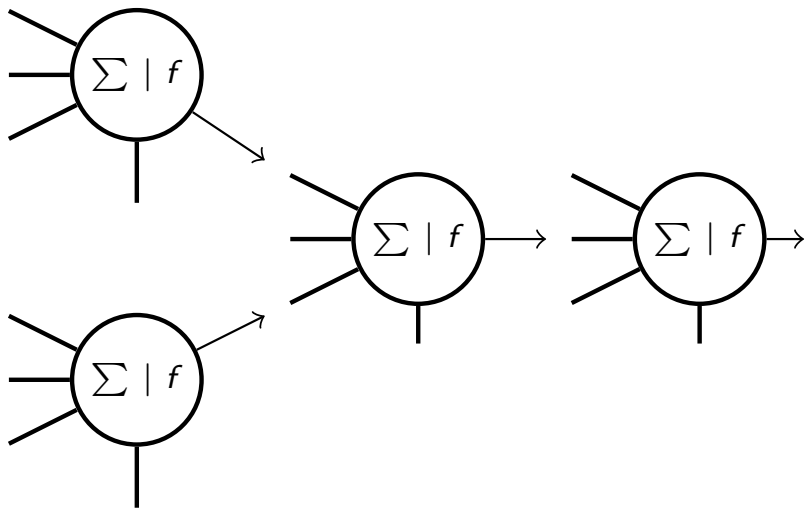

Figure: Un réseau de neurones.

- Les neurones ont chacun leurs propres poids et biais,
- Les paramètres du réseau sont alors les différents poids et les différents biais. On note tous ces paramètres θ.

Réseaux de neurones complètement connectés

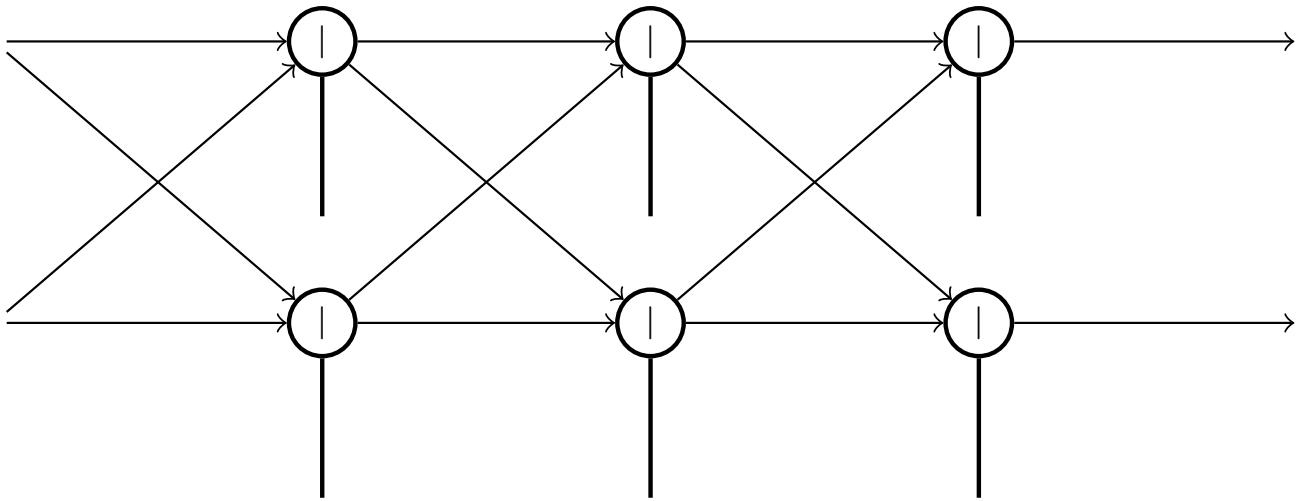

Réseaux de neurones complètement connectés

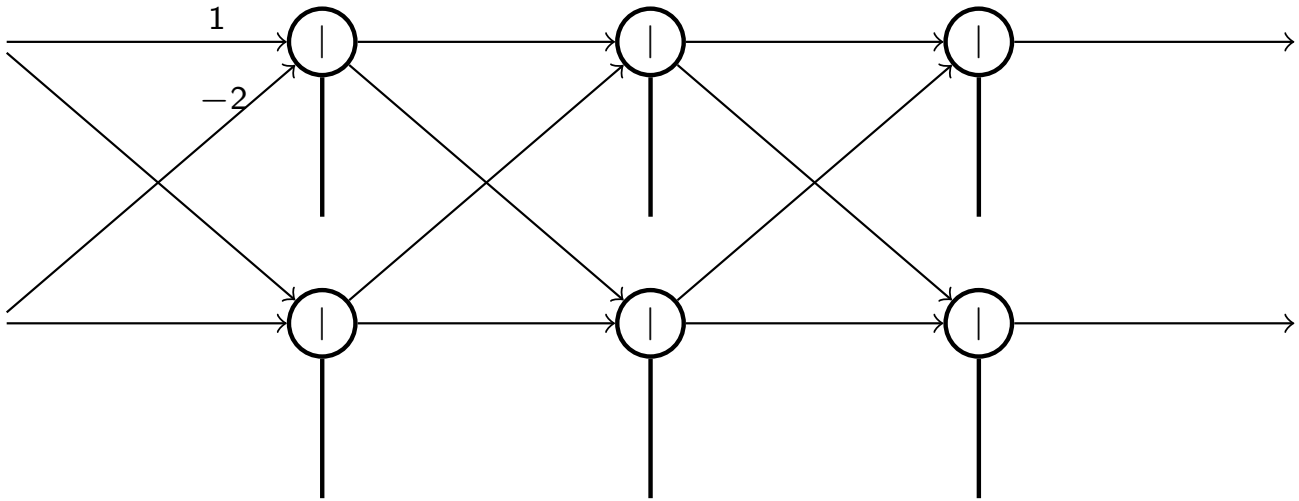

Réseaux de neurones complètement connectés

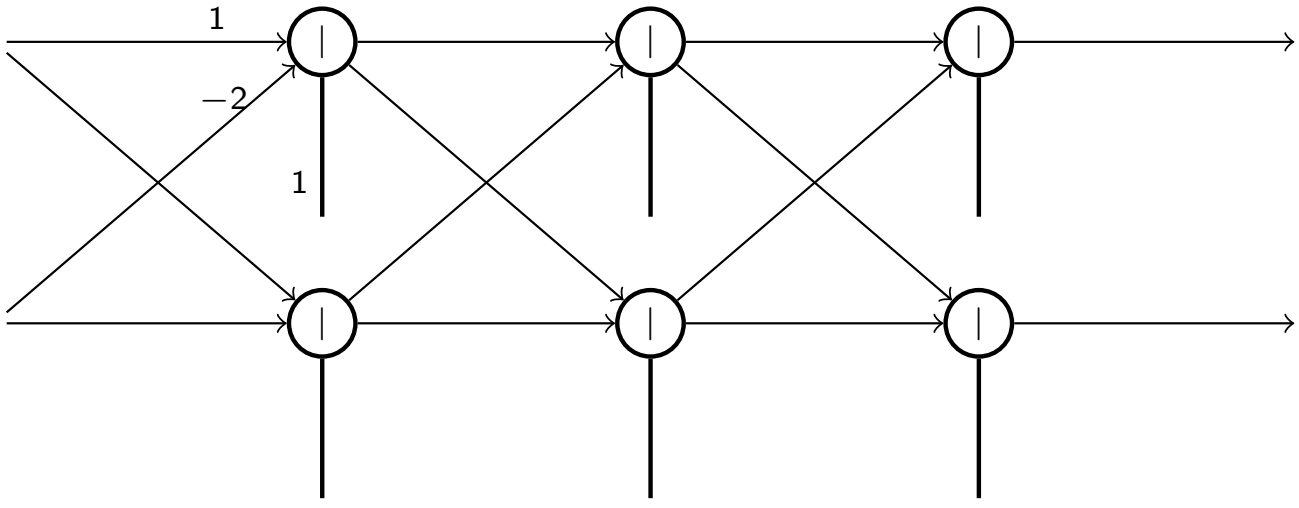

Réseaux de neurones complètement connectés

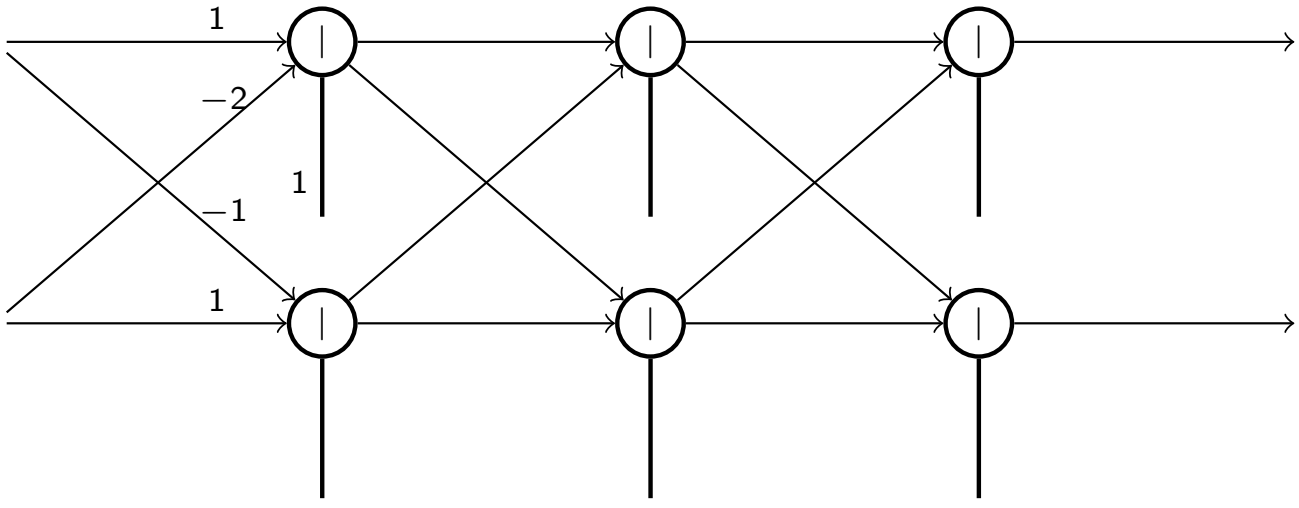

Réseaux de neurones complètement connectés

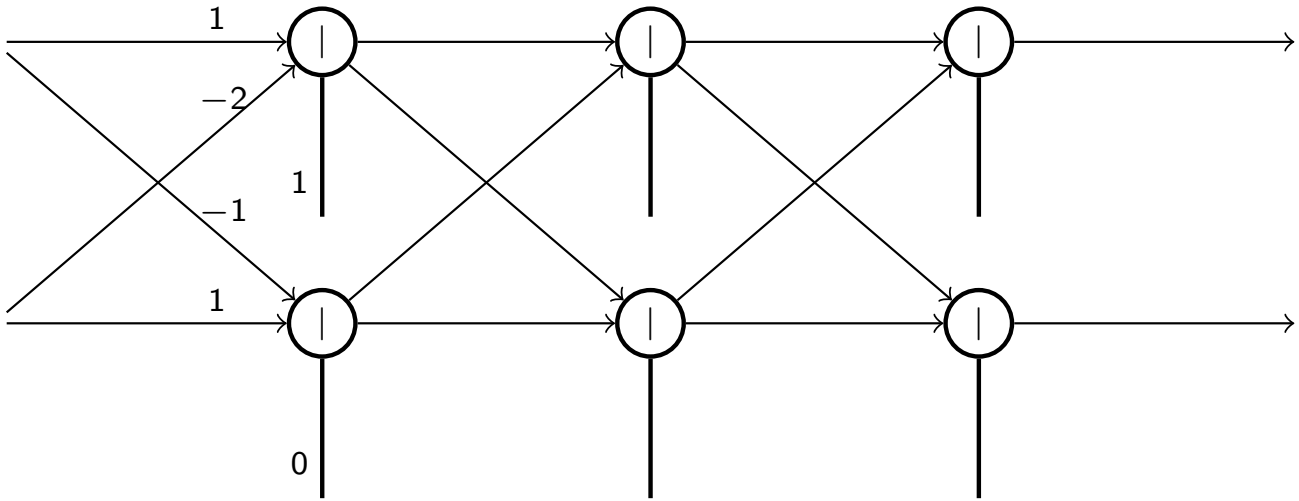

Réseaux de neurones complètement connectés

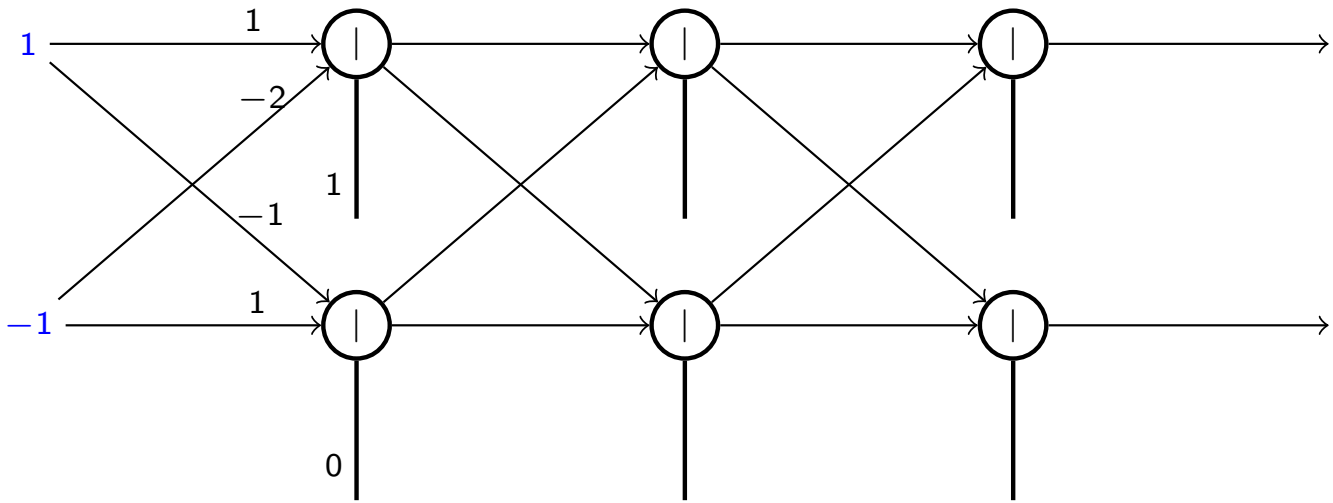

Réseaux de neurones complètement connectés

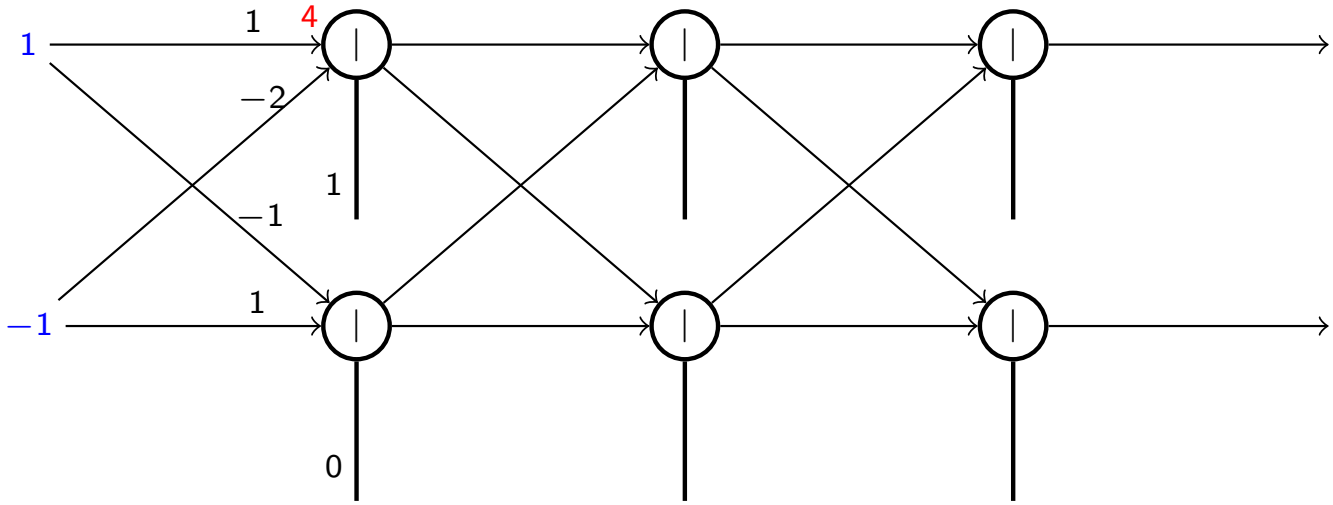

Réseaux de neurones complètement connectés

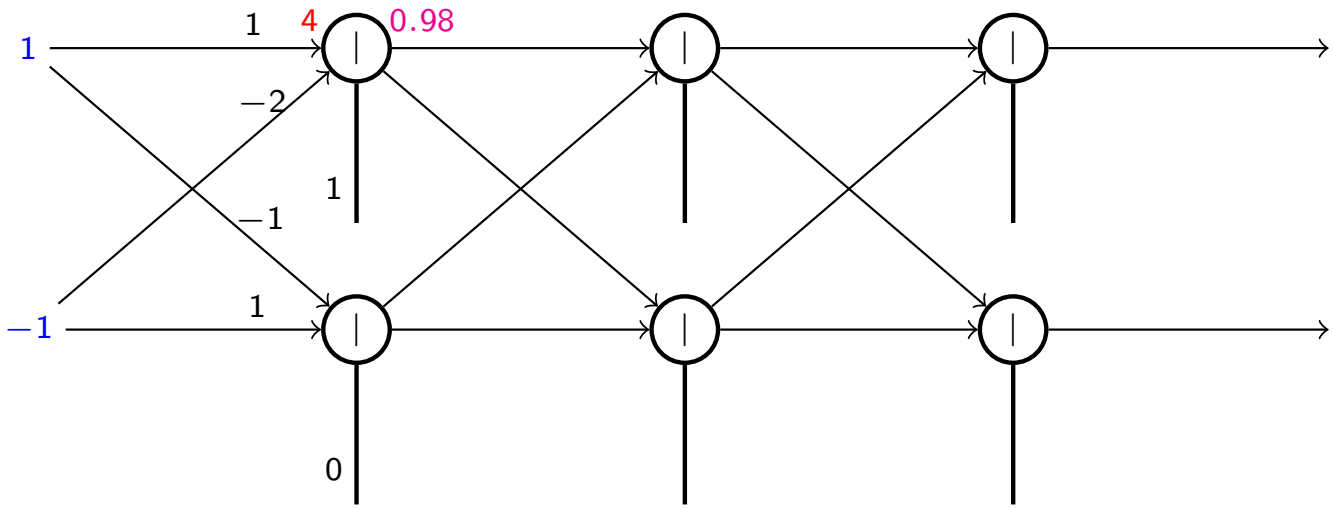

Si f est la fonction sigmoïd : $f(z) = \frac{1}{1-e^{-z}}$

Réseaux de neurones complètement connectés

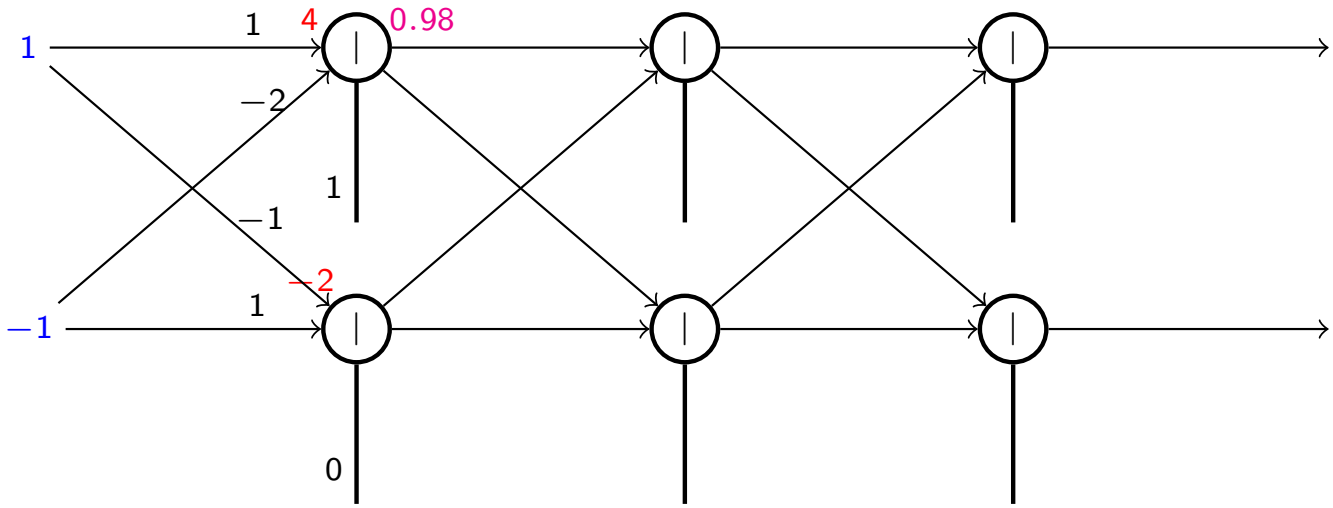

Réseaux de neurones complètement connectés

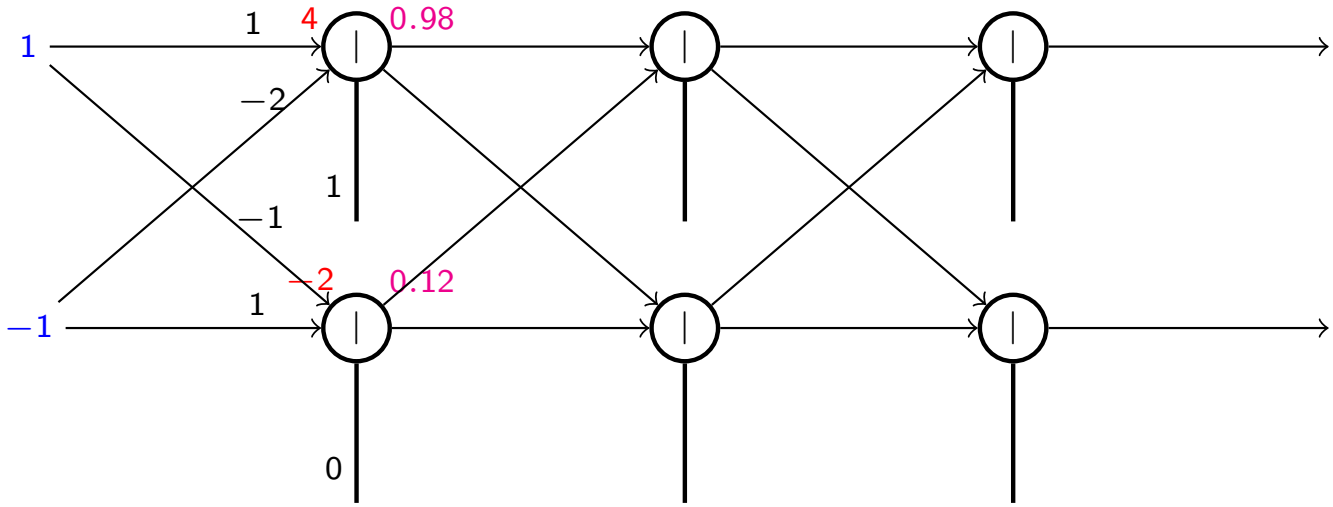

Réseaux de neurones complètement connectés

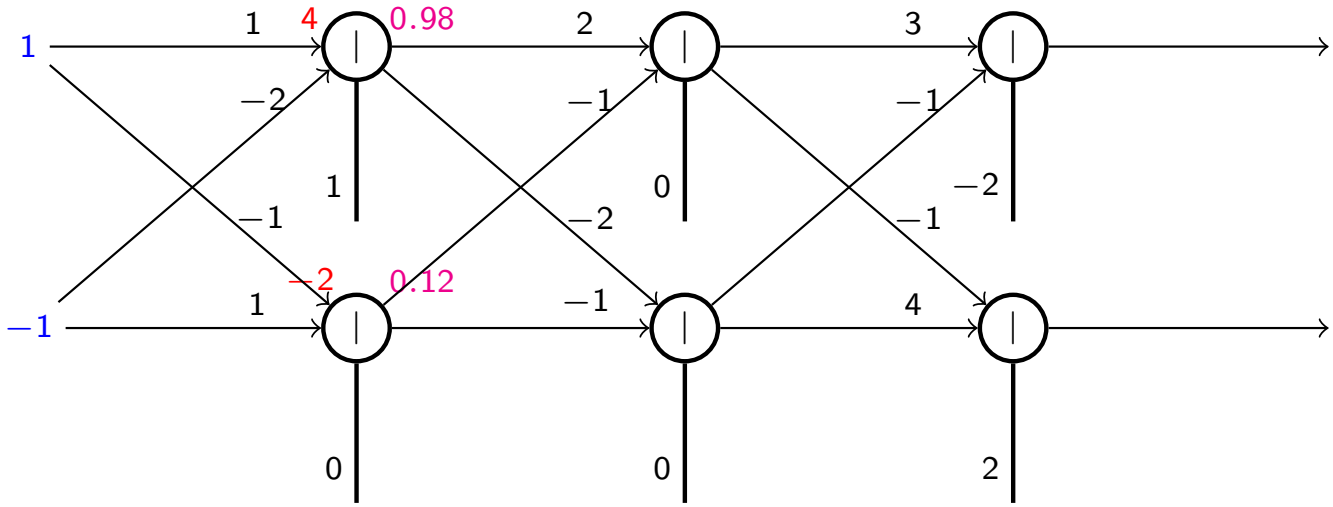

Réseaux de neurones complètement connectés

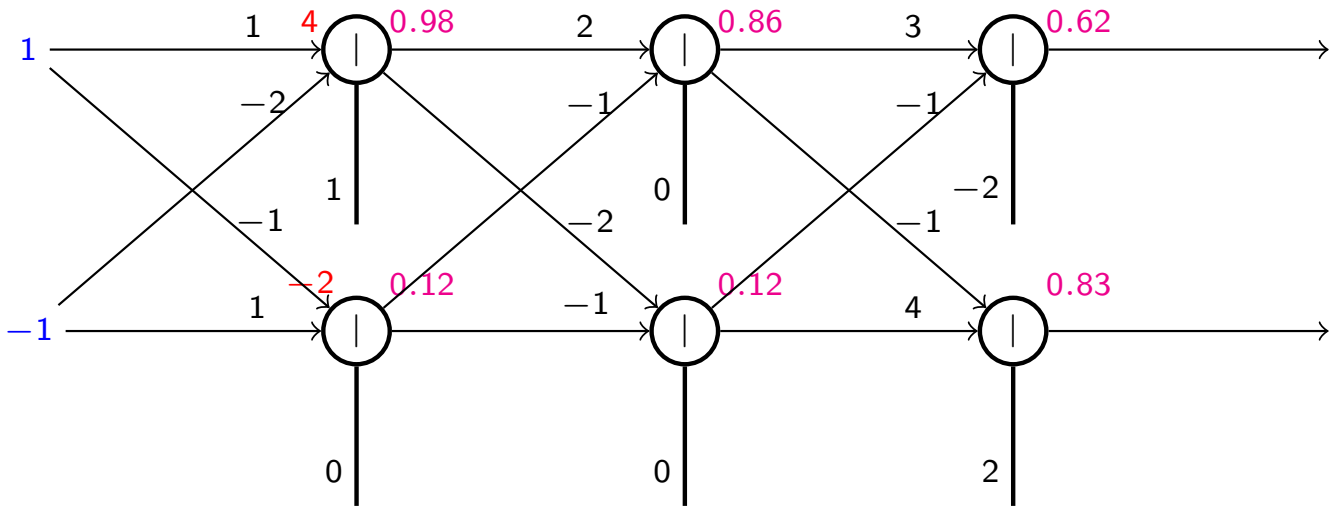

Réseaux de neurones complètement connectés

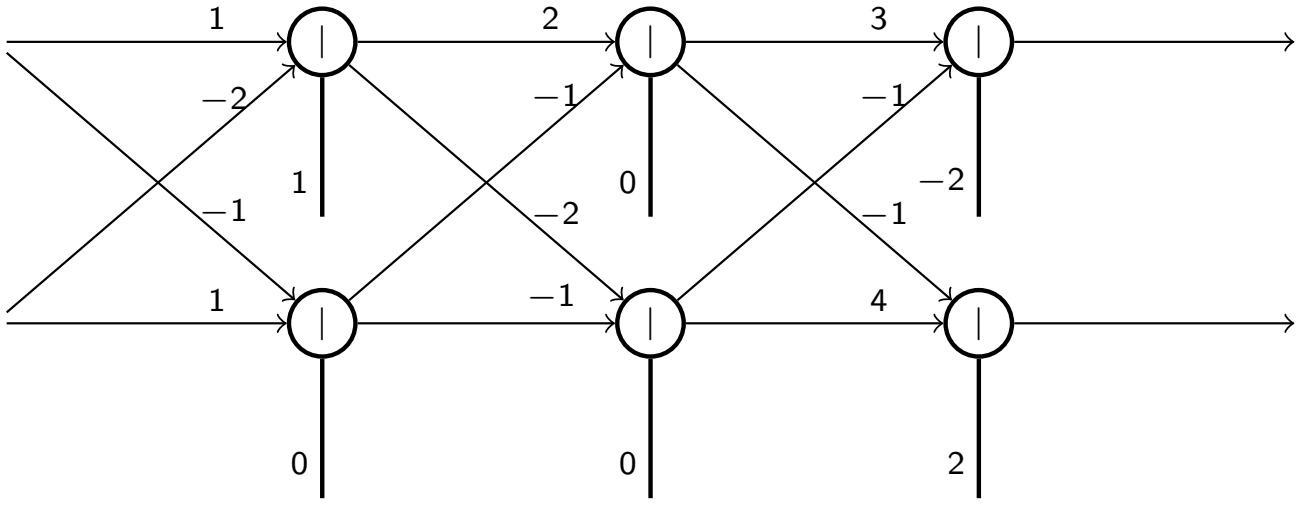

Réseaux de neurones complètement connectés

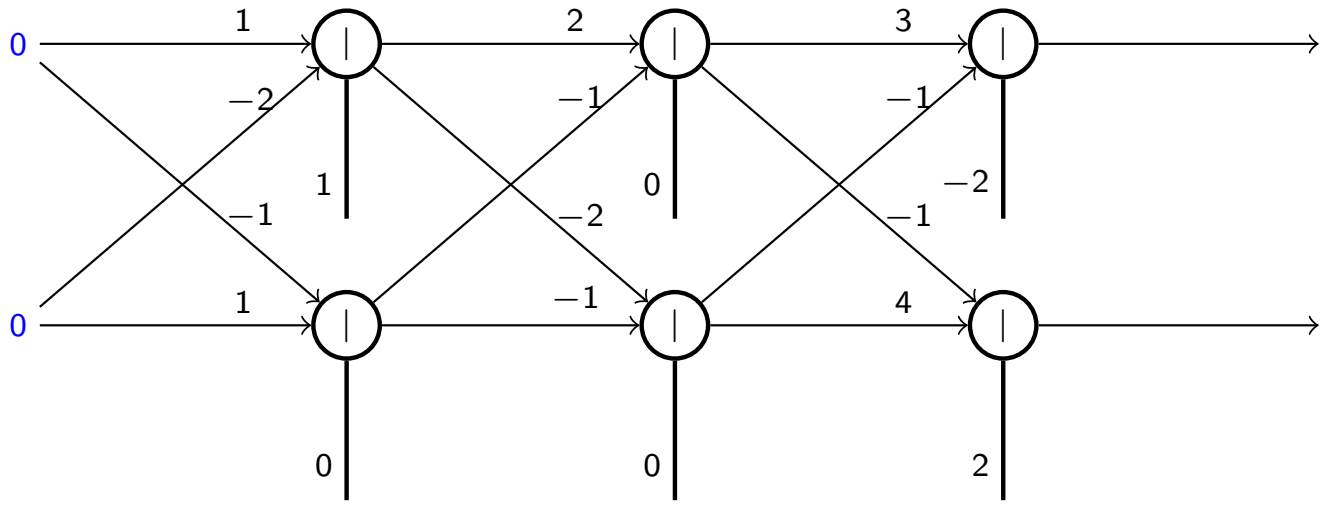

Réseaux de neurones complètement connectés

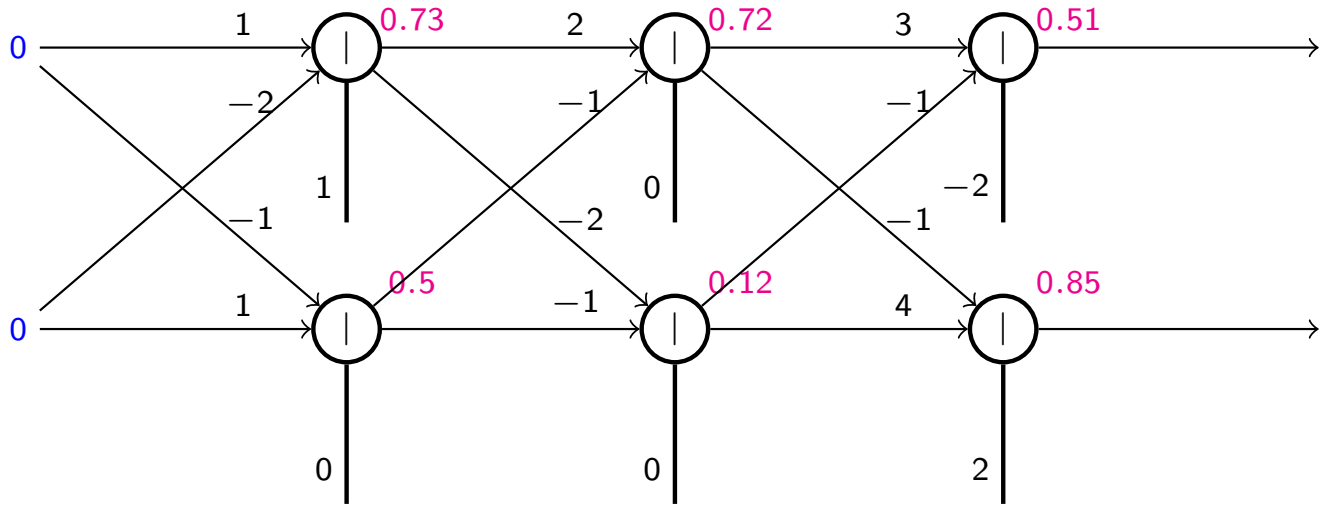

Réseaux de neurones complètement connectés

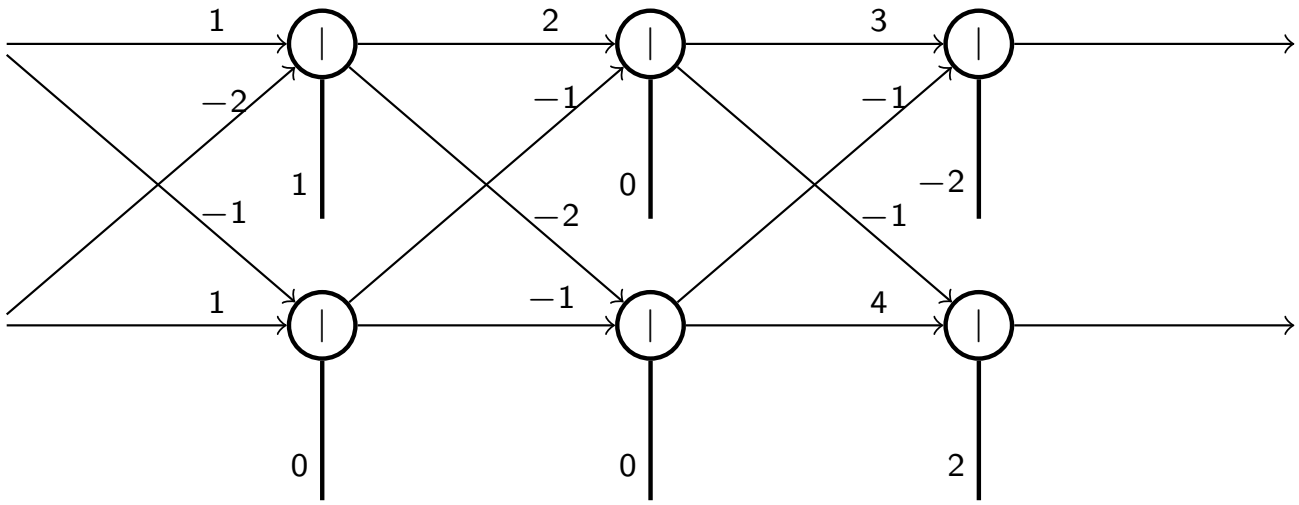

Fixer les paramètres $\theta \longrightarrow$ fixer la fonction.

Réseaux de neurones complètement connectés

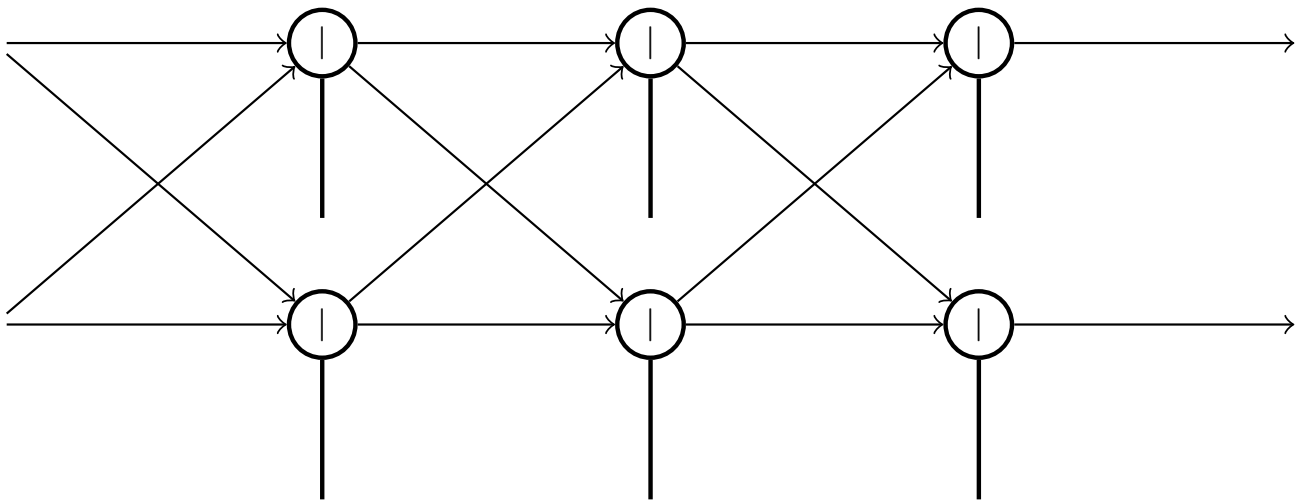

Donner la structure du réseau $\longrightarrow$ définir un ensemble de fonctions.

Réseaux à plusieurs couches

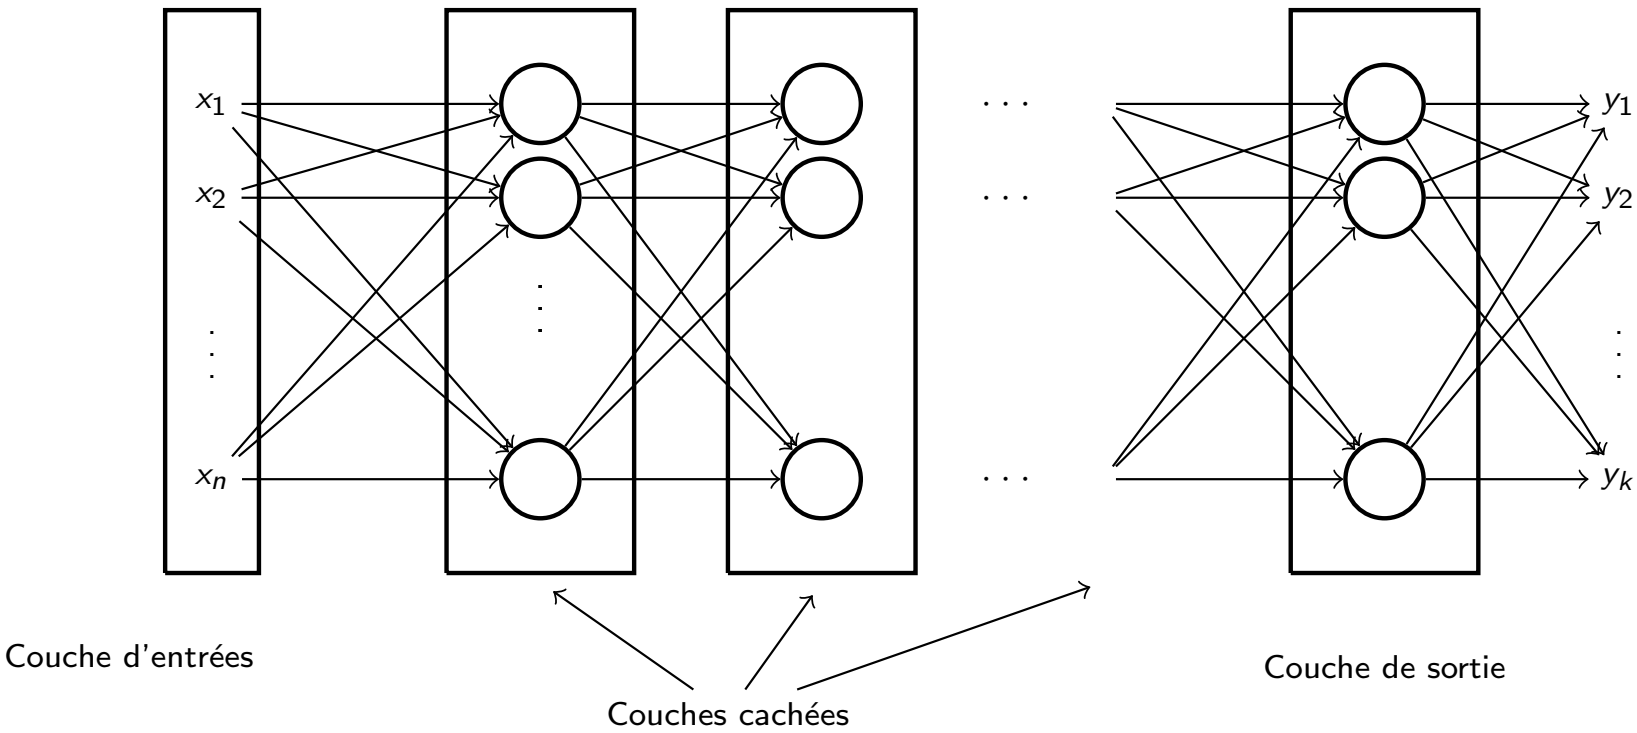

Apprentissage des paramètres

- Question :
  Comment déterminer les paramètres des neurones $w = (w_1, w_2, \cdots, w_p)$ et b.
- Réponse :
  Algorithme du Perceptron (voir le chapitre annexe correspondant).

Outline

Deep Learning = (plusieurs) couches cachées.

