

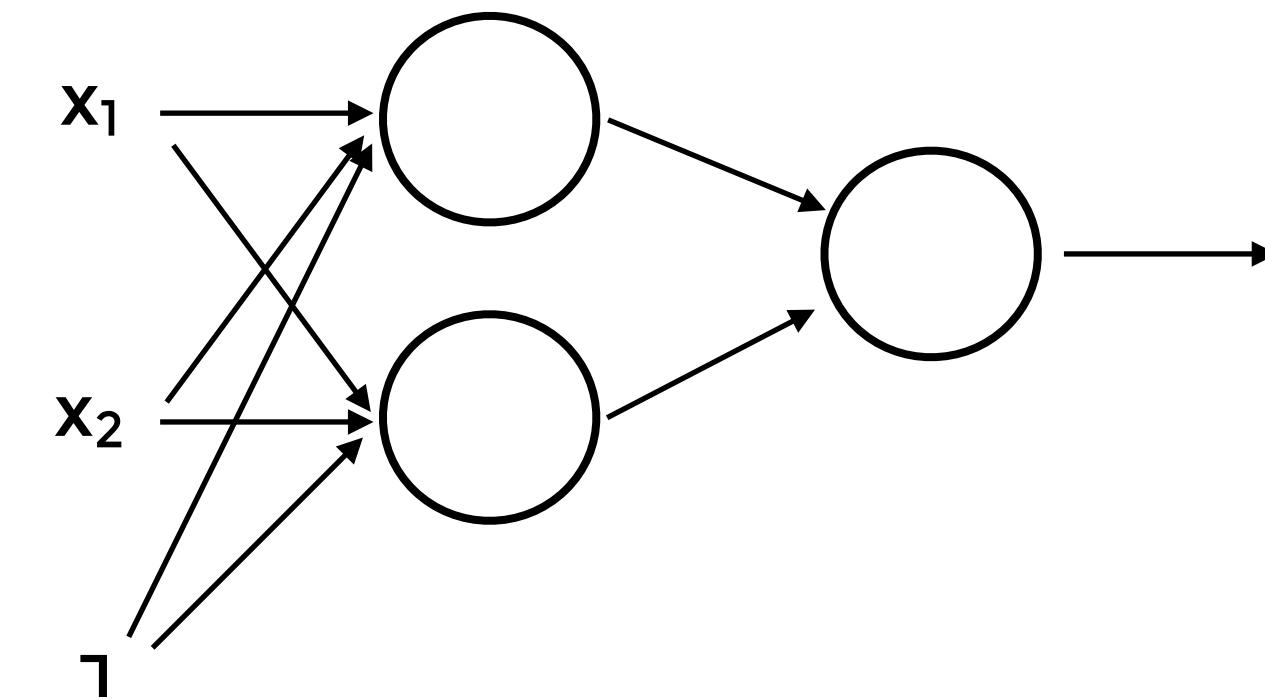
# **Apprentissage Automatique I**

## **60629**

**Sommaire**  
**CNNs et RNNs**  
– Semaine #6

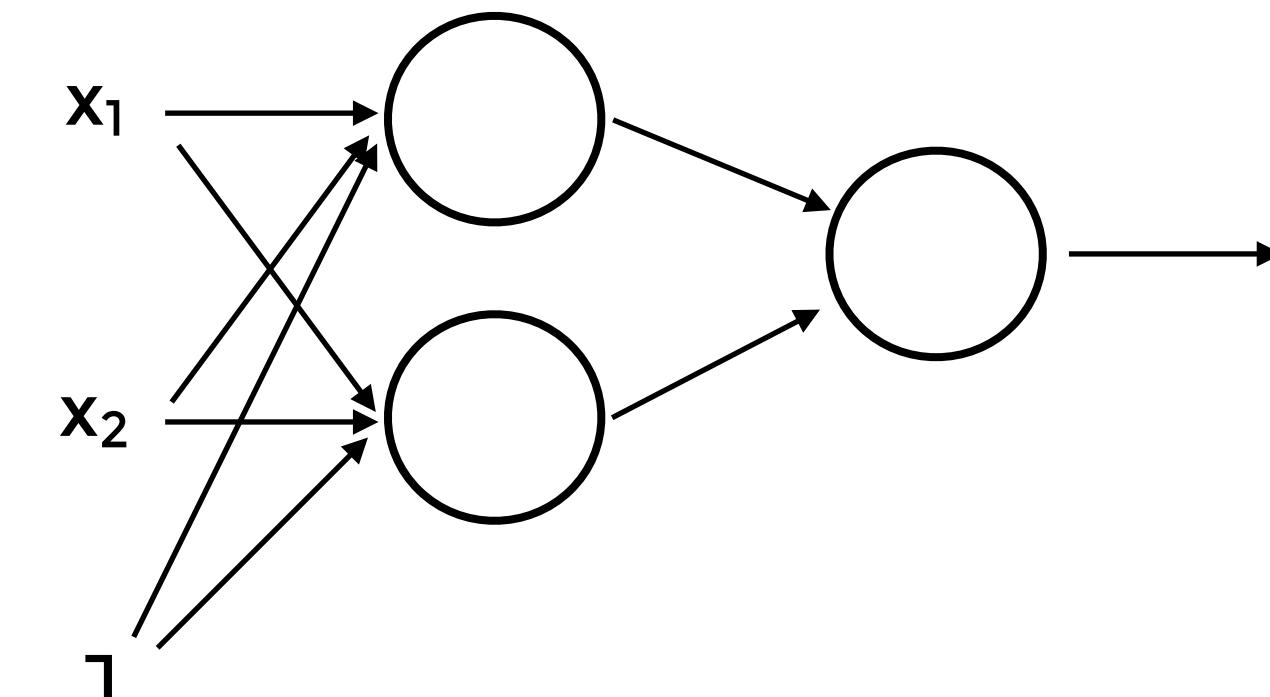
# Modèles de réseaux de neurones

- Les réseaux *feed-forward* sont standards
  - Entrées & Sorties: taille fixe
  - Les données sont traitées en par.



# Modèles de réseaux de neurones

- Les réseaux ***feed-forward*** sont standards
  - Entrées & Sorties: taille fixe
  - Les données sont traitées en par.
- On peut aussi développer des réseaux spécialisés pour certains types de données
- Des données avec différents caractéristiques



# Classification à partir de données textuelles

```
From: bcash@crchh410.NoSubdomain.NoDomain (Brian Cash)
Subject: Re: free moral agency
Nntp-Posting-Host: crchh410
Organization: BNR, Inc.
Lines: 17

In article <735295730.25282@minster.york.ac.uk>, cjhs@minster.york.ac.uk writes:
|> : Are you saying that their was a physical Adam and Eve, and that all
|> : humans are direct decendents of only these two human beings.? Then who
|> : were Cain and Able's wives? Couldn't be their sisters, because A&E
|> : didn't have daughters. Were they non-humans?
|>
|> Genesis 5:4
|>
|> and the days of Adam after he begat Seth were eight hundred years, and
|> he begat sons and daughters:
|>
|> Felicitations -- Chris Ho-Stuart

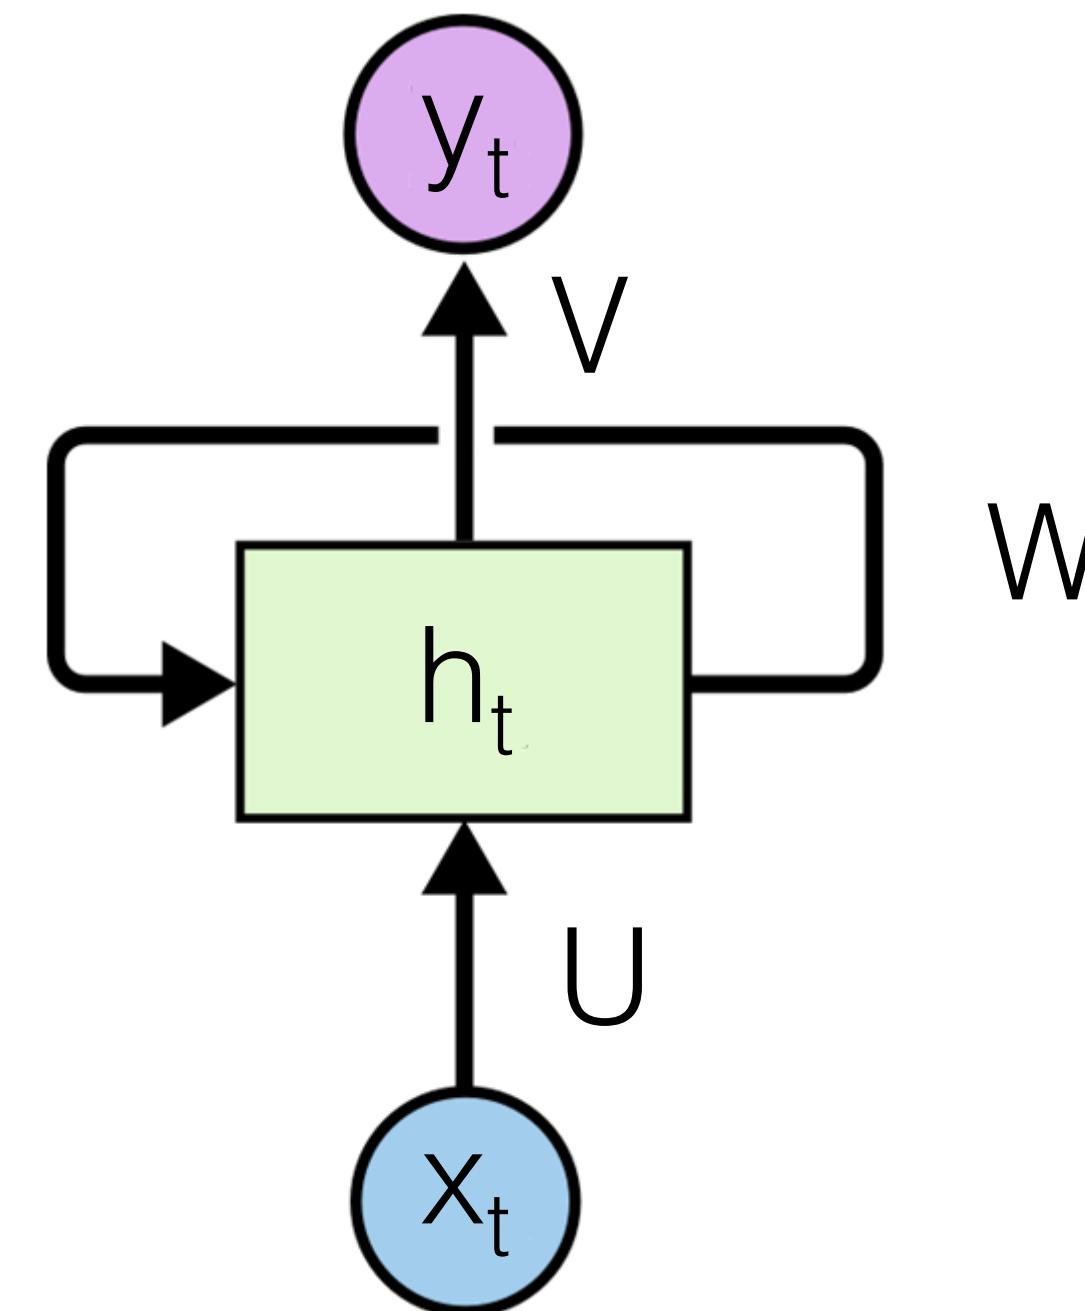
Yeah, but these were not the wives. The wives came from Nod, apparently
a land being developed by another set of gods.

Brian /-|-\  
→ Pourriel / Pas pourriel
```

# Idée de base (avec les paramètres)

**Processus à travers le temps (t)**  
•  $U, V, W$ : paramètres

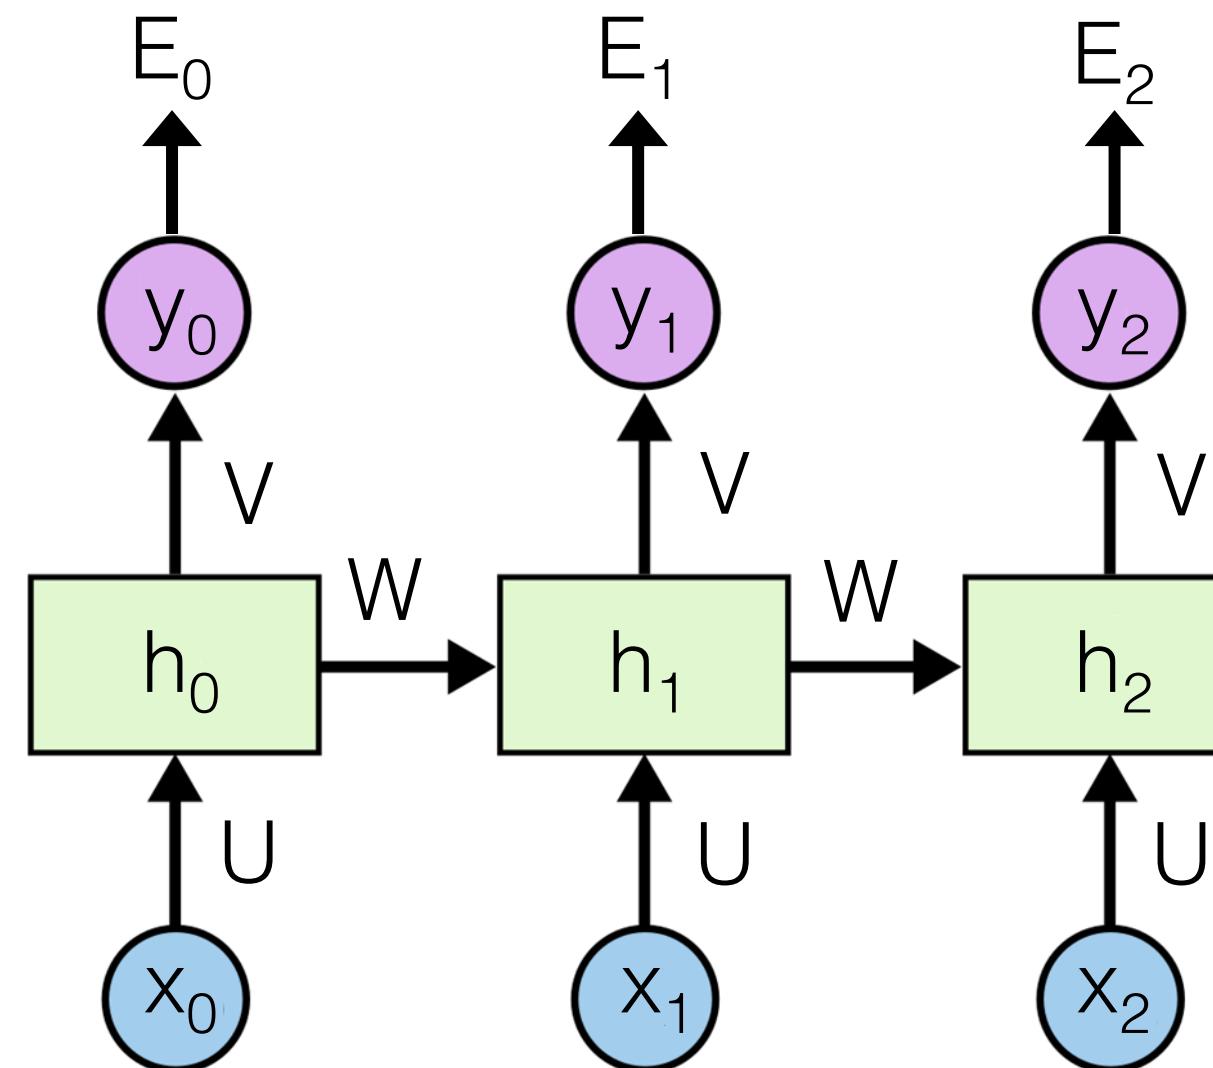
- Partagés à travers le temps
- Paramétrisation la plus simple



$$\begin{aligned} h_t &= \tanh(Ux_t + Wh_{t-1}) \\ y_t &= f(Vh_t) \end{aligned}$$

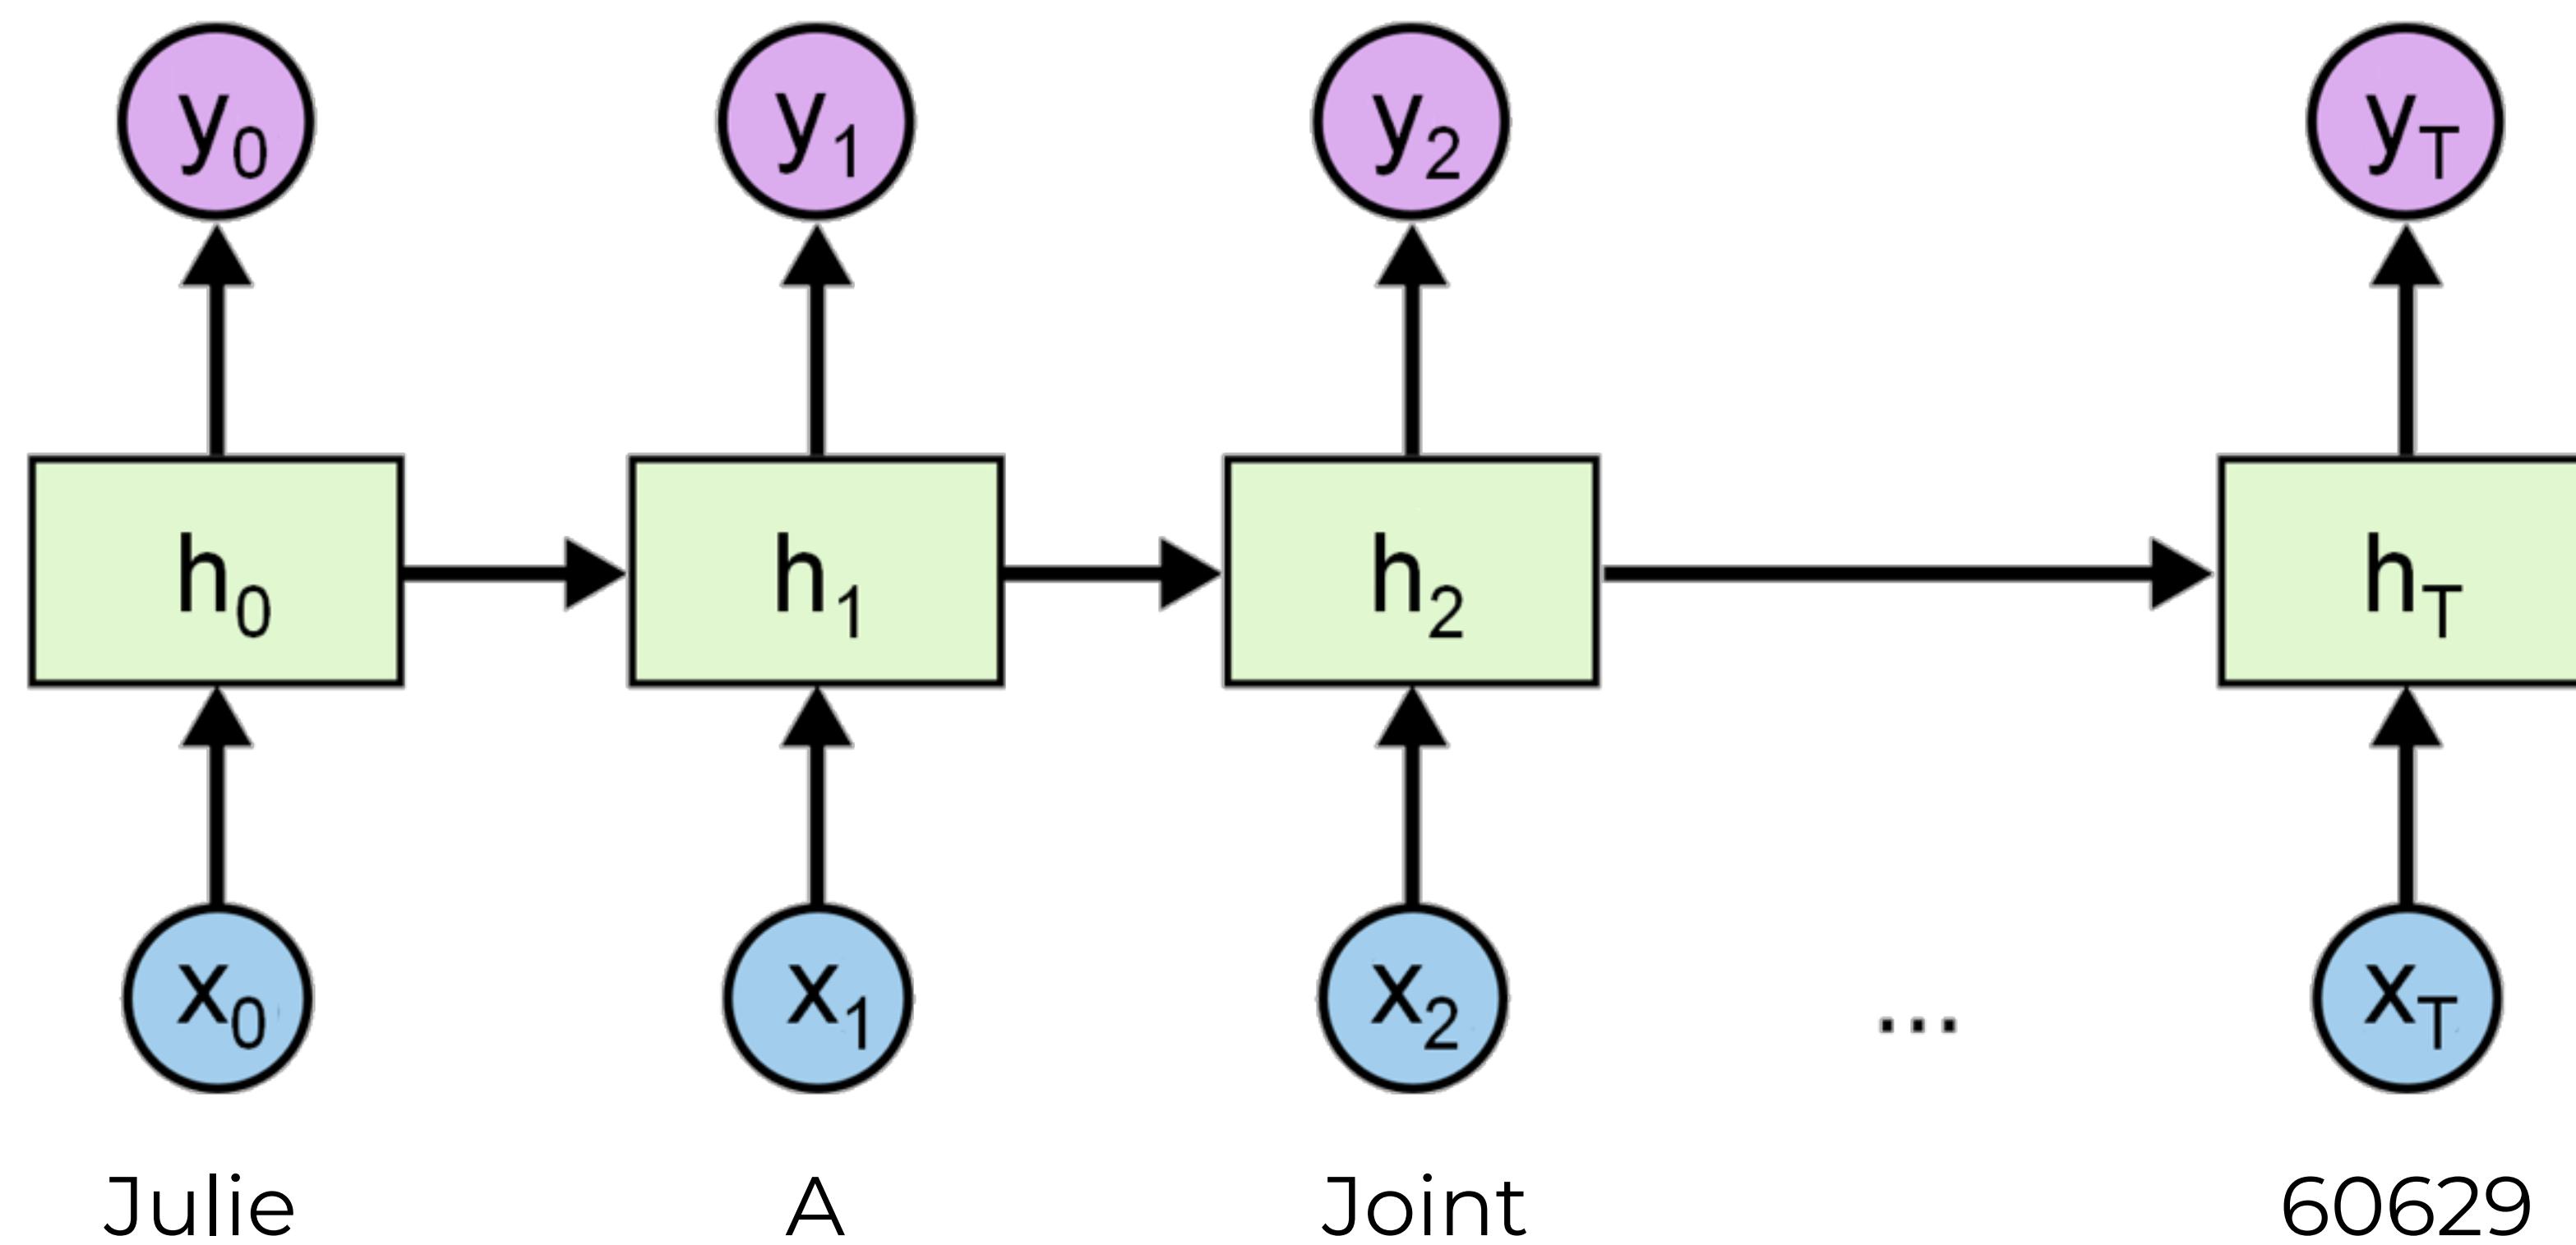
# Entraînement des RNNs

- **Descente de gradient à partir de la perte**  $E = \sum_t (y_t - \hat{y}_t)^2$
- **En suivant la structure du modèle (ses connections), le gradient est rétro-propagé dans « le temps »**



