Bienvenue!

ÉCOLE D'HIVER FRANCOPHONE EN APPRENTISSAGE PROFOND

5 - 9 mars 2018

IVADO
HEC Montréal
Polytechnique Montréal
Université de Montréal

MILA

Institut
des algorithmes
d’apprentissage
de Montréal

Réseaux Récurrents I

Ecole d’hiver IVADO

César Laurent

Plan

1. **Motivation**
2. **Introduction aux Réseaux de Neurones Récurrents (RNNs)**
3. **Entraînement des RNNs**
4. **Difficultés d’apprentissage**
5. **Architectures de RNNs**
6. **RNNs Profonds**

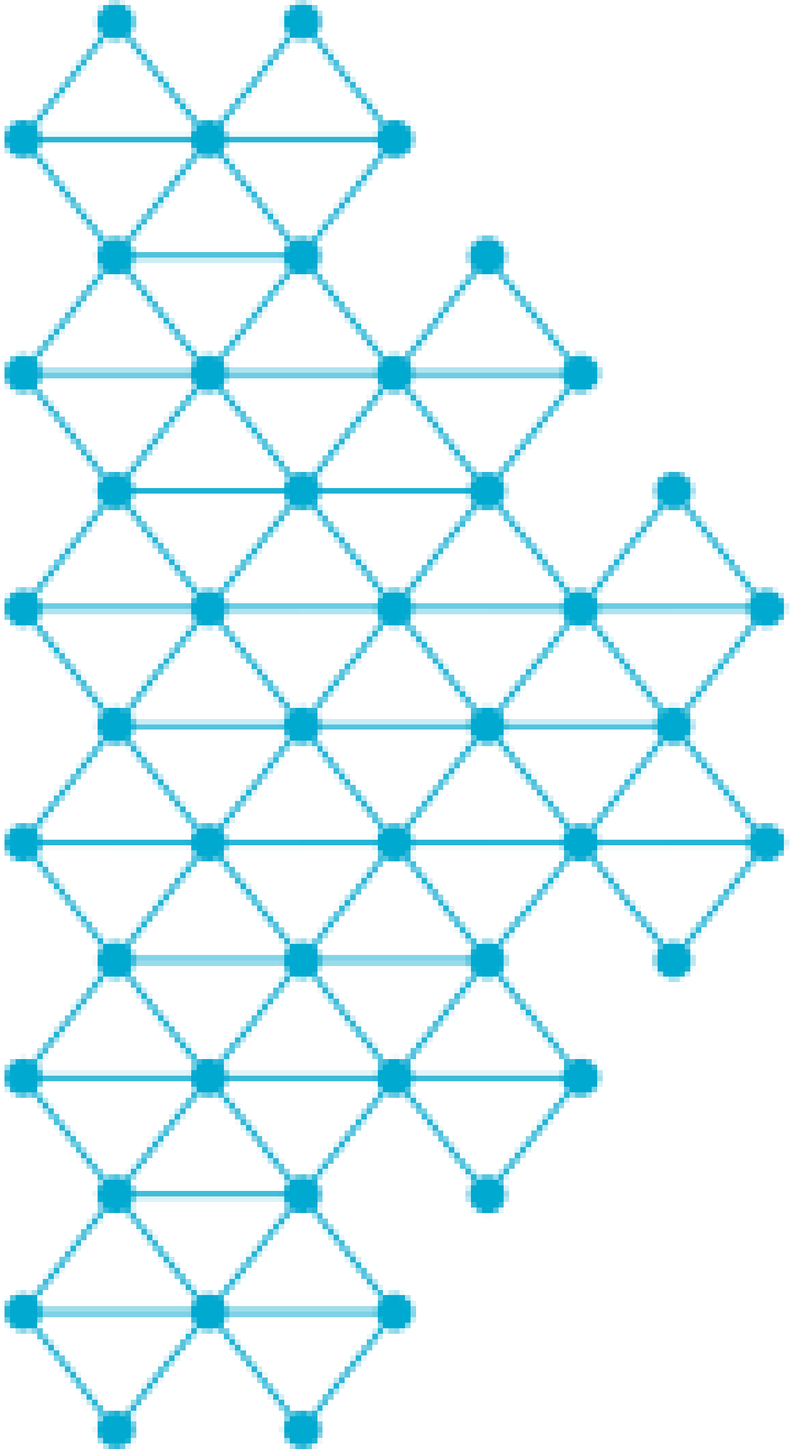

1. **Motivation**
2. **Introduction aux RNNs**
3. **Entraînement des RNNs**
4. **Difficultés d’apprentissage**
5. **Architectures de RNNs**
6. **RNNs Profonds**

Motivation

- Vous avez vu comment traîter des données de taille fixe et des images.

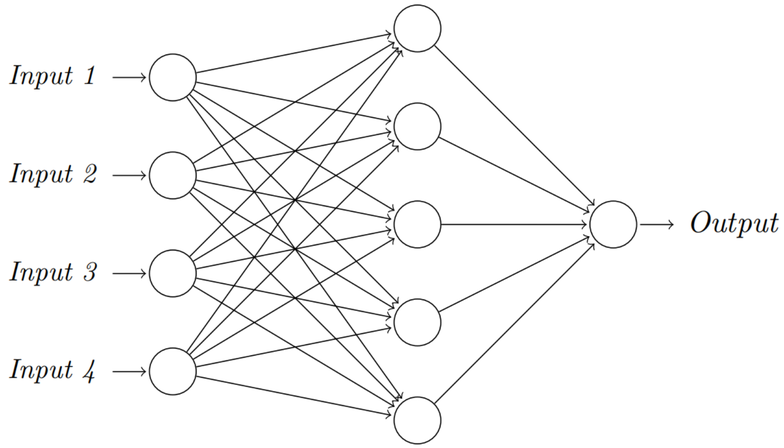

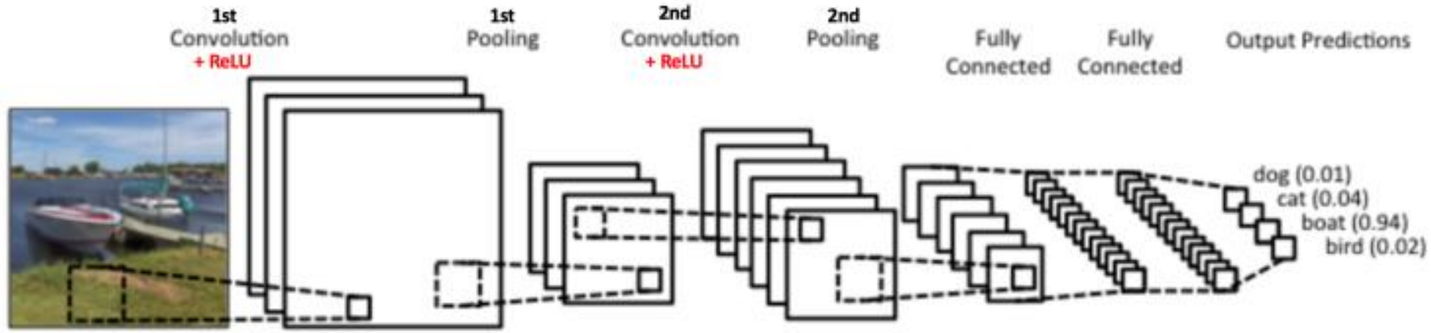

Comment traîter des **données de tailles variables**?

Image: https://ujjwalkarn.me/2016/08/11/intuitive-explanation-convnets

Motivation

Reconnaissance de la parole

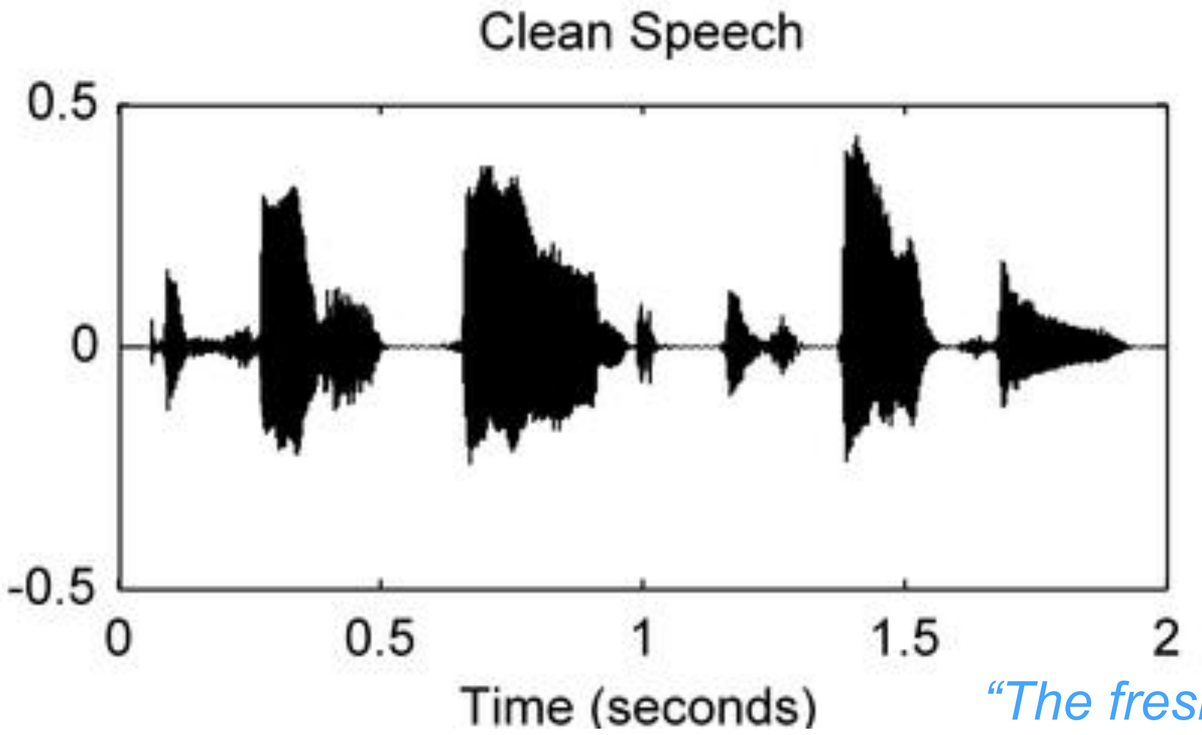

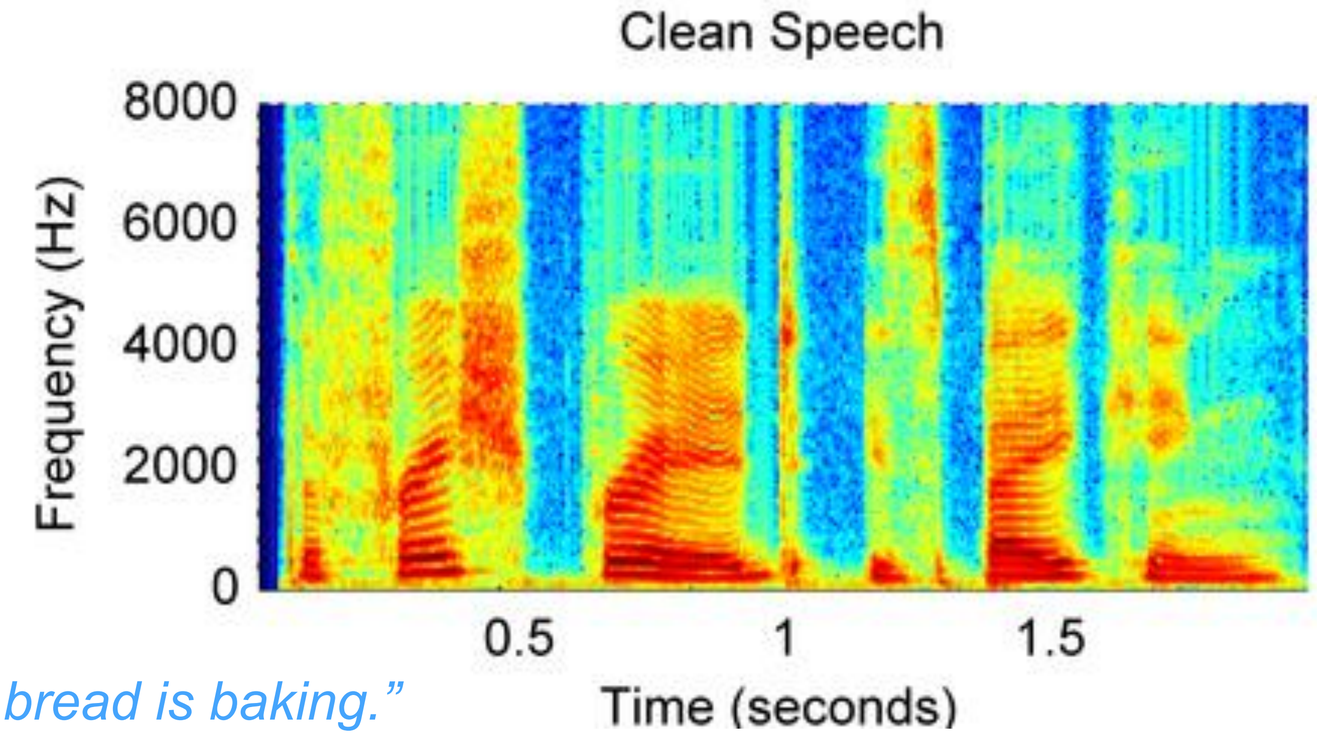

“The fresh bread is baking.”

Reconnaissance de la parole: Séquence audio → Séquence de mots.

Images: Ye et al., *A Wavelet-Based Noise Reduction Algorithm and Its Clinical Evaluation in Cochlear Implants*

Motivation

Traduction automatique

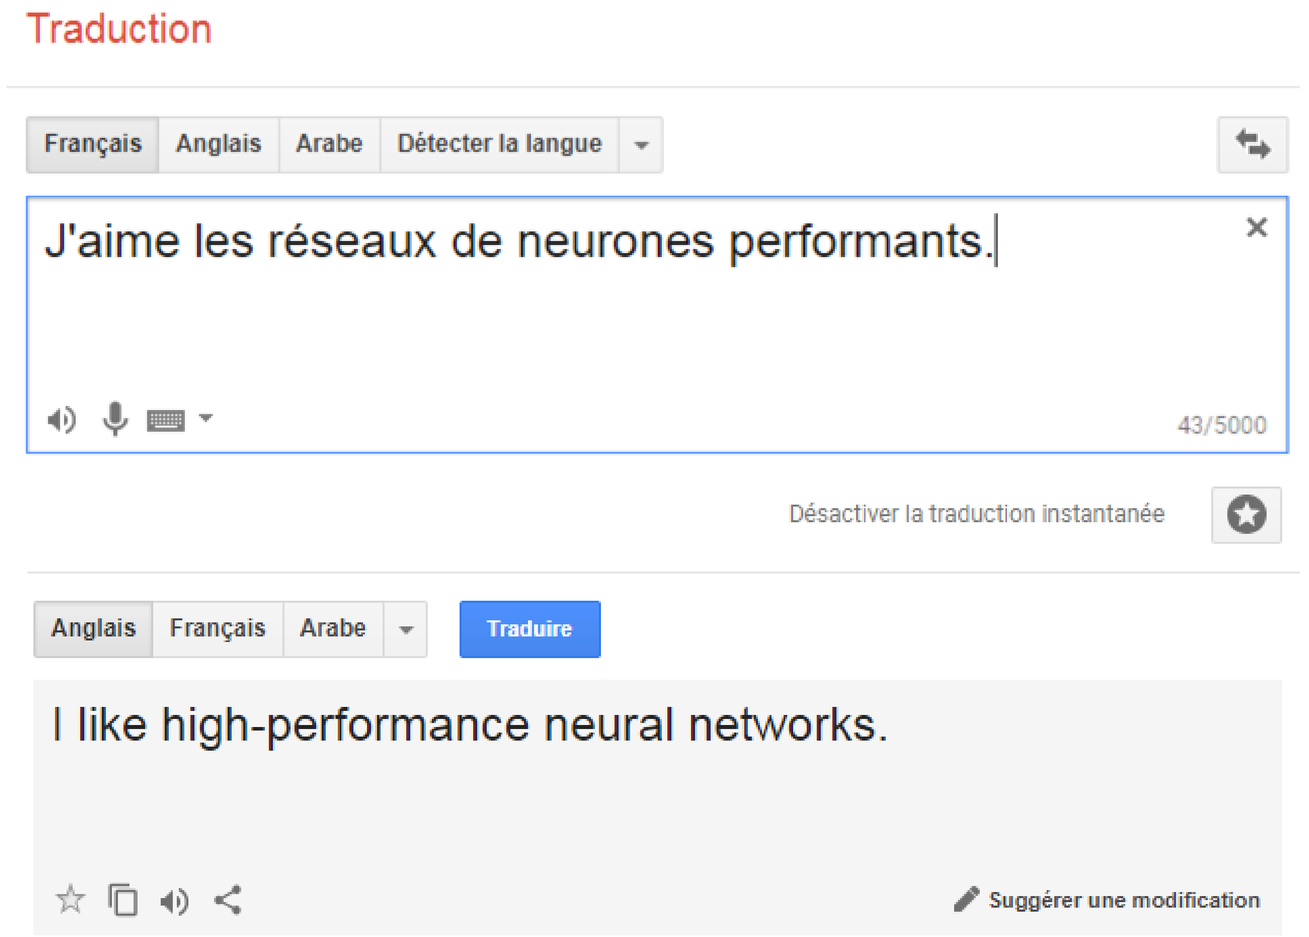

Traduction: Séquence de mots → Séquence de mots.

Motivation

Génération de légendes

A woman is throwing a frisbee in a park.

A giraffe standing in a forest with trees in the background.

Génération de légendes: Image → Séquence de mots.

Images: Xu et al., *Show, Attend and Tell: Neural Image Caption Generation with Visual Attention*

Motivation

Plus d'exemples de données séquentielles

- Audio:
  - Reconnaissance de la parole
  - Génération de parole
- Vidéos:
  - Génération de légende
  - Reconnaissance d'actions
- Textes:
  - Classification d'e-mails
  - Traduction automatique
- Données biologiques et médicales:
  - Etude de l'ADN
  - IRM fonctionnels
  - Electrocardiogramme
- Séries financières
- Etc…

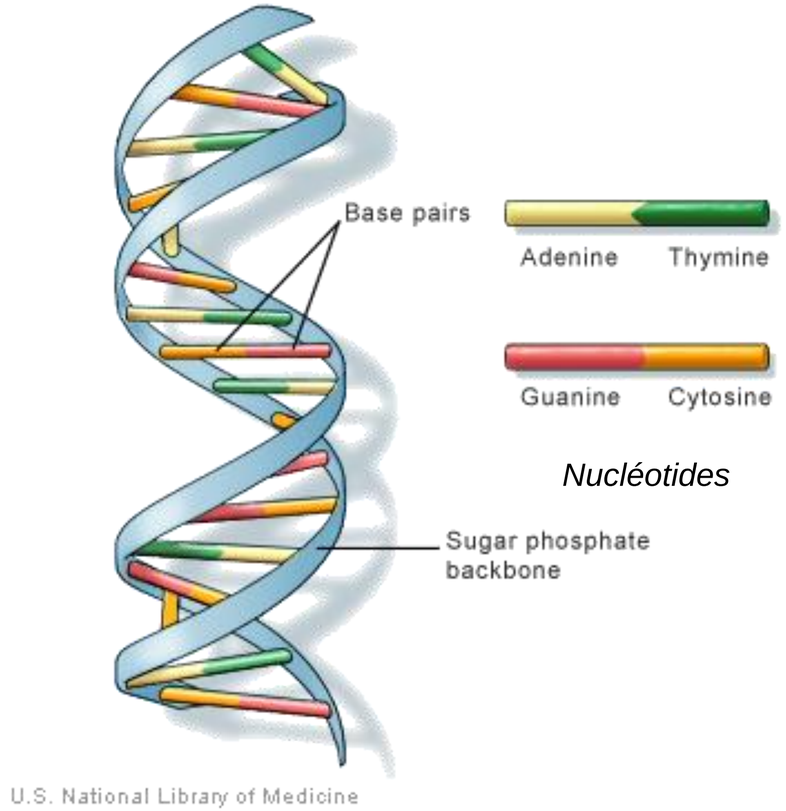

Il existe énormément de données de tailles variables!

Modélisation de séquences

Différents types d'applications

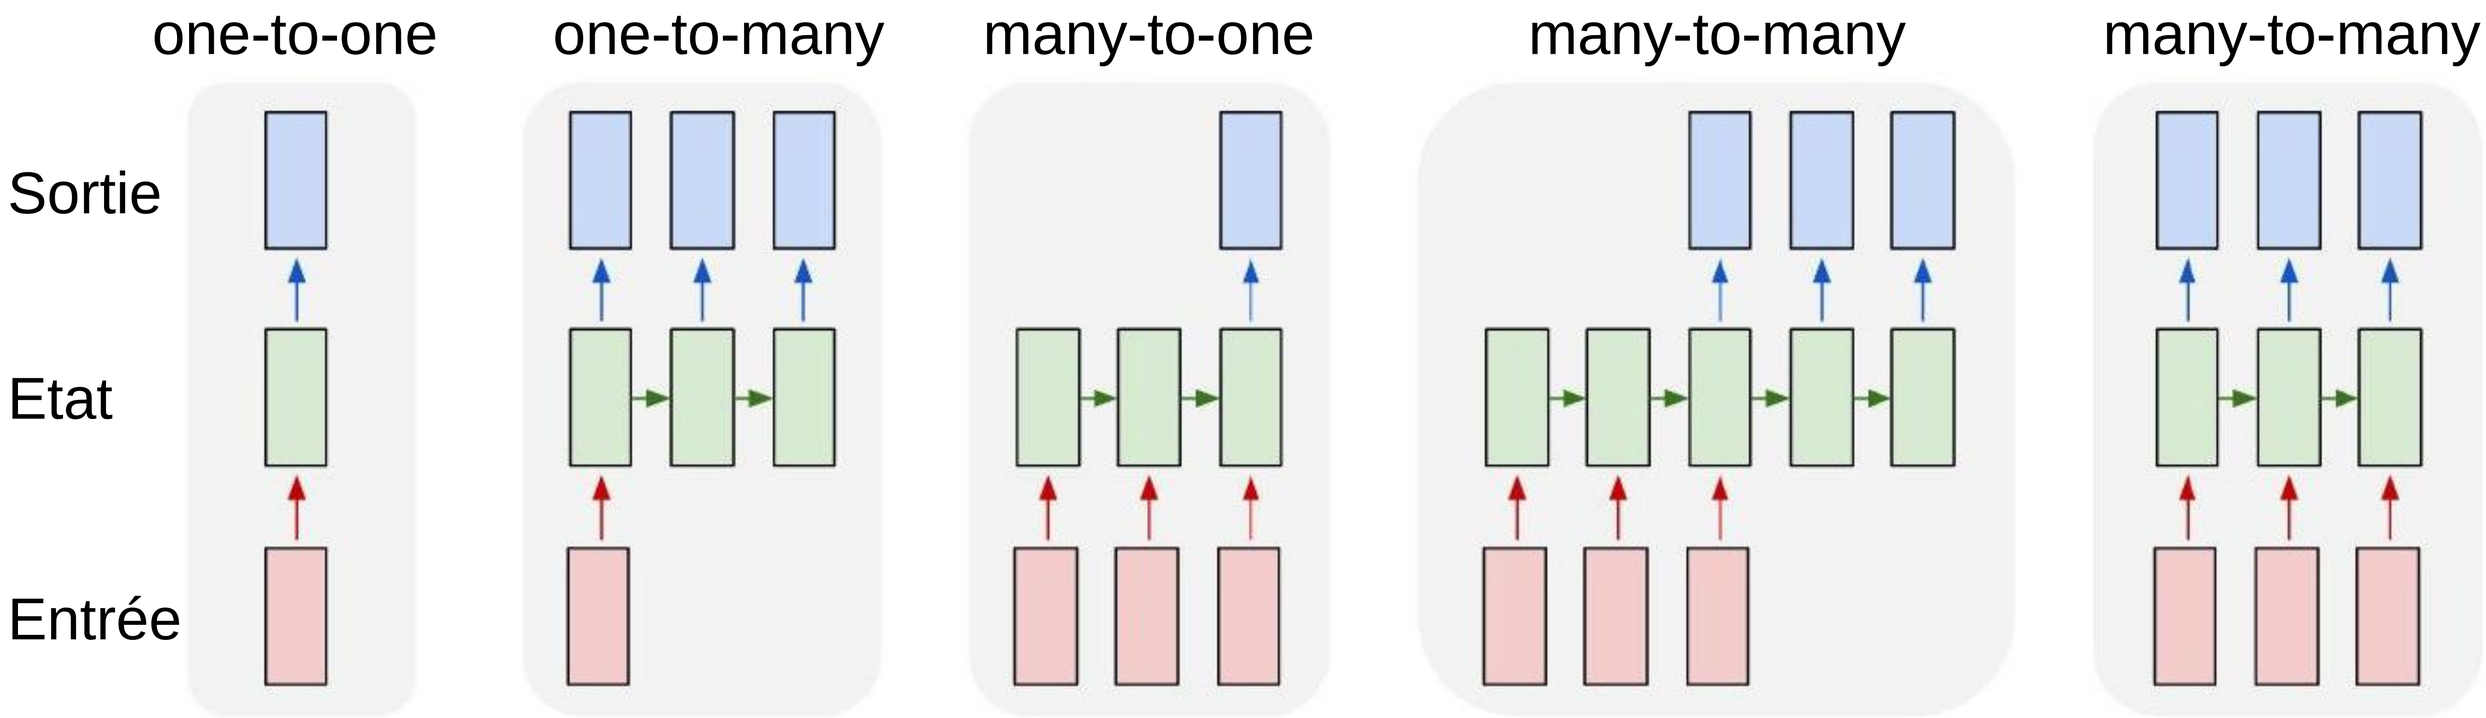

Tiré de http://vision.stanford.edu/teaching/cs231n/slides/2016/winter1516_lecture10.pdf

Modélisation de séquences

Différents types d'applications

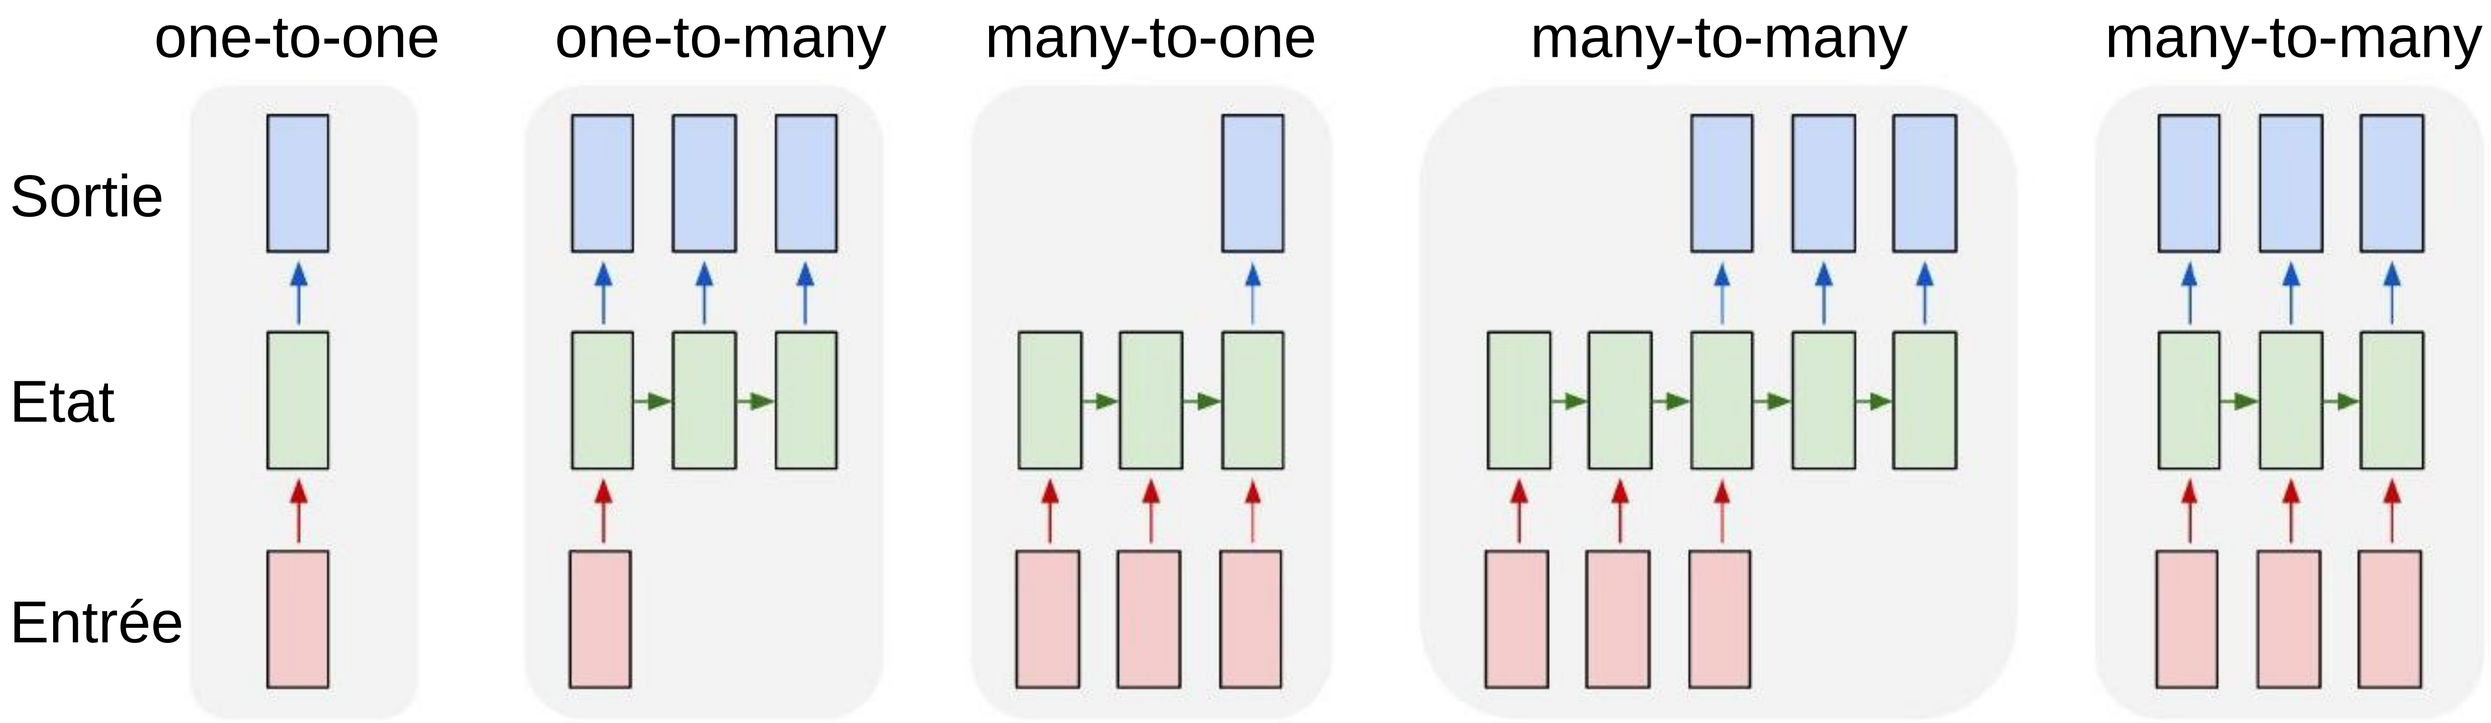

Classification d'objets

(Image → Classe)