Exemples de réseaux connus

Deep = Many hidden layers

http://cs231n.stanford.edu/slides/winter1516_lecture8.pdf

8 layers

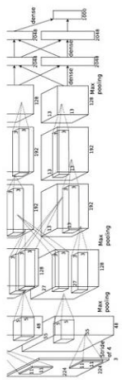

16.4%

AlexNet (2012)

19 layers

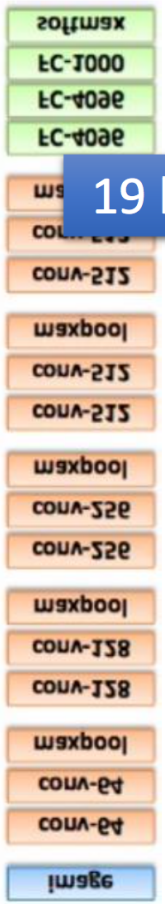

7.3%

VGG (2014)

22 layers

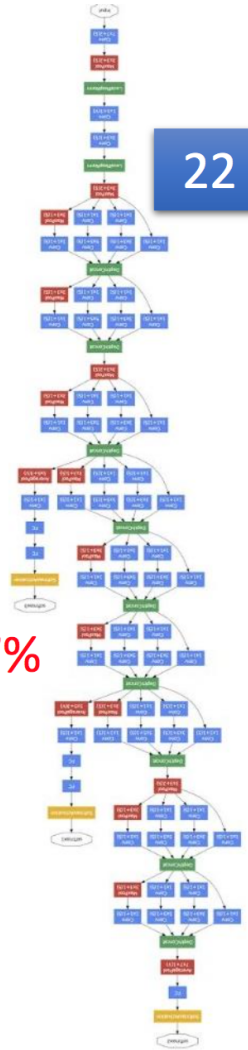

6.7%

GoogleNet (2014)

Exemples de réseaux connus

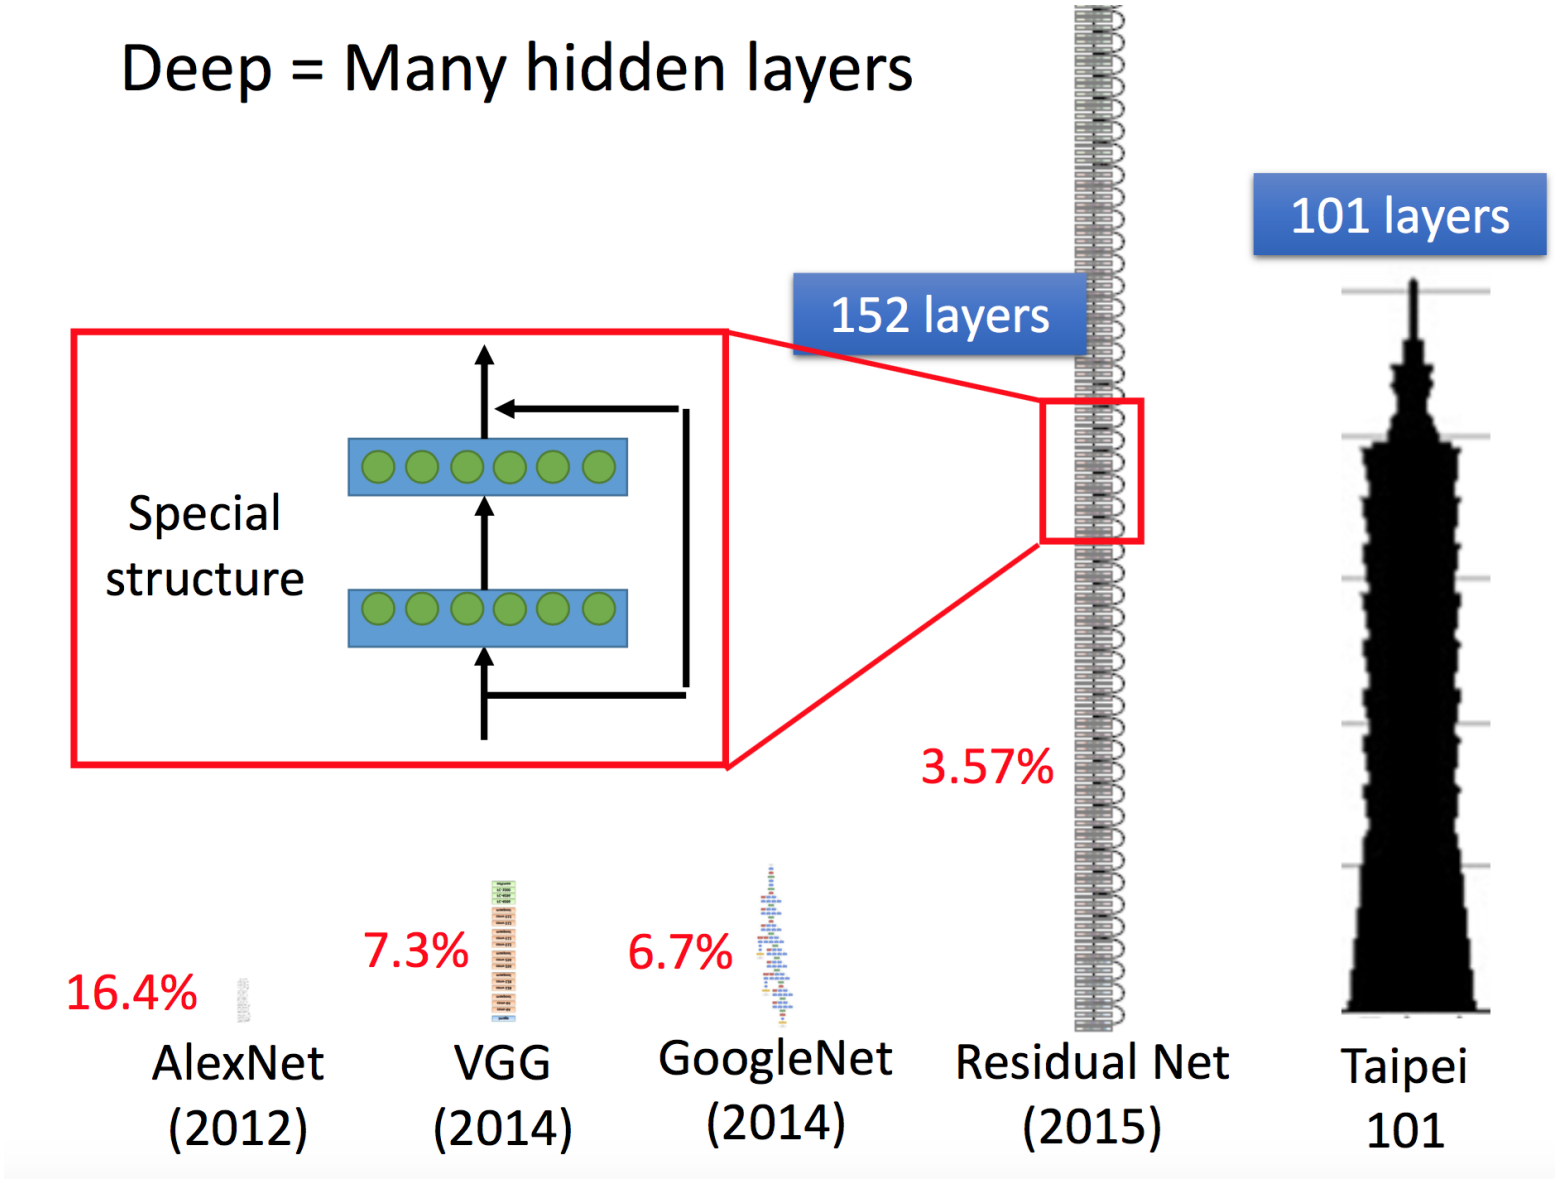

Et un réseau défini au LaBRI[1]

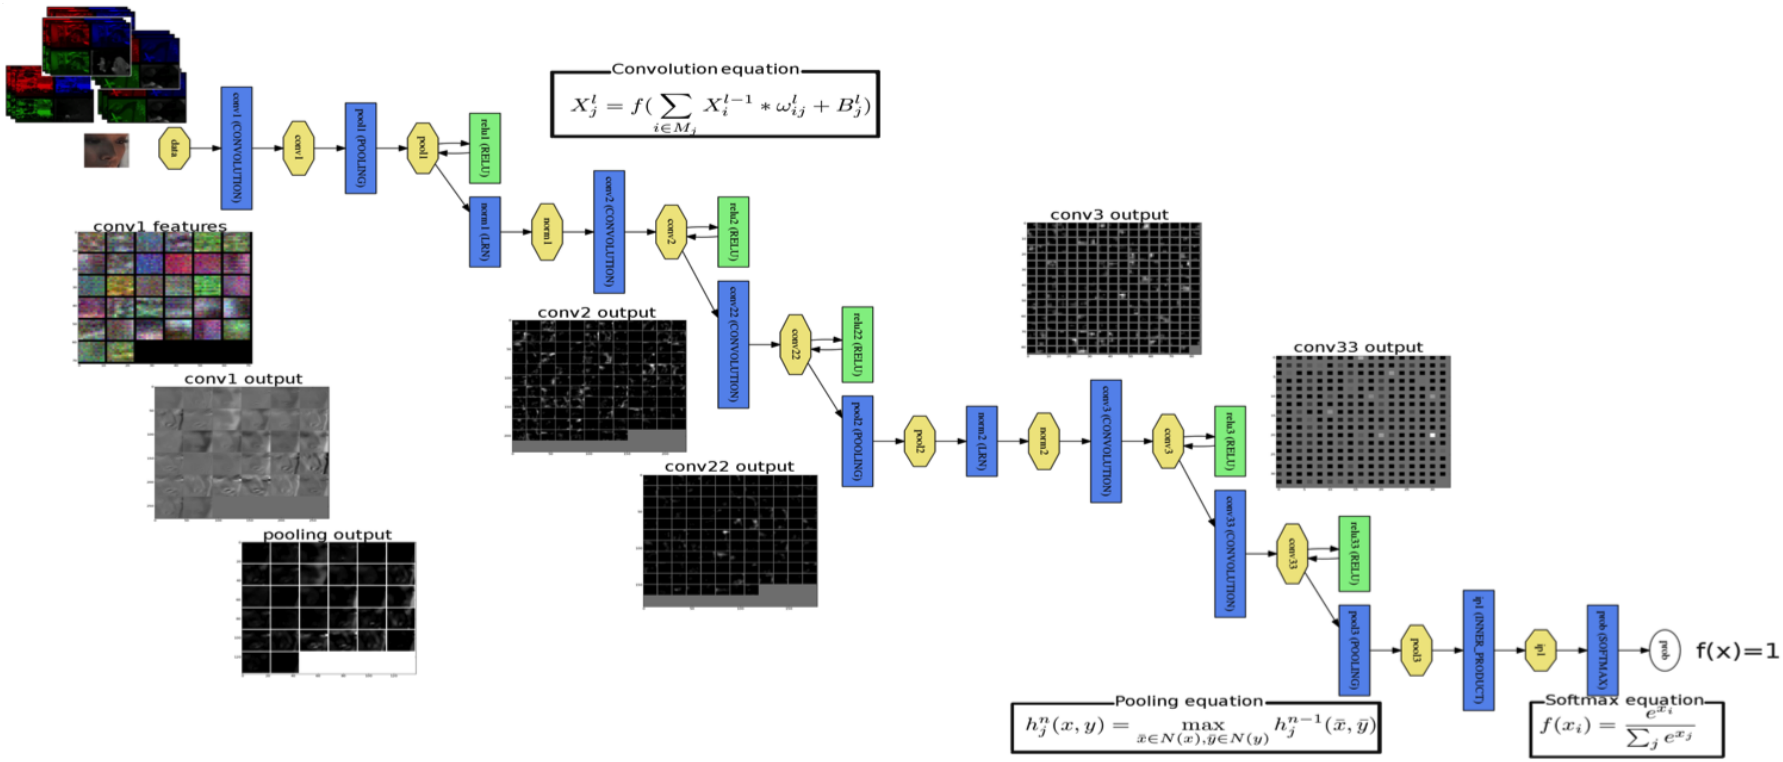

[1]Deep Saliency: Prediction of Interestingness in Video with CNN S. Chaabouni, J. Benois-Pineau, A. Zemmari, and C. Ben Amar In Visual Content Indexing and Retrieval with Psycho-Visual Models Springer 2017

Pourquoi le deep

Un exemple :

- Apprendre une fonction AND : une seule couche
- Apprendre une fonction OR : une seule couche
- Apprendre une fonction XOR : une seule couche ne suffit pas

...

Pourquoi le deep

Un exemple :

- Apprendre une fonction AND : une seule couche
- Apprendre une fonction OR : une seule couche
- Apprendre une fonction XOR : une seule couche ne suffit pas

...

Pourquoi le deep

Un exemple :

- Apprendre une fonction AND : une seule couche
- Apprendre une fonction OR : une seule couche
- Apprendre une fonction XOR : une seule couche ne suffit pas

...

Pourquoi le deep

Théorème d'universalité

Toute fonction continue $f : \mathbb{R}^n \to \mathbb{R}^n$ peut être réalisée par un réseau de neurone à une couche cachée.

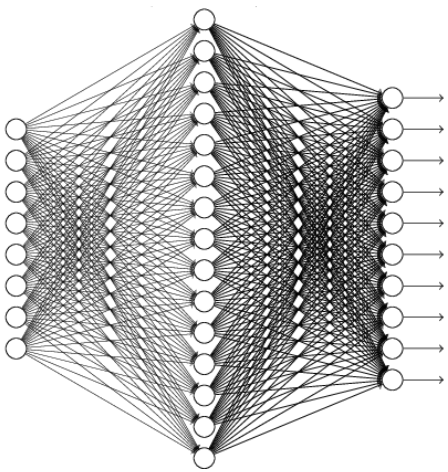

Question : pourquoi des réseaux profonds au lieu de réseaux à une couche ?

Pourquoi le deep

Théorème d'universalité

Toute fonction continue $f : \mathbb{R}^n \to \mathbb{R}^n$ peut être réalisée par un réseau de neurone à une couche cachée.

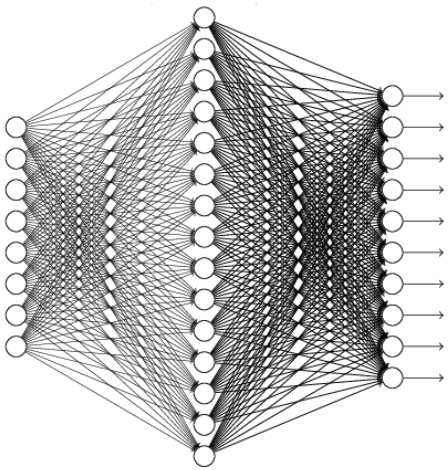

Question : pourquoi des réseaux profonds au lieu de réseaux à une couche ?

Couche de sortie

La couche de Softmax :
Ce que nous avons vu jusque là :

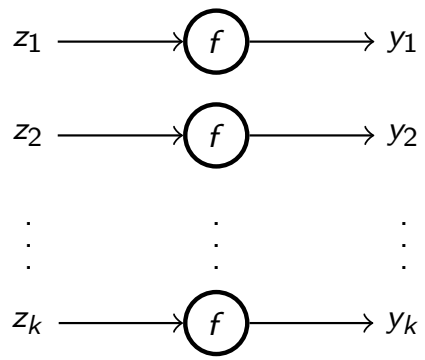

Problème : les sorties y_i prennent des valeurs quelconques et difficiles à interpréter ...
Solution : transformer les sorties en "probabilités".

Couche de sortie

La couche de Softmax :
Ce que nous avons vu jusque là :

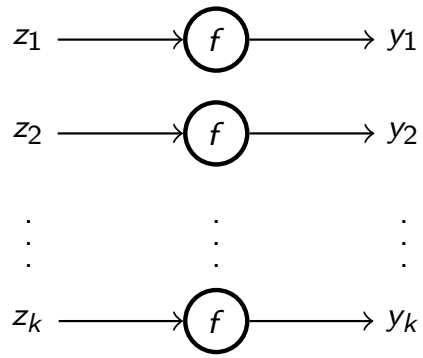

Problème : les sorties y_i prennent des valeurs quelconques et difficiles à interpréter ...
Solution : transformer les sorties en "probabilités".

Couche de sortie

La couche de Softmax :
Solution : ajouter une couche de Softmax :

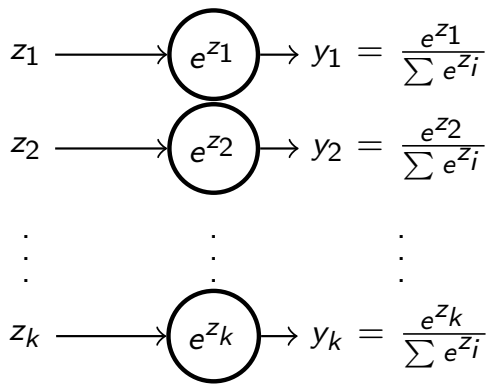

On obtient ainsi une distribution de probabilité :

- $0 < y_i < 1, \ \forall i,$
- $\sum_{i=1}^{k} y_i = 1.$

Exemple : reconnaissance d'écriture

Input **Output**

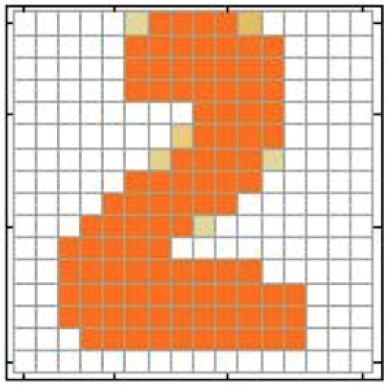

Exemple : reconnaissance d'écriture

Input **Output**

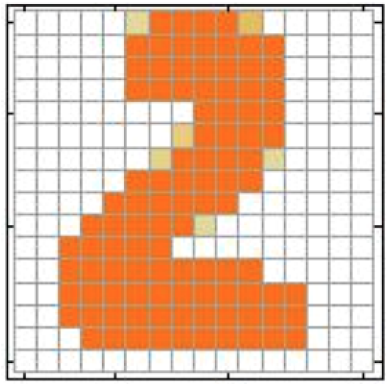

16 x 16 = 256

Exemple : reconnaissance d'écriture

Input

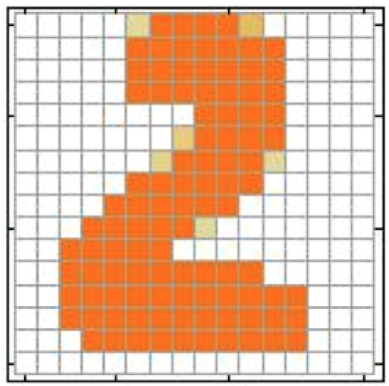

16 x 16 = 256

x_1

x_2

$\vdots$

x_{256}

Output

Exemple : reconnaissance d'écriture

Input **Output**

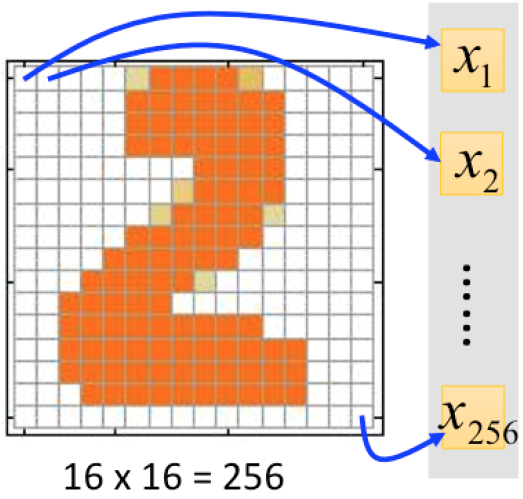

Exemple : reconnaissance d'écriture

Input **Output**

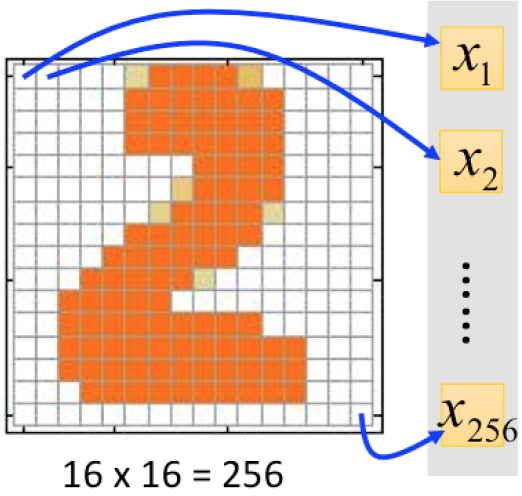

16 x 16 = 256

Ink → 1

No ink → 0

Exemple : reconnaissance d'écriture

Input

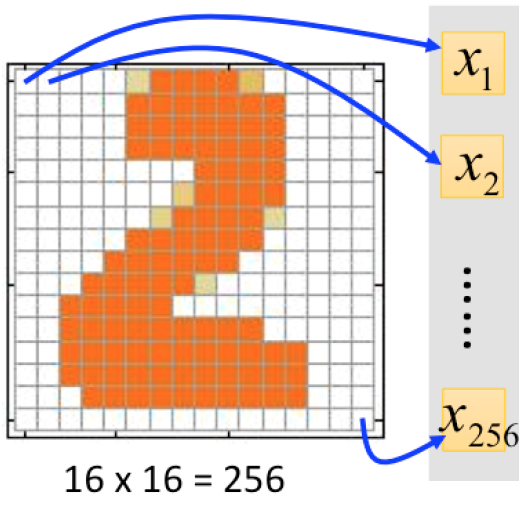

16 x 16 = 256

Ink → 1

No ink → 0

Output

y_1 is 1

y_2 is 2

y_{10} is 0

Each dimension represents the confidence of a digit.

Exemple : reconnaissance d'écriture

Input

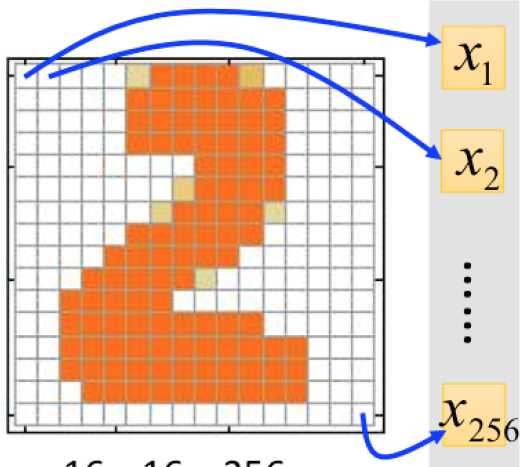

16 x 16 = 256

Ink → 1

No ink → 0

Output

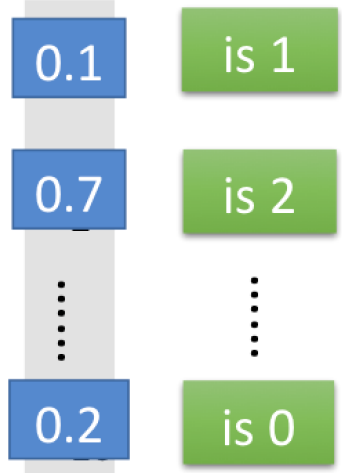

Each dimension represents the confidence of a digit.

Exemple : reconnaissance d'écriture

Input

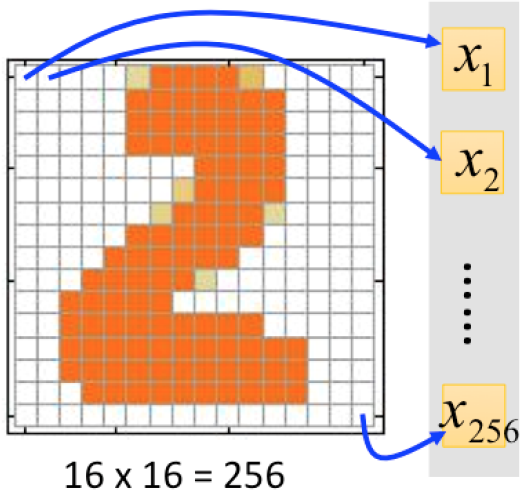

16 x 16 = 256

Ink → 1

No ink → 0

Output

Each dimension represents the confidence of a digit.

Exemple : reconnaissance d'écriture

Input

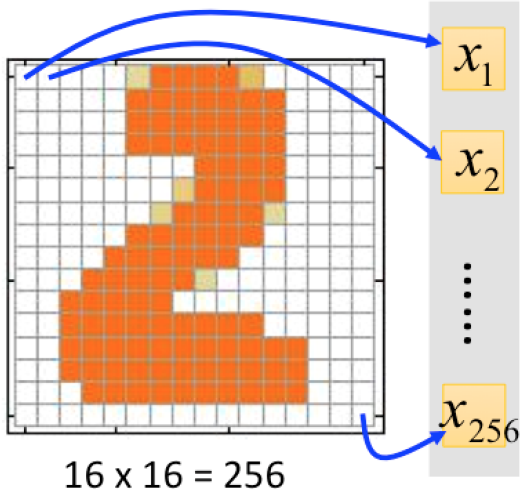

16 x 16 = 256

Ink → 1

No ink → 0

Output

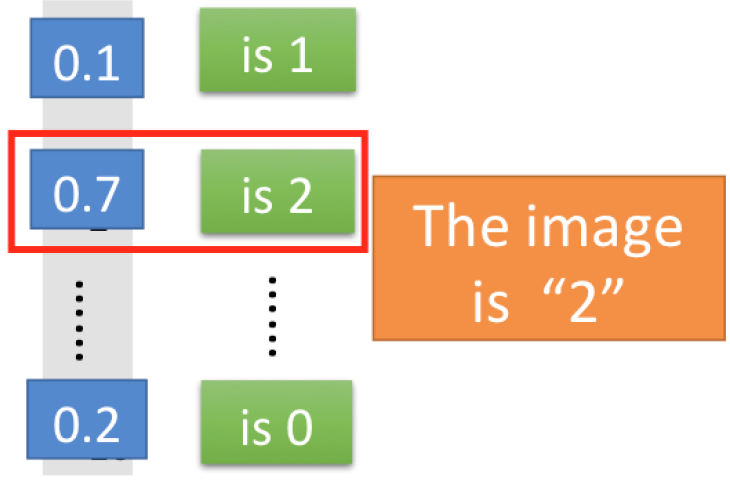

Each dimension represents the confidence of a digit.

Exemple : reconnaissance d'écriture

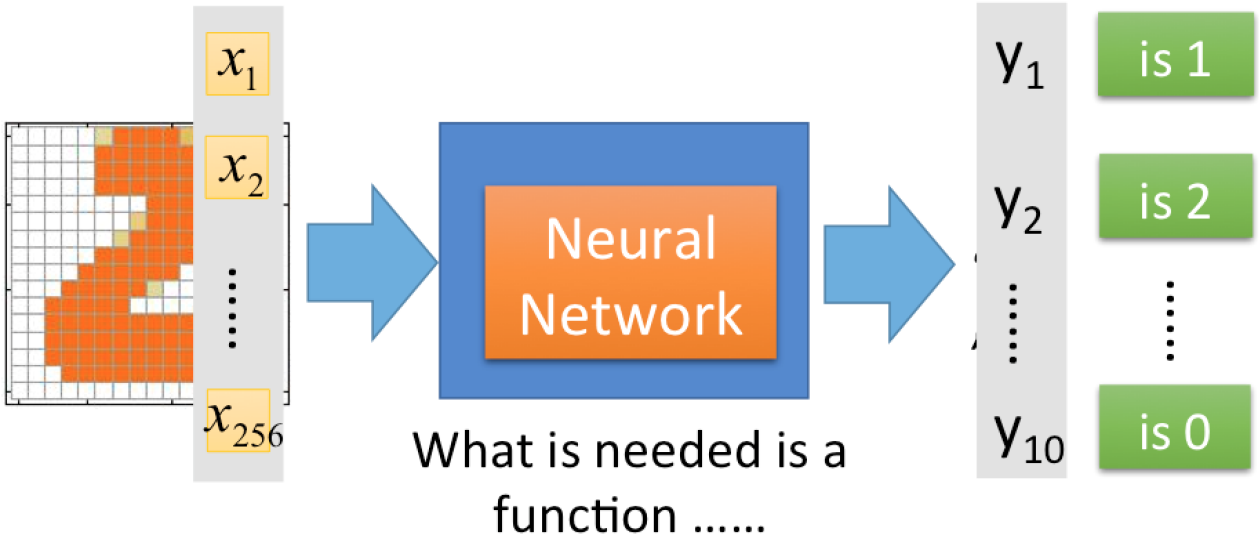

Questions/Réponses

- Combien de couches mettre dans le réseaux ?
- Essayer, apprendre des erreurs et avoir de l'intuition ...
- Peut-on concevoir la structure du réseau ?
- Réseaux de neurones à convolution ...

Questions/Réponses

- Combien de couches mettre dans le réseaux ?
- Essayer, apprendre des erreurs et avoir de l'intuition ...
- Peut-on concevoir la structure du réseau ?
- Réseaux de neurones à convolution ...

Questions/Réponses

- Combien de couches mettre dans le réseaux ?
- Essayer, apprendre des erreurs et avoir de l'intuition ...
- Peut-on concevoir la structure du réseau ?
- Réseaux de neurones à convolution ...

Questions/Réponses

- Combien de couches mettre dans le réseaux ?
- Essayer, apprendre des erreurs et avoir de l'intuition ...
- Peut-on concevoir la structure du réseau ?
- Réseaux de neurones à convolution ...

Données d'entrainement

Les Images et leurs étiquettes :

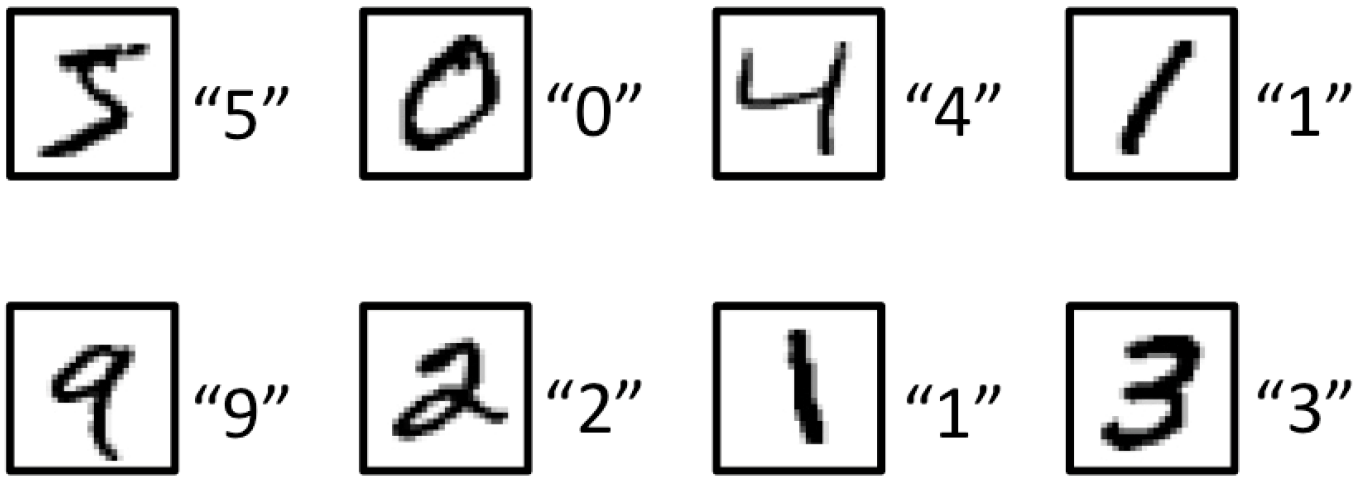

Objectif de l'entrainement

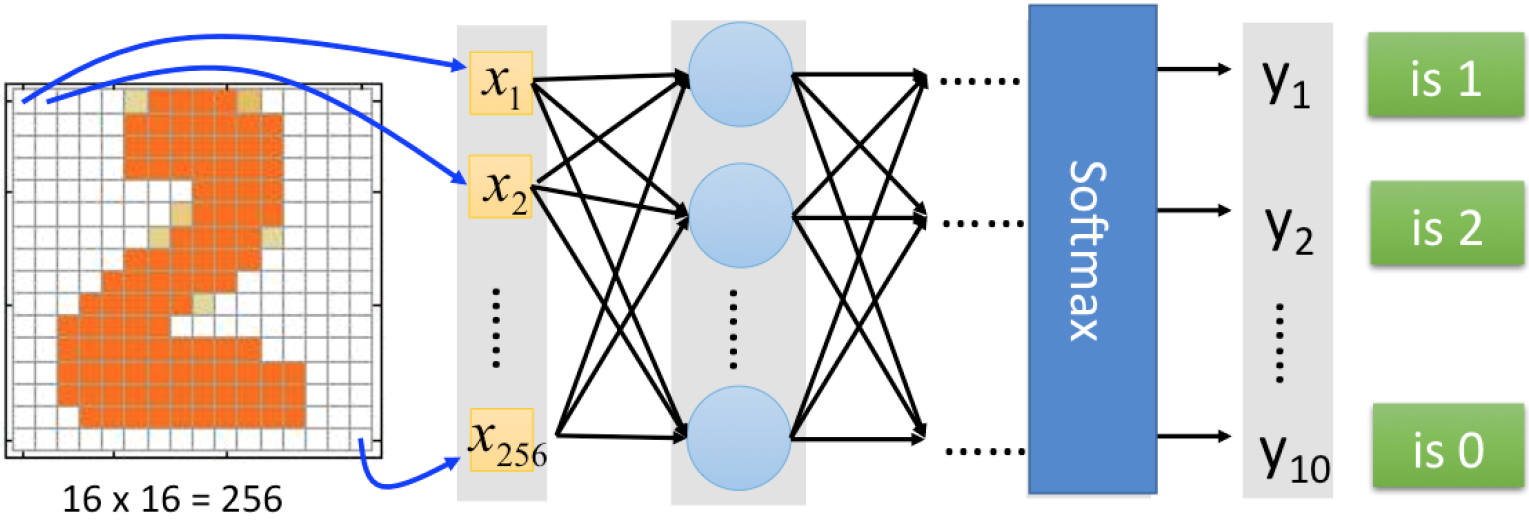

Ink → 1

No ink → 0

Input: 

$\Rightarrow$ y_1 a la plus grande valeur,

Input: 

$\Rightarrow$ y_2 a la plus grande valeur,

Objectif de l'entrainement

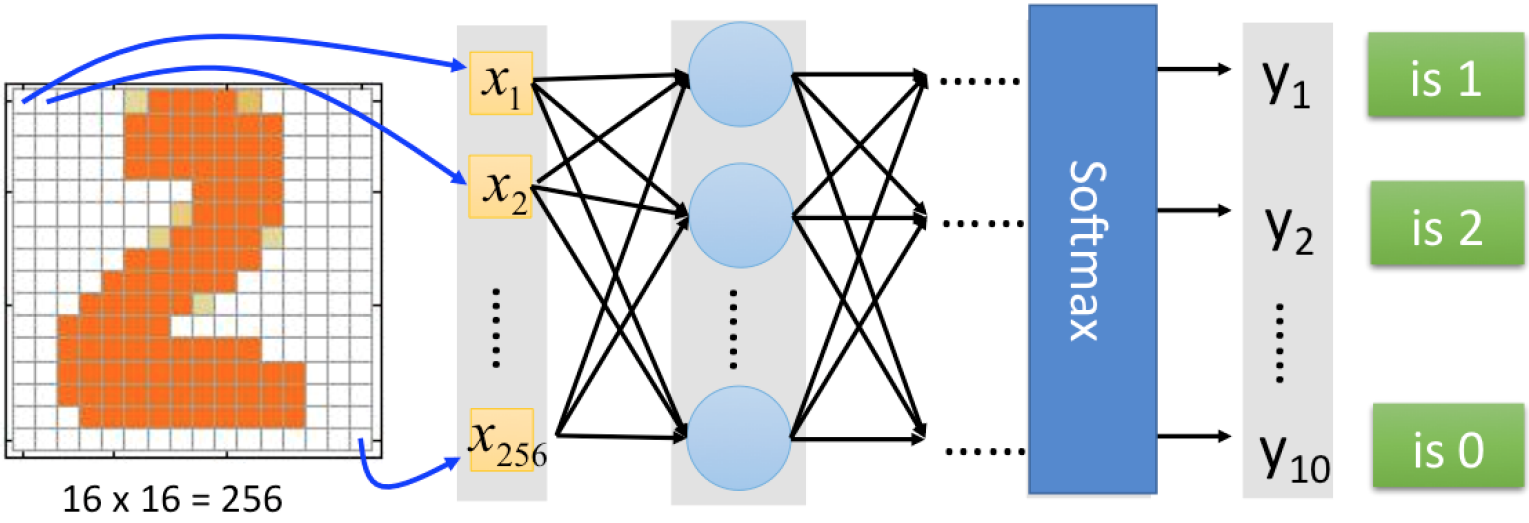

Ink → 1

No ink → 0

Input: 

$\Rightarrow$ y_1 a la plus grande valeur,

Input: 

$\Rightarrow$ y_2 a la plus grande valeur,

Fonction de perte (Loss Function)

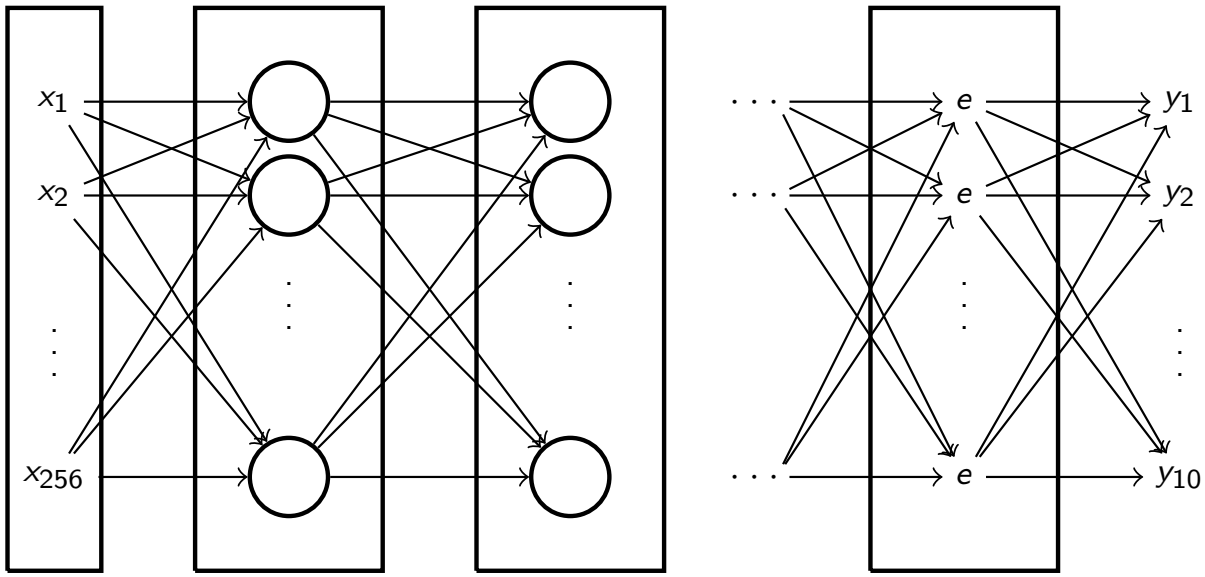

Couche de Softmax

Fonction de perte (Loss Function)

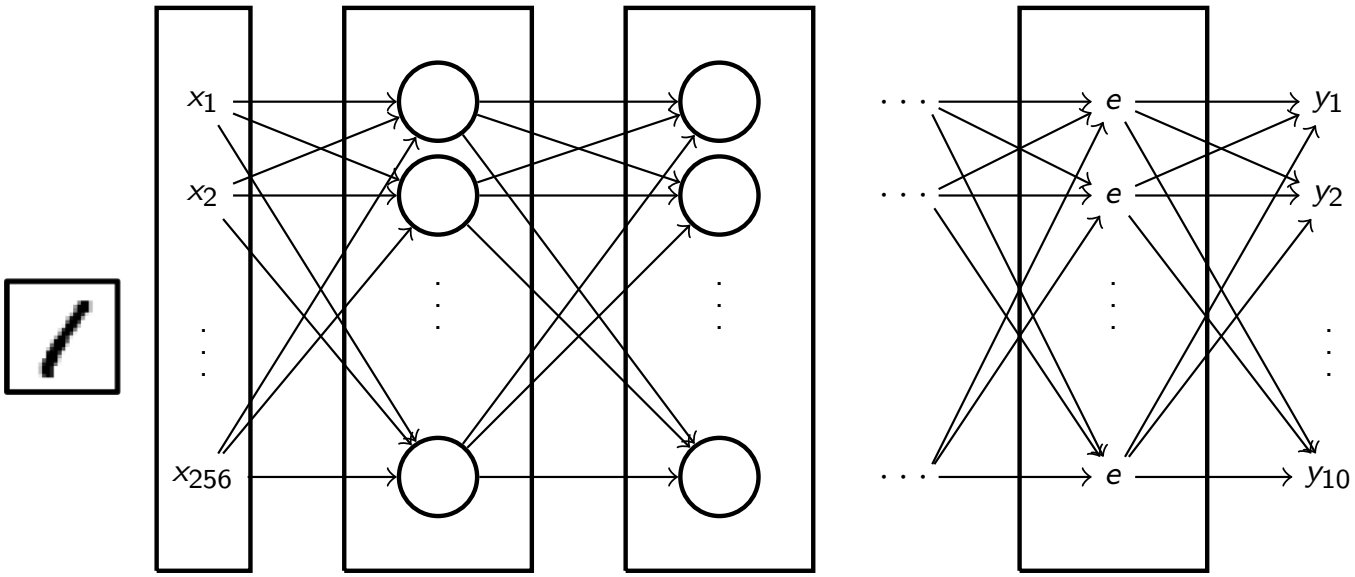

Couche de Softmax

Fonction de perte (Loss Function)

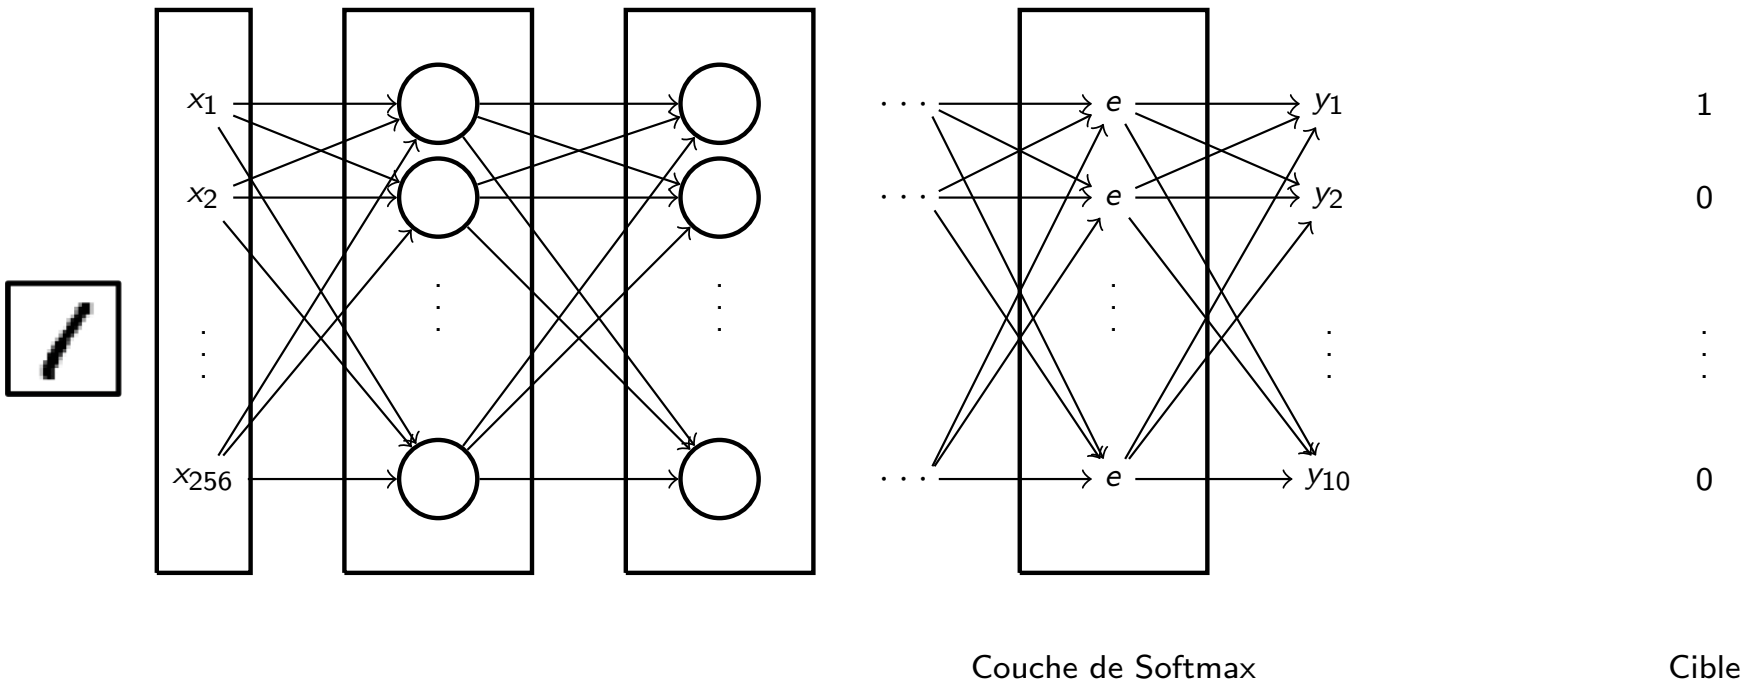

Fonction de perte (Loss Function)

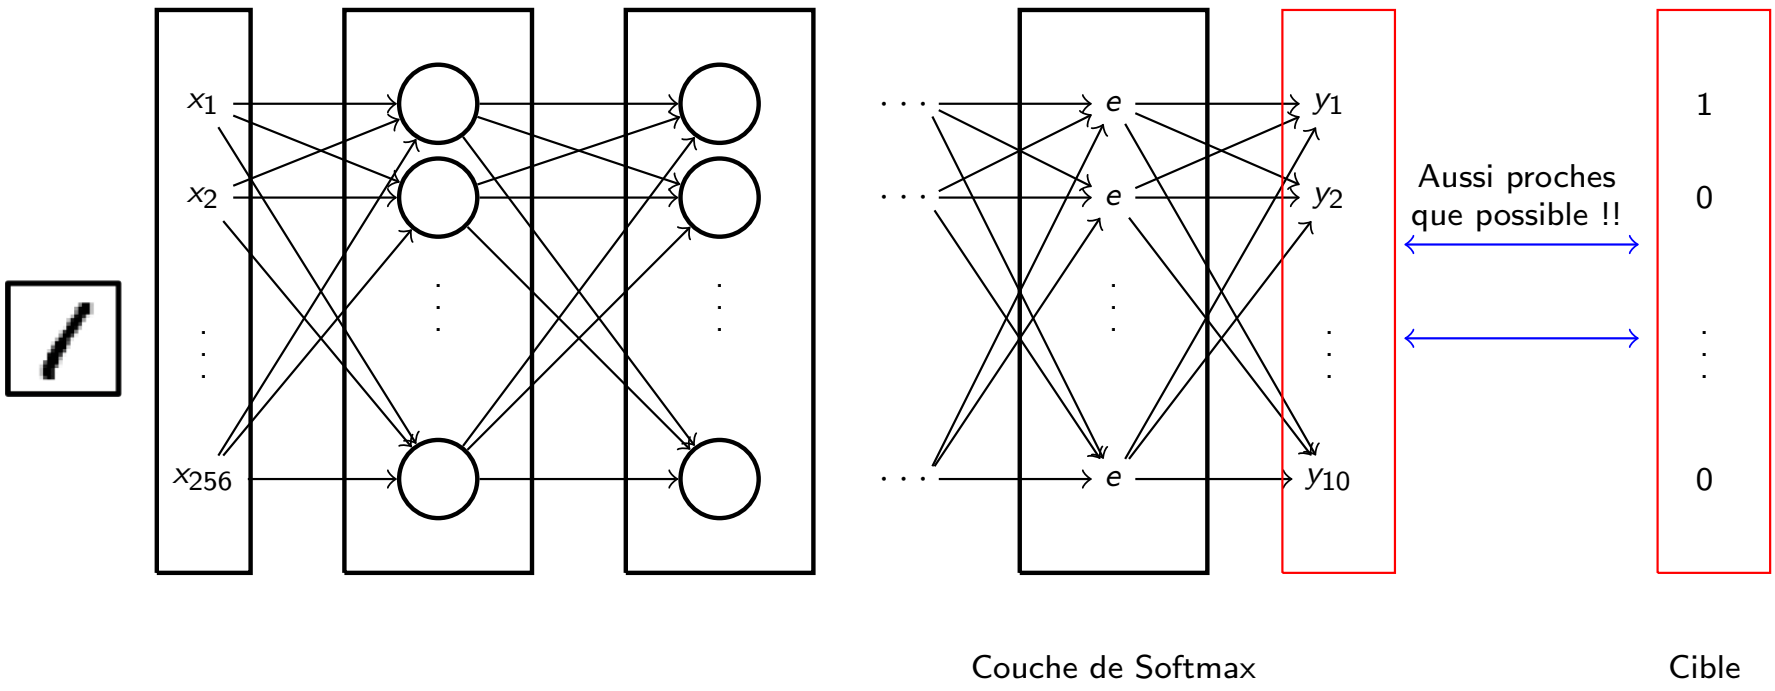

Fonction de perte (Loss Function)

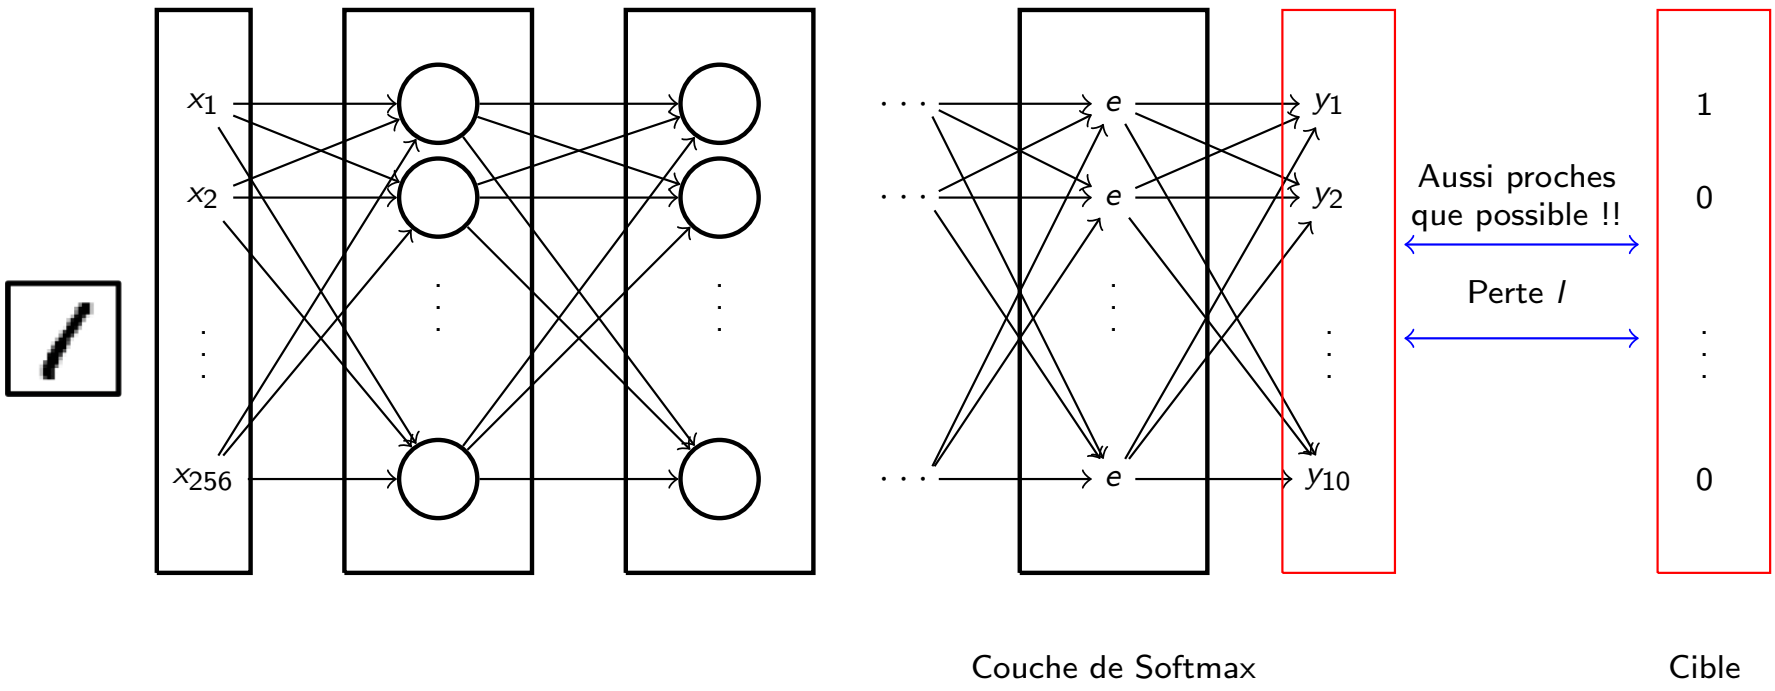

Fonction de perte (Loss Function)

- La fonction de perte peut être :
  - La somme des carrés des écarts :

$$I = \sum_{i=1}^{10} (y_i - \hat{y}_i)^2 .$$

  - La *cross entropy* :

$$I = -\sum_{i=1}^{10} \hat{y}_i \ln(y_i).$$

Une bonne fonction (définie par les paramètres que l'on met sur le réseau) doit minimiser la *valeur totale* de la fonction de perte ...