# Limites

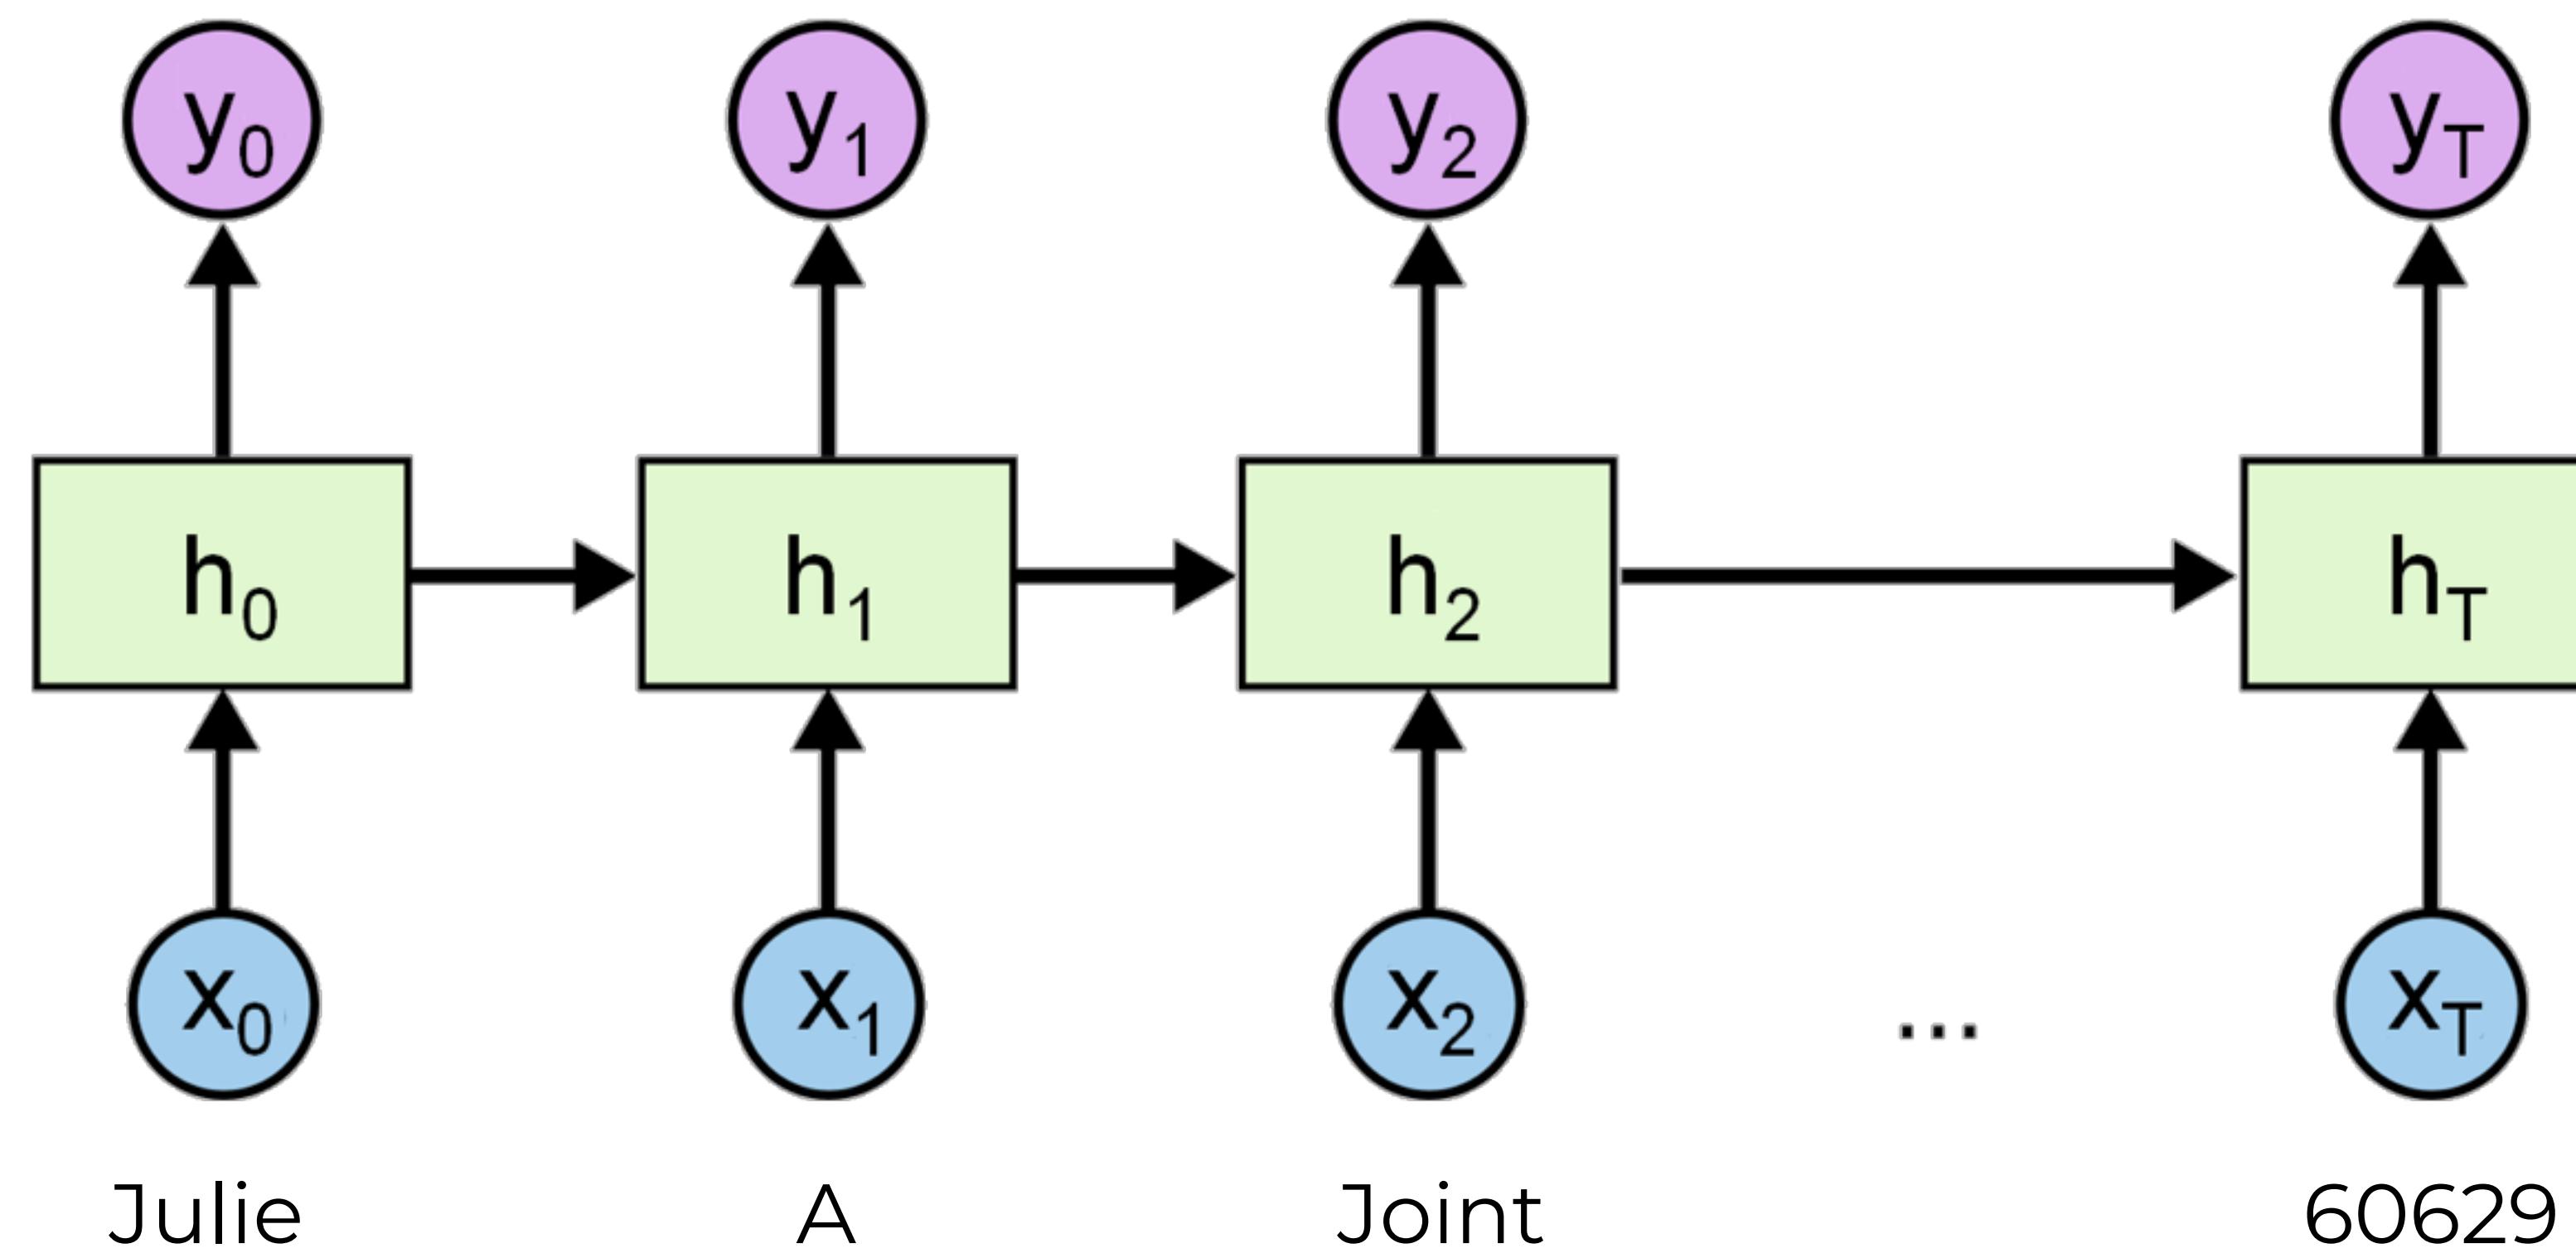
- Les dépendances lointaines sont difficiles à apprendre



# Limites

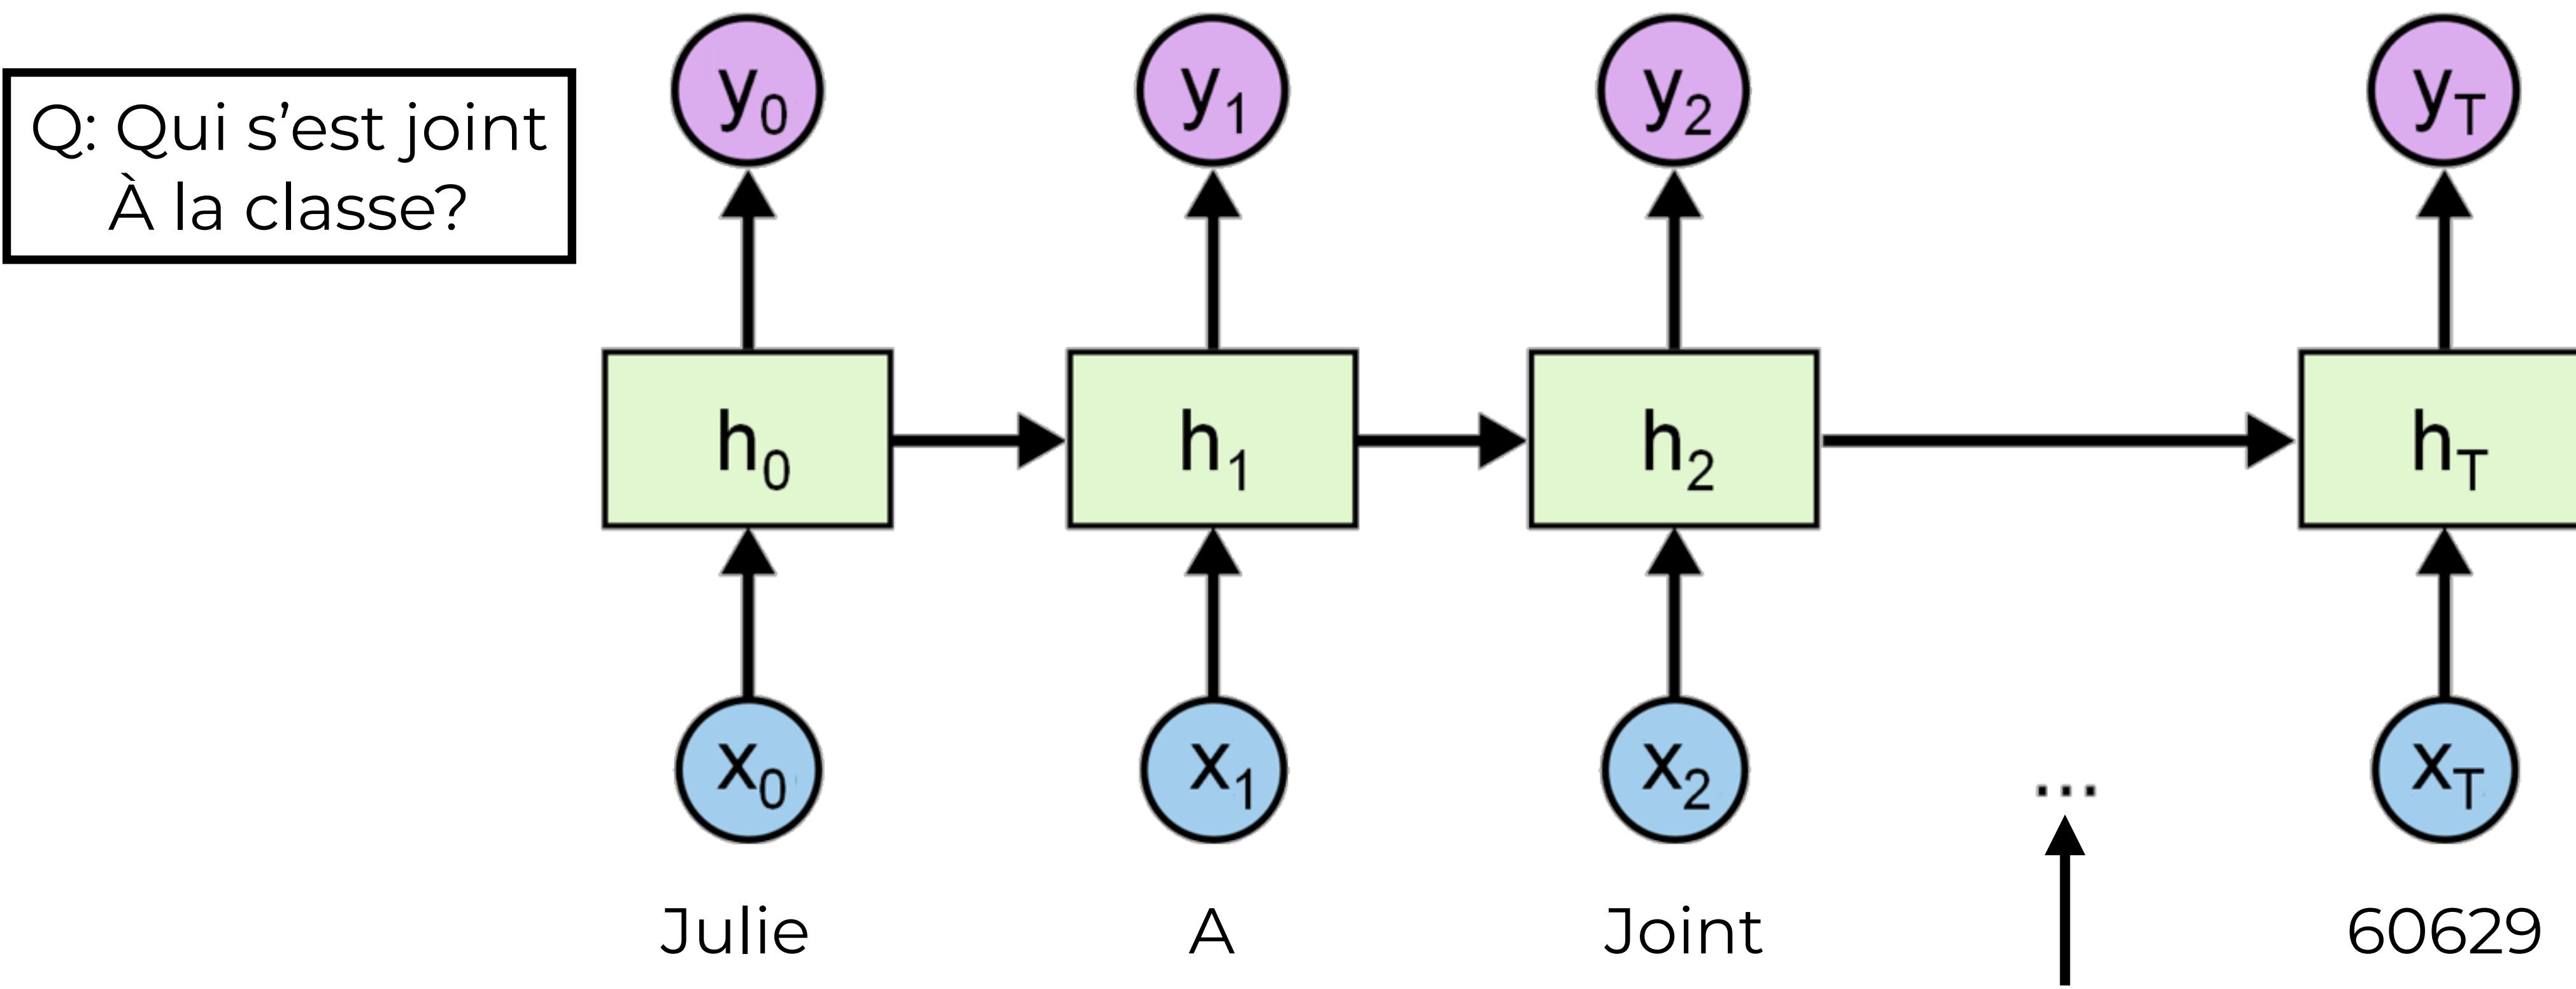
- **Les dépendances lointaines sont difficiles à apprendre**

Q: Qui s'est joint  
À la classe?