Tiré de http://vision.stanford.edu/teaching/cs231n/slides/2016/winter1516_lecture10.pdf

Modélisation de séquences

Différents types d'applications

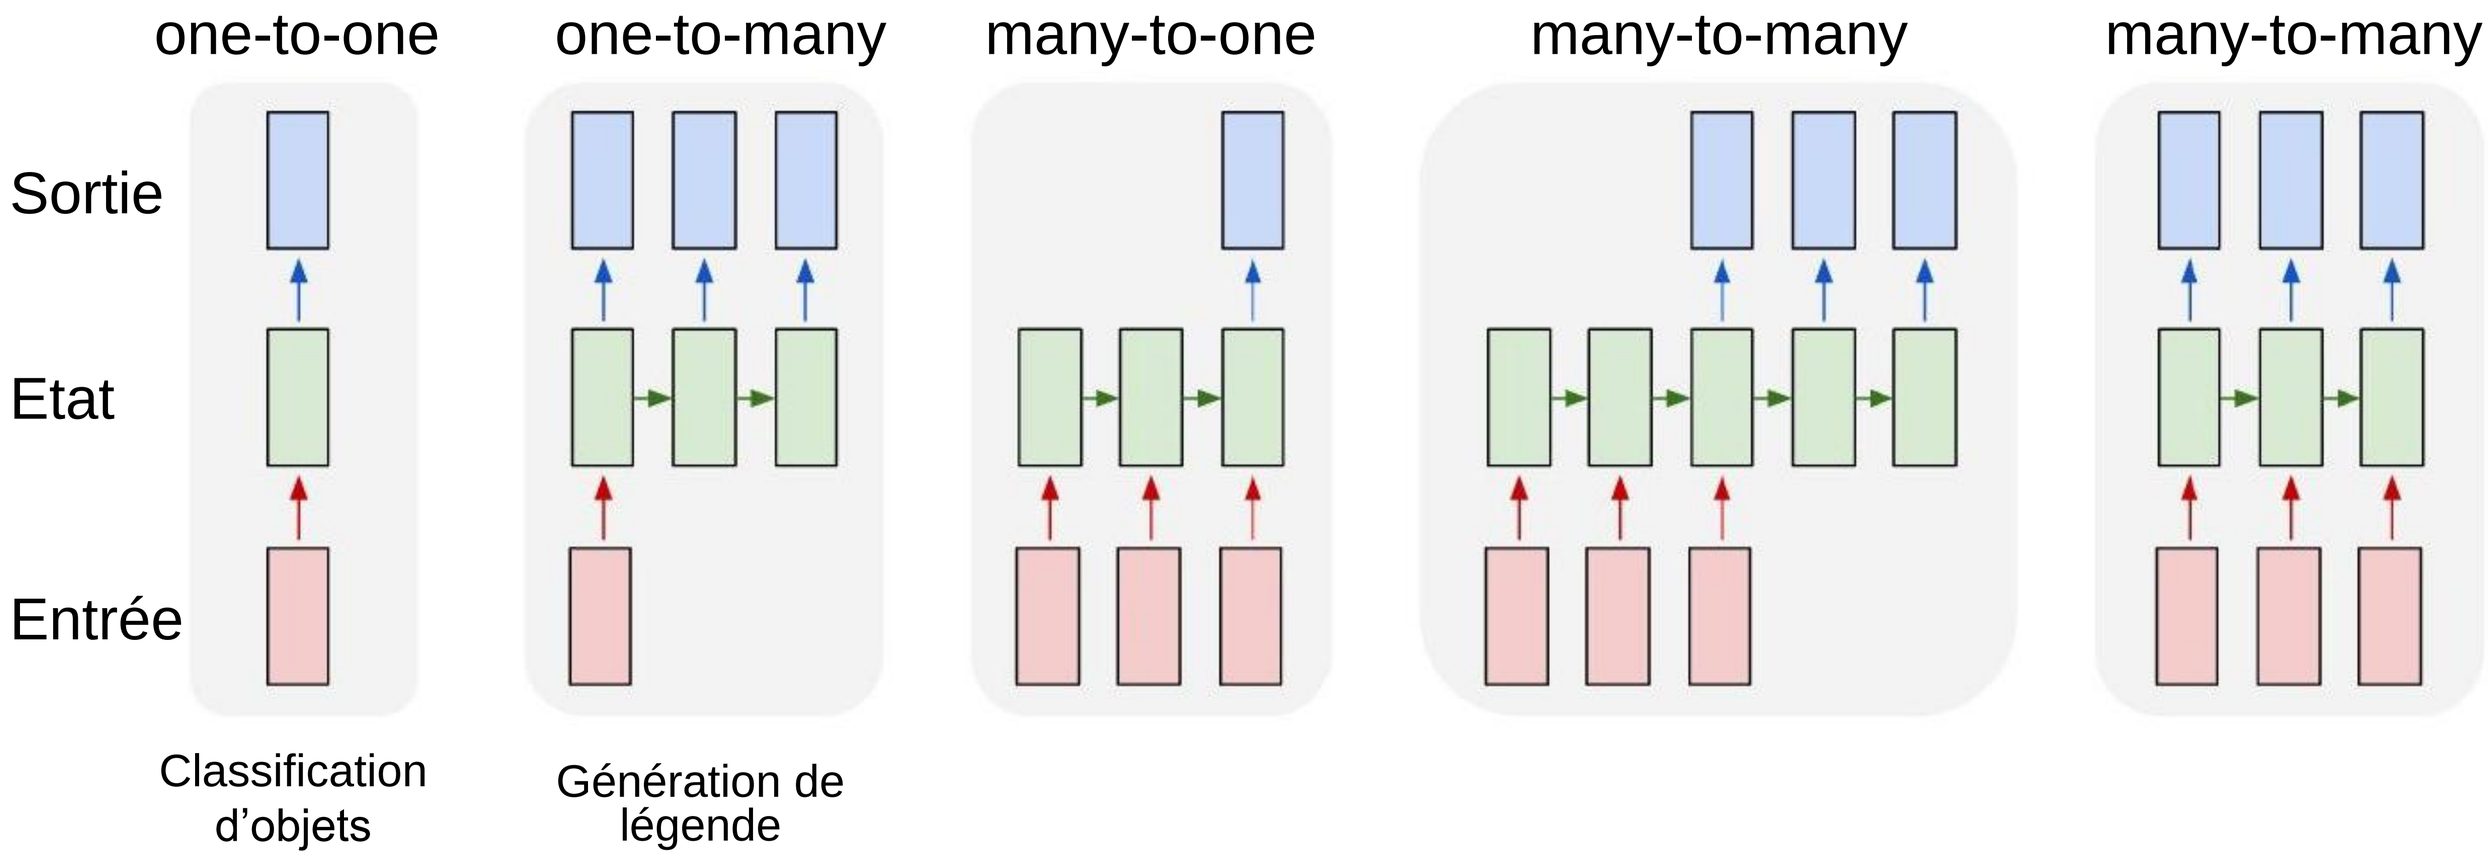

Tiré de http://vision.stanford.edu/teaching/cs231n/slides/2016/winter1516_lecture10.pdf

Modélisation de séquences

Différents types d'applications

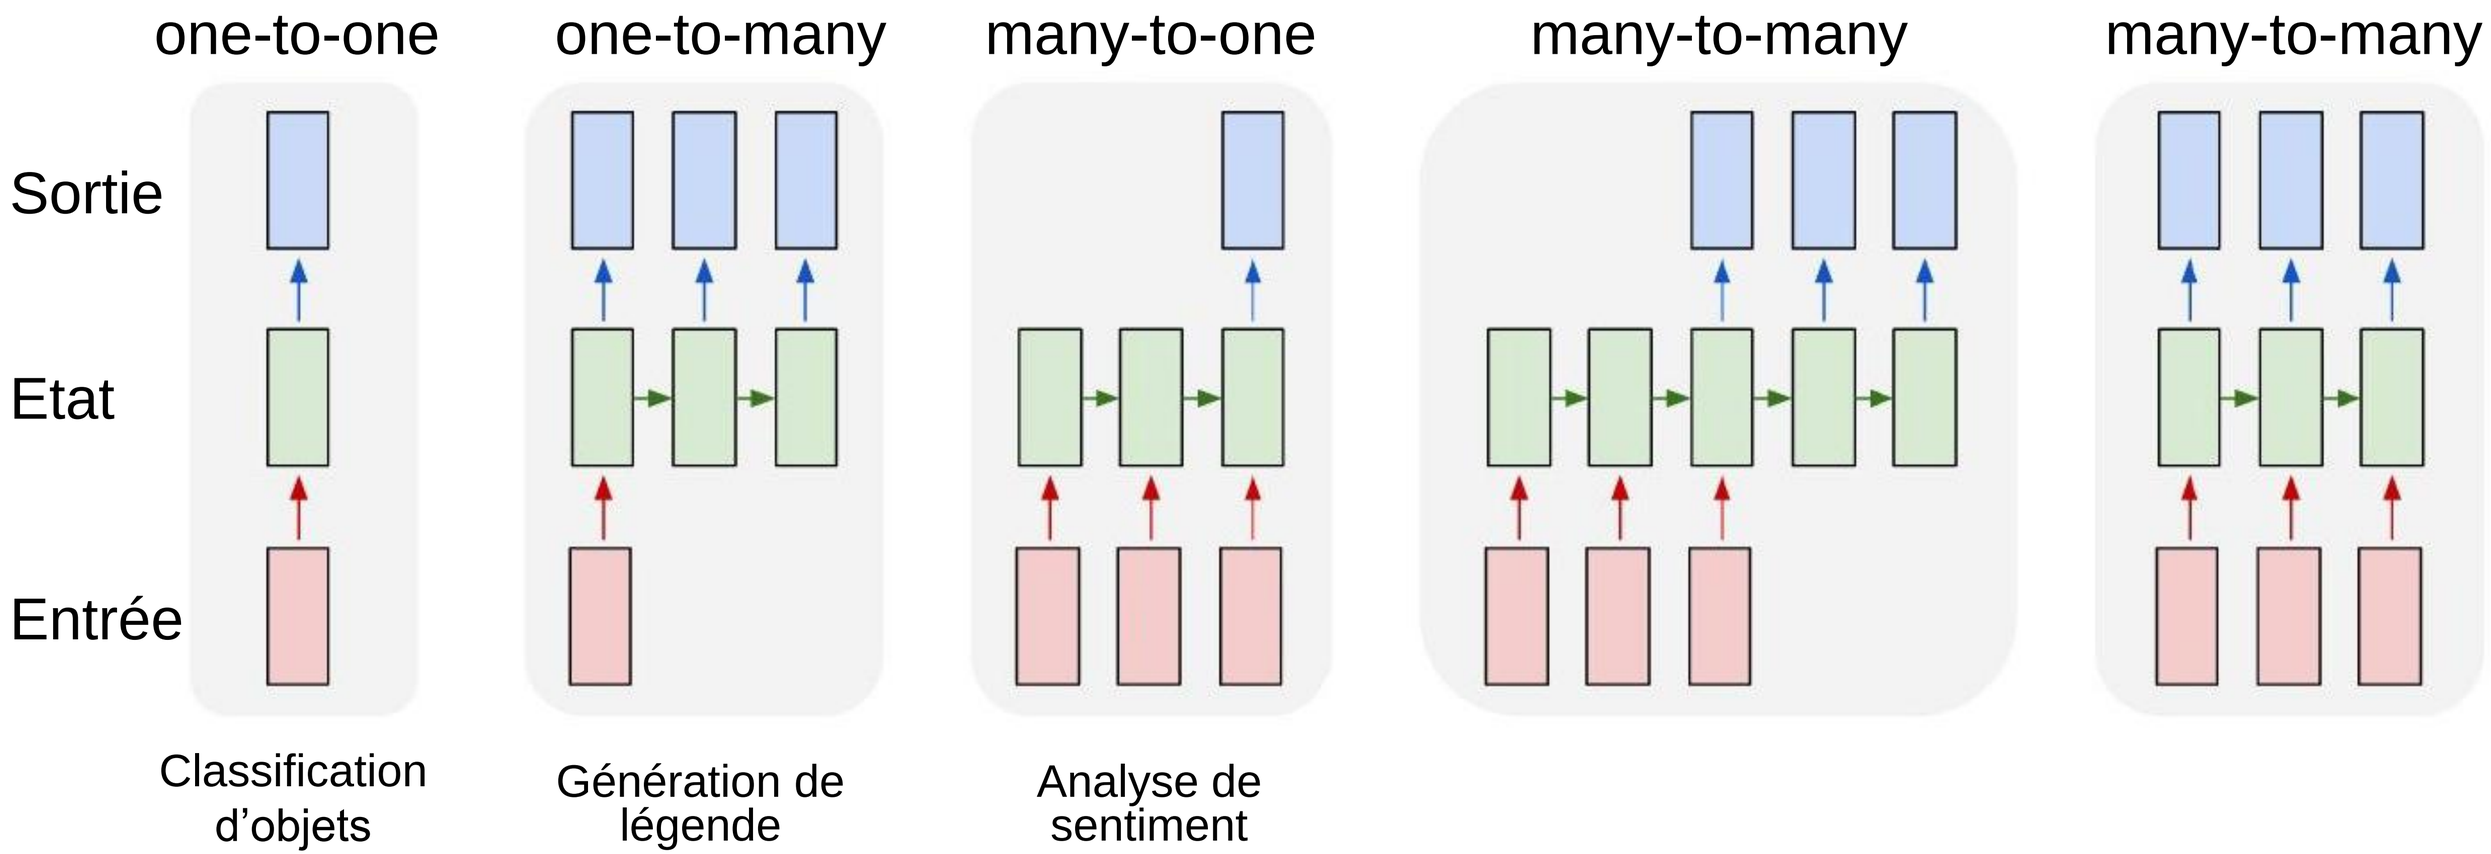

Tiré de http://vision.stanford.edu/teaching/cs231n/slides/2016/winter1516_lecture10.pdf

Modélisation de séquences

Différents types d'applications

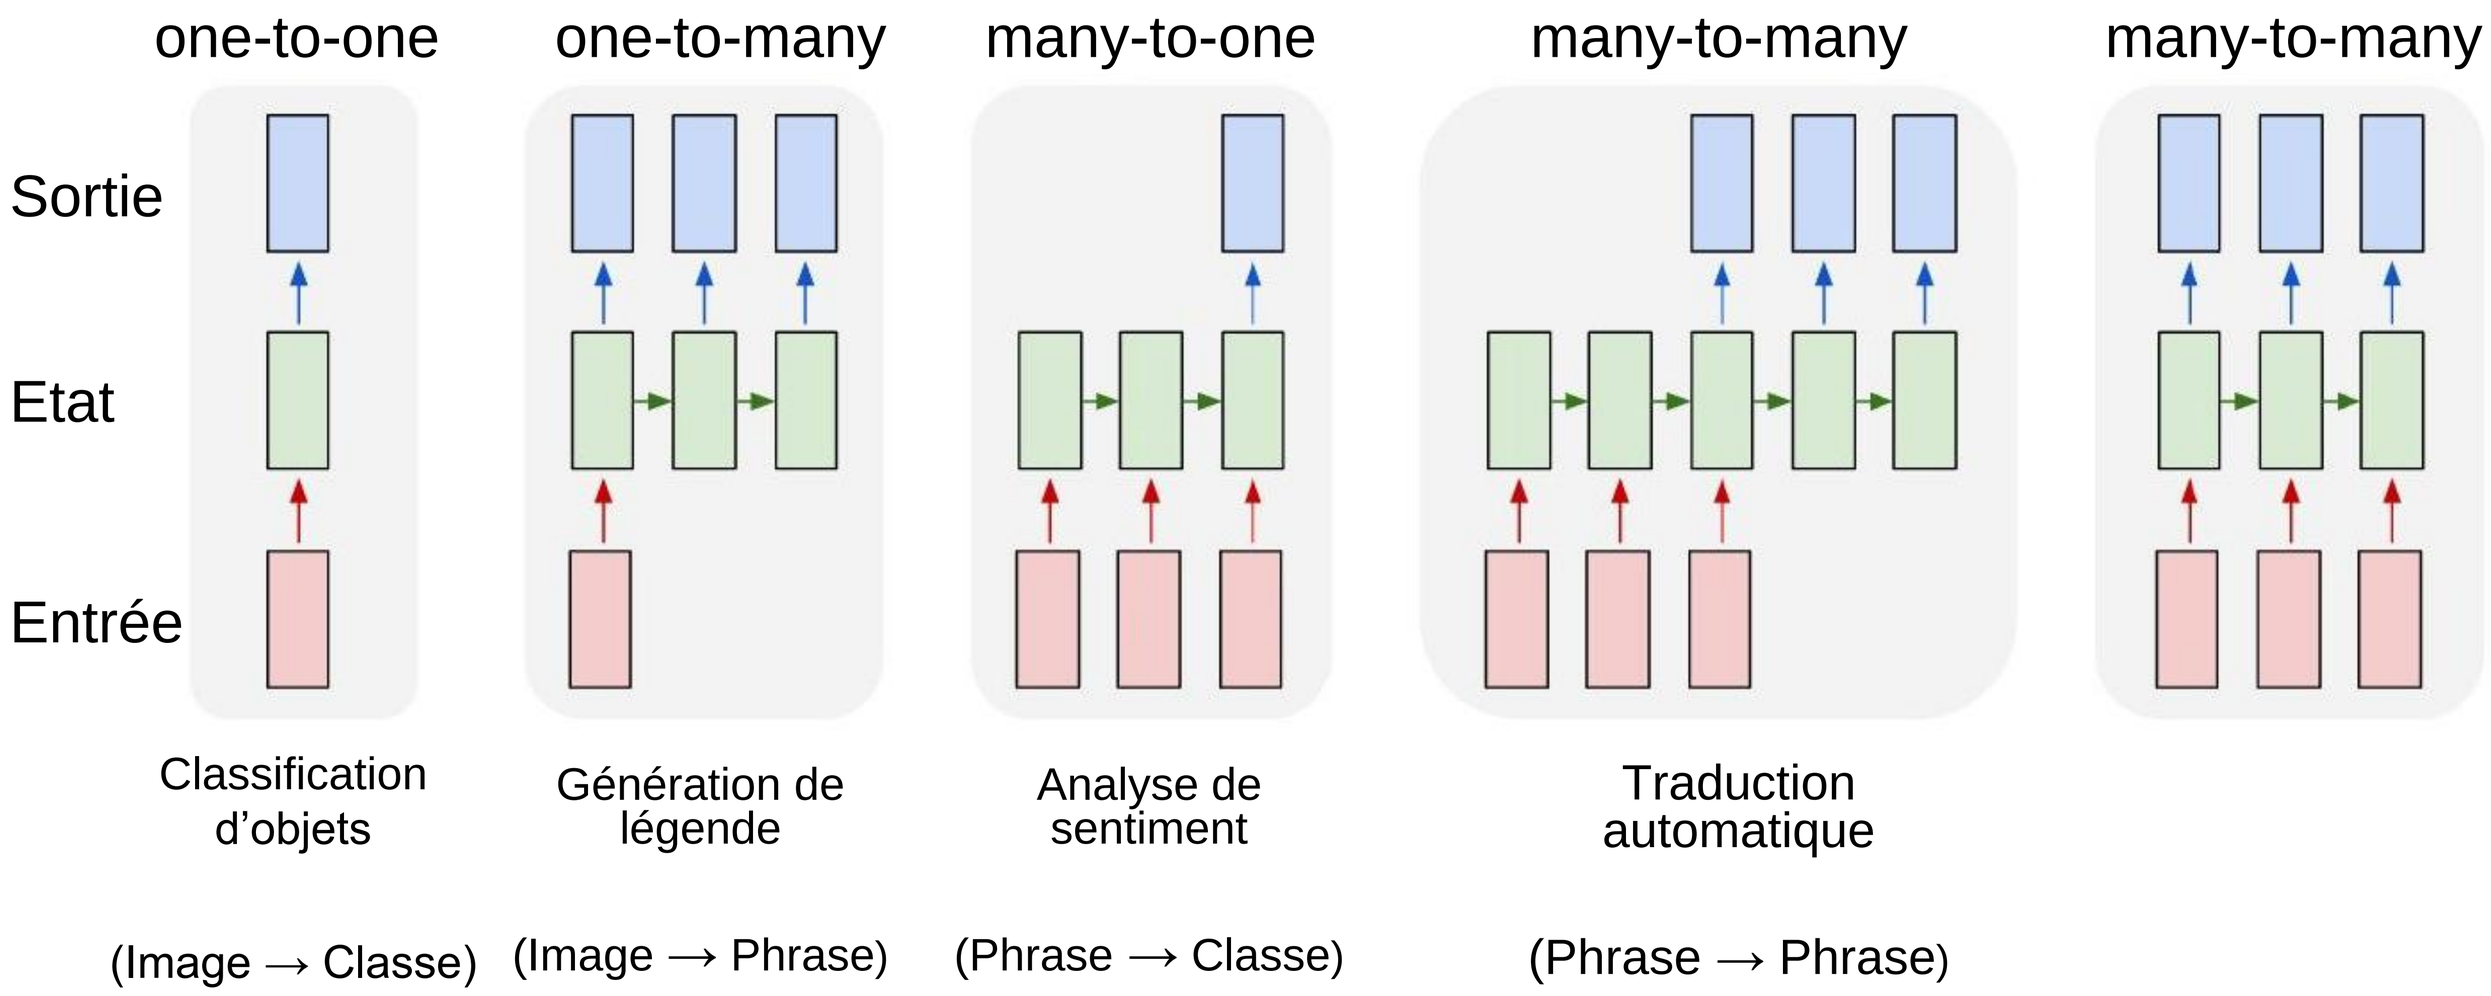

Tiré de http://vision.stanford.edu/teaching/cs231n/slides/2016/winter1516_lecture10.pdf

Modélisation de séquences

Différents types d'applications

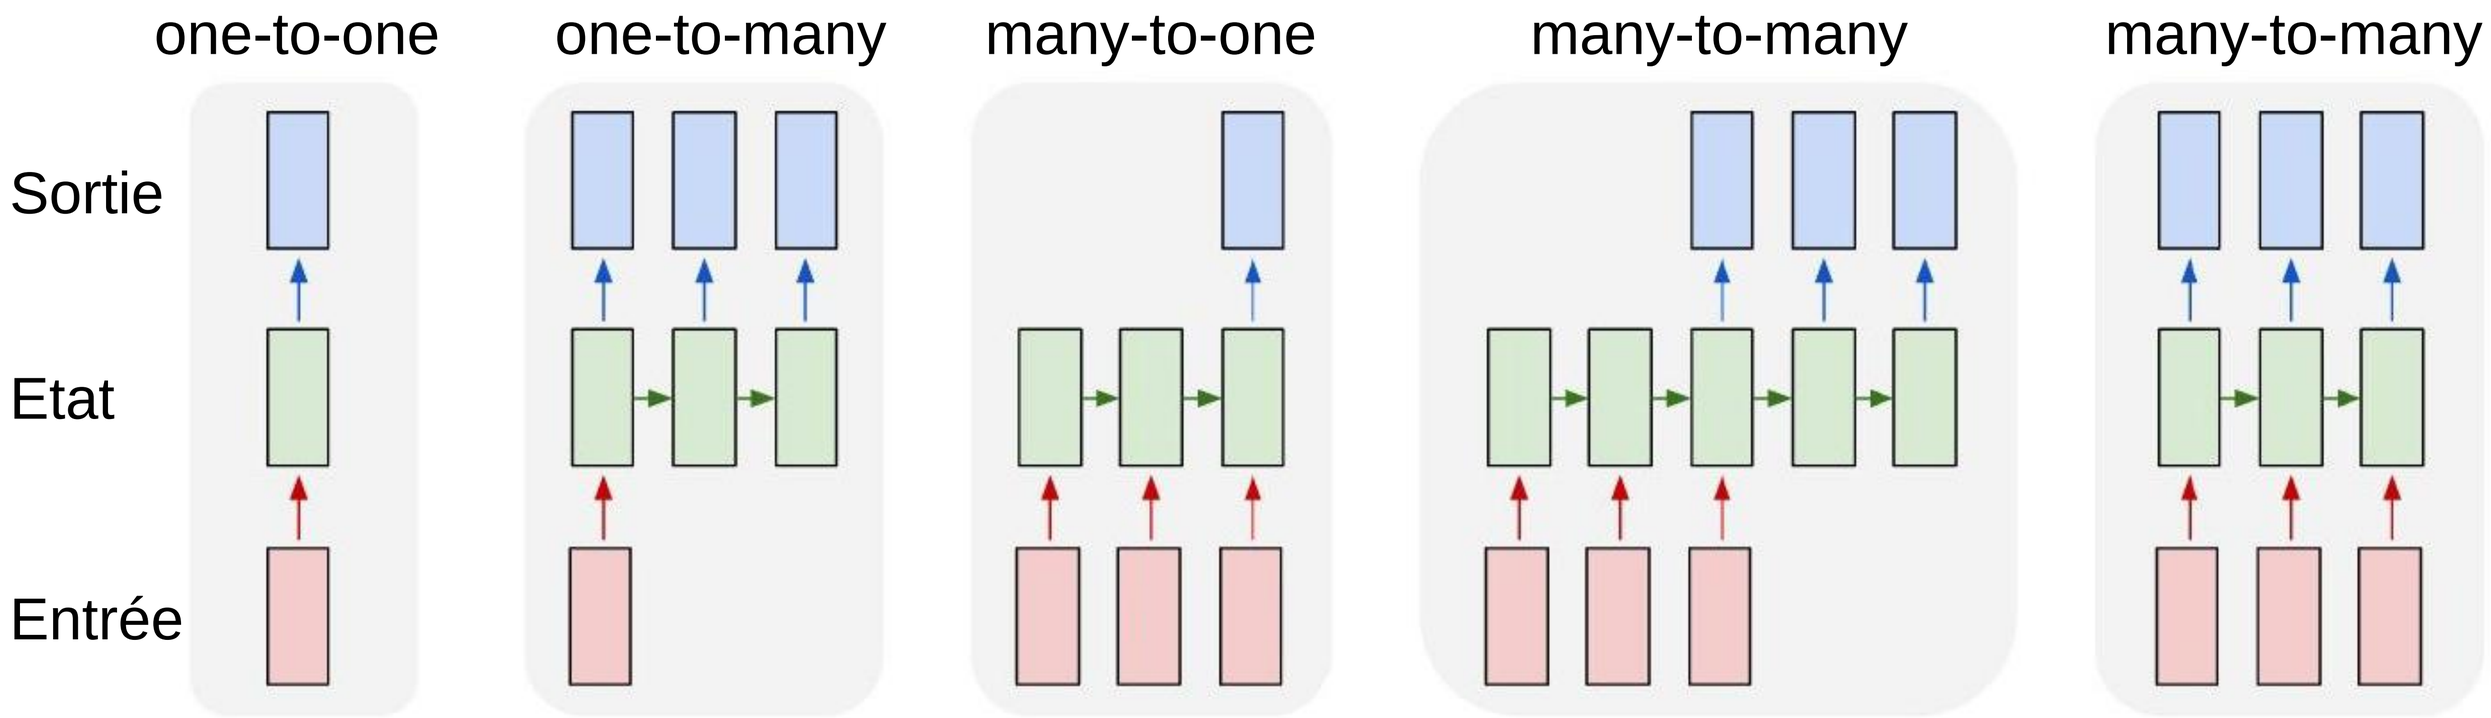

Tiré de http://vision.stanford.edu/teaching/cs231n/slides/2016/winter1516_lecture10.pdf

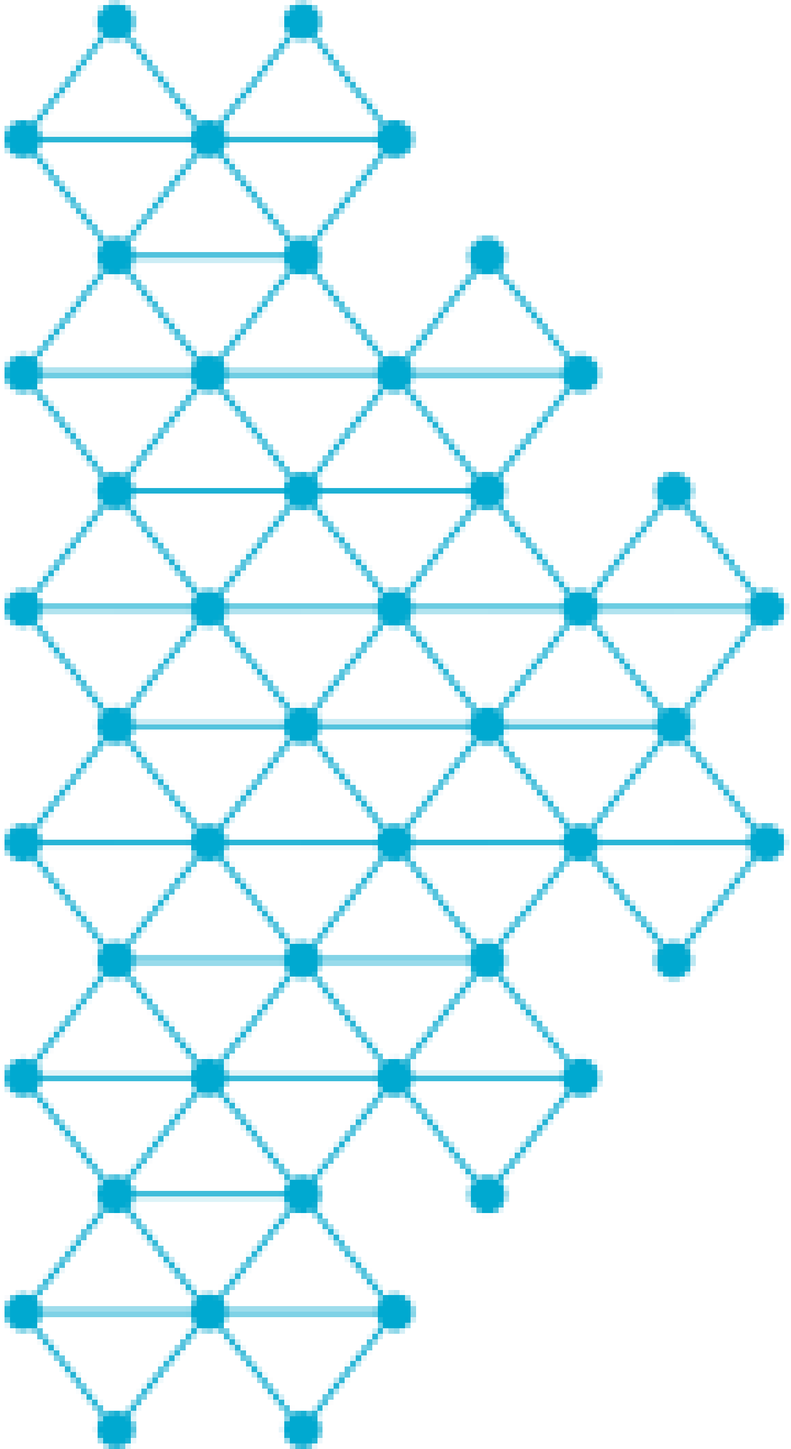

1. Motivation
2. Introduction aux RNNs
3. Entraînement des RNNs
4. Difficultés d’apprentissage
5. Architectures de RNNs
6. RNNs Profonds

Réseaux Récurrents

Introduction

Un RNN applique une fonction à une **séquence d'entrée** $[x_1, x_2, \ldots, x_T]$, pour produire une **séquence de sortie** $[y_1, y_2, \ldots, y_T]$, en maintenant un **état interne** $[h_1, h_2, \ldots, h_T]$.

