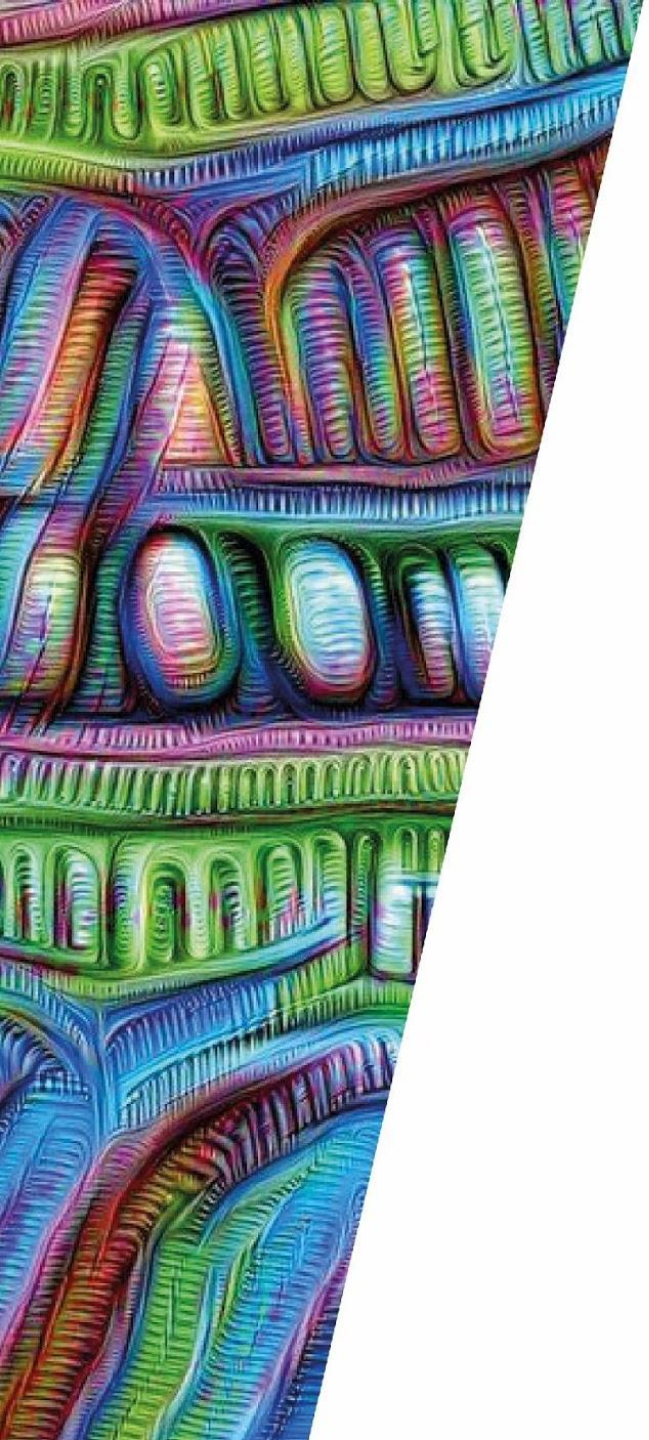

Bienvenue!

ÉCOLE D'ÉTÉ FRANCOPHONE EN APPRENTISSAGE PROFOND

21-25 août 2017

IVADO
HEC Montréal
Polytechnique Montréal
Université de Montréal

MILA

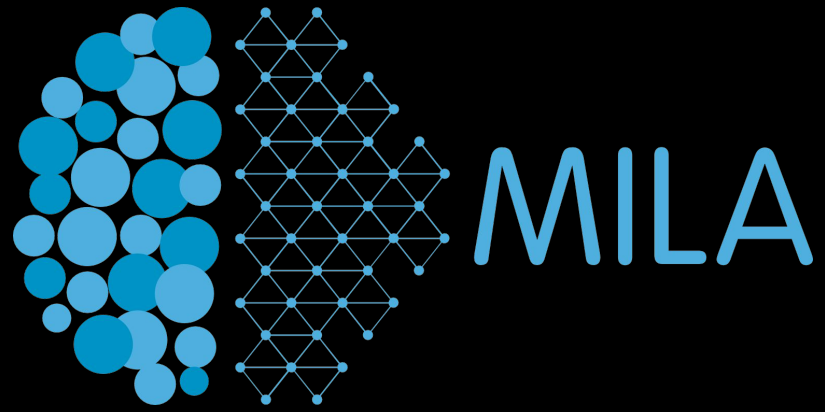

Conseils pratiques : entraînement et mise en oeuvre informatique

Guillaume Alain
guillaume.alain.umontreal@gmail.com

TL; DR

1. Acheter GPU Titan plus récent par nVidia.
2. Mettre dans un bon desktop correct avec Linux.
3. Utiliser des modèles préfabriqués en ligne.
4. Imiter le code des experts. S'inspirer sur github.
5. Vérifier qu'on obtient des outputs corrects. Sanity checks.
6. Bien organiser ses expériences. Éviter les fouillis.

Bonus : Ensemble de modèles pour classification.

Comment s’équiper pour faire du Deep Learning ?

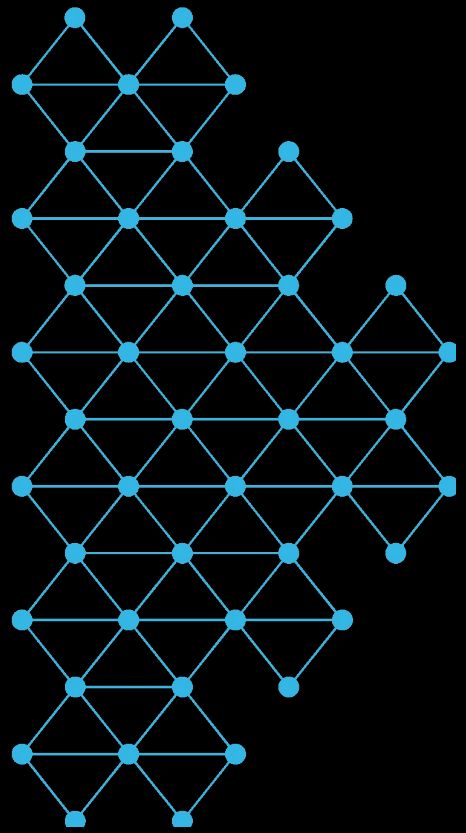

Graphical Processing Unit (GPU)

Accélérateur de calcul, avec sa propre mémoire vive (RAM), branché dans le port PCI-E sur la carte mère.

Possibilité de faire beaucoup d'opérations simples en parallèle.

- Faire des calculs sur beaucoup de triangles pour faire du rendu 3D.
- Multiplier des grosses matrices.

Graphical Processing Unit (GPU)