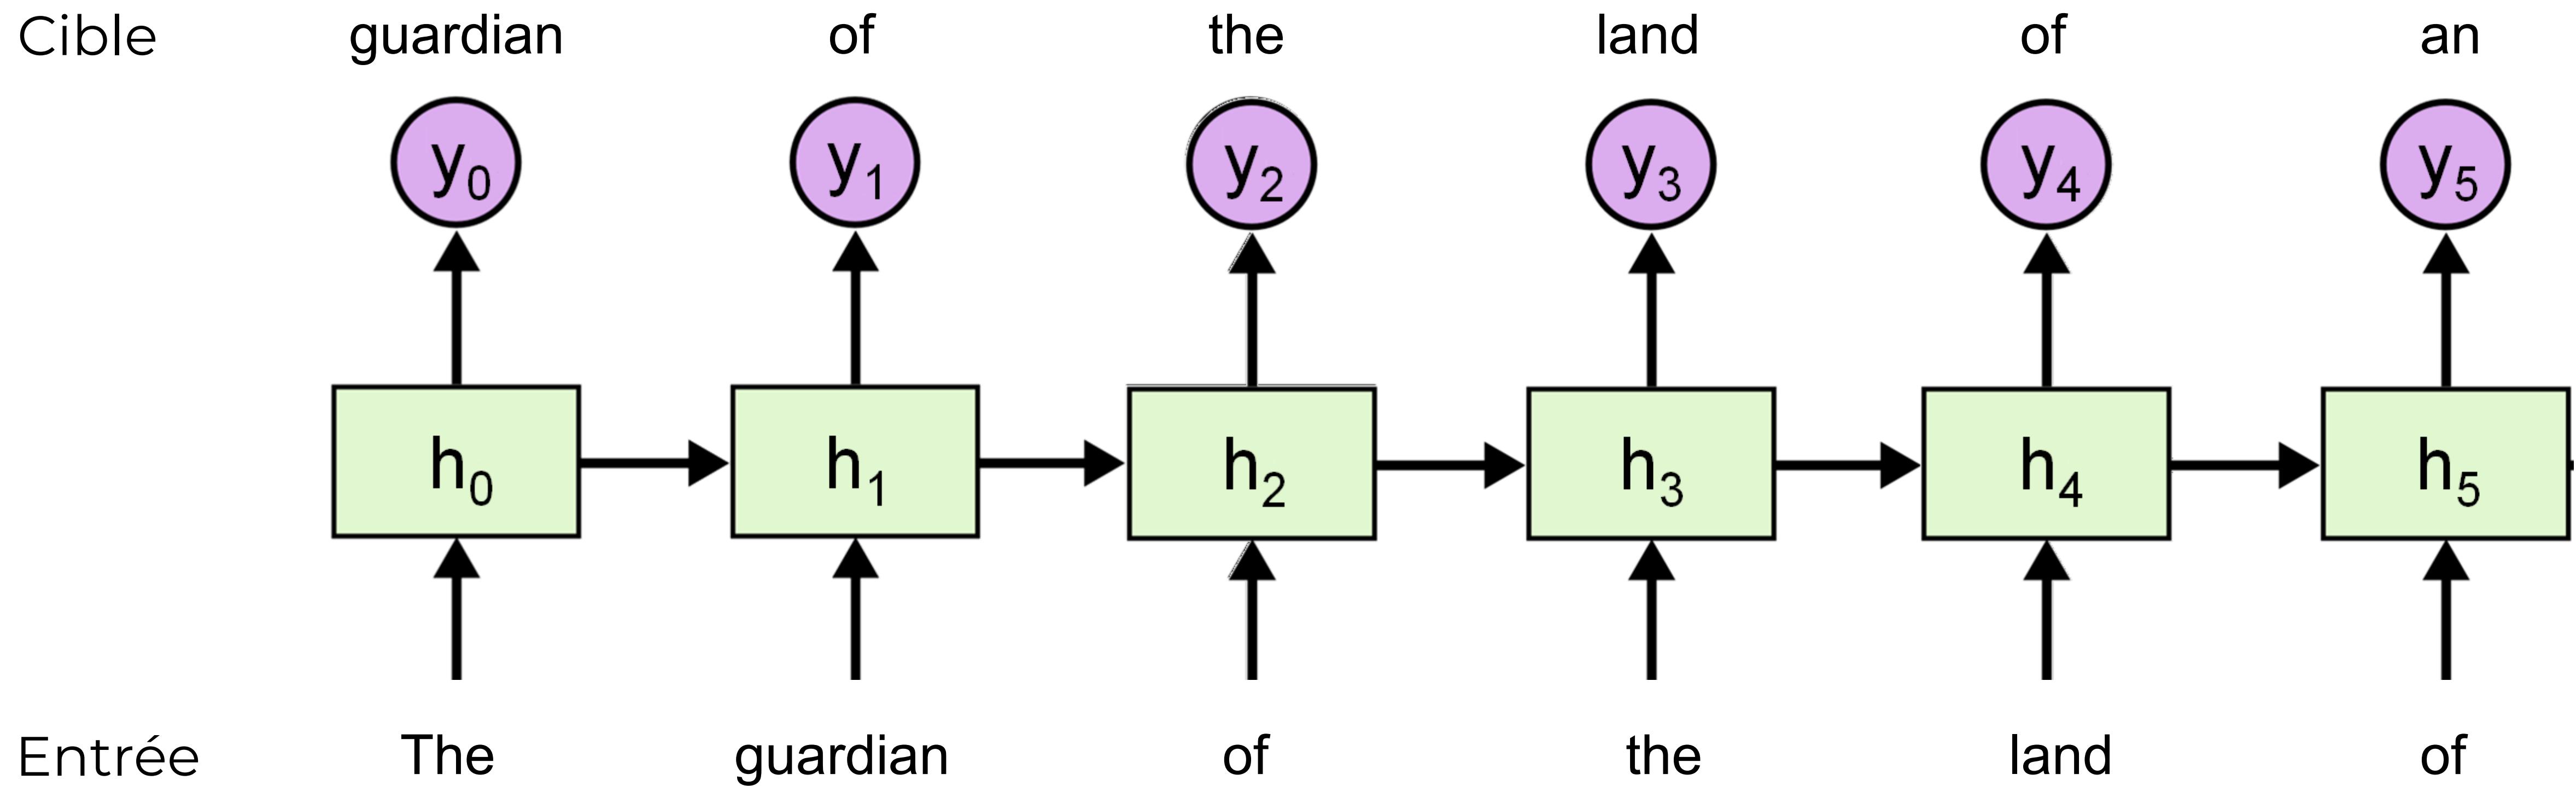


# Limites

- **Les dépendances lointaines sont difficiles à apprendre**



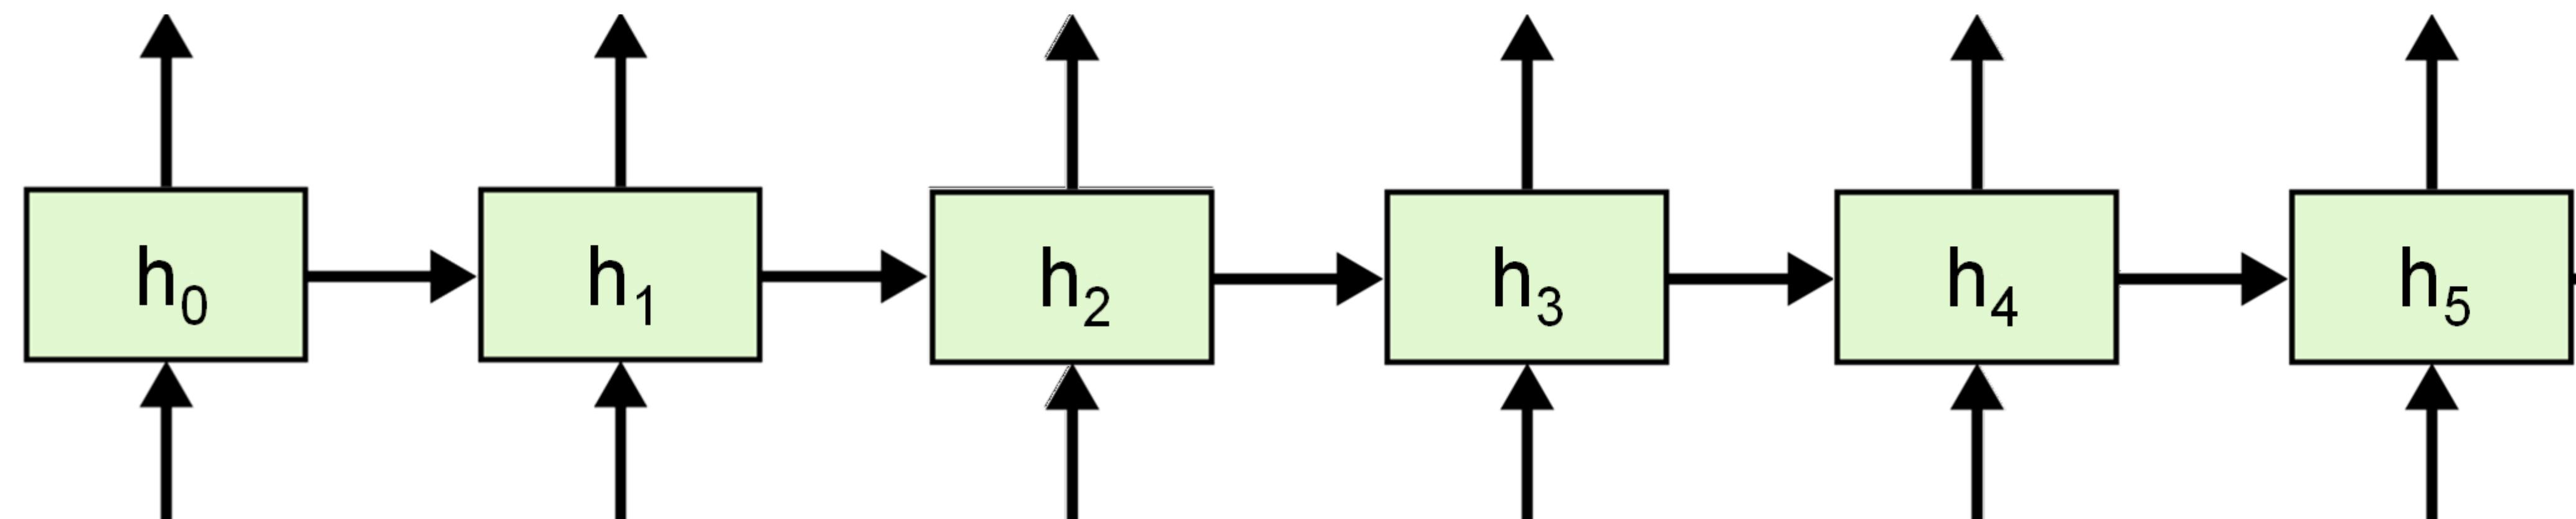
Entrainement.  
Étant donné le mot précédent, prédire le mot suivant



Test.

1. Prédire un mot à la fois
2. On donne la prédiction en entrée au prochain pas de temps

Prédiction

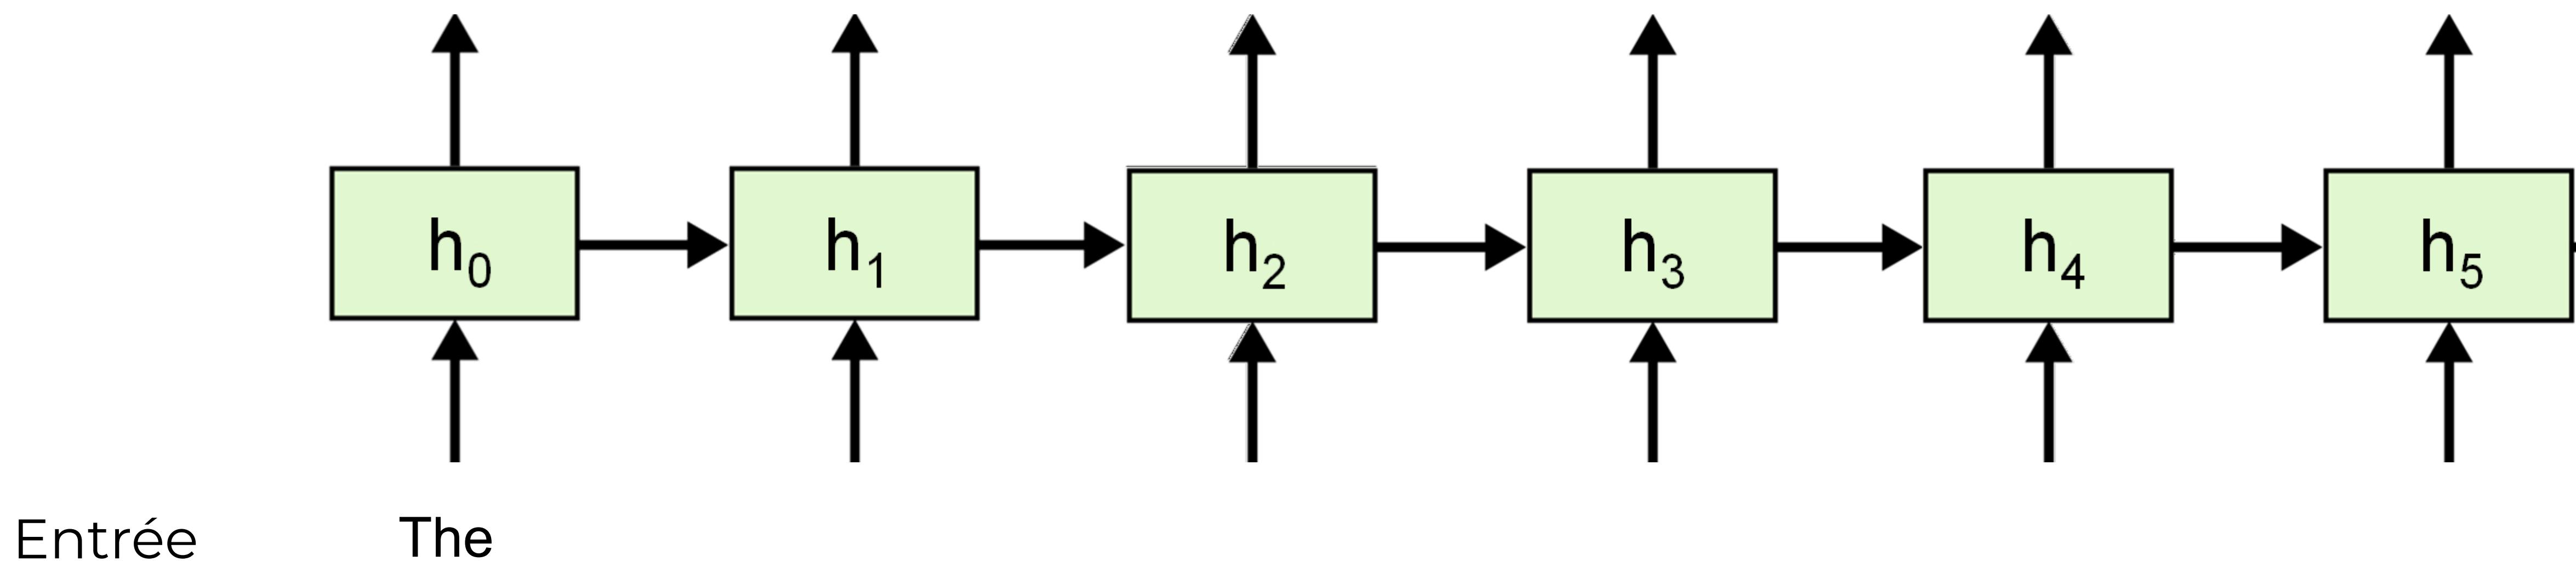


Entrée

Test.

1. Prédire un mot à la fois
2. On donne la prédiction en entrée au prochain pas de temps

Prédiction

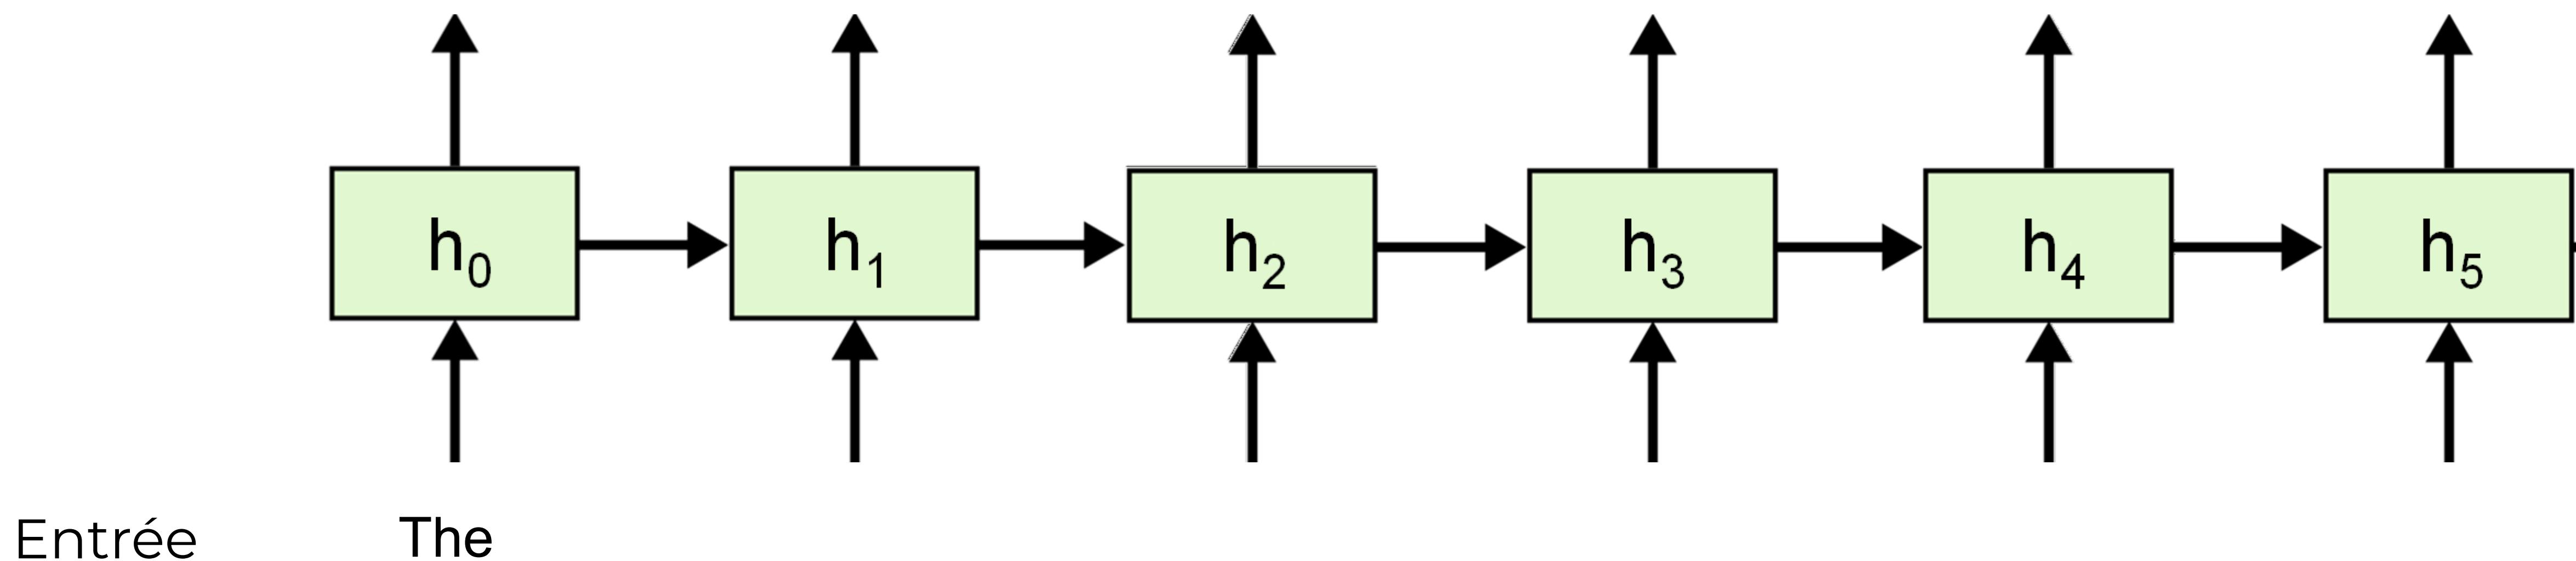


Test.

1. Prédire un mot à la fois
2. On donne la prédiction en entrée au prochain pas de temps

Prédiction

woman

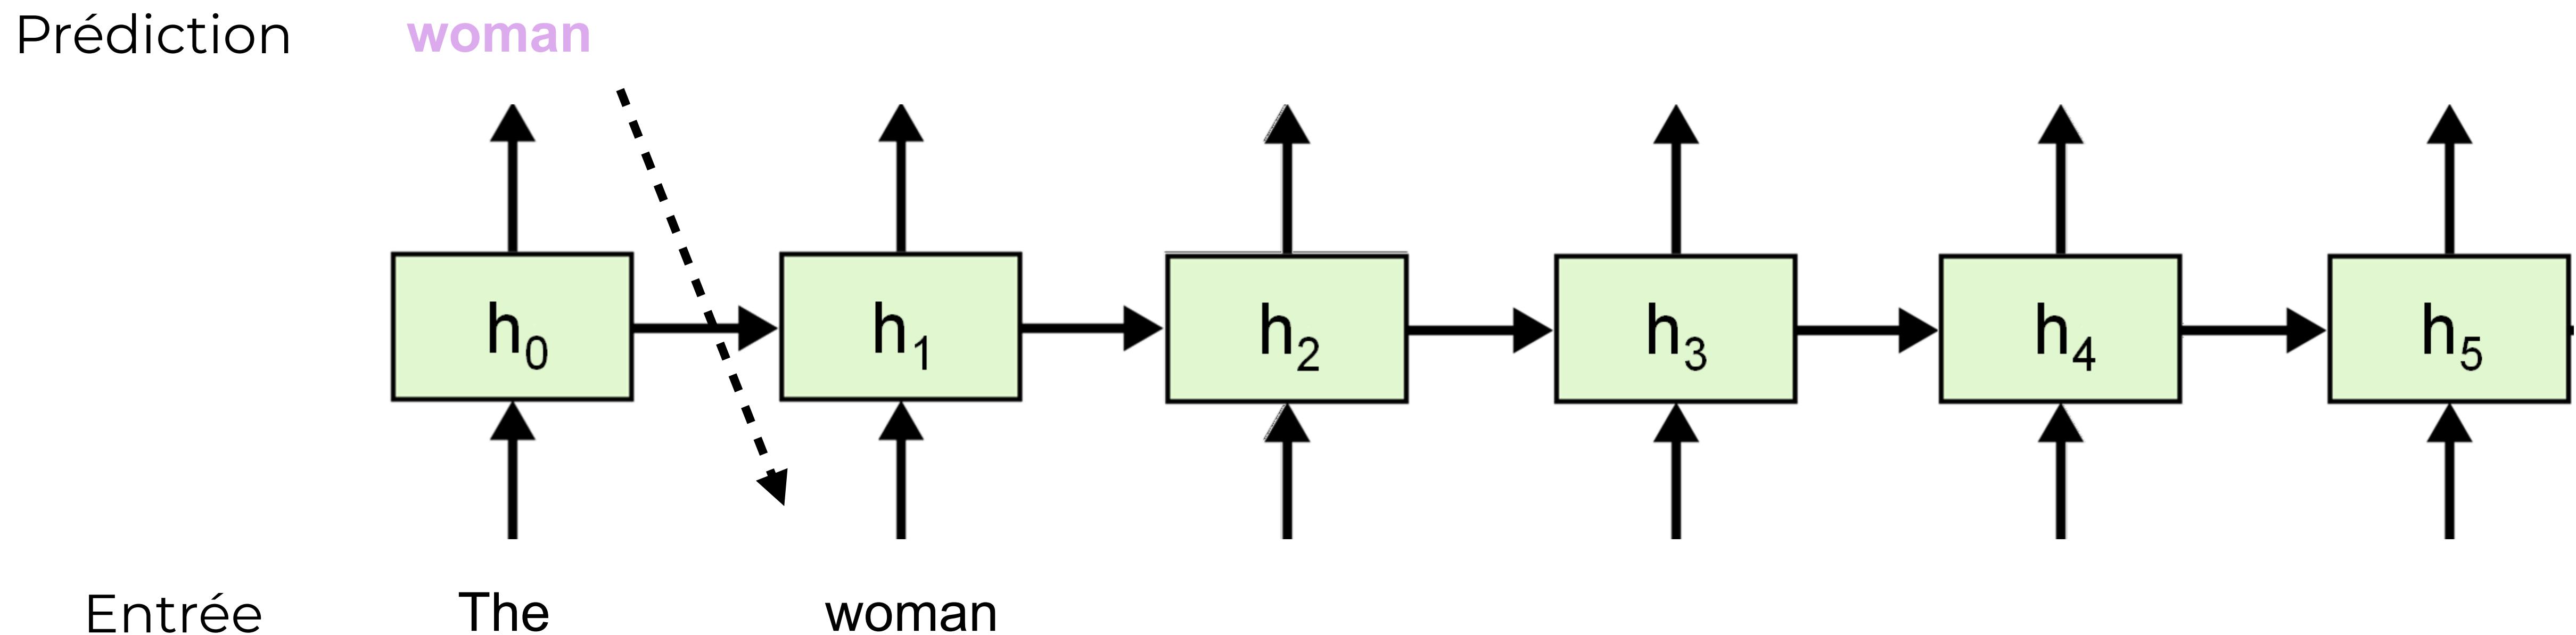


Entrée

The

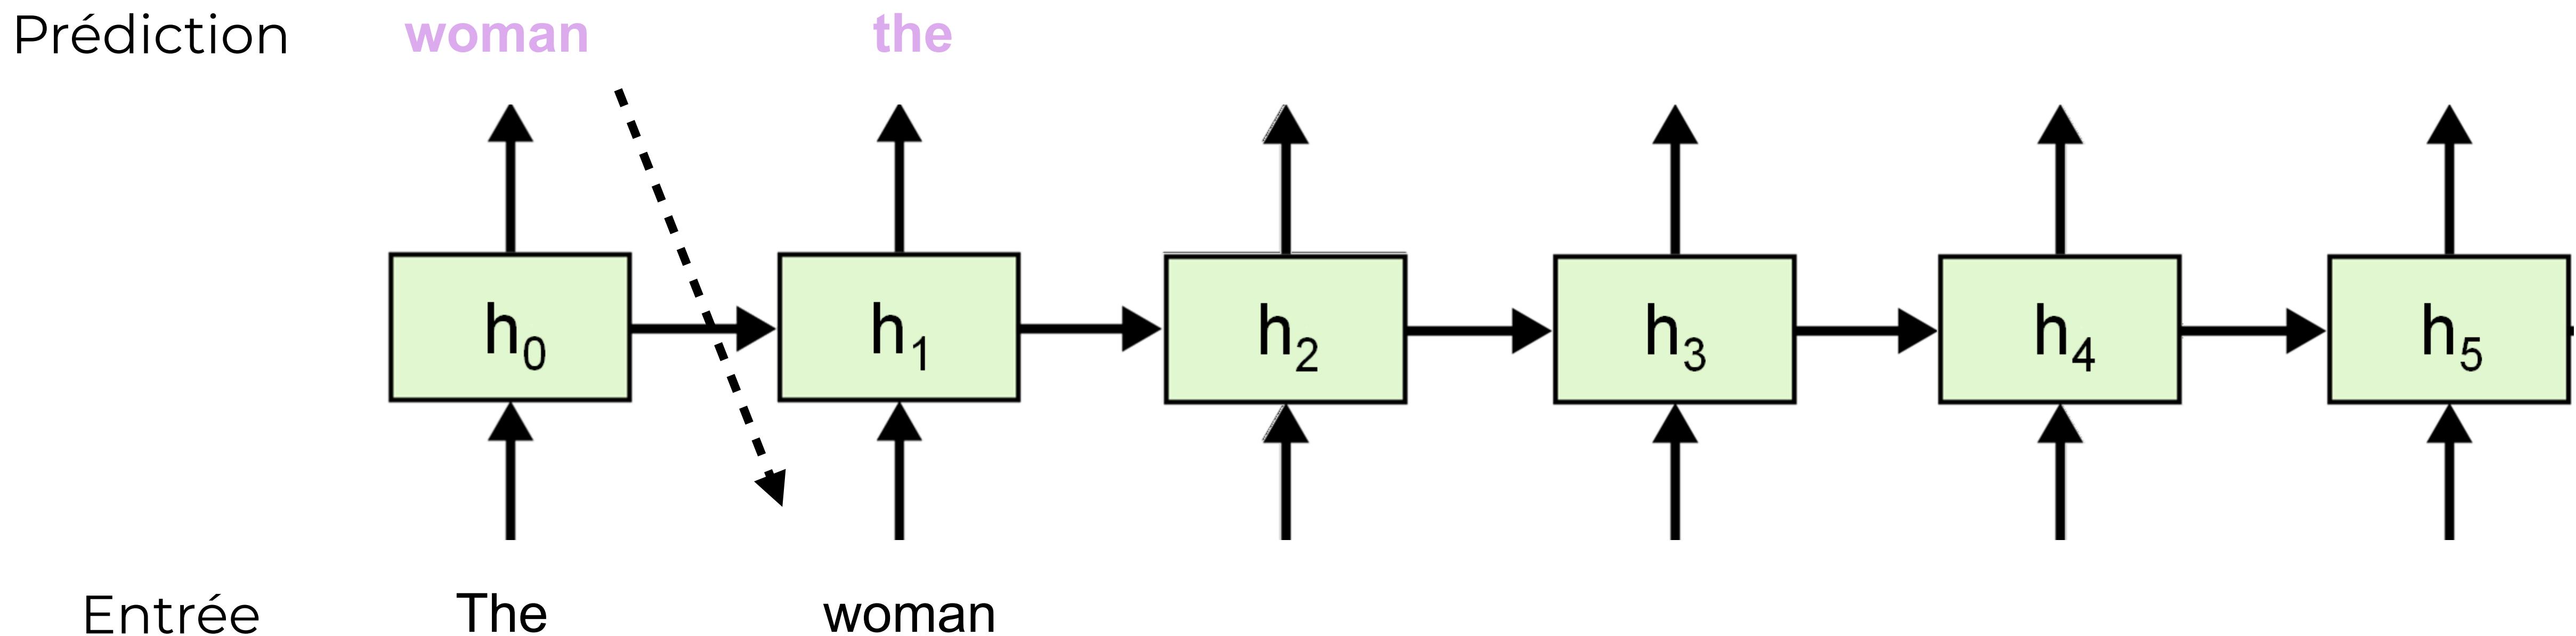
## Test.