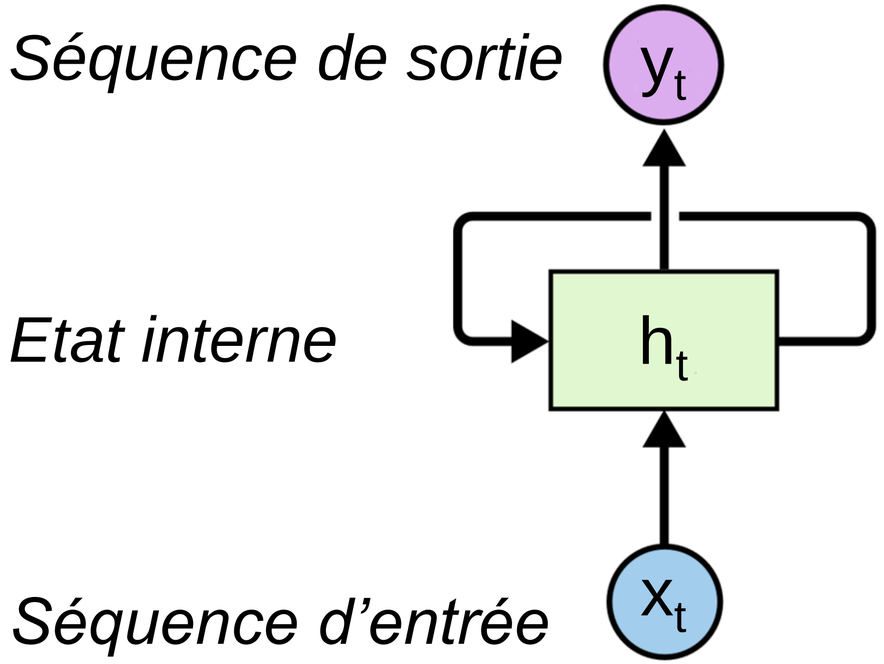

Image from Christopher Olah's blog

Réseaux Récurrents

Le RNN basique (Tanh-RNN; Simple RNN; Elman RNN)

- La version la plus simple:

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

- W, U et V sont les paramètres du réseau.
  - Ils sont **partagés** à travers le temps.
- h_{-1} peut également être un paramètre.

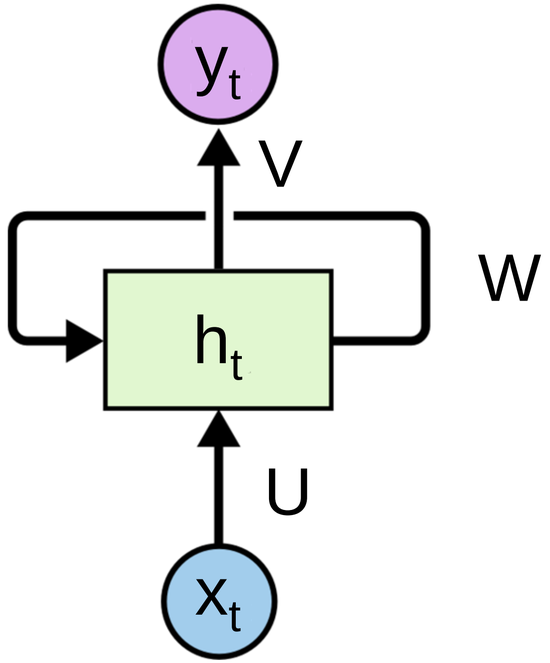

Image from Christopher Olah's blog

Réseaux Récurrents

Exemple déroulé dans le temps

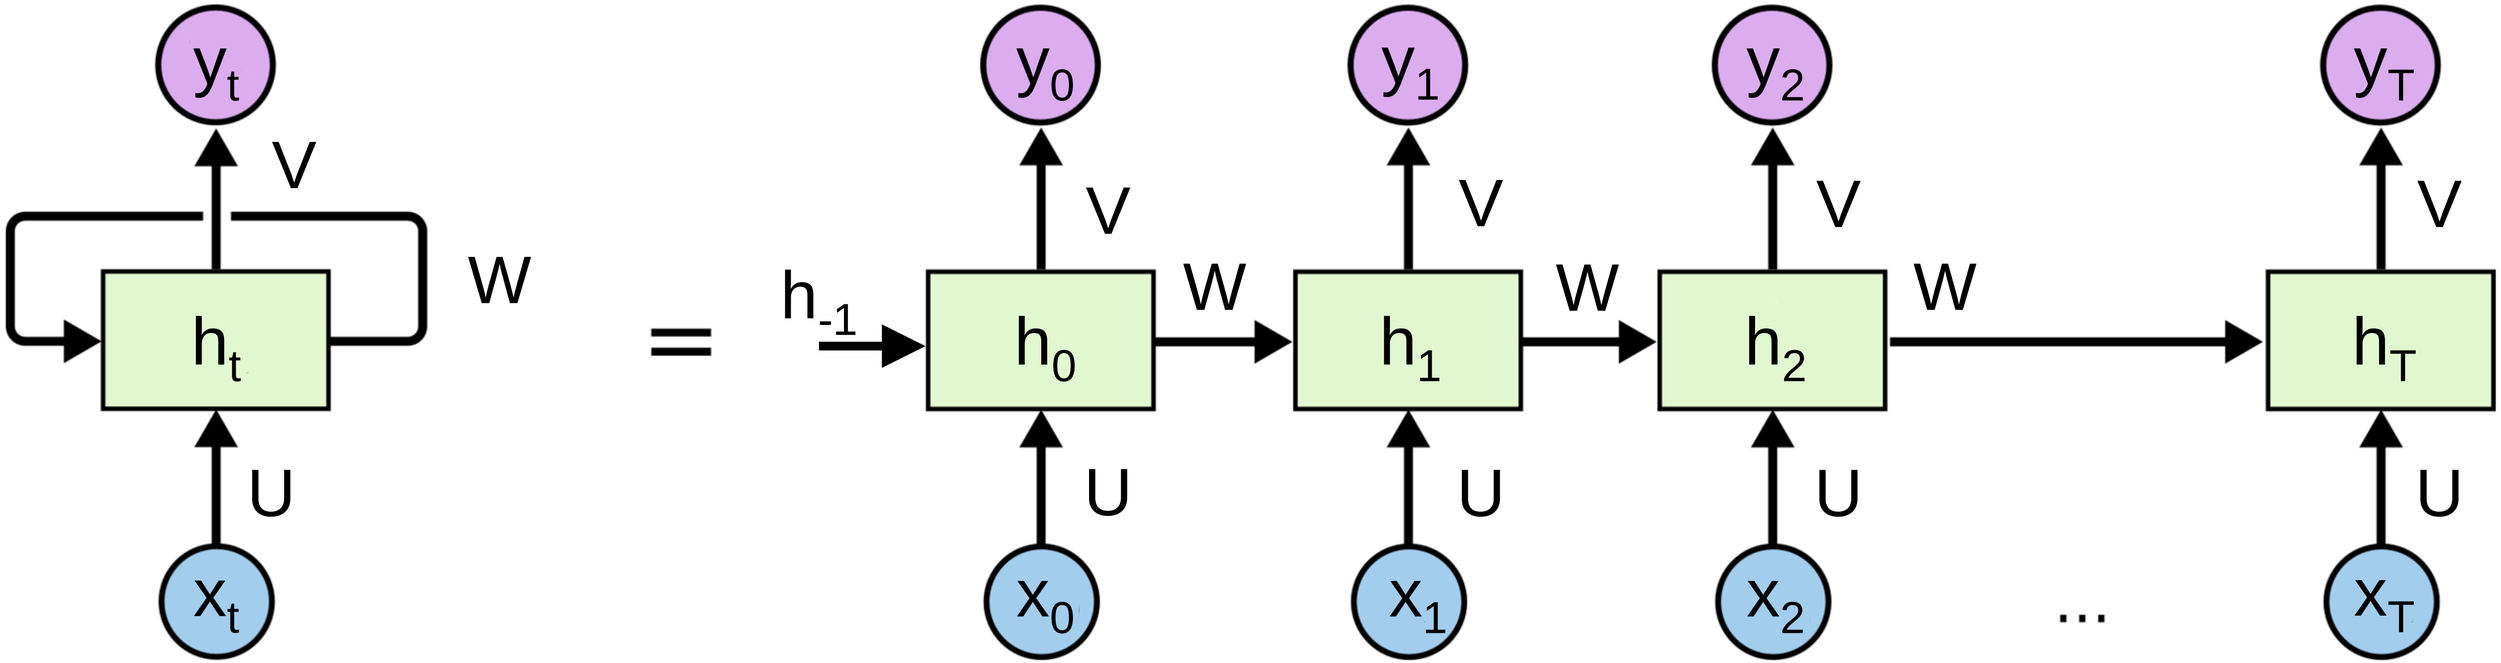

Les paramètres sont **partagés** à travers le temps!

Image from Christopher Olah's blog

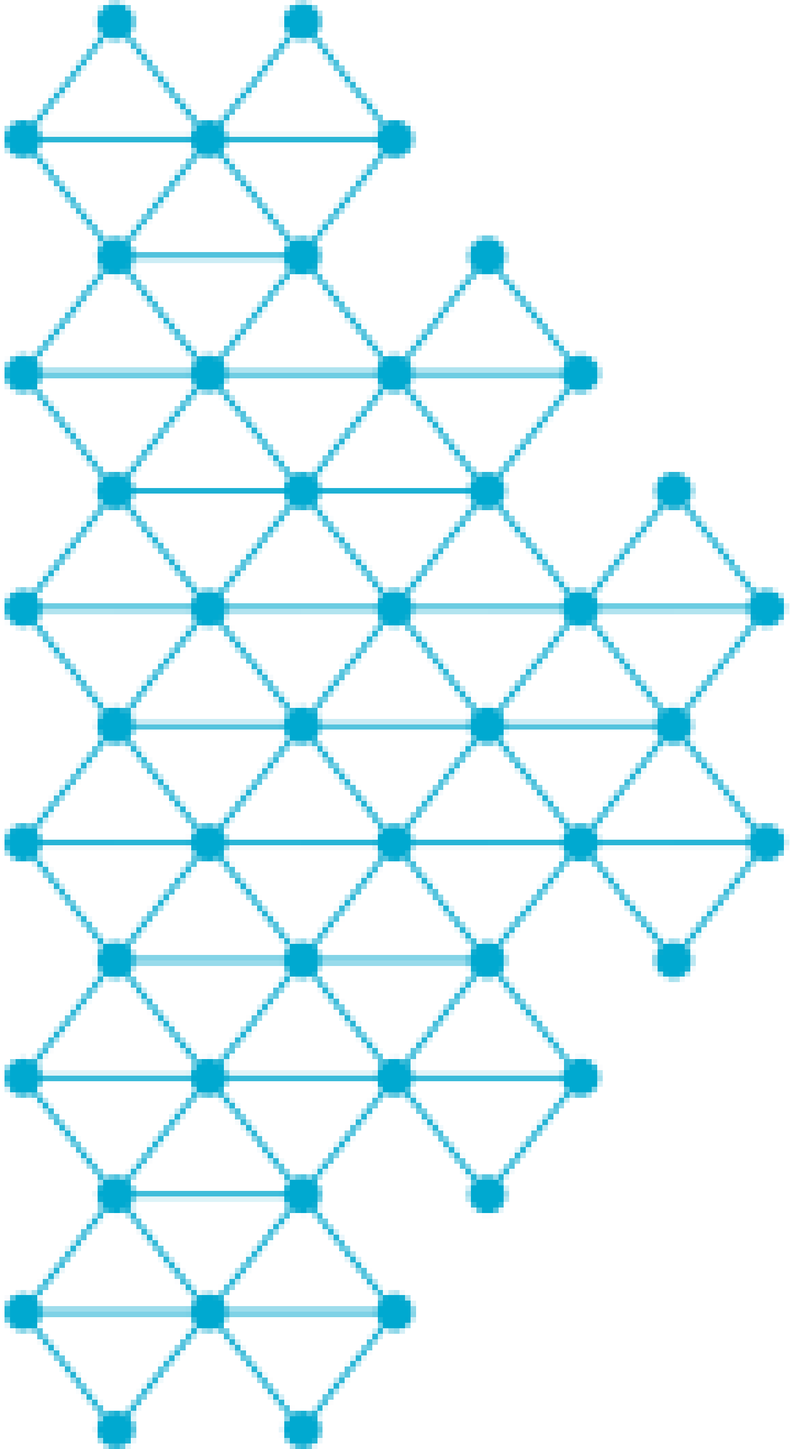

1. Motivation
2. Introduction aux RNNs
3. Entraînement des RNNs
4. Difficultés d’apprentissage
5. Architectures de RNNs
6. RNNs Profonds

Réseaux Récurrents

Ajout des cibles

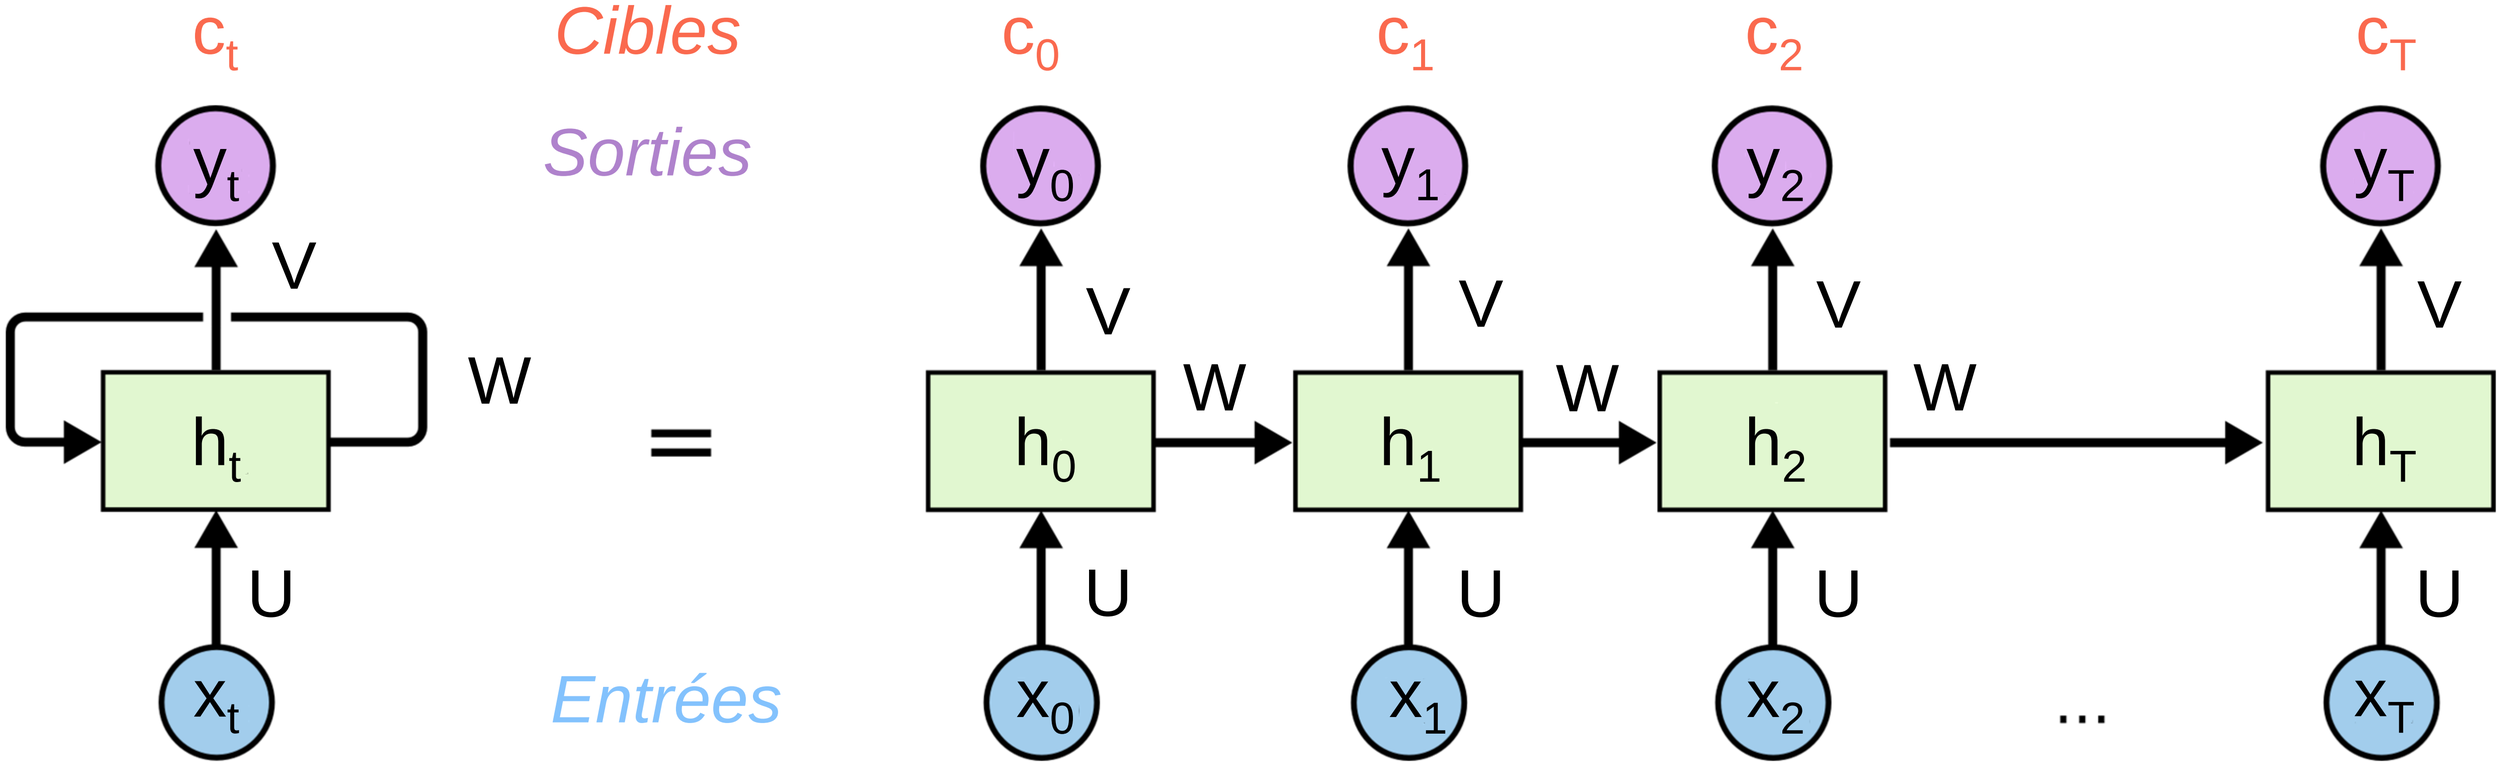

Erreur Globale E = Somme de l'erreur à chaque temps:

$$E = \sum_{t=0}^{T} E_t(y_t, c_t)$$

E_t = entropie croisée, erreur quadratique moyenne, etc…

Rétropropagation à travers le temps

Introduction

- Calcul de l'erreur globale:

$$E = \sum_{t=0}^{T} E_t$$

- Rétropropagation classique pour adapter les paramètres.

- Prenons l'exemple de U:

$$\frac{\partial E}{\partial U} = \sum_{t=0}^{T} \frac{\partial E_t}{\partial U}$$

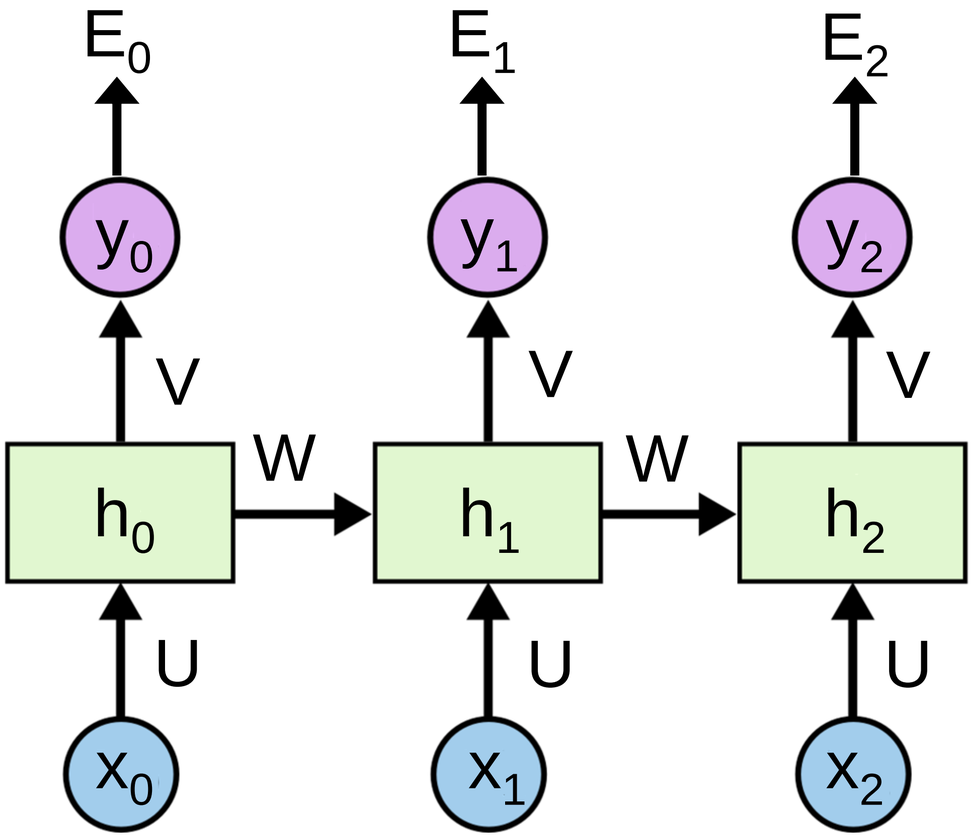

Image from Christopher Olah's blog

Rétropropagation à travers le temps

Exemple: Calcul du gradient sur U

- Pour calculer dE/dU, calculons d'abord dE_2/dU.
  - La première étape est de propager l'erreur jusqu'à l'état interne h_2.

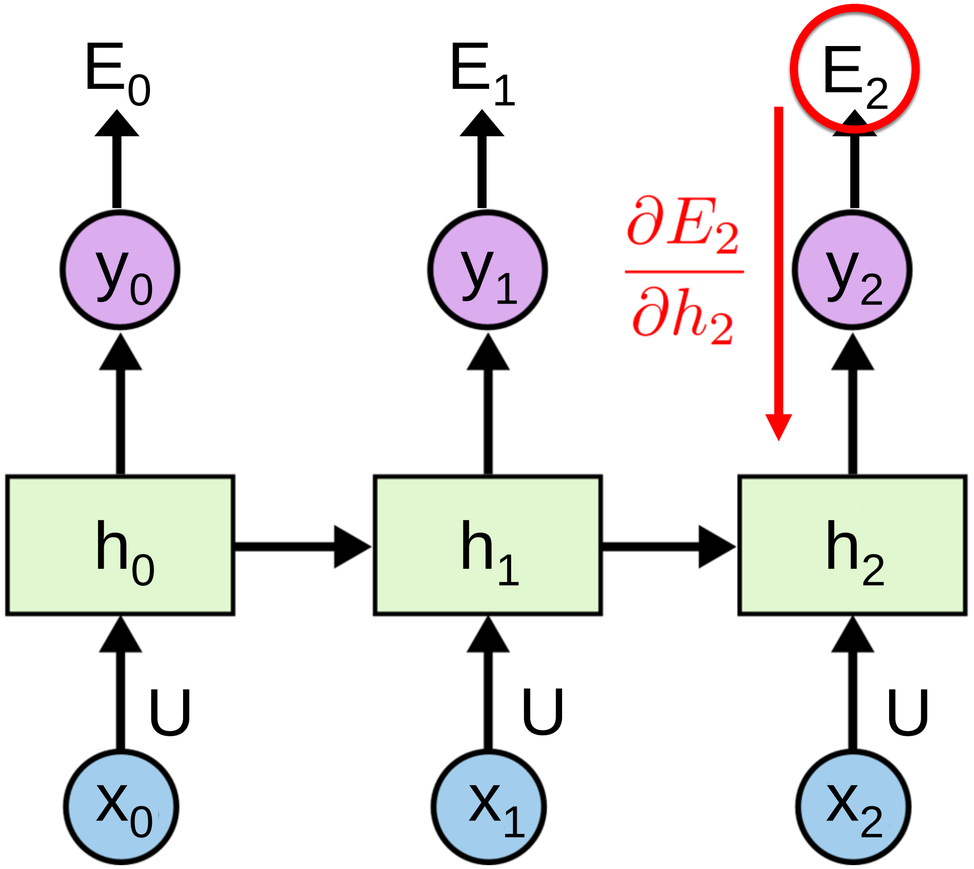

$$\frac{\partial E_2}{\partial U} = \frac{\partial E_2}{\partial h_2} \cdots$$

Image from Christopher Olah's blog

Rétropropagation à travers le temps

Exemple: Calcul du gradient sur U

- Pour calculer dE/dU, calculons d'abord dE_2/dU.
  - L'erreur peut ensuite être propagée sur U au 2ème pas de temps.