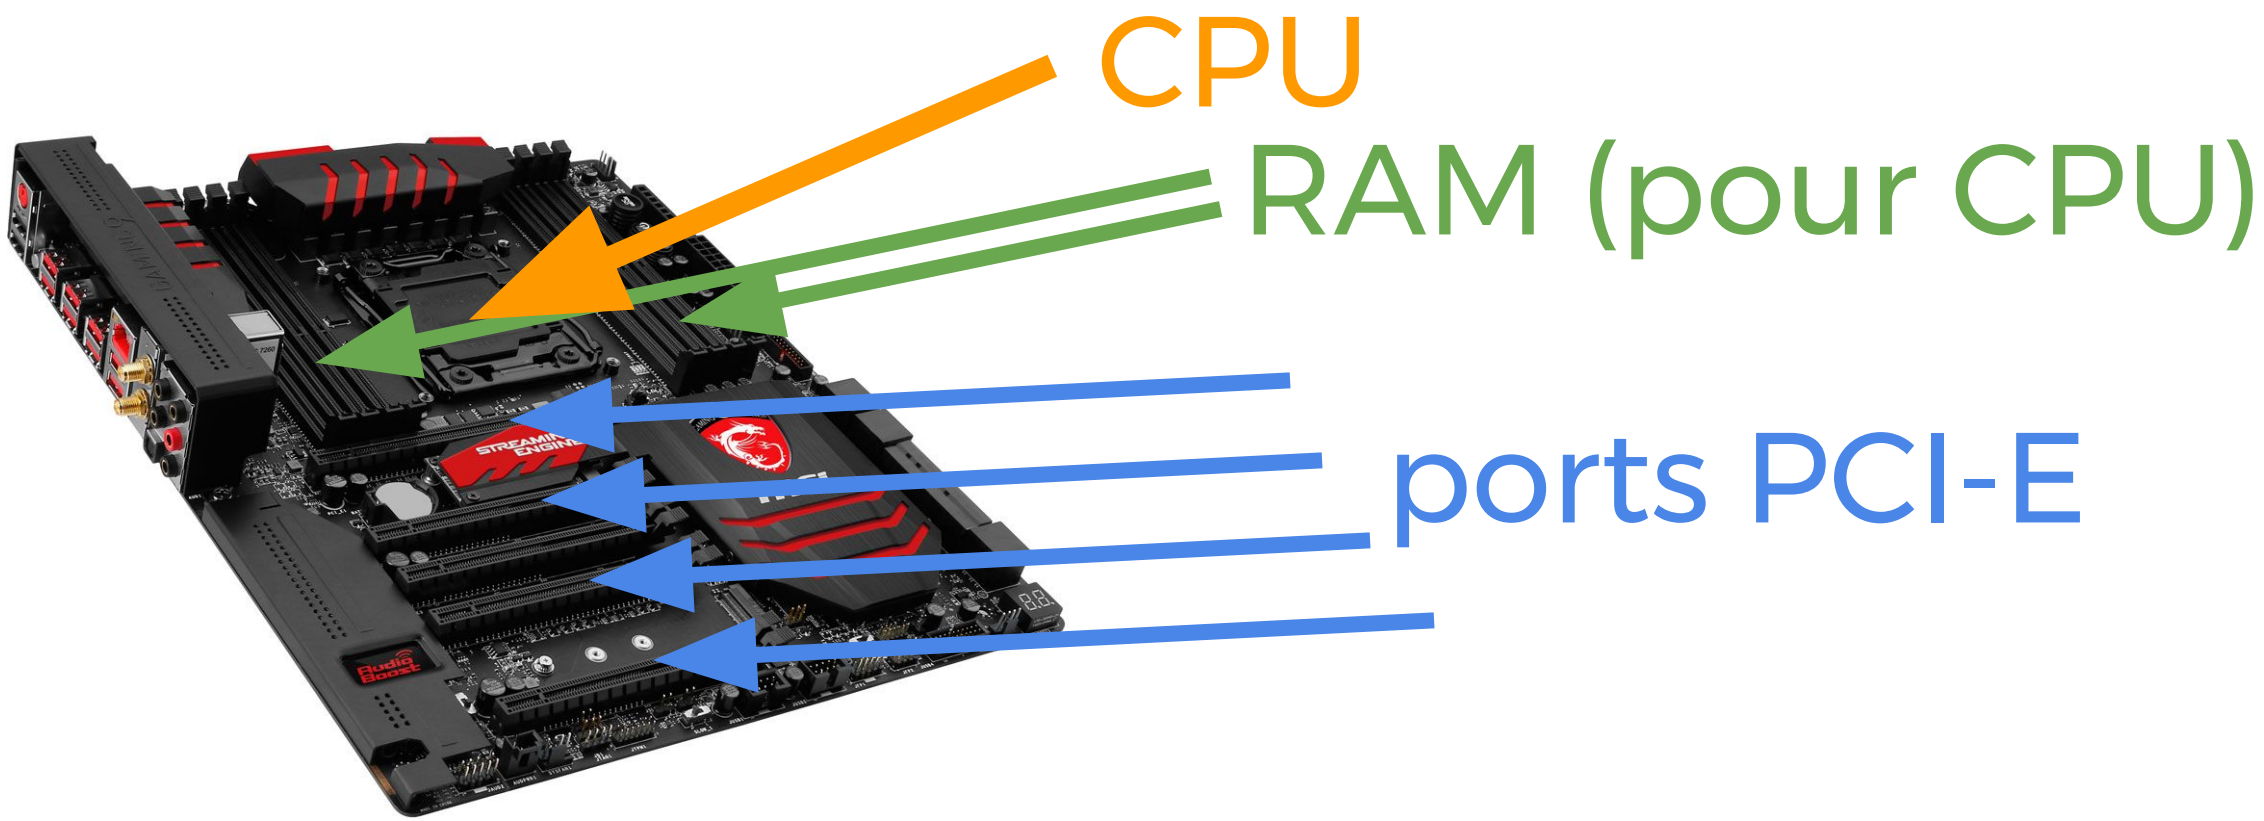

MILA

Graphical Processing Unit (GPU)

MILA

Graphical Processing Unit (GPU)

Le marché est complètement séparé entre deux compagnies.

- AMD (en rouge, noir, blanc) qui ont acheté ATI
- nVidia (en vert fluo, noir)

Pour les jeux vidéos, les deux s'équivalent approximativement.
(Allez sur reddit si vous voulez vous chicaner à ce sujet.)

Graphical Processing Unit (GPU)

nVidia ont décidé de faire un pari sur le deep learning en développant des librairies pour accélérer les opérations utiles pour les gens qui font de l'apprentissage profond.

Ils ont aussi du hardware spécifiquement conçu pour simplifier la vie des gens qui veulent faire du DL à grande échelle.

Présentement, le seul choix possible pour du DL c'est nVidia.

Graphical Processing Unit (GPU)

GPU pour “gamers”
GTX1050 (150 USD)
GTX1080Ti (700 USD)

GPU pour “calcul scientifique”
K20, K80
P40, P100 (~12 000 USD)

Machines pour clusters
DGX-1 (contient 8 x P100)
(~150 000 USD)

GTX Titan Xp (1200 USD)

Plus cher. Plus de mémoire. Plus “sérieux”.

MILA

Quelques solutions suggérées

La solution minimale correcte

- GTX Titan (récente) dans un desktop (possibilité de GTX1080)
- bon disque dur SSD
- disque dur d'extra avec quelques TB
- Linux (de préférence)
- un bon processeur quadcore (ex : i7)
- pas besoin de monstre Xeon 16 cores (argent mal dépensé)
- 32 GB de RAM (ou possiblement 64 GB, quoique pas prioritaire)

(Possibilité de mettre deux GPUs au besoin.
Comme peut-être deux GTX1080 pour le prix d'une GTX Titan.)

Source de courant

Une GTX Titan ça tire environ 250W.
Deux Titans + CPU ça donne environ 600-700W.

Il faut prévoir une marge de manoeuvre pour éviter d'avoir des ennuis. Personnellement j'utilise une Corsair RM1000 (~200$) pour deux gros GPUs et ça marche bien.

Mettre 4 GPUs dans une machine, c'est pas si difficile, mais ça demande une expertise que je n'ai pas.

Générations de GPU

Fermi < Kepler < Maxwell < Pascal < Volta

- Titan Black (Kepler)
- Titan X (Maxwell)
- Titan X (Pascal), aka “Titan Xp”

Personnellement, j’ai remarqué environ un facteur d’amélioration d’environ 1.5 - 2.0 de performance entre ces trois versions de Titans pour des tâches de classification d’images.

Donc, il faut bien s’informer en commandant son “titan”.

Performance CPU sans GPU

Personnellement, pour des tâches de classification d'images j'ai pu observer une différence d'environ 80x entre l'entraînement sur CPU et sur GPU.

C'est la différence entre

- ça roule pendant un mois
- ça roule cette nuit et c'est prêt demain matin

Sur certains modèles de NLP, la différence peut être d'un facteur de 2-4x. Les benchmarks les plus menteurs pourraient dire 200x dans les meilleurs cas. Disons que 20x c'est peut-être plus raisonnable.

Performance CPU sans GPU

Entraînement sur dataset de 1 million d'exemples.
On veut faire 10 passes sur le dataset au complet, à raison de 100 exemples par seconde (avec GPU).

	Entraînement	Évaluation sur 1000 images
 GPU	28 heures	10 secondes
 CPU	2216 heures (92 jours)	80 secondes (une minute)

Hardware Apple

Il n’existe pas de laptop Apple récent avec un GPU nVidia. Pas de desktop Apple non plus.

Les laptops Dell XPS ont une GTX1050.

Goulot d’étranglement

Il faut que le goulot d’étranglement (“bottleneck”) soit l’aspect computationnel du modèle d’apprentissage profond.

- Pas le chargement des données sur le disque dur.
- Pas la mémoire disponible pour stocker le modèle désiré sur GPU.

Taille minibatch	Temps pour une minibatch	Total exemples / seconde	Coût en mémoire
8	300 ms	~ 25	100 MB + 1000 MB
16	300 ms	~ 50	100 MB + 2000 MB
32	300 ms	~ 100	100 MB + 4000 MB
64	600 ms	~ 100	100 MB + 8000 MB

Solutions “cloud”

Google Cloud Platform

MILA


MILA

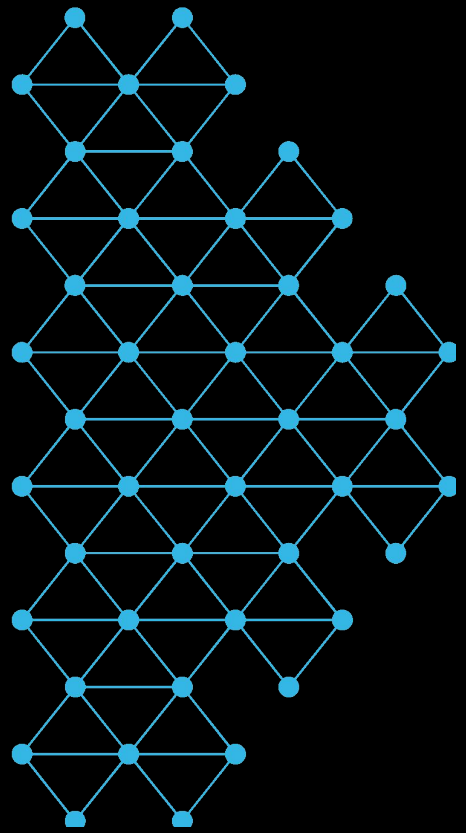

Rouler une expérience de DL

diagramme d'entraînement pour une instance de modèle

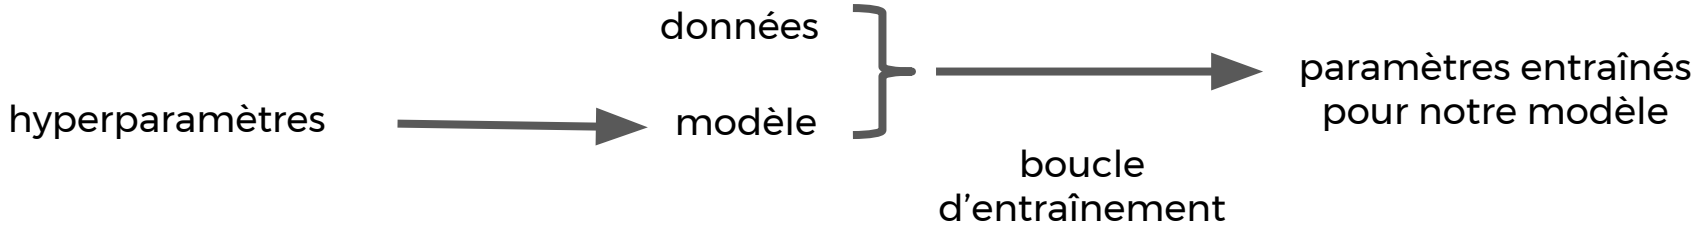

exploration d'hyperparamètres pour obtenir le meilleur modèle

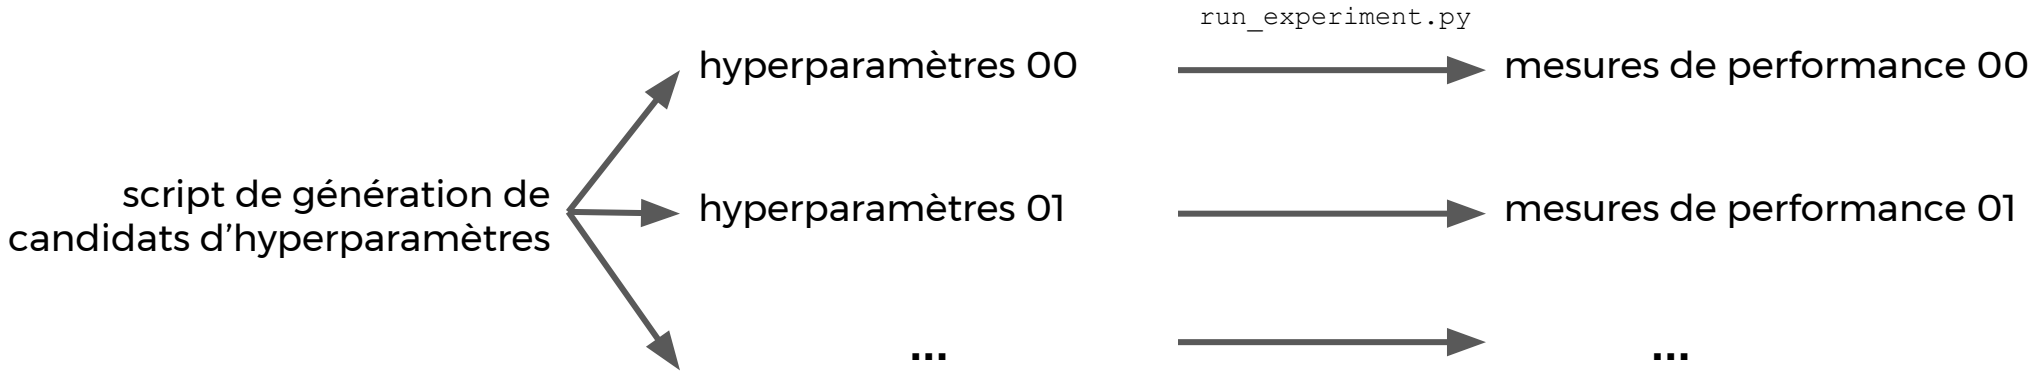

MILA

Quel est l'équivalent "deep learning" de ça ?