Perte totale

Pour tout l'ensemble de traitement :

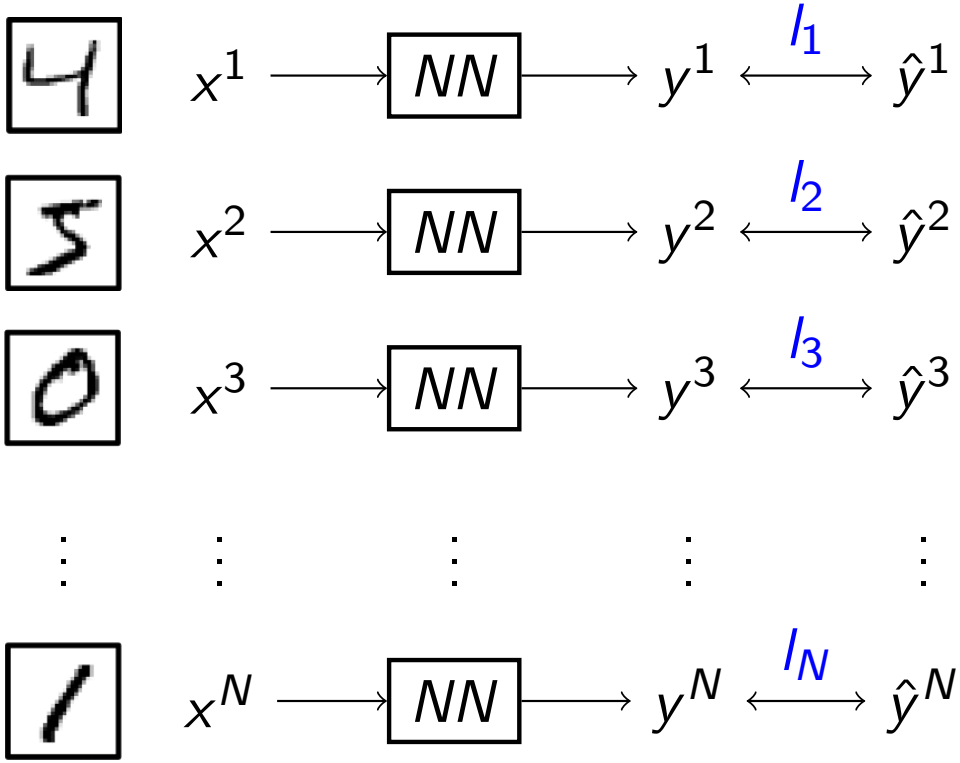

Perte totale :

$$L = \sum_{i=1}^{N} l_i.$$

Objectif :

Minimiser cette fonction.

Outline

Apprentissage ?

Comment choisir la meilleure fonction de classification ?
Trouver les meilleurs paramètres θ qui minimisent la perte totale L.

- Solution 1. : Enumérer toutes les possibilités $\rightarrow$ infaisable !!
- Solution 2. : Descente du Gradient.

Apprentissage ?

Comment choisir la meilleure fonction de classification ?
Trouver les meilleurs paramètres θ qui minimisent la perte totale L.

- Solution 1. : Enumérer toutes les possibilités $\rightarrow$ infaisable !!
- Solution 2. : Descente du Gradient.

Descente du gradiant

Objectif : déterminer les paramètres θ du réseau qui minimisent la perte total L.

Descente du gradient

Trouver les paramètres θ du réseau qui minimisent la fonction de perte totale L.

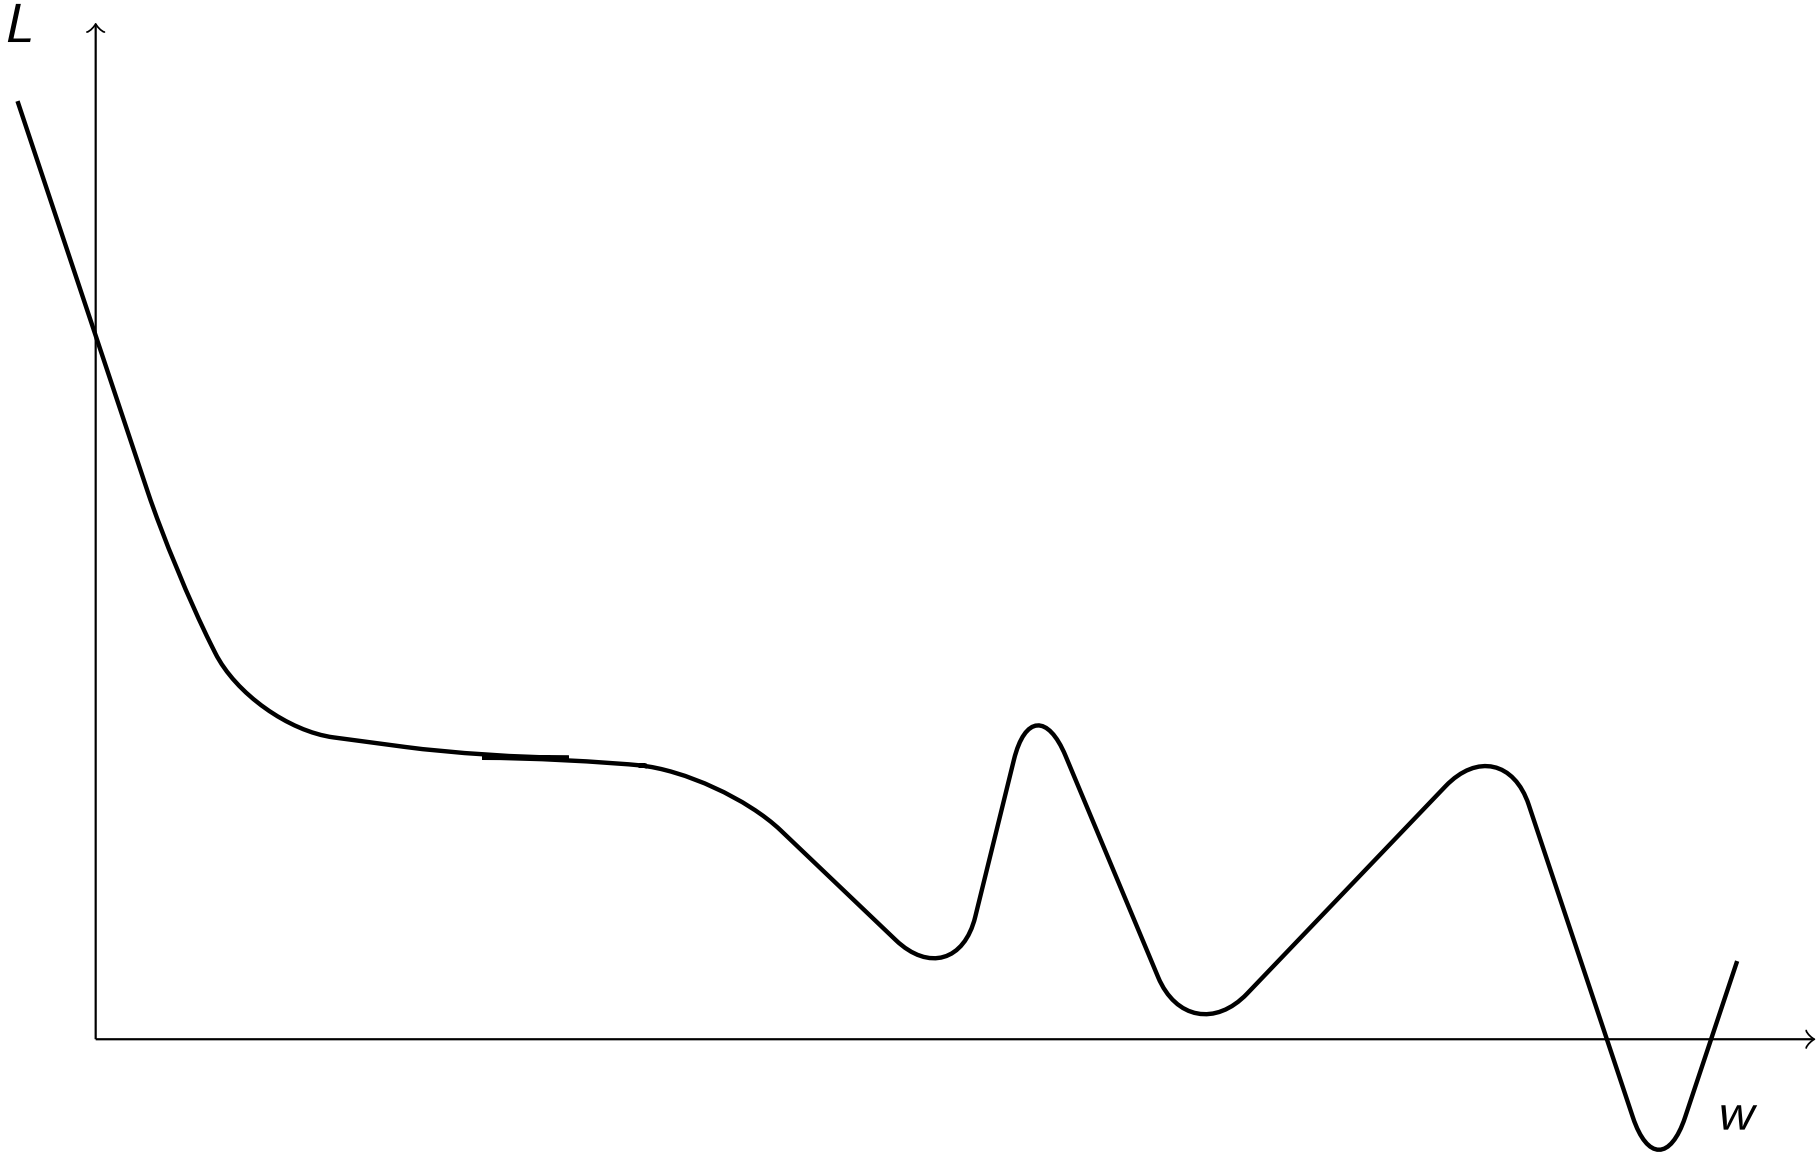

Descente du gradient

Trouver les paramètres θ du réseau qui minimisent la fonction de perte totale L.

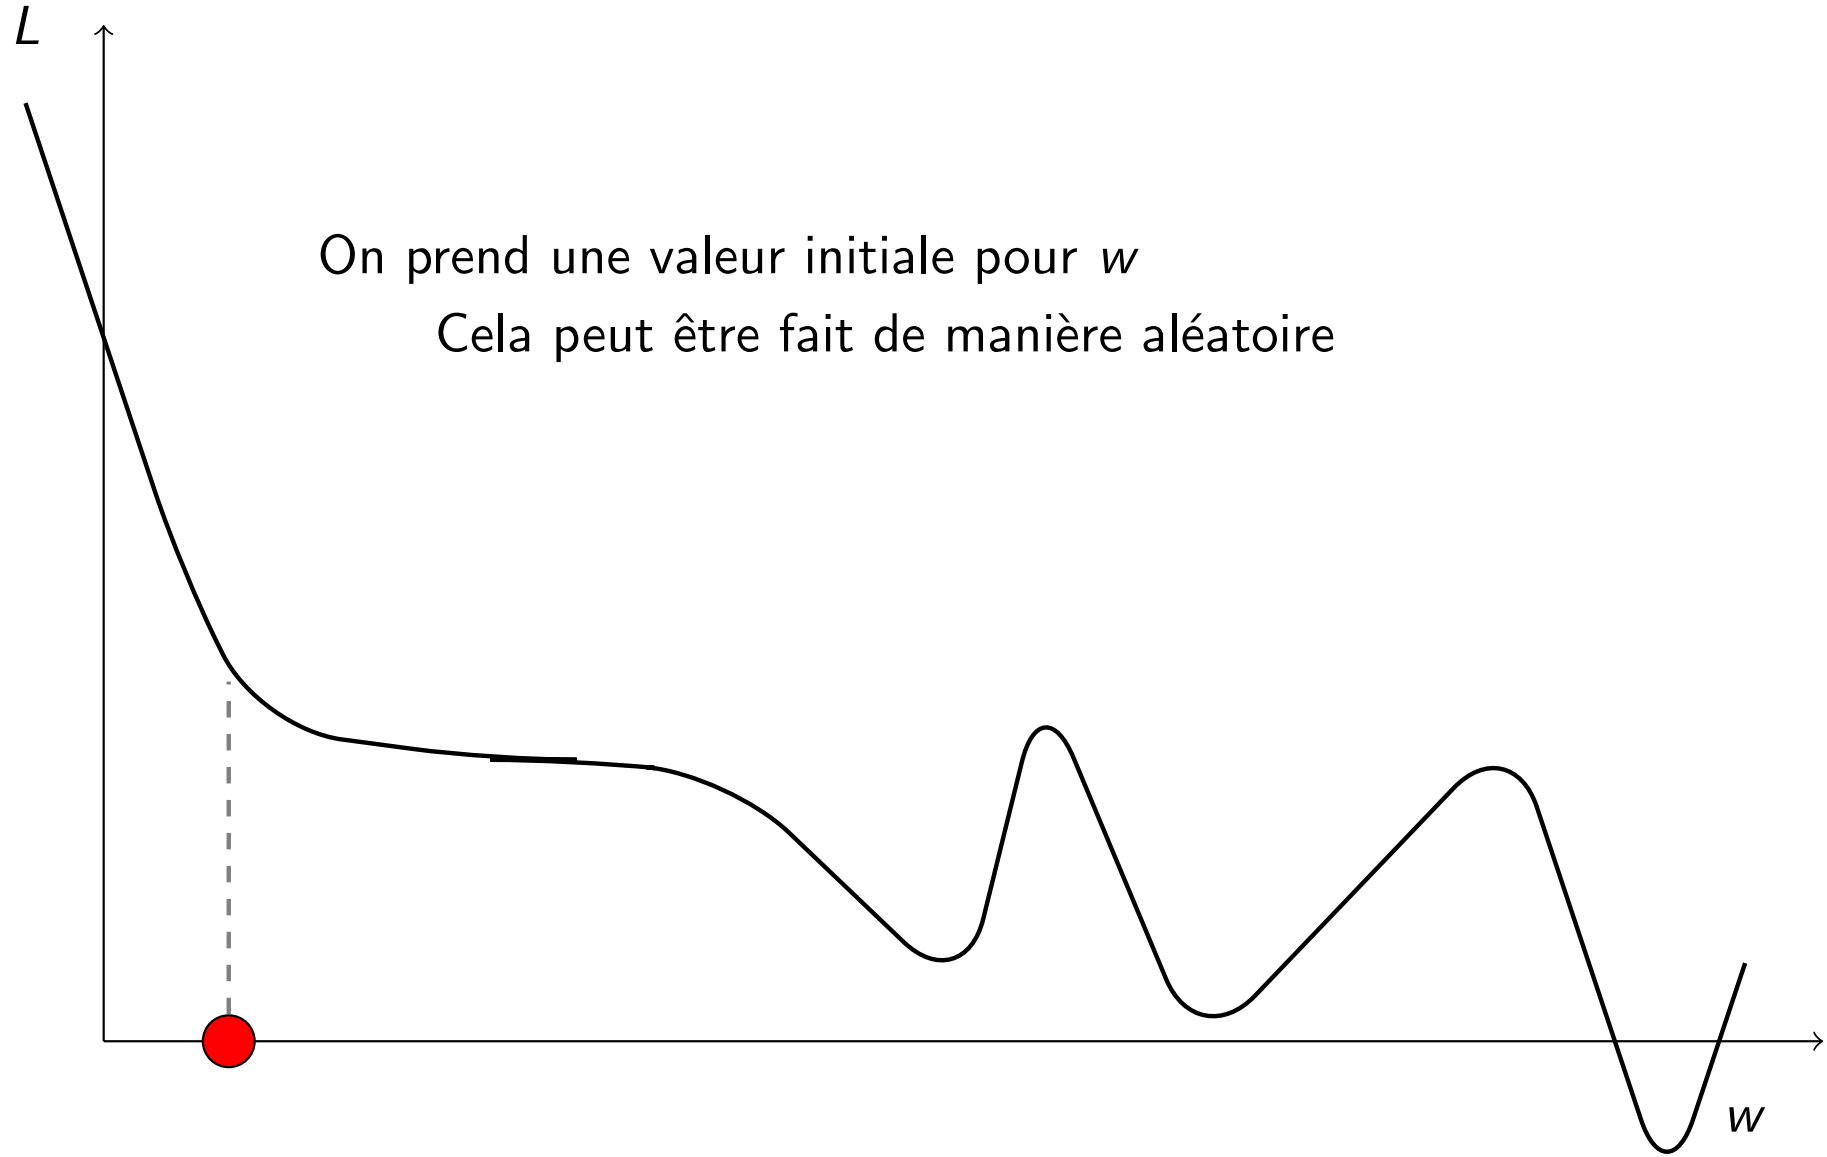

Descente du gradient

Trouver les paramètres θ du réseau qui minimisent la fonction de perte totale L.

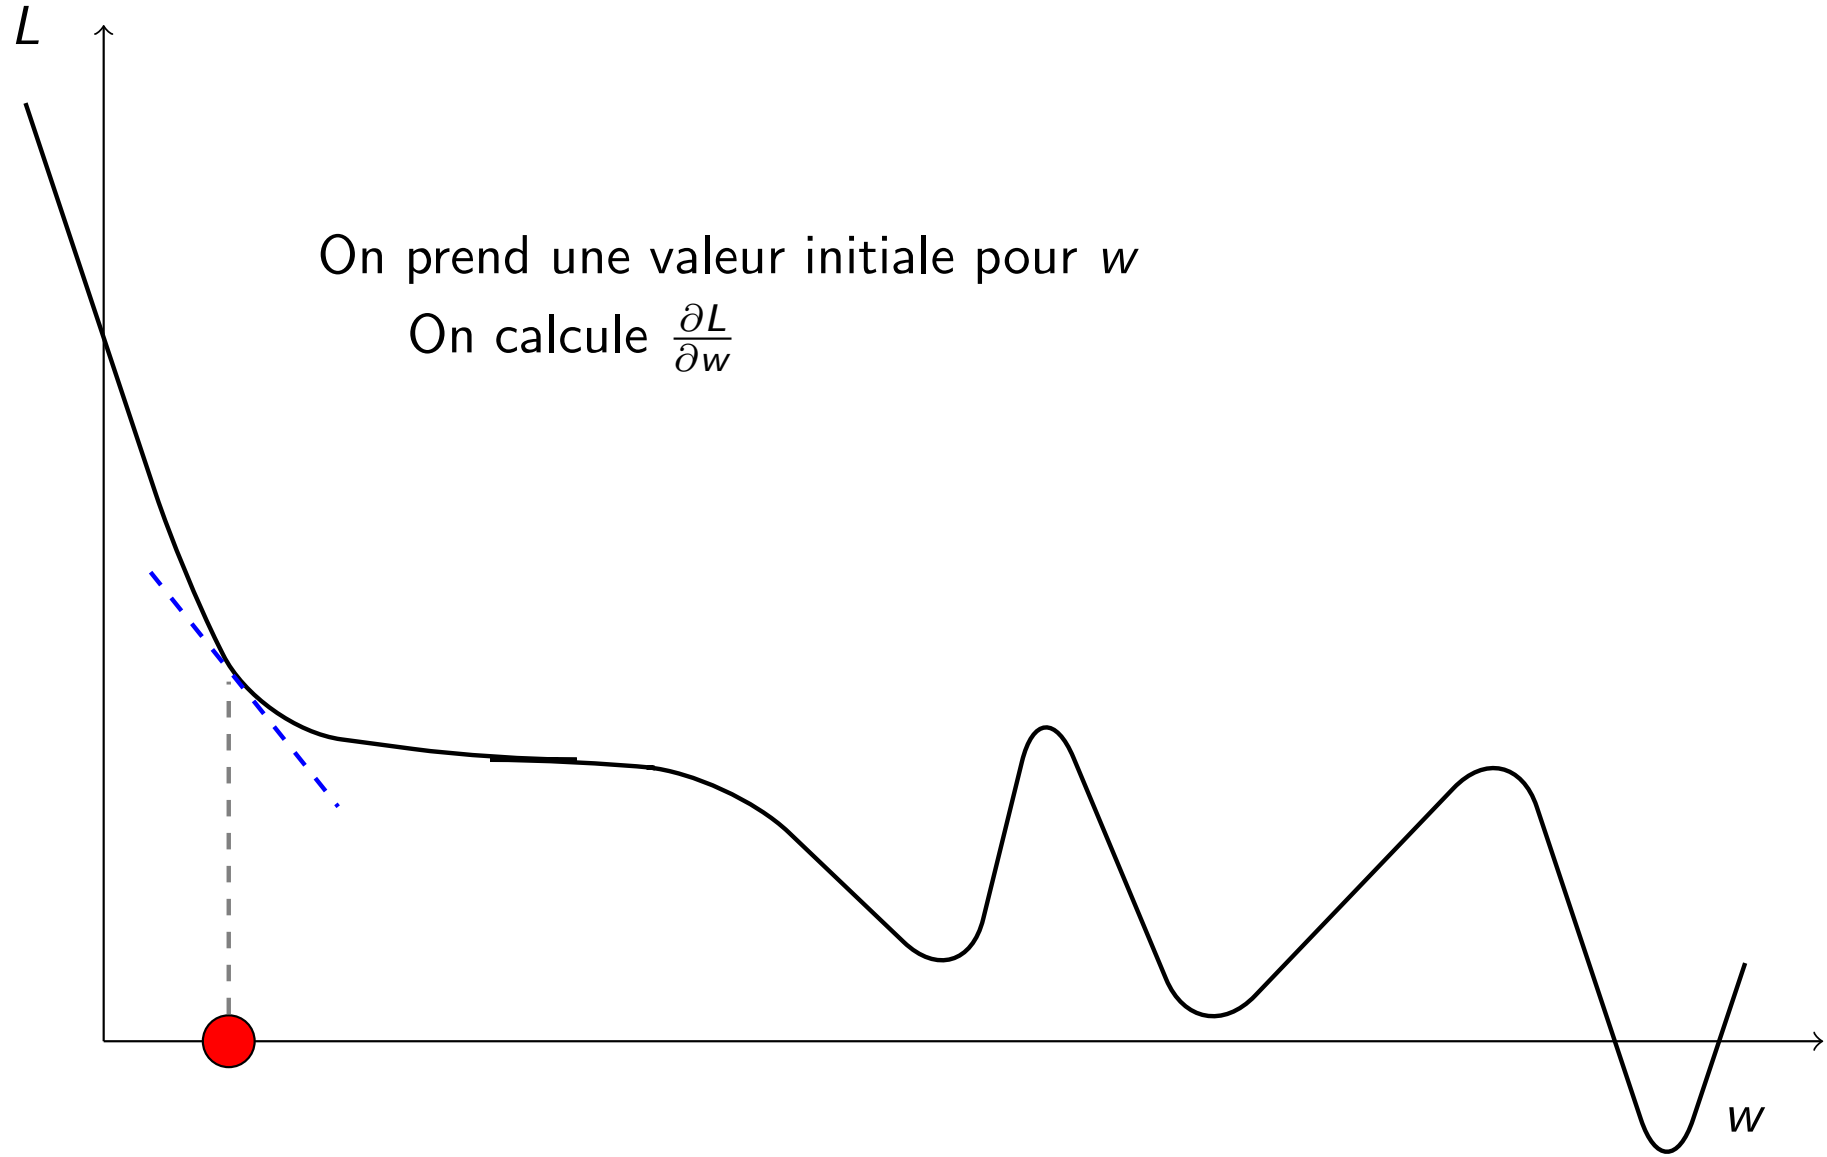

Descente du gradient

Trouver les paramètres θ du réseau qui minimisent la fonction de perte totale L.

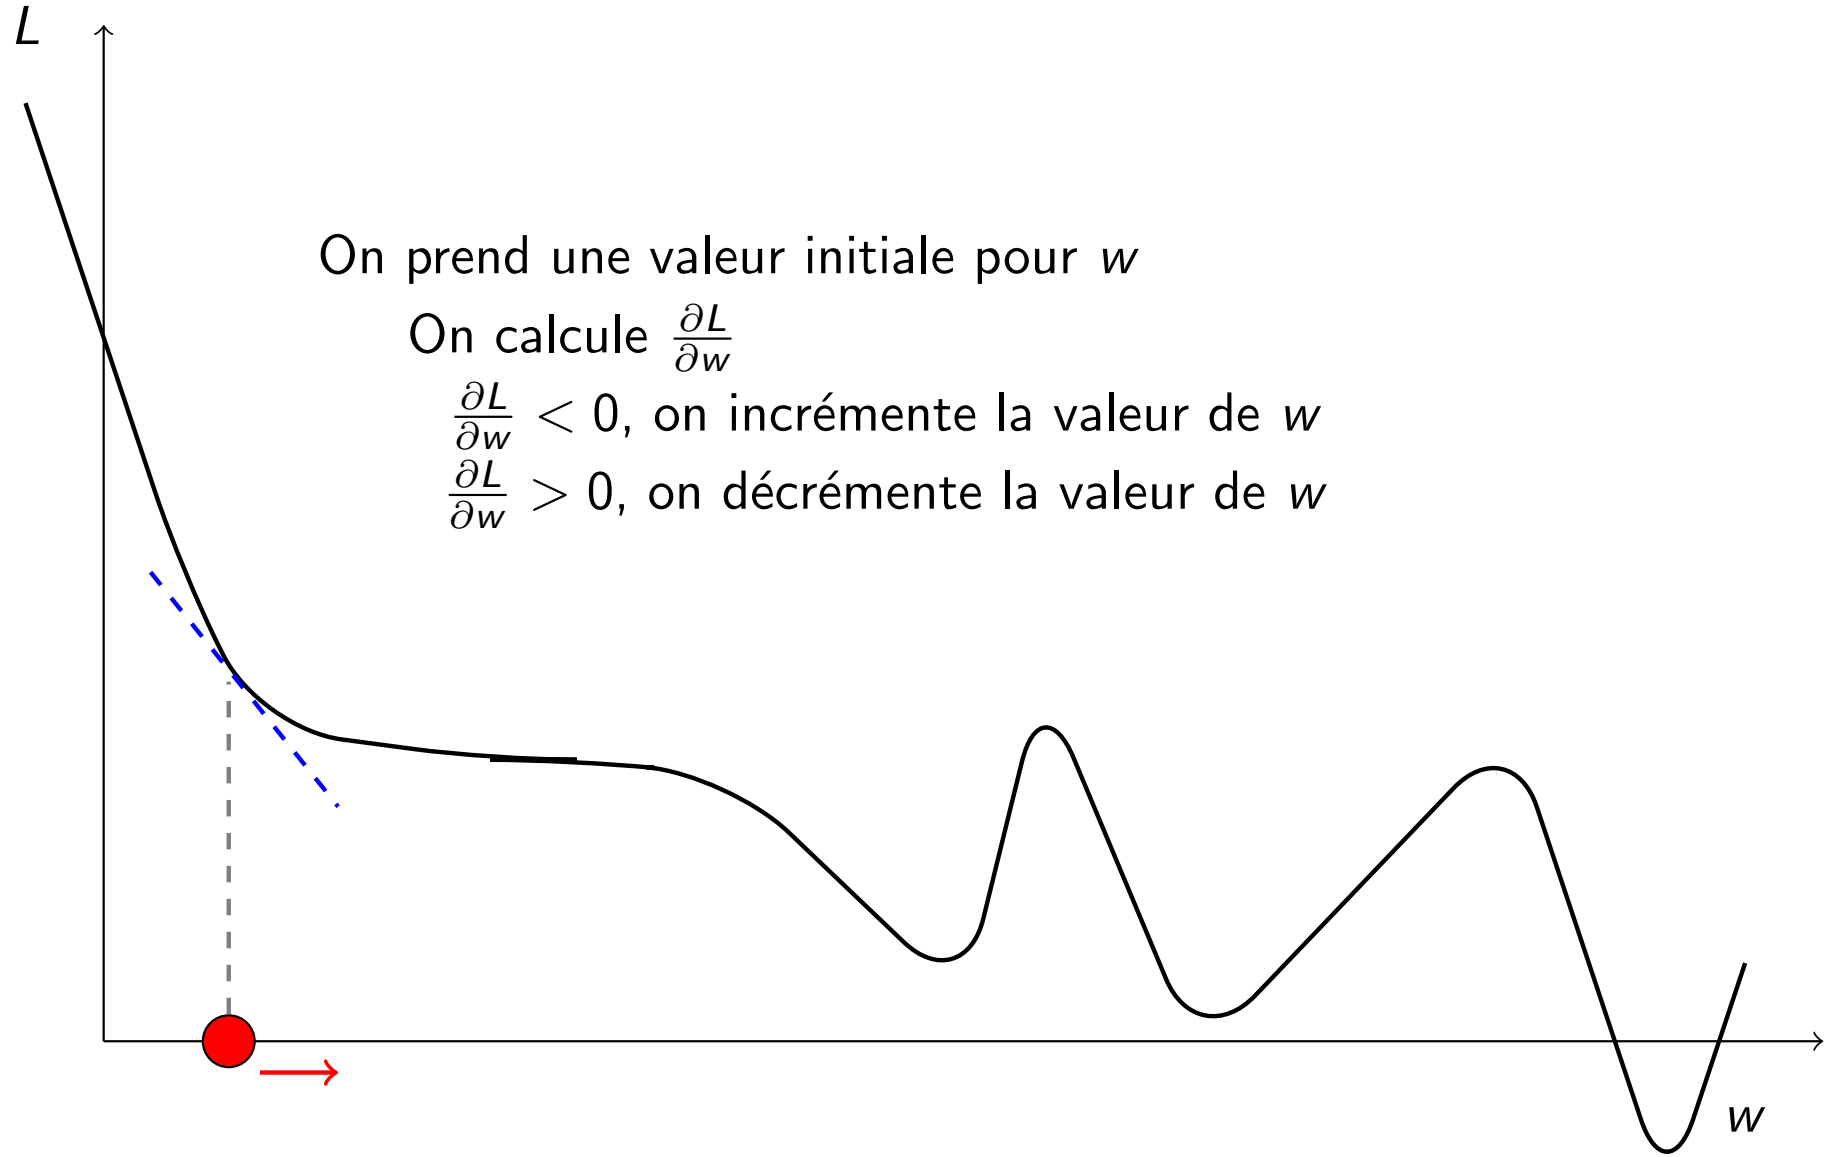

Descente du gradient

Trouver les paramètres θ du réseau qui minimisent la fonction de perte totale L.

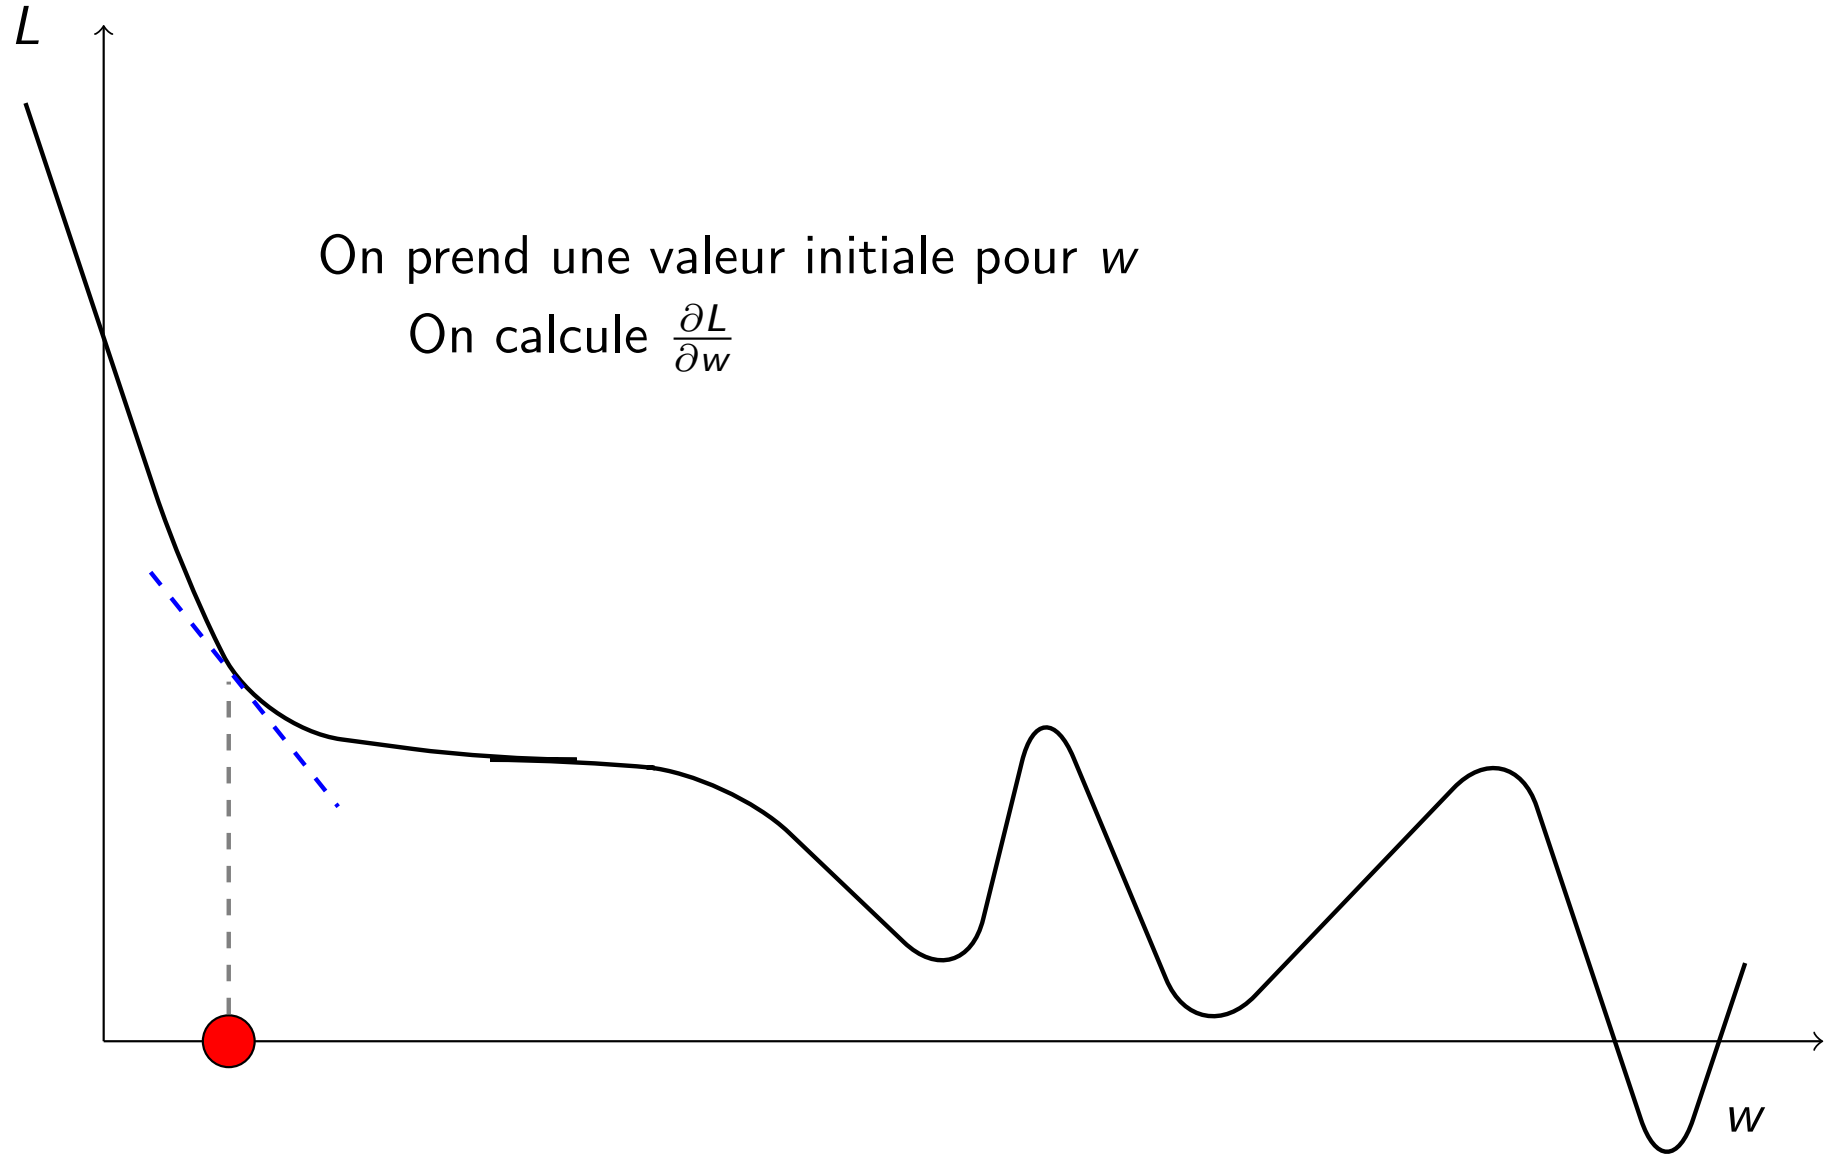

Descente du gradient

Trouver les paramètres θ du réseau qui minimisent la fonction de perte totale L.

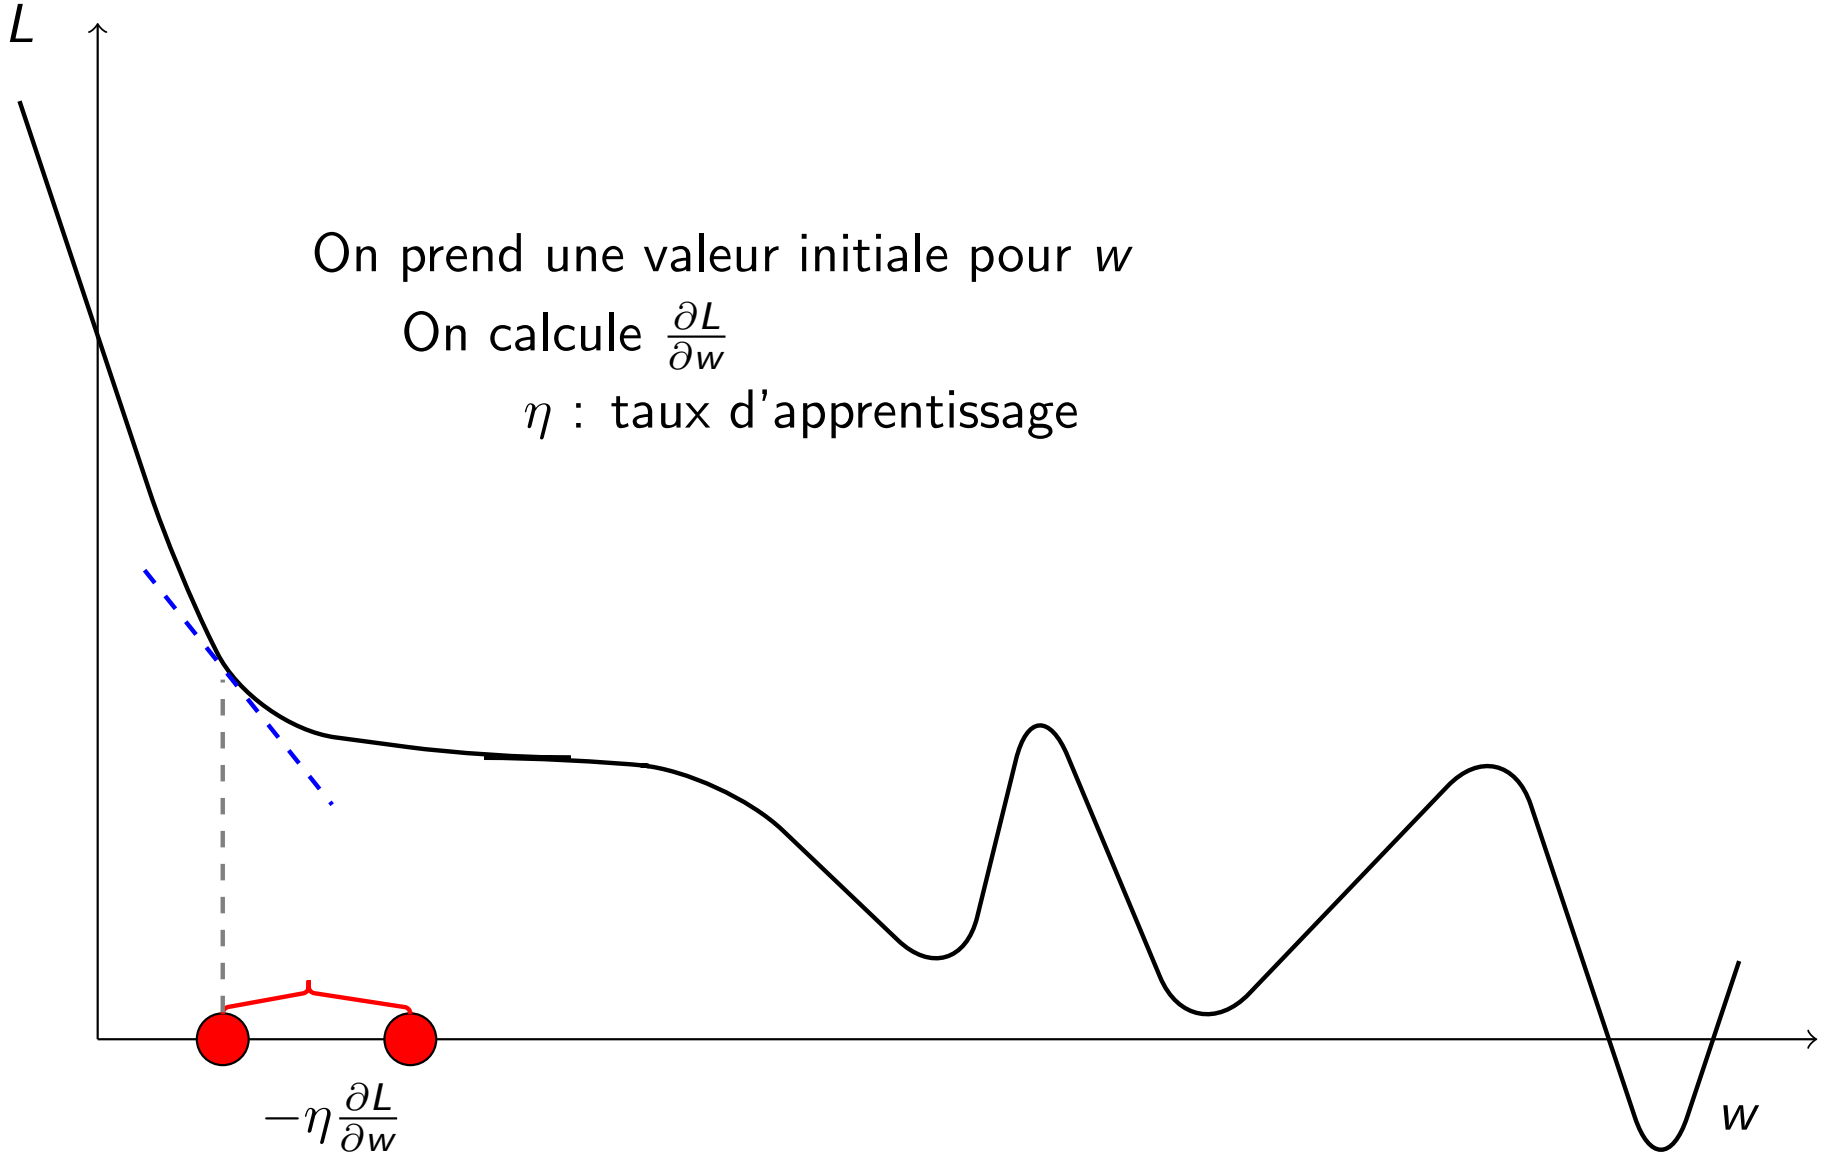

Descente du gradient

Trouver les paramètres θ du réseau qui minimisent la fonction de perte totale L.