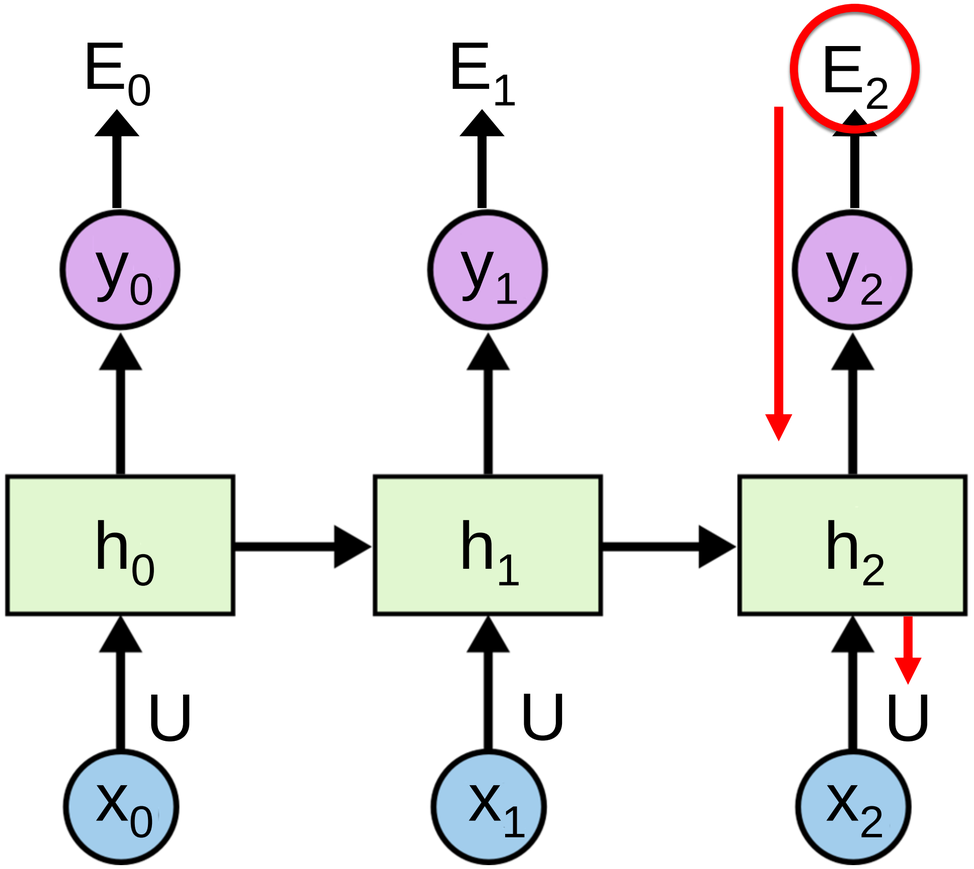

$$\frac{\partial E_2}{\partial U} = \frac{\partial E_2}{\partial h_2} \left(x_2^T \cdots \right.$$

Image from Christopher Olah's blog

Rétropropagation à travers le temps

Exemple: Calcul du gradient sur U

- Pour calculer dE/dU, calculons d'abord dE_2/dU.
  - Mais U intervient également dans le calcul de h_1 et h_0.
  - Il faut donc rétropropager l'erreur à travers le temps.

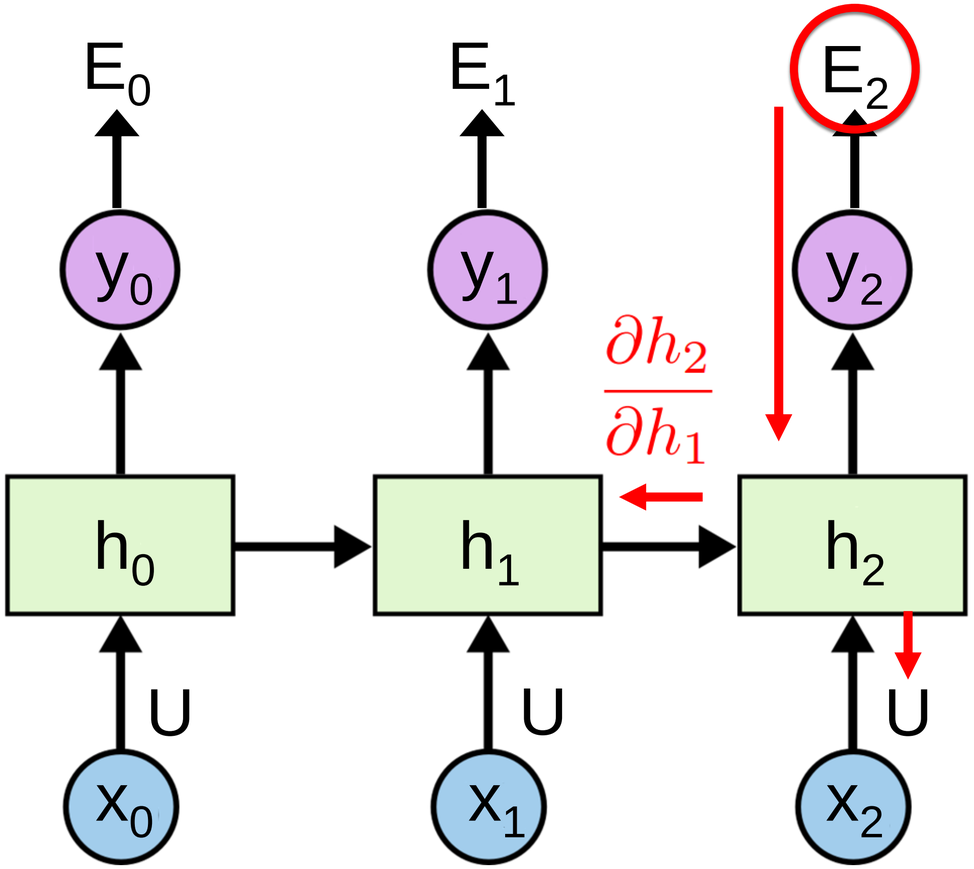

$$\frac{\partial E_2}{\partial U} = \frac{\partial E_2}{\partial h_2}\left(x_2^T + \frac{\partial h_2}{\partial h_1}(\cdots\right.$$

Image from Christopher Olah's blog

Rétropropagation à travers le temps

Exemple: Calcul du gradient sur U

- Pour calculer dE/dU, calculons d'abord dE_2/dU.
  - L'erreur peut ensuite être propagée sur U au 1ème pas de temps.

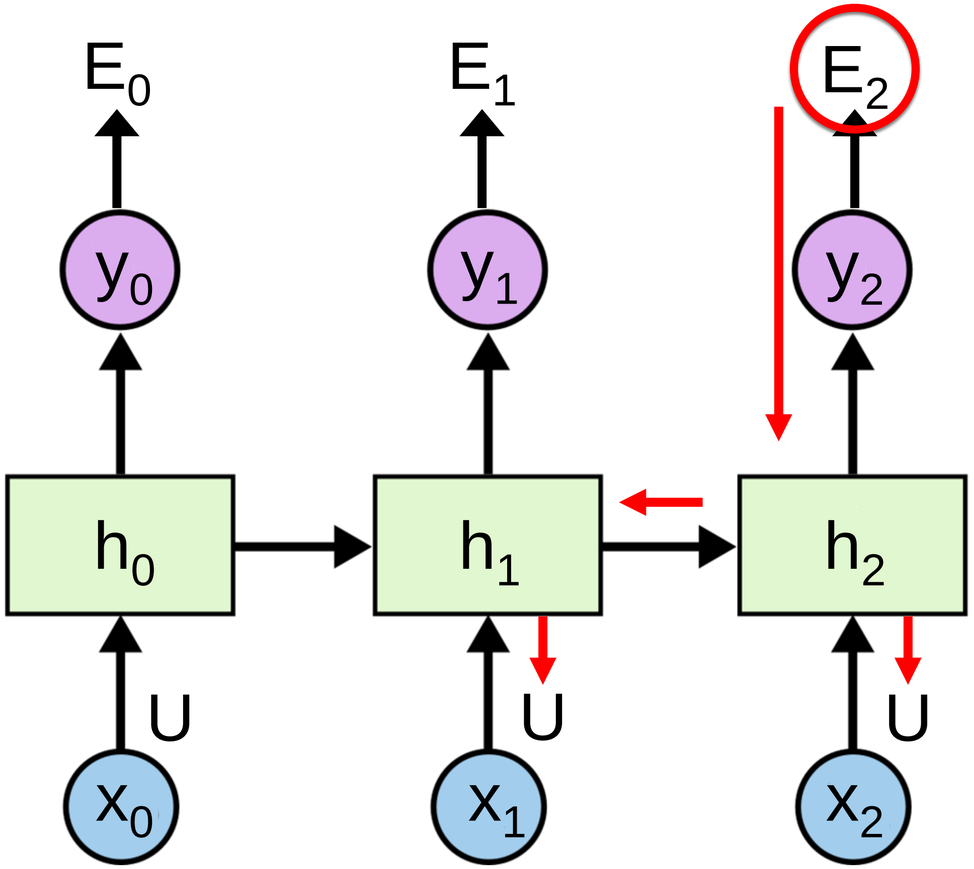

$$\frac{\partial E_2}{\partial U} = \frac{\partial E_2}{\partial h_2}\left(x_2^T + \frac{\partial h_2}{\partial h_1}(x_1^T \cdots\right.$$

Image from Christopher Olah's blog

Rétropropagation à travers le temps

Exemple: Calcul du gradient sur U

- Pour calculer dE/dU, calculons d'abord dE_2/dU.
  - Mais U intervient également dans le calcul h_0.
  - Il faut donc encore rétropropager l'erreur à travers le temps.

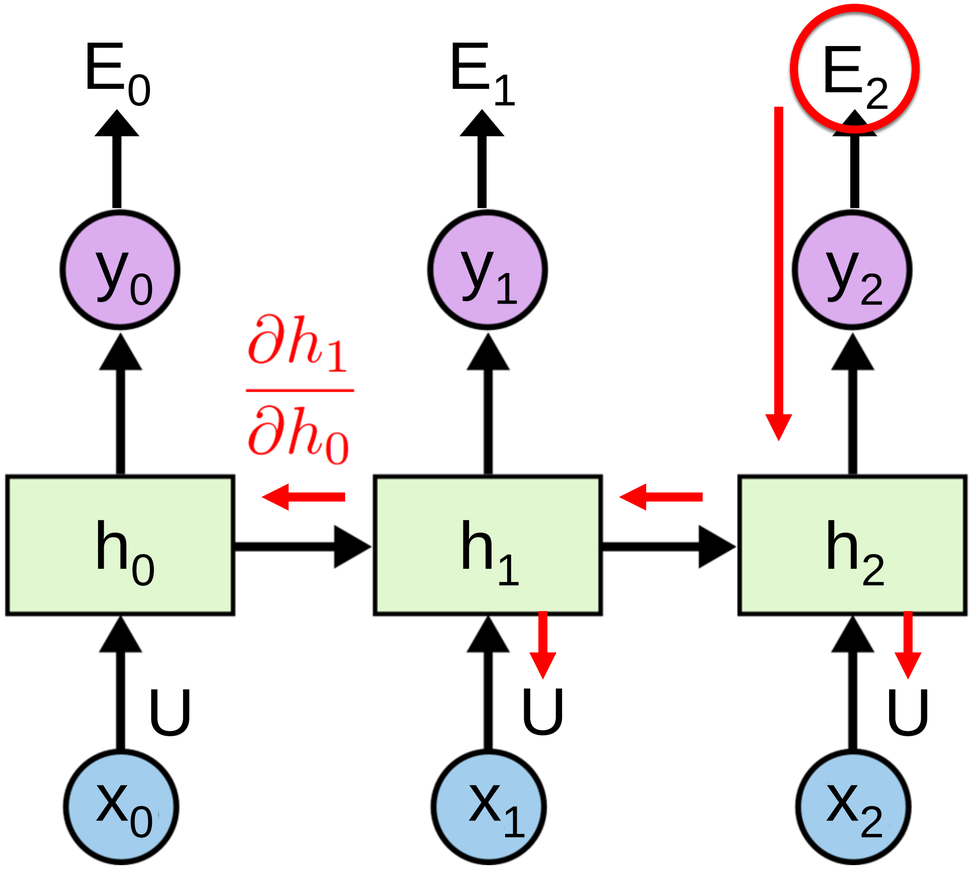

$$\frac{\partial E_2}{\partial U} = \frac{\partial E_2}{\partial h_2}\left(x_2^T + \frac{\partial h_2}{\partial h_1}\left(x_1^T + \frac{\partial h_1}{\partial h_0}\cdots\right.\right.$$

Image from Christopher Olah's blog

Rétropropagation à travers le temps

Exemple: Calcul du gradient sur U

- Pour calculer dE/dU, calculons d'abord dE_2/dU.
  - L'erreur peut ensuite être propagée sur U au 1ème pas de temps.
  - La rétropropagation dE_2/dU est maintenant complète!

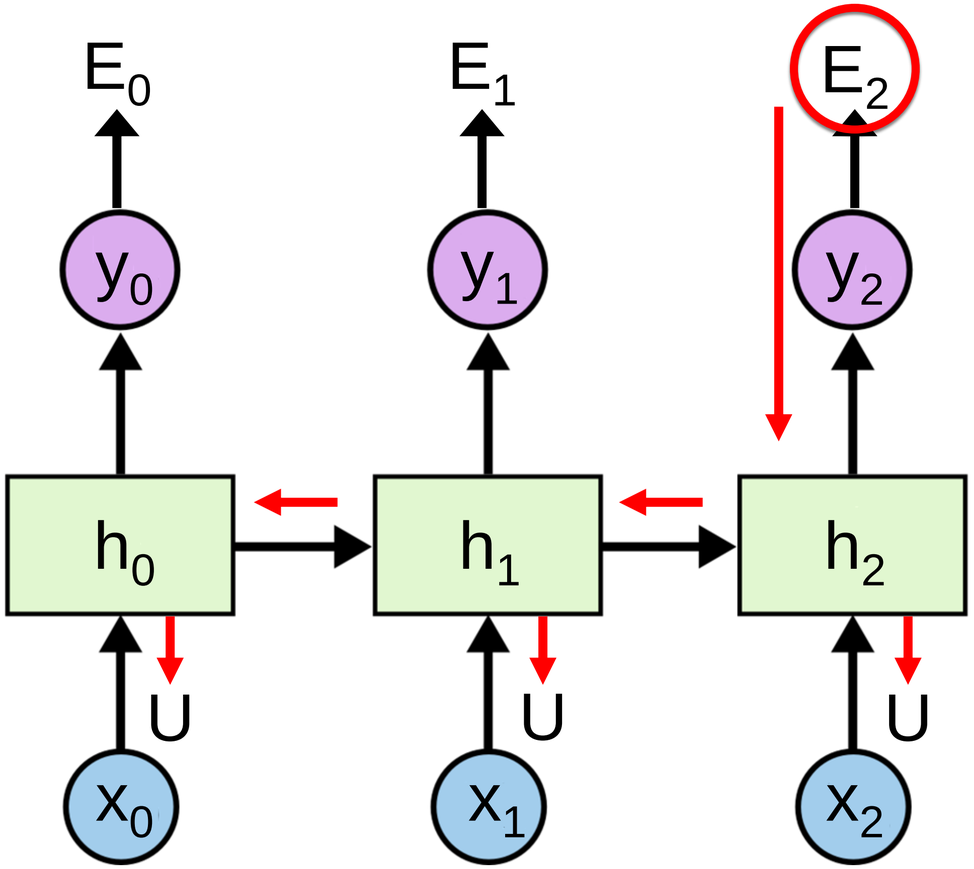

$$\frac{\partial E_2}{\partial U} = \frac{\partial E_2}{\partial h_2}\left(x_2^T + \frac{\partial h_2}{\partial h_1}\left(x_1^T + \frac{\partial h_1}{\partial h_0}x_0^T\right)\right)$$

Image from Christopher Olah's blog

Rétropropagation à travers le temps

Exemple: Calcul du gradient sur U

- Les mêmes opérations sont effectuées pour calculer dE_1/dU

1. Rétropropager l'erreur sur h_1
2. Calculer dh_1/dU au pas de temps 1
3. Rétropropager l'erreur dans le temps sur h_0
4. Calculer dh_0/dU

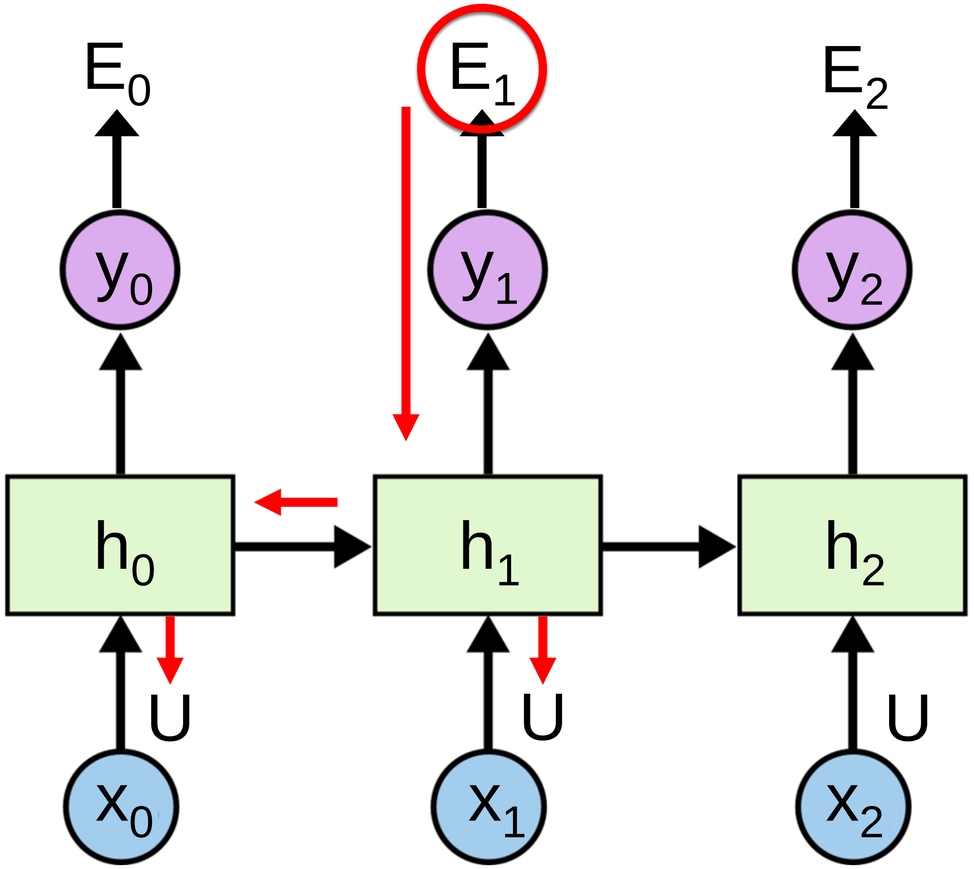

Image from Christopher Olah's blog

Rétropropagation à travers le temps

Exemple: Calcul du gradient sur U

- Les mêmes opérations sont effectuées pour calculer dE_0/dU

1. Rétropropager l'erreur sur h_0
2. Calculer dh_0/dU

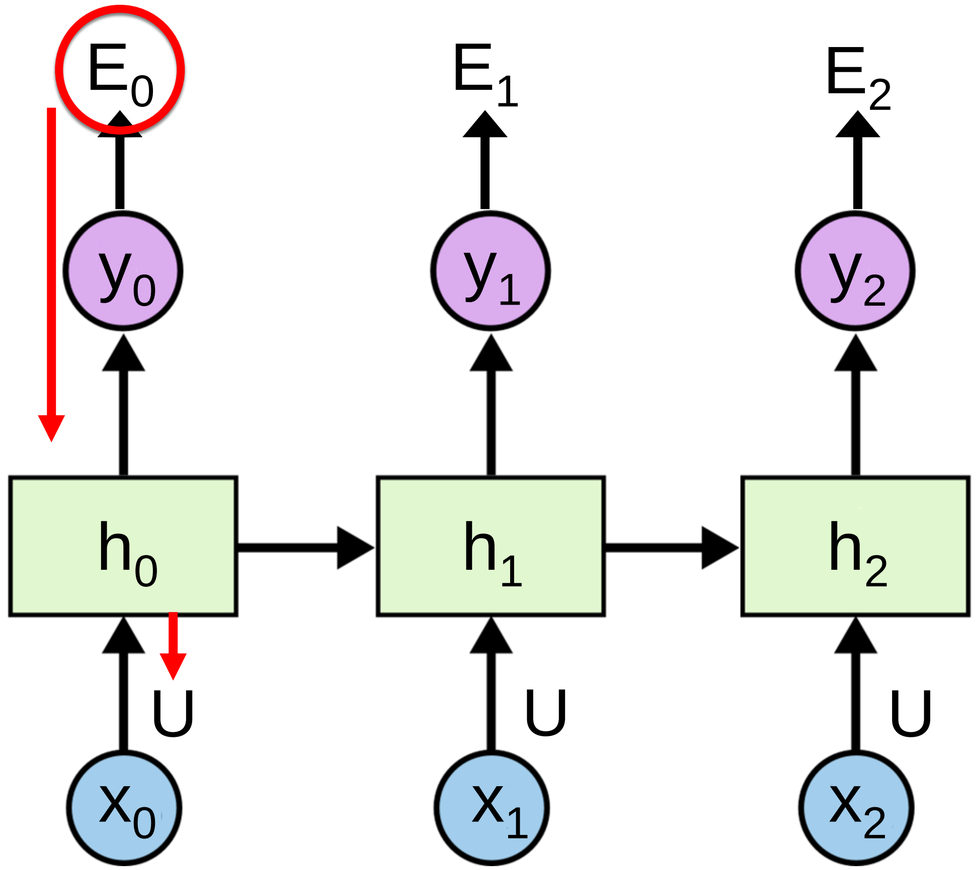

Image from Christopher Olah's blog

Rétropropagation à travers le temps

Exemple: Calcul du gradient sur U

- Toutes les contributions sont sommées pour obtenir le gradient sur U:

$$\frac{\partial E}{\partial U} = \sum_{t=0}^{T} \frac{\partial E_t}{\partial U}$$

- Les gradients sur les autres paramètres sont calculés de la même manière.

$$\frac{\partial E}{\partial V} = \sum_{t=0}^{T} \frac{\partial E_t}{\partial V} \qquad \frac{\partial E}{\partial W} = \sum_{t=0}^{T} \frac{\partial E_t}{\partial W}$$

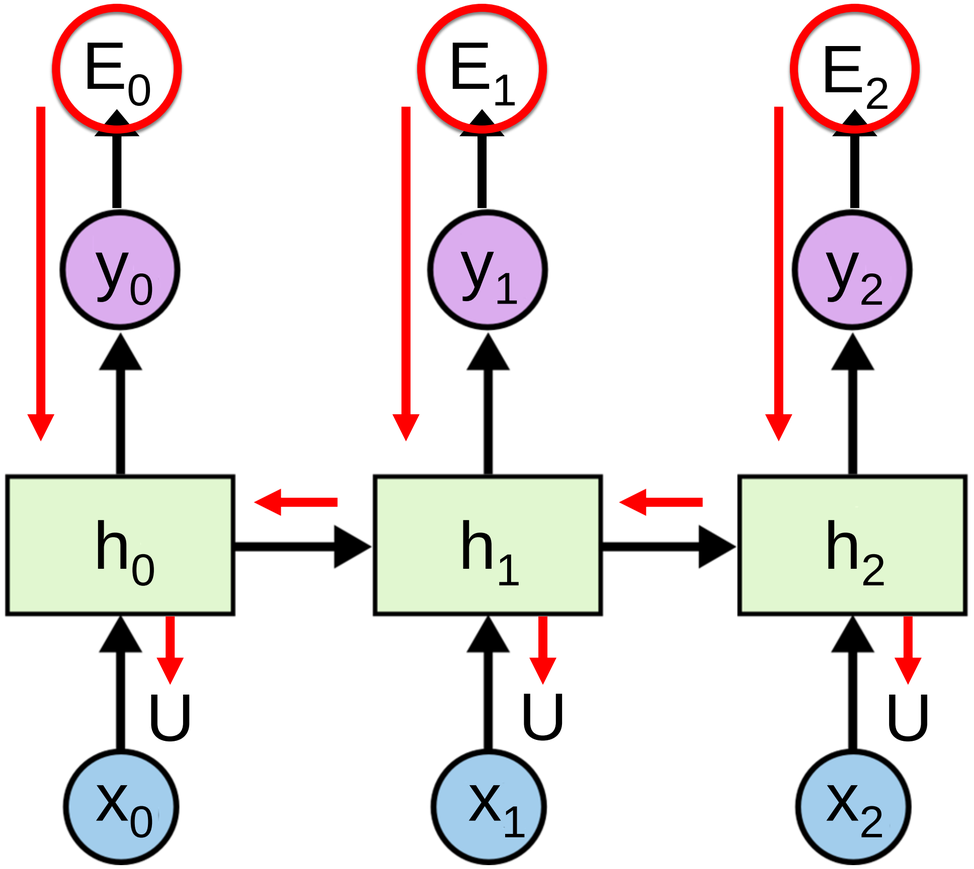

Image from Christopher Olah's blog

Exemple: Genre musical

Présentation de la tâche

But: Reconnaitre le genre musical à partir de la partition

- Données: 500 partitions de musique (durée variable):
  - x: 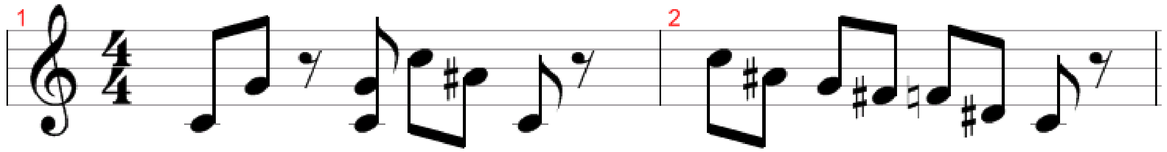
- 3 Classes: Blues, Rock, Classique
  - c: (1, 0, 0) ou (0, 1, 0) ou (0, 0, 1)

Exemple: Genre musical

Représentation des données

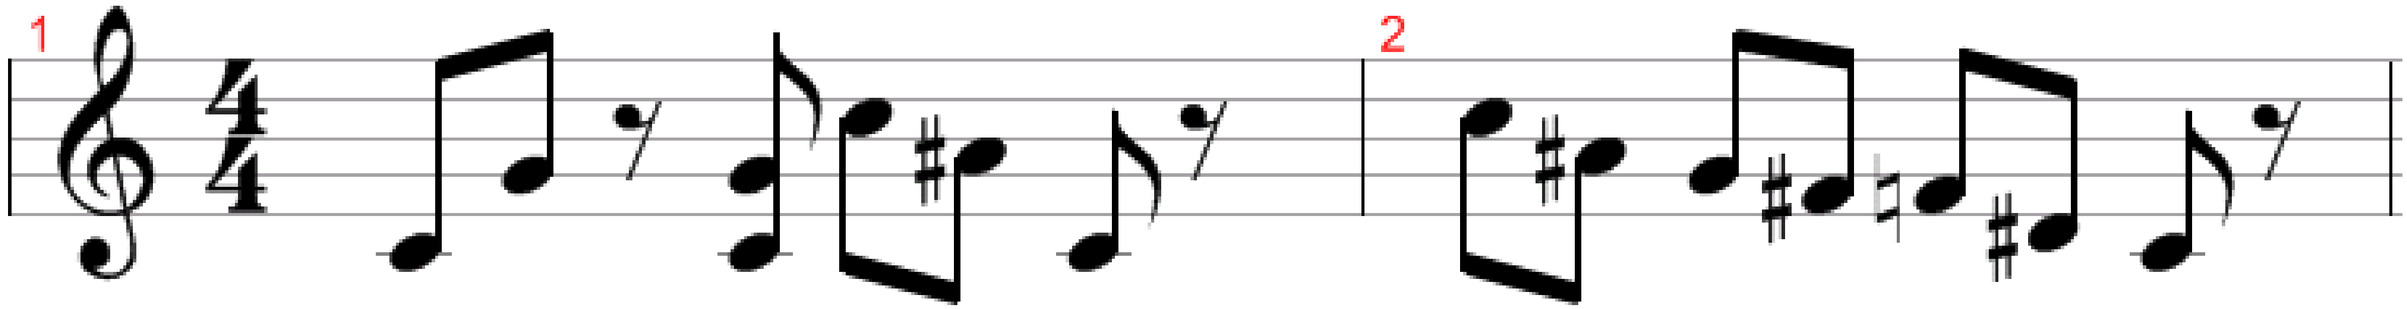

0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	1	0	0	0	1	0	0	0	1	0	0
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
0	1	0	1	0	0	0	0	0	0	1	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
1	0	0	1	1	0	1	0	1	0	0	1	1	0	1	0

Exemple: Genre musical

Réseau récurrent

Exemple avec un RNN Simple, et en utilisant uniquement la sortie au dernier temps.