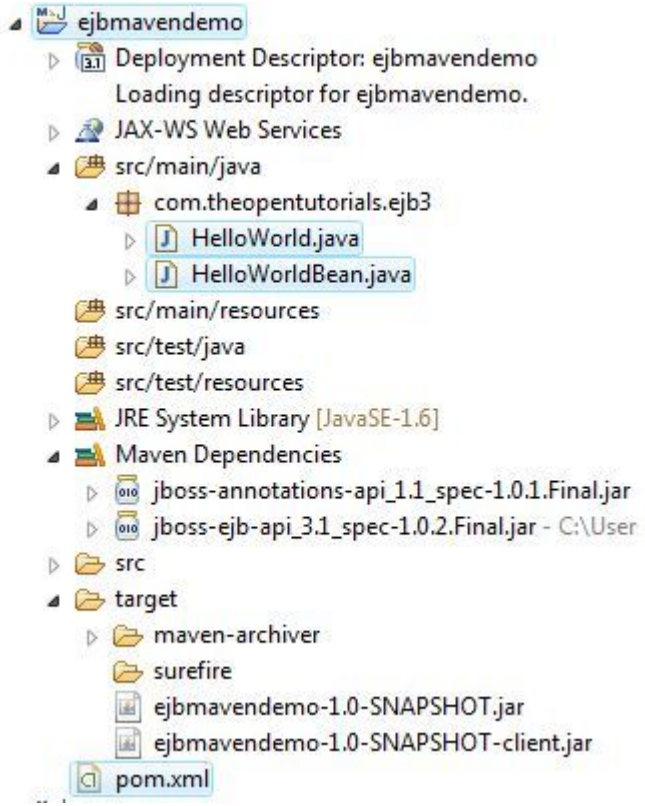

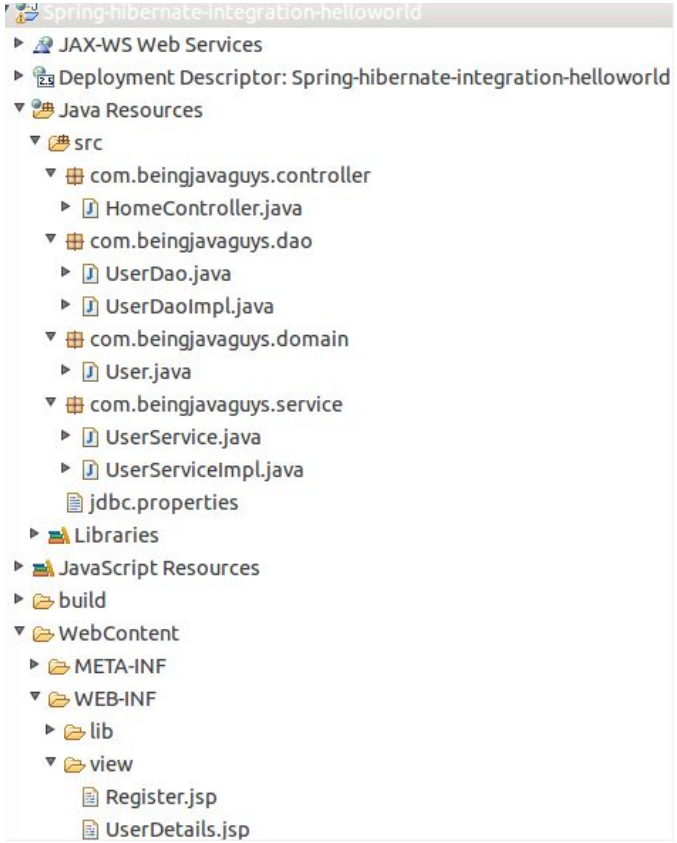

MILA

A Research to Engineering Workflow

by Dustin Tran
http://dustintran.com/blog/a-research-to-engineering-workflow

```
-- doc/
  -- 2017-nips/
    -- preamble/
    -- img/
    -- main.pdf
    -- main.tex
    -- introduction.tex
-- etc/
  -- 2017-03-25-whiteboard.jpg
  -- 2017-04-03-whiteboard.jpg
  -- 2017-04-06-dustin-comments.md
  -- 2017-04-08-dave-comments.pdf
-- src/
  -- checkpoints/
  -- codebase/
  -- log/
  -- out/
  -- script1.py
  -- script2.py
-- README.md
```

```
.
├── .gitignore
├── README
├── data
|   └── download.sh
├── hpsearch
|   ├── hyperband.py
|   └── randomsearch.py
├── main.py
├── models
|   ├── __init__.py
|   └── basic_model.py
├── results
|   └── .gitkeep
└── tests
```

TensorFlow: A proposal of good practices for files, folders and models architecture

https://blog.metaflow.fr/tensorflow-a-proposal-of-good-practices-for-files-folders-and-models-architecture-f23171501ae3

MILA

Conseil général :

Voir ce que les autres personnes font
et s'en servir comme inspiration.
Développer son propre style à partir de ça.

Aller aux conférences de DL/ML et potiner avec les chercheurs.


MILA

mise en oeuvre du modèle d’apprentissage profond

Réutiliser autant que possible des modèles déjà disponibles en ligne. Chercher pour “model zoo”.

Parfois on veut même utiliser un modèle pré-entraîné et s’éviter beaucoup de travail. Chercher pour “pretrained model” ou “pretrained model weights”.

mise en oeuvre du modèle d'apprentissage profond

github.com/tensorflow/models

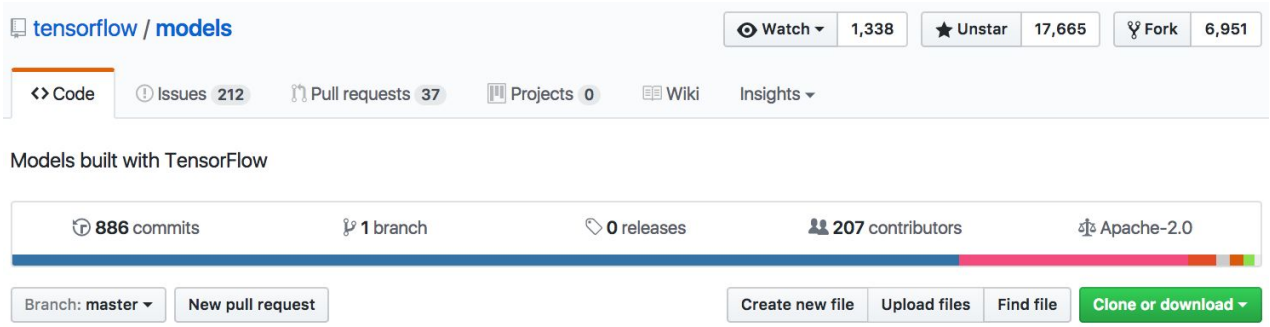

- alexnet.py
- alexnet_test.py
- cifarnet.py
- inception.py
- inception_resnet_v2.py
- inception_resnet_v2_test.py
- inception_utils.py
- inception_v1.py
- inception_v1_test.py
- inception_v2.py
- inception_v2_test.py
- inception_v3.py
- inception_v3_test.py
- inception_v4.py
- inception_v4_test.py
- lenet.py
- mobilenet_v1.md
- mobilenet_v1.png
- mobilenet_v1.py
- mobilenet_v1_test.py
- nets_factory.py
- nets_factory_test.py
- overfeat.py
- overfeat_test.py
- resnet_utils.py
- resnet_v1.py
- resnet_v1_test.py
- resnet_v2.py
- resnet_v2_test.py
- vgg.py
- vgg_test.py

MILA

mise en oeuvre du modèle d'apprentissage profond

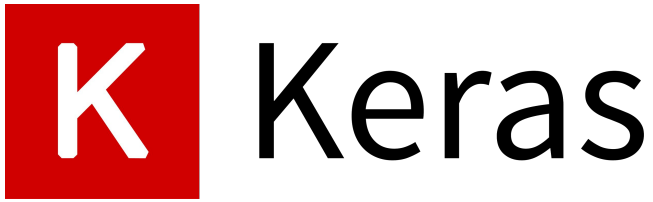

keras.io/applications

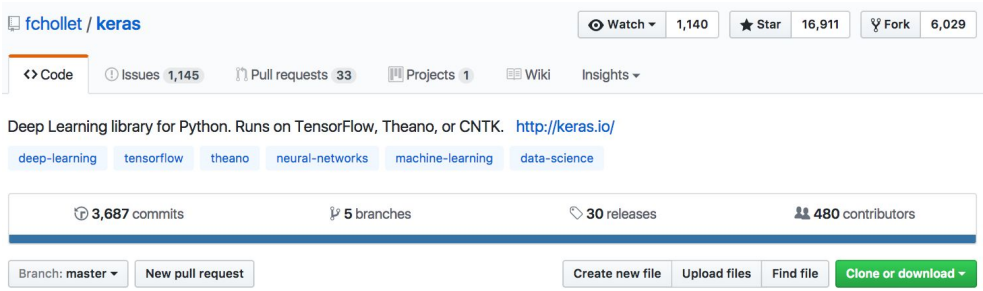

Classify ImageNet classes with ResNet50

```
from keras.applications.resnet50 import ResNet50
from keras.preprocessing import image
from keras.applications.resnet50 import preprocess_input, decode_predictions
import numpy as np

model = ResNet50(weights='imagenet')

img_path = 'elephant.jpg'
img = image.load_img(img_path, target_size=(224, 224))
x = image.img_to_array(img)
x = np.expand_dims(x, axis=0)
x = preprocess_input(x)

preds = model.predict(x)
# decode the results into a list of tuples (class, description, probability)
# (one such list for each sample in the batch)
print('Predicted:', decode_predictions(preds, top=3)[0])
# Predicted: [(u'n02504013', u'Indian_elephant', 0.82658225), (u'n01871265', u'
```