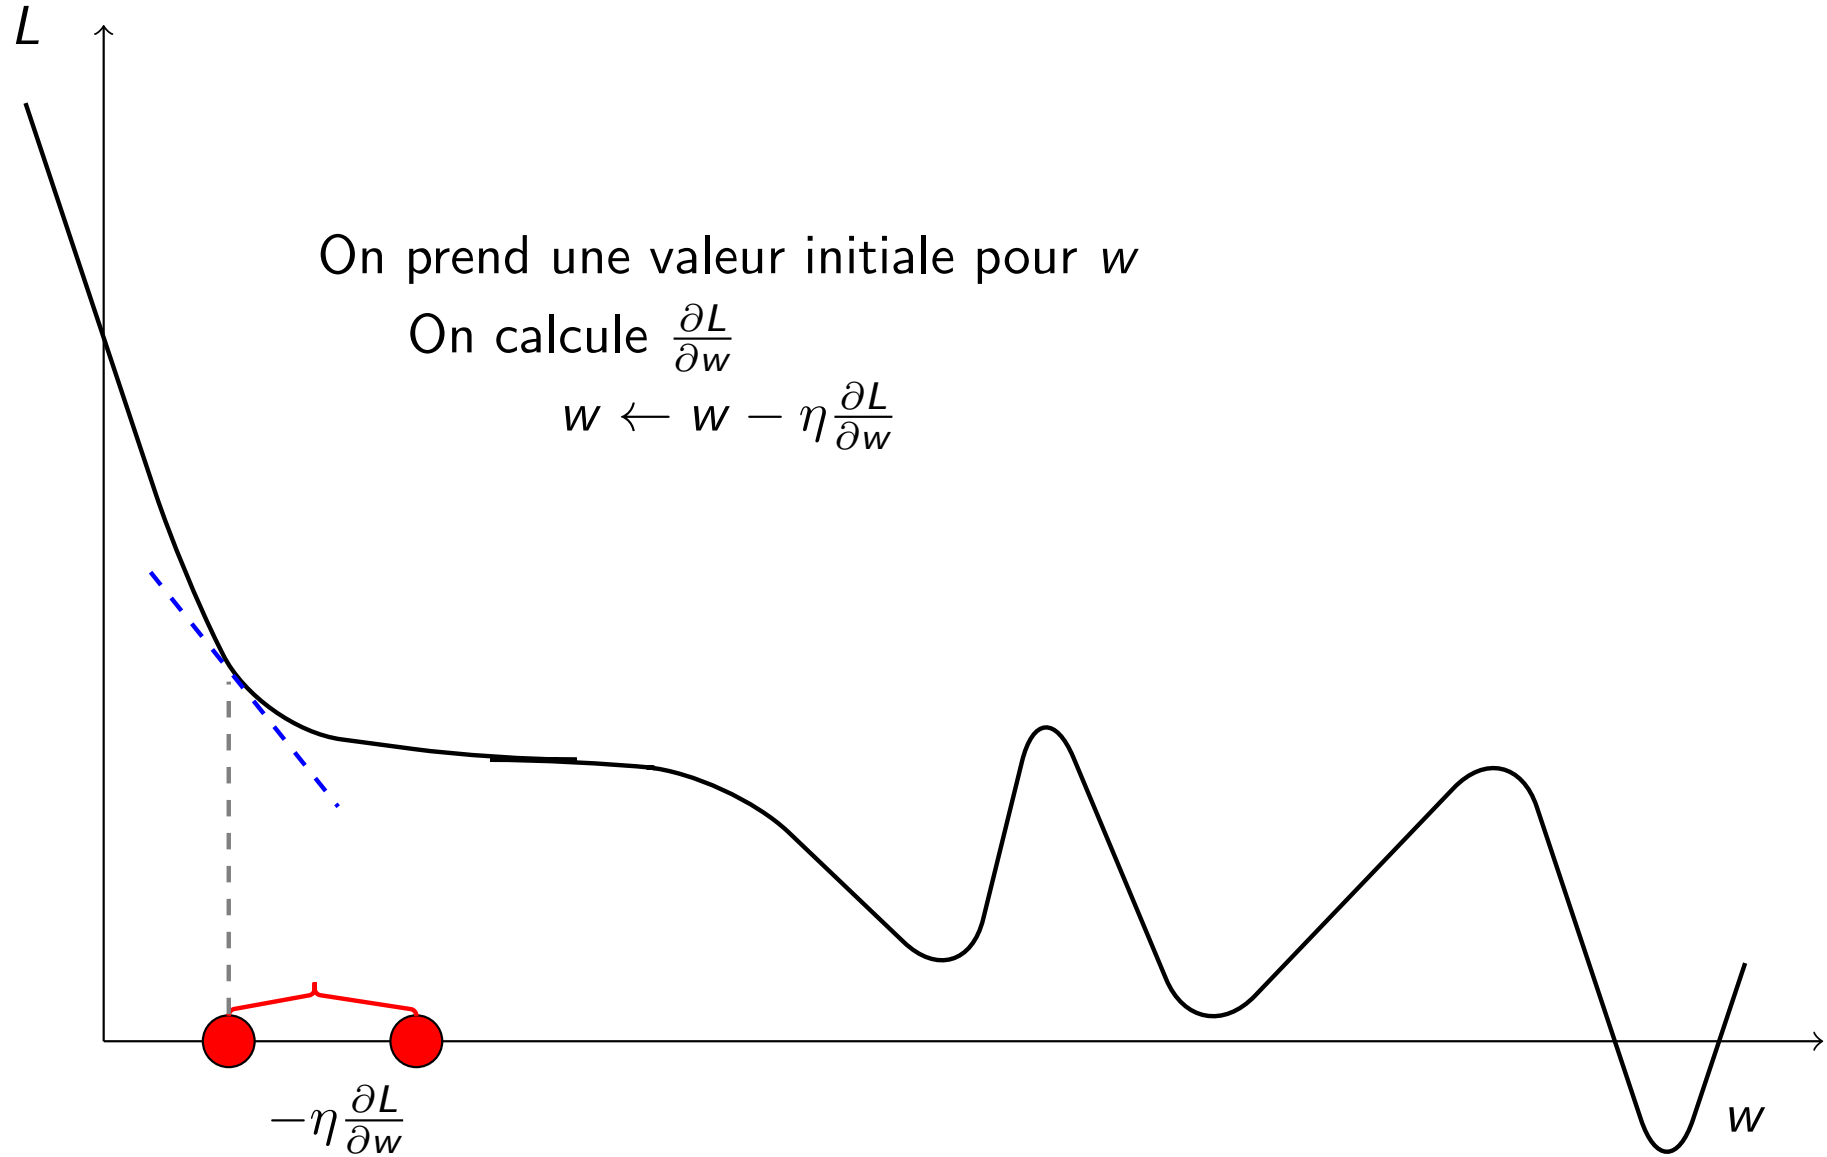

Descente du gradient

Trouver les paramètres θ du réseau qui minimisent la fonction de perte totale L.

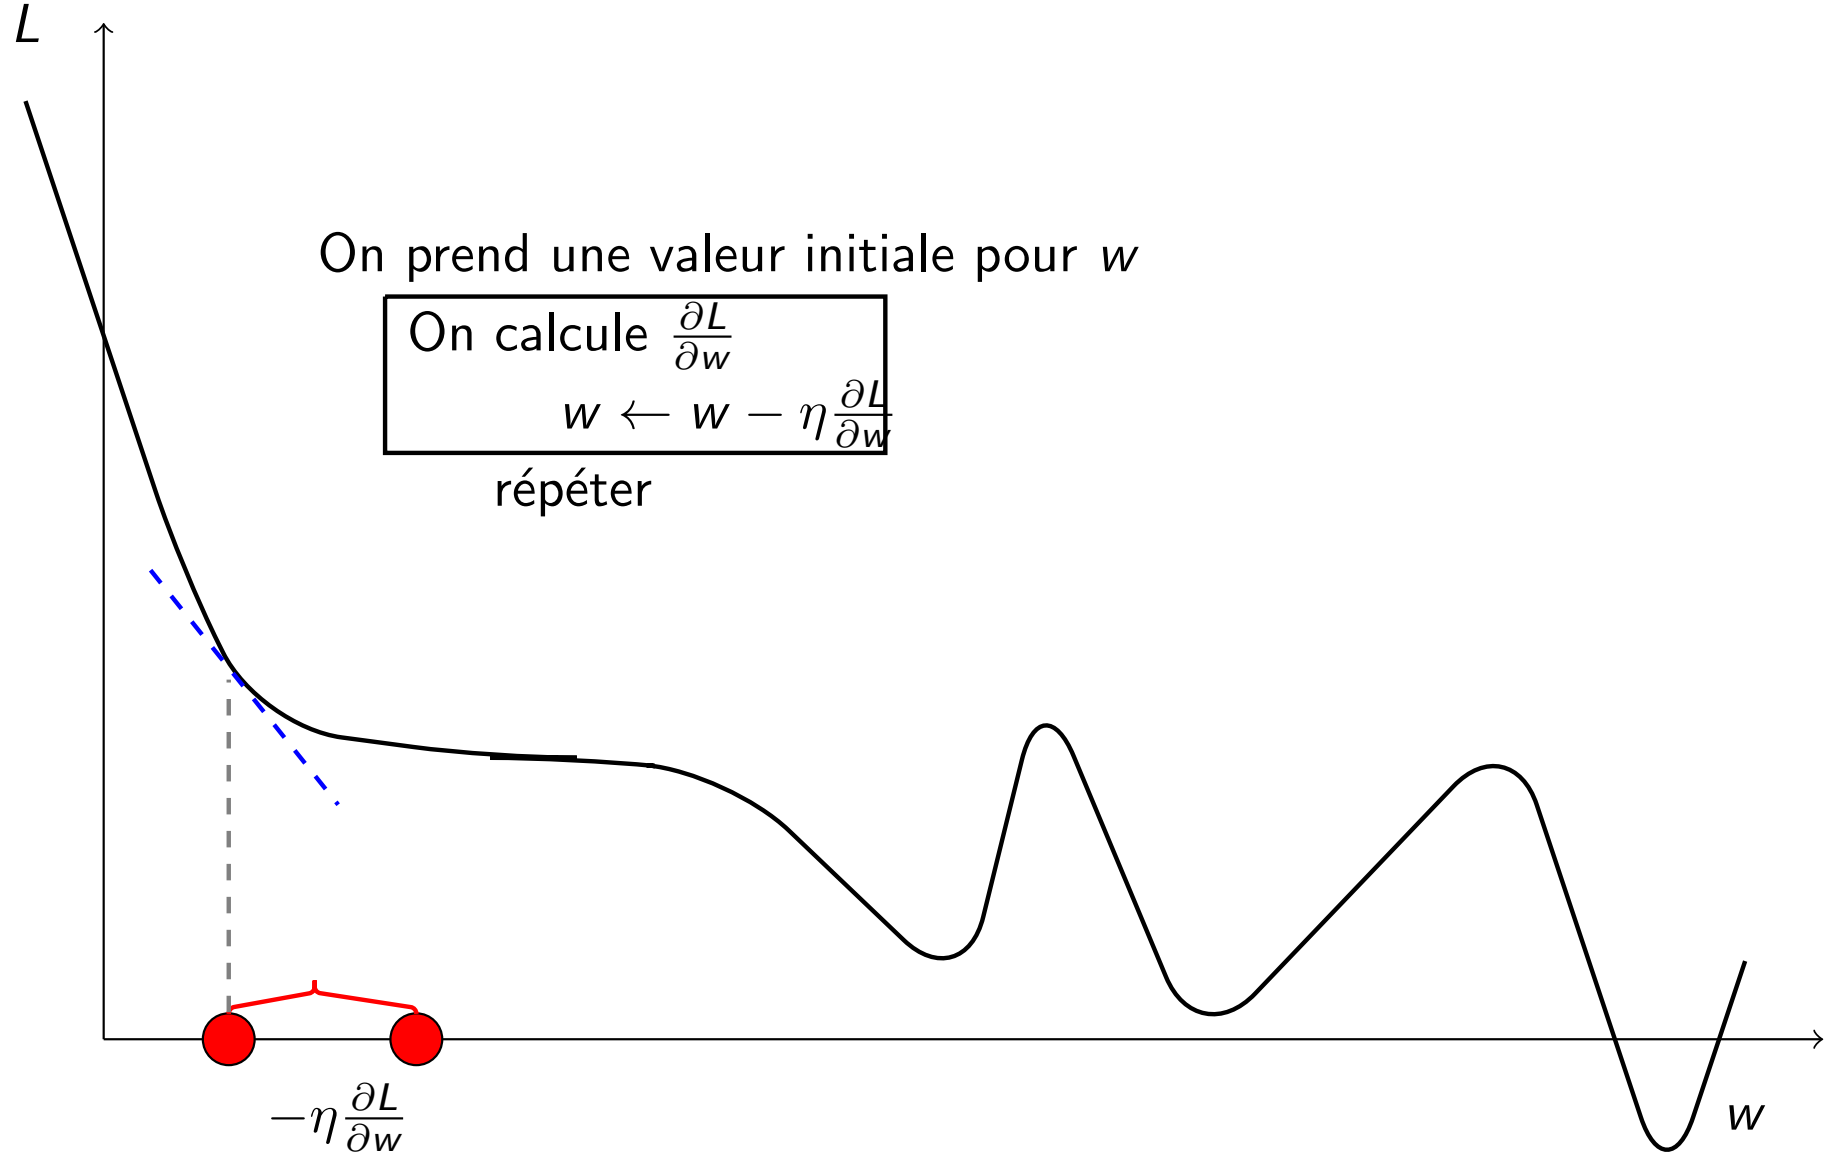

Descente du gradient

Trouver les paramètres θ du réseau qui minimisent la fonction de perte totale L.

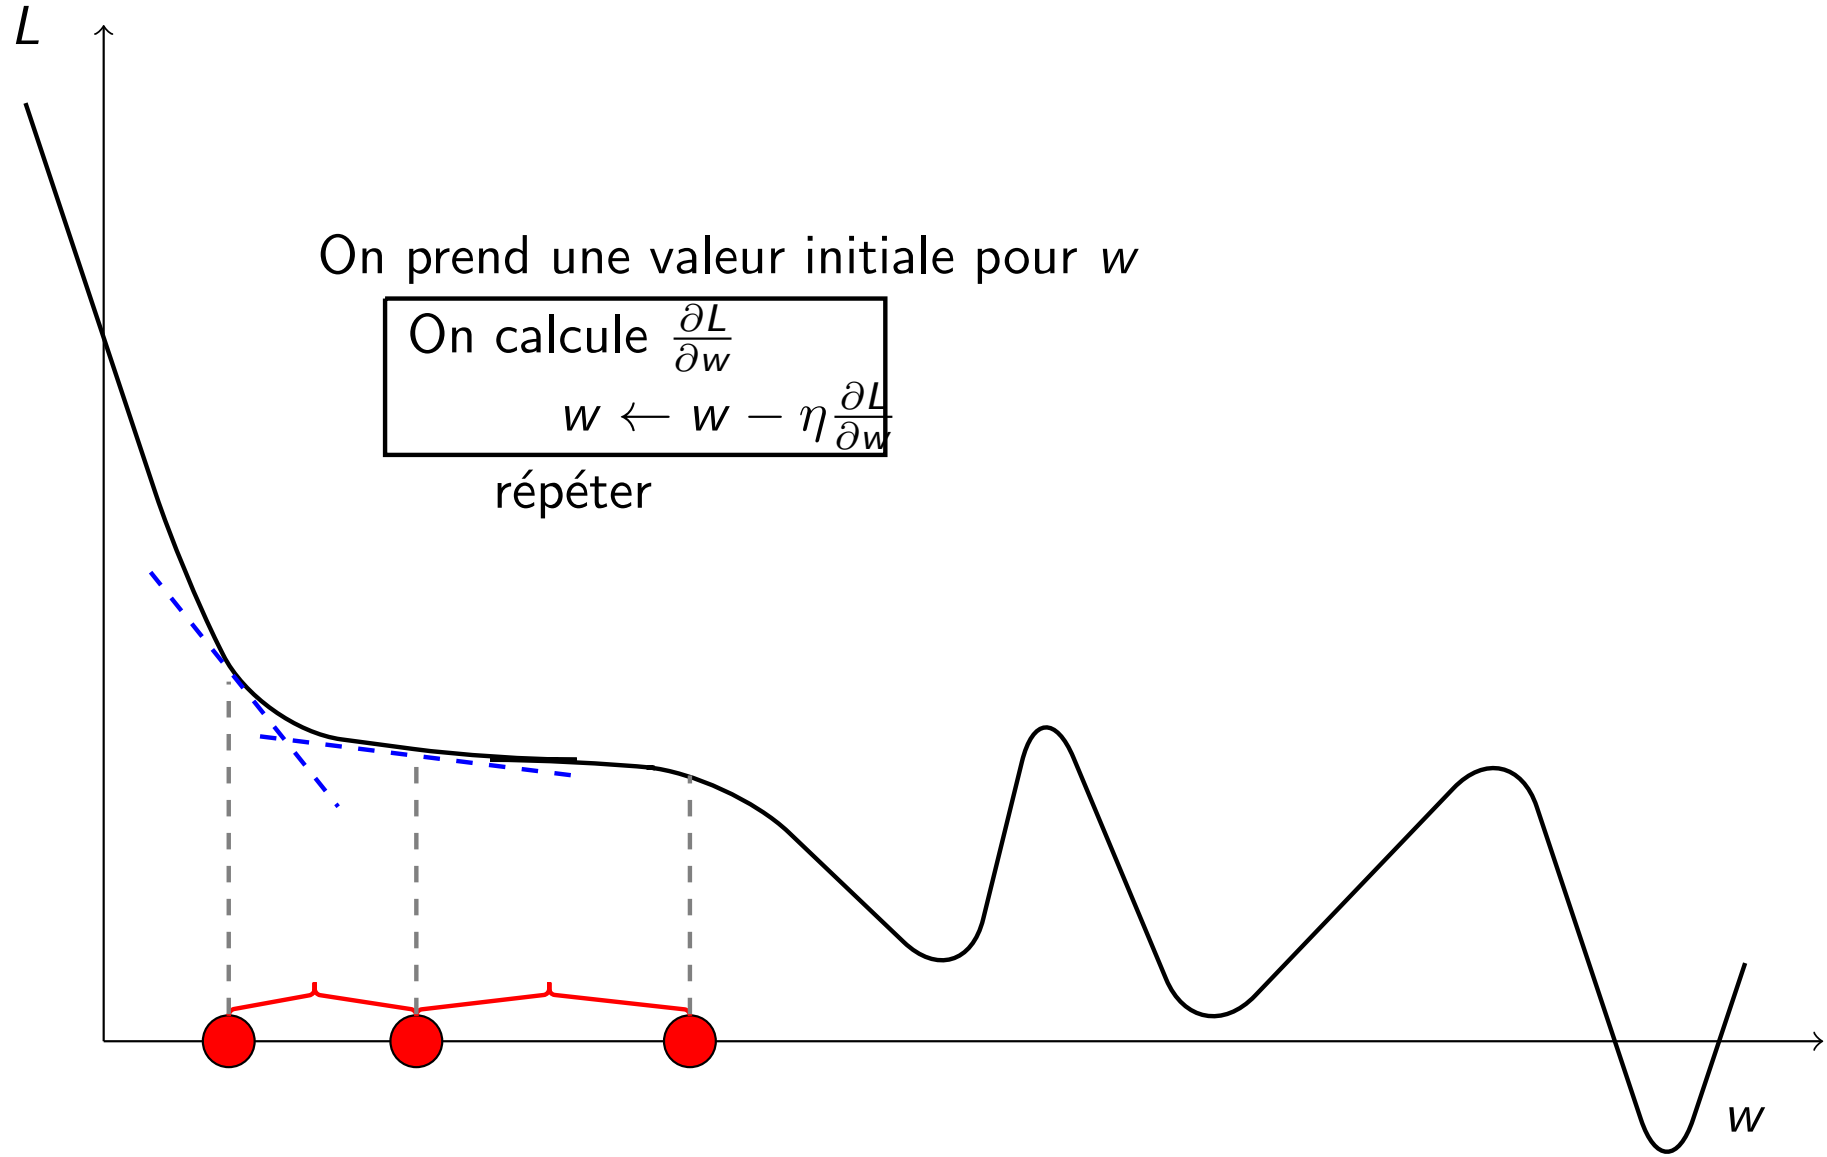

Descente du gradient

Trouver les paramètres θ du réseau qui minimisent la fonction de perte totale L.

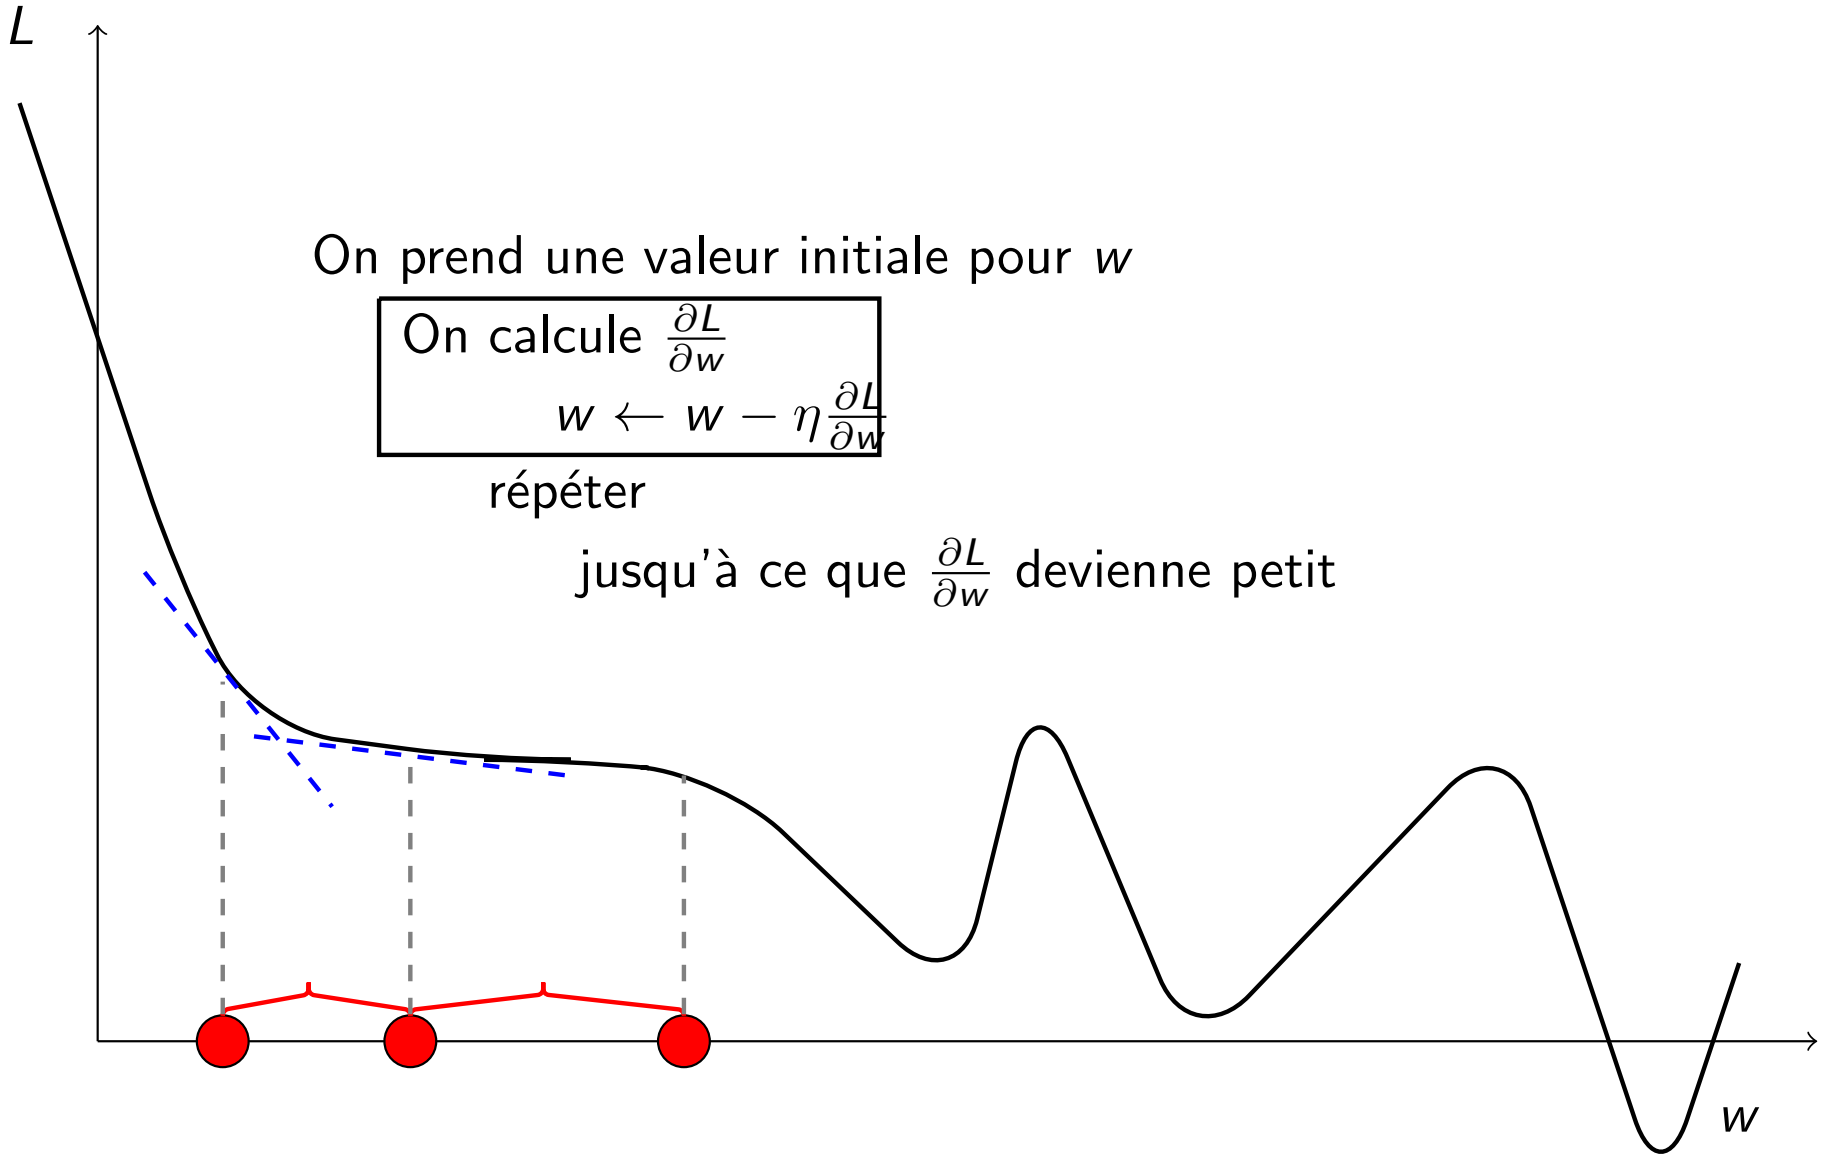

Descente du gradient

de l'importance du choix du taux d'apprentissage η :

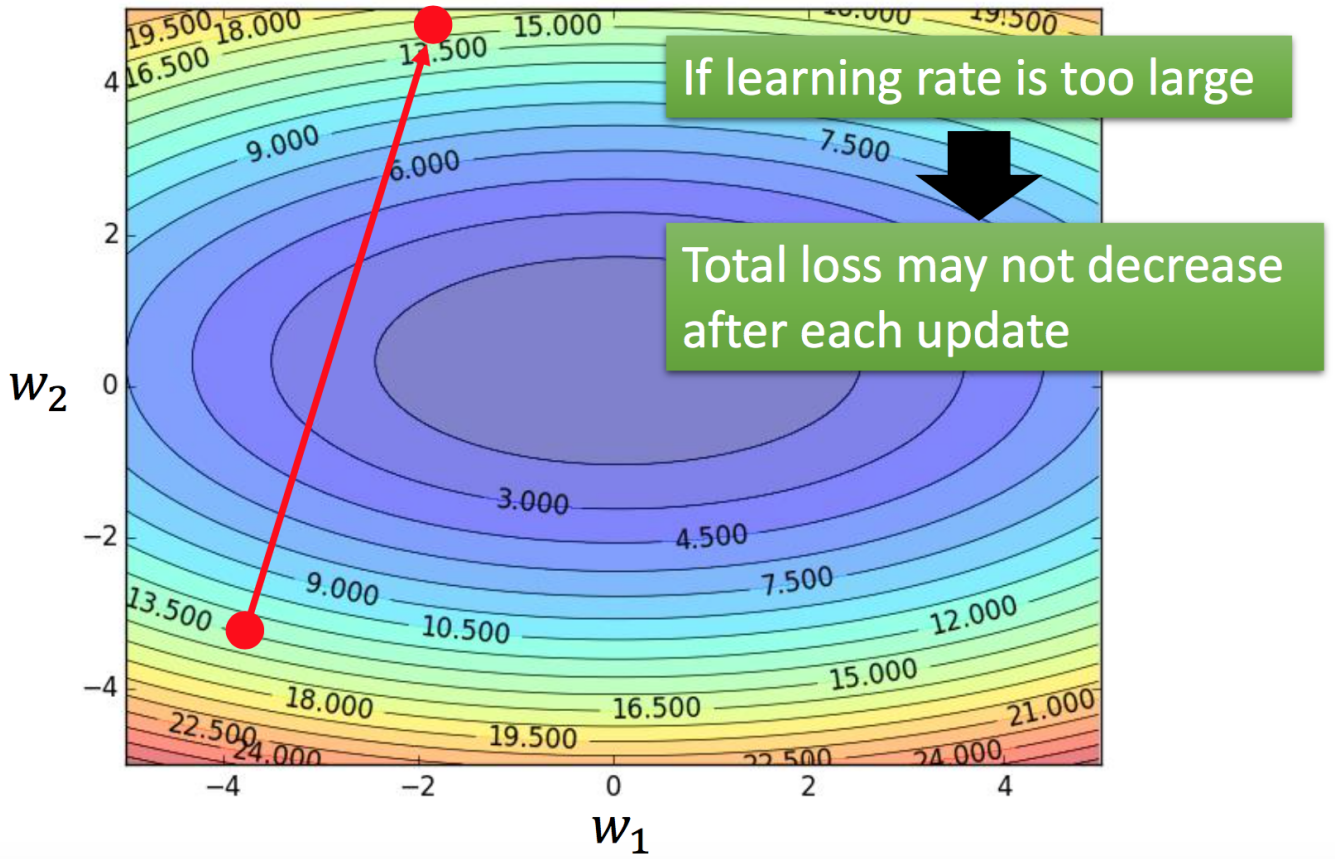

Descente du gradient

de l'importance du choix du taux d'apprentissage η :

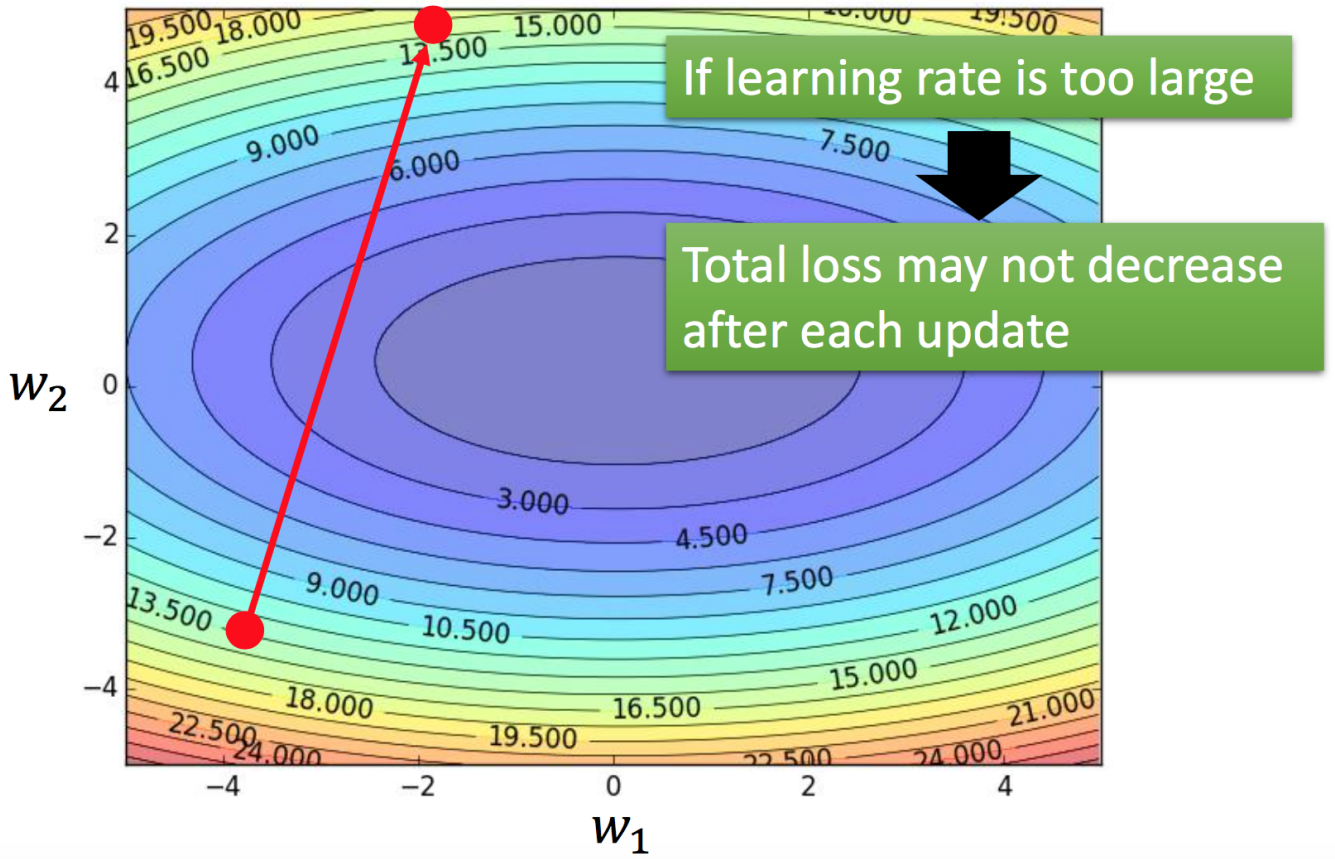

Descente du gradient

de l'importance du choix du taux d'apprentissage η :

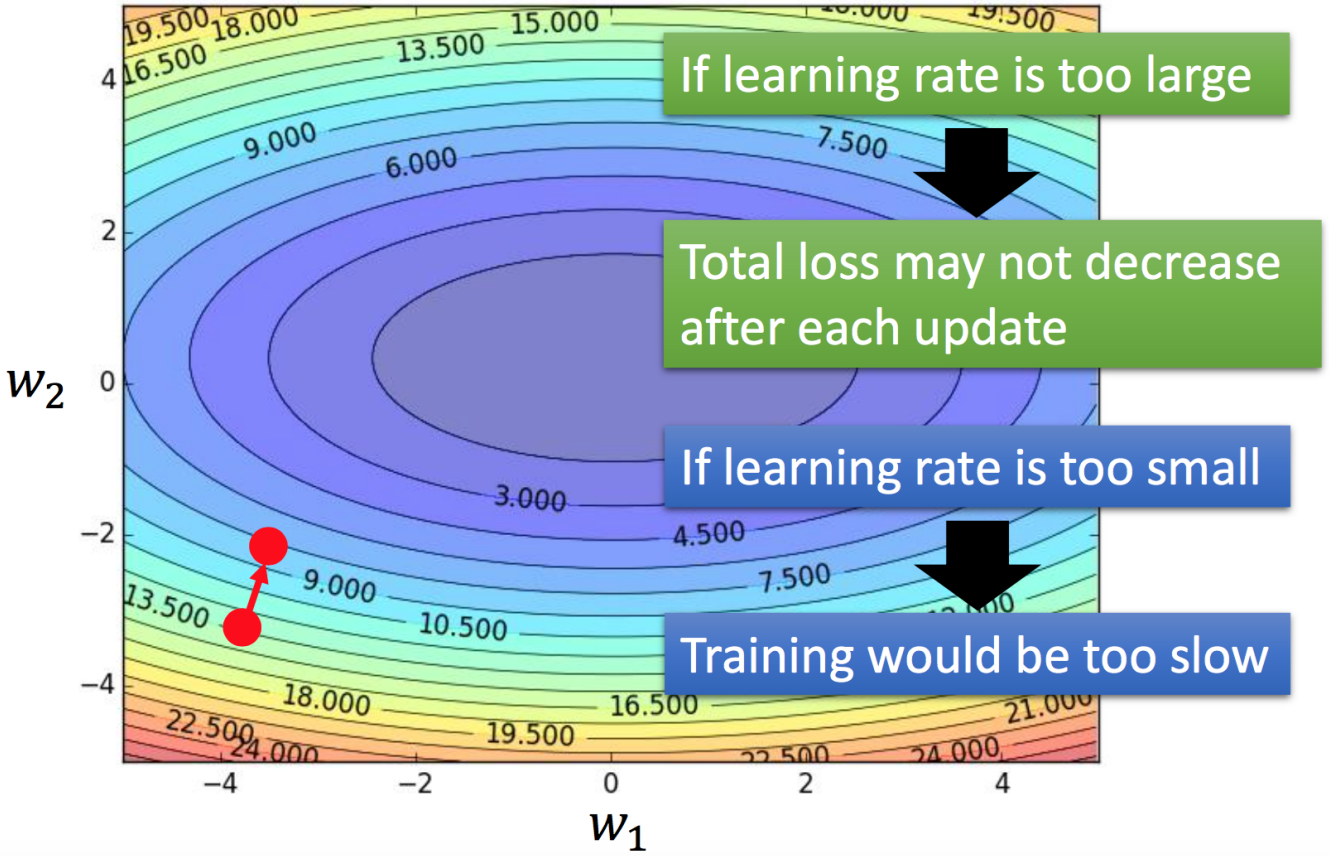

Descente du gradient

de l'importance du choix du taux d'apprentissage η :

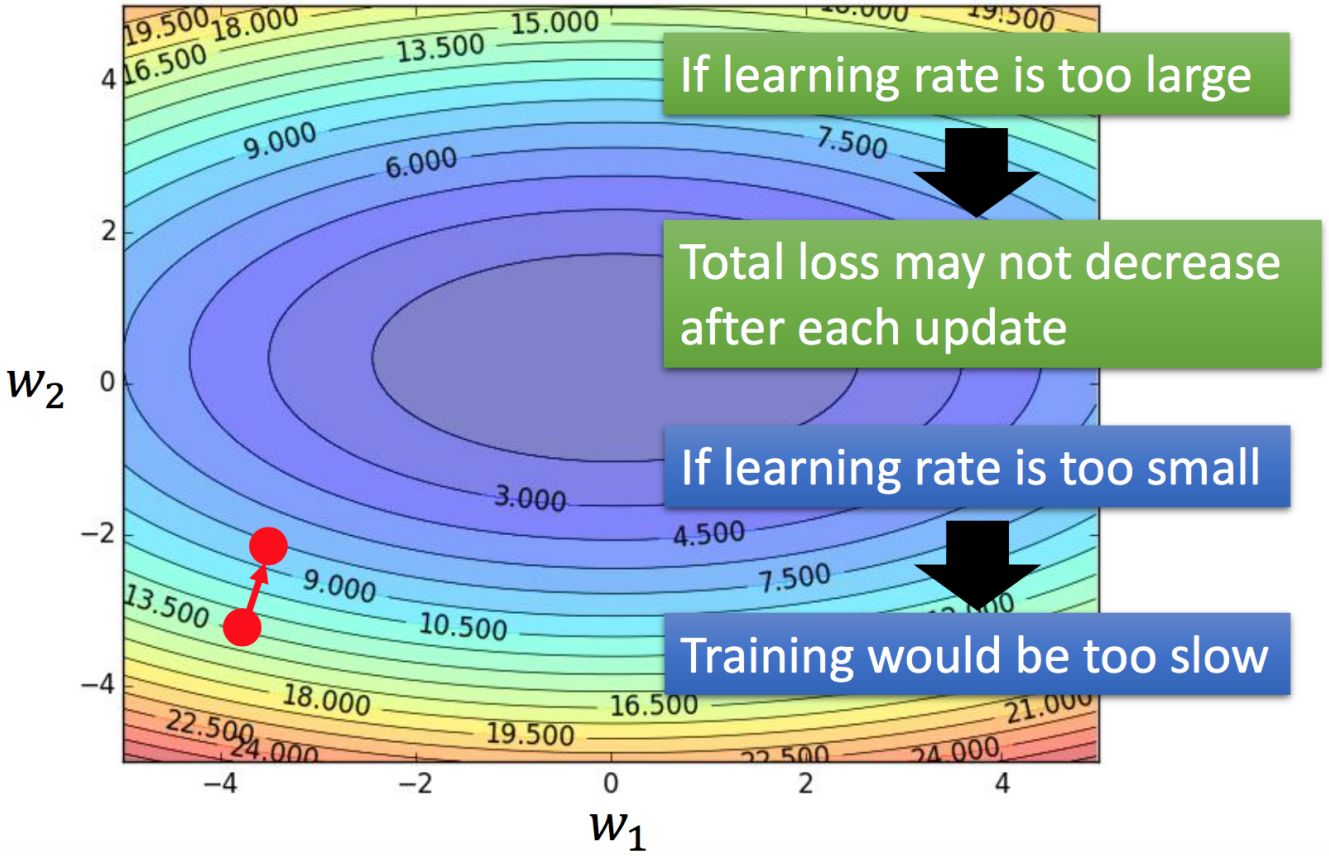

Descente du gradient

de l'importance du choix du taux d'apprentissage η :

- Un taux trop petit garantit une convergence vers un minimum mais le temps de convergence peut être trop grand ....
- Un taux trop grand peut faire "sauter" le minimum ..

Descente du gradient

de l'importance du choix du taux d'apprentissage η :

Une solution simple : réduire le taux par un facteur toutes les K itérations

- Initialement, on est loin de la destination, on utilise donc un pas assez grand,
- Après quelques itérations, on est proche de la destination, on réduit donc le pas.
- En général, on utilise la mise à jour suivante :

$$\eta^{(t)} = \frac{\eta}{\sqrt{t+1}}$$

Descente du gradient

de l'importance du choix du taux d'apprentissage η :
Une solution simple : réduire le taux par un facteur toutes les K itérations

- Initialement, on est loin de la destination, on utilise donc un pas assez grand,
- Après quelques itérations, on est proche de la destination, on réduit donc le pas.
- En général, on utilise la mise à jour suivante :

$$\eta^{(t)} = \frac{\eta}{\sqrt{t+1}}$$

Descente du gradient

- La descente du gradient ne garantie pas de trouver un minimum global,
- Néanmoins, c'est LA méthode d'apprentissage du deep ...

Descente du gradient

Problème : minimum mais local ....

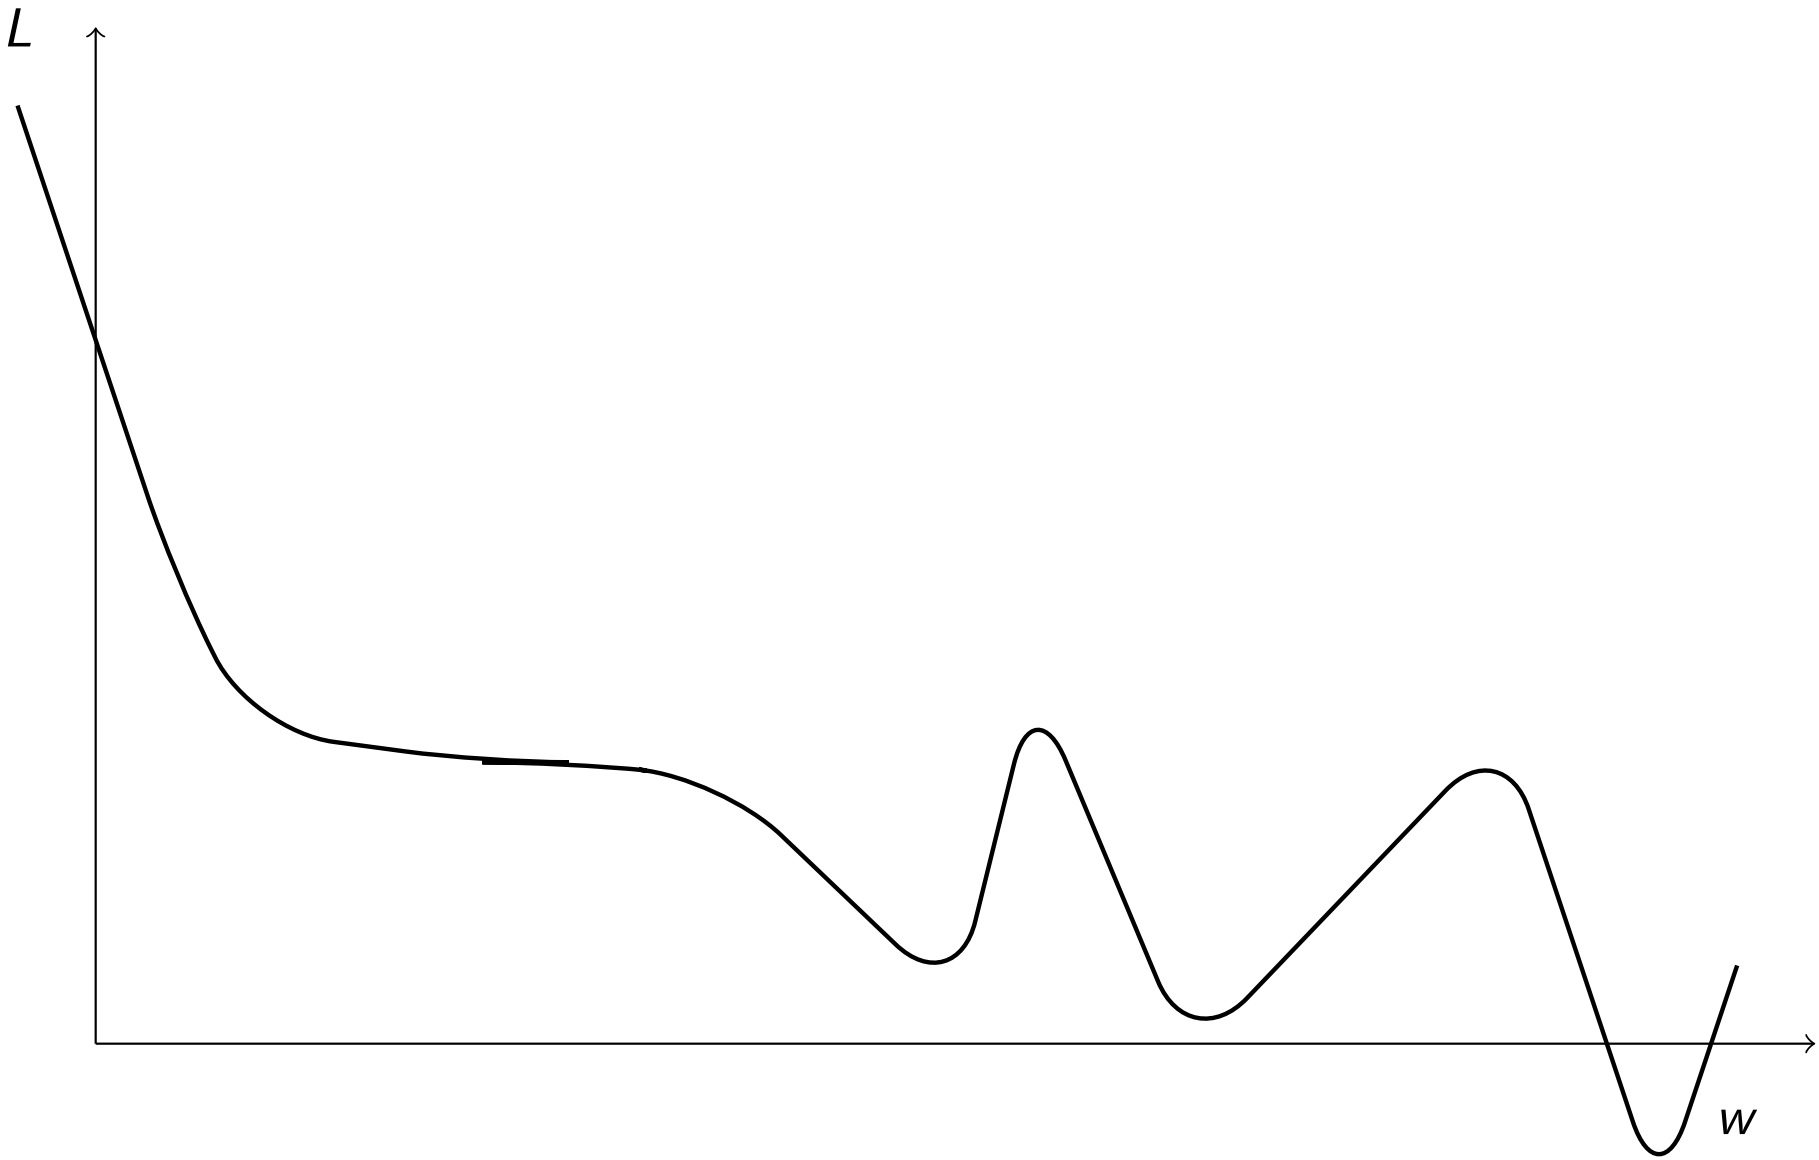

Descente du gradient

Problème : minimum mais local ...