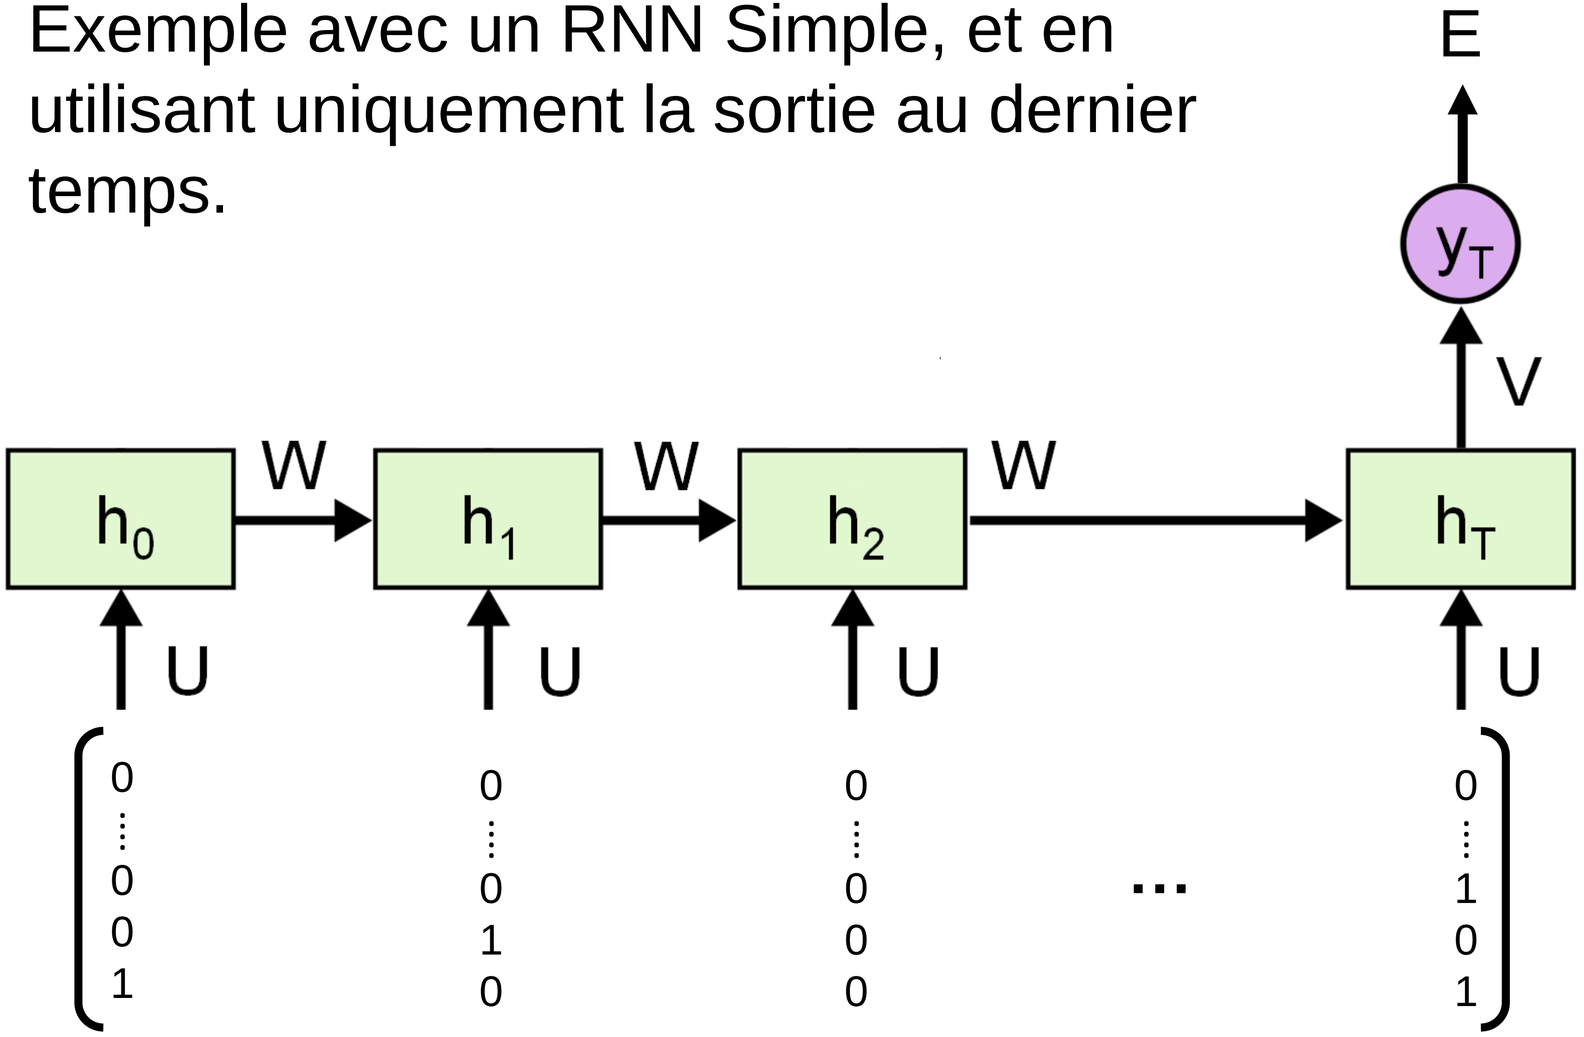

$$E = \text{cross\_entropy}(y_T, c)$$

$$y_T = \text{Softmax}(V h_T + d)$$

$$h_t = \tanh(U x_t + W h_{t-1} + b)$$

$$x$$

Exemple: Genre musical

Rétropropagation des gradients

Exemple avec un RNN Simple, et en utilisant uniquement la sortie au dernier temps.

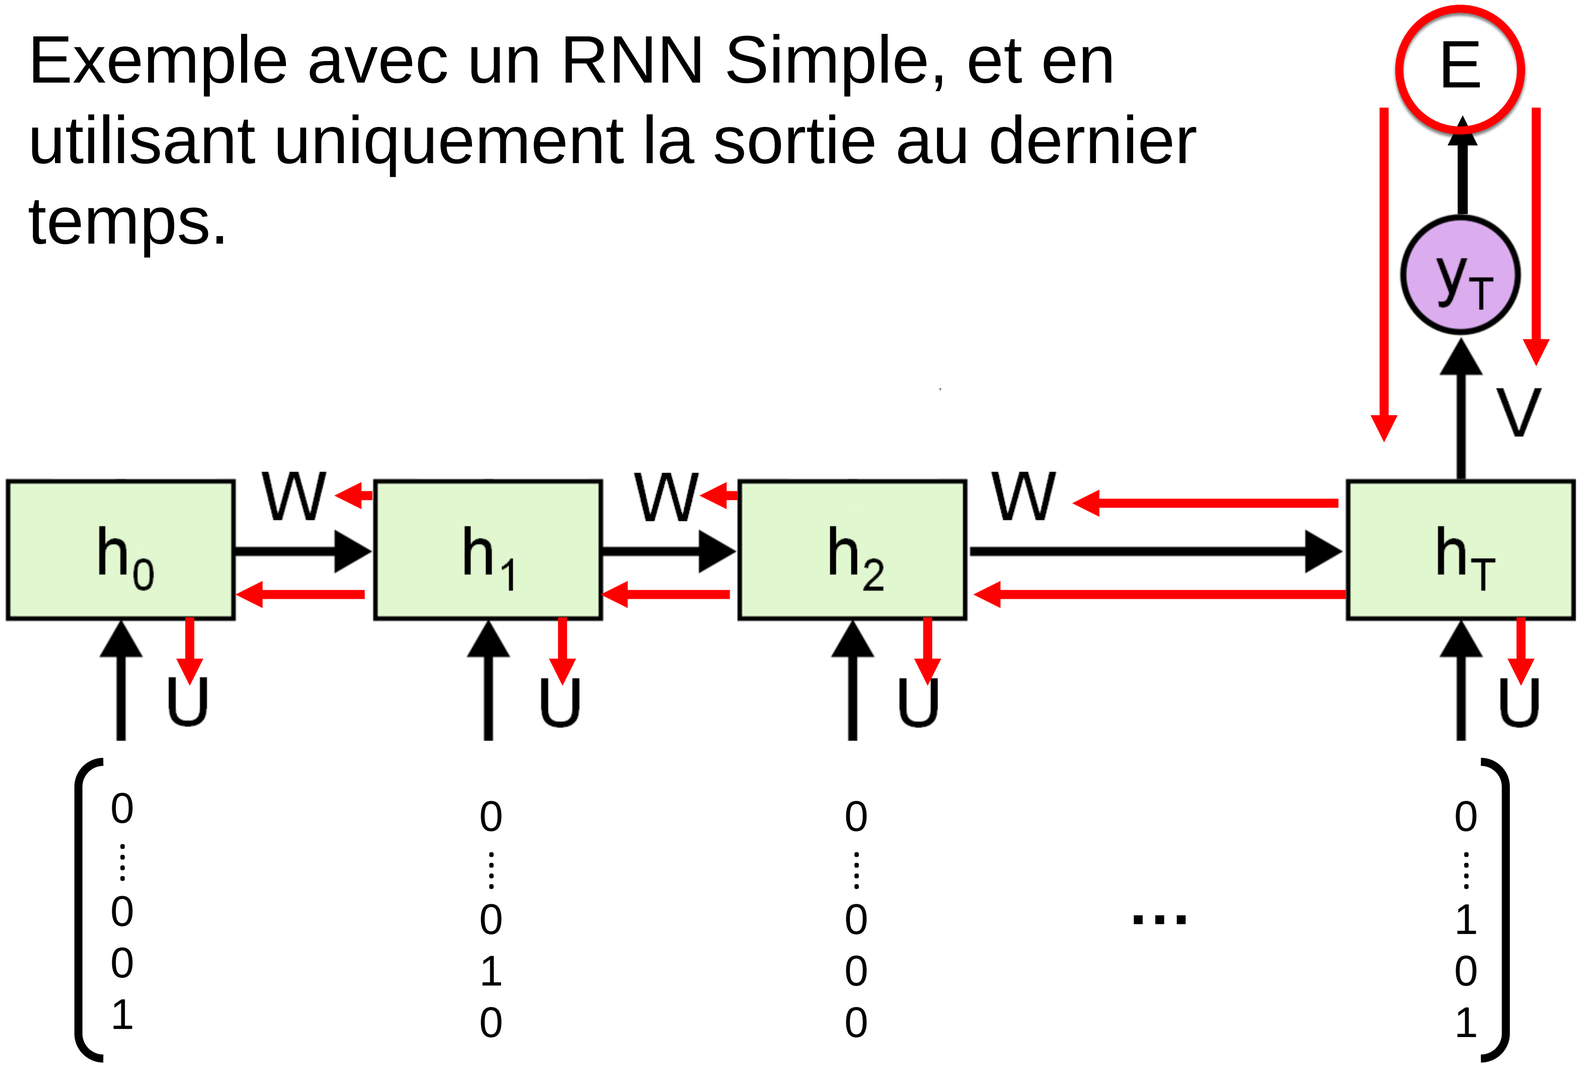

$$E = \text{cross\_entropy}(y_T, c)$$

$$y_T = \text{Softmax}(V h_T + d)$$

$$h_t = \tanh(U x_t + W h_{t-1} + b)$$

$$x$$

Exemple: Genre musical

Réseau récurrent et code

```
from keras.models import Sequential
from keras.layers import Dense
from keras.layers import SimpleRecurrent

model = Sequential()
model.add(Dense(100))
model.add(SimpleRecurrent(100,
                          return_sequence=False))
model.add(Dense(3, activation='softmax'))
model.compile(loss='categorical_crossentropy',
              optimizer='sgd',
              metrics=['accuracy'])
```

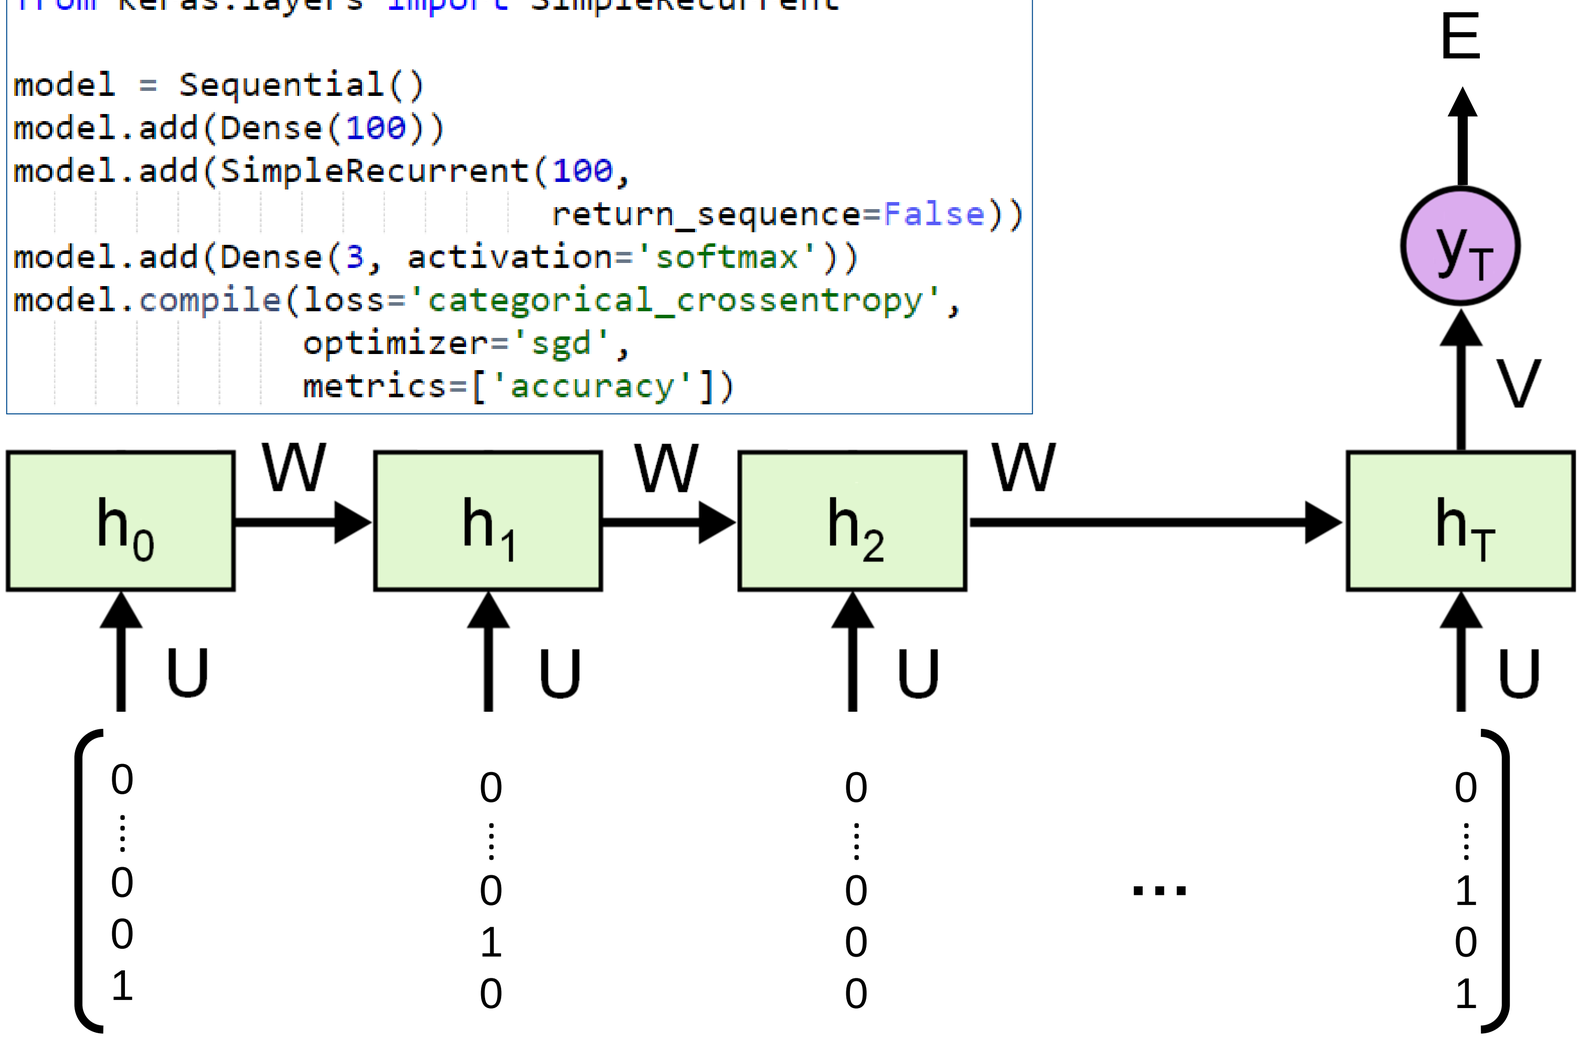

$$E = \text{cross\_entropy}(y_T, c)$$

$$y_T = \text{Softmax}(V h_T + d)$$

$$h_t = \tanh(U x_t + W h_{t-1} + b)$$

$$x$$

Réseaux Récurrents

Autres tâches

D’autres tâches qui peuvent être traitées de la même façon :

- Analyse de sentiment (texte)
- Détection d’arythmie cardiaque (ECG)
- Détection de spam
- Classification de séquences

Rétropropagation à travers le temps

Librairies d'apprentissage profond

- Si vous n'avez pas tout compris:
  - Les librairies d'apprentissage profond calculent les gradients automatiquement pour vous!
- **Attention:** Il y a quand même quelques difficultés d'apprentissage qui peuvent survenir.

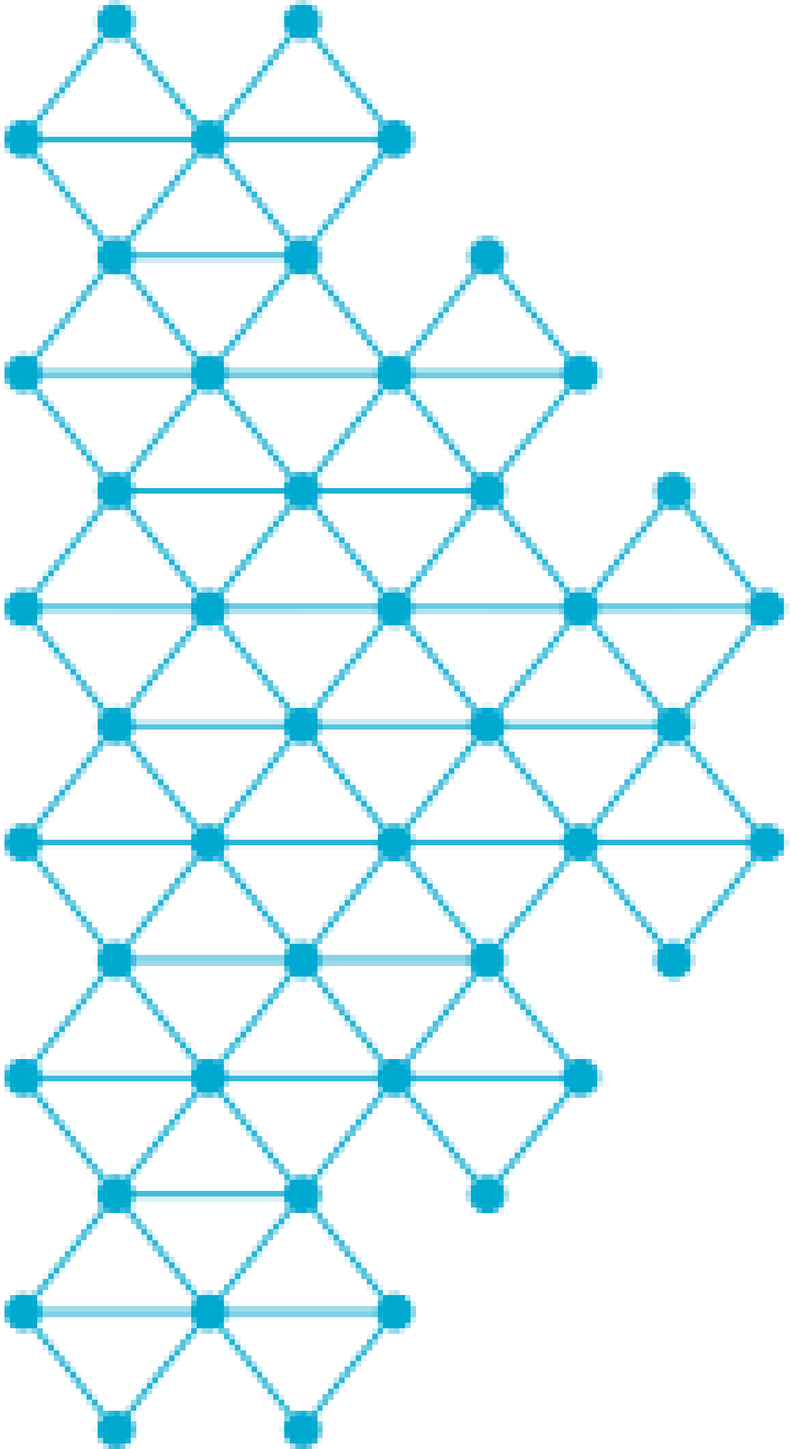

1. Motivation
2. Introduction aux RNNs
3. Entraînement des RNNs
4. Difficultés d’apprentissage
5. Architectures de RNNs
6. RNNs Profonds

Dépendances à long terme

Exemple

Qui est allé à Paris?

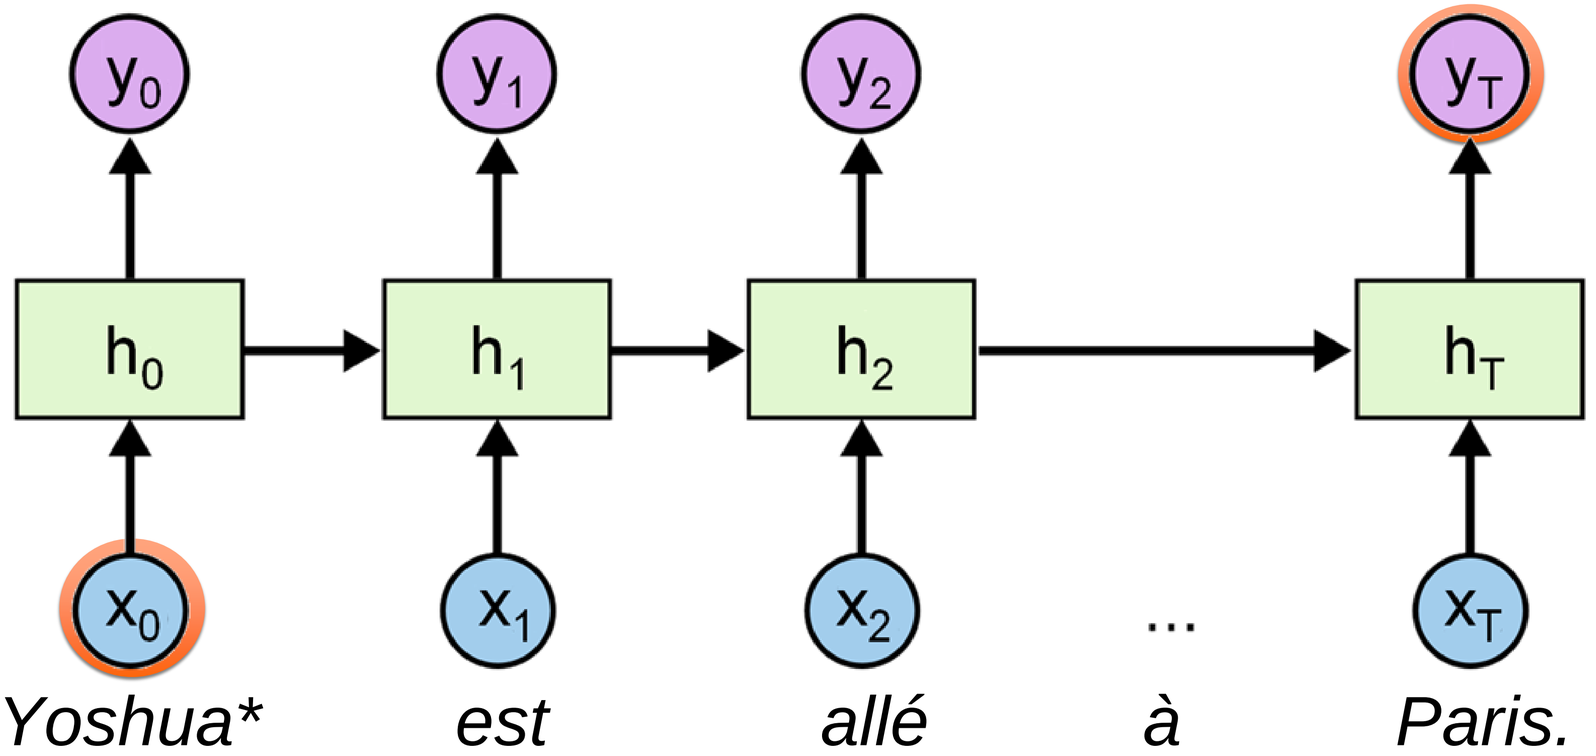

Image from Christopher Olah's blog

**prénom d'emprut*

Dépendances à long terme

Exemple

Qui est allé à Paris?

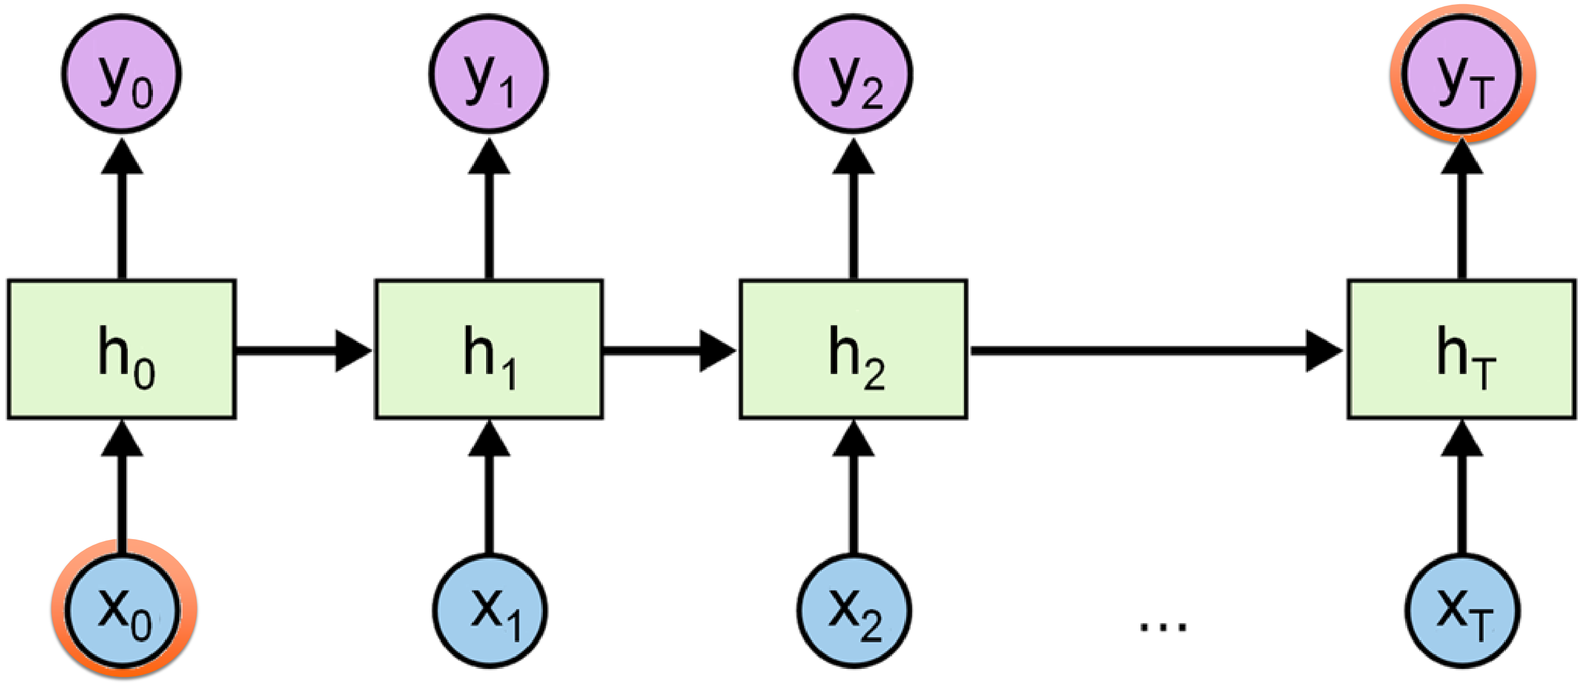

présenter sa recherche à une conférence d'apprentissage profond qui se déroulait à

Image from Christopher Olah's blog

**prénom d'emprut*

Dépendances à long terme

Exemple

Qui est allé à Paris?