MILA

mise en oeuvre du modèle d'apprentissage profond

Caffe

github.com/BVLC/caffe/wiki/Model-Zoo

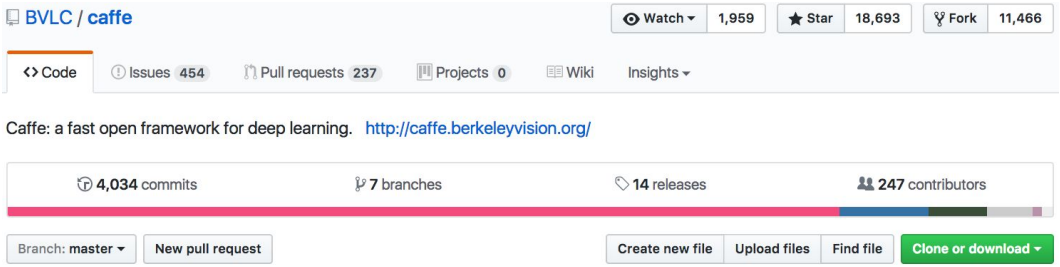

ResNets: Deep Residual Networks from MSRA at ImageNet and COCO 2015

This repository contains the original models (ResNet-50, ResNet-101, and ResNet-152) described in the paper "Deep Residual Learning for Image Recognition" (http://arxiv.org/abs/1512.03385). These models are those used in [ILSVRC] (http://image-net.org/challenges/LSVRC/2015/) and COCO 2015 competitions, which won the 1st places in: ImageNet classification, ImageNet detection, ImageNet localization, COCO detection, and COCO segmentation.

More instructions with prototxt and binary weight files are in: https://github.com/KaimingHe/deep-residual-networks

Reference:

```
@article{He2015,
        author = {Kaiming He and Xiangyu Zhang and Shaoqing Ren and Jian Sun},
        title = {Deep Residual Learning for Image Recognition},
        journal = {arXiv preprint arXiv:1512.03385},
        year = {2015}
}
```

MILA

mise en oeuvre du modèle d'apprentissage profond

```
from resnet50 import ResNet50
from keras.preprocessing import image
from imagenet_utils import preprocess_input,
decode_predictions

model = ResNet50(weights='imagenet')

img_path = 'elephant.jpg'
img = image.load_img(img_path, target_size=(224, 224))
x = image.img_to_array(img)
x = np.expand_dims(x, axis=0)
x = preprocess_input(x)

preds = model.predict(x)
print('Predicted:', decode_predictions(preds))
# print: [[u'n02504458', u'African_elephant']]
```

mise en oeuvre du modèle d'apprentissage profond

```
from resnet50 import ResNet50
from keras.preprocessing import image
from imagenet_utils import preprocess_input,
decode_predictions

model = ResNet50(weights='imagenet')

img_path = 'elephant.jpg'
img = image.load_img(img_path, target_size=(224, 224))
x = image.img_to_array(img)
x = np.expand_dims(x, axis=0)
x = preprocess_input(x)

preds = model.predict(x)
print('Predicted:', decode_predictions(preds))
# print: [[u'n02504458', u'African_elephant']]
```

```
def preprocess_input(x, data_format=None):

    if data_format == 'channels_first':
        # 'RGB'->'BGR'
        x = x[:, ::-1, :, :]
        # Zero-center by mean pixel
        x[:, 0, :, :] -= 103.939
        x[:, 1, :, :] -= 116.779
        x[:, 2, :, :] -= 123.68
    else:
        # 'RGB'->'BGR'
        x = x[:, :, :, ::-1]
        # Zero-center by mean pixel
        x[:, :, :, 0] -= 103.939
        x[:, :, :, 1] -= 116.779
        x[:, :, :, 2] -= 123.68
    return x
```

mise en oeuvre du modèle d'apprentissage profond

Machine Learning: The High-Interest Credit Card of Technical Debt

D. Sculley, Gary Holt, Daniel Golovin, Eugene Davydov,
Todd Phillips, Dietmar Ebner, Vinay Chaudhary, Michael Young
{dsculley,gholt,dgg,edavydov}@google.com
{toddphillips,ebner,vchaudhary,mwyoung}@google.com
Google, Inc

Abstract

Machine learning offers a fantastically powerful toolkit for building complex systems quickly. This paper argues that it is dangerous to think of these quick wins as coming for free. Using the framework of *technical debt*, we note that it is remarkably easy to incur massive ongoing maintenance costs at the system level when applying machine learning. The goal of this paper is highlight several machine learning specific risk factors and design patterns to be avoided or refactored where possible. These include boundary erosion, entanglement, hidden feedback loops, undeclared consumers, data dependencies, changes in the external world, and a variety of system-level anti-patterns.

MILA


MILA

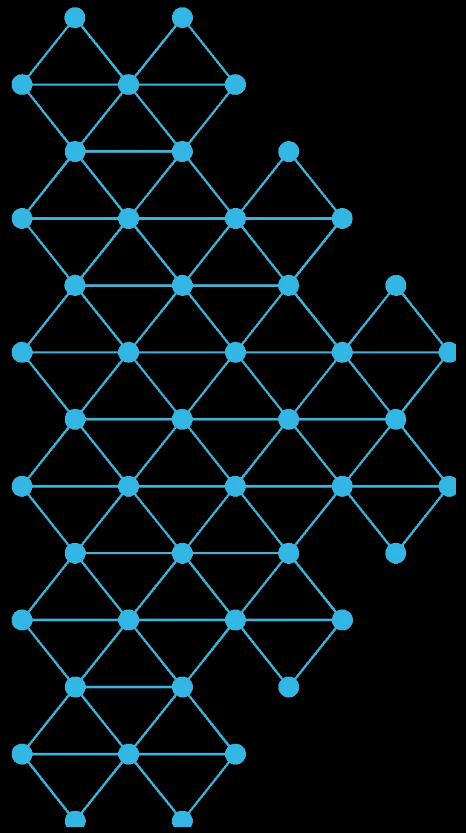

Exploration d’hyperparamètres

exploration d'hyperparamètres pour obtenir le meilleur modèle

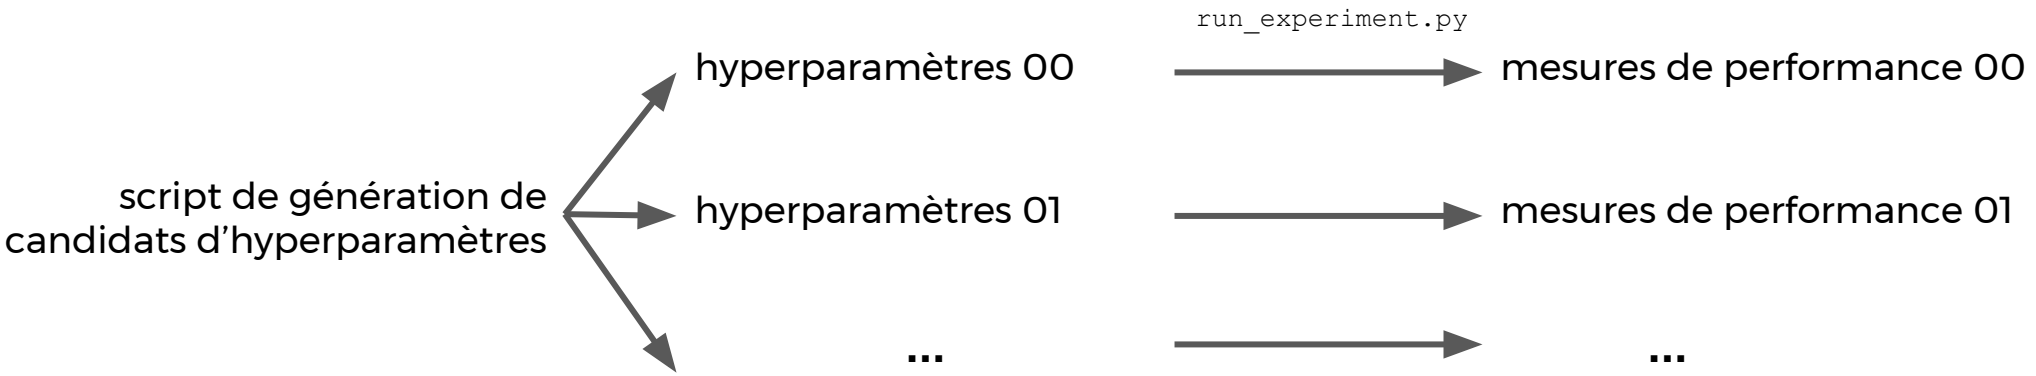

Chaque expérience doit produire assez de logs pour

- diagnostiquer les erreurs et les comportements louches
- permettre de sélectionner celle qu'on considère comme la plus propice à mieux généraliser à des données nouvelles

Tensorboard vient avec Tensorflow. Pour s'en servir, il faut utiliser les "summaries" en Tensorflow.

```
batch_loss = tf.nn.softmax_cross_entropy_with_logits(...)
loss = tf.reduce_mean(batch_loss)
batch_accuracy = ...
accuracy = tf.reduce_mean(tf.cast(batch_accuracy, "float"))

tf.summary.scalar("train/loss", loss)
tf.summary.scalar("train/accuracy", accuracy)
```