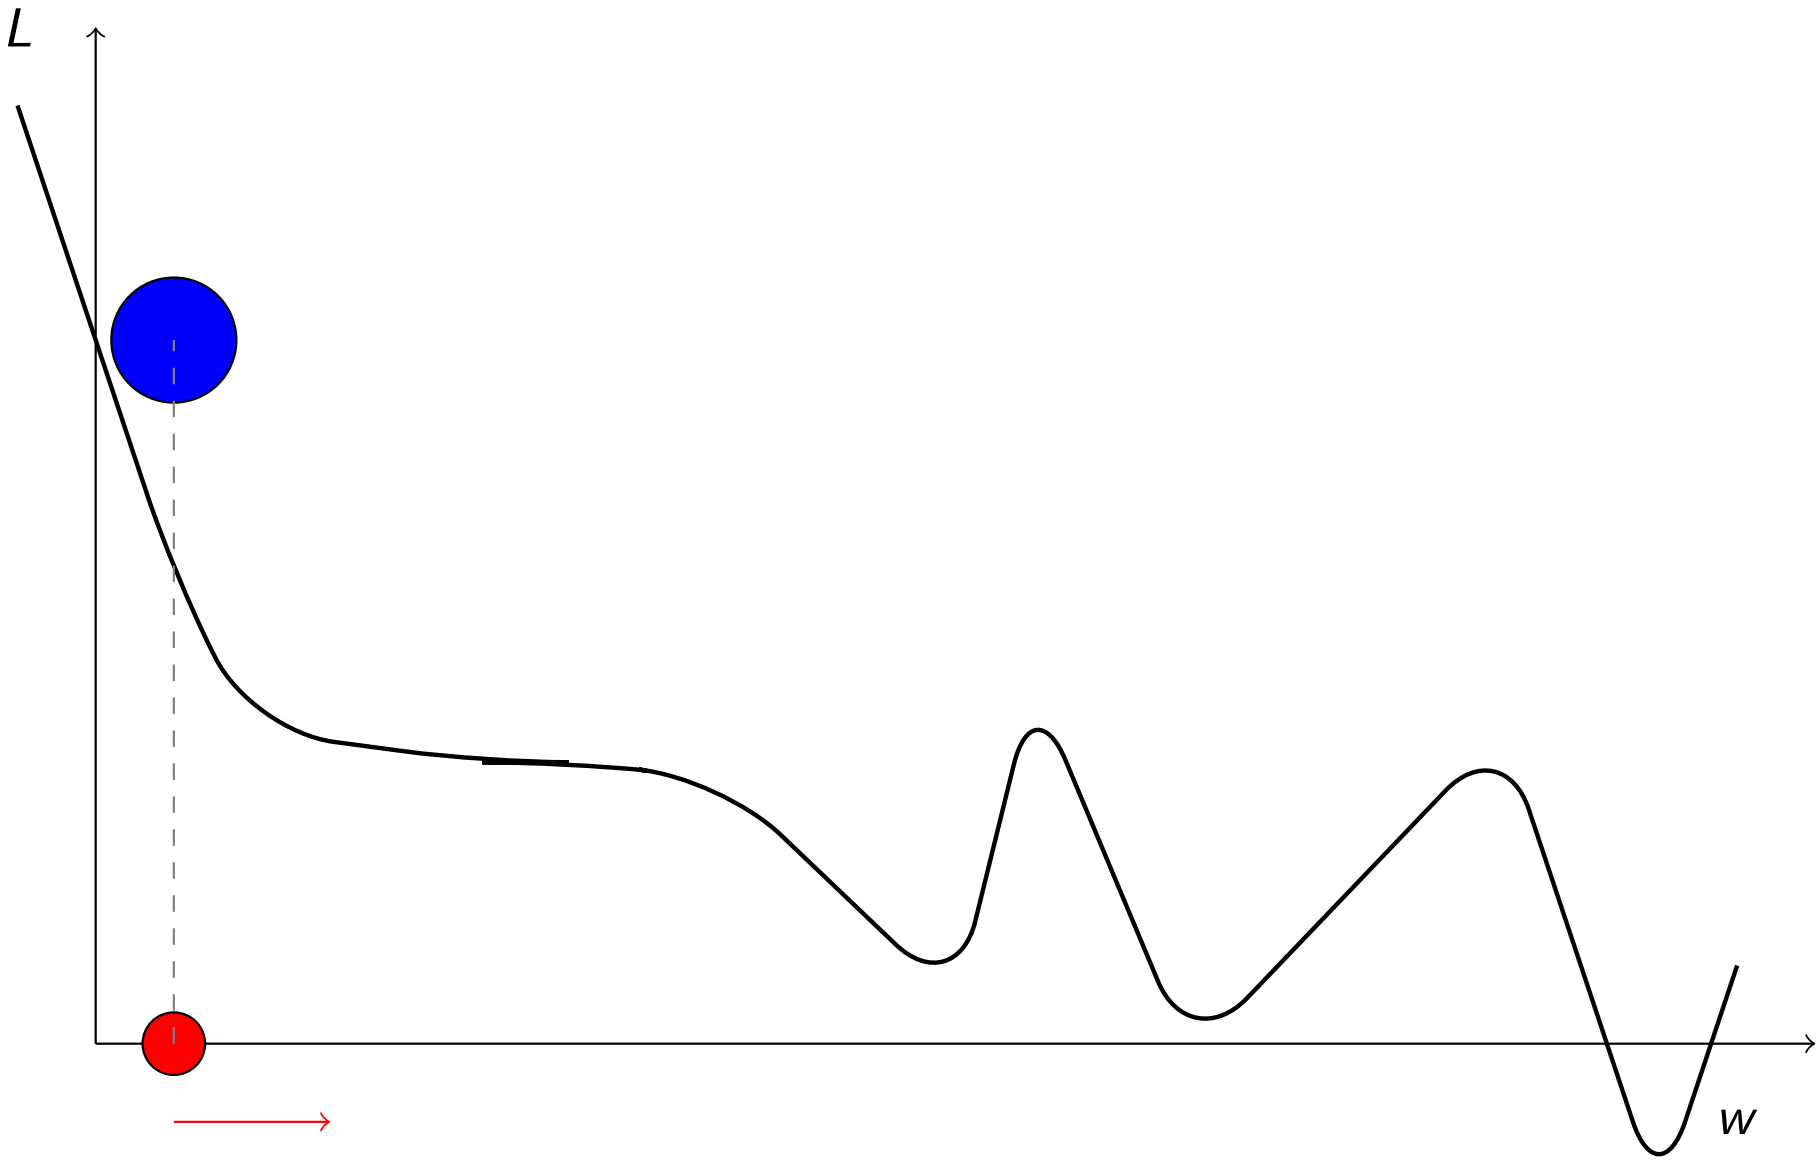

Descente du gradient

Problème : minimum mais local ....

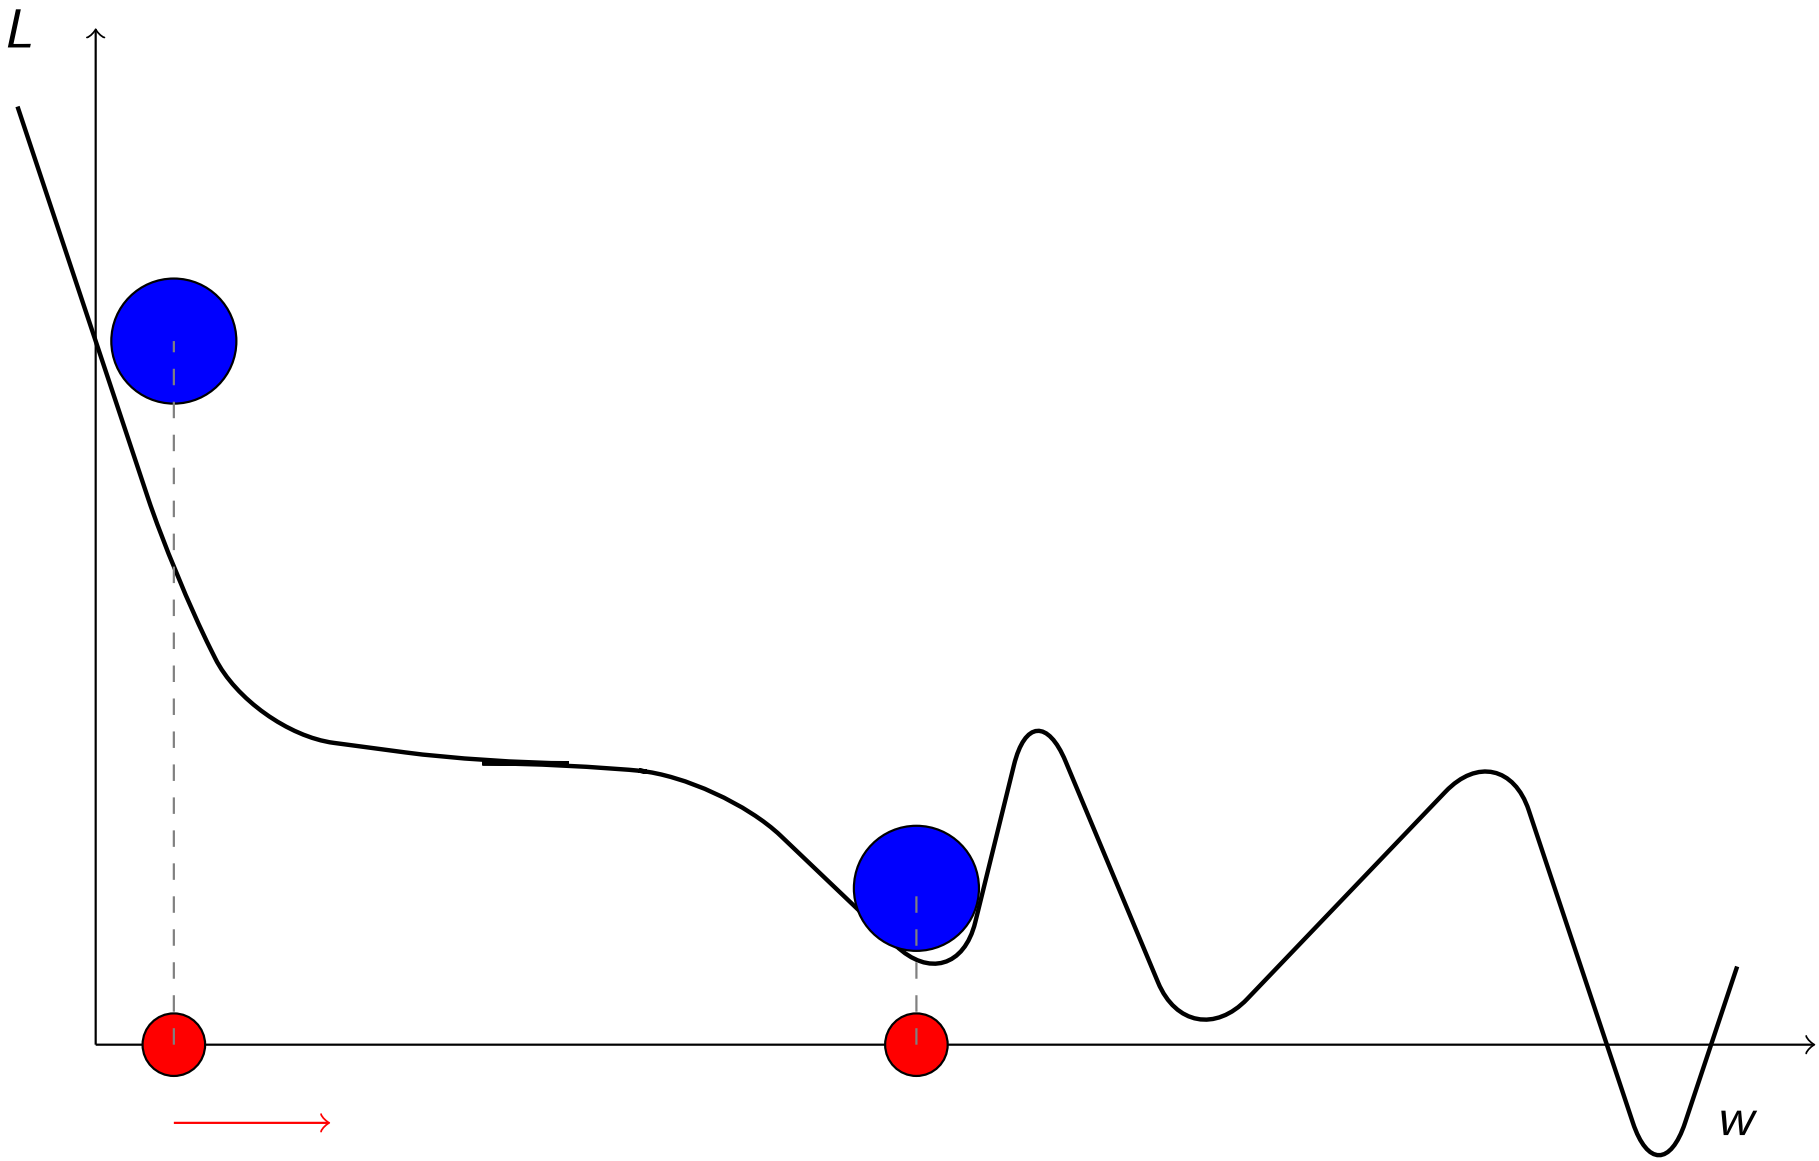

Descente du gradient

Problème : minimum mais local ....

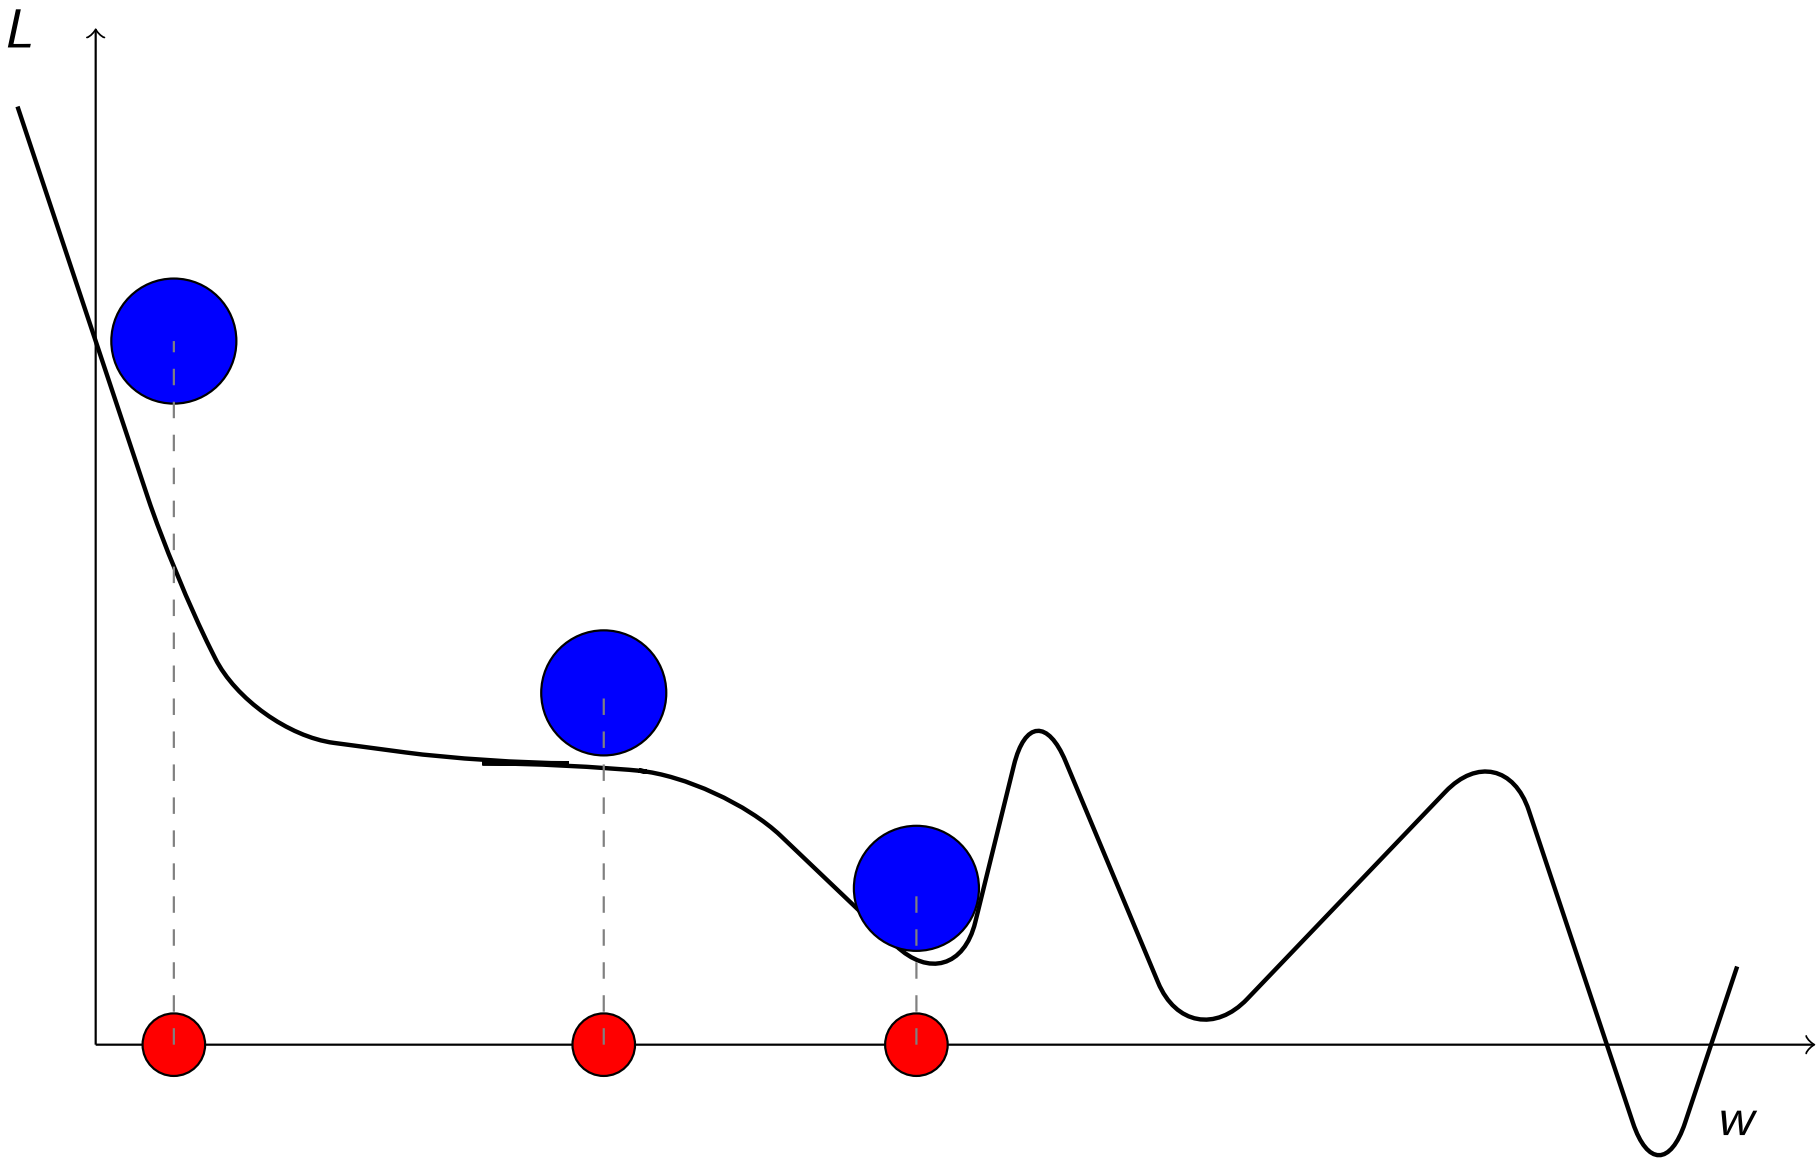

Descente du gradient

Problème : minimum mais local ....

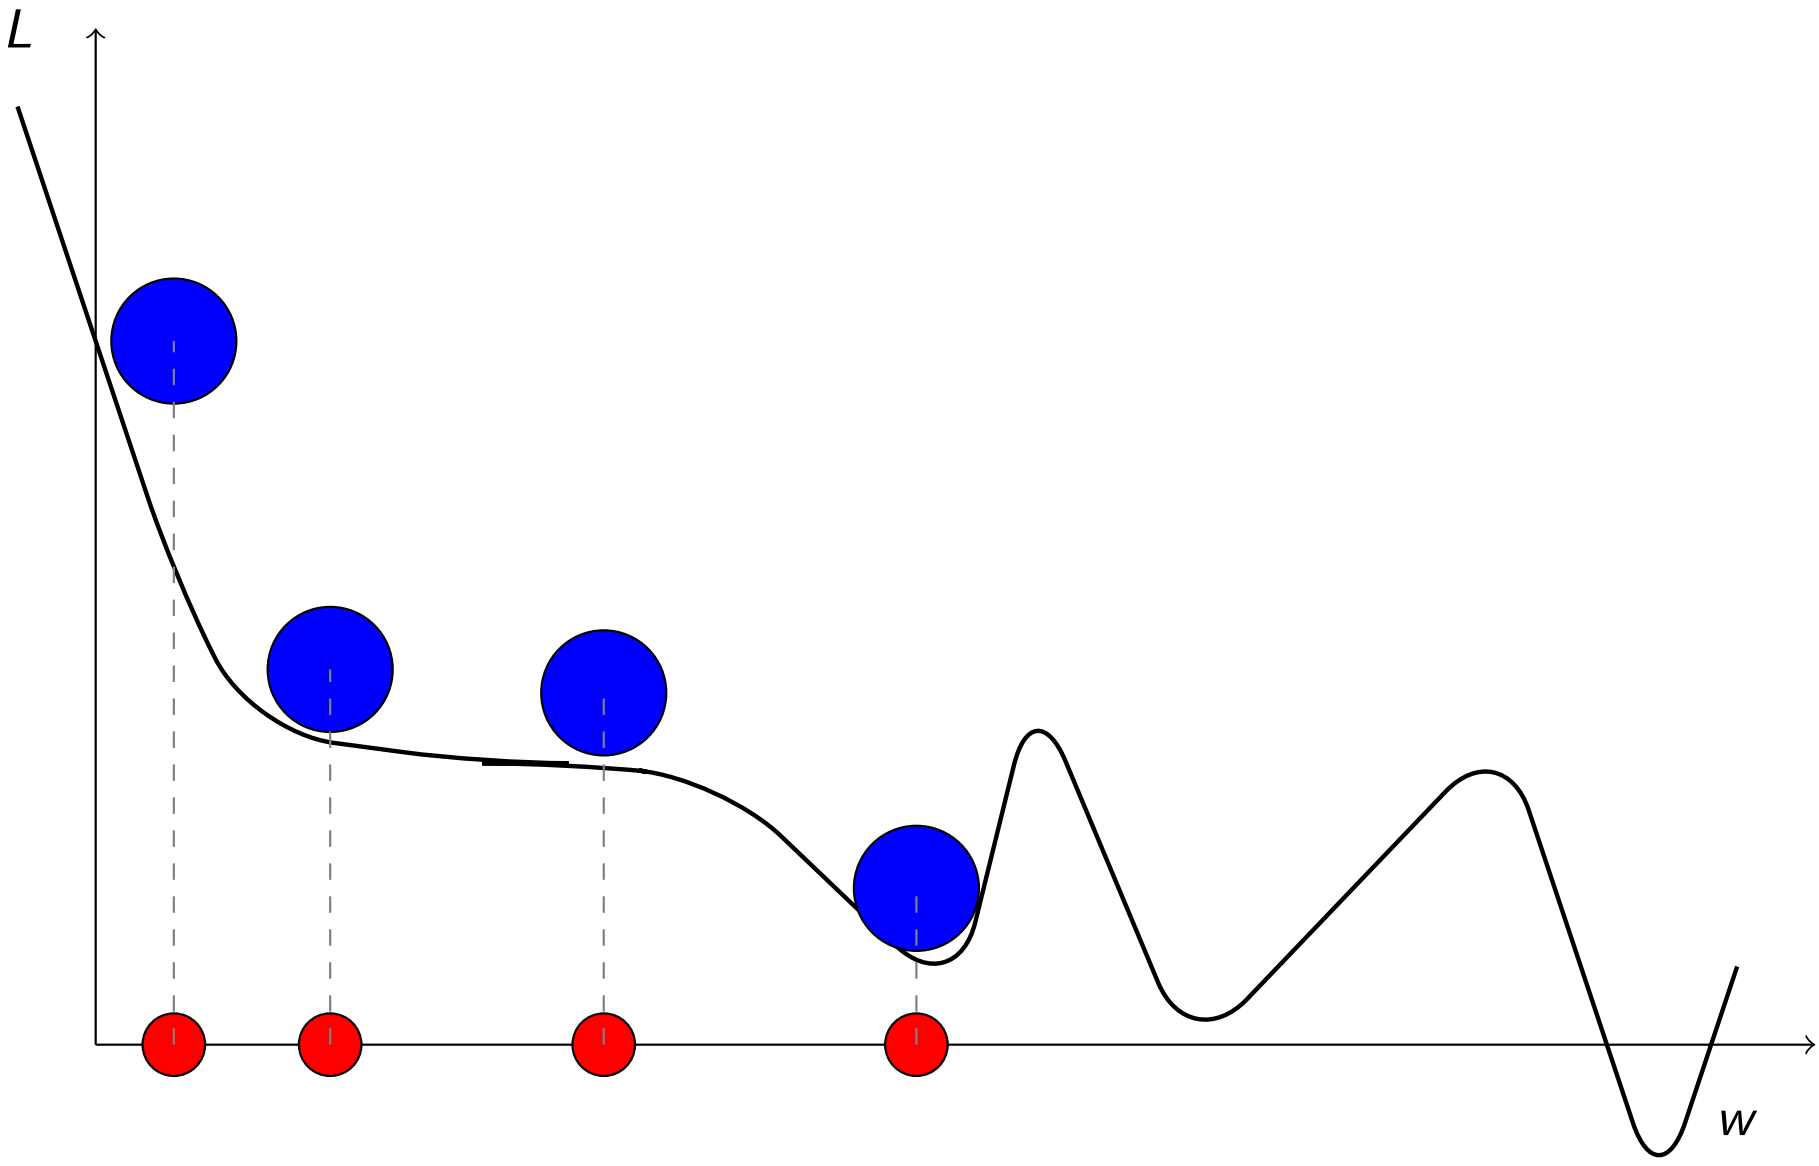

Descente du gradient

Problème : minimum mais local ....

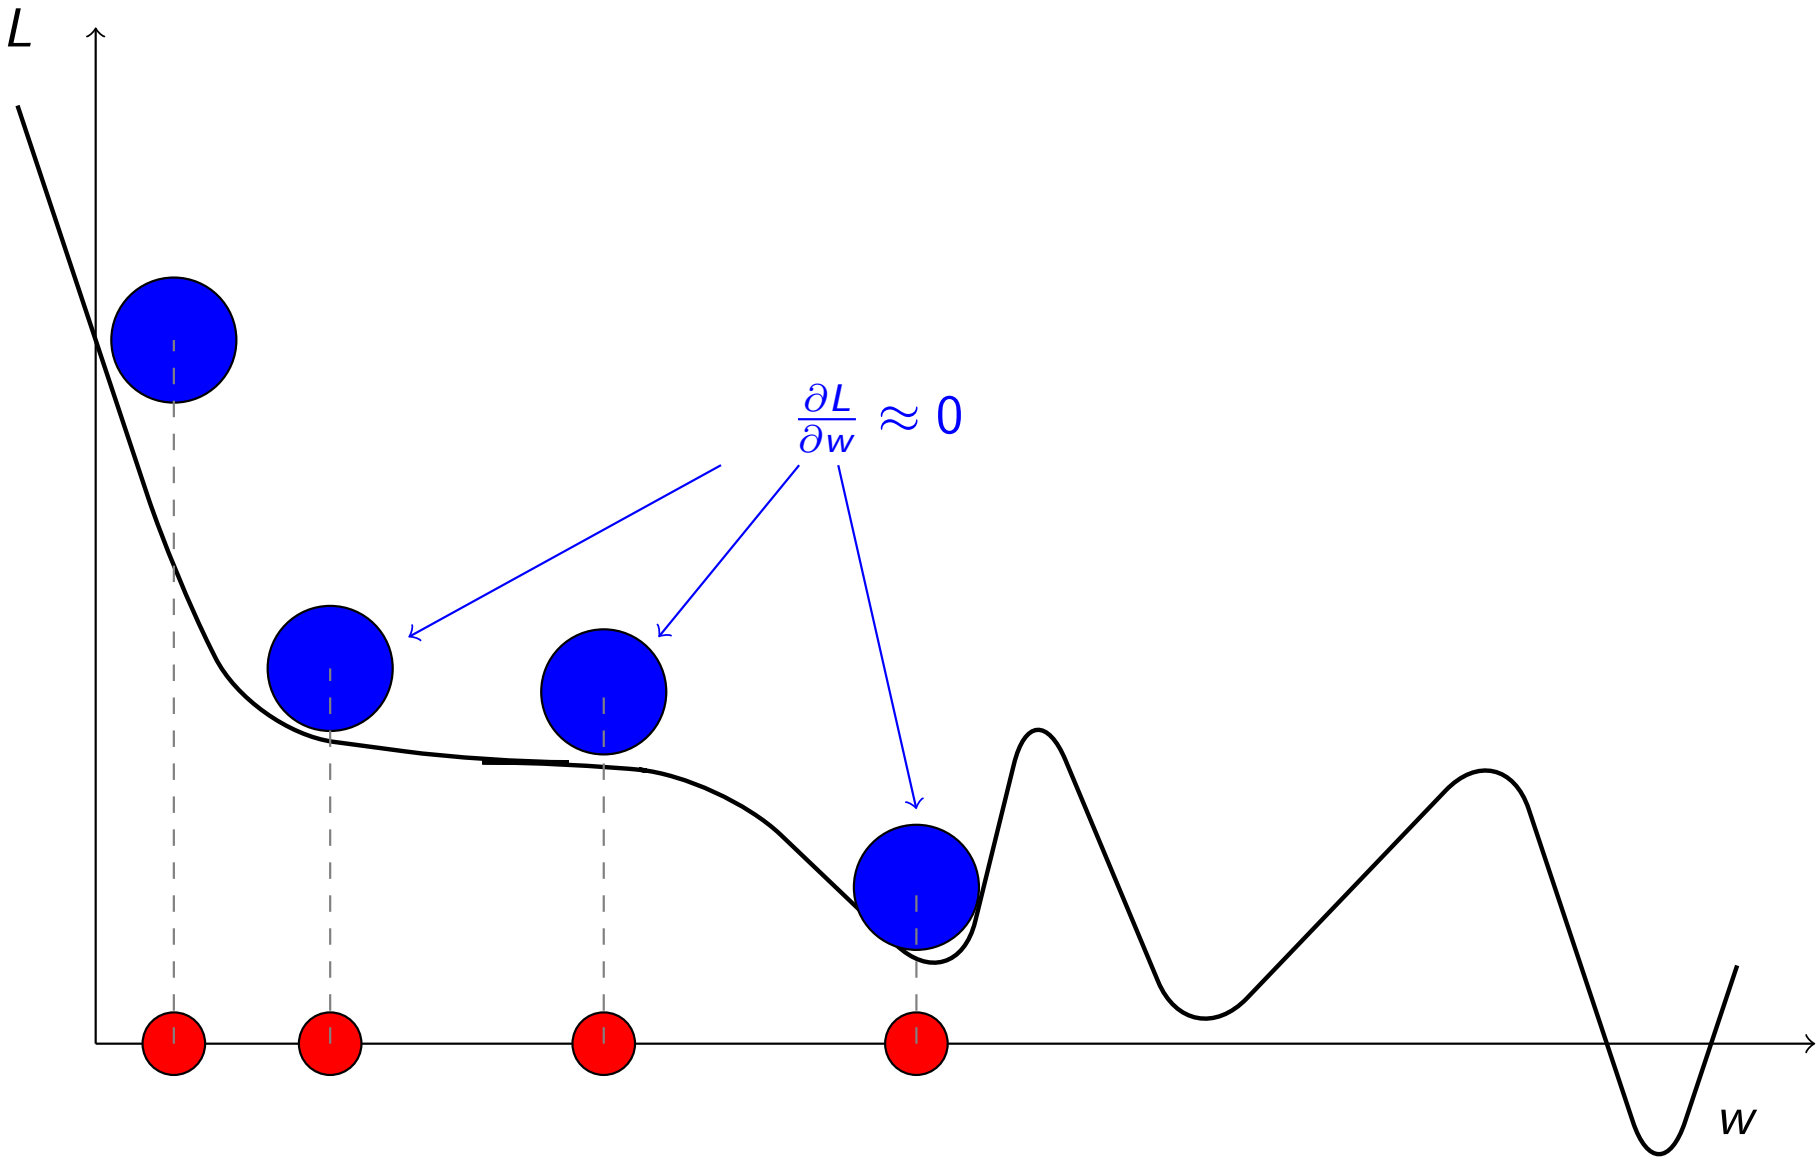

Descente du gradient

Problème : minimum mais local ....
Idée : s'inspirer de la physique et d'une balle qui dévale une pente

Descente du gradient

Méthode du Momentum :

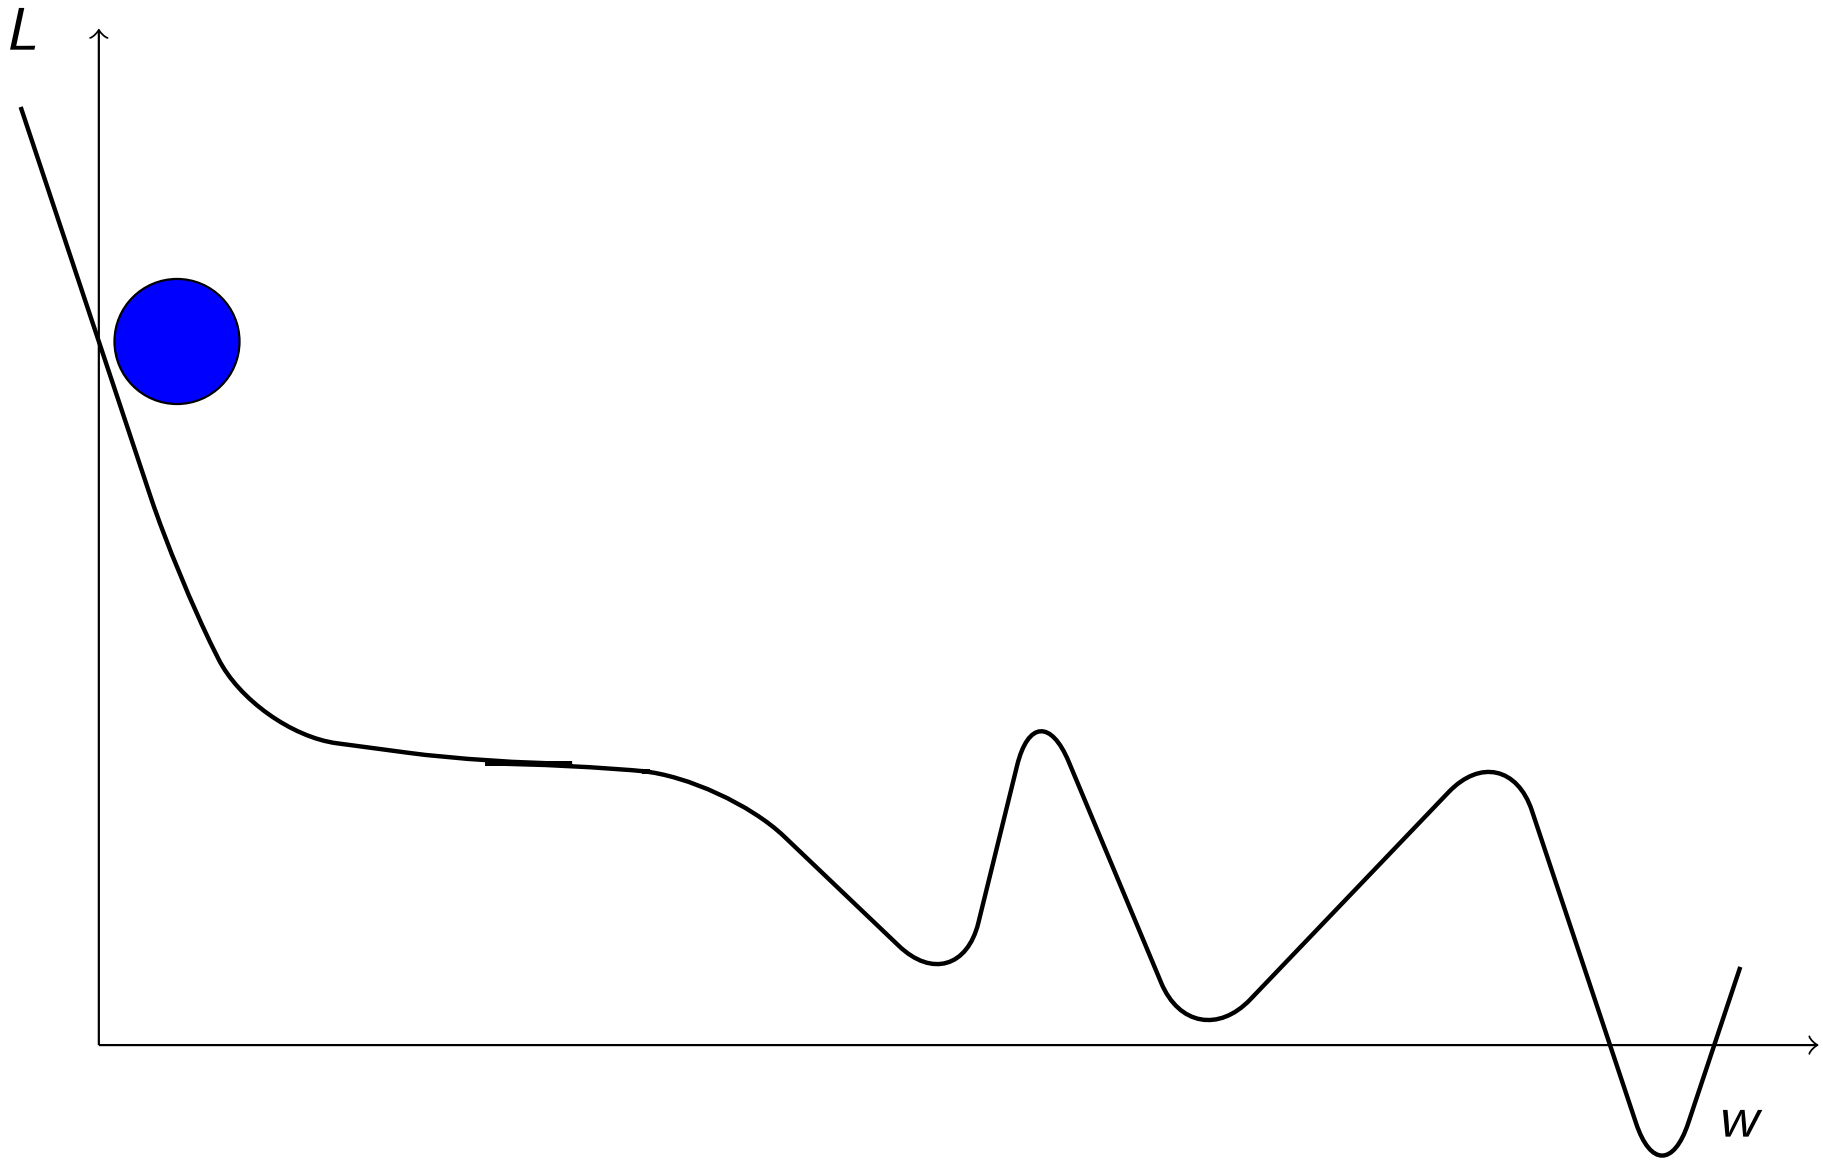

Descente du gradient

Méthode du Momentum :

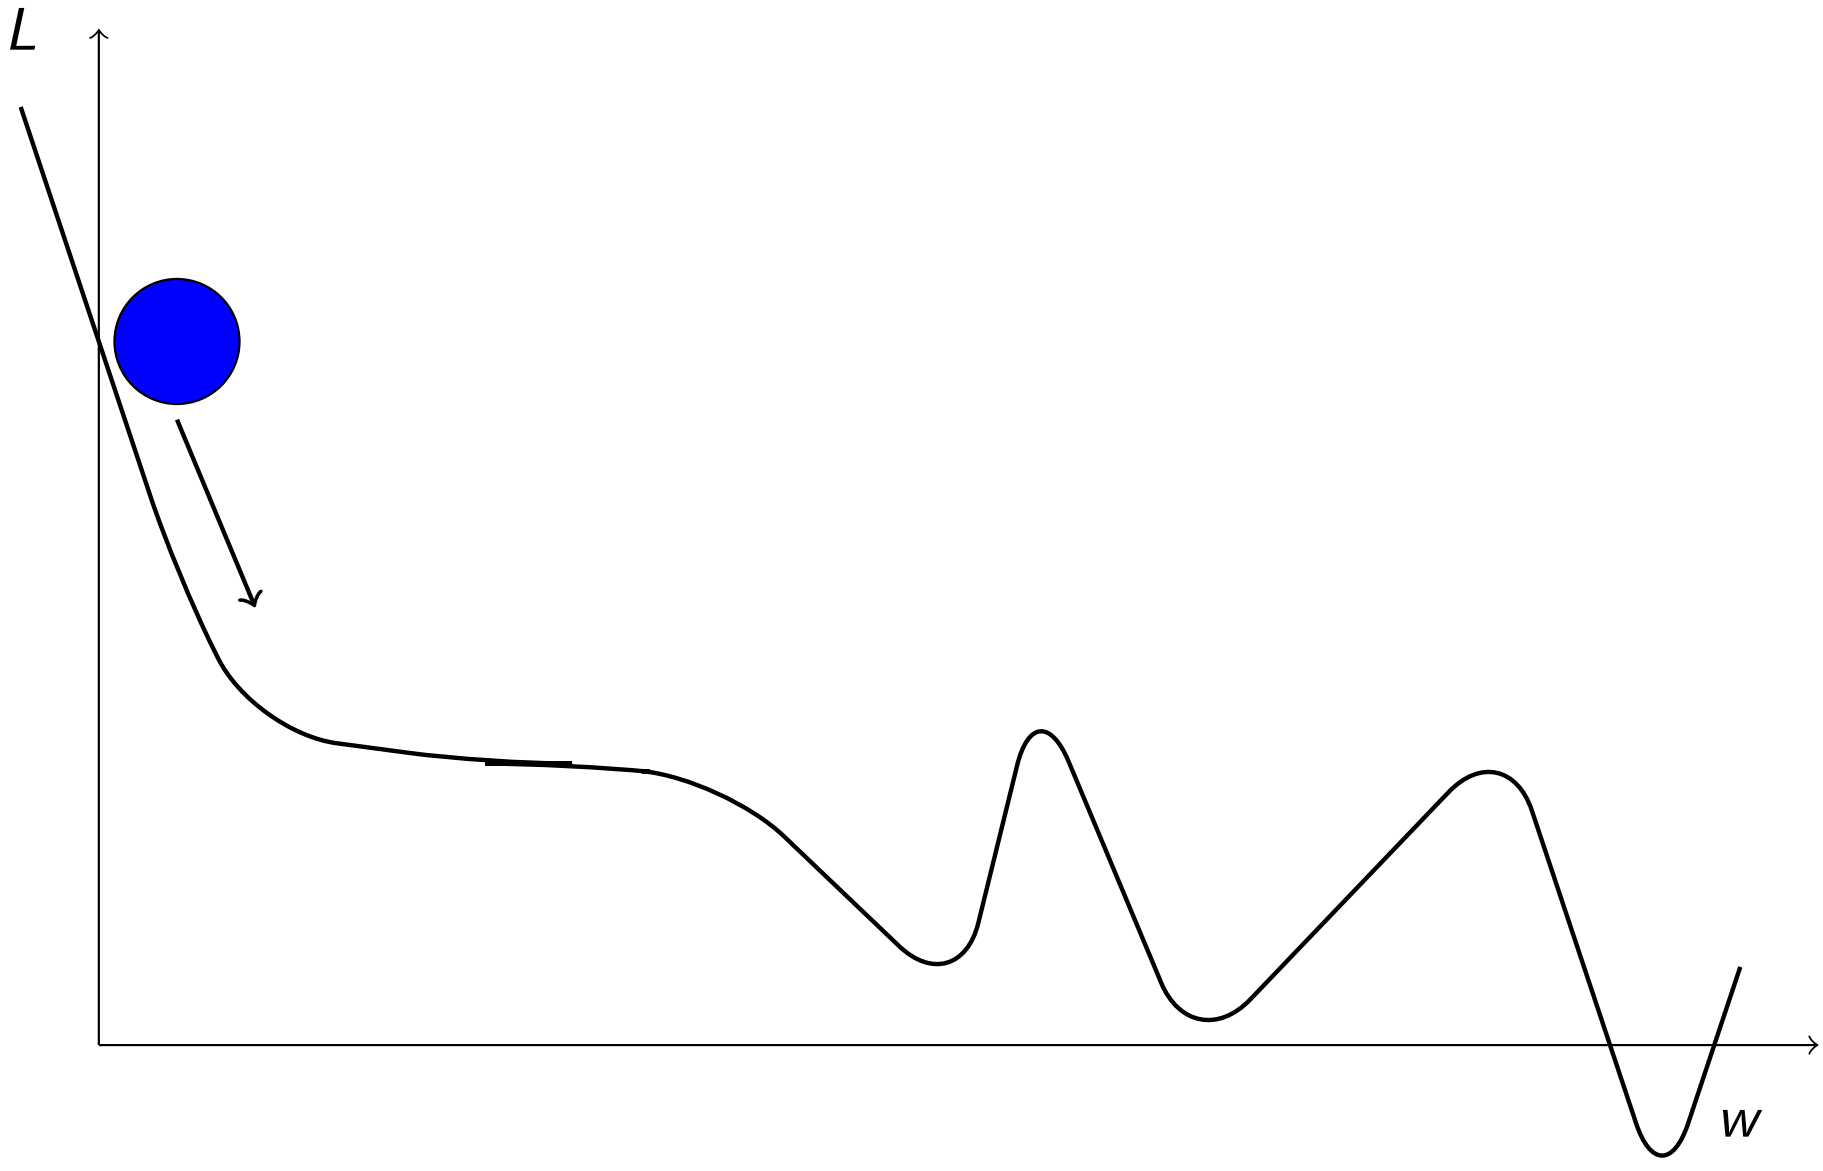

Descente du gradient

Méthode du Momentum :