1. Prédire un mot à la fois
2. On donne la prédiction en entrée au prochain pas de temps



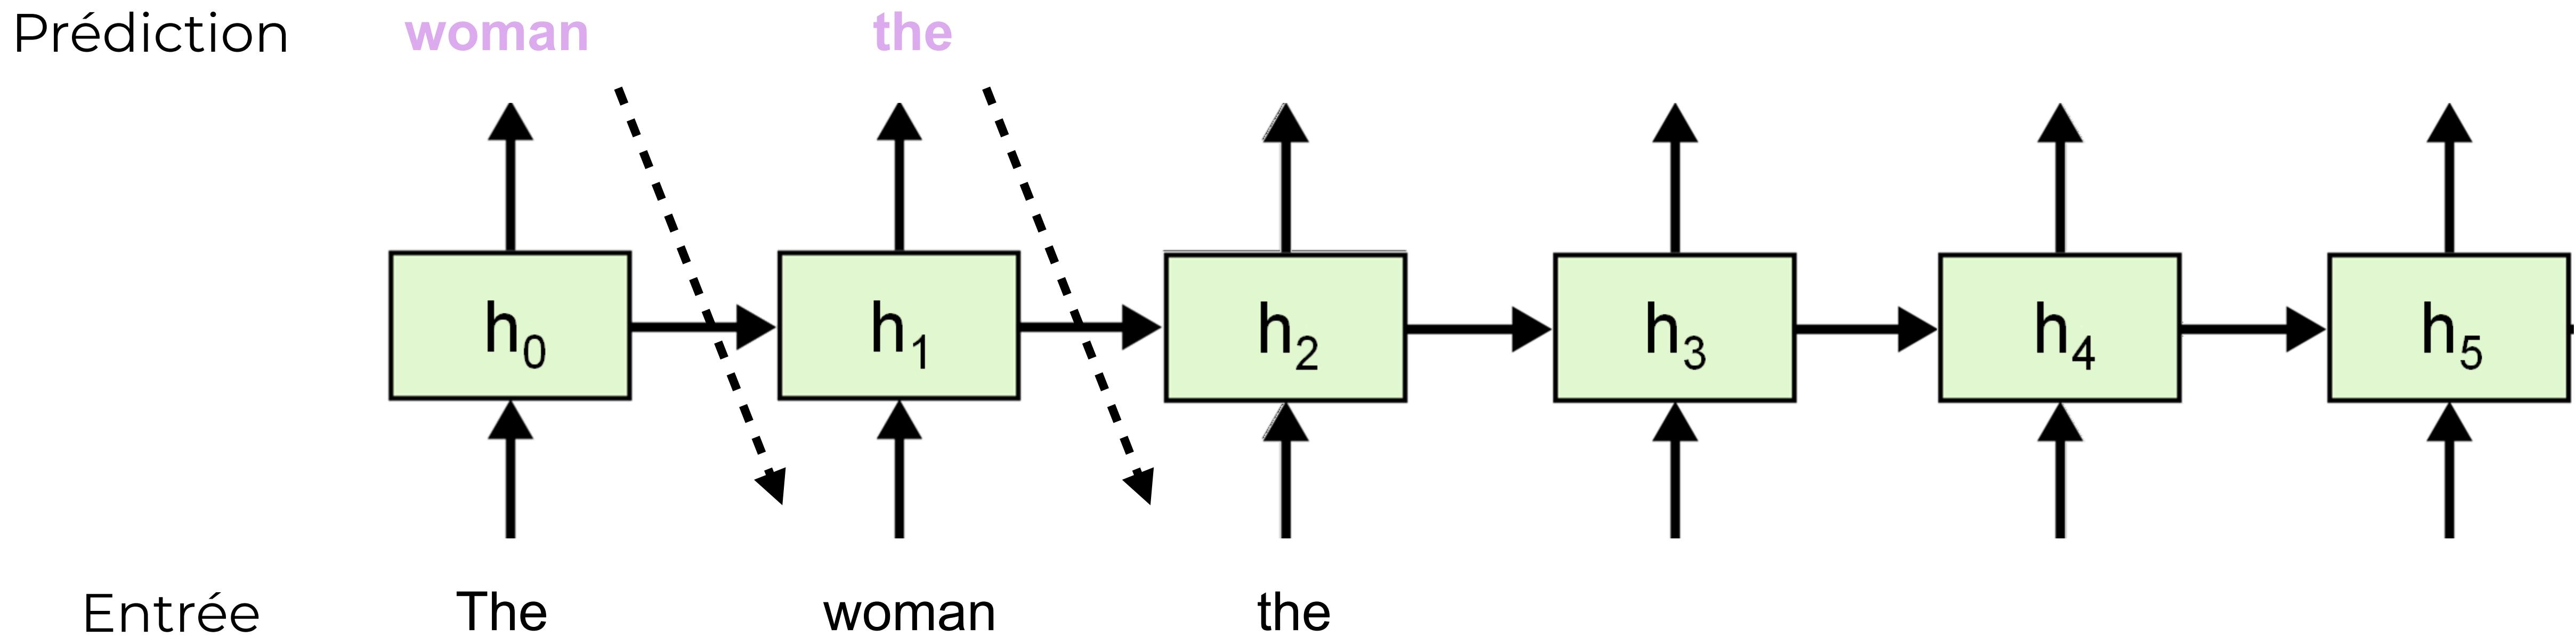
## Test.

1. Prédire un mot à la fois
2. On donne la prédiction en entrée au prochain pas de temps



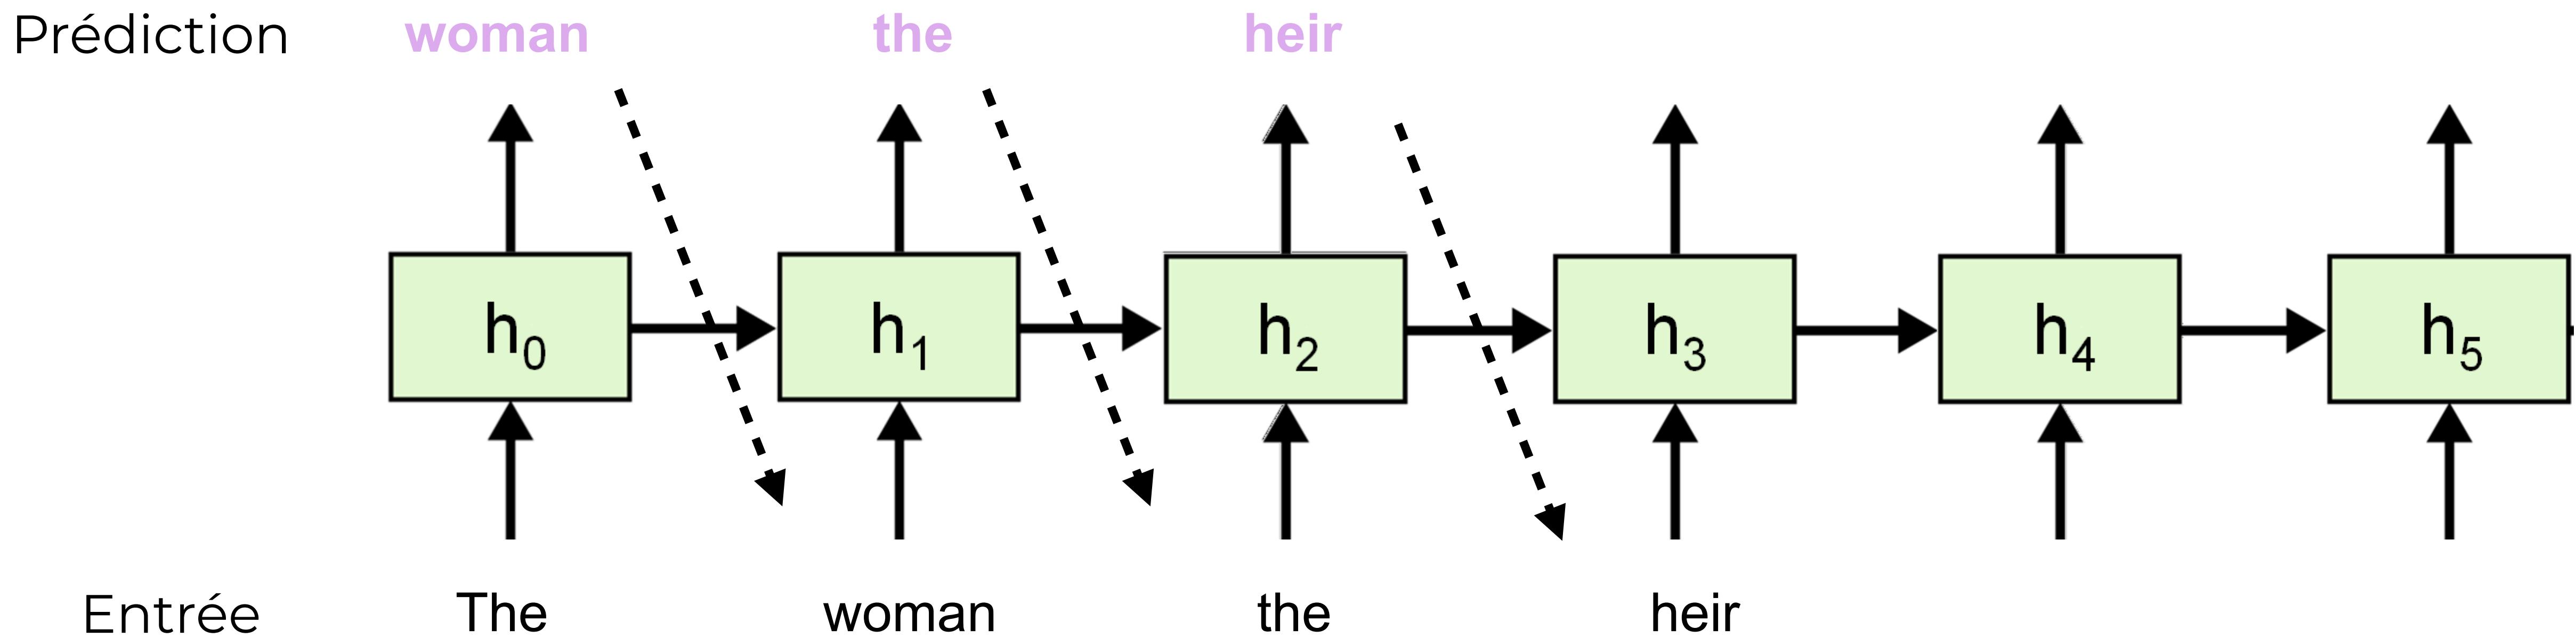
## Test.

1. Prédire un mot à la fois
2. On donne la prédiction en entrée au prochain pas de temps



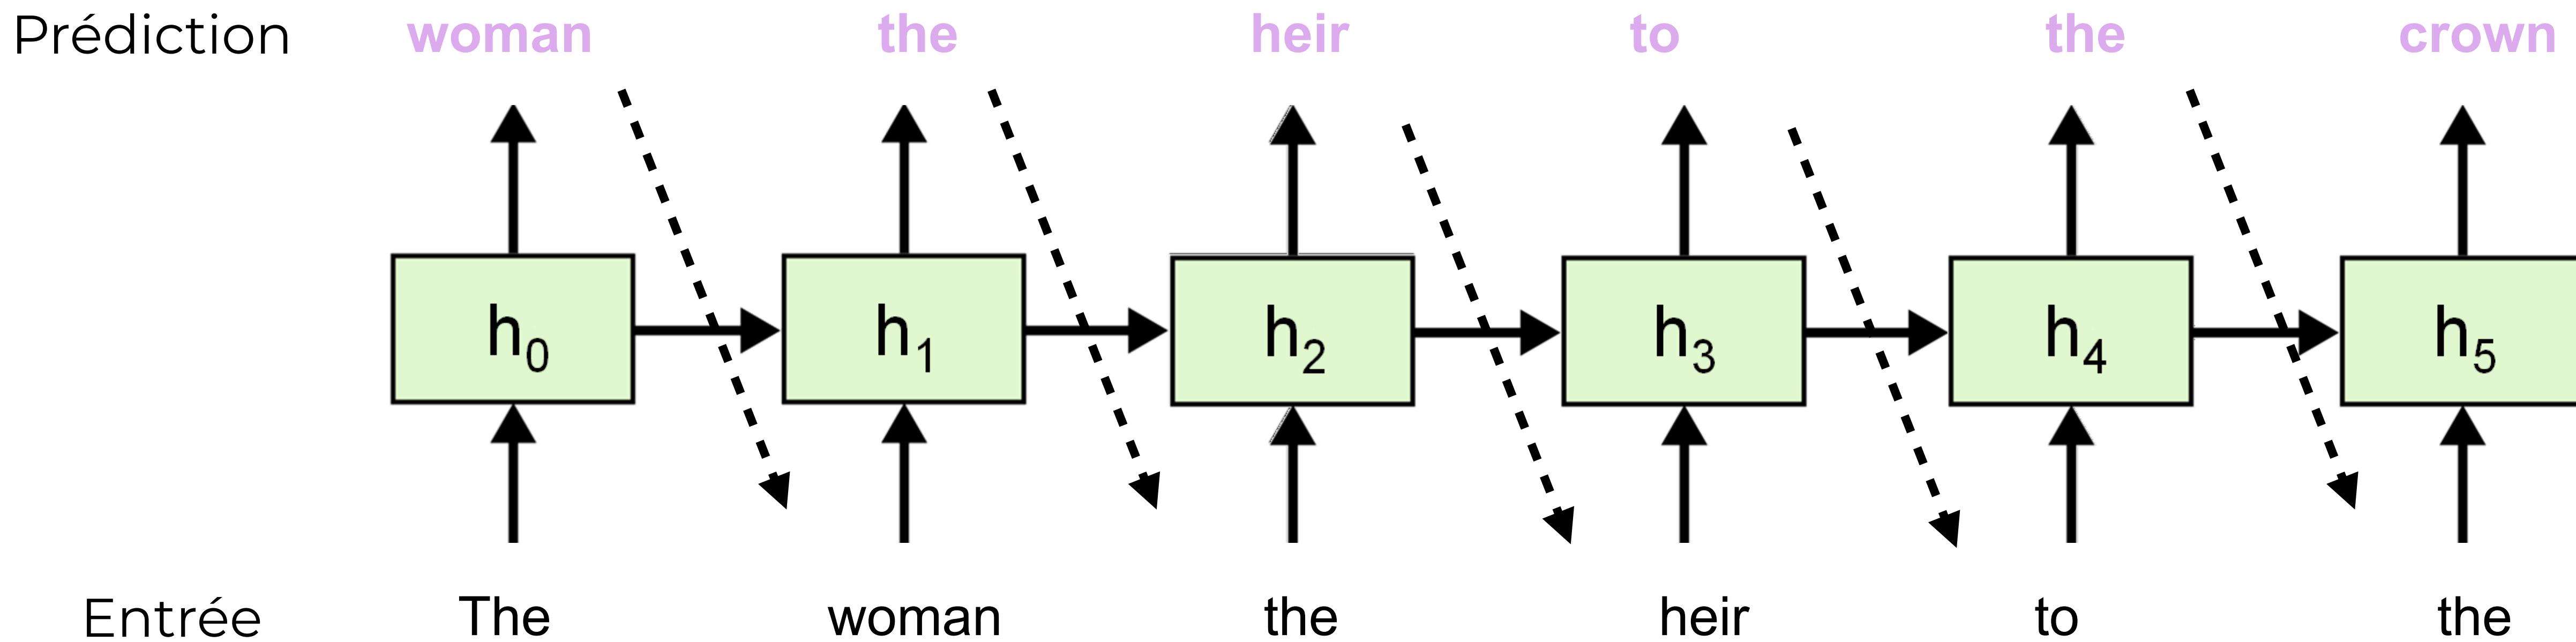
## Test.

1. Prédire un mot à la fois
2. On donne la prédiction en entrée au prochain pas de temps



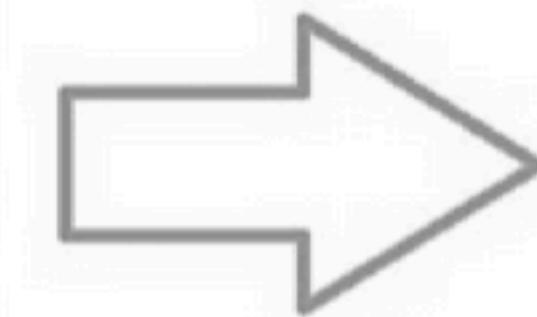
## Test.

1. Prédire un mot à la fois
2. On donne la prédiction en entrée au prochain pas de temps





This is how I see

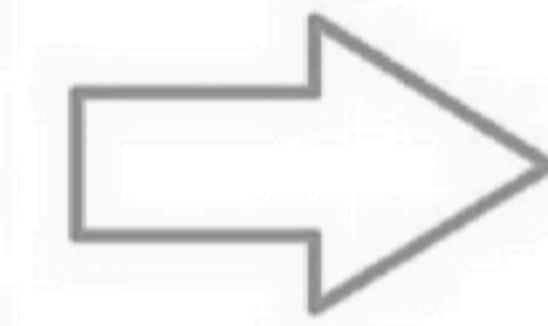


88	126	145	85	123	142	85	123	142	86	124
86	125	142	84	123	140	83	122	139	85	124
85	124	141	82	121	138	82	121	138	84	123
82	119	135	80	117	133	80	117	133	85	122
78	114	128	77	113	127	79	115	129	84	120
79	115	129	78	114	128	80	116	130	83	119
82	118	130	81	117	129	81	117	129	82	118
83	117	129	82	116	128	82	116	128	82	116
79	113	123	79	113	123	80	114	124	81	115
76	108	119	76	108	119	77	109	120	80	112
76	109	118	76	109	118	77	110	119	79	112

This is how my computer sees



This is how I see

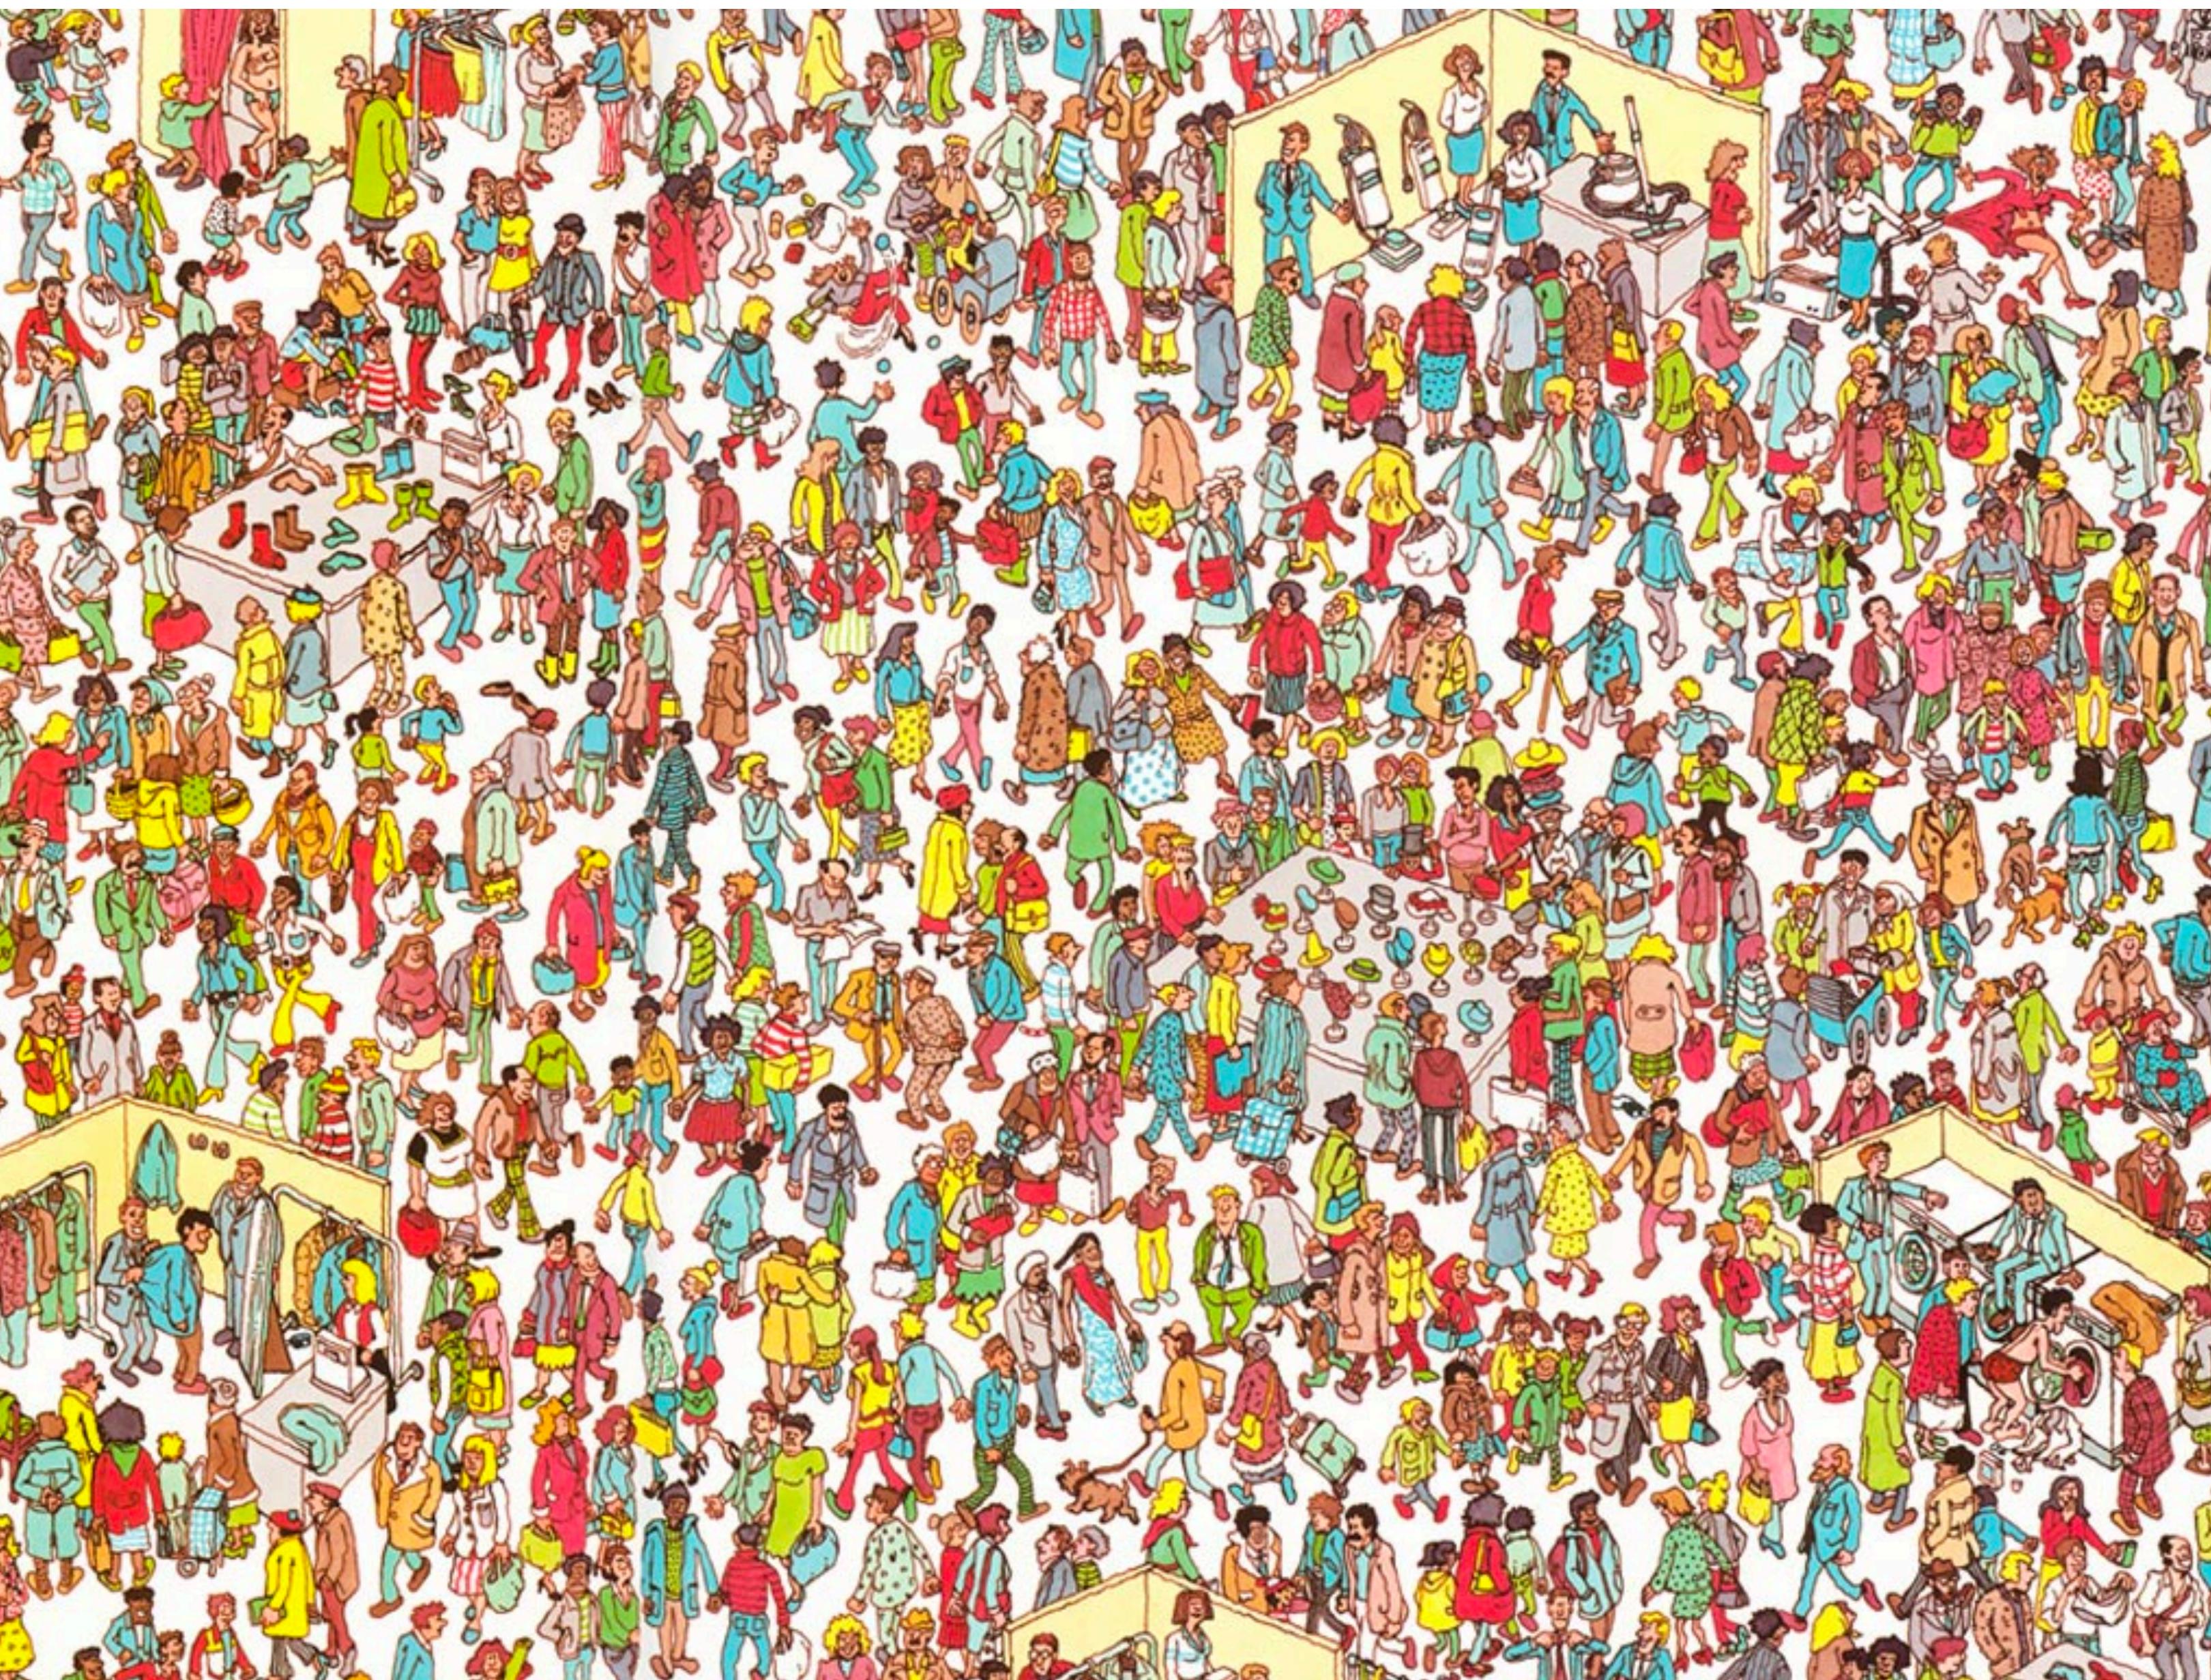


88	126	145	85	123	142	85	123	142	86	124
86	125	142	84	123	140	83	122	139	85	124
85	124	141	82	121	138	82	121	138	84	123
82	119	135	80	117	133	80	117	133	85	122
78	114	128	77	113	127	79	115	129	84	120
79	115	129	78	114	128	80	116	130	83	119
82	118	130	81	117	129	81	117	129	82	118
83	117	129	82	116	128	82	116	128	82	116
79	113	123	79	113	123	80	114	124	81	115
76	108	119	76	108	119	77	109	120	80	112
76	109	118	76	109	118	77	110	119	79	112