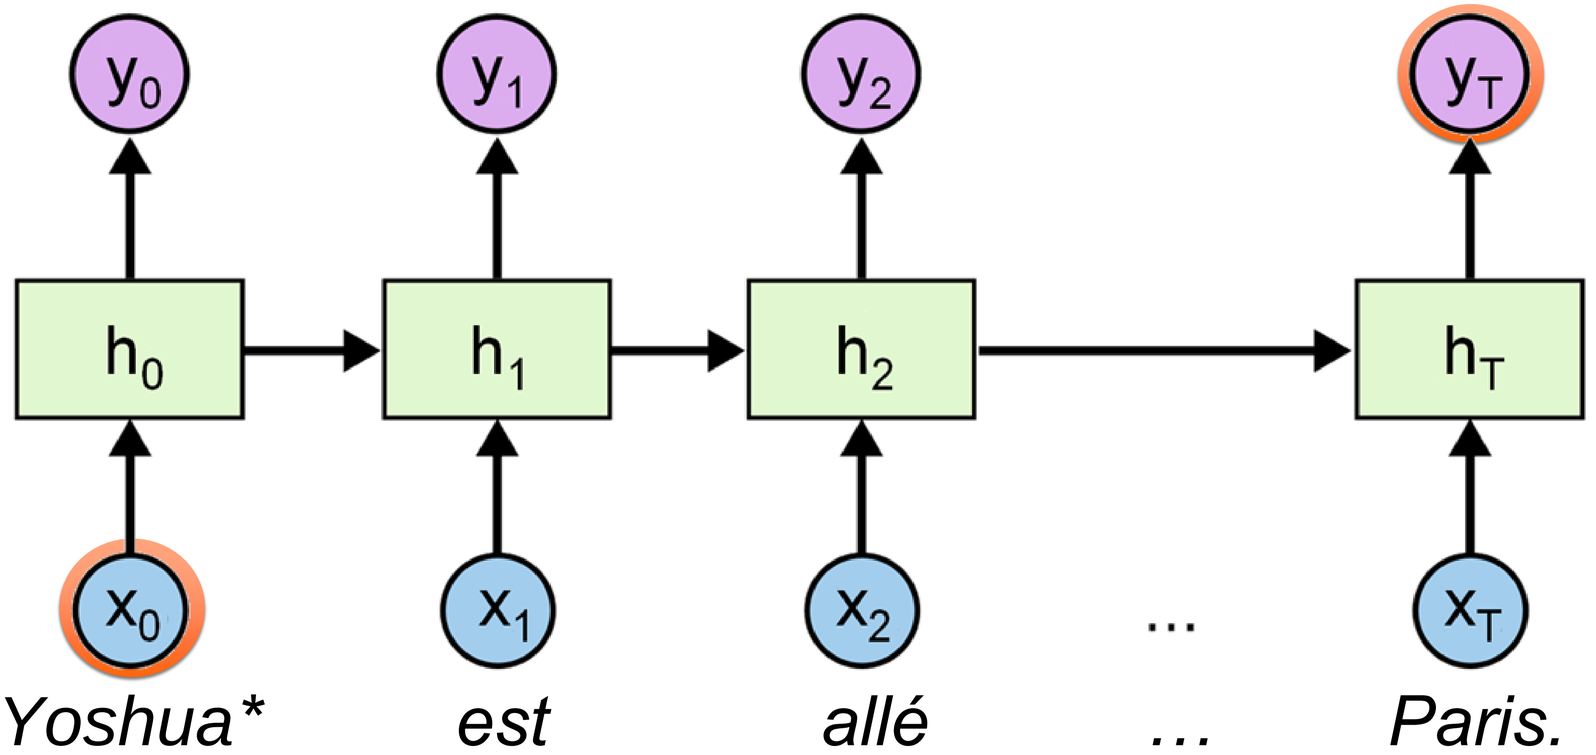

Un RNN doit être capable d'apprendre des dépendances à long terme!

Image from Christopher Olah's blog

**prénom d'emprut*

Dépendances à long terme

Propagation du gradient

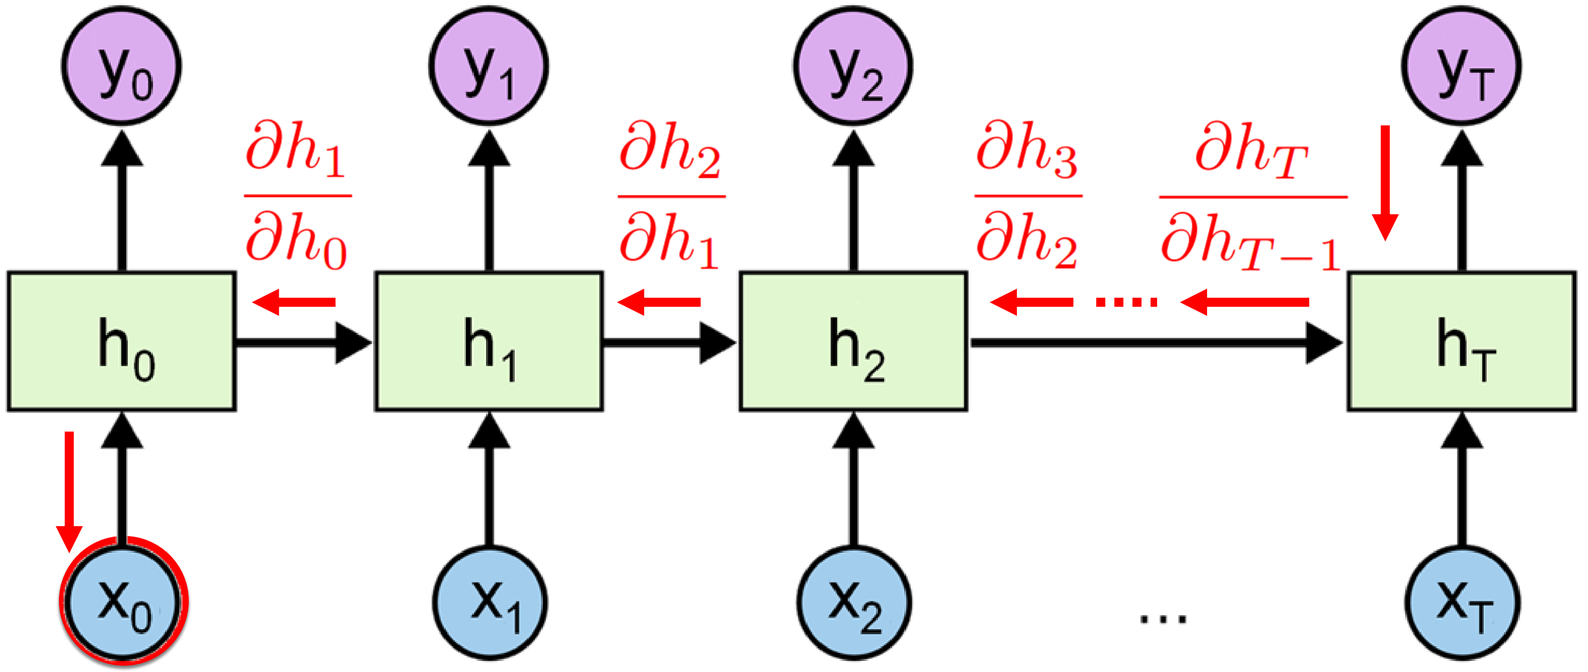

Apprendre des dépendances à long terme

= Propager le gradient loin dans le temps

Image from Christopher Olah's blog

Difficultés d'apprentissage

Problème

- Pour apprendre des dépendances à long terme, il faut pouvoir propager le gradient loin dans le temps.

- La propagation des gradients à travers de nombreux pas de temps peut devenir instable et créer des problèmes d'entraînement.

  - $$\frac{\partial y_T}{\partial x_0} = \frac{\partial y_T}{\partial h_T}\frac{\partial h_T}{\partial h_{T-1}} \cdots \frac{\partial h_3}{\partial h_2}\frac{\partial h_2}{\partial h_1}\frac{\partial h_1}{\partial h_0}\frac{\partial h_0}{\partial x_0}$$

  - C'est la principale difficulté lors de l'entraînement de RNNs!

Explosion de gradient

Schéma

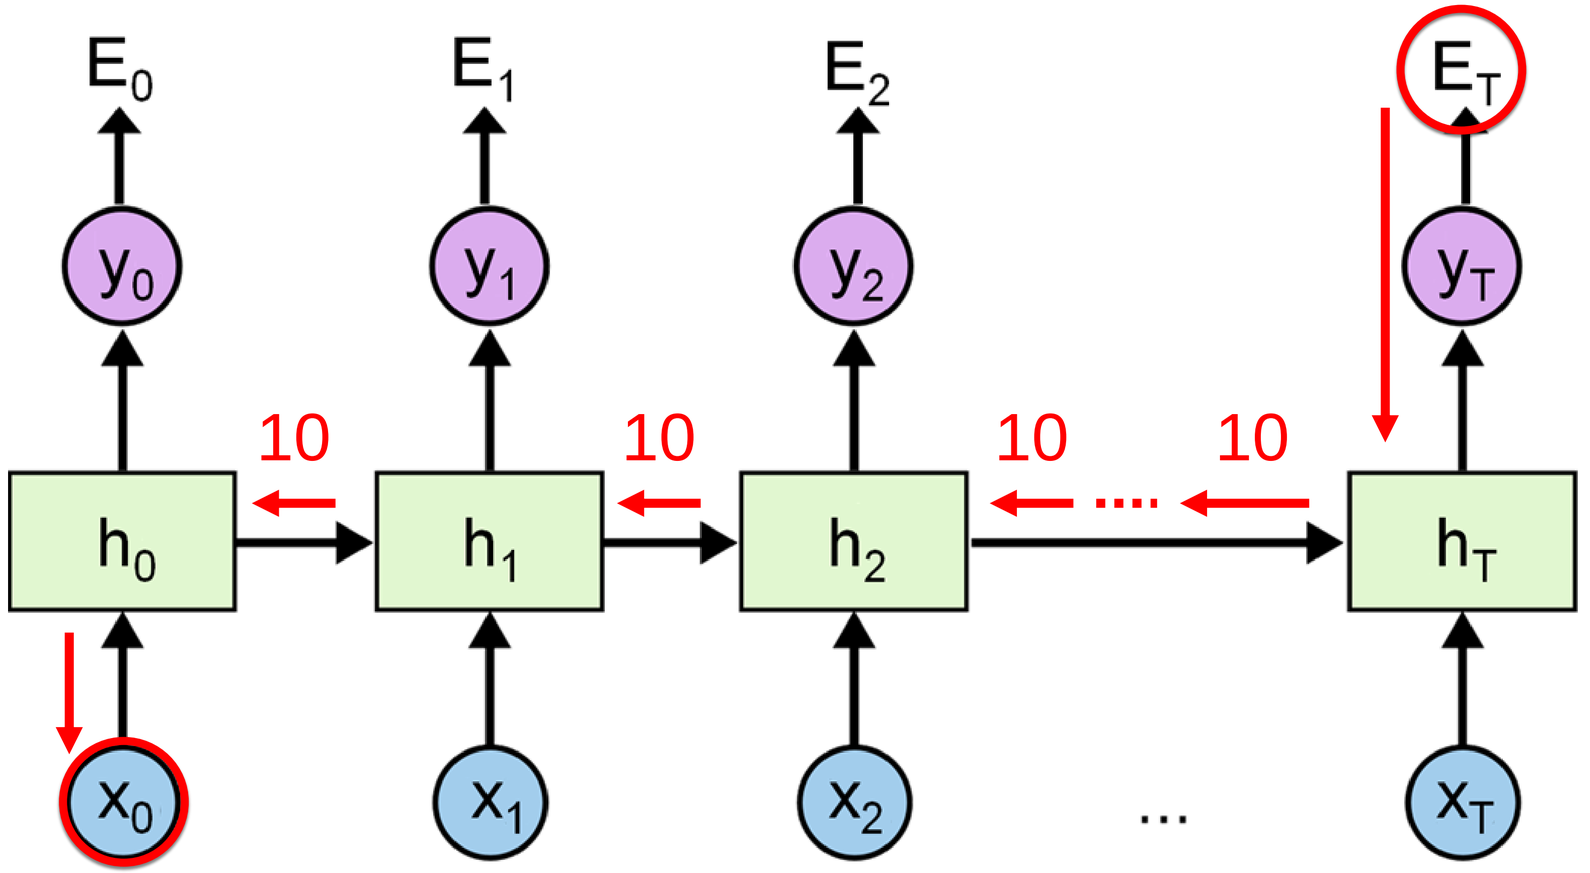

Gradient amplifié à chaque temps = Explosion!

Explosion de gradient

Solution

- Gradient amplifié à chaque temps → Explosion de Gradient!
  - Problème: Fait diverger les paramètres
- Solution simple: **Gradient Clipping**:

$$g = \frac{\partial E}{\partial W}$$
$$\textbf{if } ||g|| \geq \text{seuil } \textbf{then}$$
$$g \leftarrow \frac{\text{seuil}}{||g||} g$$
$$\textbf{end if}$$

Pascanu et al., *On the difficulty of training Recurrent Neural Networks*, 2013

Dissipation de gradient

Schéma

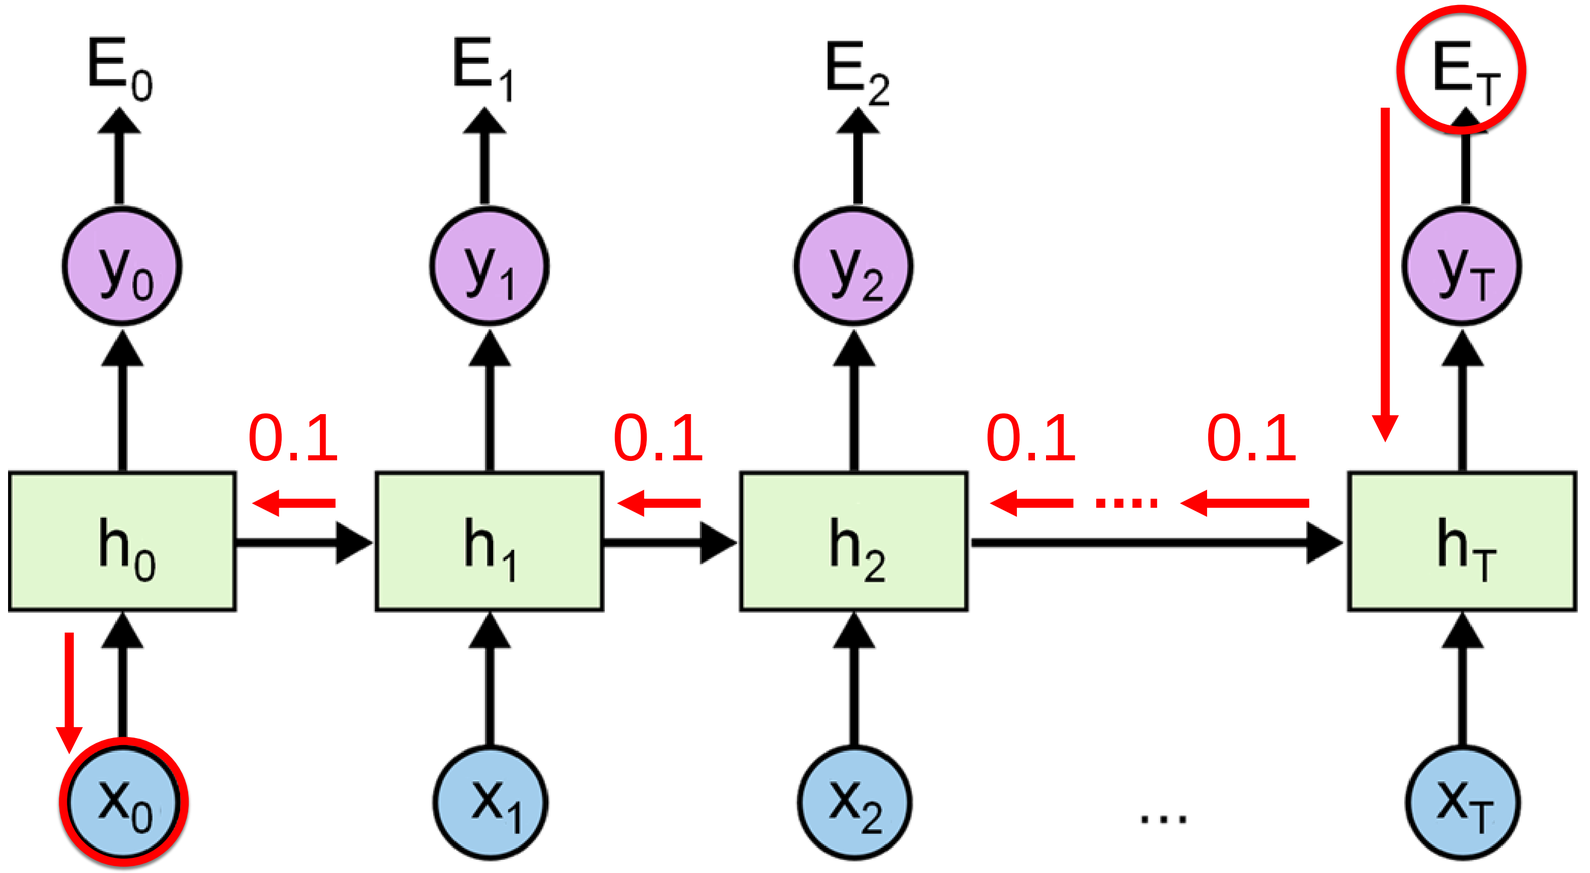

Gradient atténué à chaque temps = Dissipation!

Dissipation de gradient

Solution

- Gradient atténué à chaque temps → Dissipation de Gradient!
  - Problème: Empêche l'apprentissage de dépendances à long terme!
- Pas de solution simple.
  - Utilisation d'architectures de RNN particulières.

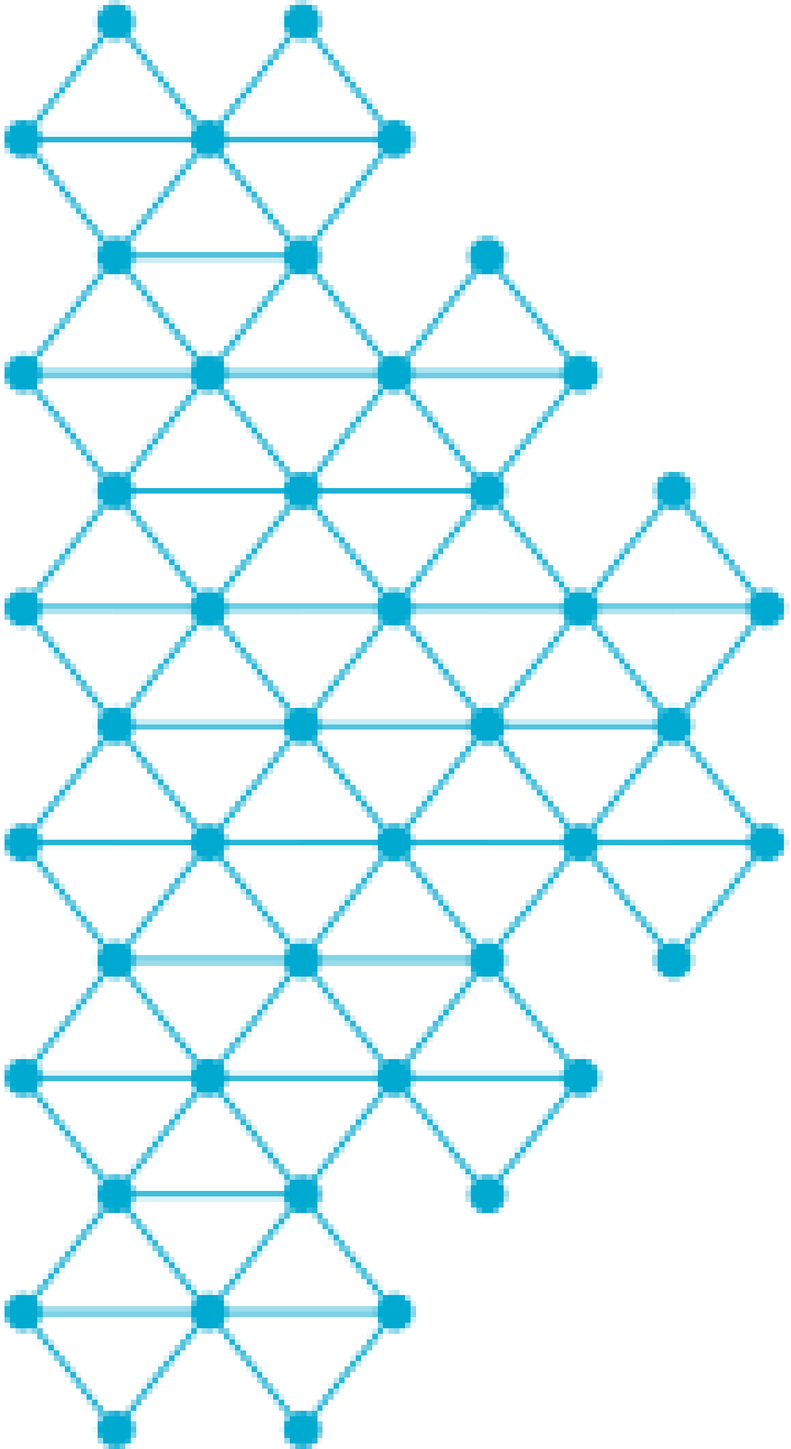

1. Motivation
2. Introduction aux RNNs
3. Entraînement des RNNs
4. Difficultés d’apprentissage
5. Architectures de RNNs
6. RNNs Profonds

Manque de mémoire

Présentation

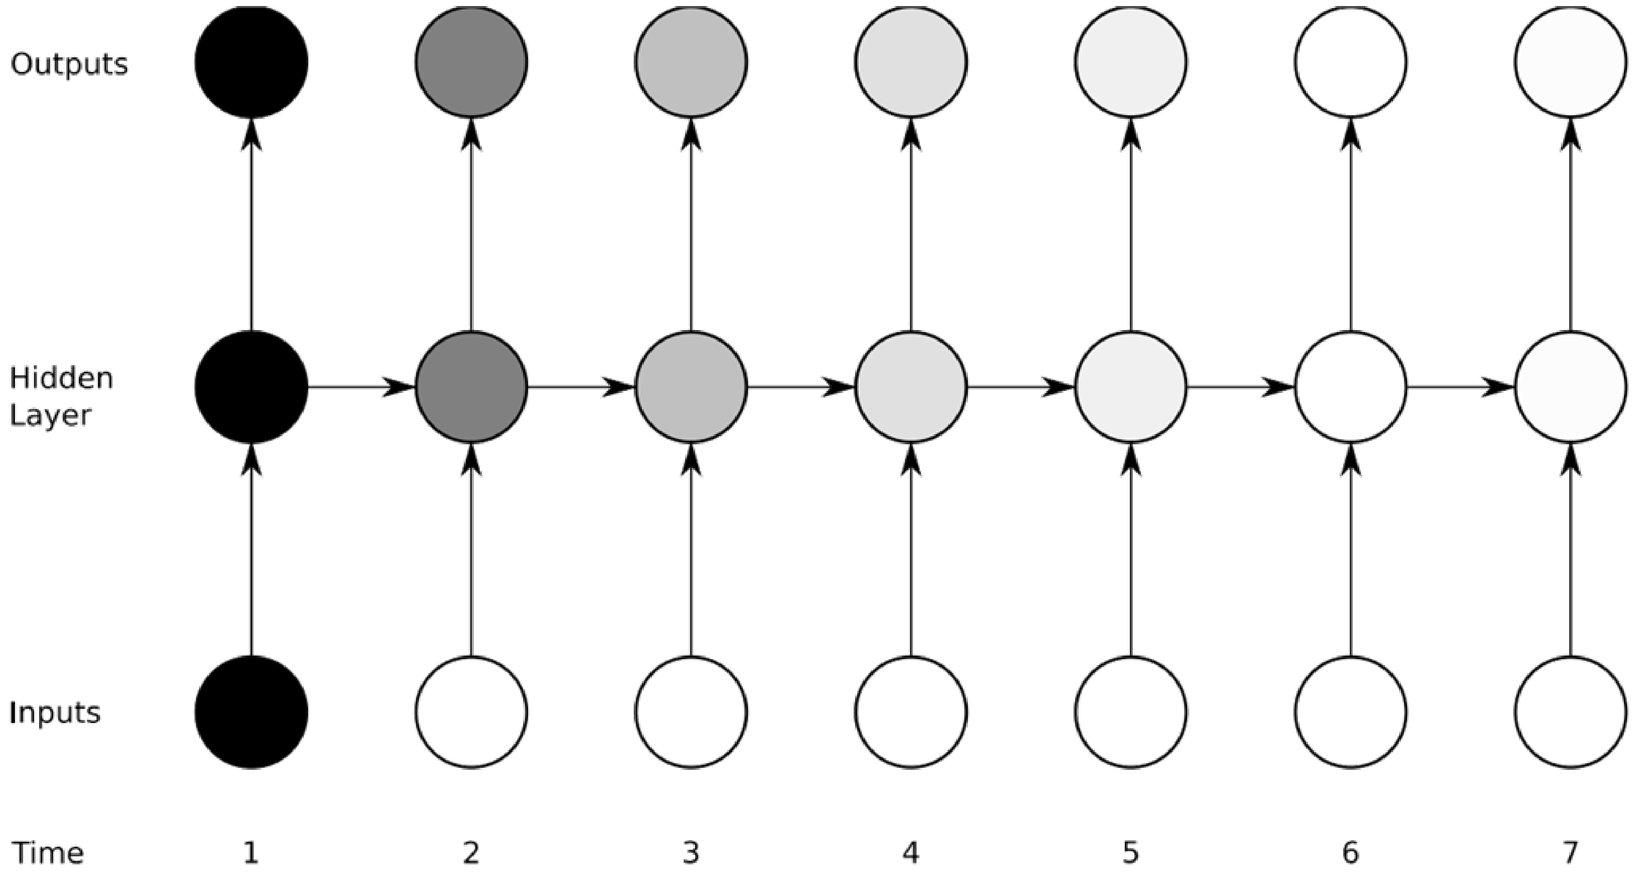

La nuance de gris montre l'influence de l'entrée du RNN au temps 1. Elle décroit au cours du temps, comme le RNN oublie peu à peu sa première entrée.

Graves, *Supervised Sequence Labelling with Recurrent Neural Networks*

Manque de mémoire

Ajout de gates

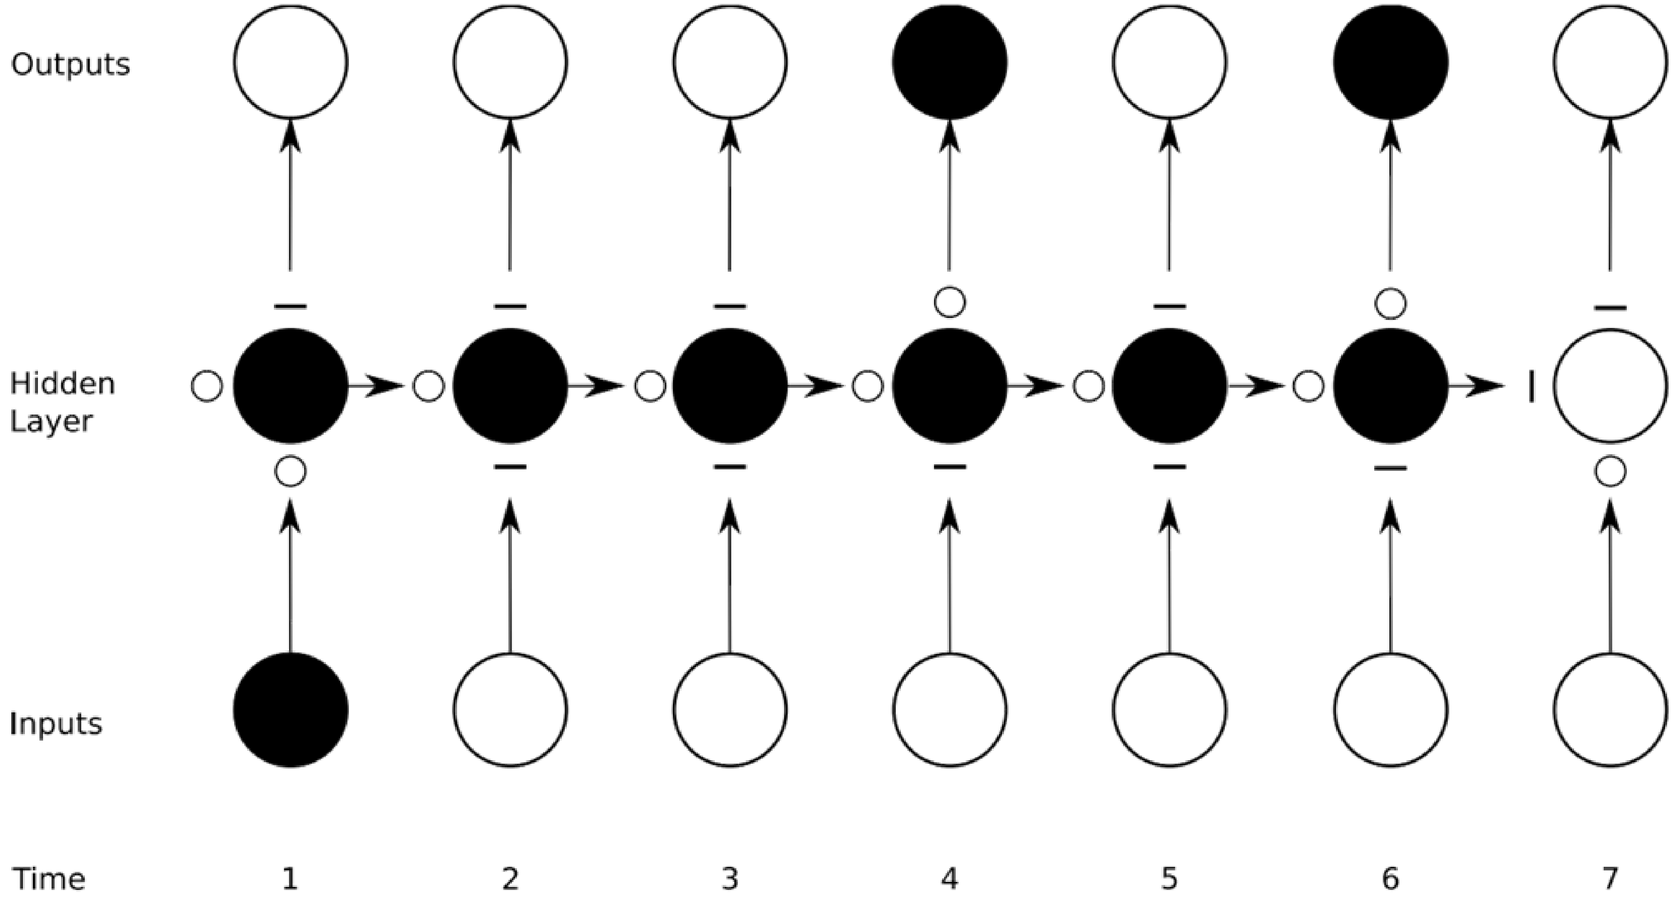

En ajoutant 3 gates (o ouvert; - fermé), qui contrôlent l'entrée, la sortie et l'effacement de l'état, on peut retenir et propager l'information dans le temps.