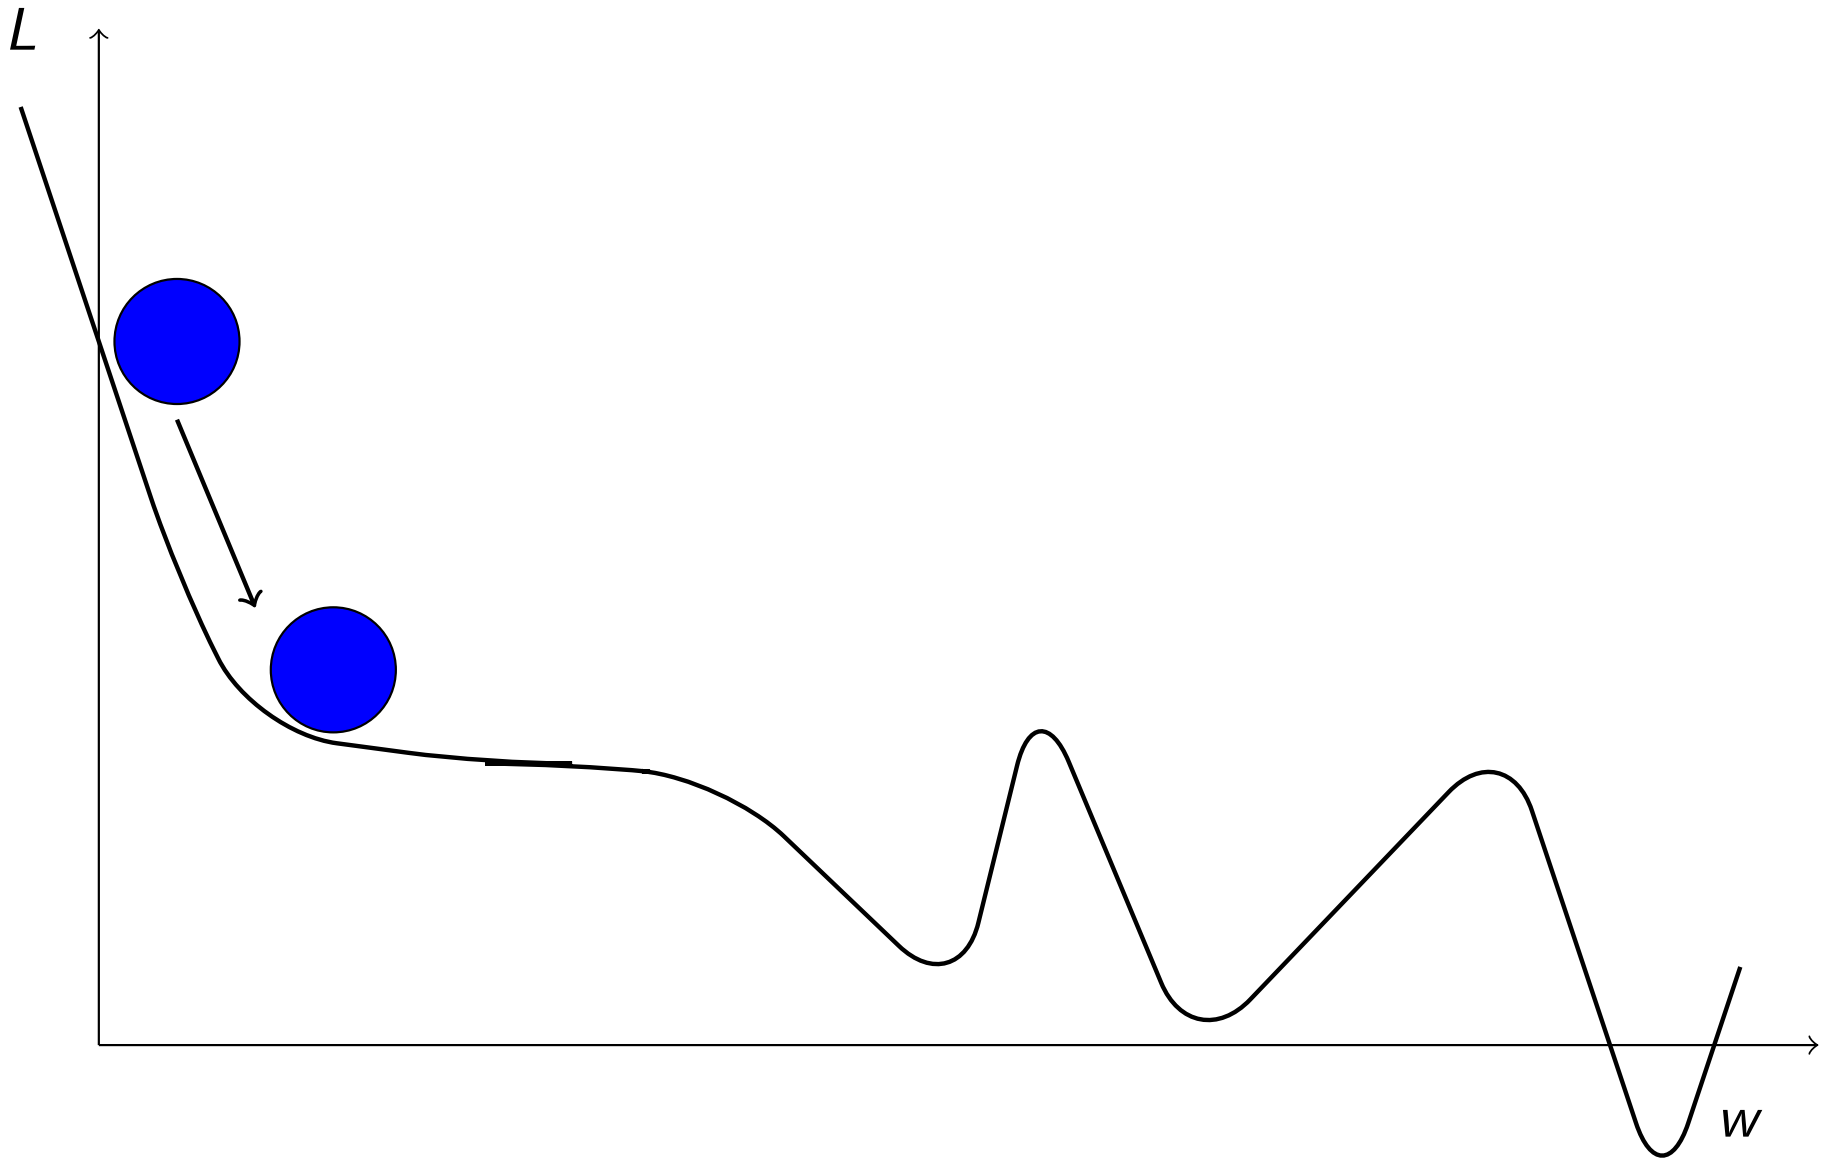

Descente du gradient

Méthode du Momentum :

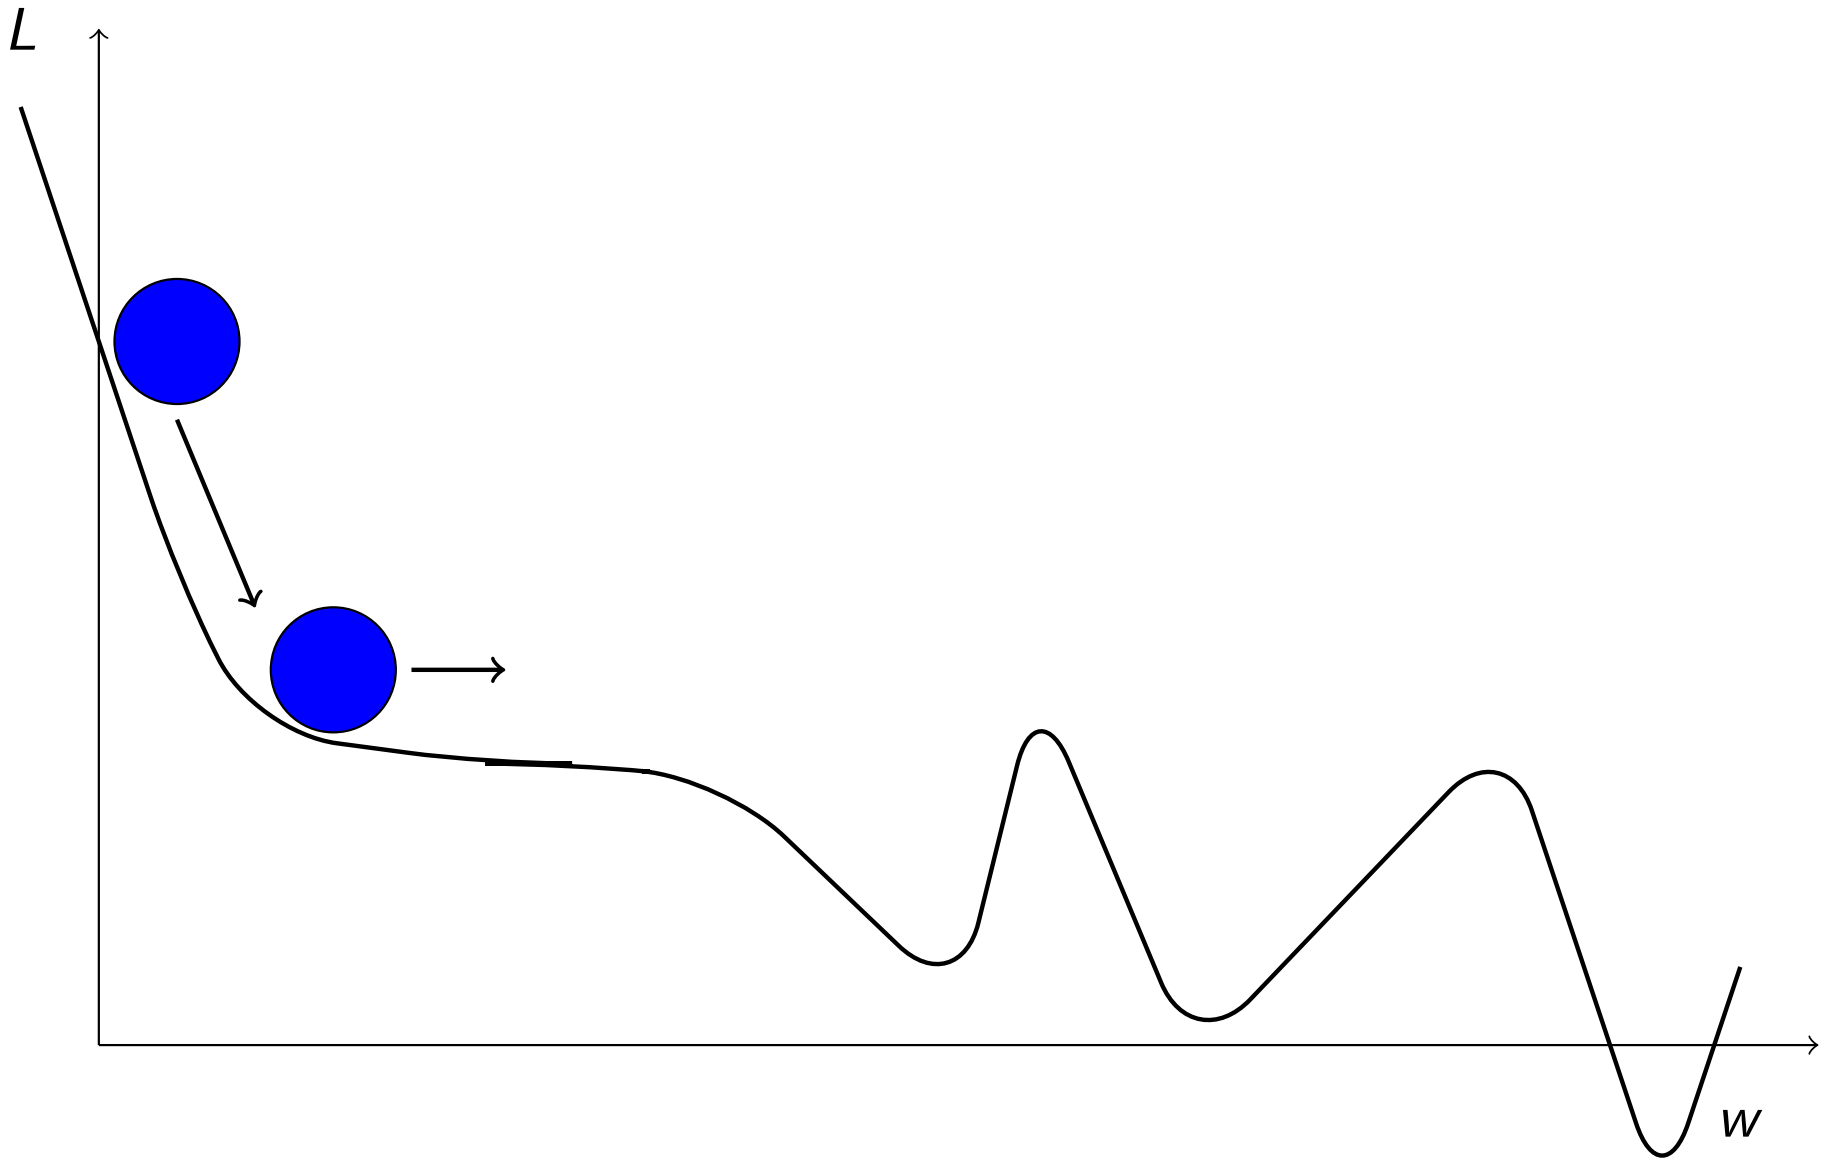

Descente du gradient

Méthode du Momentum :

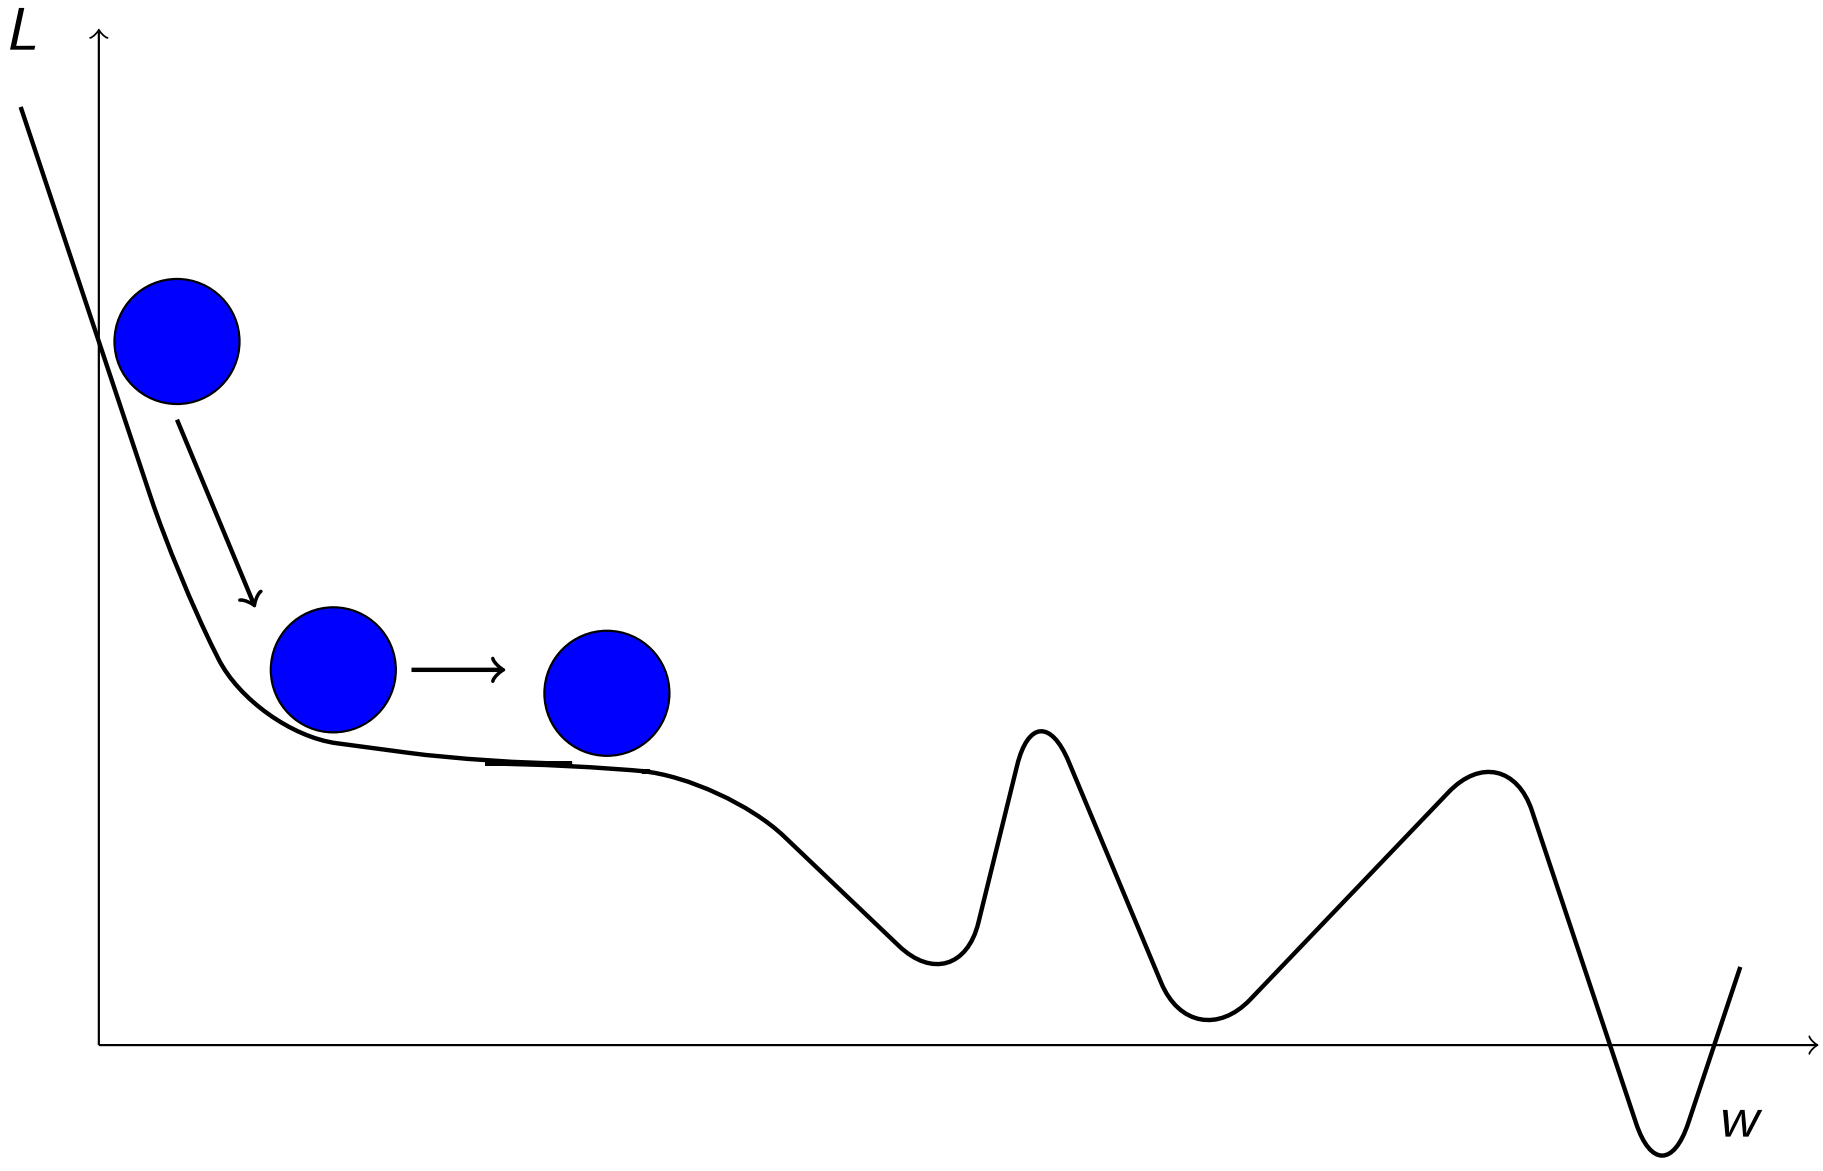

Descente du gradient

Méthode du Momentum :

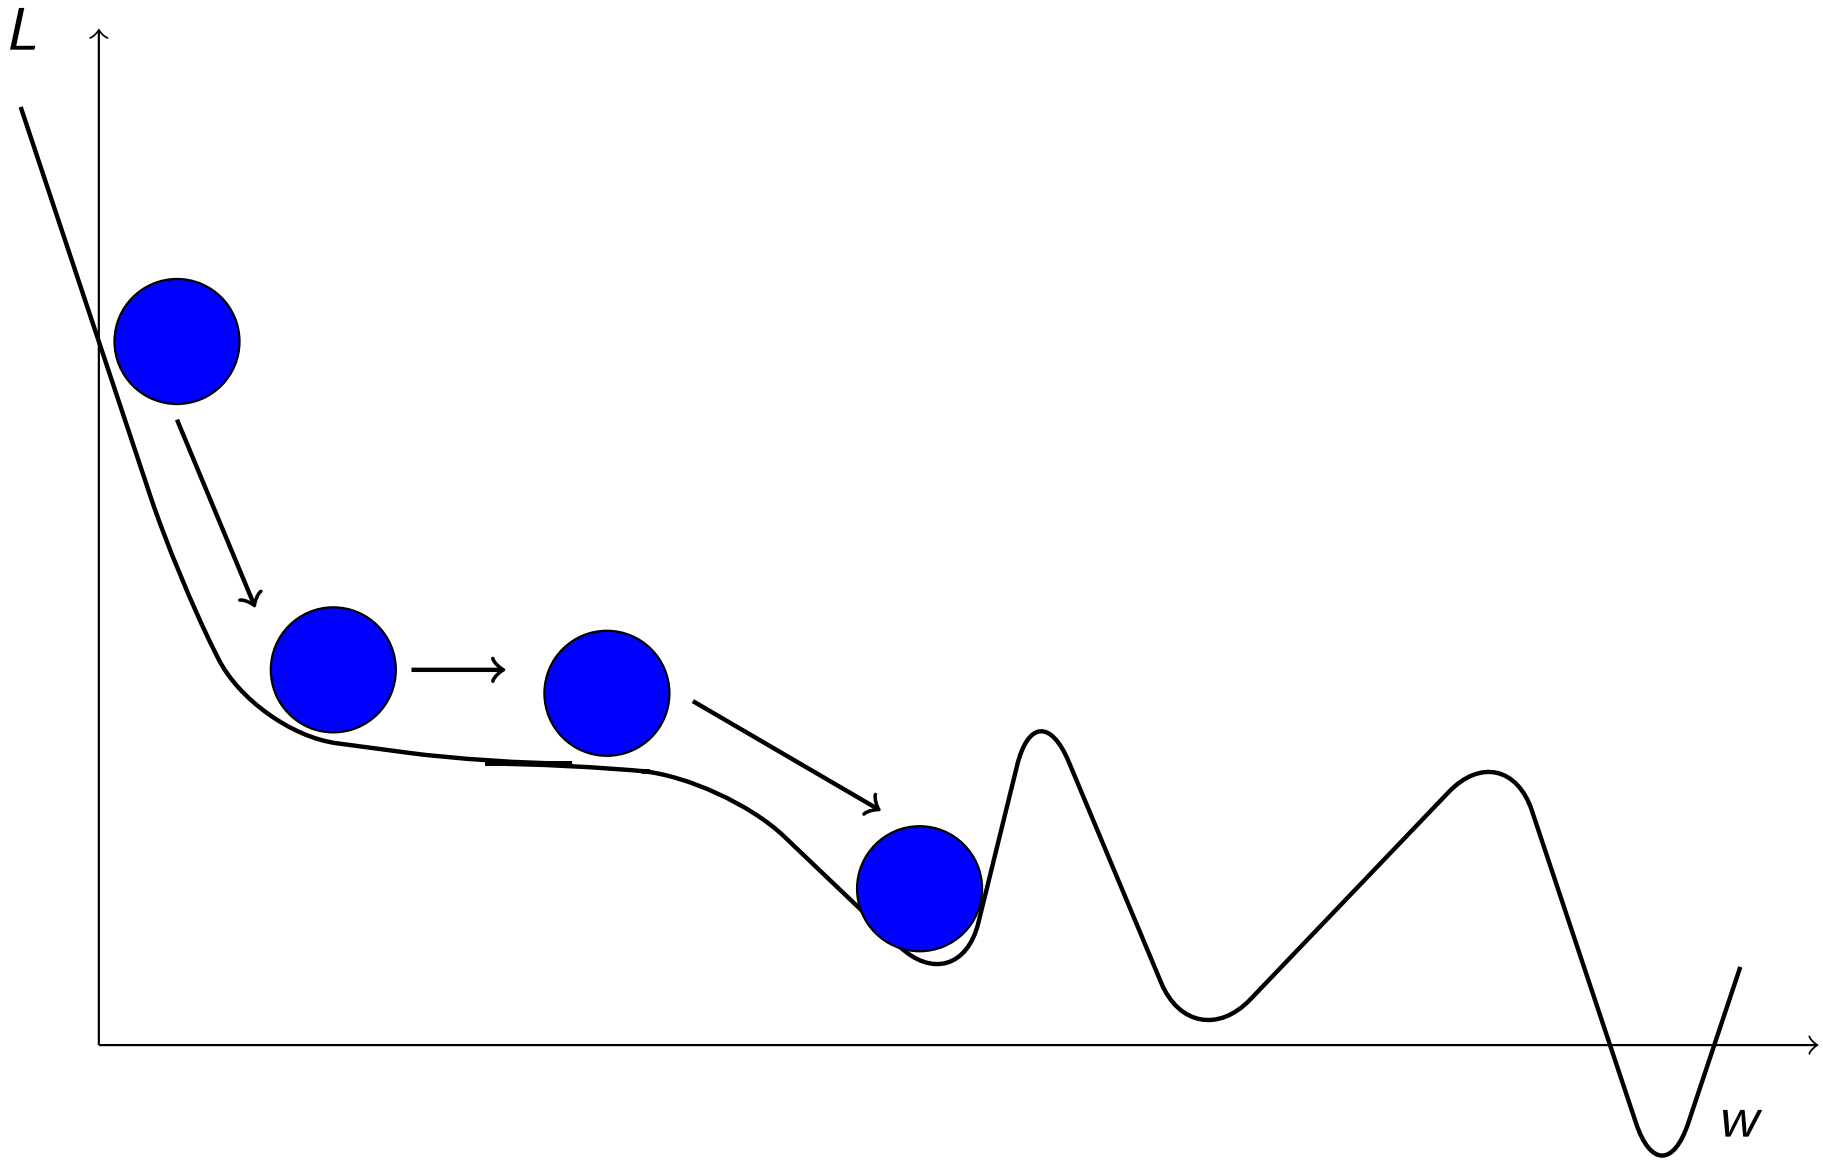

Descente du gradient

Méthode du Momentum :

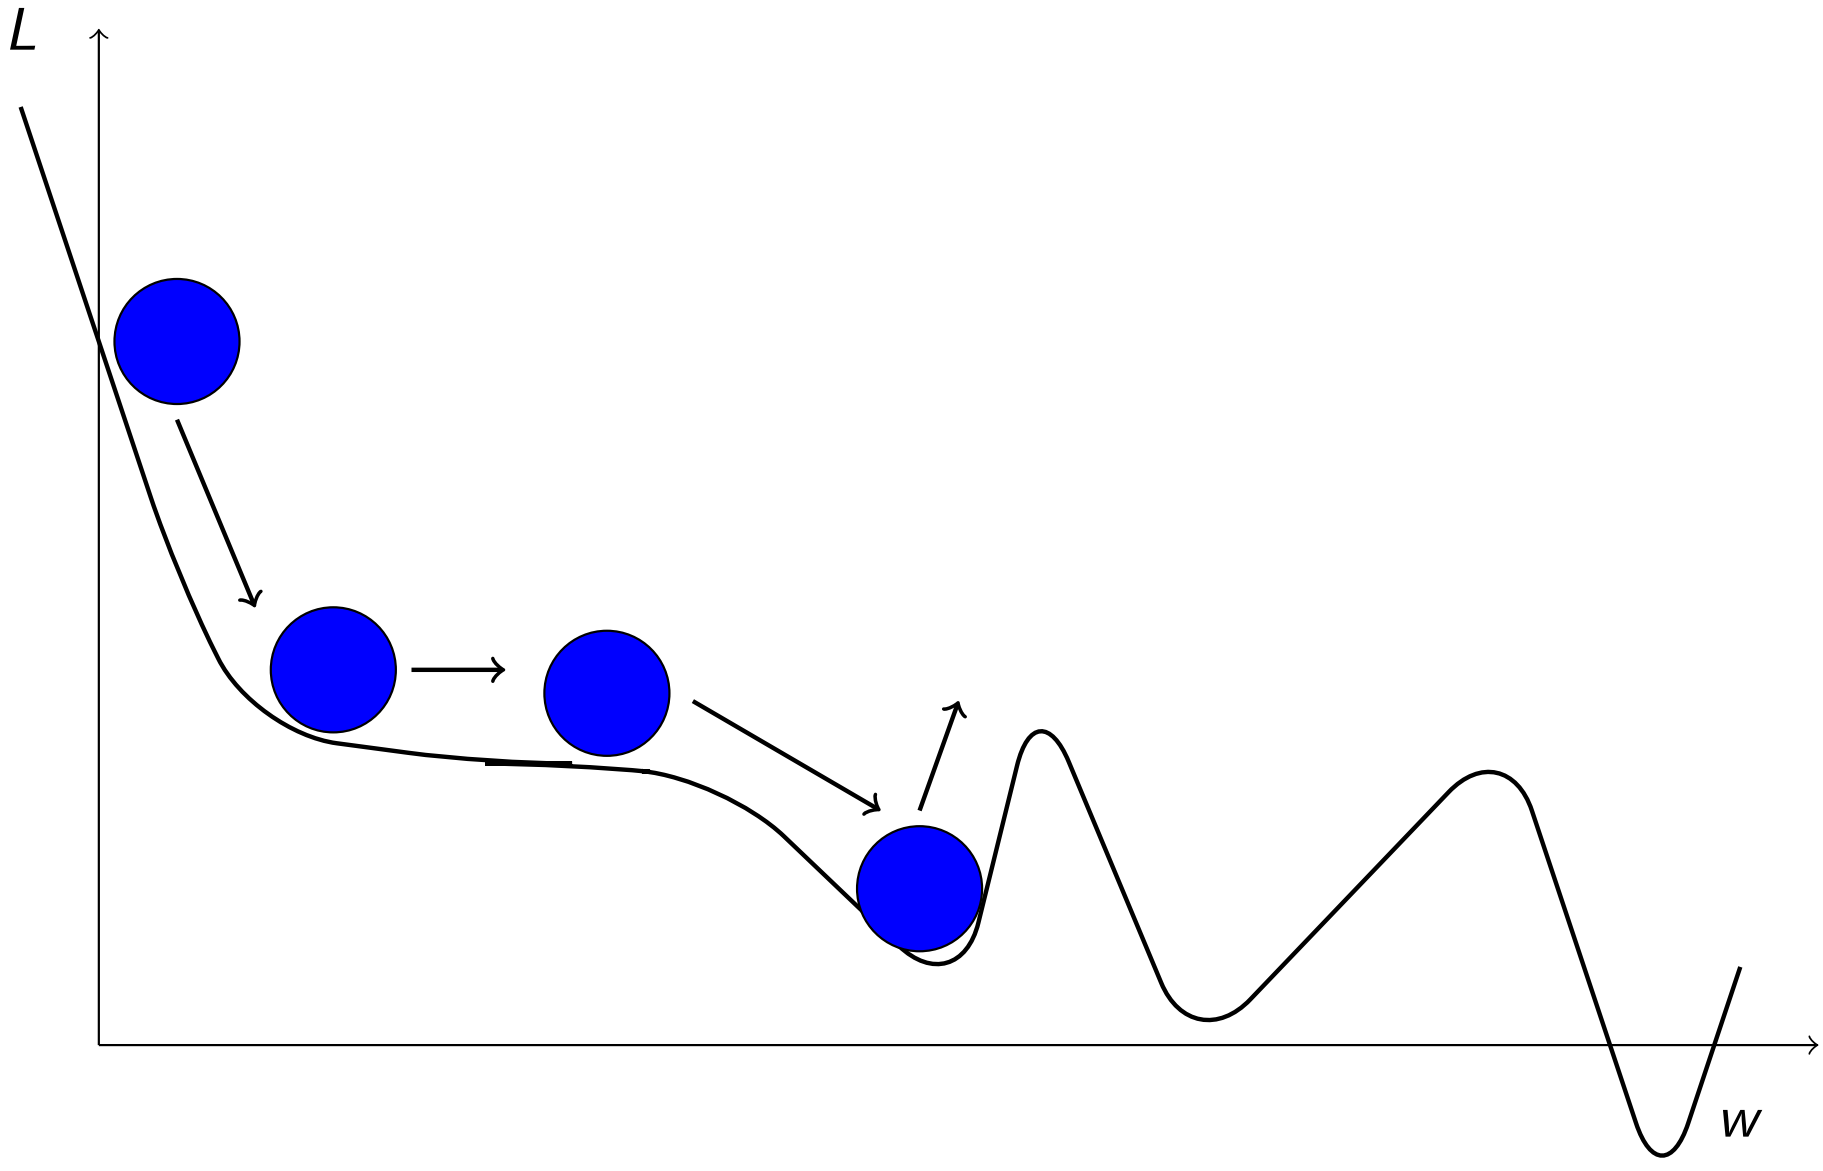

Descente du gradient

Problème : minimum mais local ....

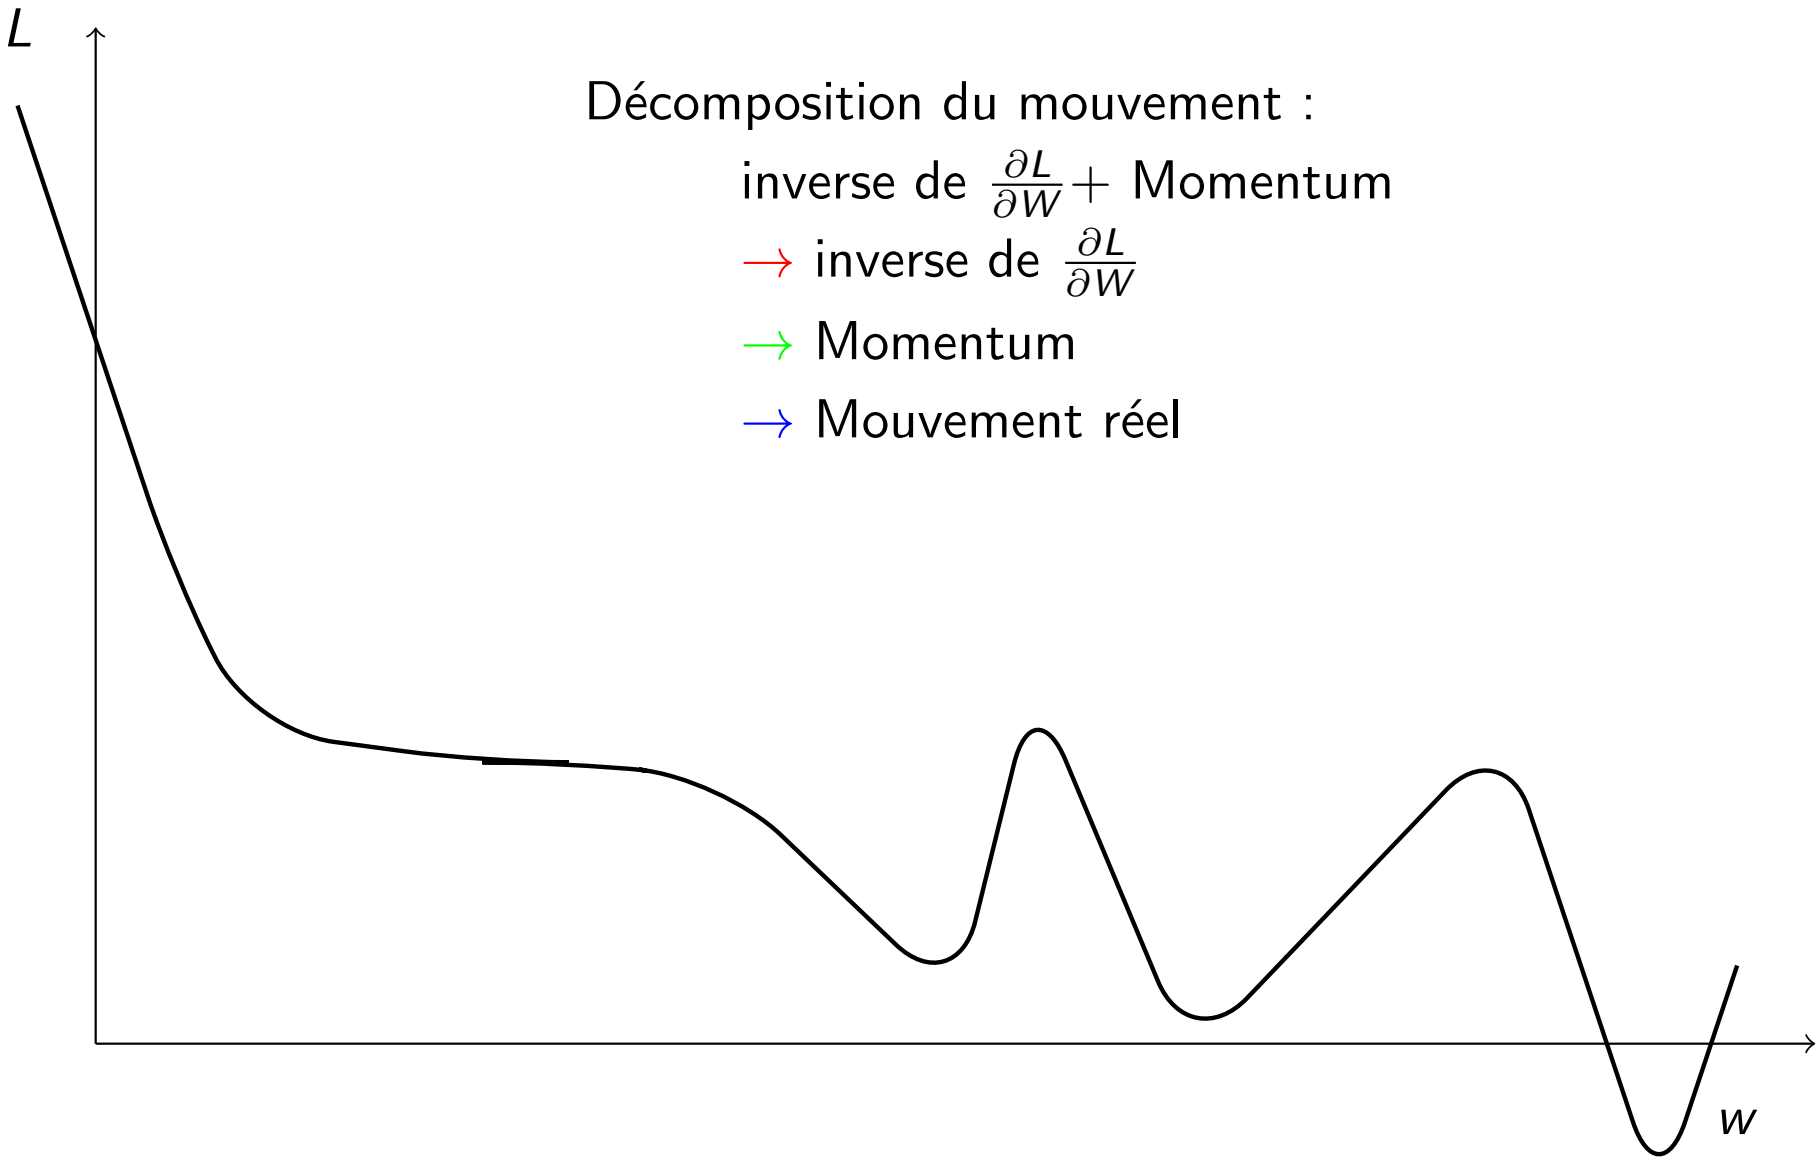

Décomposition du mouvement :

inverse de $\frac{\partial L}{\partial W}$ + Momentum

→ inverse de $\frac{\partial L}{\partial W}$

→ Momentum

→ Mouvement réel

Descente du gradient

Problème : minimum mais local ....

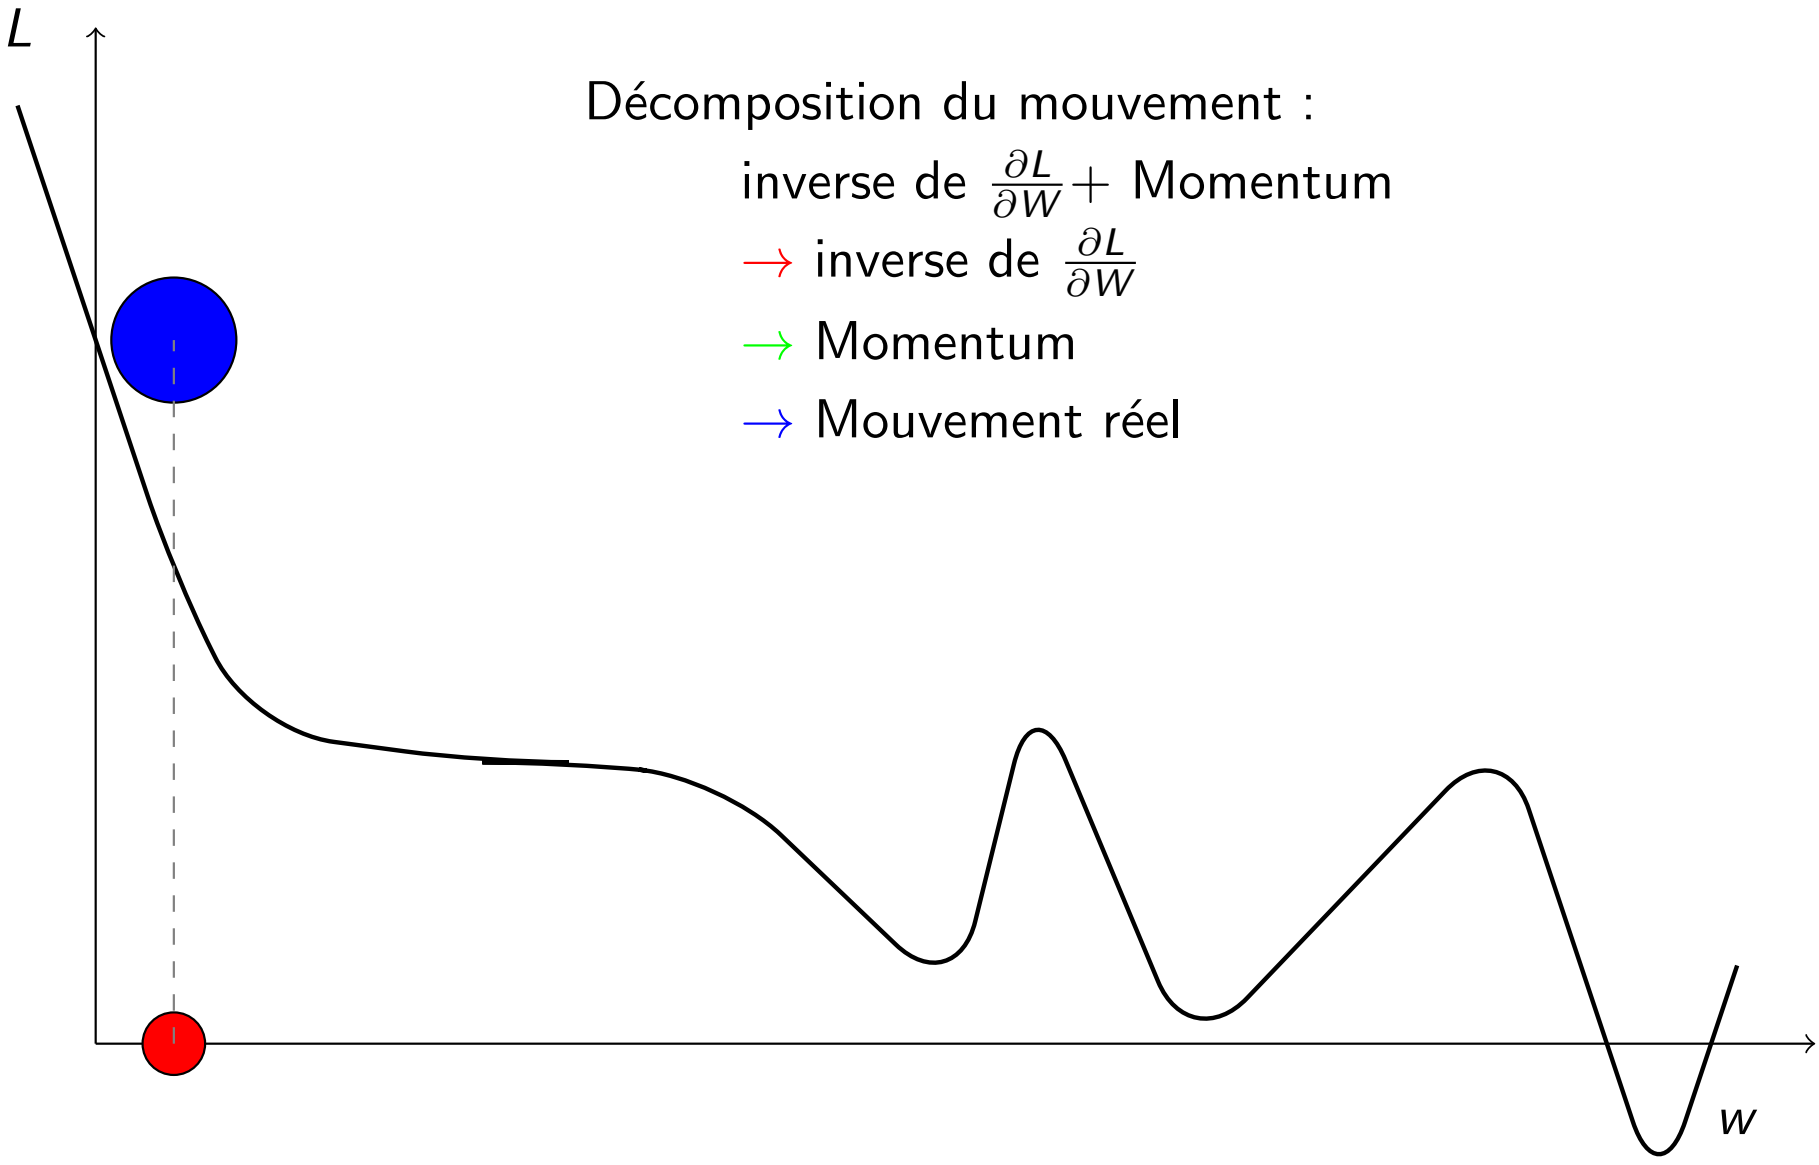

Décomposition du mouvement :

inverse de $\frac{\partial L}{\partial W}$ + Momentum

→ inverse de $\frac{\partial L}{\partial W}$

→ Momentum

→ Mouvement réel

Descente du gradient

Problème : minimum mais local ....