This is how my computer sees

- **Une image de 100 x 100 pixels a 10,000 dimensions**
- **Plus si l'image est en couleur**
- **Un téléphone récent(12 MP): 4032 x 3024 pixels**

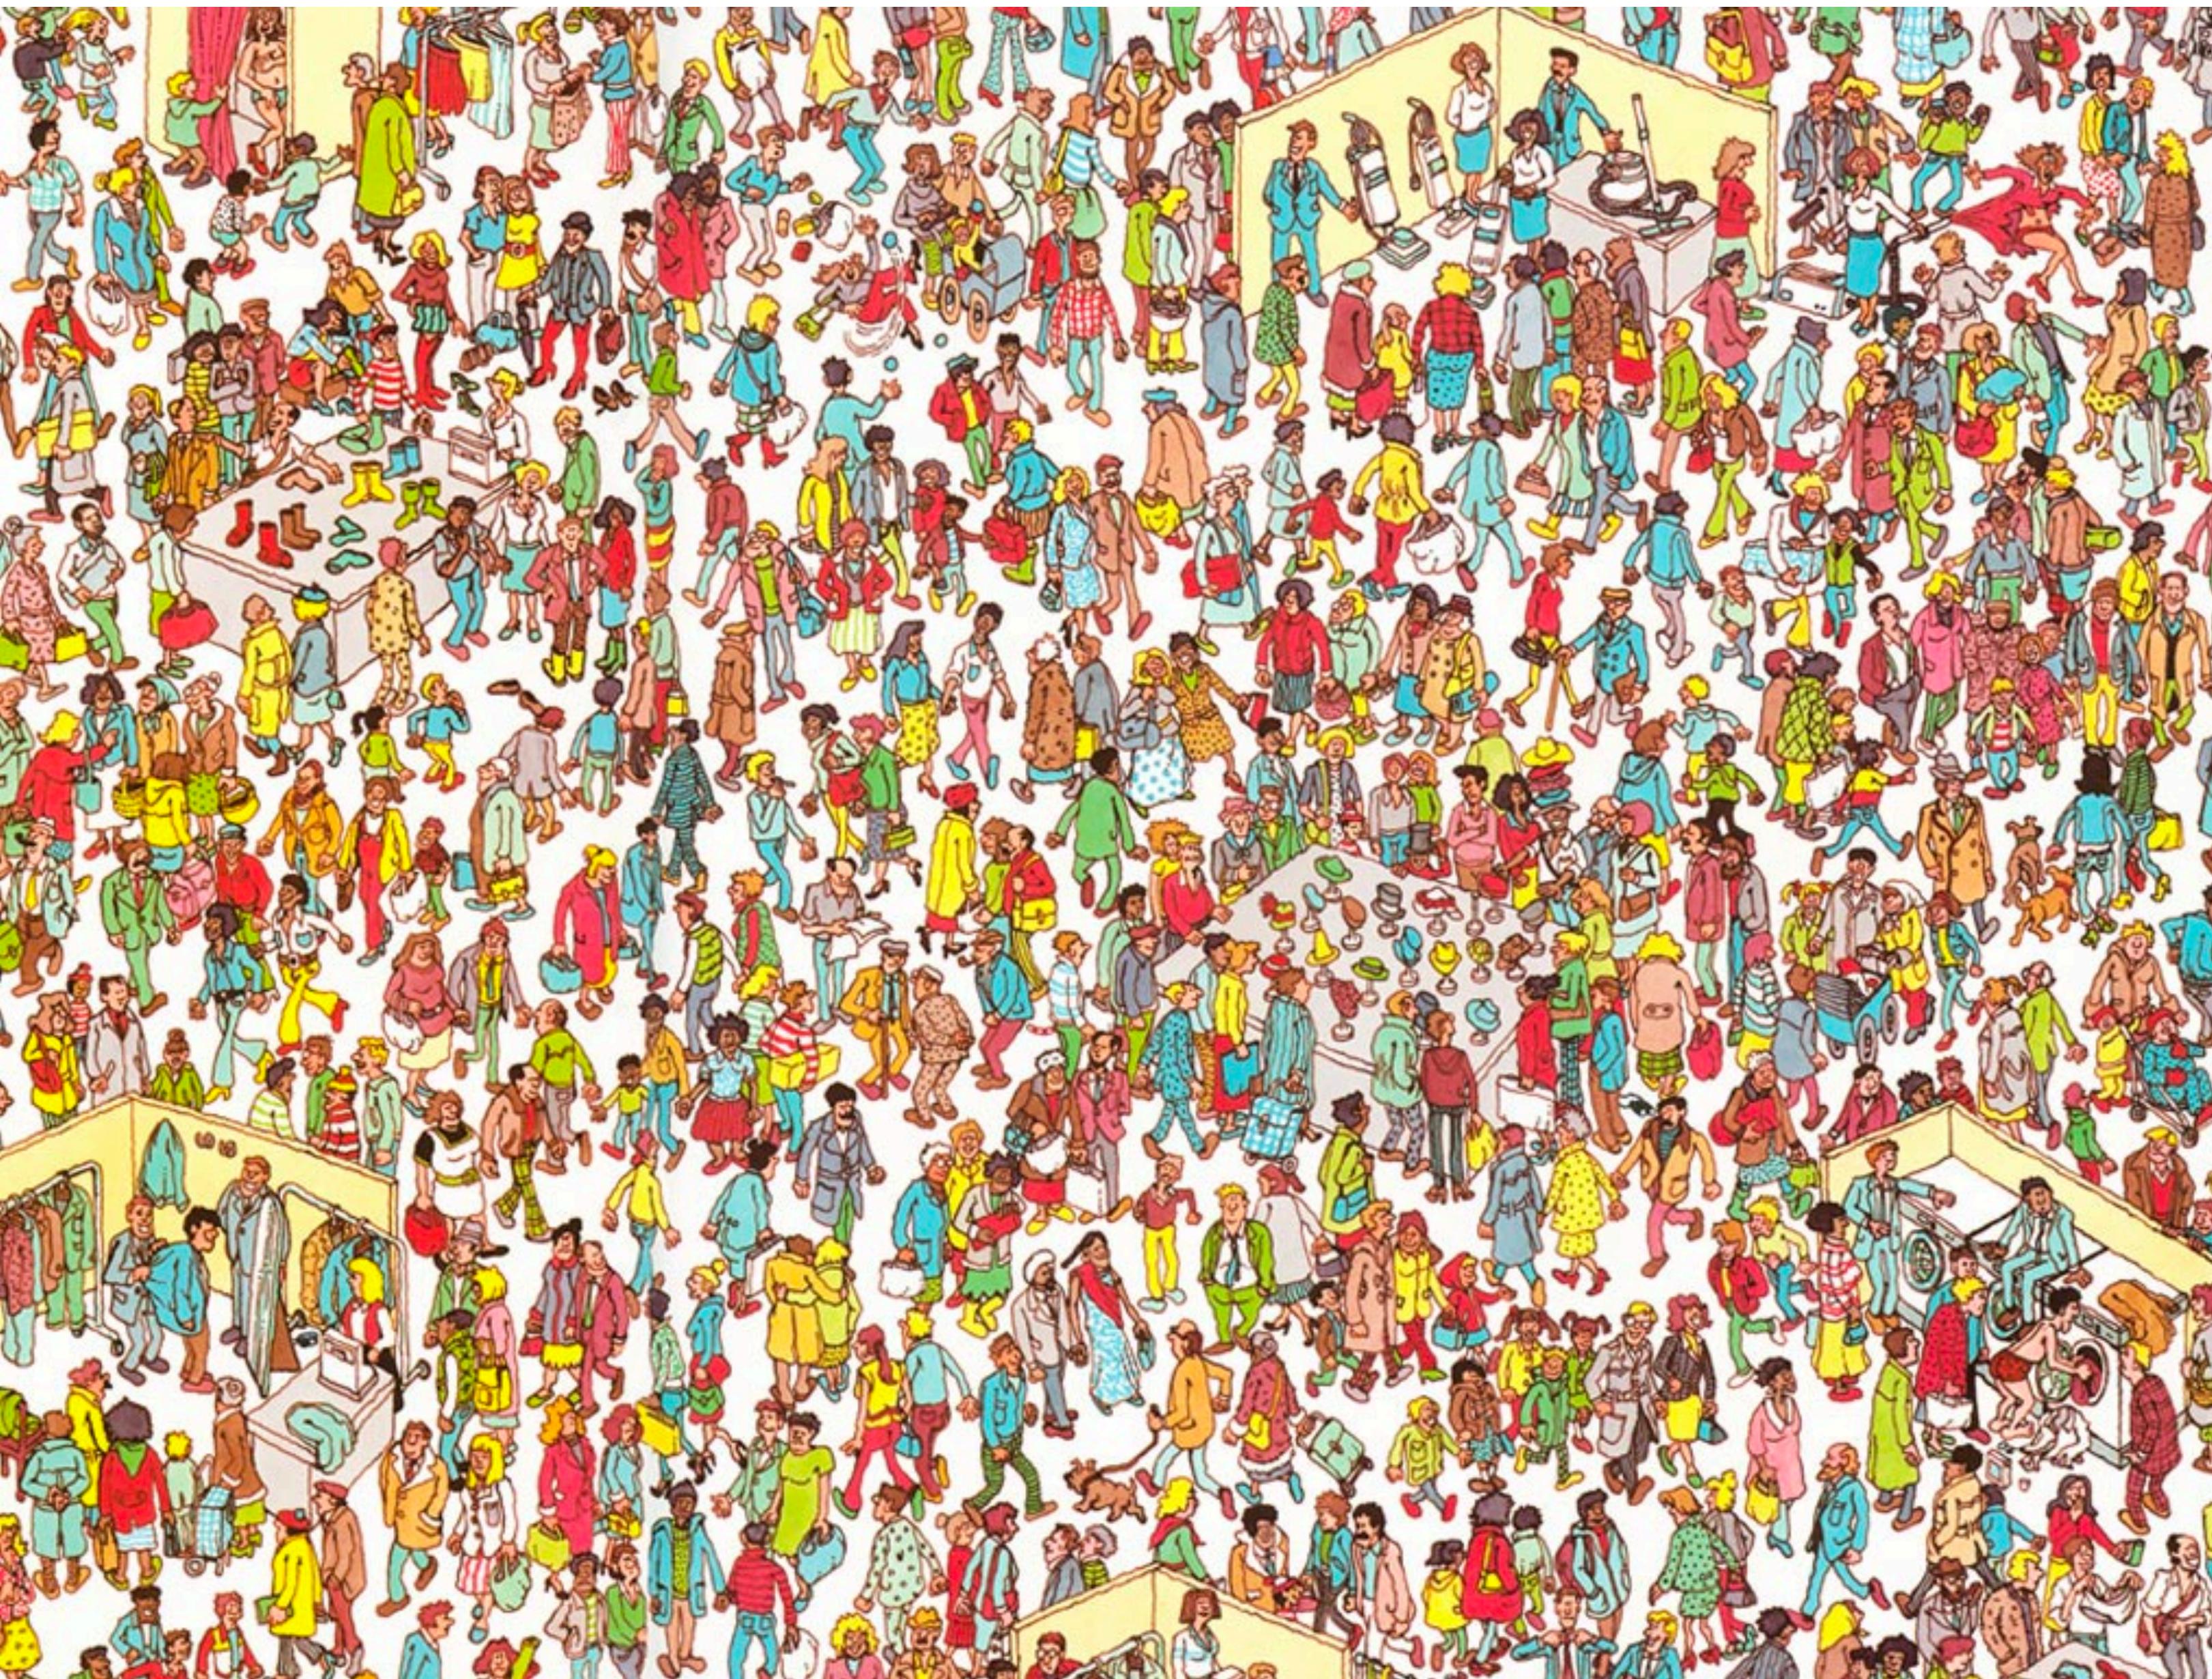
Source: <https://medium.com/deep-math-machine-learning-ai/chapter-8-0-convolutional-neural-networks-for-deep-learning-364971e34ab2>



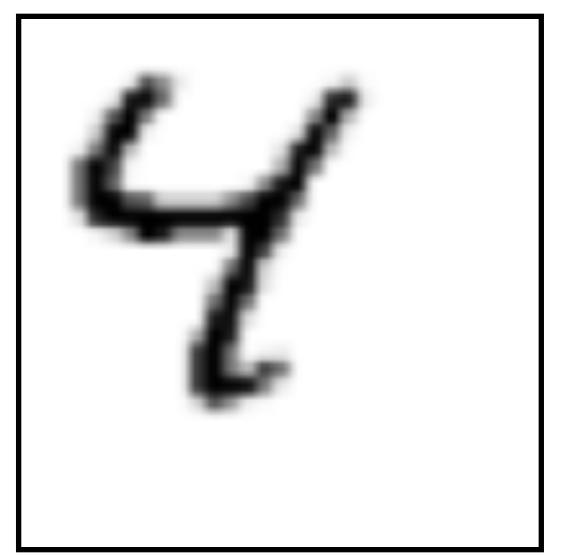


●

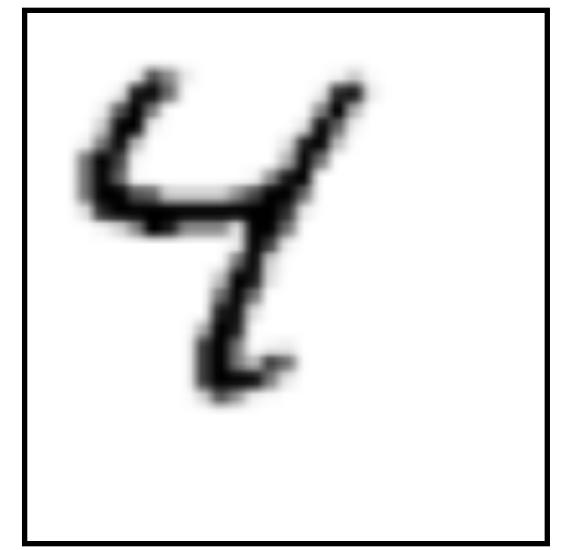
●



Image



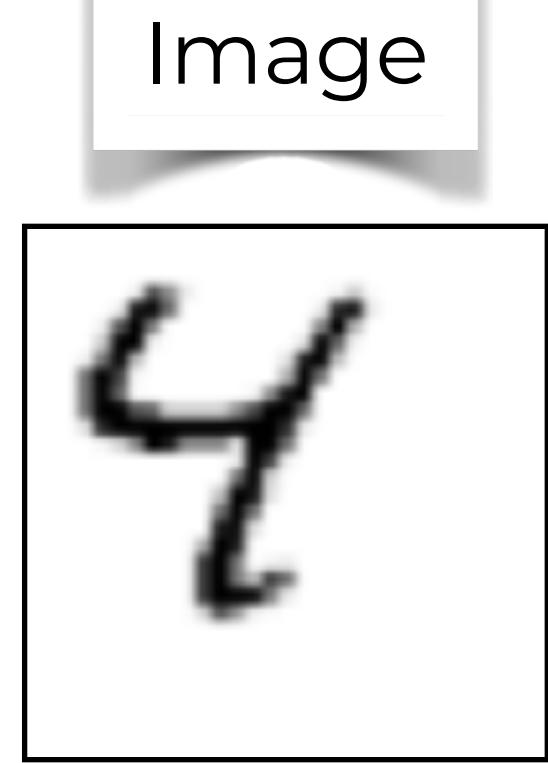
Image



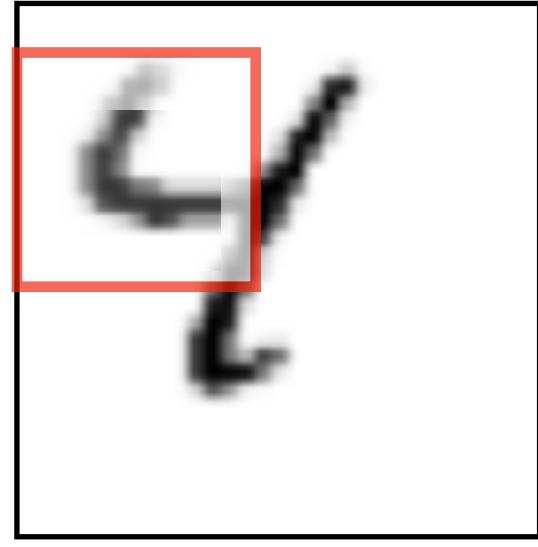
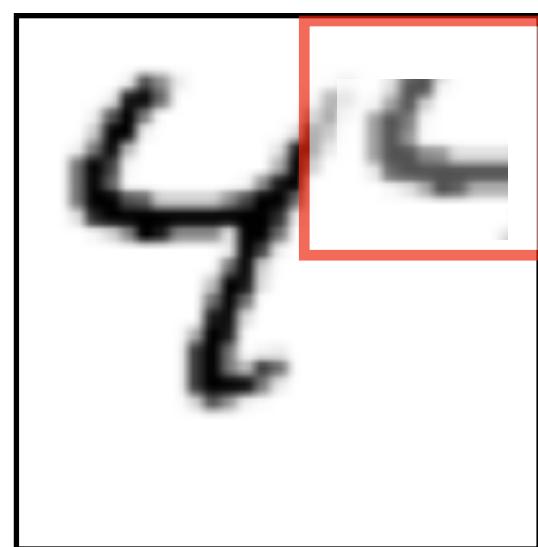
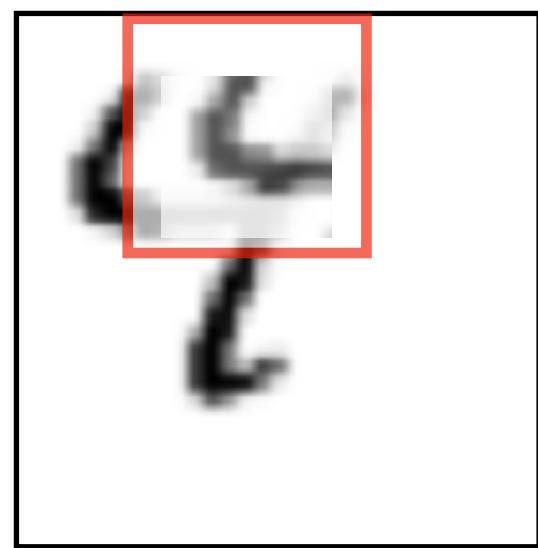
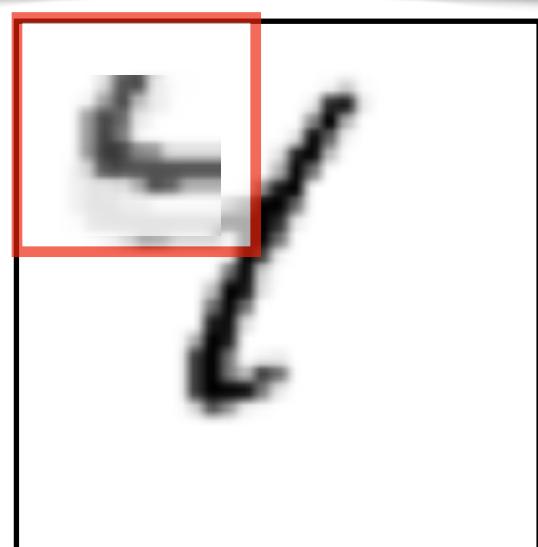
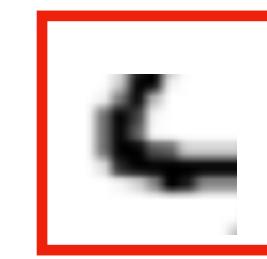
Filtre (Kernel)



Glisser le filtre partout sur l'image  
(Convolutions)