Graves, *Supervised Sequence Labelling with Recurrent Neural Networks*

Long Short-Term Memory (LSTM)

Introduction

Réduction du probème de disspation avec **un méchanisme de gates** et une **cellule mémoire**.

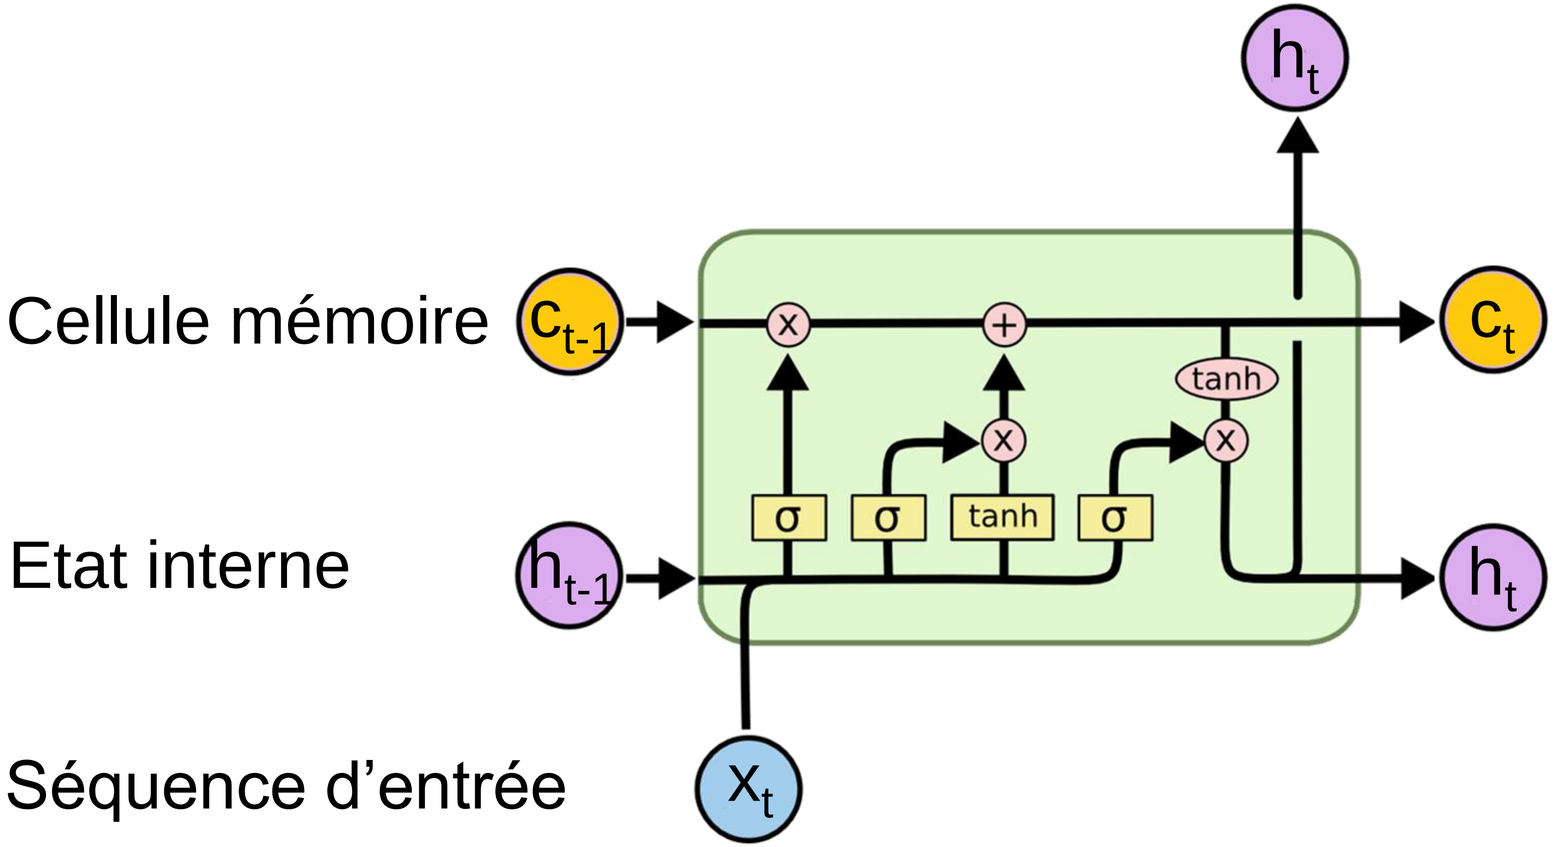

Image from Christopher Olah's blog

Hochreiter et al., *Long short-term memory*, Neural Computation 1997

LSTM pas à pas

La cellule mémoire

- Le point clé de la LSTM est sa cellule mémoire.
  - Très peu d'opérations dessus.
  - L'information peut passer très facilement.

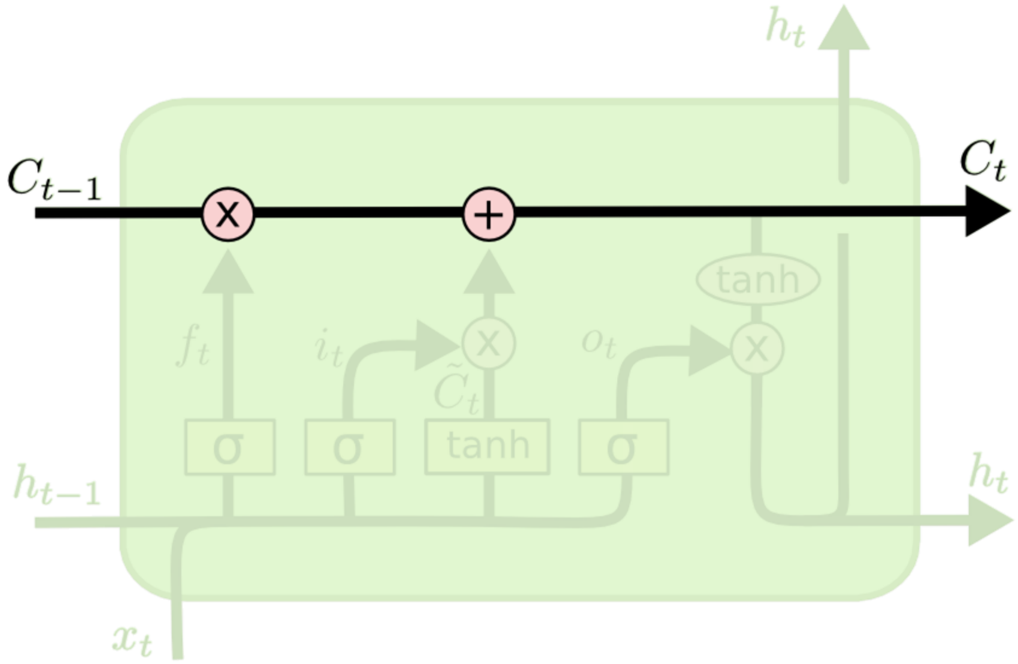

Image from Christopher Olah's blog

LSTM pas à pas

Calcul de la forget gate

- Calcul de la forget gate à partir de x_t et h_{t-1}.
  - $f_t = \sigma(U_f x_t + W_f h_{t-1} + b_f)$
  - σ est la fonction sigmoïde (bornée entre 0 et 1).

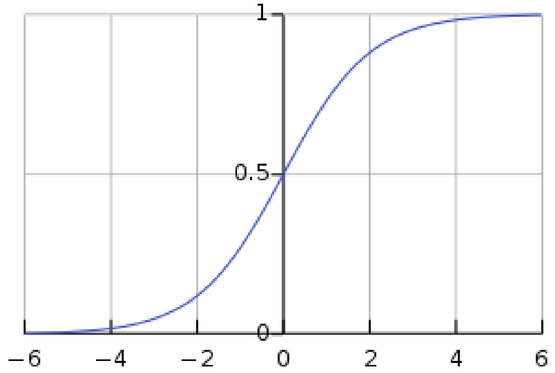

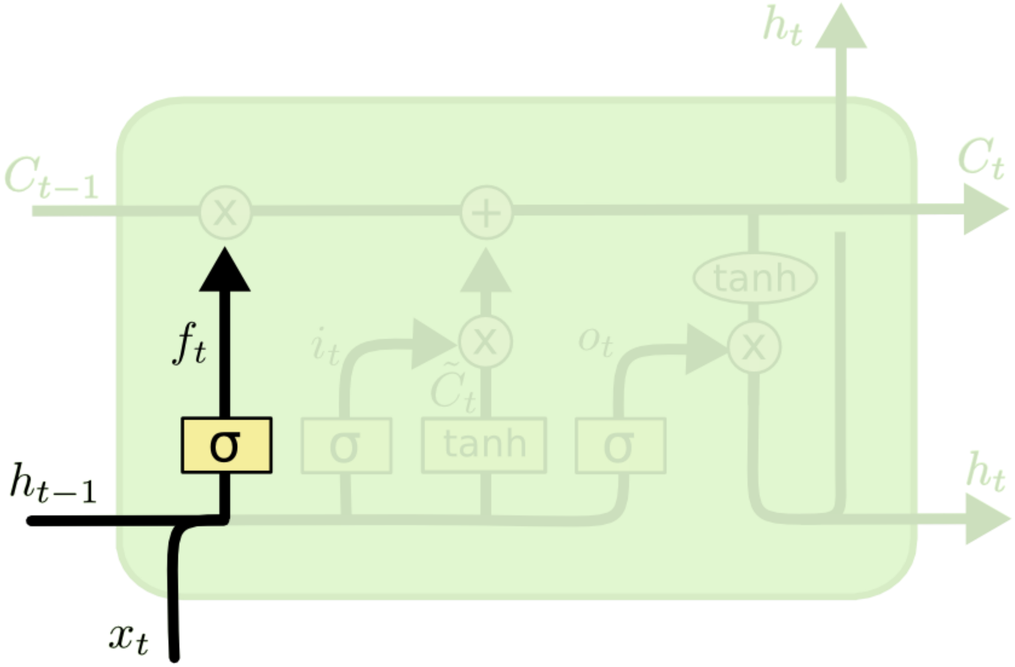

Image from Christopher Olah's blog

LSTM pas à pas

Calcul de la forget gate (2)

- Calcul de la forget gate à partir de x_t et h_{t-1}.
  - $f_t = \sigma(U_f x_t + W_f h_{t-1} + b_f)$
  - σ est la fonction sigmoïde
  - La forget gate permet d'oublier ce qui est présent dans la cellule mémoire.

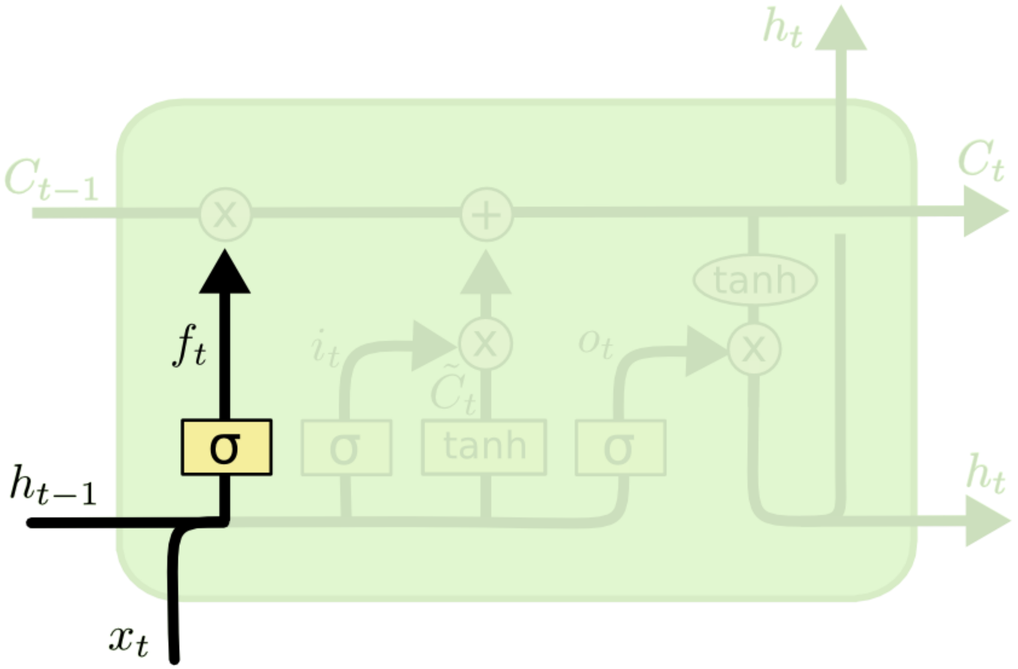

Image from Christopher Olah's blog

LSTM pas à pas

Calcul de l'input gate et du cell candidate

- Calcul de l'input gate à partir de x_t et h_{t-1}.
  - $i_t = \sigma(U_i x_t + W_i h_{t-1} + b_i)$
  - L'input gate contrôle ce qui entre dans la cellule mémoire.
- Calcul de ce qui va être ajouté à la cellule mémoire.
  - $g_t = \tanh(U_g x_t + W_g h_{t-1} + b_g)$

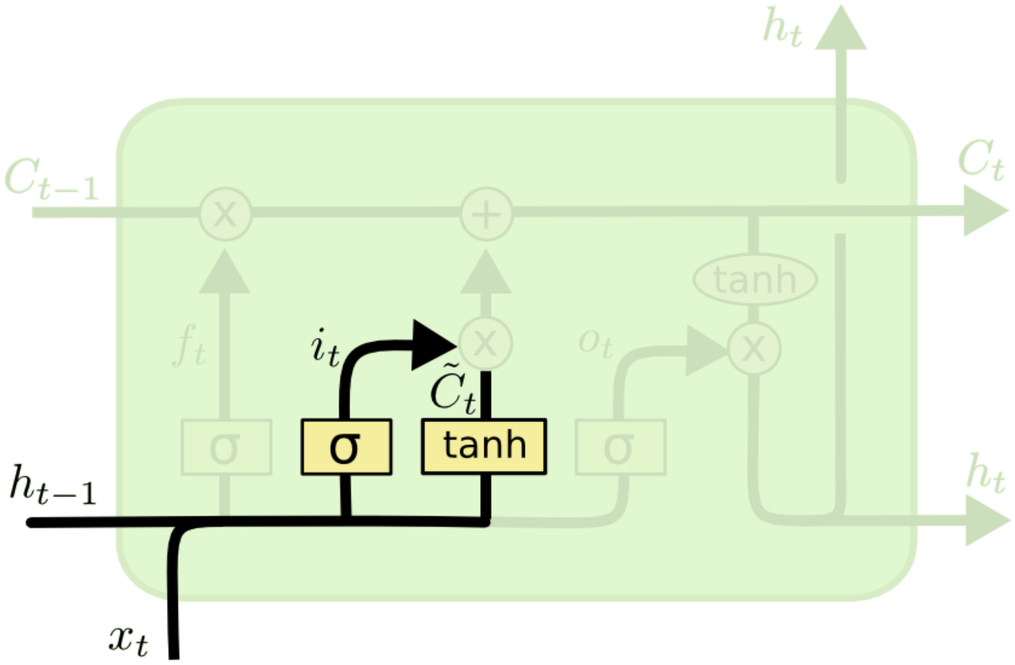

Image from Christopher Olah's blog

LSTM pas à pas

Calcul de la cellule mémoire

- Mise à jour de la cellule mémoire à l'aide de l'input et de la forget gate.
  - $c_t = i_t \odot g_t + f_t \odot c_{t-1}$
  - $\odot$ = multiplication terme à terme.
  - L'input gate permet d'ajouter de l'information dans la cellule, et la forget gate permet d'oublier l'information déjà présente dans la cellule.

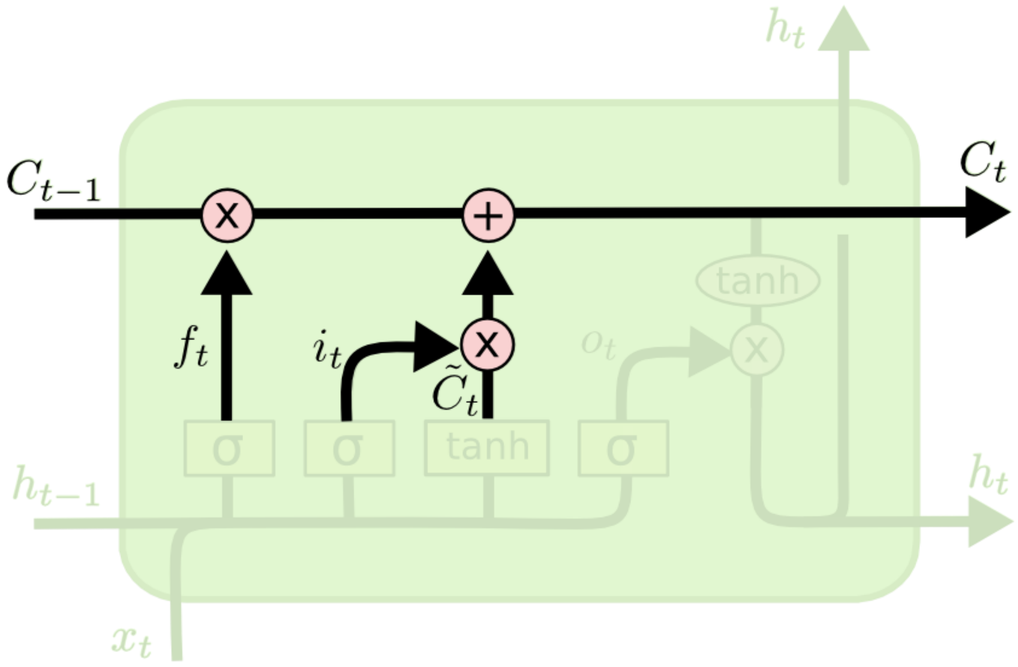

Image from Christopher Olah's blog

LSTM pas à pas

Calcul de l'output gate et de la séquence de sortie

- Calcul de l'output gate à partir de x_t et h_{t-1}.
  - $o_t = \sigma(U_o x_t + W_o h_{t-1} + b_o)$
  - L'output gate contrôle ce qui sort de la cellule mémoire.
- Calcul de l'état interne.
  - $h_t = o_t \odot \tanh(c_t)$

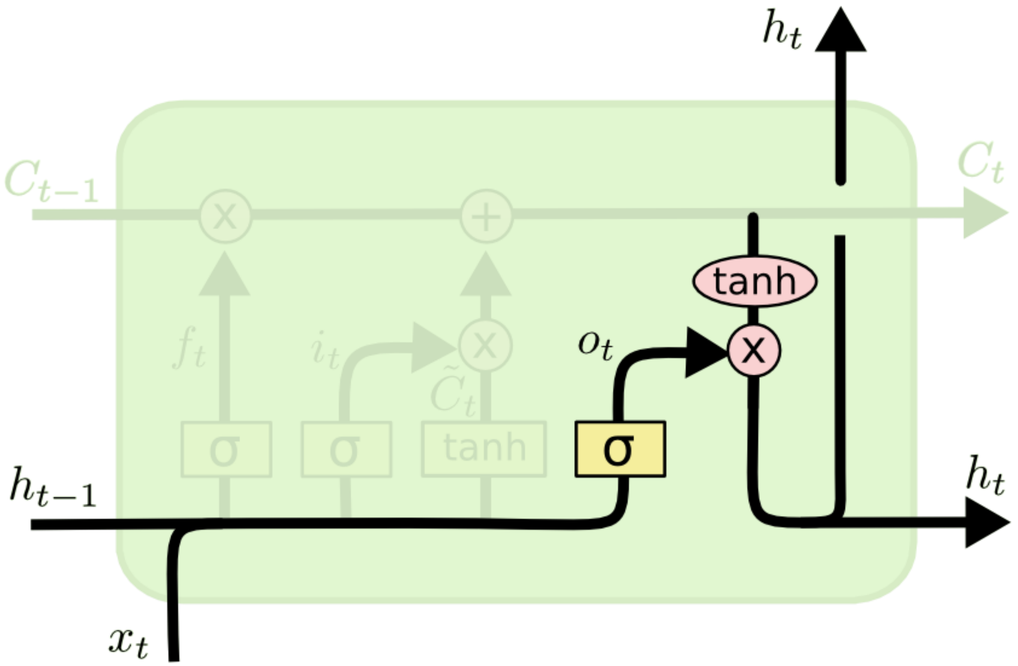

Image from Christopher Olah's blog

Long Short-Term Memory (LSTM)

En entier

Réduction du probème de disspation avec **un méchanisme de gates** et une **cellule mémoire**.

$$
\begin{aligned}
i_t &= \sigma(U_i x_t + W_i h_{t-1} + b_i) \\
f_t &= \sigma(U_f x_t + W_f h_{t-1} + b_f) \\
o_t &= \sigma(U_o x_t + W_o h_{t-1} + b_o) \\
g_t &= \tanh(U_g x_t + W_g h_{t-1} + b_g) \\
c_t &= i_t \odot g_t + f_t \odot c_{t-1} \\
h_t &= o_t \odot \tanh(c_t)
\end{aligned}
$$

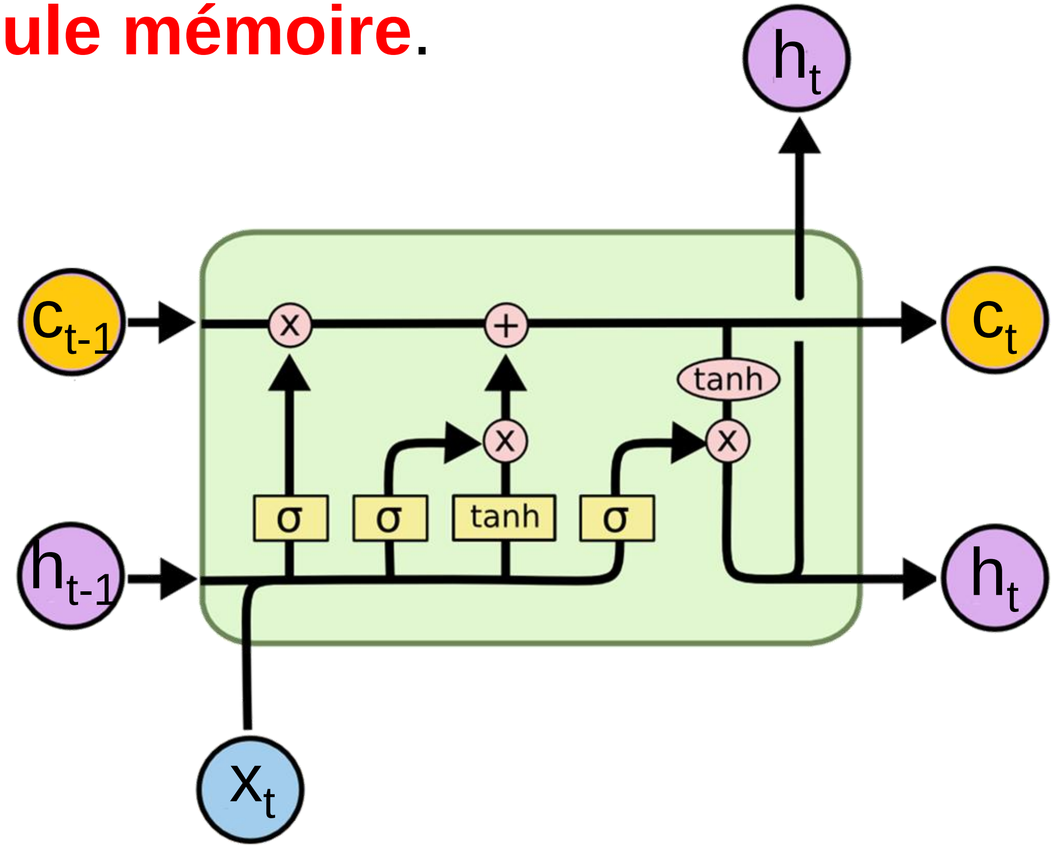

Image from Christopher Olah's blog

Hochreiter et al., *Long short-term memory*, Neural Computation 1997

Gated Recurrent Unit (GRU)

Aperçu

- Une variante populaire de la LSTM.
  - Pas de cellule mémoire explicite.
  - Input et forget gates combinées.
- En pratique, performances égales à la LSTM.
  - Plus rapide à calculer.

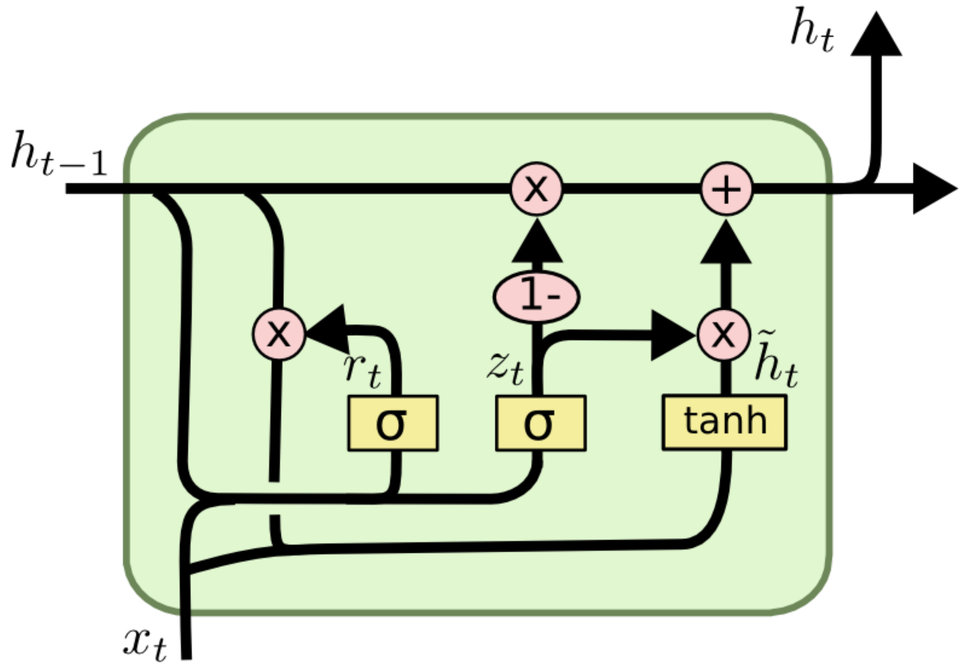

$$z_t = \sigma(U_z x_t + W_z h_{t-1} + b_z)$$
$$r_t = \sigma(U_r x_t + W_r h_{t-1} + b_r)$$
$$g_t = \tanh(U_g x_t + W_g(r_t \odot h_{t-1}) + b_g)$$
$$h_t = z_t \odot g_t + (1 - z_t) \odot h_{t-1}$$

Image from Christopher Olah's blog

Chung et al.: *Empirical Evaluation of Gated Recurrent Neural Networks on Sequence Modeling*

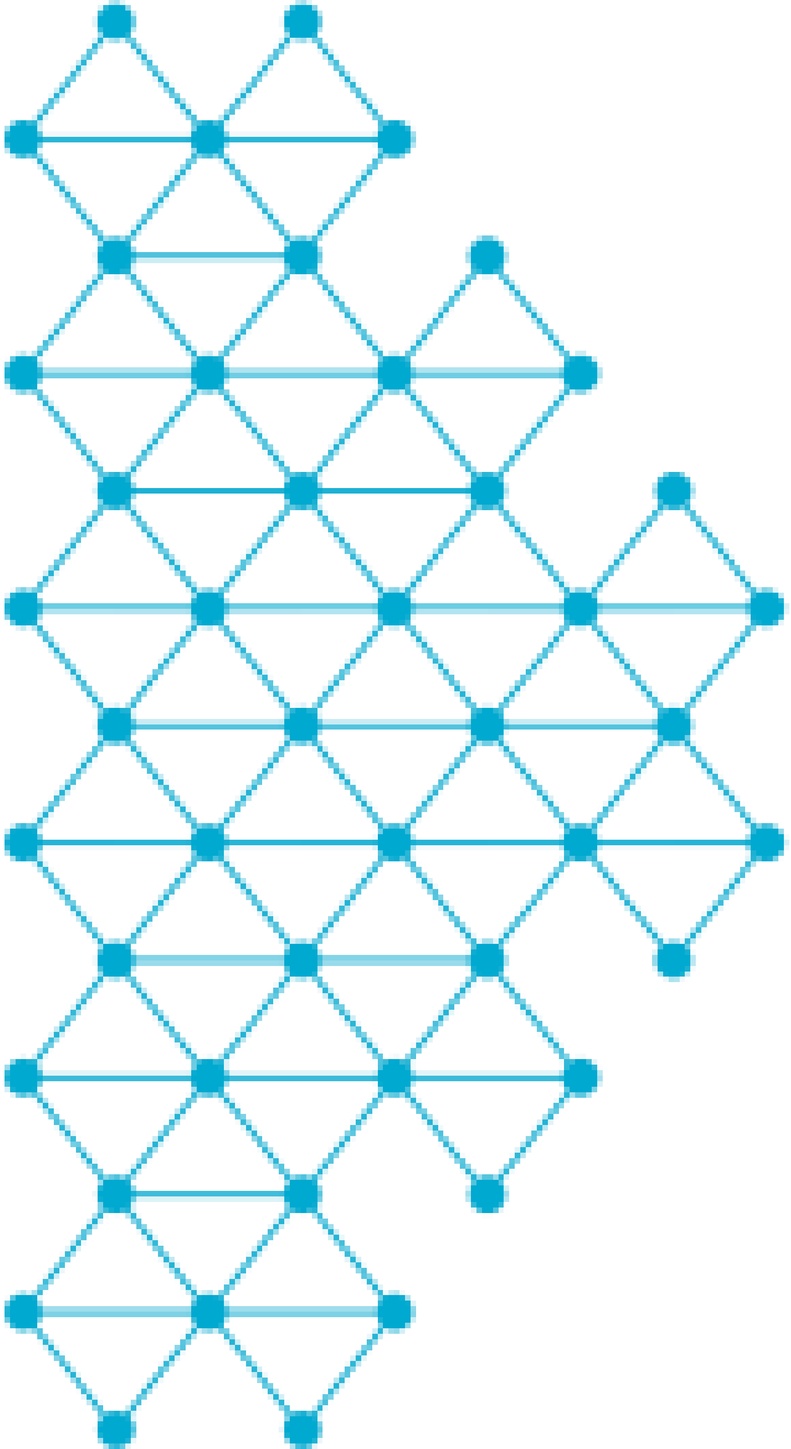

1. **Motivation**
2. **Introduction aux RNNs**
3. **Entraînement des RNNs**
4. **Difficultés d’apprentissage**
5. **Architectures de RNNs**
6. **RNNs Profonds**

Piles de Réseaux Récurrents

- Pour créer des RNNs profonds, on peut empiler des couches
  - Chaque RNN peut être un RNN simple, une LSTM, GRU,…
- La séquence de sortie de la première couche est la séquence d'entrée de la seconde couche, etc.