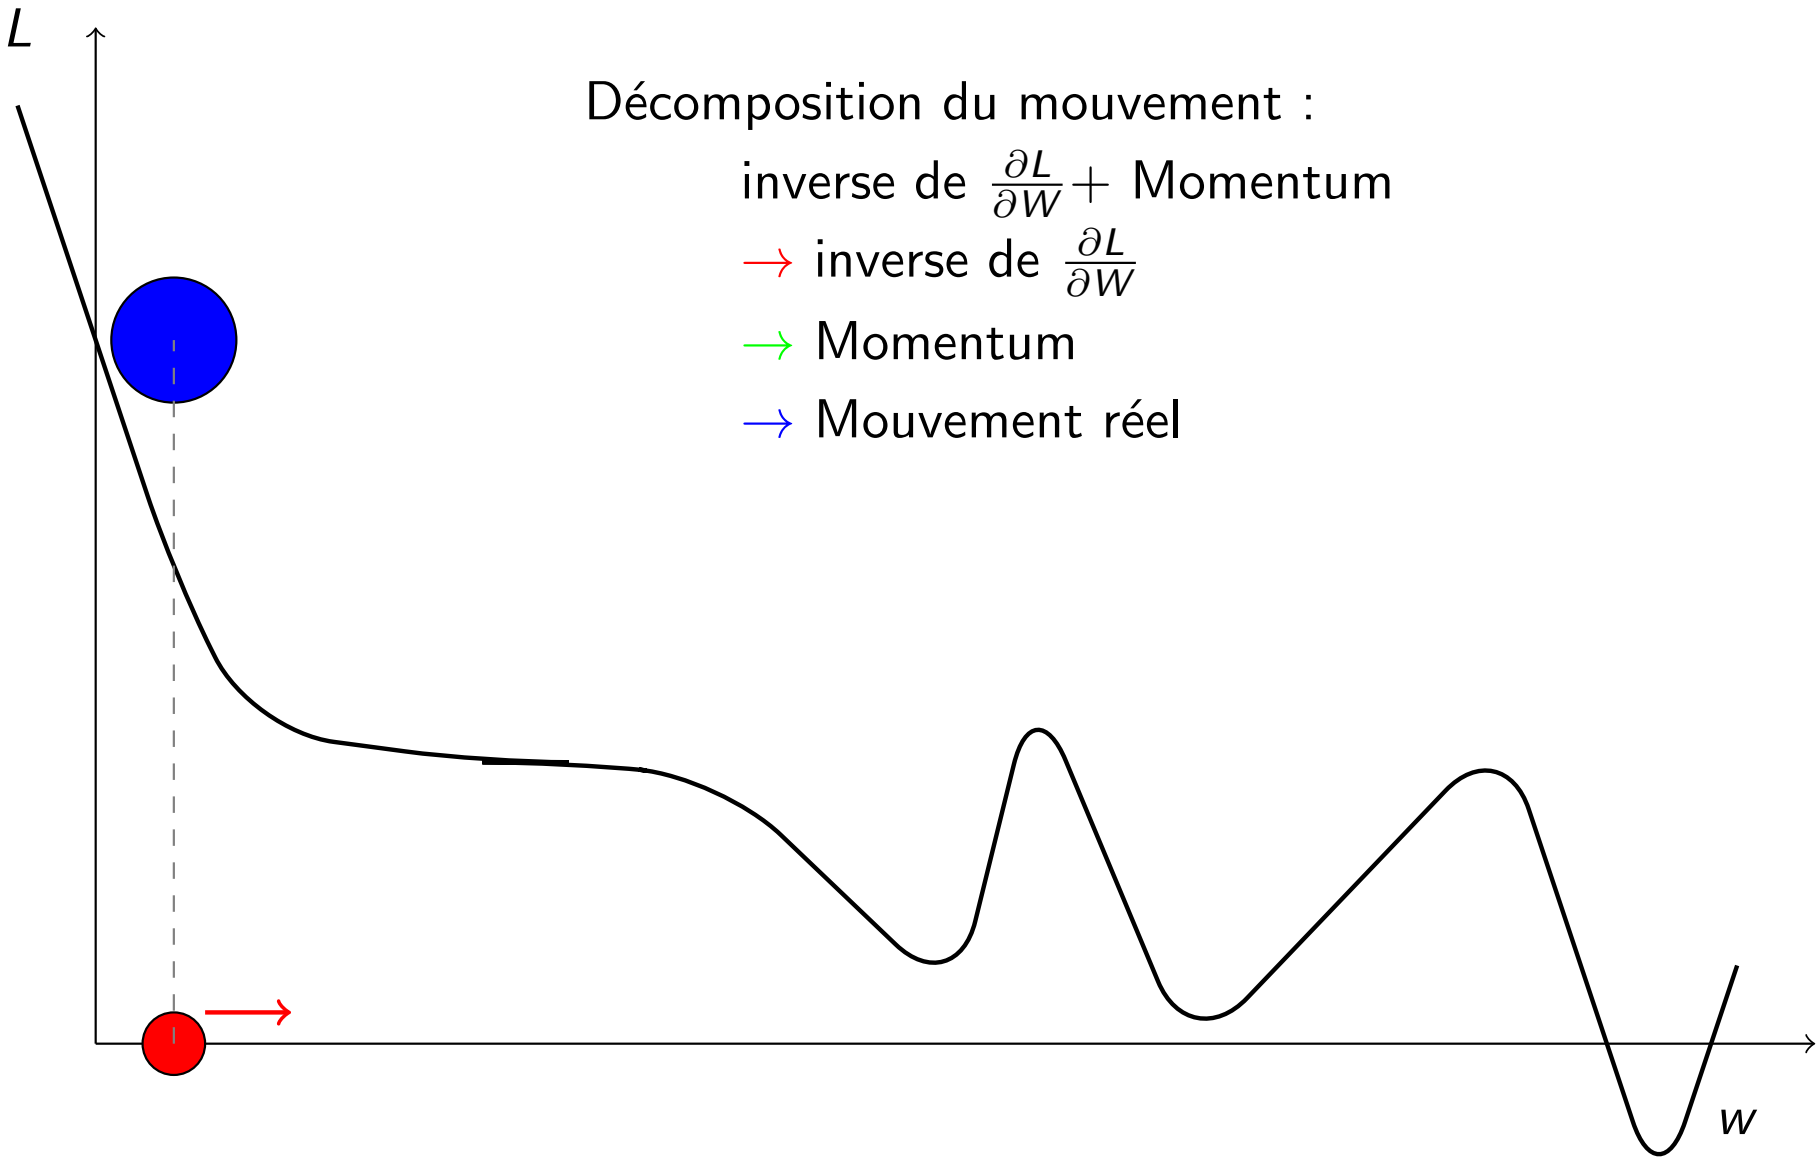

Décomposition du mouvement :

inverse de $\frac{\partial L}{\partial W}$ + Momentum

→ inverse de $\frac{\partial L}{\partial W}$

→ Momentum

→ Mouvement réel

Descente du gradient

Problème : minimum mais local ....

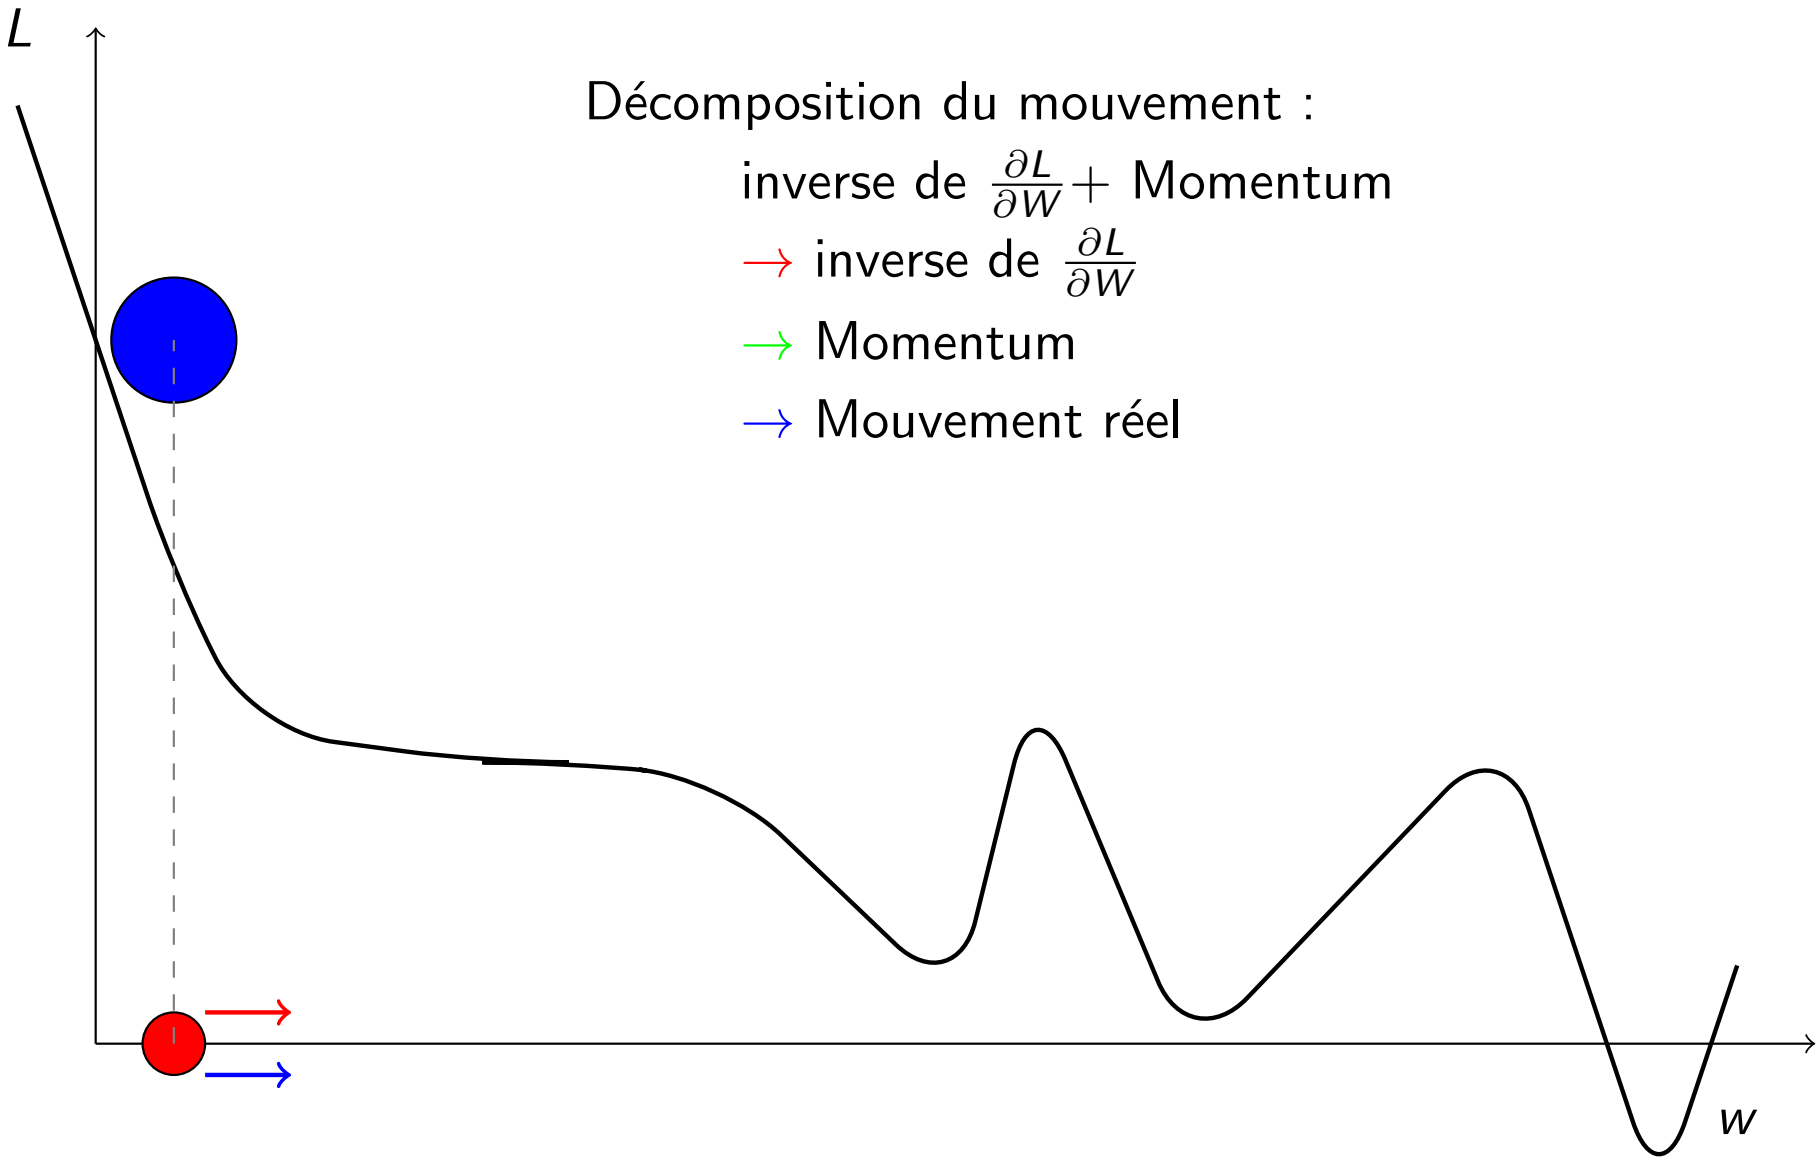

Décomposition du mouvement :

inverse de $\frac{\partial L}{\partial W}$ + Momentum

→ inverse de $\frac{\partial L}{\partial W}$

→ Momentum

→ Mouvement réel

Descente du gradient

Problème : minimum mais local ....

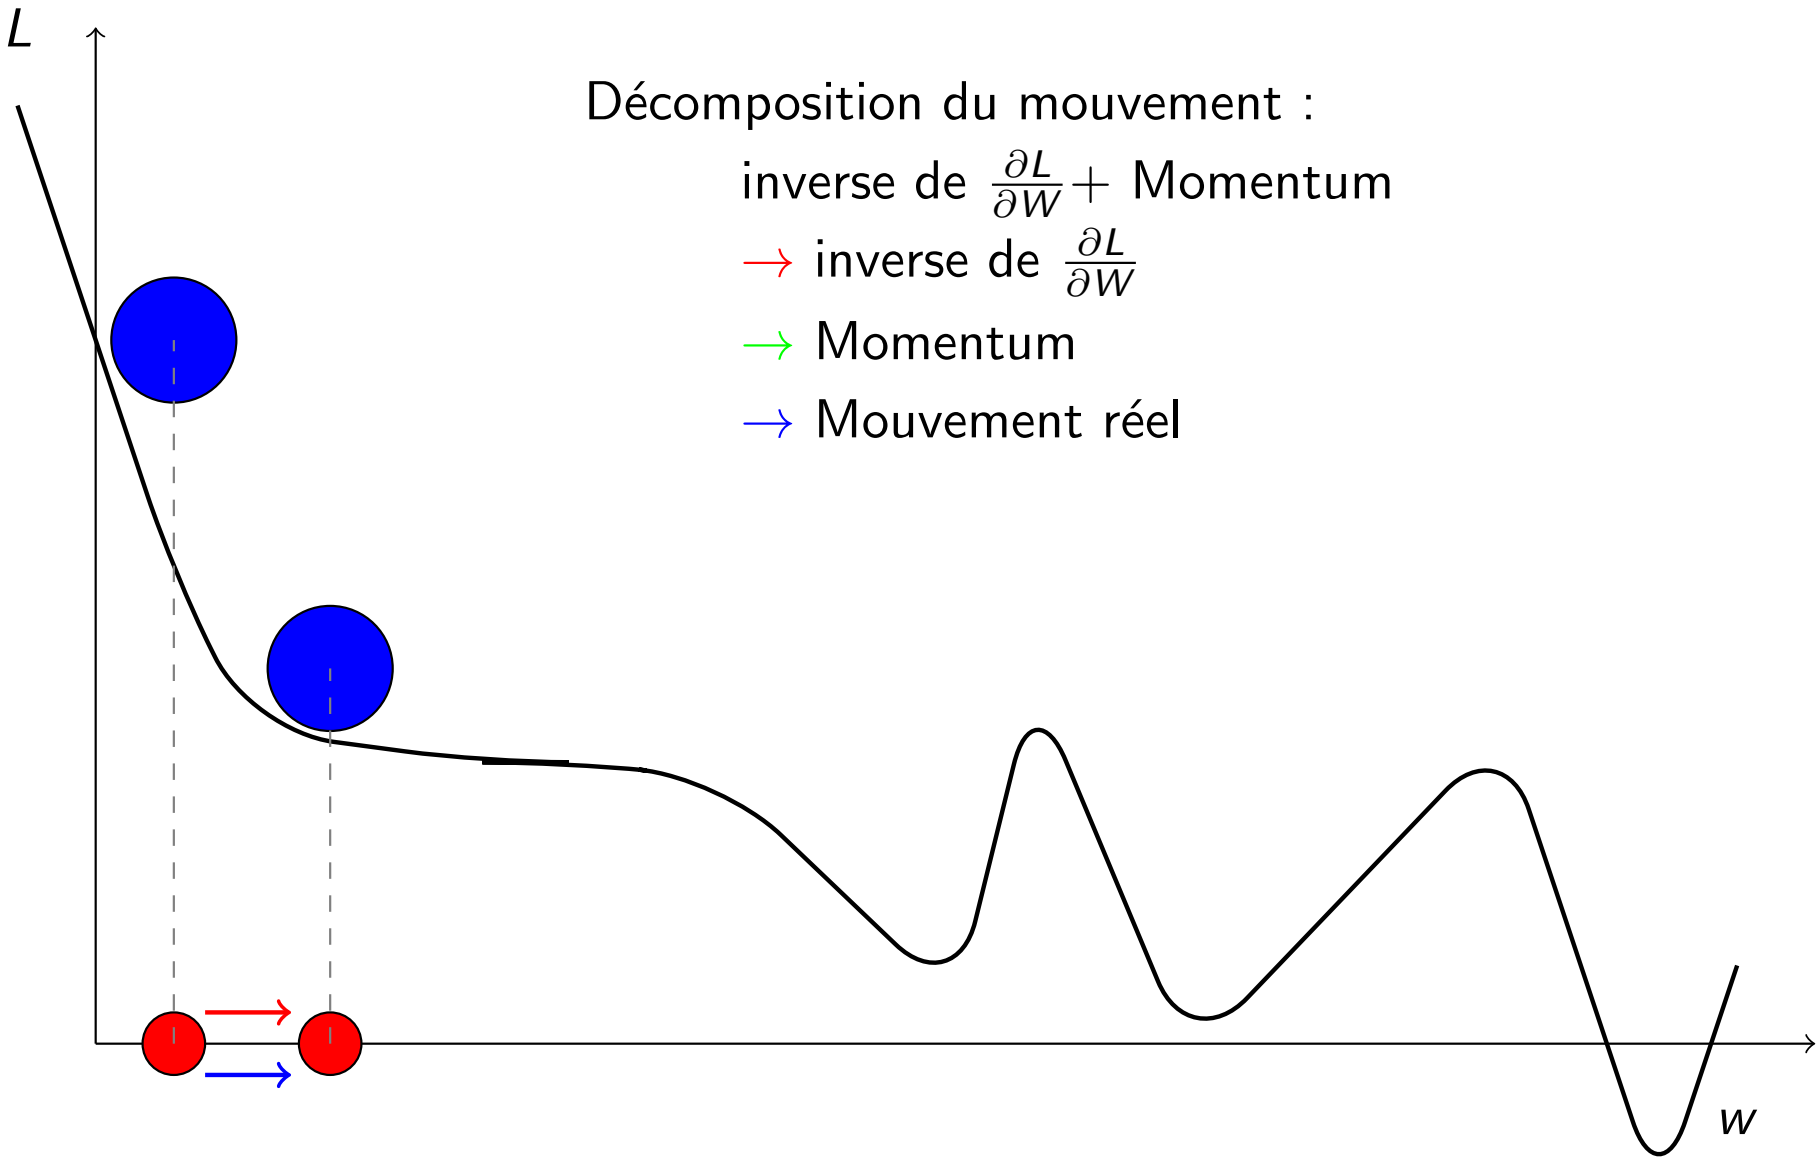

Décomposition du mouvement :

inverse de $\frac{\partial L}{\partial W}$ + Momentum

→ inverse de $\frac{\partial L}{\partial W}$

→ Momentum

→ Mouvement réel

Descente du gradient

Problème : minimum mais local ....

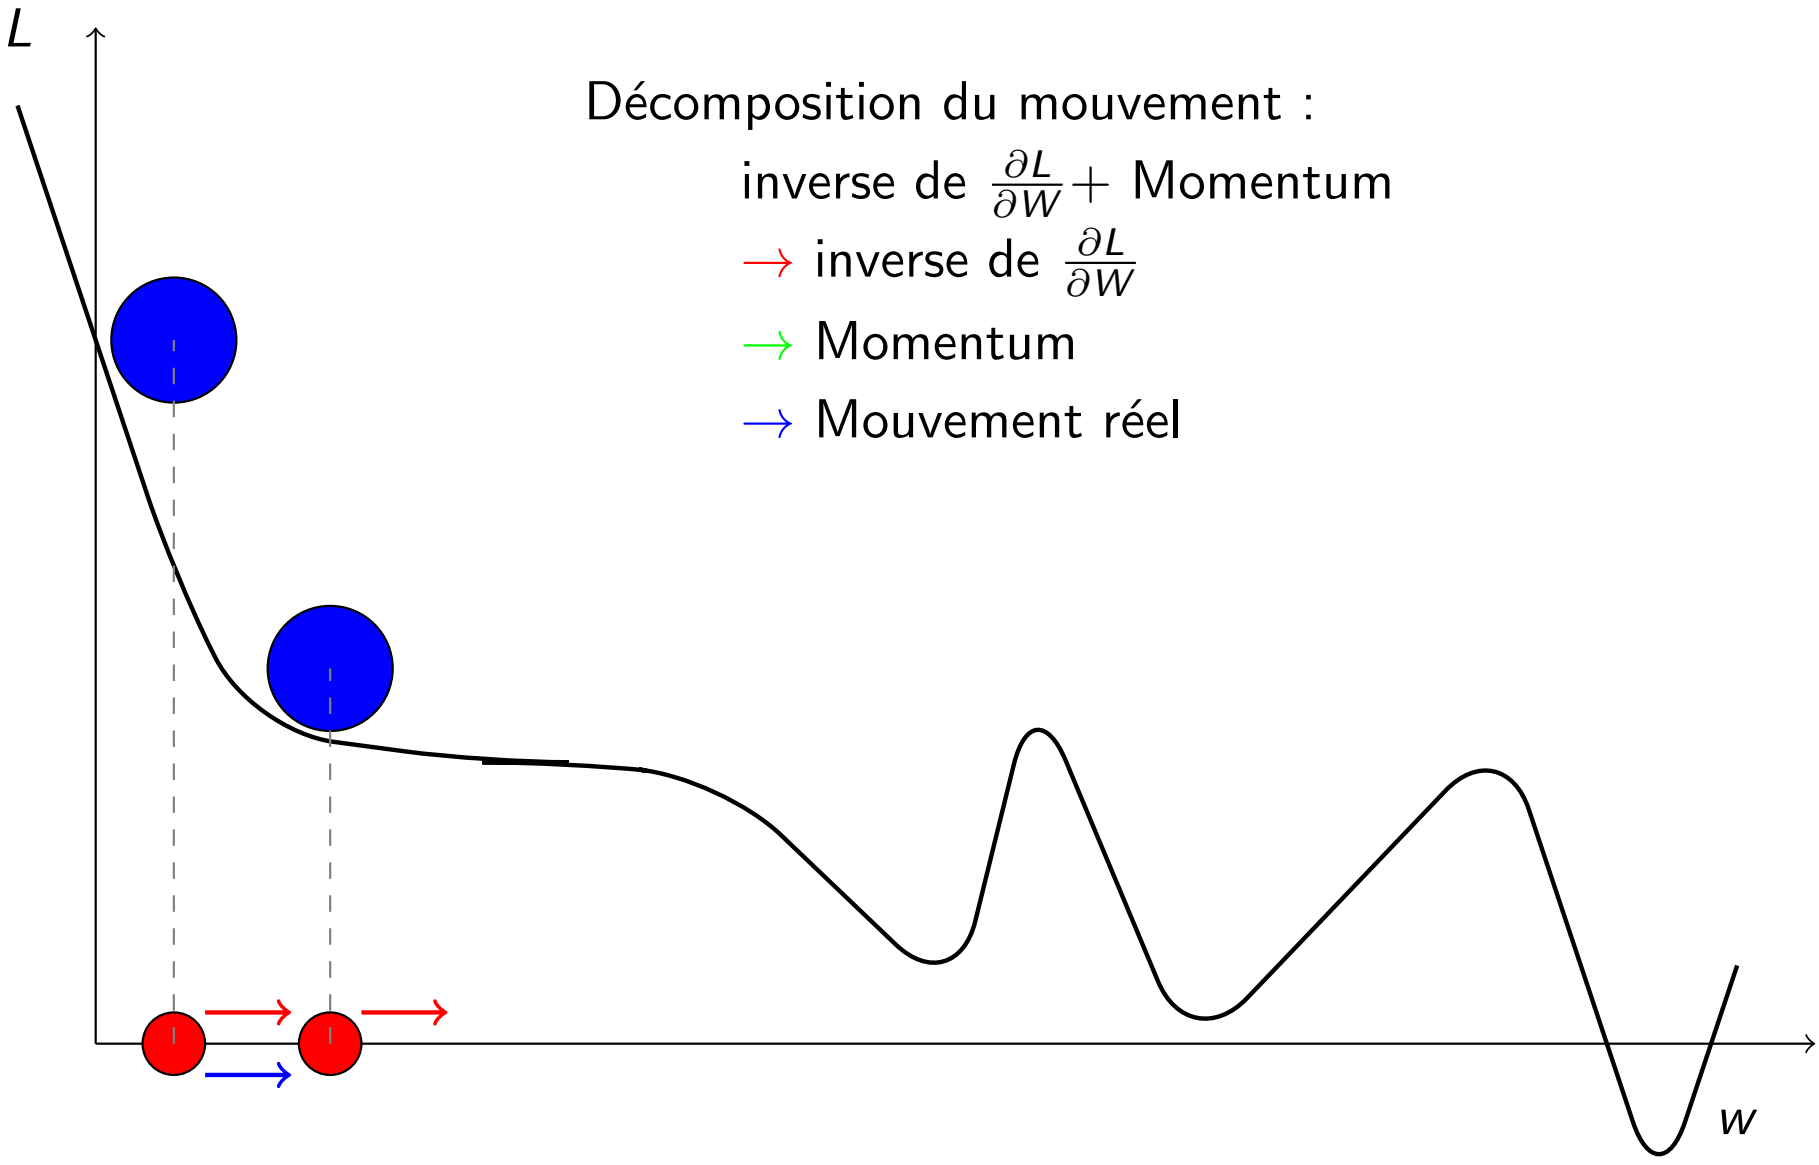

Décomposition du mouvement :

inverse de $\frac{\partial L}{\partial W}$ + Momentum

→ inverse de $\frac{\partial L}{\partial W}$

→ Momentum

→ Mouvement réel

Descente du gradient

Problème : minimum mais local ....

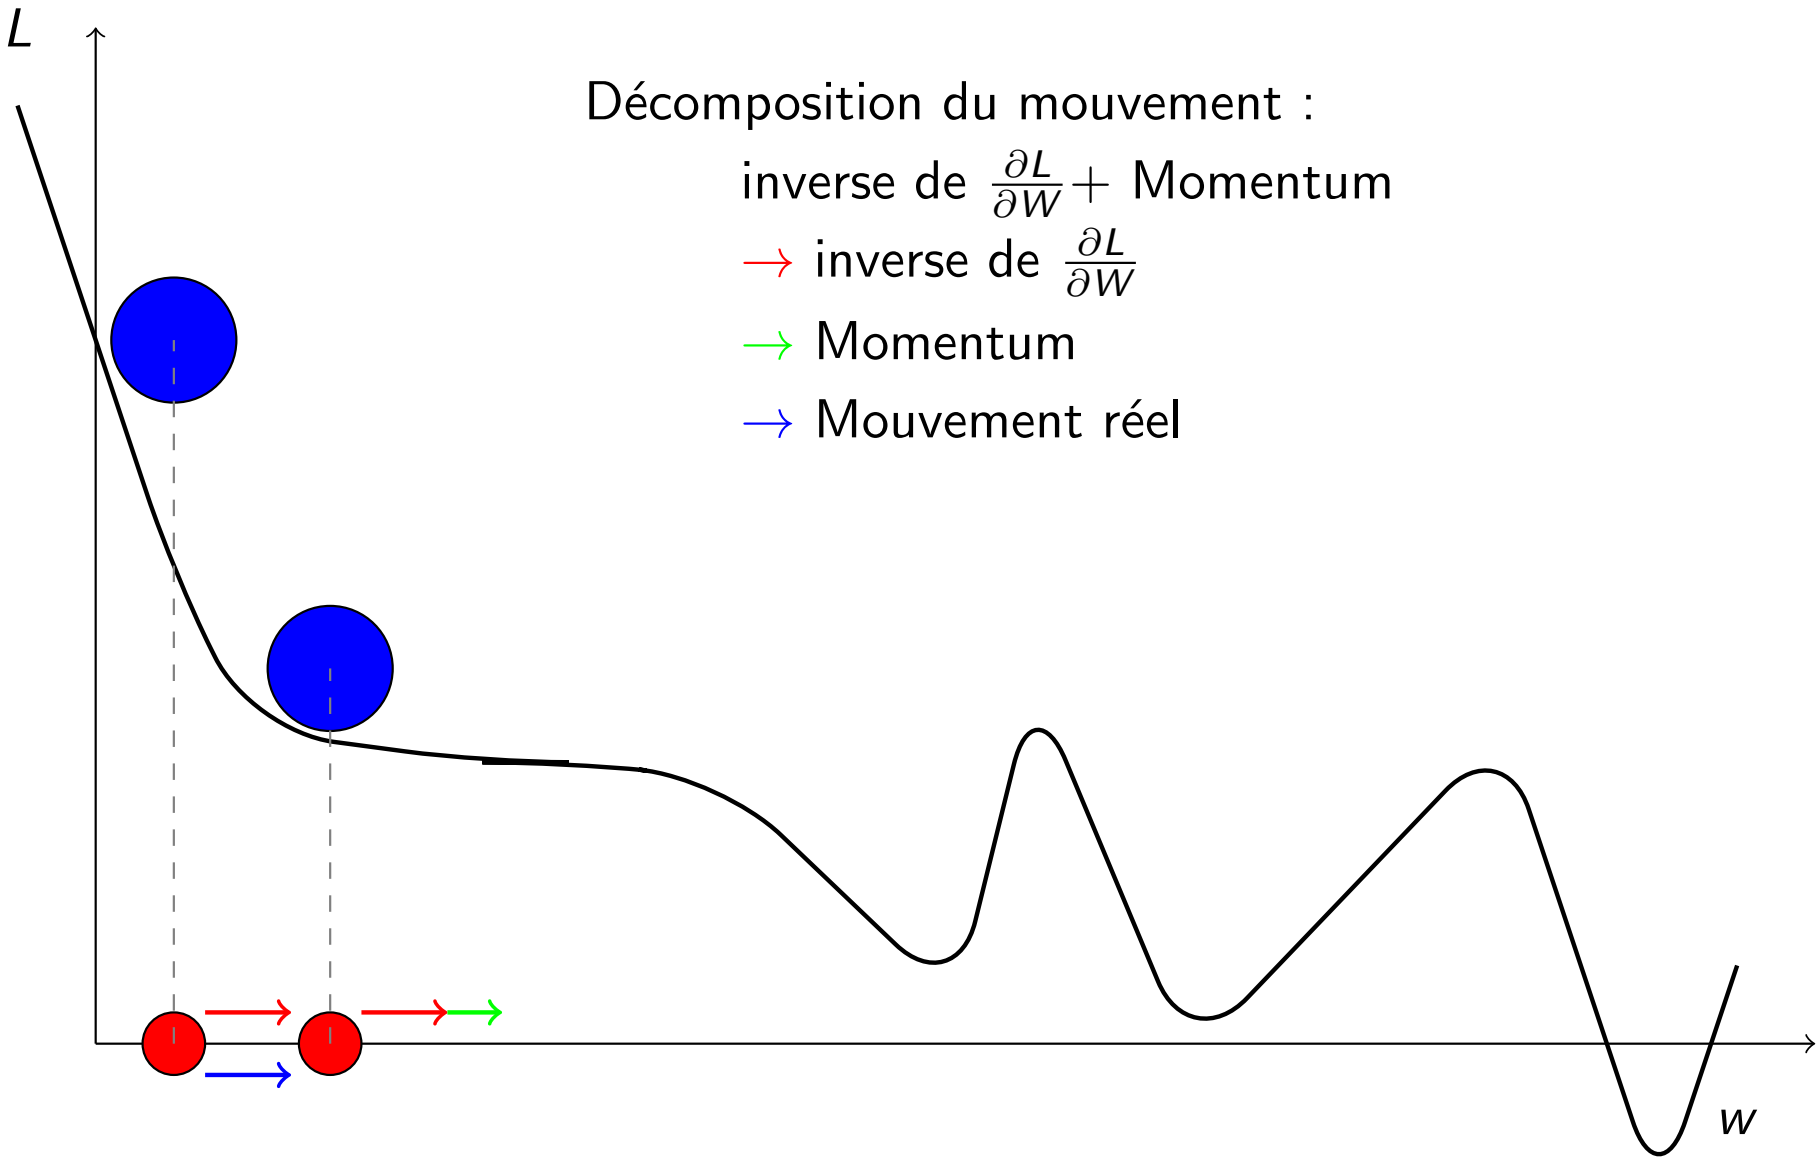

Décomposition du mouvement :

inverse de $\frac{\partial L}{\partial W}$ + Momentum

→ inverse de $\frac{\partial L}{\partial W}$

→ Momentum

→ Mouvement réel

Descente du gradient

Problème : minimum mais local ....

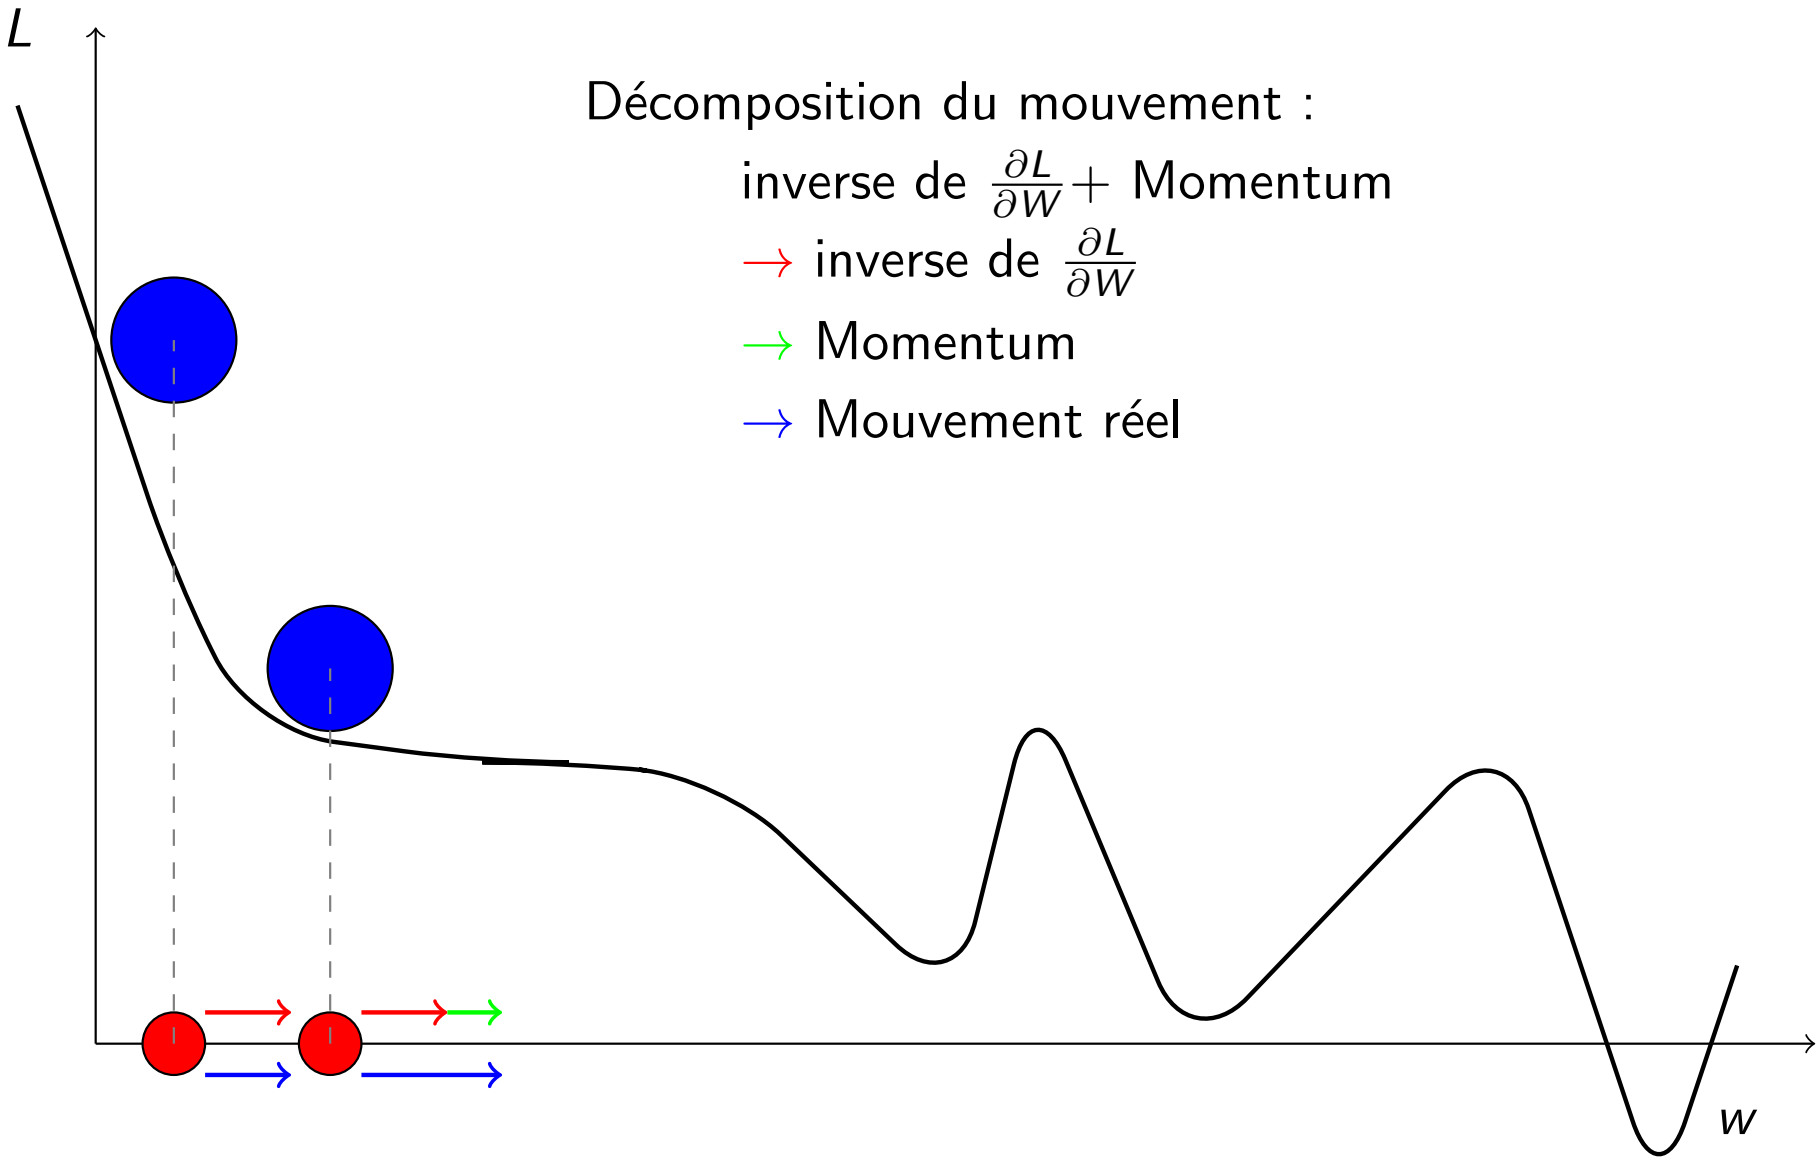

Décomposition du mouvement :

inverse de $\frac{\partial L}{\partial W}$ + Momentum

→ inverse de $\frac{\partial L}{\partial W}$

→ Momentum

→ Mouvement réel

Descente du gradient

Problème : minimum mais local ....