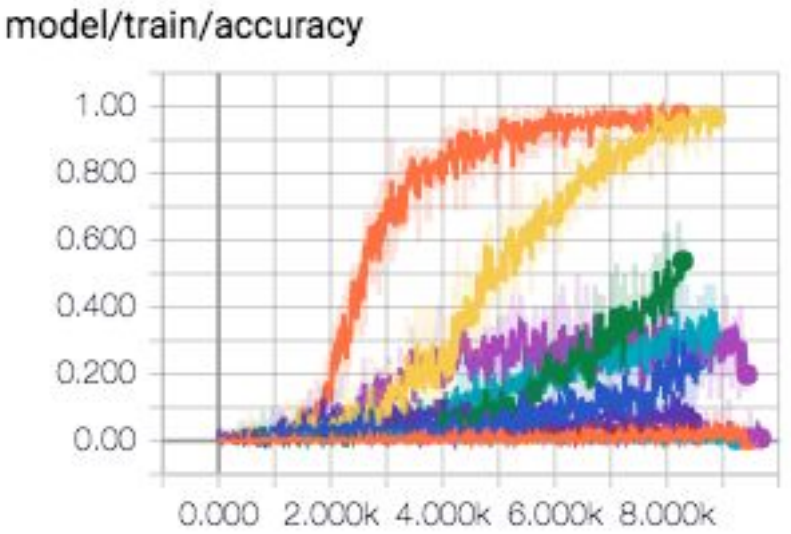

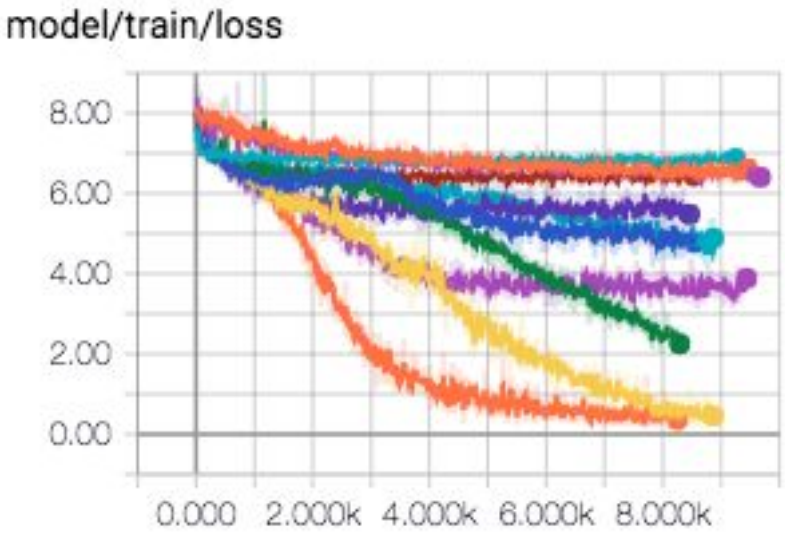

model/train/accuracy

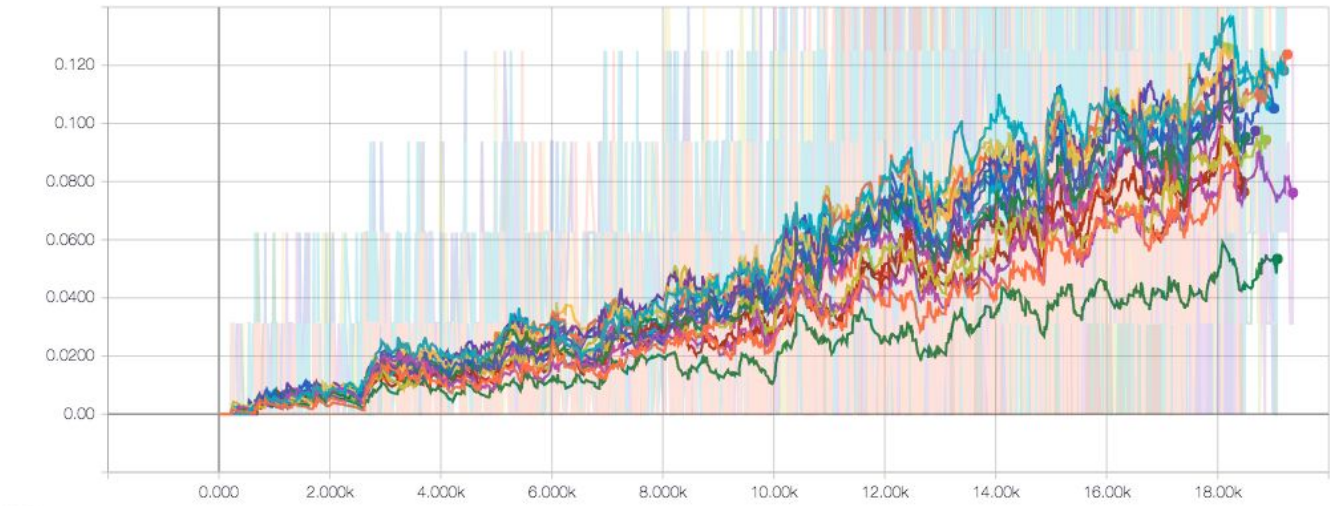

model/train/loss

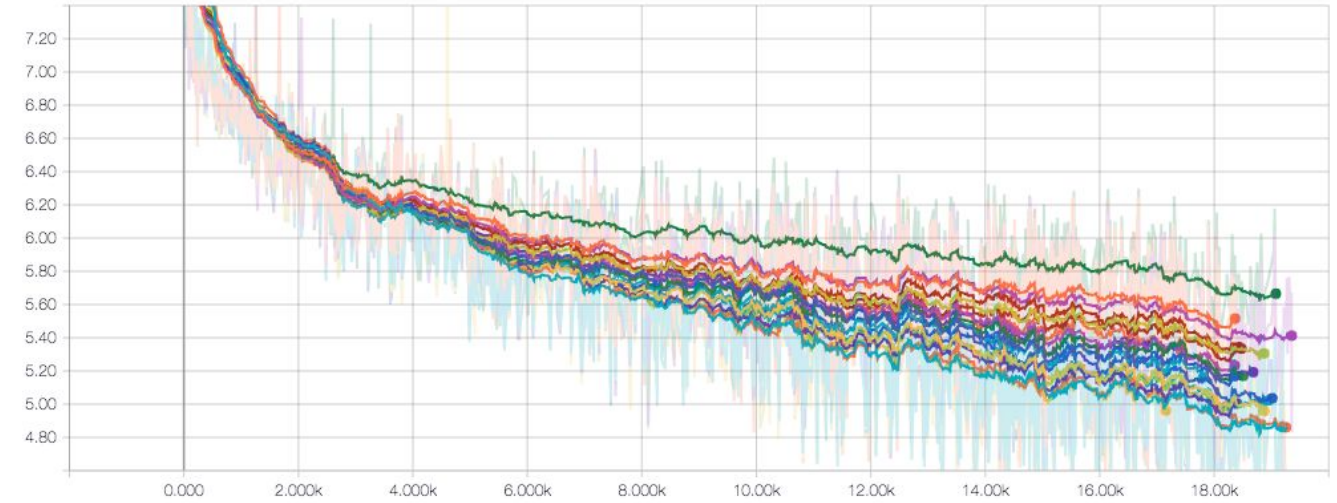

MILA

Conseil général :

Quand on roule plusieurs expériences à grande échelle, il faut être capable de générer de manière indépendante les graphiques qui affichent les résultats.

Une expérience est lancée

```
python performing_training.py --expdir=”experiment_000”
```

et après 10 heures de calculs elle génère un graphique

```
experiment_000/loss_over_training_epochs.png
```

Conseil général :

Quand on roule plusieurs expériences à grande échelle, il faut être capable de générer de manière indépendante les graphiques qui affichent les résultats.

Une expérience est lancée

```
python performing_training.py --expdir="experiment_000"
```

et après 10 heures de calculs elle génère un graphique

```
experiment_000/loss_over_training_epochs.png
```

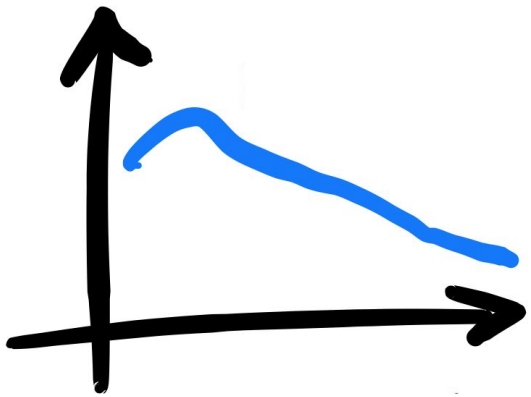

Conseil général :

Quand on roule plusieurs expériences à grande échelle, il faut être capable de générer de manière indépendante les graphiques qui affichent les résultats.

Une expérience est lancée

```
python performing_training.py --expdir="experiment_000"
```

et après 10 heures de calculs elle génère un graphique

```
experiment_000/loss_over_training_epochs.png
```

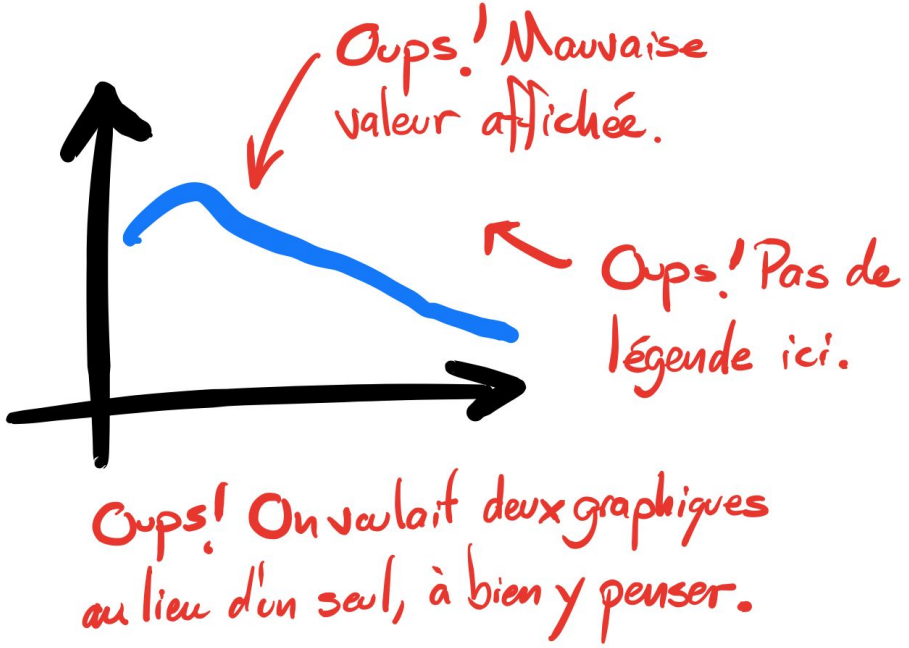

Conseil général :

Une expérience qui peut être interrompue en plein milieu puis relancée sans être affectée par l'interruption, c'est beaucoup plus facile à gérer.

```
with tf.Session(
    config=tf.ConfigProto(
        log_device_placement=False,
        allow_soft_placement=True)
) as session:

    # Your code for the main loop here.
```

Pas facile à interrompre.

```
sv = tf.train.Supervisor(
    logdir=hparams.train_dir,
    init_op=init_op,
    summary_op=merged_summaries,
    saver=saver,
    global_step=global_step,
    save_model_secs=600)

with sv.managed_session(
    config=tf.ConfigProto(
        log_device_placement=False,
        allow_soft_placement=True)
    ) as session :

    # Your code for the main loop here.
```

Continuable automatiquement.