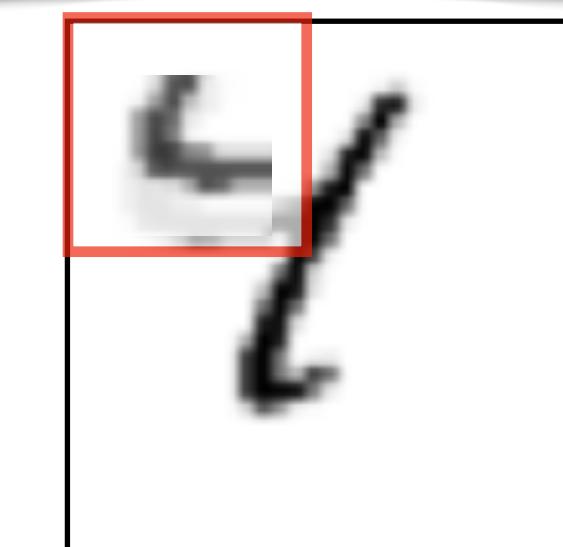
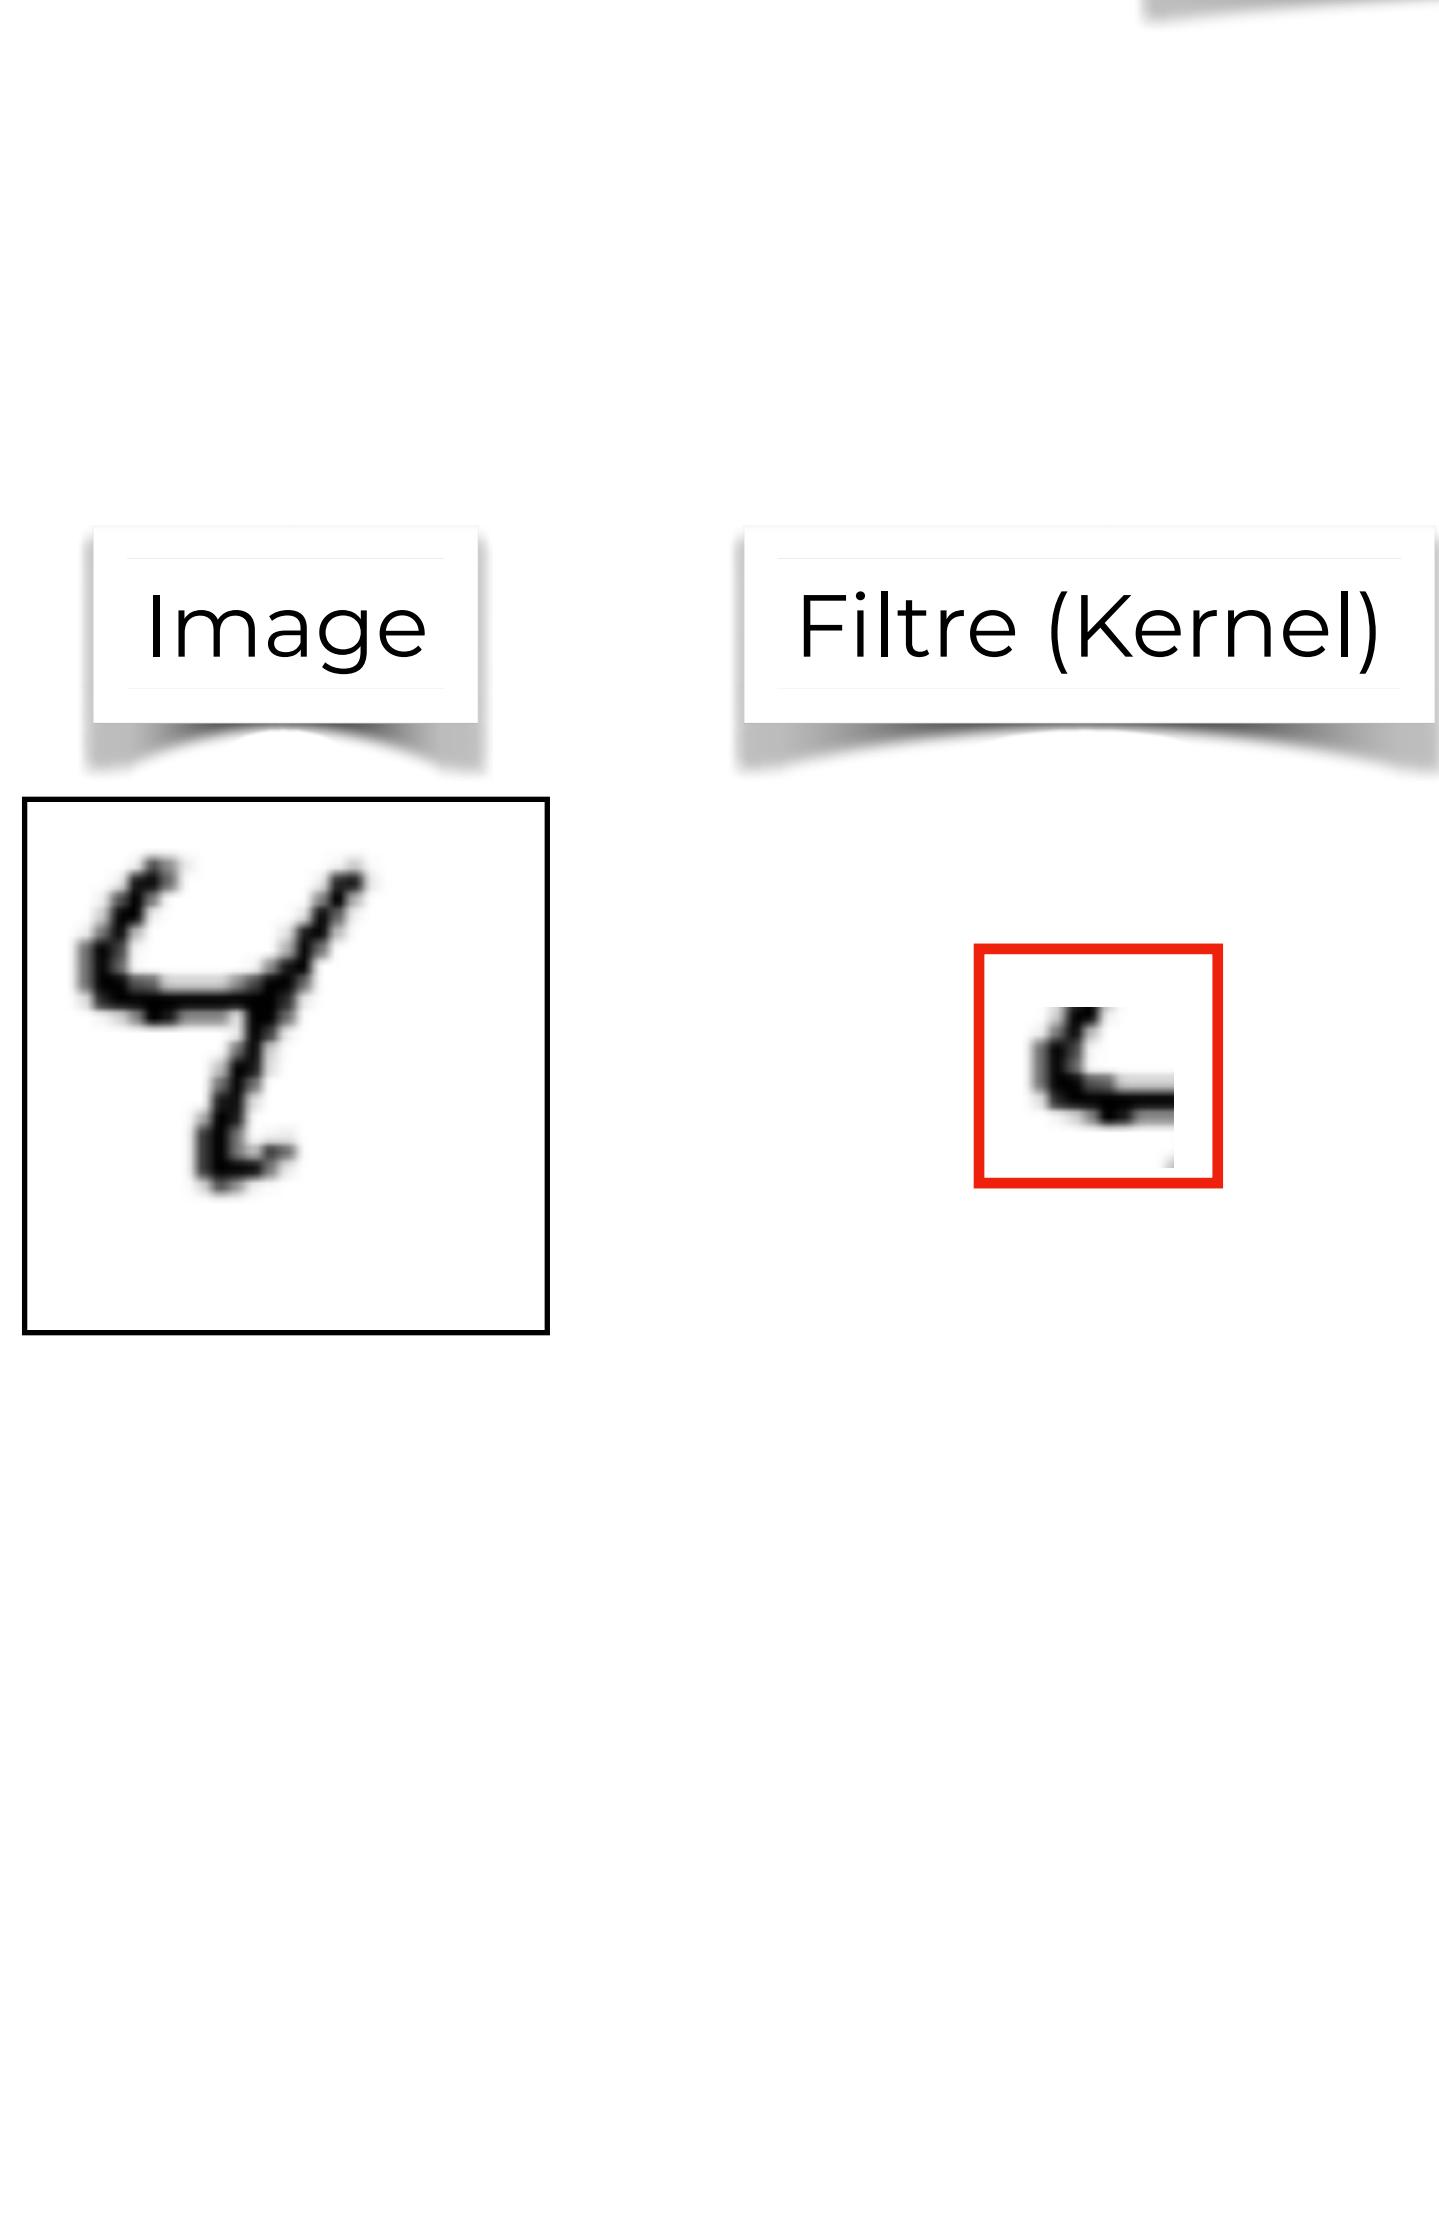


Filtre (Kernel)

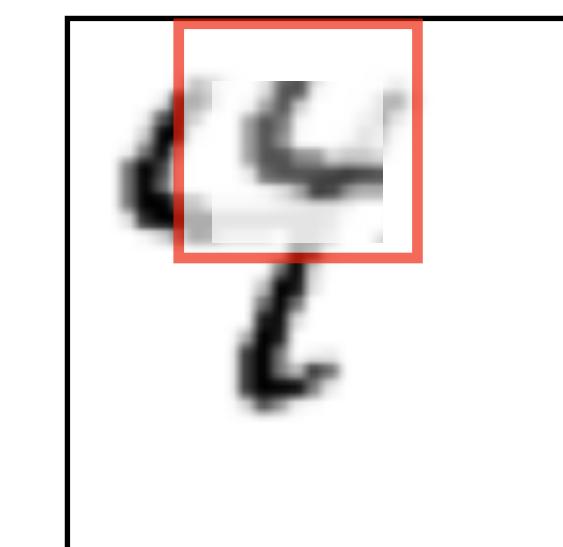


...

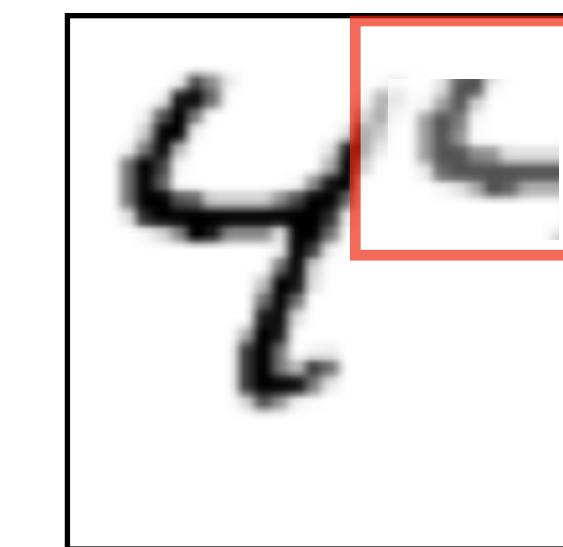
Glisser le filtre partout sur l'image  
(Convolutions)



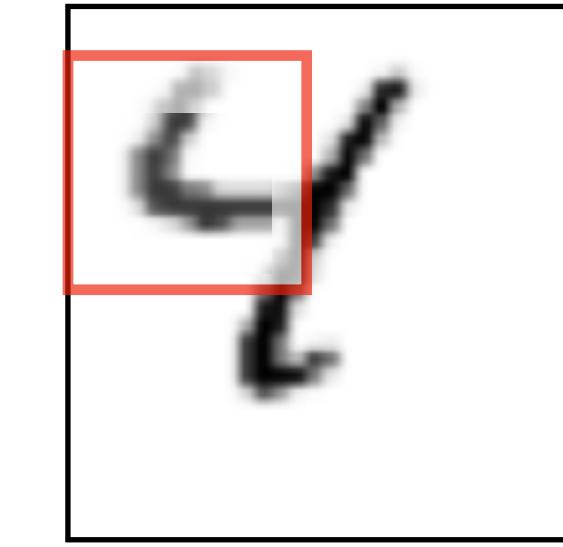
→ Pas de détection  
Sortie: Basse



→ Pas de détection  
Sortie: Basse



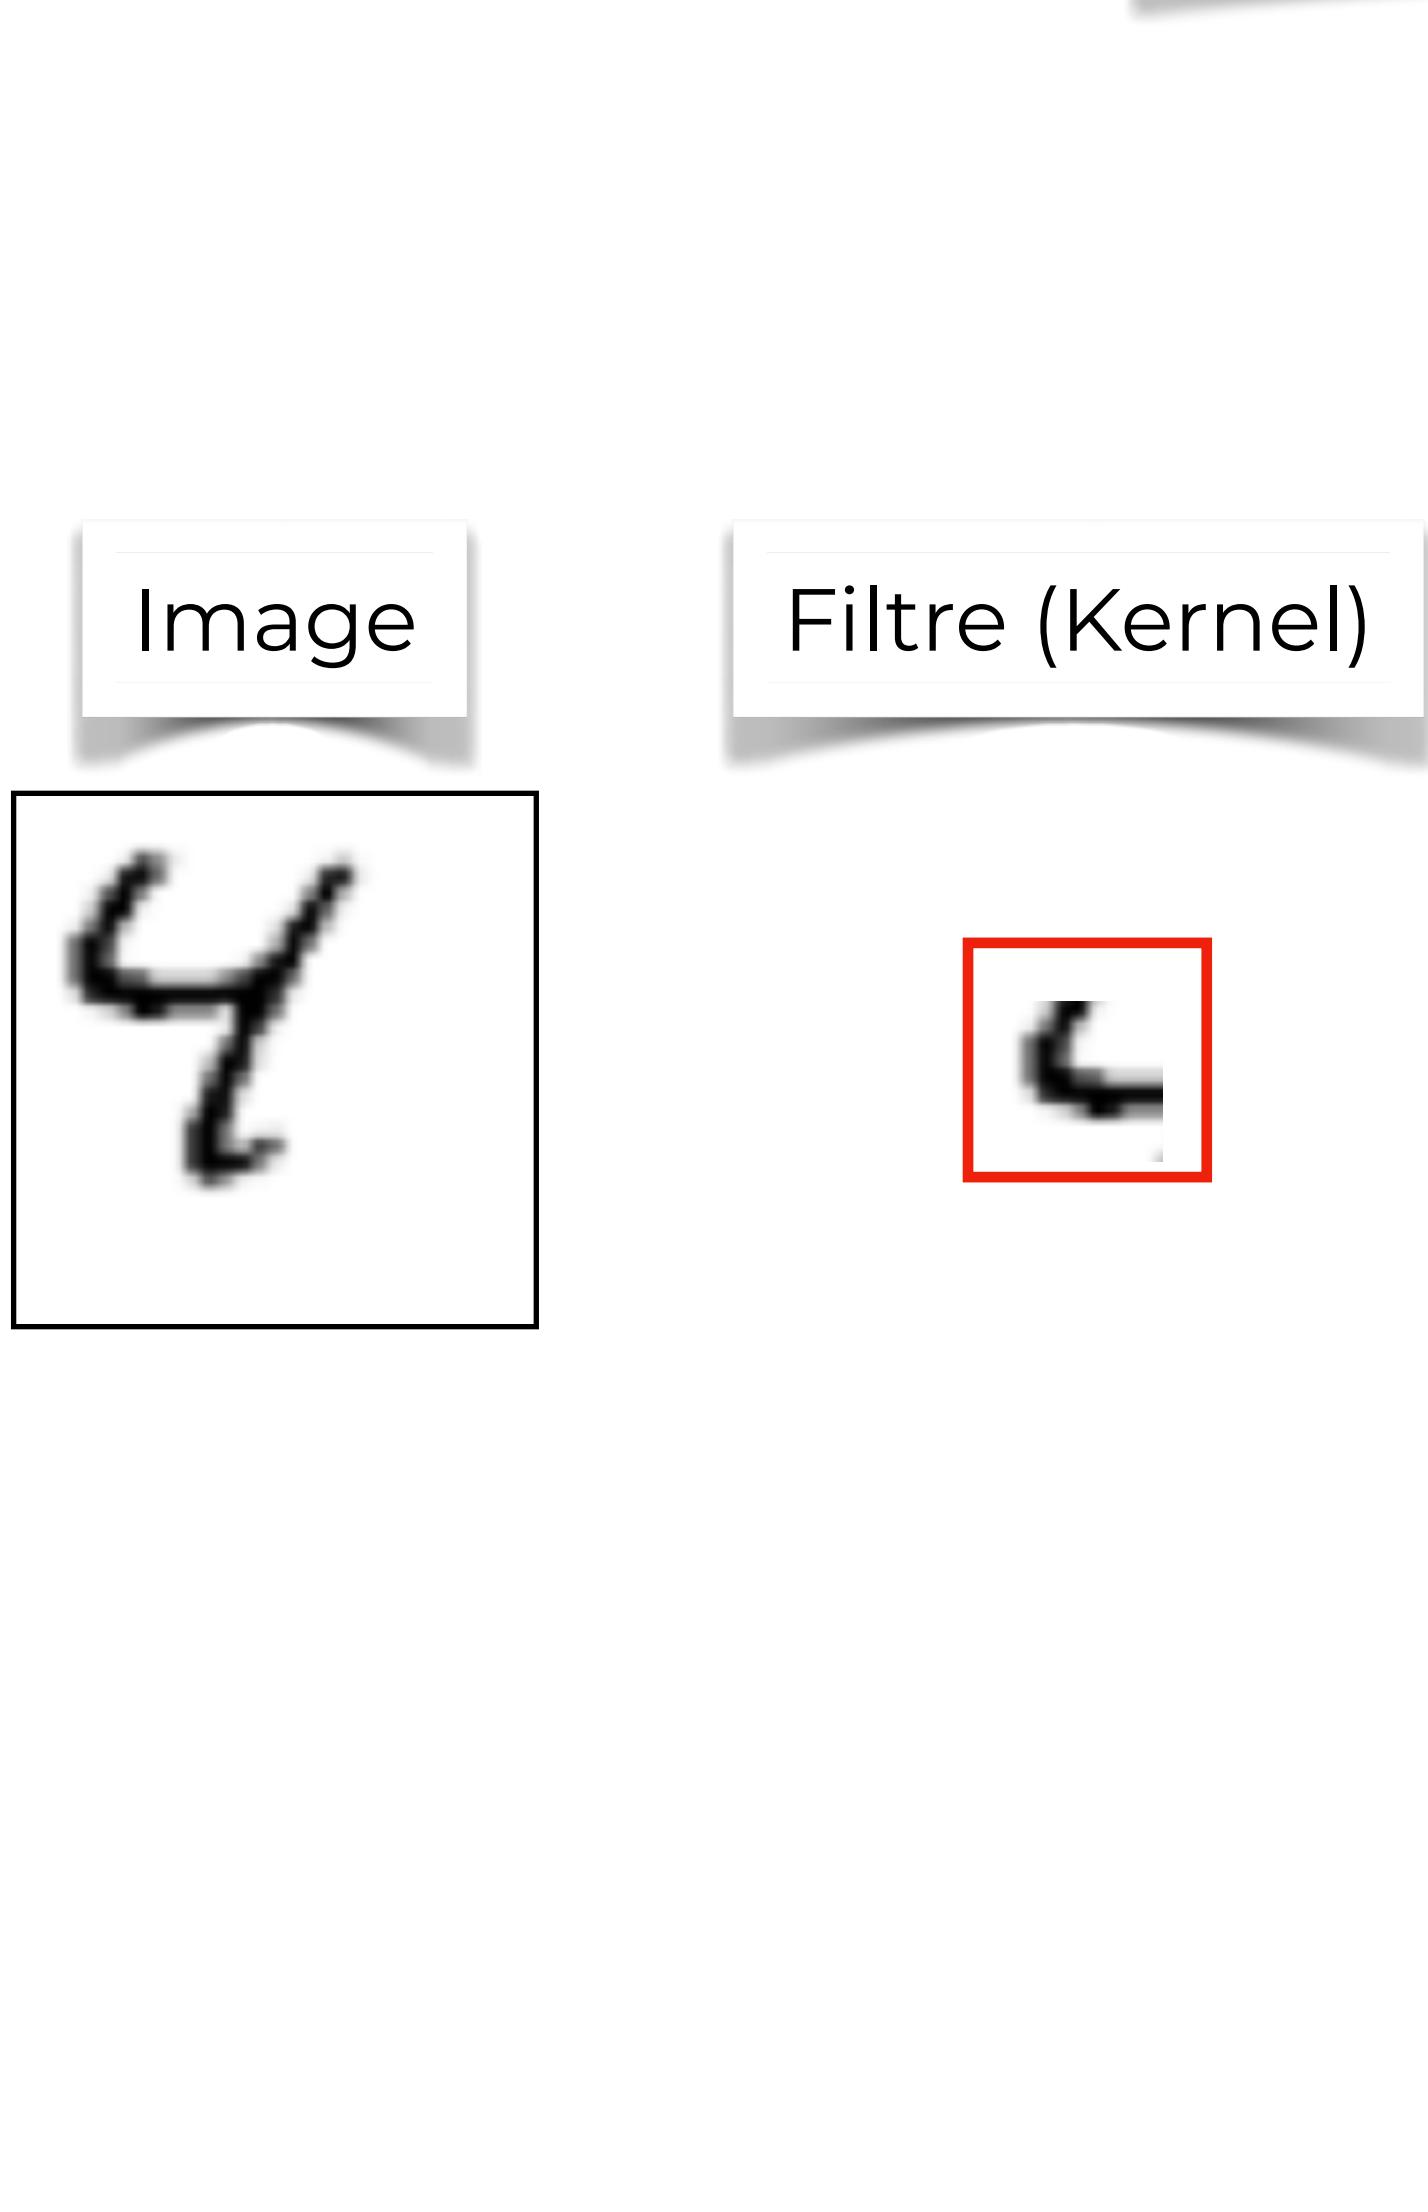
→ Pas de détection  
Sortie: Basse



→ **Détection**  
**Sortie: Haute**

...