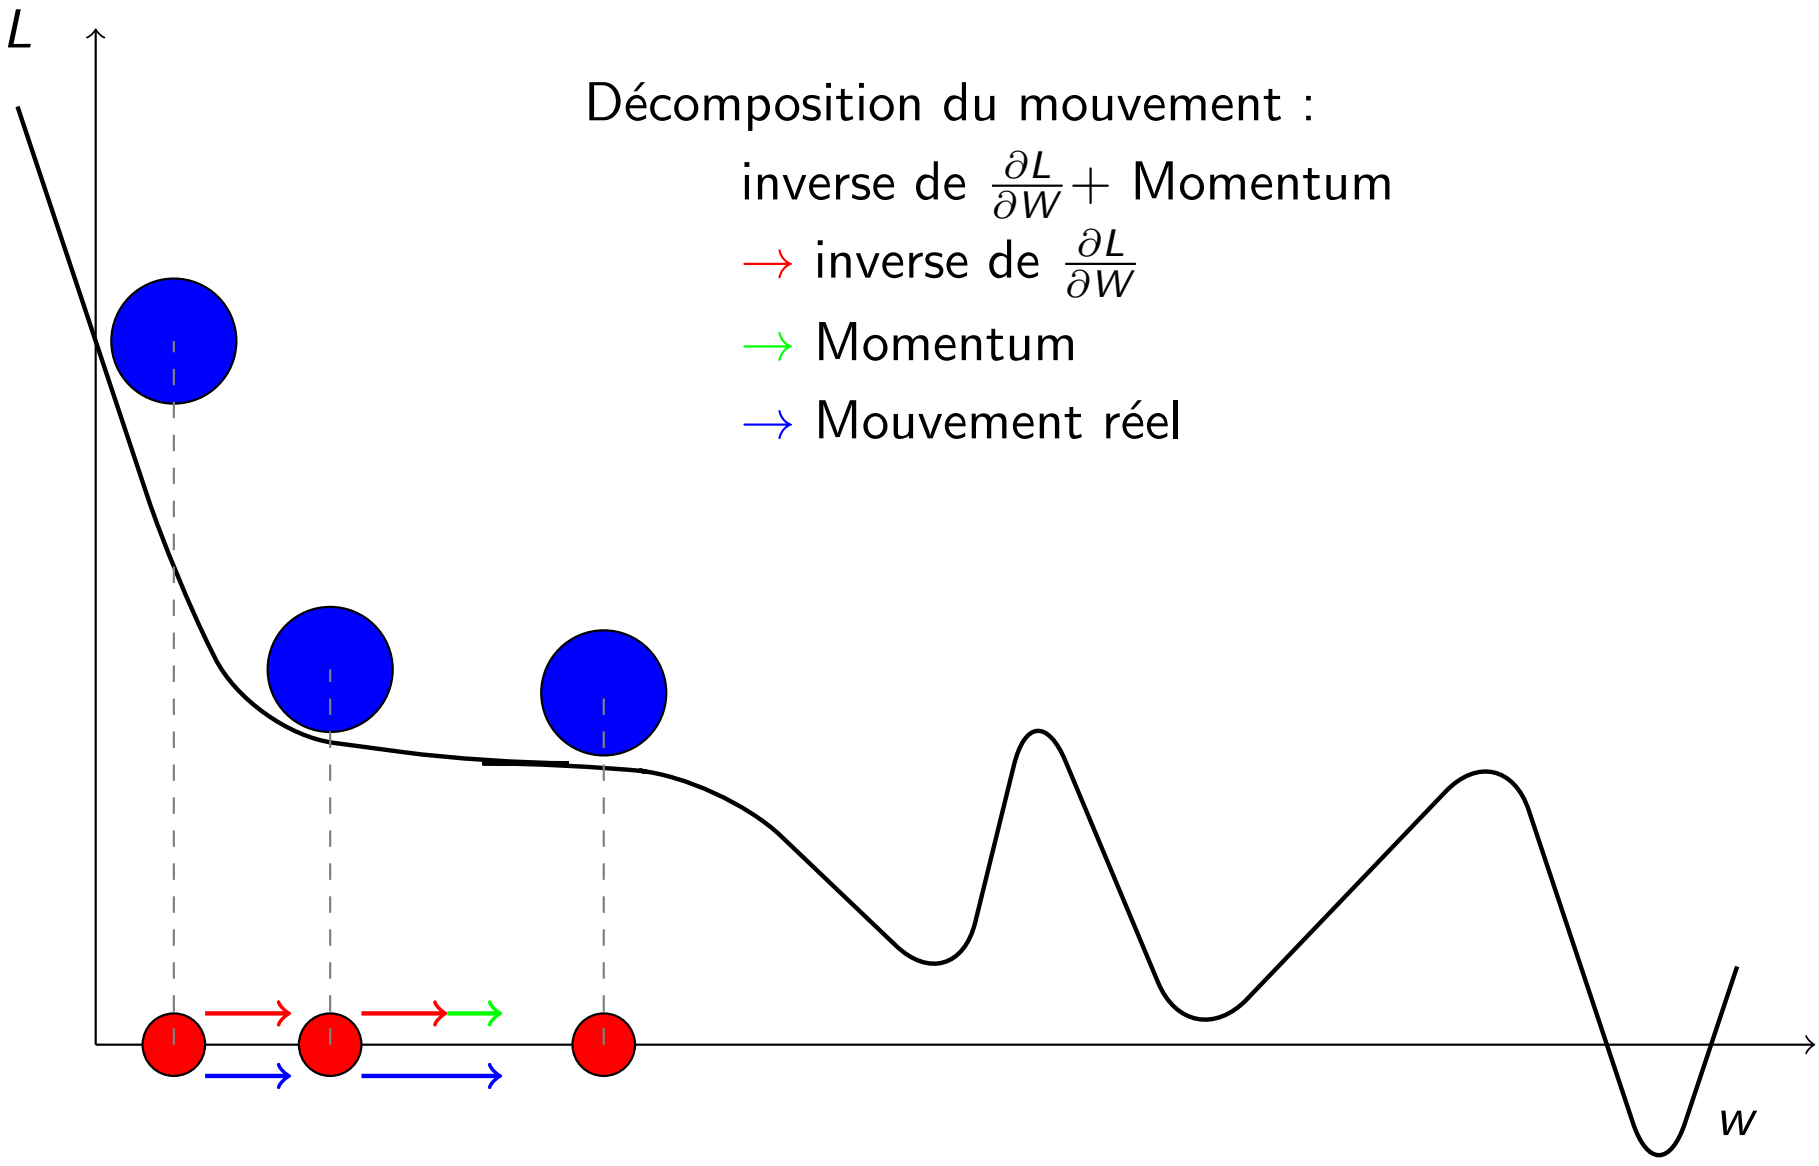

Décomposition du mouvement :

inverse de $\frac{\partial L}{\partial W}$ + Momentum

→ inverse de $\frac{\partial L}{\partial W}$

→ Momentum

→ Mouvement réel

Descente du gradient

Problème : minimum mais local ....

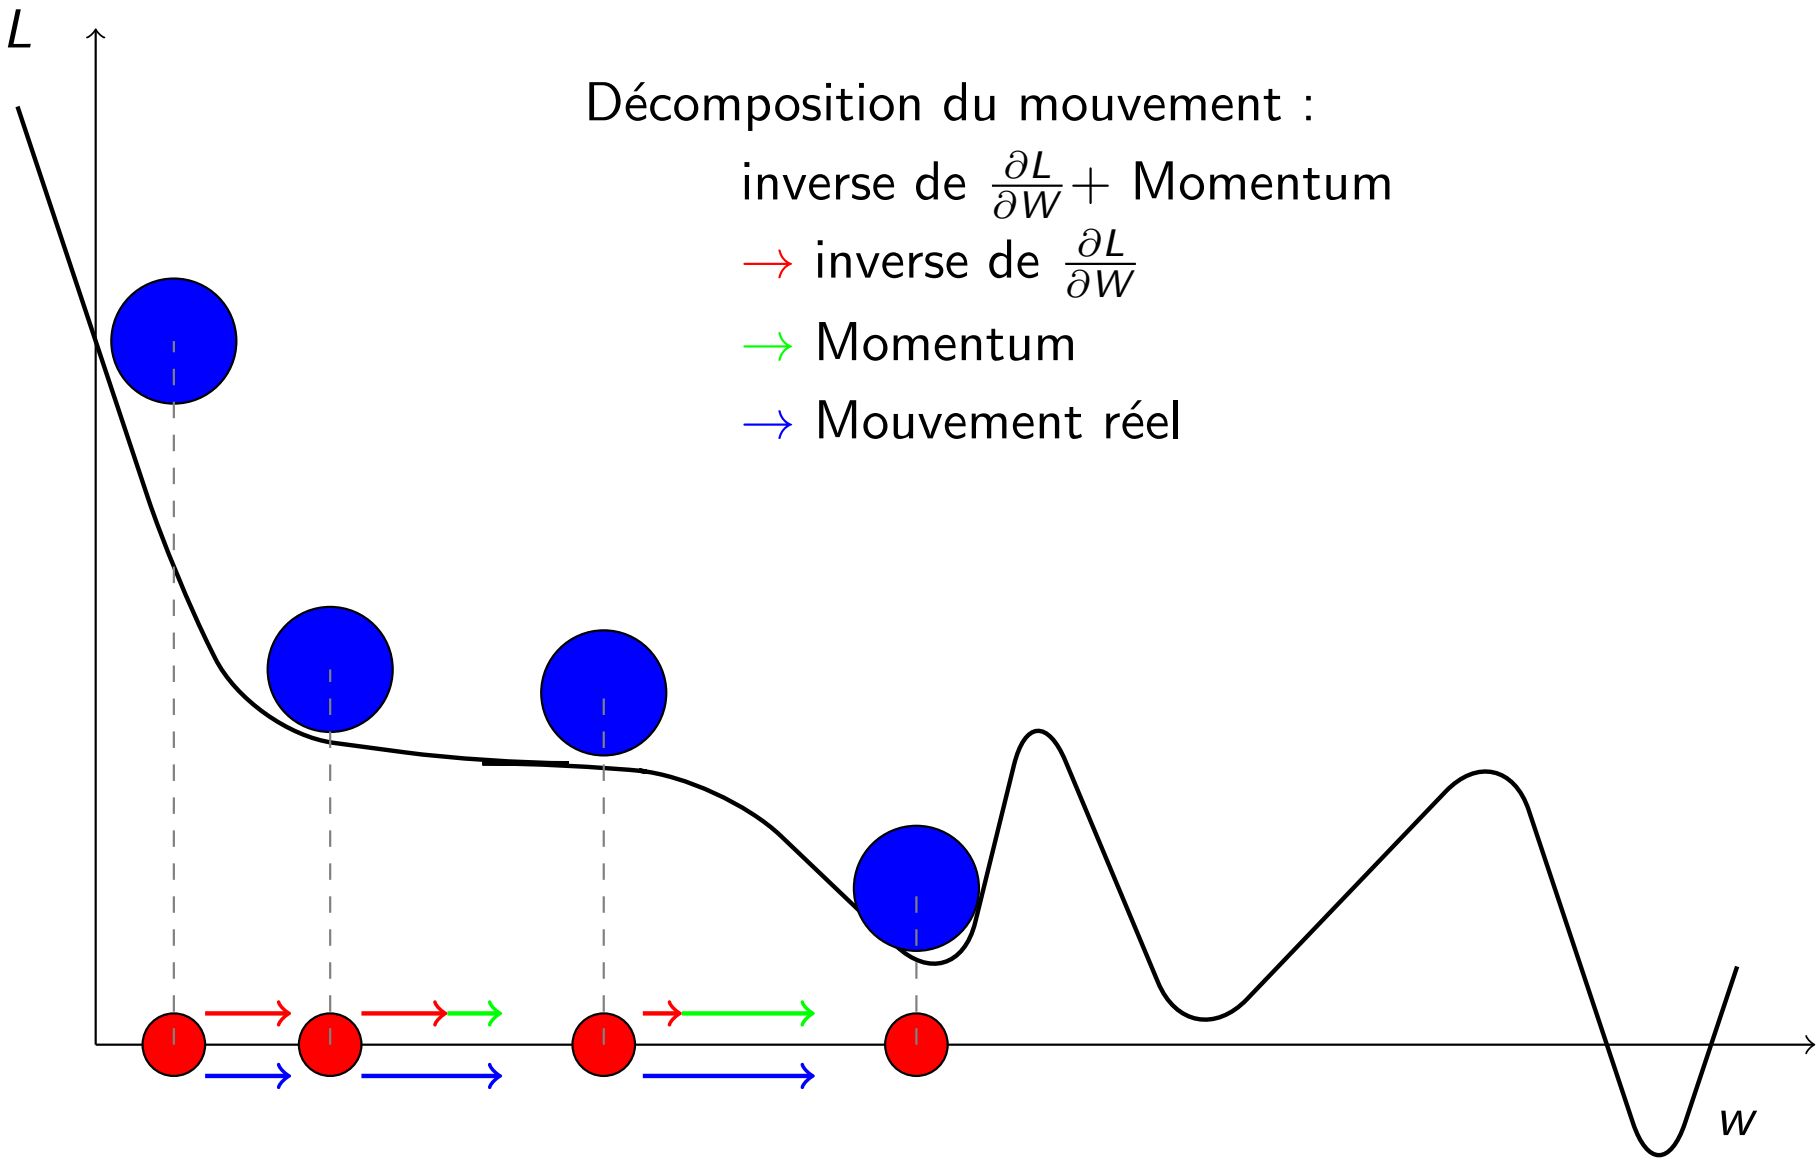

Décomposition du mouvement :

inverse de $\frac{\partial L}{\partial W}$ + Momentum

→ inverse de $\frac{\partial L}{\partial W}$

→ Momentum

→ Mouvement réel

Descente du gradient

Problème : minimum mais local ....

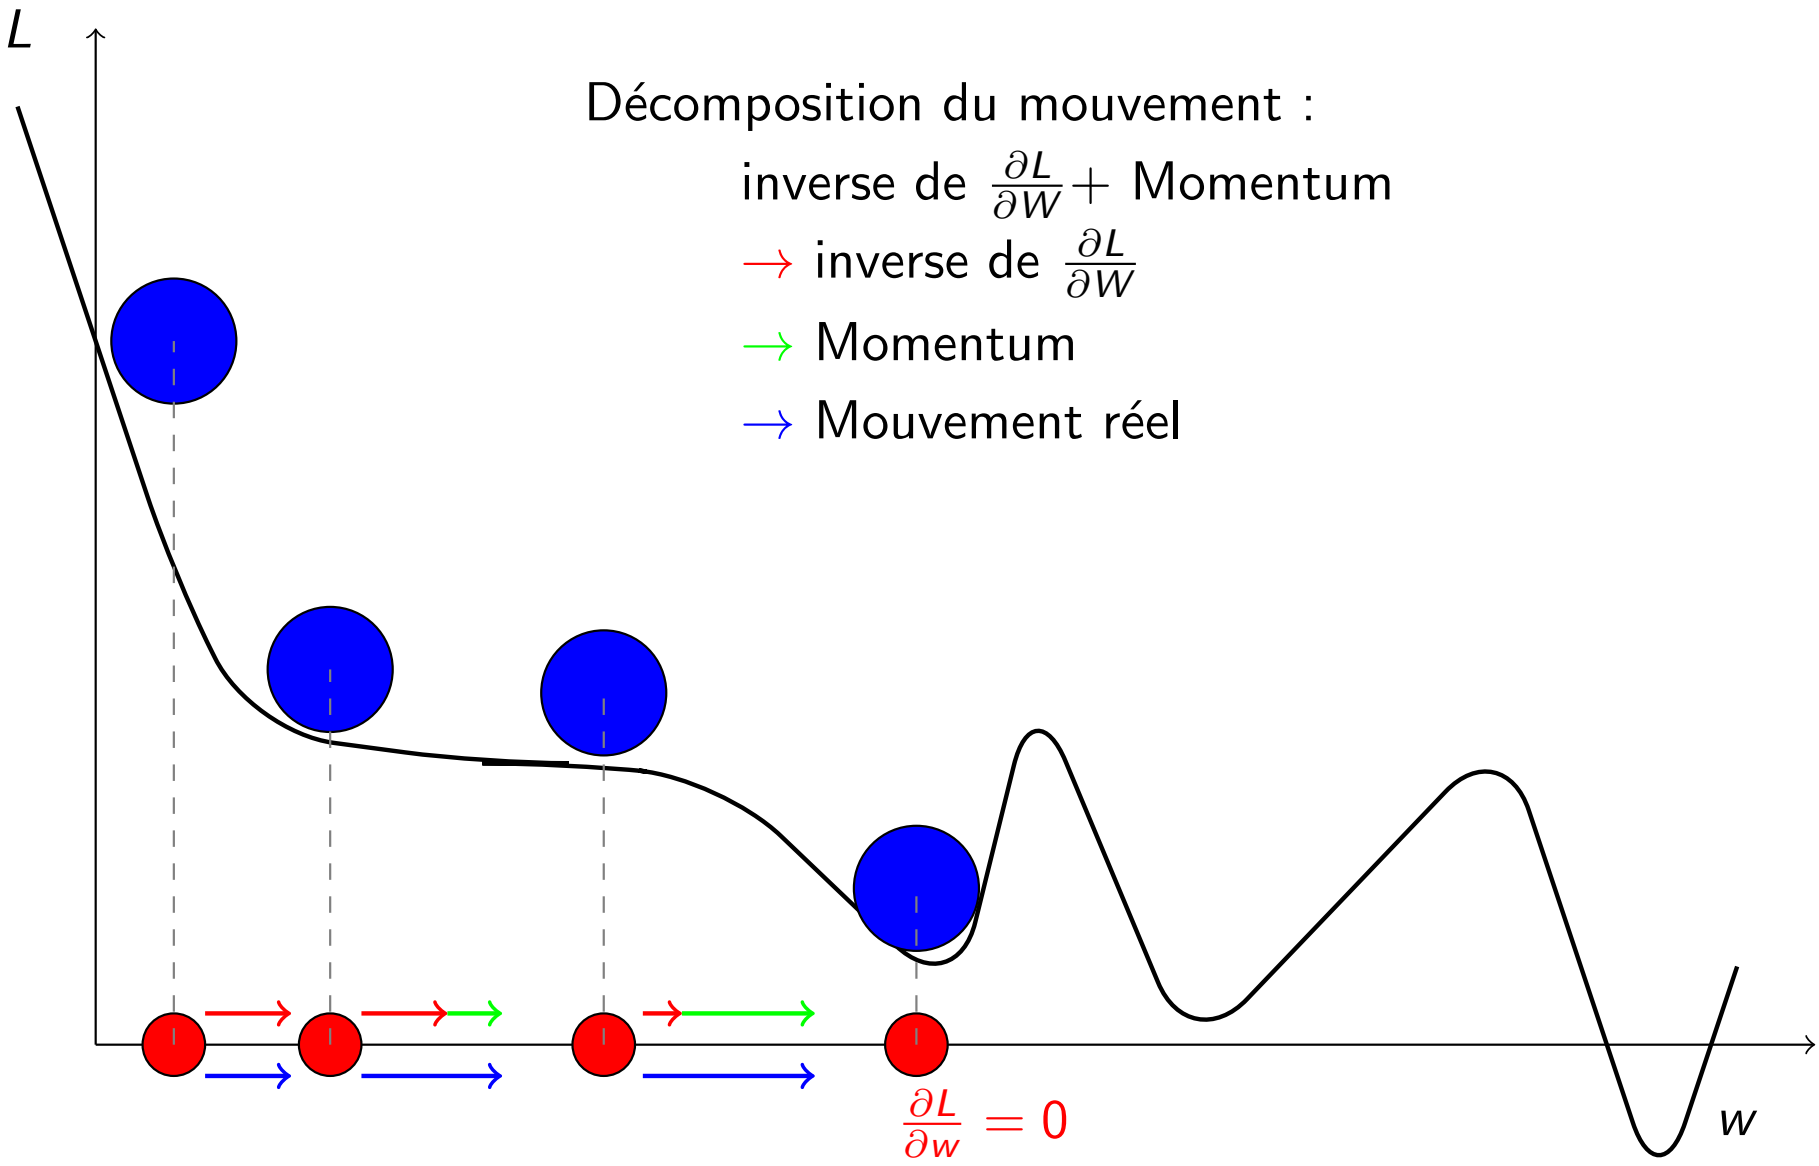

Décomposition du mouvement :

inverse de $\frac{\partial L}{\partial W}$ + Momentum

→ inverse de $\frac{\partial L}{\partial W}$

→ Momentum

→ Mouvement réel

Descente du gradient

Problème : minimum mais local ....

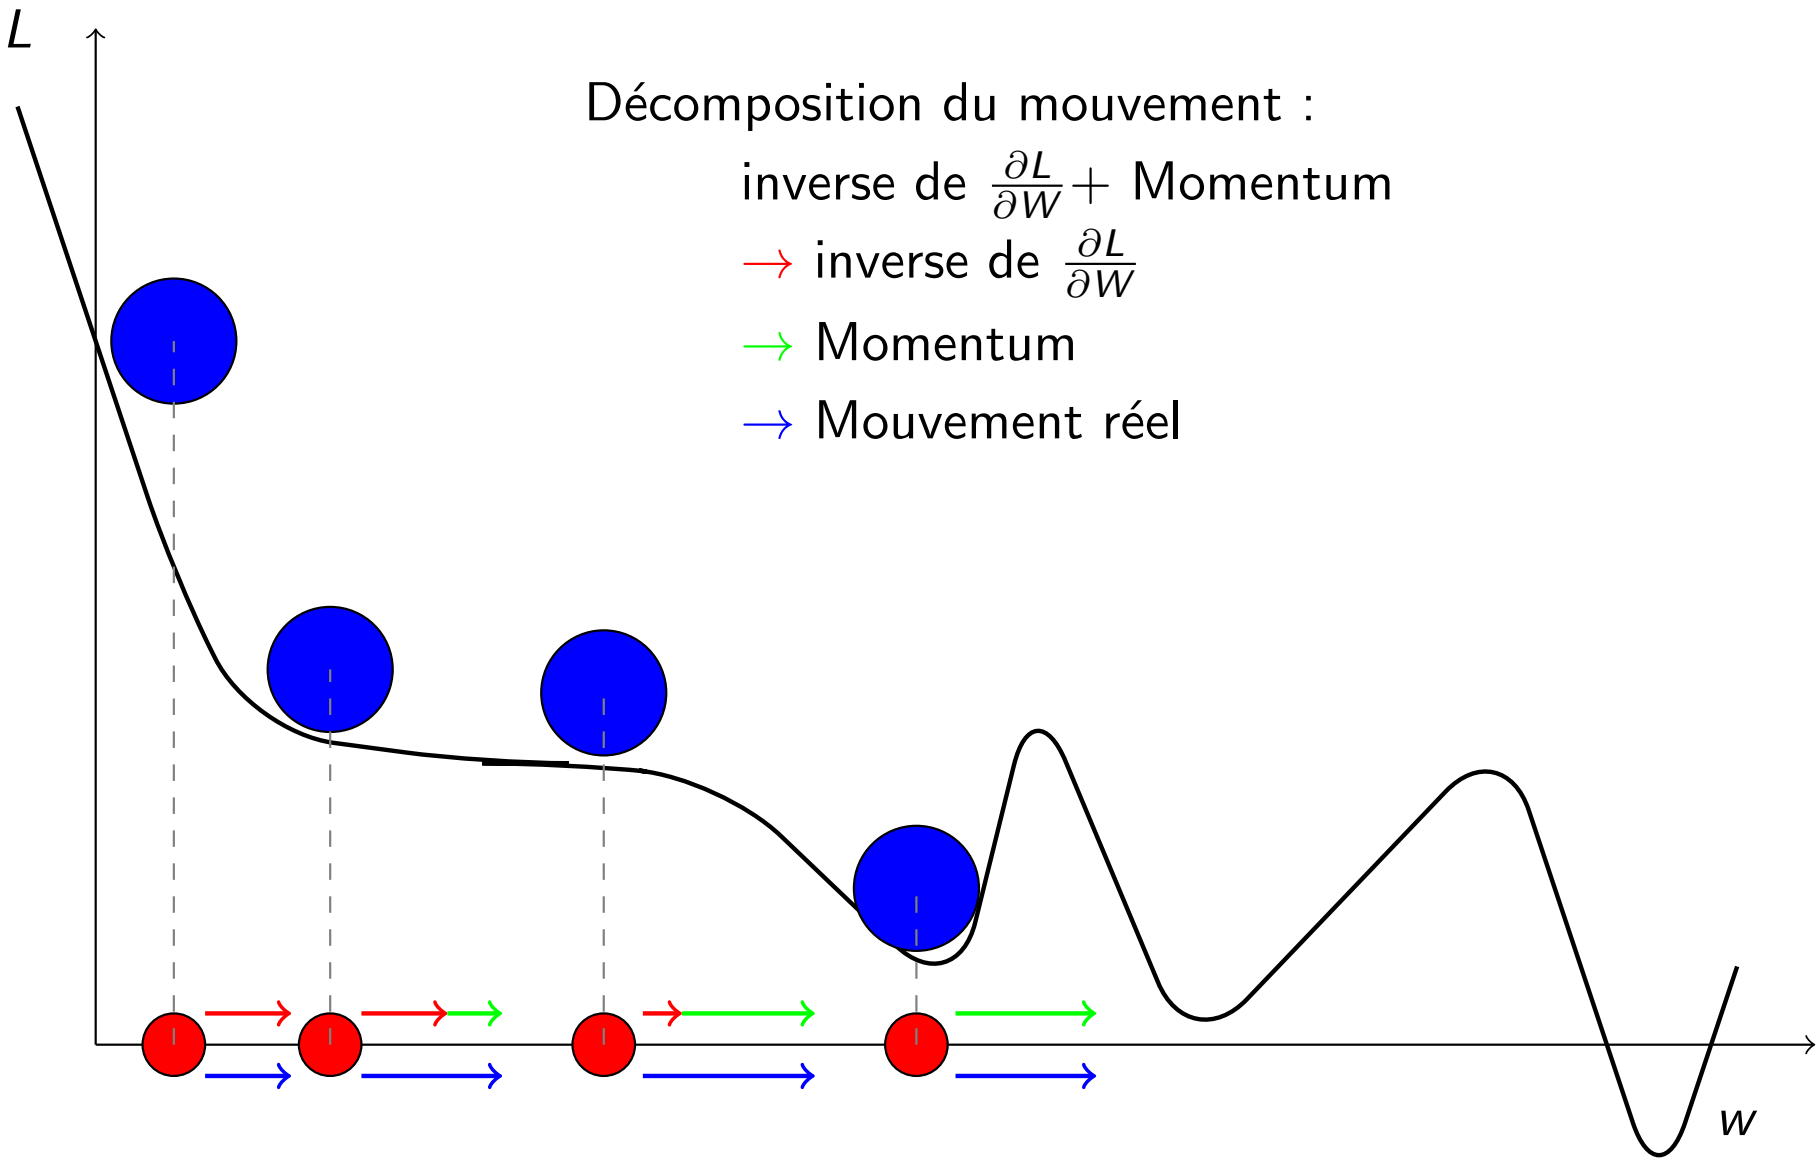

Décomposition du mouvement :

inverse de $\frac{\partial L}{\partial W}$ + Momentum

→ inverse de $\frac{\partial L}{\partial W}$

→ Momentum

→ Mouvement réel

Descente du gradient

Problème : minimum mais local ....

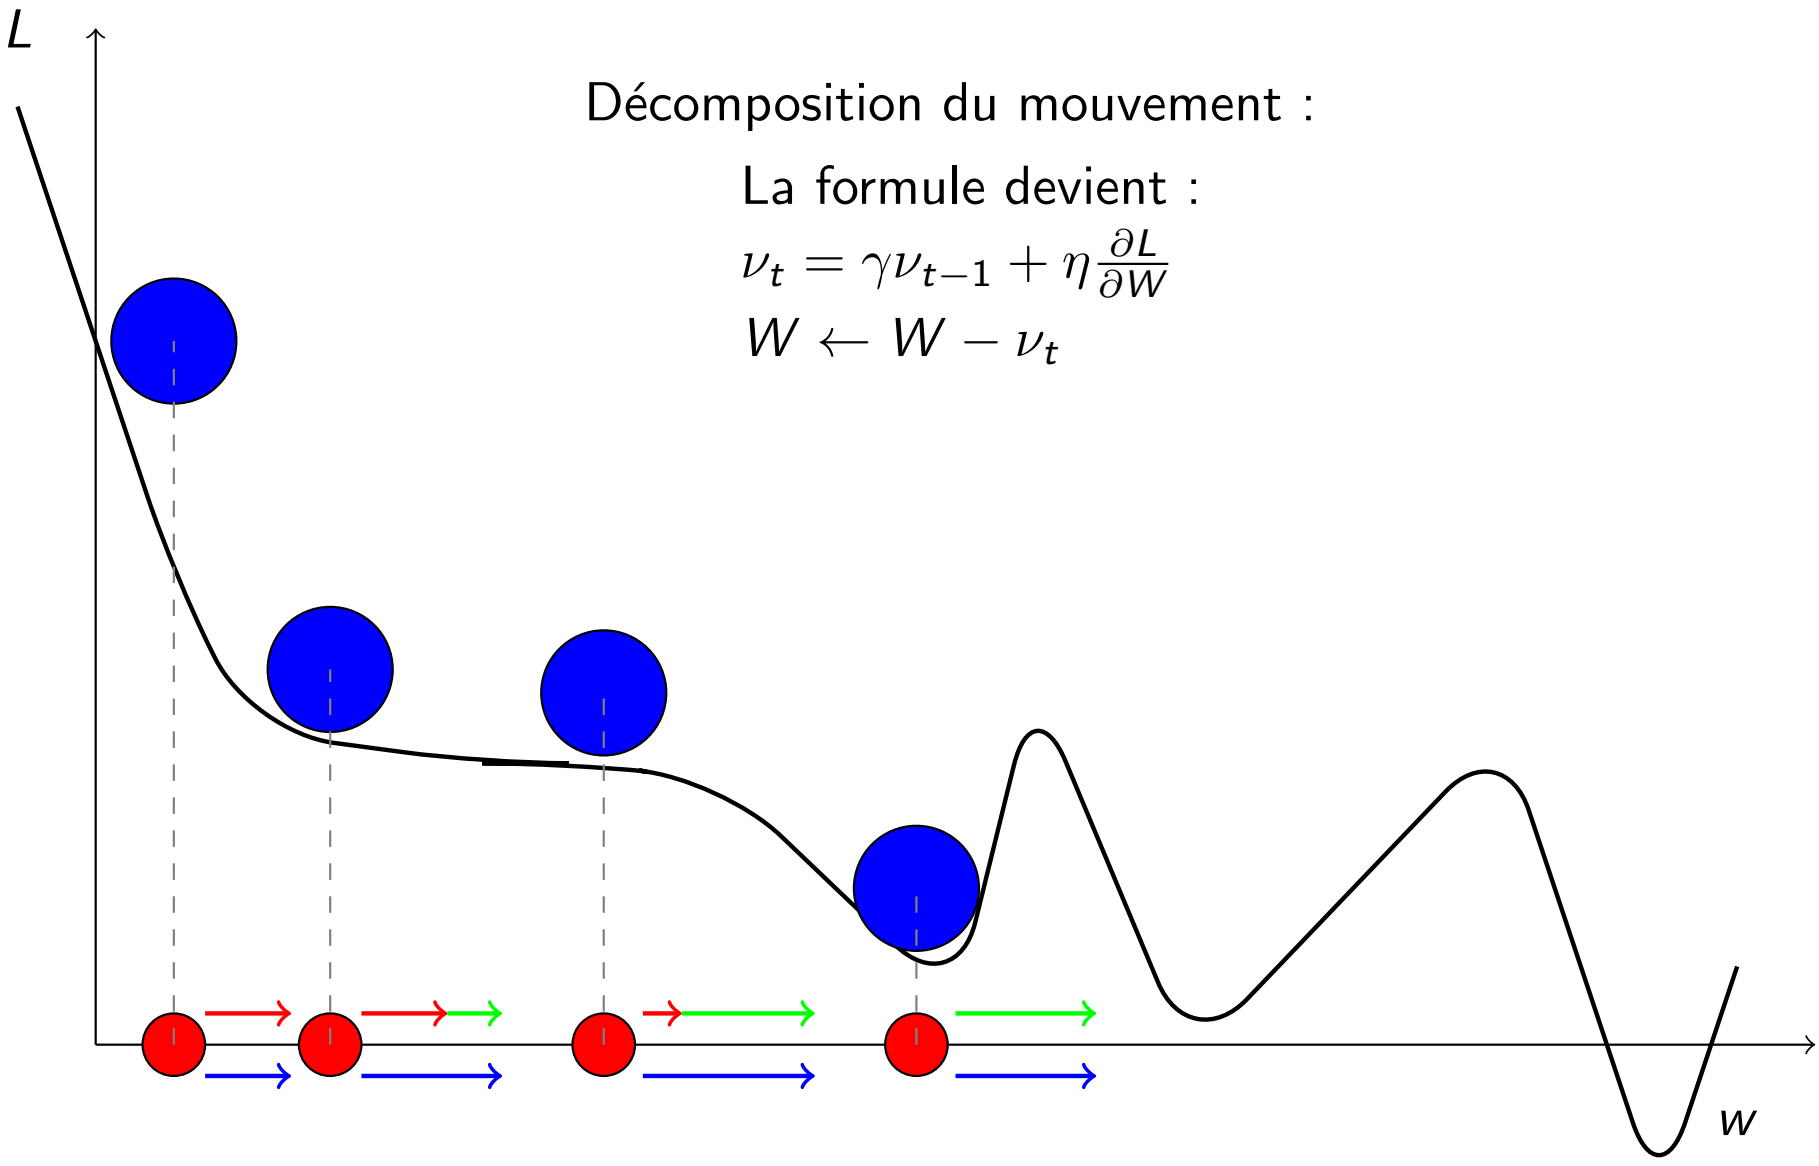

Décomposition du mouvement :

La formule devient :

$$\nu_t = \gamma \nu_{t-1} + \eta \frac{\partial L}{\partial W}$$

$$W \leftarrow W - \nu_t$$

A la recherche de la meilleure fonction

On prend un premier mini-batch :

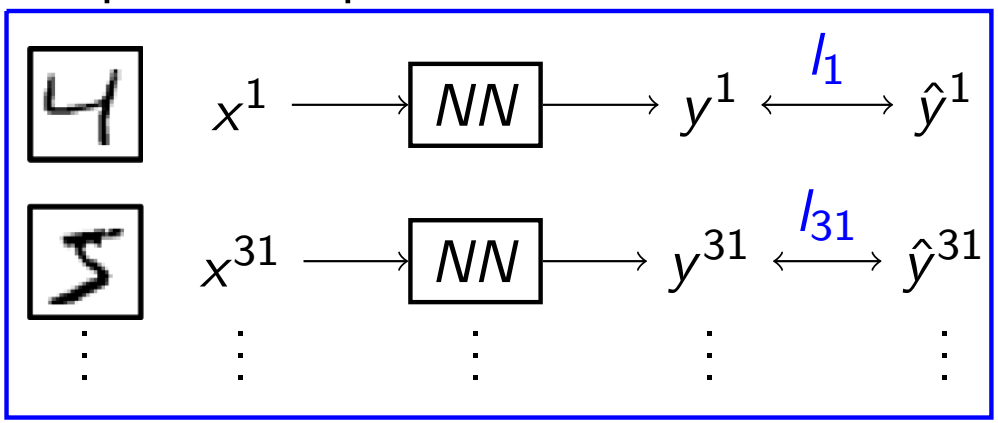

$L' = l^1 + l^{31} + \cdots$

Mettre à jour les paramètres

A la recherche de la meilleure fonction

On prend un premier mini-batch :

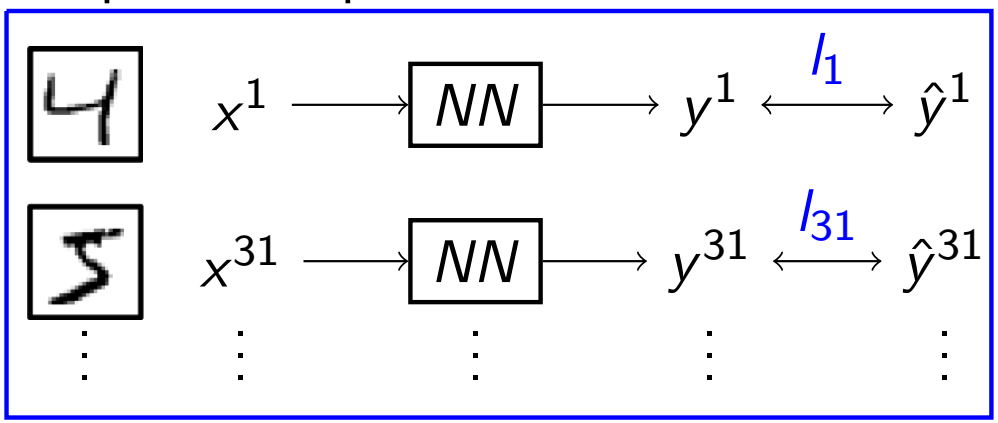

$L' = l^1 + l^{31} + \cdots$

Mettre à jour les paramètres

A la recherche de la meilleure fonction

On prend un premier mini-batch :

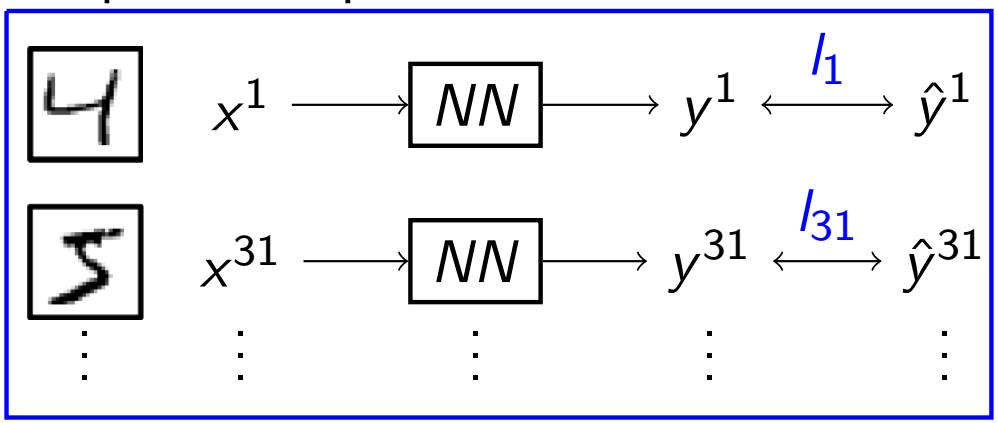

$L' = l^1 + l^{31} + \cdots$

Mettre à jour les paramètres

A la recherche de la meilleure fonction

Puis un deuxième mini-batch :

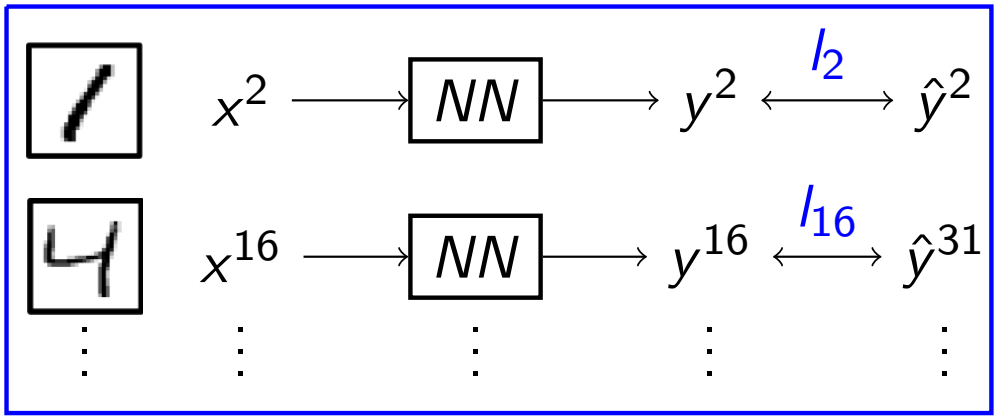

$L'' = l^2 + l^{16} + \cdots$

Mettre à jour les paramètres

Et ainsi de suite

...

Jusqu'à ce que tous les mini-batchs soient lus.

$\Rightarrow$ Cele correspond à un(e) epoch.

Et l'on répète le processus un nombre d'epochs ...

A la recherche de la meilleure fonction

Puis un deuxième mini-batch :

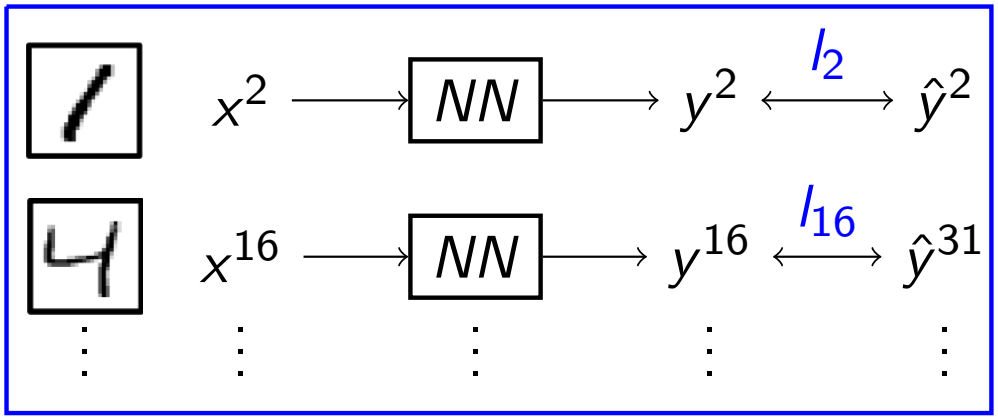

$L'' = l^2 + l^{16} + \cdots$

Mettre à jour les paramètres

Et ainsi de suite

...

Jusqu'à ce que tous les mini-batchs soient lus.

$\Rightarrow$ Cele correspond à un(e) epoch.

Et l'on répète le processus un nombre d'epochs ...

A la recherche de la meilleure fonction

Puis un deuxième mini-batch :

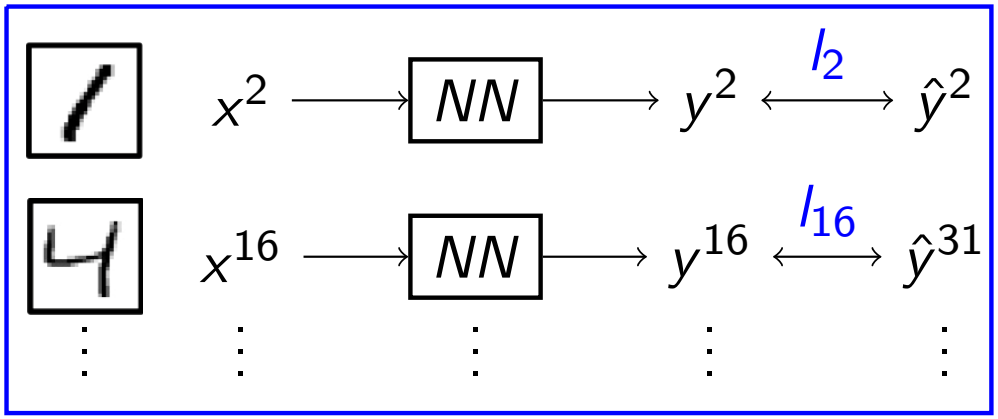

$L'' = l^2 + l^{16} + \dots$

Mettre à jour les paramètres

Et ainsi de suite

...

Jusqu'à ce que tous les mini-batchs soient lus.

$\Rightarrow$ Cele correspond à un(e) epoch.

Et l'on répète le processus un nombre d'epochs ...

A la recherche de la meilleure fonction

Puis un deuxième mini-batch :

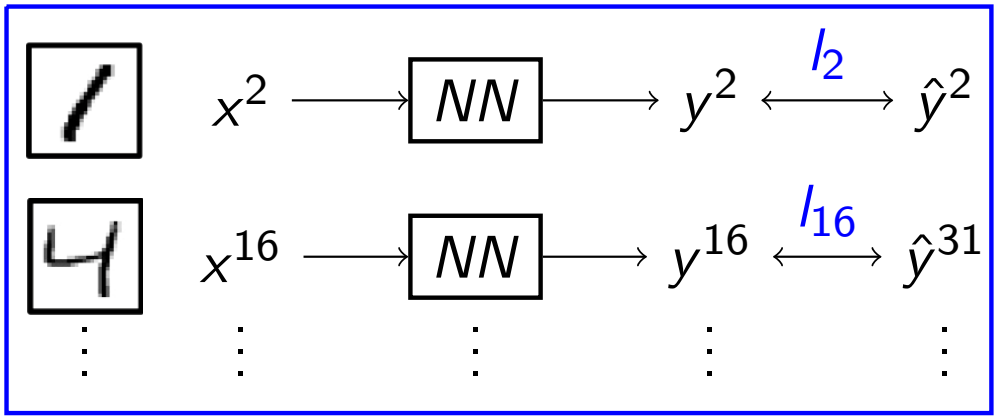

$L'' = l^2 + l^{16} + \dots$

Mettre à jour les paramètres

Et ainsi de suite

$\dots$

Jusqu'à ce que tous les mini-batchs soient lus.

$\Rightarrow$ Cele correspond à un(e) epoch.

Et l'on répète le processus un nombre d'epochs ...

A la recherche de la meilleure fonction

Puis un deuxième mini-batch :

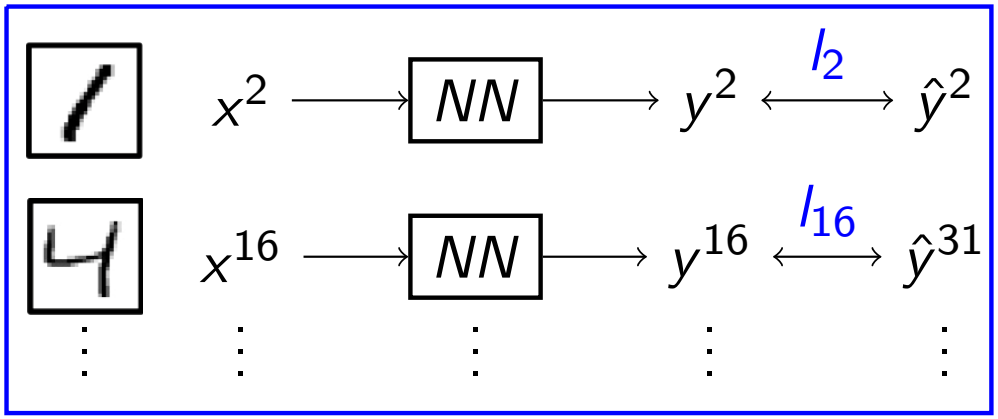

$L'' = l^2 + l^{16} + \dots$

Mettre à jour les paramètres

Et ainsi de suite

$\dots$

Jusqu'à ce que tous les mini-batchs soient lus.

$\Rightarrow$ Cele correspond à un(e) epoch.

Et l'on répète le processus un nombre d'epochs ...

A la recherche de la meilleure fonction

Puis un deuxième mini-batch :

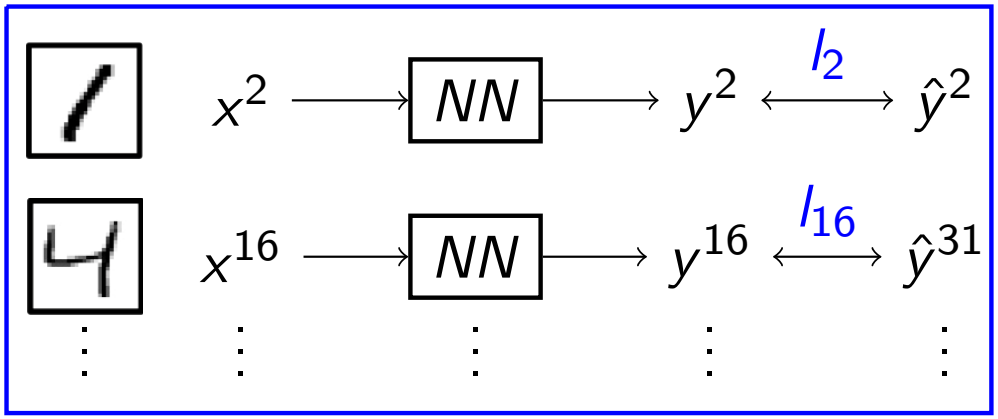

$L'' = l^2 + l^{16} + \dots$

Mettre à jour les paramètres

Et ainsi de suite

$\dots$

Jusqu'à ce que tous les mini-batchs soient lus.

$\Rightarrow$ Cele correspond à un(e) epoch.

Et l'on répète le processus un nombre d'epochs ...

A la recherche de la meilleure fonction

Dans la majorité des outils de deep learning, ces deux paramètres sont à indiquer :

- batch_size correspond au nombre d'exemples utilisé pour estimer le gradient de la fonction de coût.
- epochs est le nombre d'époques (i.e. passages sur l'ensemble des exemples de la base d?apprentissage) lors de la descente de gradient.

Problème de la disparition du gradient

Intuition :
La mise à jour des paramètres se fait si la dérivée n'est pas nulle.
Problème : avec la sigmoid (et d'autres fonctions) comme fonction d'activation, au bout d'un certain nombre d'itérations, $\frac{\partial L}{\partial W}$ devient nulle ...
Solution :
Utiliser, comme fonction d'activation, la fonction ReLU (Rectified Linear Unit) :