MILA

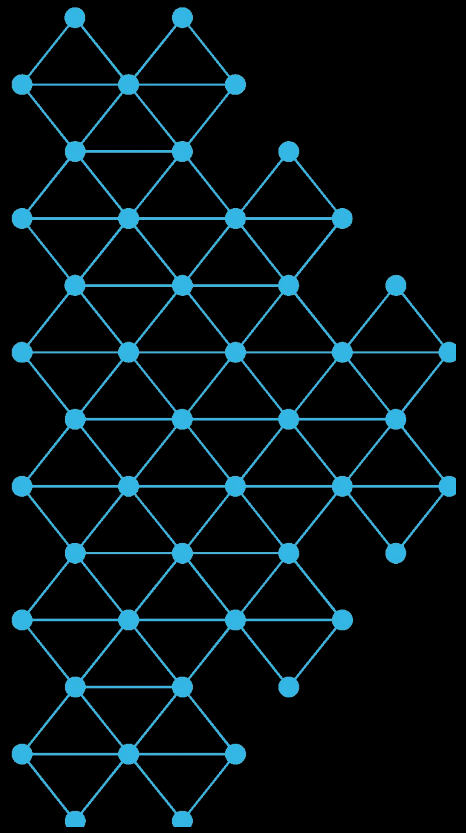

Ensemble de modèles

Ensemble de modèles

Votre méthode expérimentale :

Ensemble de modèles

Votre méthode expérimentale :

La méthode populaire :

Ensemble de modèles

MILA

Ensemble de modèles

On fait un vote populaire à chaque fois.

Pour se tromper, il faut que 2 ou 3 des experts se trompent en même temps.

```
P(erreur) =   0.7*0.3*0.3 + 0.3*0.7*0.3 + 0.3*0.3*0.7
            + 0.3*0.3*0.3
P(erreur) = 0.216
```

Les chances d'erreur sont maintenant de 21.6 %. On est passés de 30% à 21.6% juste en combinant 3 instances du même modèle !?

WTF !?

MILA

Ensemble de modèles

30% erreur

25% erreur

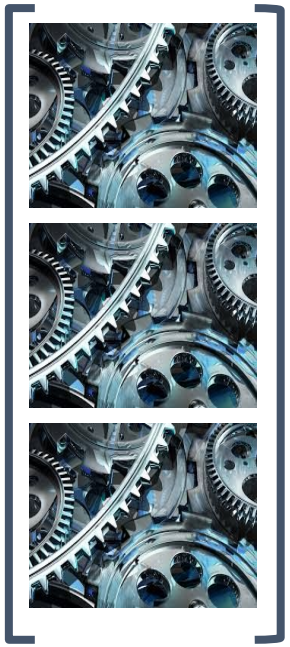

21.6% erreur

Ensemble de modèles

30% erreur

25% erreur

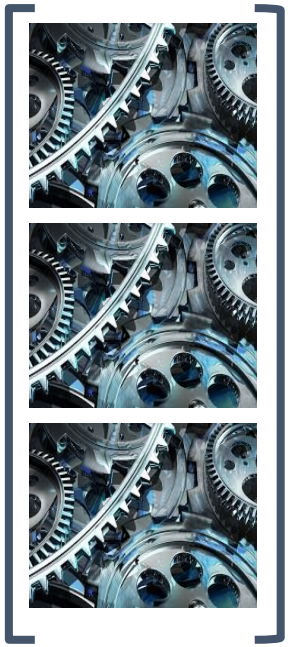

21.6% erreur

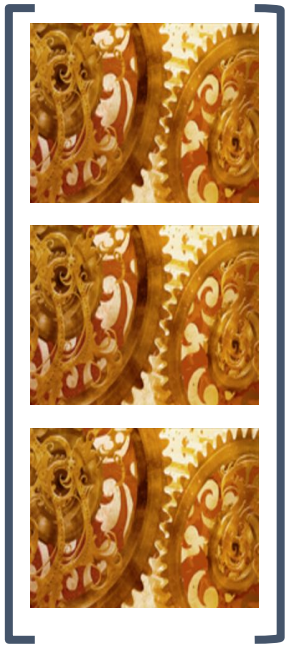

15.6% erreur

Ensemble de modèles

25% erreur

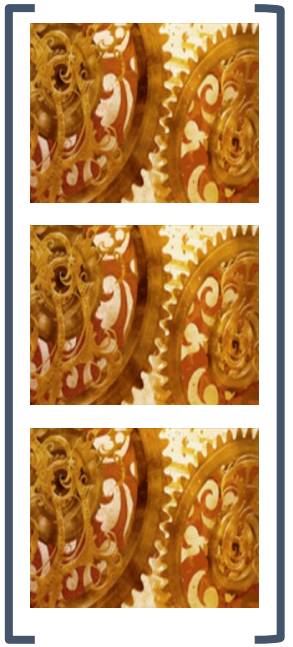

15.6% erreur

Ensemble d’experts

25% erreur

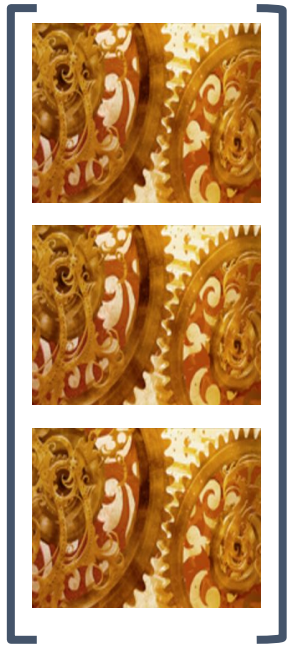

15.6% erreur

Ensemble de modèles

Le raisonnement s'applique uniquement si les instances de modèles font chacun une classification de manière **indépendante**.

Un même modèle entraîné 10 fois va avoir tendance à faire des erreurs un peu différentes, mais pas si radicalement différentes.

Ensemble de modèles

Un groupe d’experts trop pareils,
ça se trompe ensemble de manière coordonnée.

Ensemble de modèles

Peu importe le nombre d'experts qu'on met ensemble, on n'aura jamais une meilleure classification sur certains exemples ambigus.

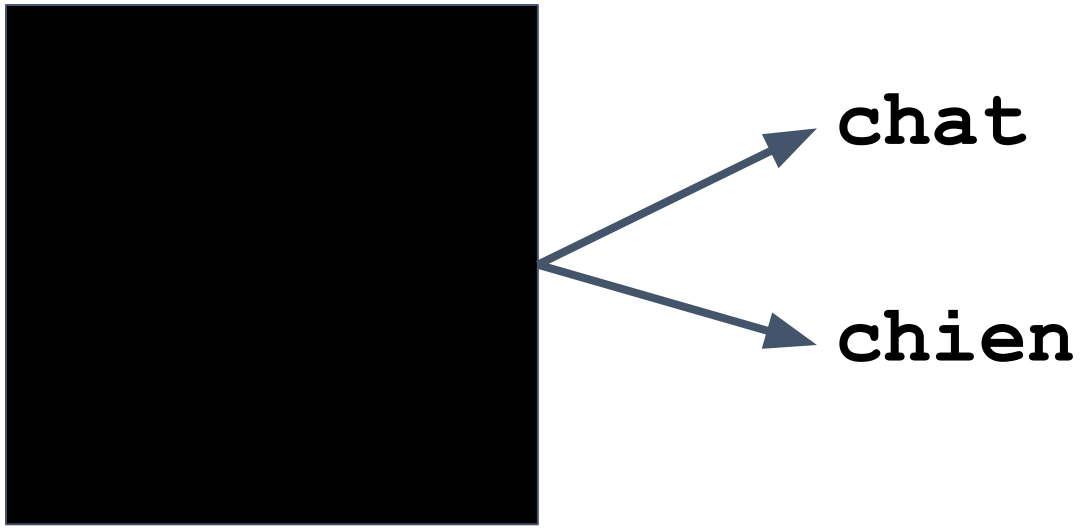

Ensemble de modèles

Il se peut très bien qu'on ait une situation comme ça :

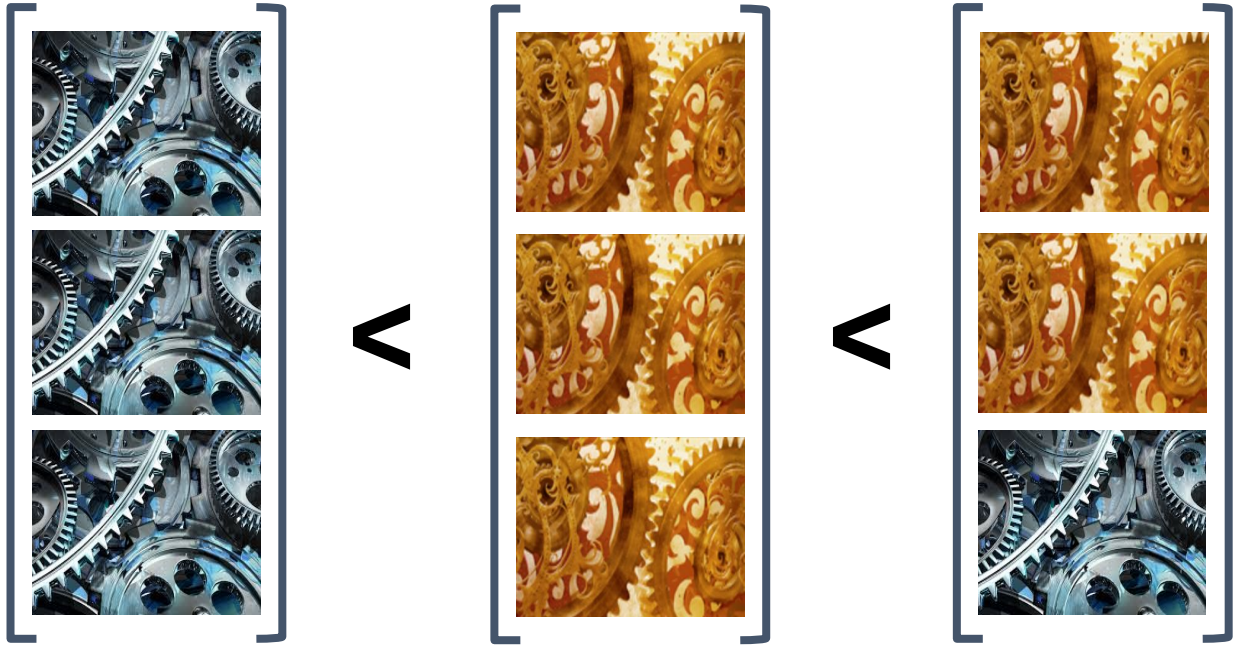

Ensemble de modèles

Penser au coût computationnel de rouler plusieurs modèles en parallèle. Possibilité de prendre des modèles moins chers pour mitiger ça.