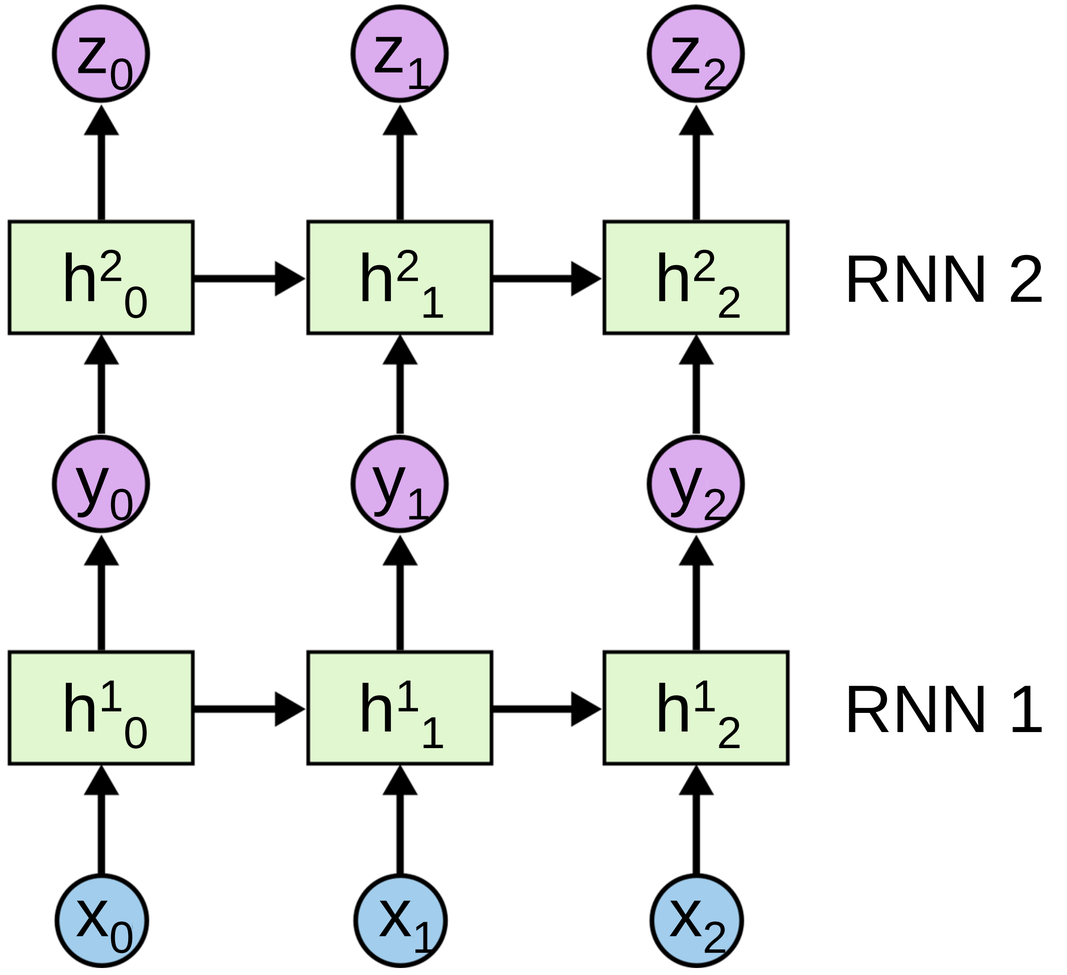

Réseaux Récurrents Bidirectionnels

- Ajout d'un second RNN qui lit la séquence à l'envers.
- Permet d'avoir de l'information sur ce qui se passe avant **et** après.
- Les 2 RNNs sont différents (paramètres différents)!

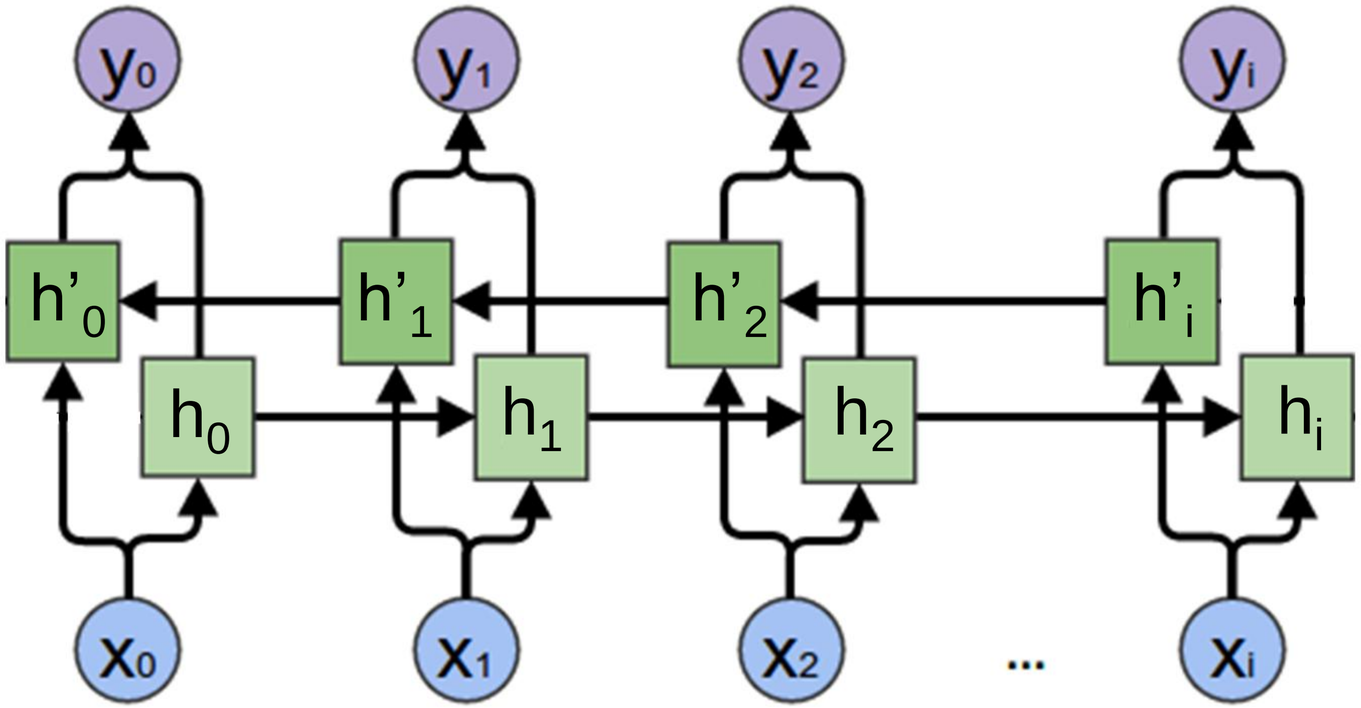

Image from Christopher Olah's blog

Reconnaissance de la Parole

Description des données

Enregistrement brut

Entrée: Spectrogramme

Cible: 39 *Phonèmes*

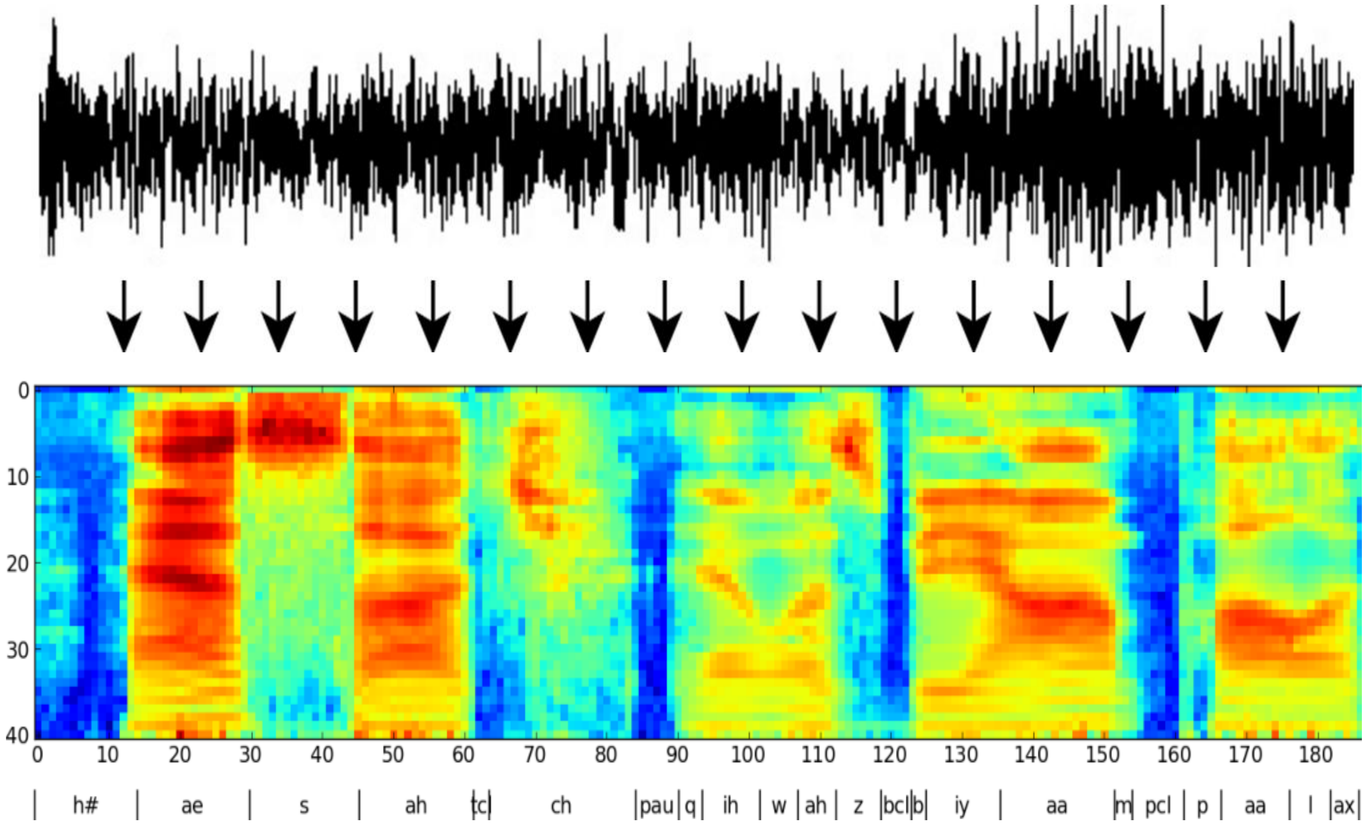

Phonèmes: *Plus petite unité que l'on peut isoler dans de la parole.*

Graves et al., *Speech Recognition with Deep Recurrent Neural Networks*, 2013

Reconnaissance de la Parole

Modèle

Enregistrement brut

Entrée: Spectrogramme

LSTM bidirectionnels (3)

Prédictions

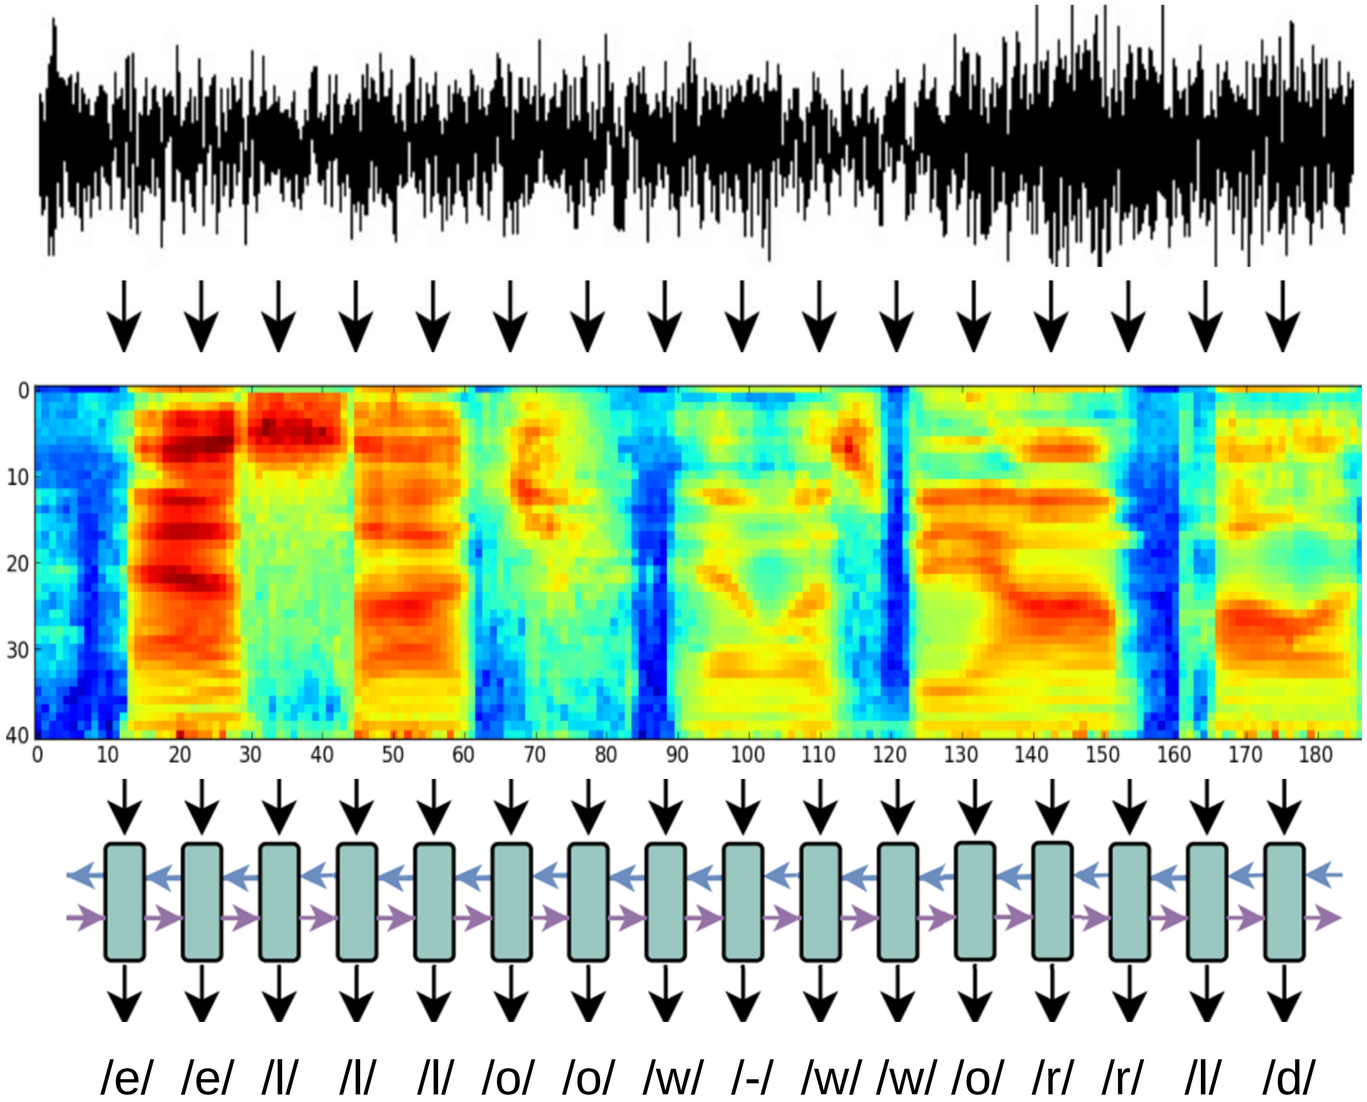

Graves et al., *Speech Recognition with Deep Recurrent Neural Networks*, 2013

Reconnaissance de la Parole

Code


```
from keras.models import Sequential
from keras.layers import Dense, LSTM, Merge

# First Layer
fwd1 = Sequential()
fwd1.add(LSTM(250, return_sequence=True))
bwd1 = Sequential()
bwd1.add(LSTM(250, return_sequence=True, go_backwards=True))

# Second Layer
fwd2 = Sequential()
fwd2.add(LSTM(250, return_sequence=True))
bwd2 = Sequential()
bwd2.add(LSTM(250, return_sequence=True, go_backwards=True))

# Model
model = Sequential()
model.add(Merge([fwd1, bwd1], mode='sum'))
model.add(Merge([fwd2, bwd2], mode='sum'))
model.add(Dense(39, activation='softmax'))
model.compile(loss='categorical_crossentropy',
              optimizer='sgd',
              metrics=['accuracy'])
```

Reconnaissance de la Parole

Résultats

Modèle	# Paramètres	Taux d'erreur
Tanh – 3 L (500 unités)	3.7 M	37.6 %
LSTM – 1 L (250 unités)	0.8 M	23.9 %
LSTM – 1 L (622 unités)	3.8 M	23.0 %
LSTM – 3 L (250 unités)	3.8 M	**18.6** %
LSTM – 3 L (421 unités) – Unidir.	3.8 M	19.6 %

- 1 couche de LSTM est meilleure 3 couches de RNN Simple (Tanh) !
- 3 couches de LSTM sont meilleures que 1 couche de LSTM !
- Des couches bidirectionnelles augmentent les performances !

Graves et al., *Speech Recognition with Deep Recurrent Neural Networks*, 2013

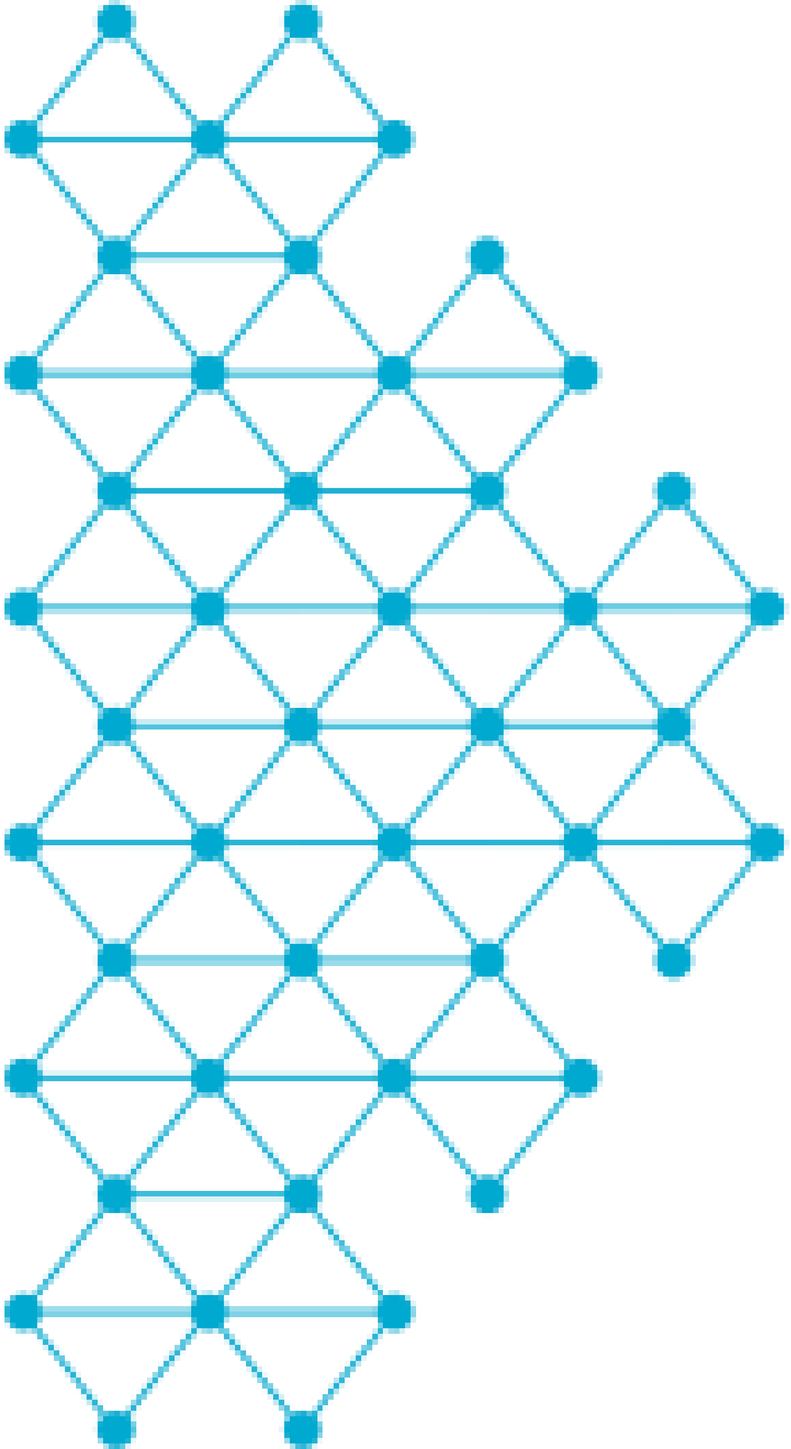

1. **Motivation**
2. **Introduction aux RNNs**
3. **Entraînement des RNNs**
4. **Difficultés d’apprentissage**
5. **Architectures de RNNs**
6. **RNNs Profonds**

QUESTIONS ?

Rajout de zéros

Introduction

Comment faire des mini-lots (mini-batches) avec des séquences de tailles différentes?

- Rajouter des zéros à la fin des séquences (zero-padding)!

Dataset

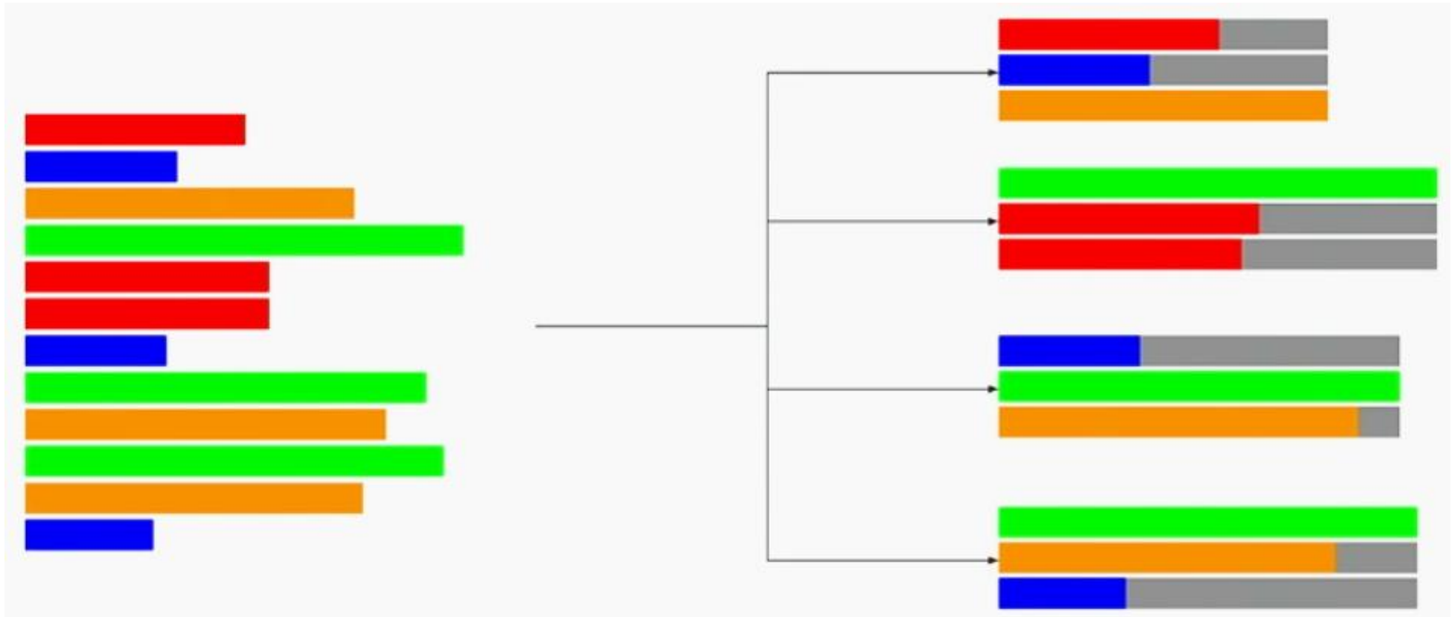

Mini-batches

Image from https://blog.altoros.com/the-magic-behind-google-translate-sequence-to-sequence-models-and-tensorflow.html

Rajout de zéros

Tailles très différentes

Comment faire des mini-lots (mini-batches) avec des séquences de taille différentes?

- Si les tailles sont très différentes, il peut être avantageux de trier les séquences!

Dataset

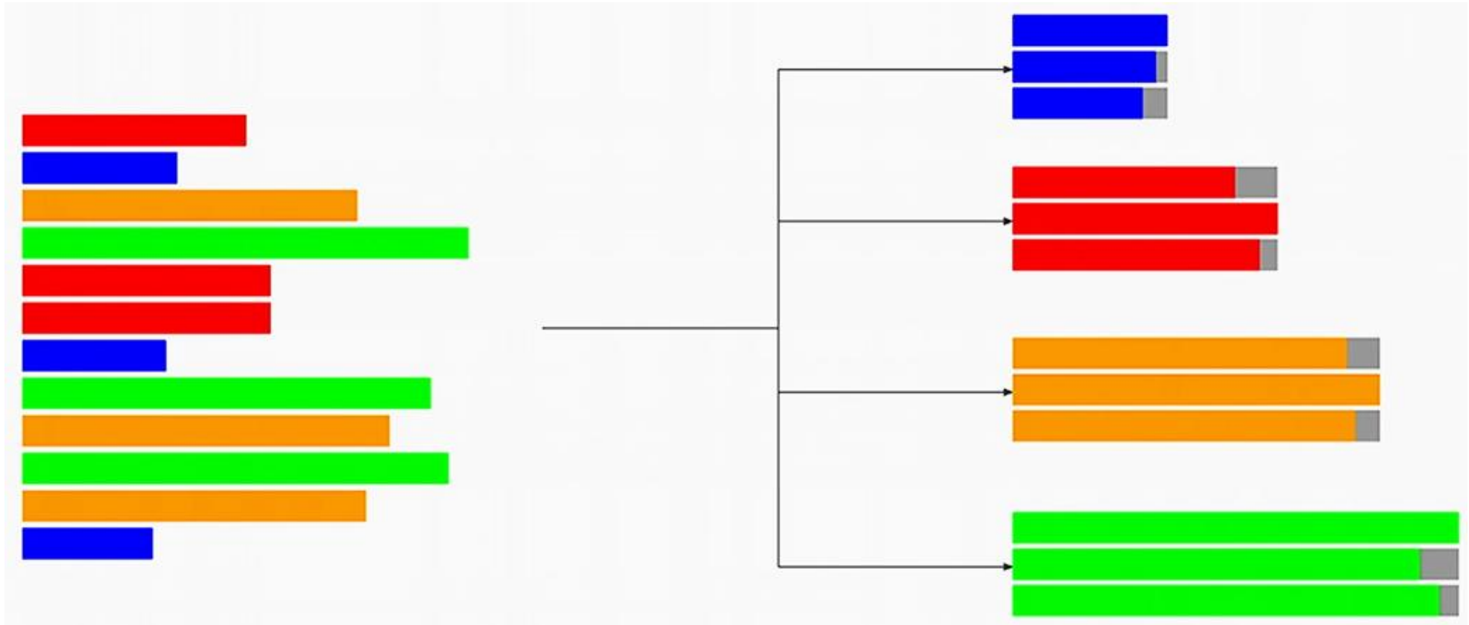

Mini-batches

Image from https://blog.altoros.com/the-magic-behind-google-translate-sequence-to-sequence-models-and-tensorflow.html