Glisser le filtre partout sur l'image  
(Convolutions)



Agréger les sorties  
de plusieurs filtres  
(Pooling)

Pas de détection  
Sortie: Basse

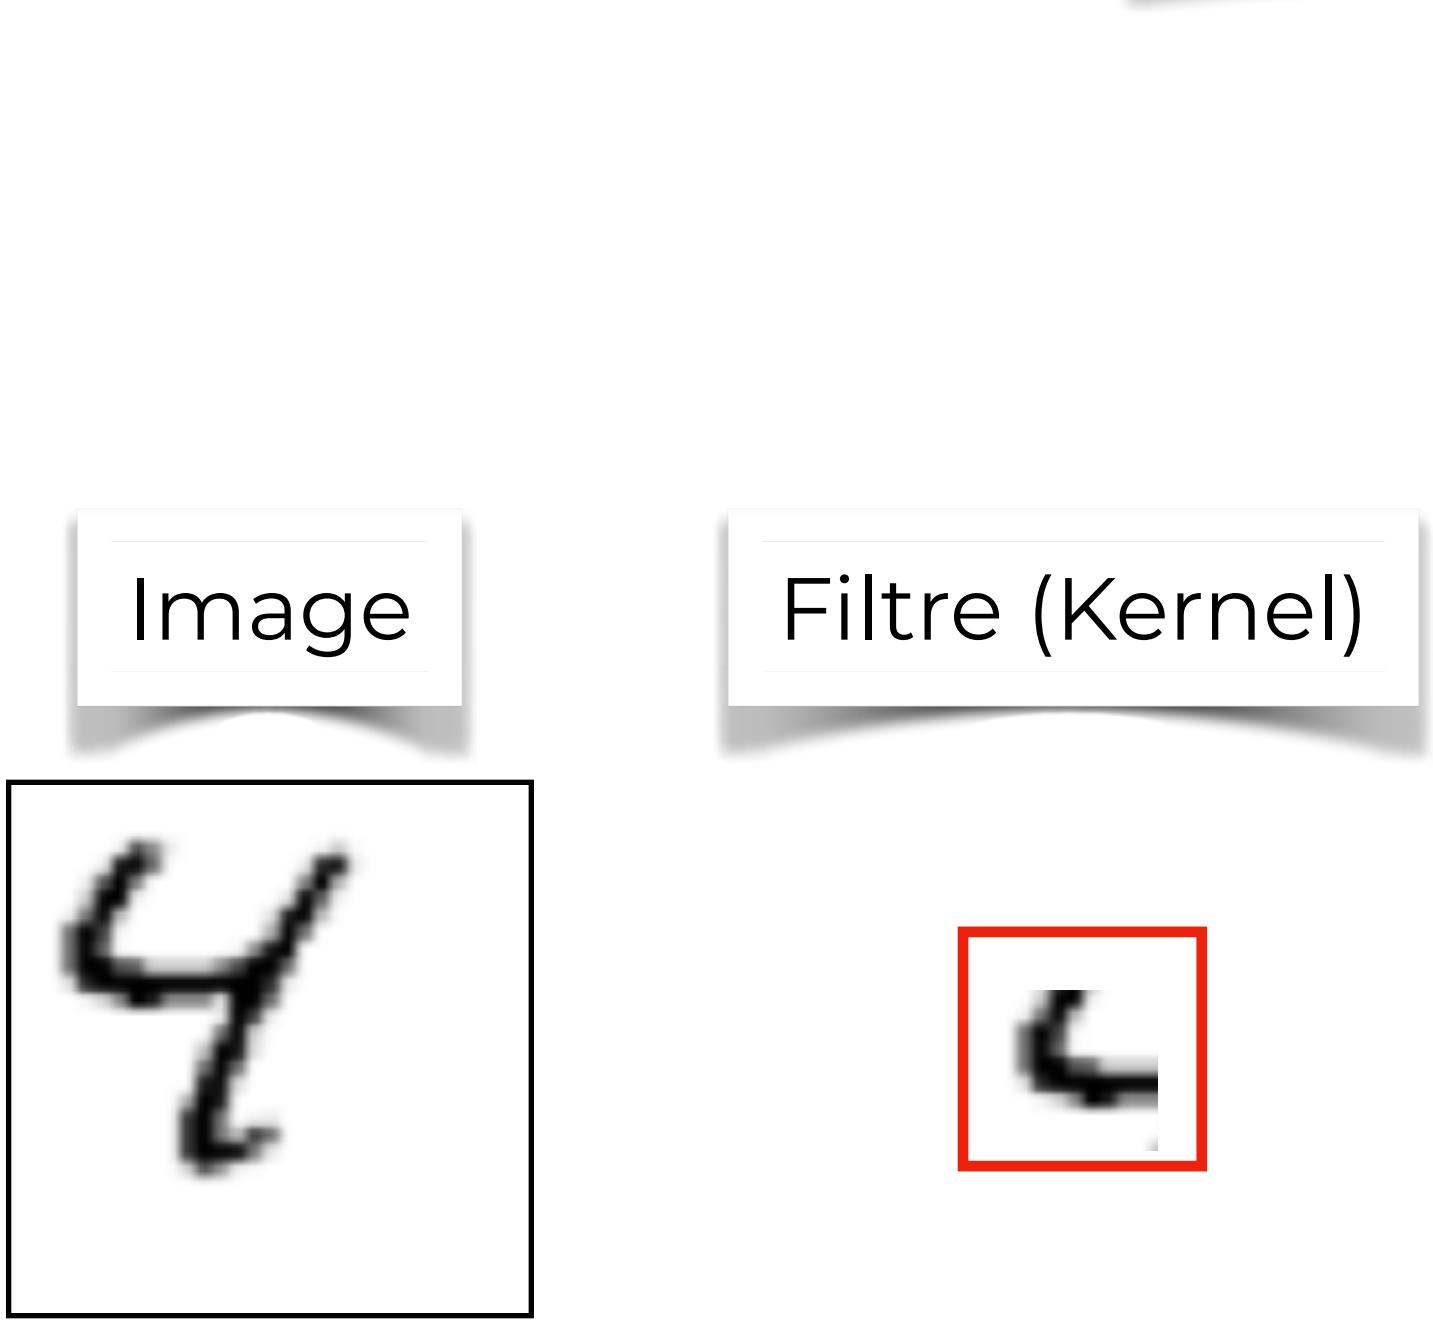
Pas de détection  
Sortie: Basse

Pas de détection  
Sortie: Basse

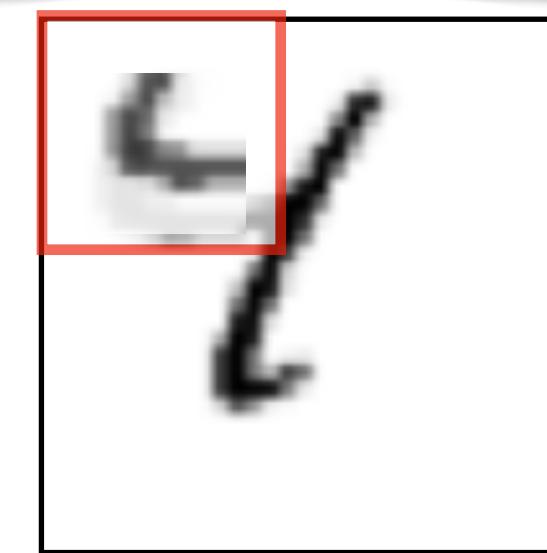
Détection  
Sortie: Haute

**Un des filtres a détecté  
une partie d'un objet  
Sortie: élevée**

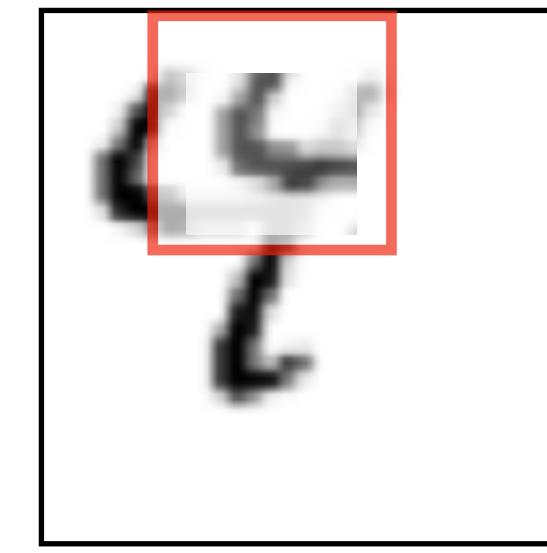
Glisser le filtre partout sur l'image  
(Convolutions)



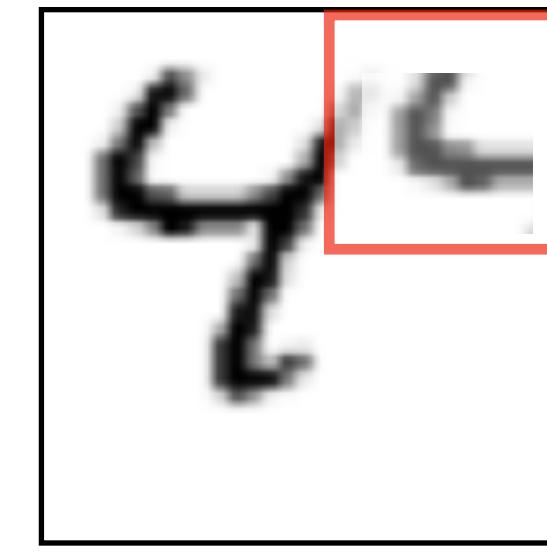
Ingrédients importants:  
1) Apprendre les filtres;  
2) Utiliser beaucoup de filtres.



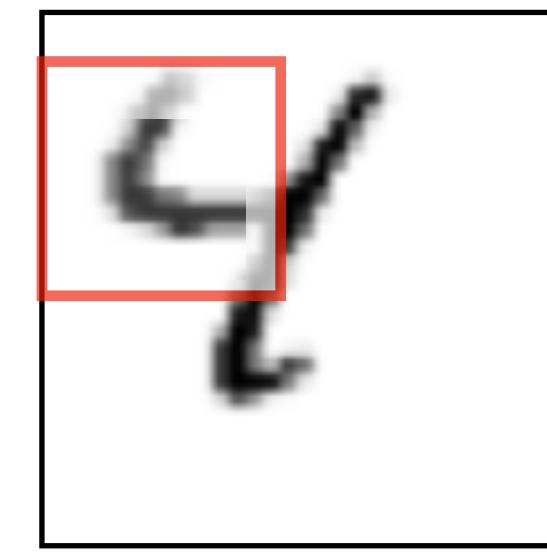
Pas de détection  
Sortie: Basse



Pas de détection  
Sortie: Basse



Pas de détection  
Sortie: Basse

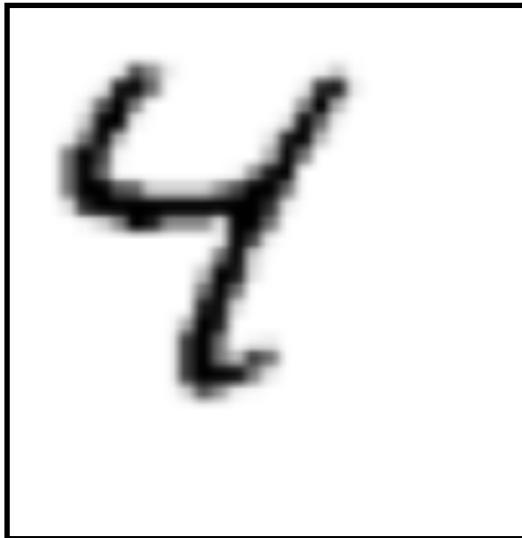


Détection  
Sortie: Haute

Agréger les sorties de plusieurs filtres (Pooling)

**Un des filtres a détecté une partie d'un objet  
Sortie: élevée**

# Convolutions



Pour un pixel  $(i,j)$ :

$$S(i,j) = (K * I)(i,j) = \sum_m \sum_n I(i+m, j+n) K(m, n)$$

k. width k. height

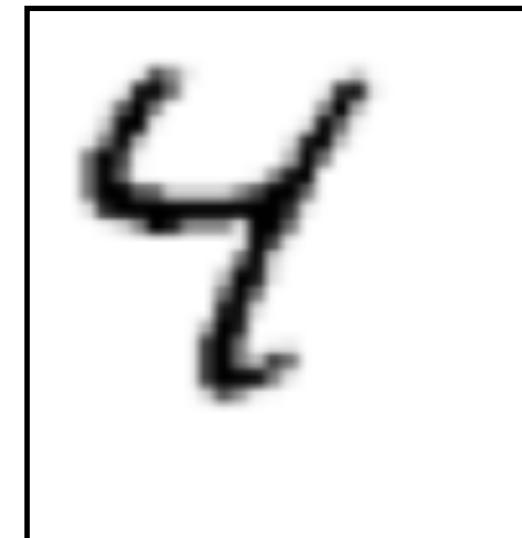
Kernel                      Input

A diagram illustrating the convolution operation. It shows a large input image on the left and a smaller kernel on the right. Arrows point from the kernel to the input image, indicating the receptive field of the kernel's pixels. The formula  $S(i,j) = (K * I)(i,j) = \sum_m \sum_n I(i+m, j+n) K(m, n)$  is displayed above, with 'Kernel' pointing to the kernel and 'Input' pointing to the input image.



- **Produit scalaire entre “le kernel et une région de l’image”**

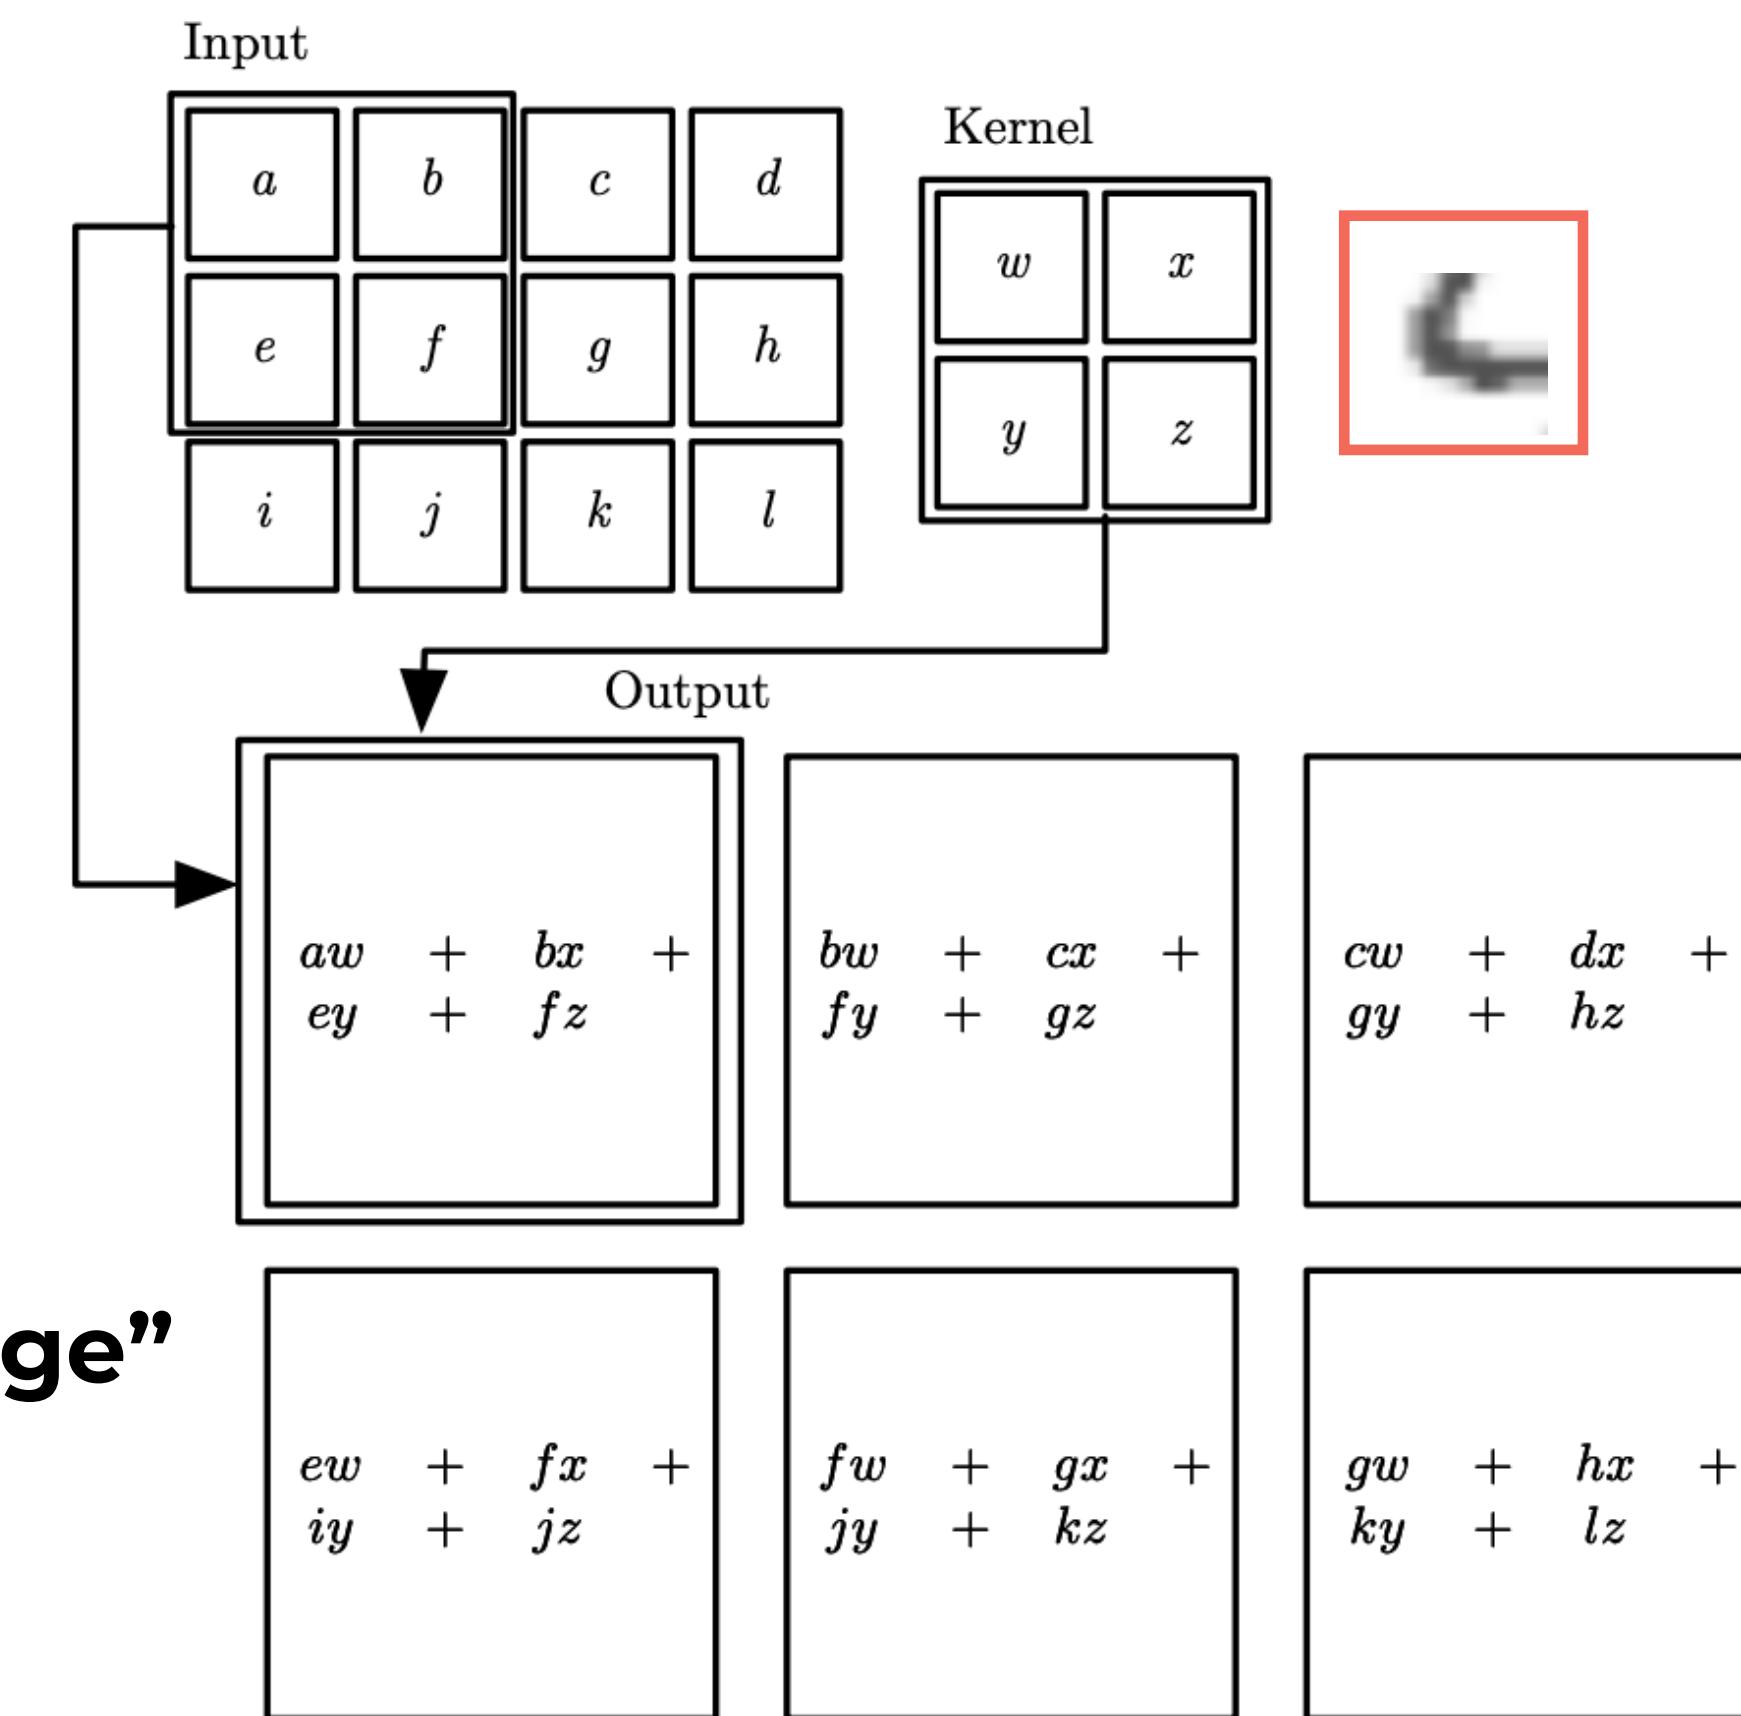
# Convolutions



**Pour un pixel  $(i,j)$ :**

$$S(i,j) = (K * I)(i,j) = \sum_{m=0}^{k. \text{ width}} \sum_{n=0}^{k. \text{ height}} I(i+m, j+n) K(m, n)$$

Kernel                      Input



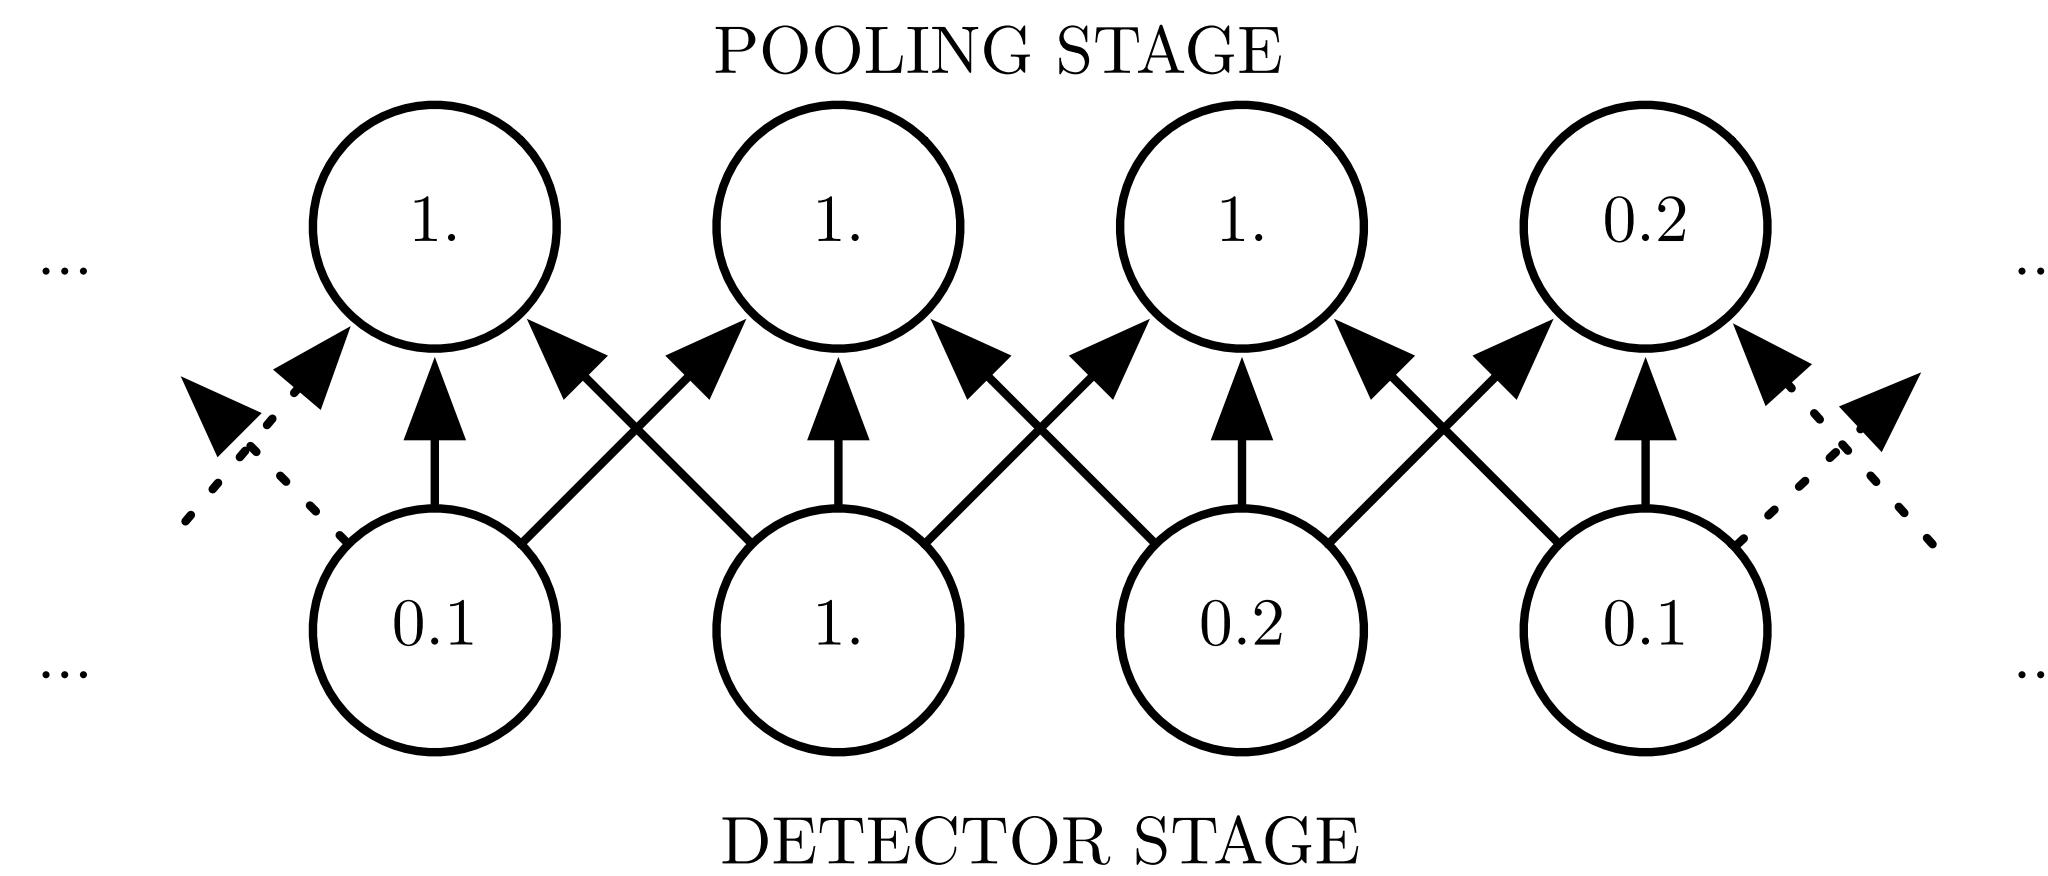
- **Produit scalaire entre “le kernel et une région de l’image”**

# Pooling

- Rend la représentation invariante à des petites translations de l'image d'entrée
  - “Pool” les valeurs des unités voisines (entrées)
  - E.g., max-pooling prend le max. de ses entrées.