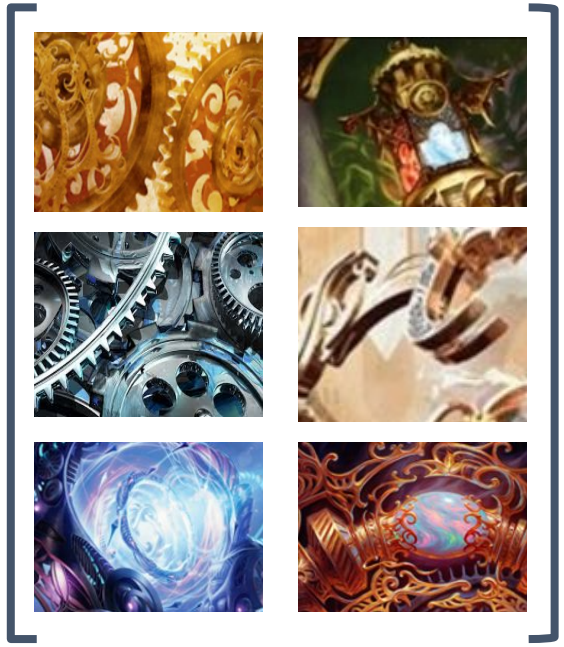

Ensemble de modèles

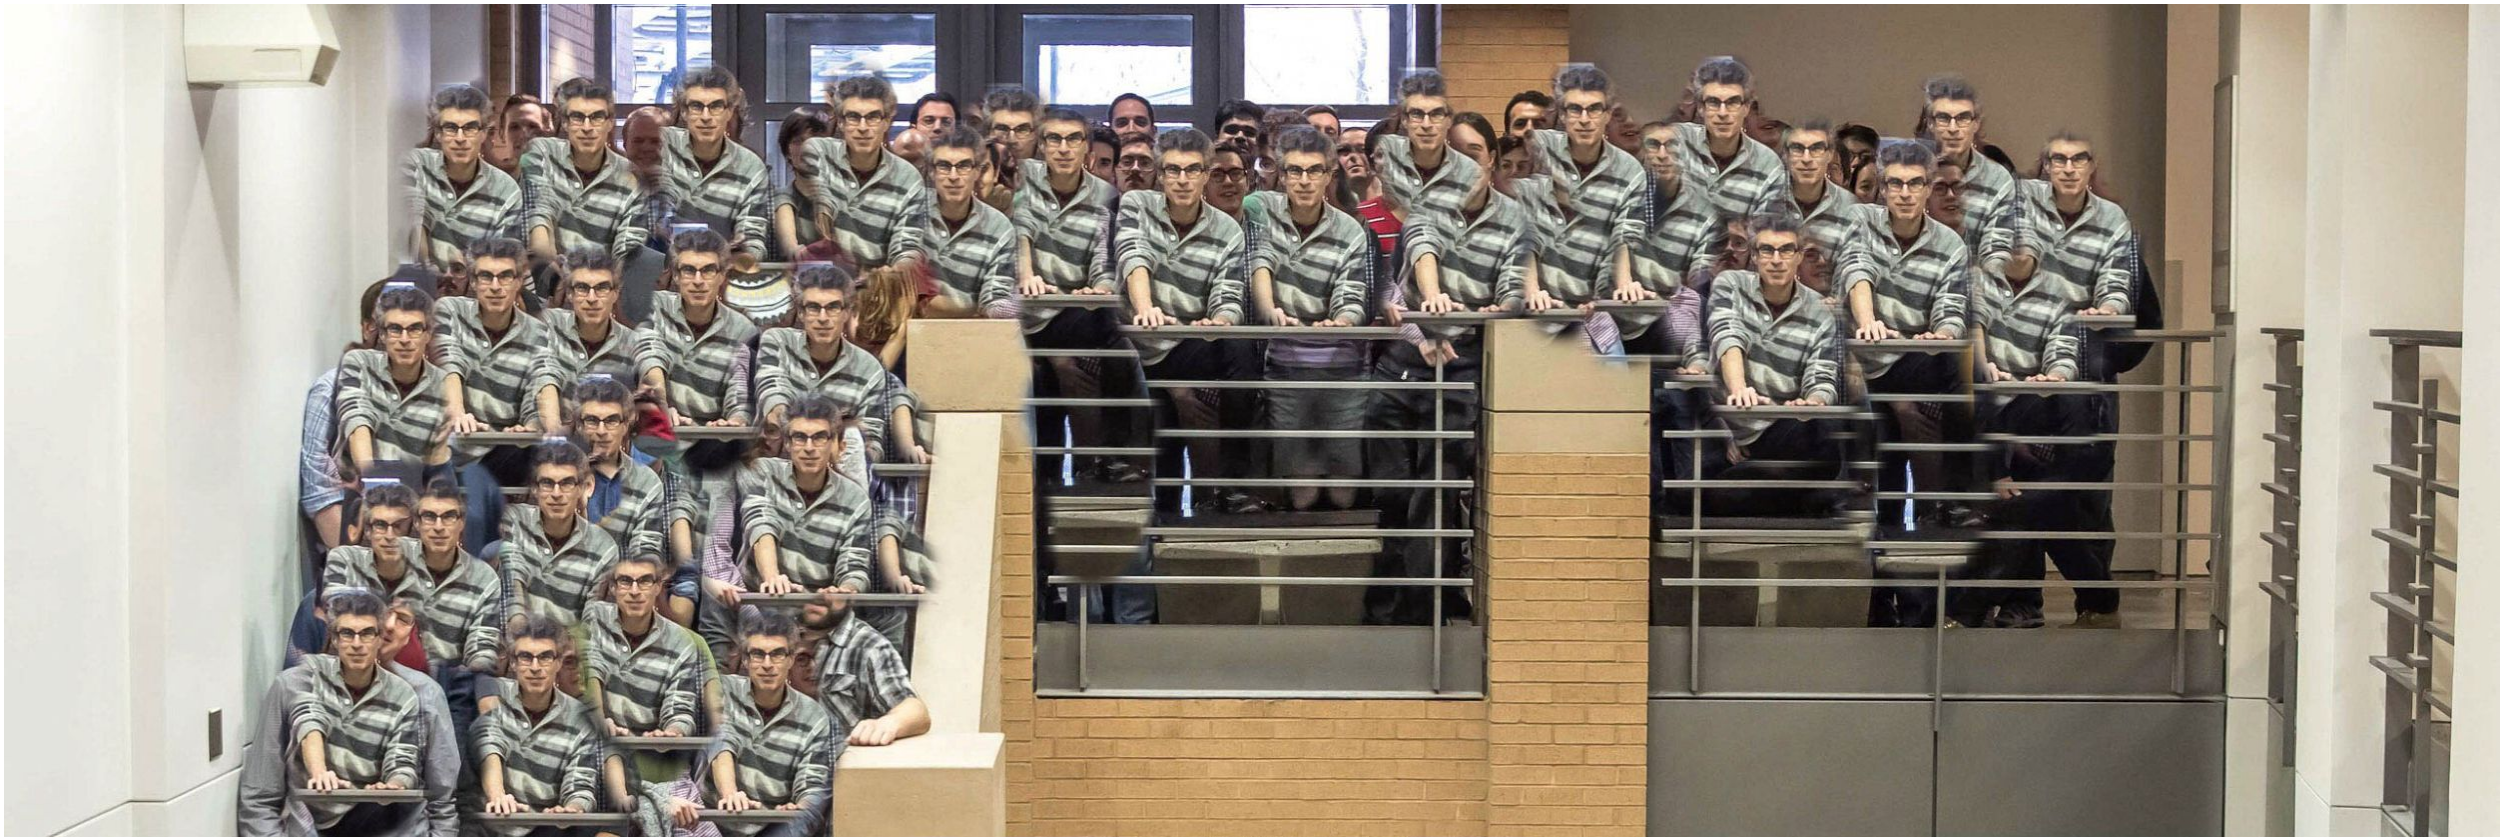

MILA


MILA

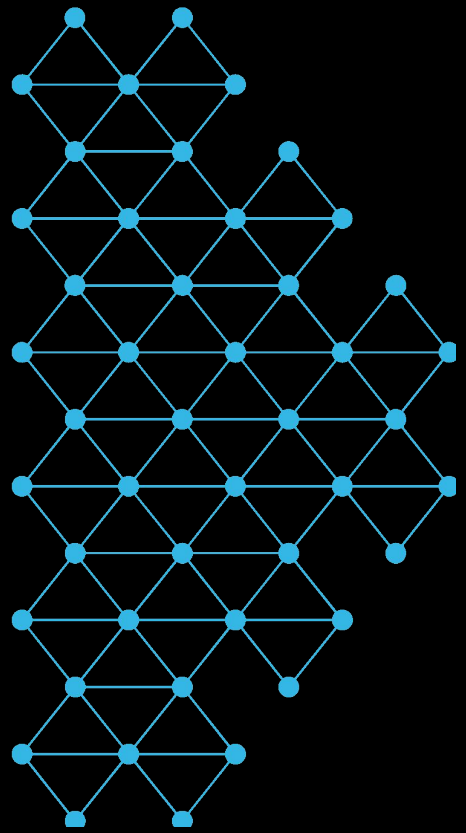

Merci !
Bonne aventure dans le merveilleux monde du Deep Learning !

Contact

http:/mila.umontreal.ca/mila-fr/

Guillaume Alain guillaume.alain.umontreal@gmail.com

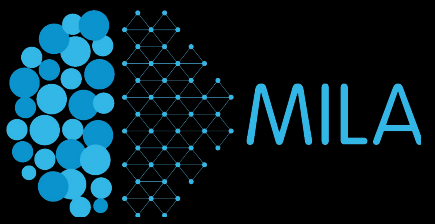

TL; DR

1. Acheter GPU Titan plus récent par nVidia.
2. Mettre dans un bon desktop correct avec Linux.
3. Utiliser des modèles préfabriqués en ligne.
4. Imiter le code des experts. S'inspirer sur github.
5. Vérifier qu'on obtient des outputs corrects. Sanity checks.
6. Bien organiser ses expériences. Éviter les fouillis.