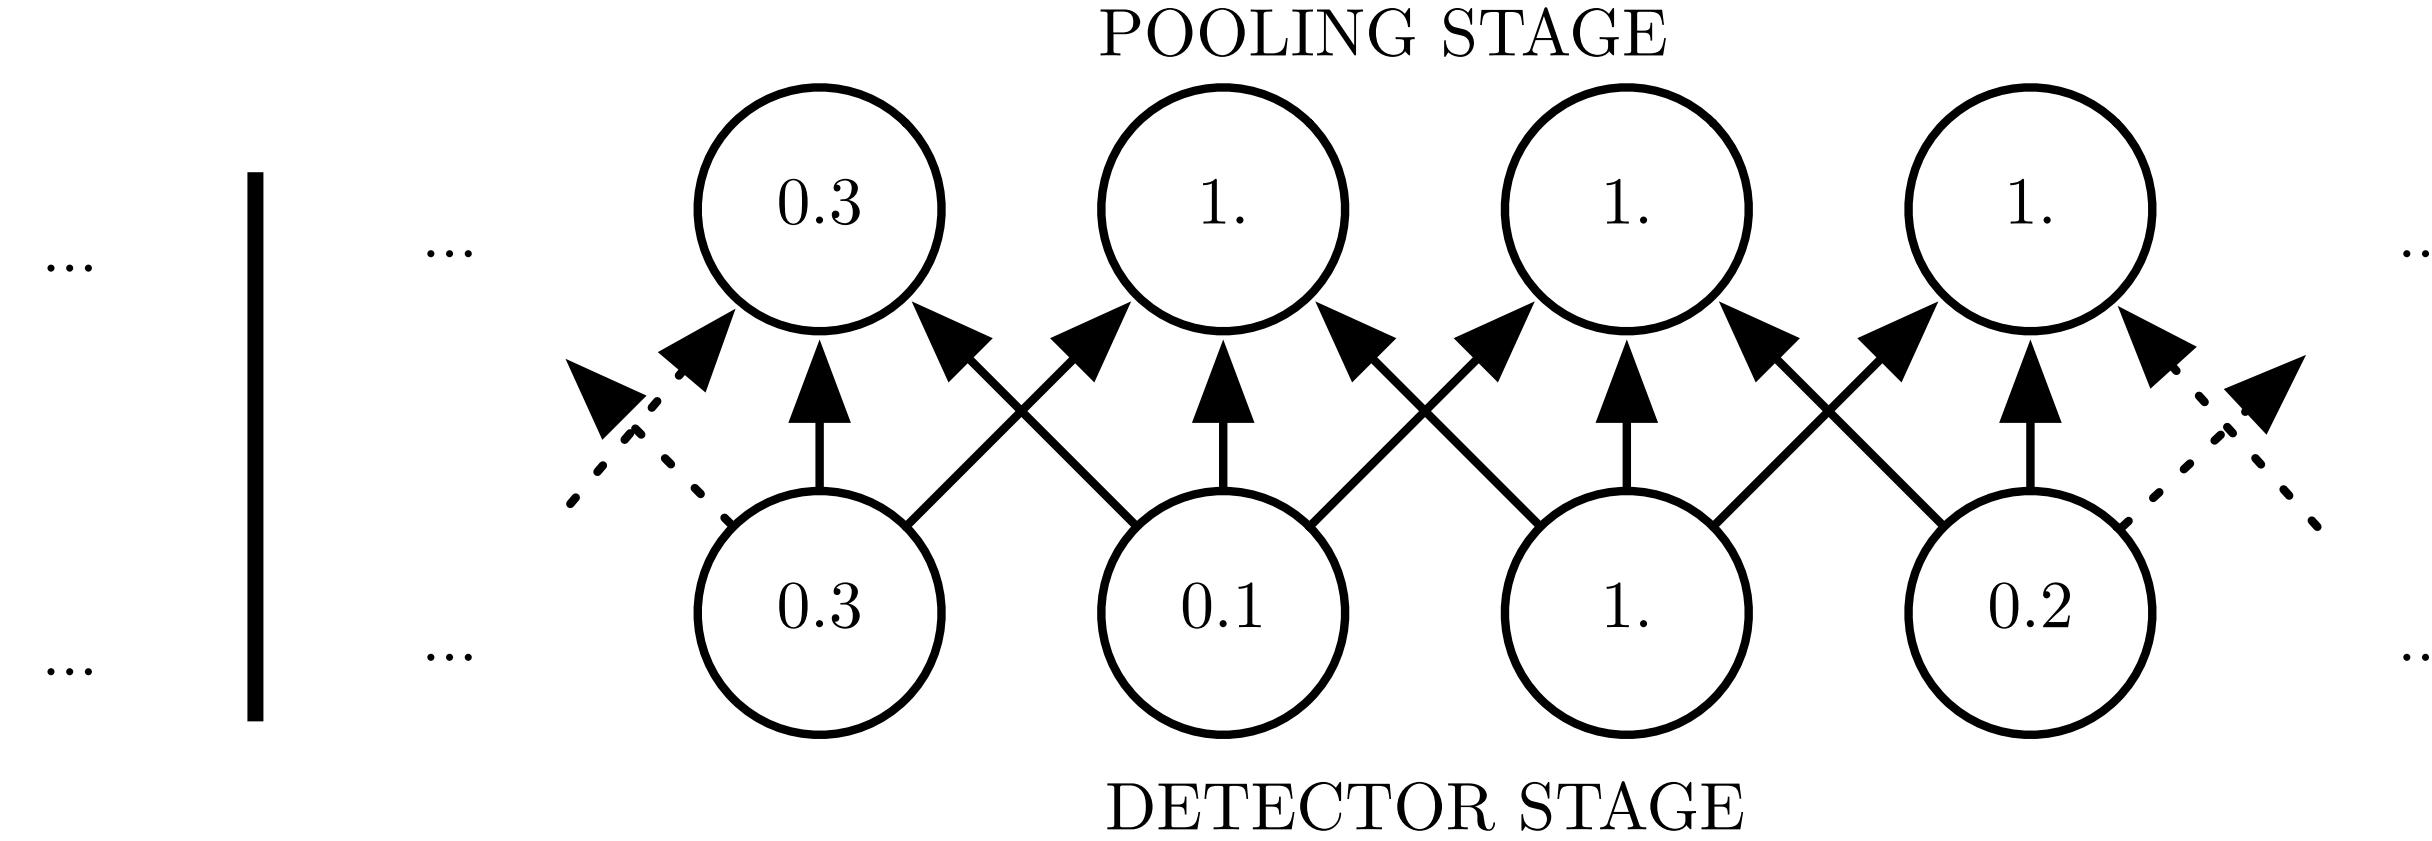
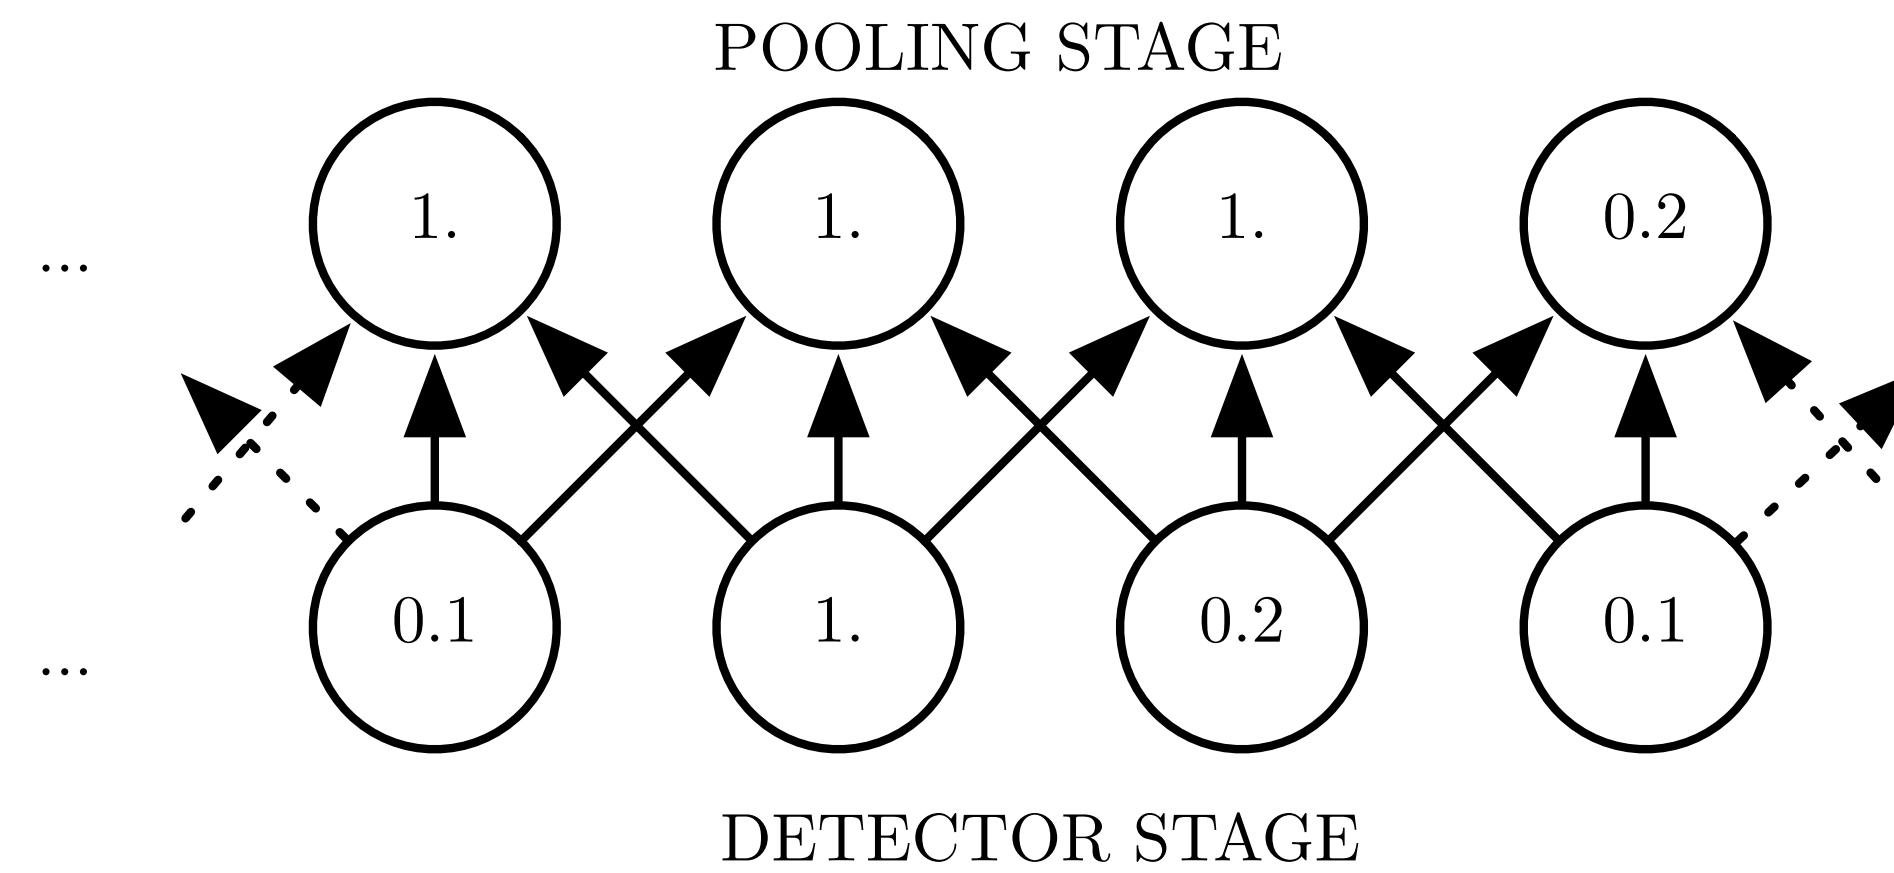
# Pooling

- Rend la représentation invariante à des petites translations de l'image d'entrée
  - “Pool” les valeurs des unités voisines (entrées)
  - E.g., max-pooling prend le max. de ses entrées.

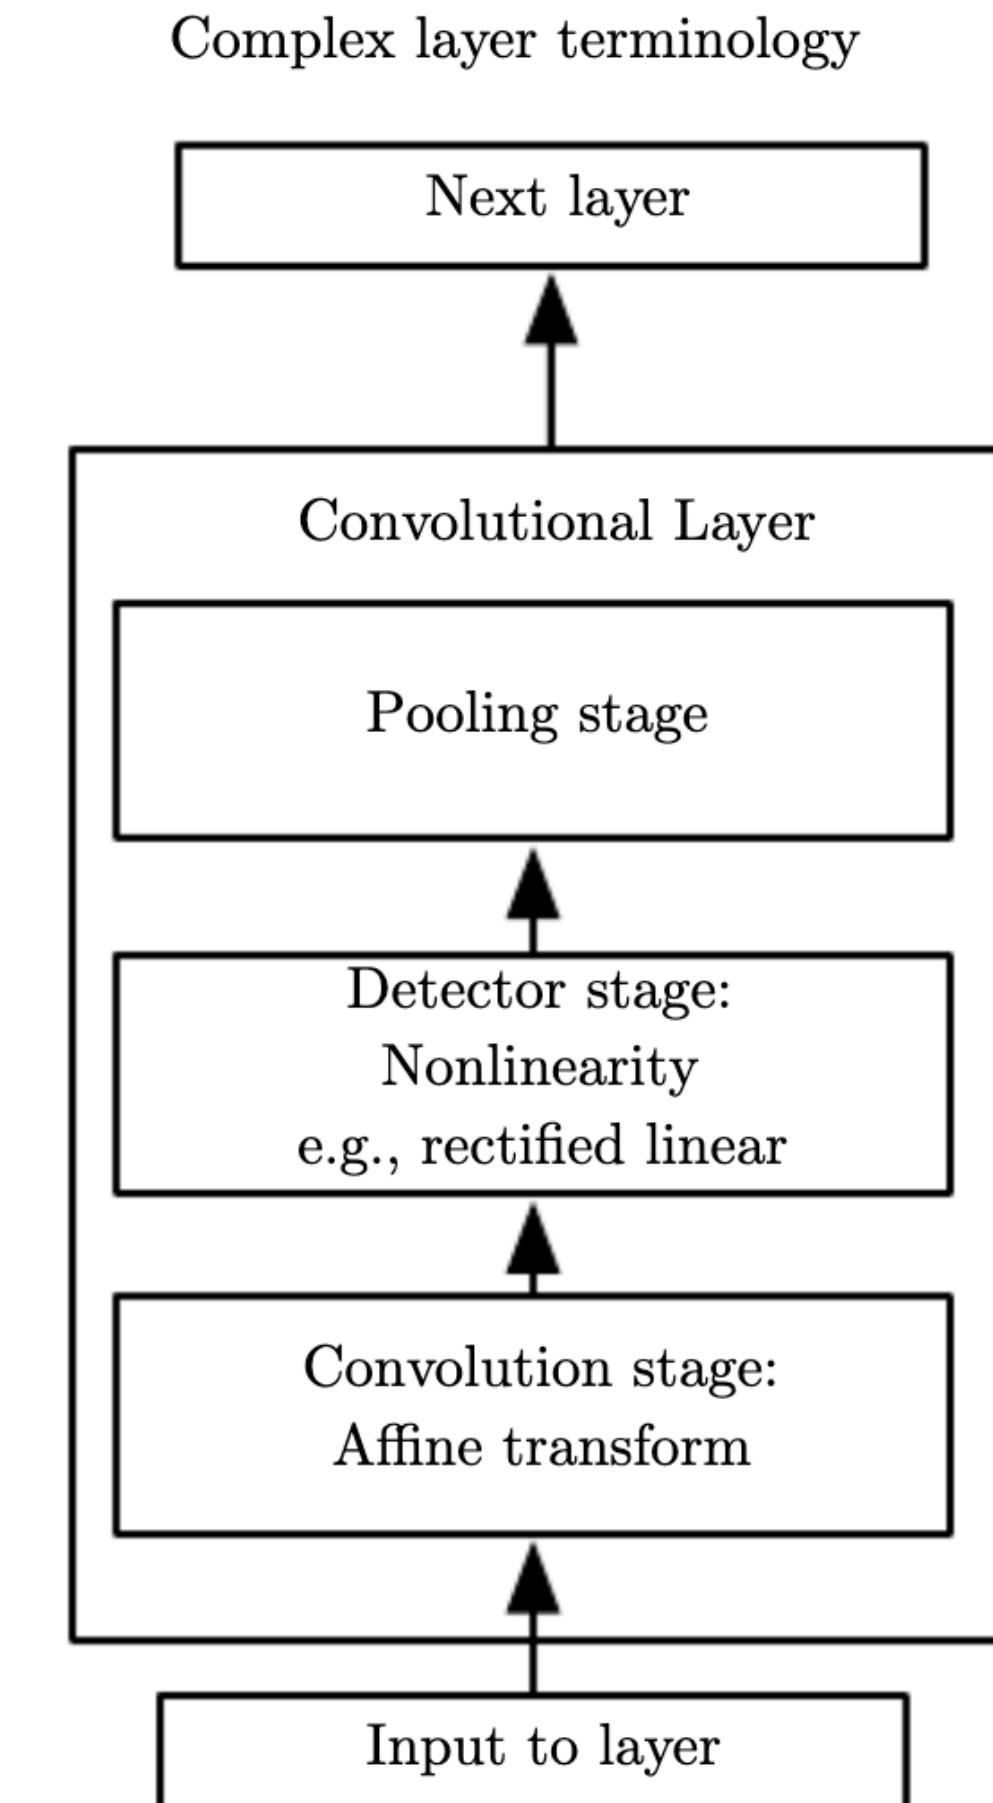


# Pooling

- Rend la représentation invariante à des petites translations de l'image d'entrée
  - “Pool” les valeurs des unités voisines (entrées)
  - E.g., max-pooling prend le max. de ses entrées.

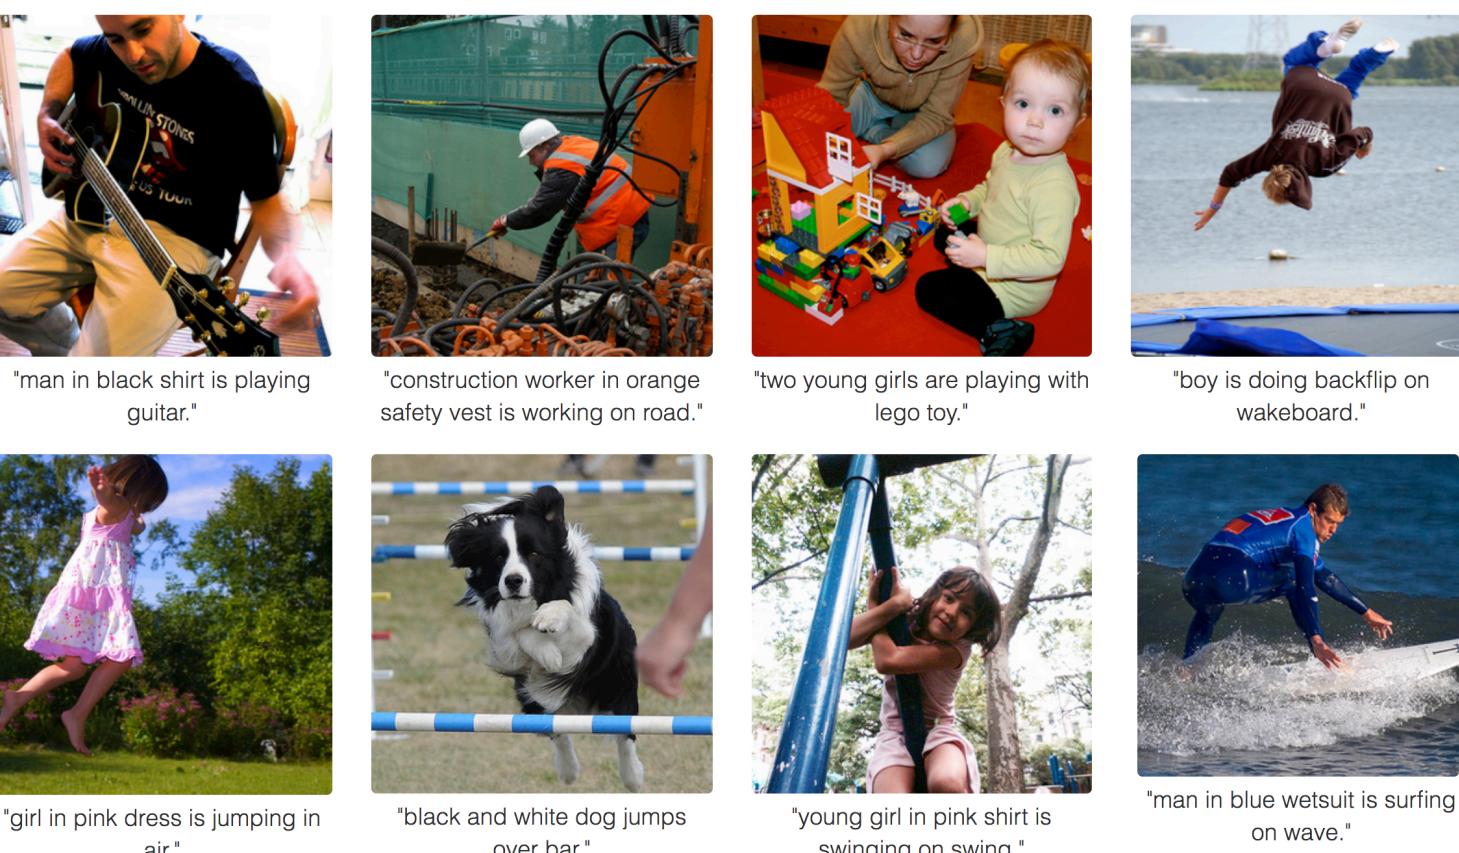


# Convolutions + non-linéarité + Pooling = Une couche cachée d'un CNN

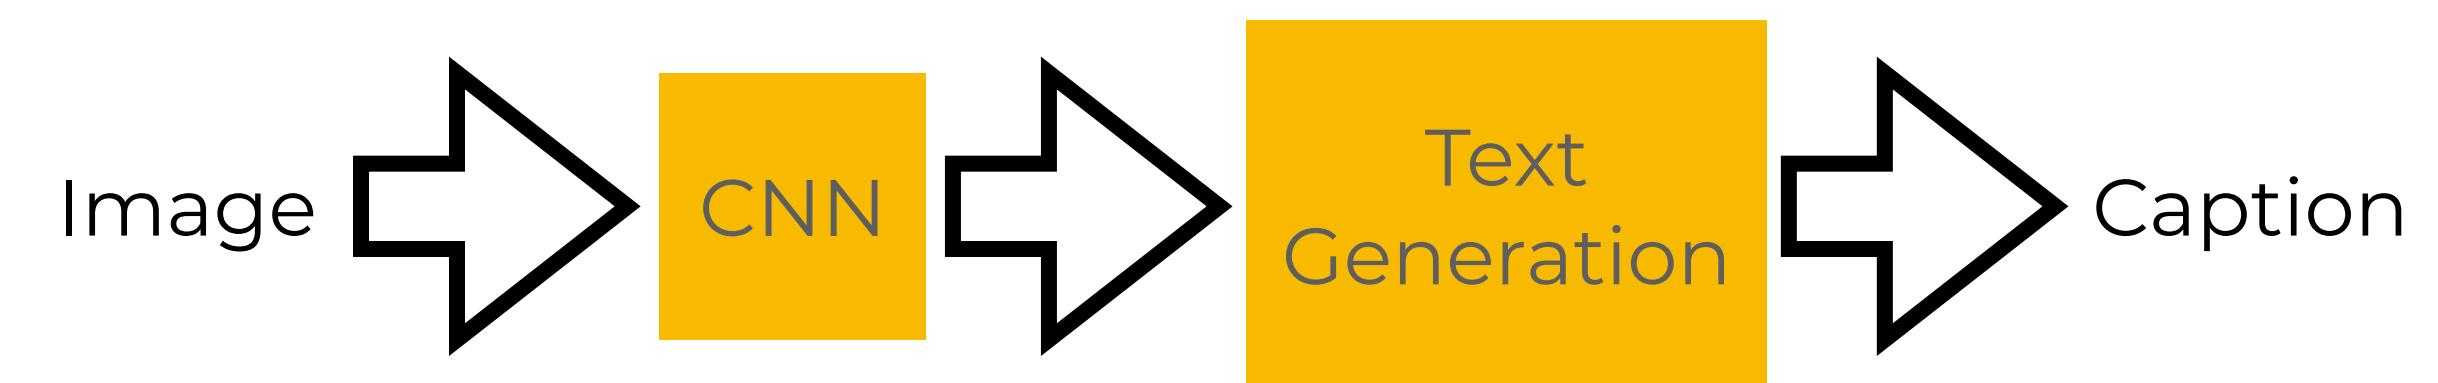


# Les CNNs et les RNNs peuvent être utilisés comme des modules dans de plus grands réseaux

- Description d'image



[<https://cs.stanford.edu/people/karpathy/cvpr2015.pdf>]



- Répondre à des questions se référant à des images

Is the umbrella upside down?

yes



no