Bonus : Ensemble de modèles pour classification.

Guillaume Alain guillaume.alain.umontreal@gmail.com

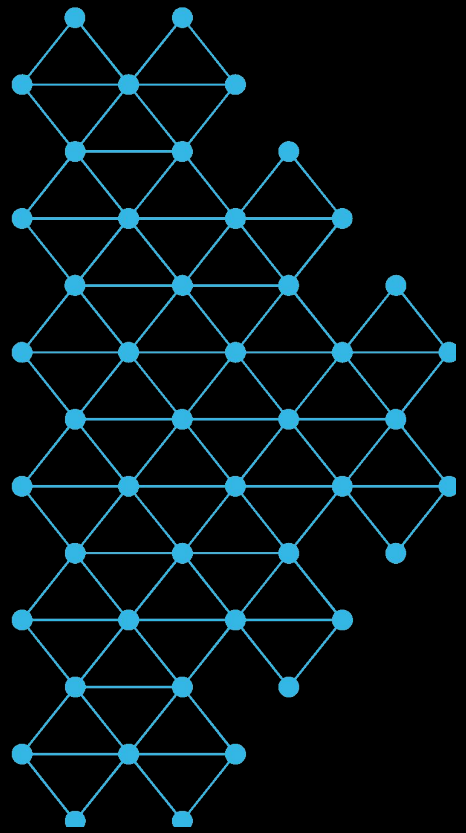

Appendice

GPU utilisé pour écran en même temps

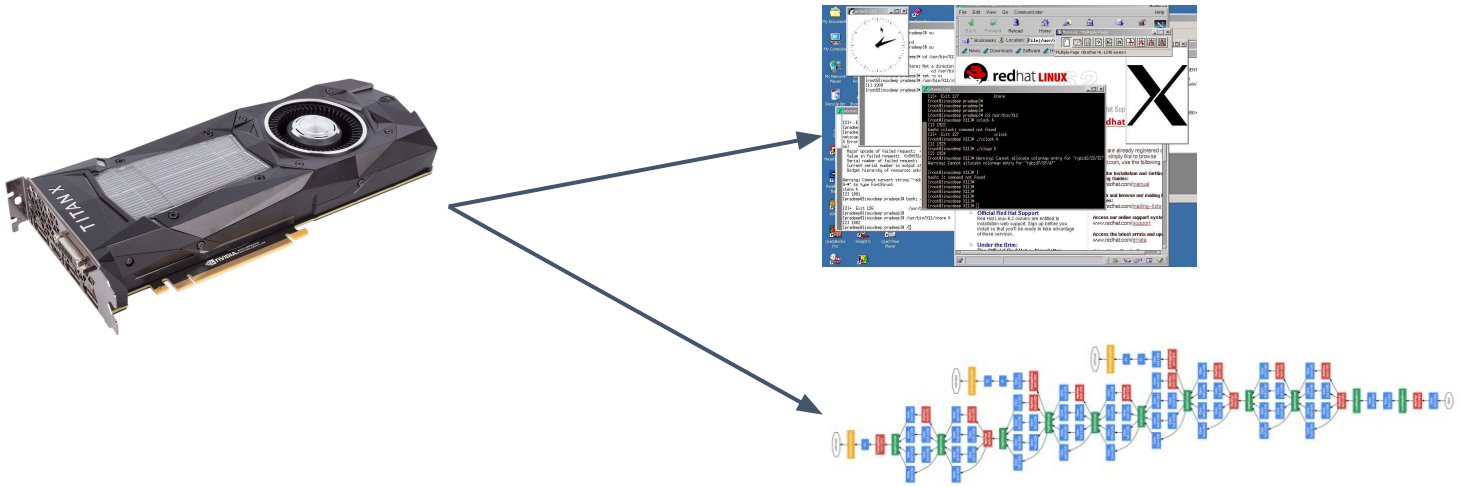

GPU utilisé pour écran en même temps

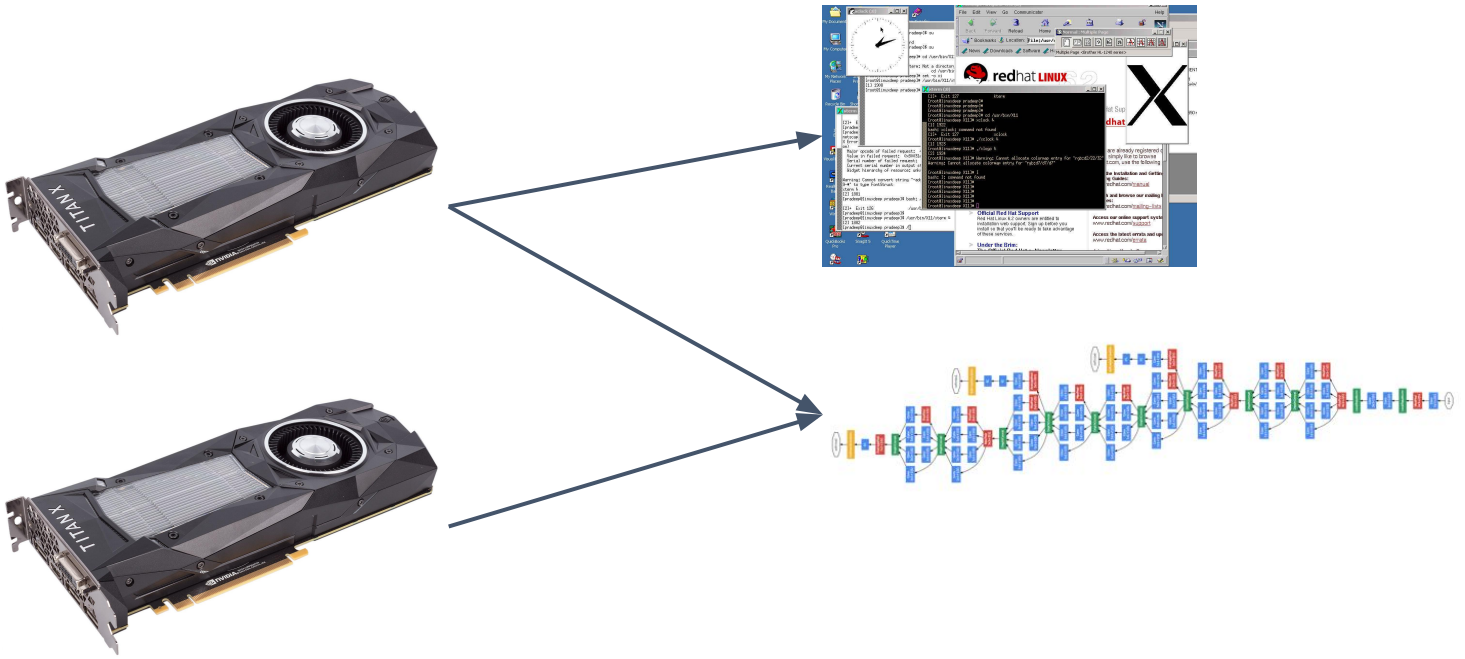

GPU utilisé pour écran en même temps

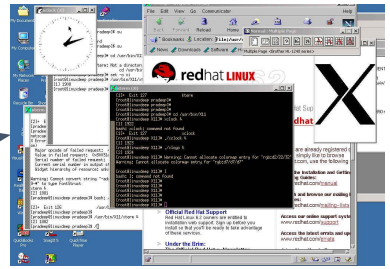

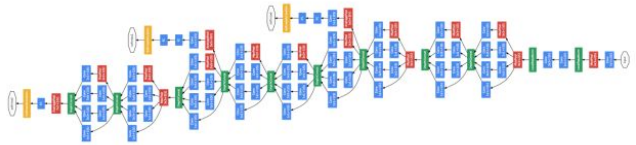

MILA

GPU utilisé pour écran en même temps

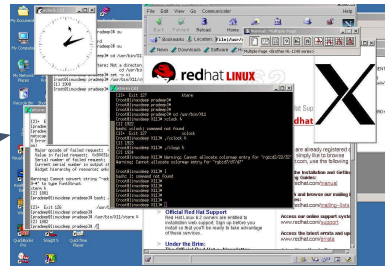

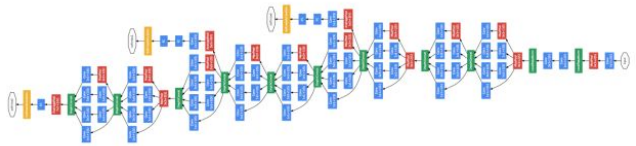

NON !! On ne mélange pas les types de GPU.

MILA

scripts d'entraînement

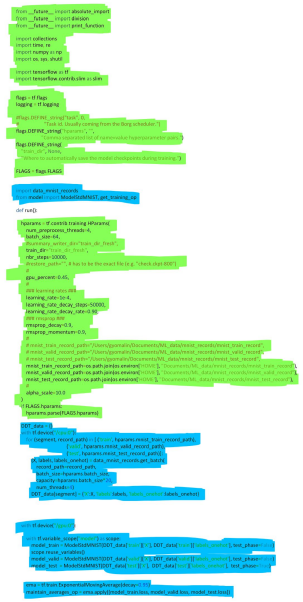

page 1

page 2

Code boilerplate pur.
Ajustements très mineurs.

Code assez standard.
Changements légers.

Code très spécifique.
Non réutilisable.

MILA

scripts d'entraînement

Code boilerplate pur.
Ajustements très mineurs.

Code assez standard.
Changements légers.

Code très spécifique.
Non réutilisable.

MILA

scripts d'entraînement

Souvent le code prend de la place parce qu'il expose essentiellement tous les boutons auxquels on va vouloir toucher pour convaincre le modèle de fonctionner, ou pour le lancer sur une autre machine.

```
gpu_options = tf.GPUOptions(per_process_gpu_memory_fraction=hparams.gpu_percent)
config=tf.ConfigProto(
    log_device_placement=False,
    allow_soft_placement=True,
    gpu_options=gpu_options)
session = tf.Session(config=config)
# https://blog.keras.io/keras-as-a-simplified-interface-to-tensorflow-tutorial.html
K.set_session(session)
```

```
probe_model.compile(optimizer=RMSprop(lr=0.001, rho=0.95, epsilon=1e-08, decay=0.9999),
                    loss='categorical_crossentropy',
                    metrics=['accuracy', accuracy_top5])
```