# “Réseaux de neurones” artificiels

## Les questions à poser

Jean Feydy

Congrès de la SFNR, Paris – 28 mars 2019

Écoles Normales Supérieures de Paris et Paris-Saclay

# À mon sujet

Jean Feydy (2016-2019) :

- Élève en thèse avec Alain Trouvé, ENS Cachan,
  **Recalage d'images médicales.**
- TDs pour Gabriel Peyré, M2 MVA et ENS Ulm,
  **Fondements mathématiques des Data Sciences.**
- Fils d'Antoine Feydy, PUPH à Cochin,
  Spécialisé en **imagerie musculo-squelettique**.

# Aujourd’hui

Réseaux de neurones ?

# Aujourd'hui

Réseaux de neurones ?

Une généralisation de la **régression linéaire**
à des modèles plus complexes.

# Aujourd'hui

Réseaux de neurones ?

Une généralisation de la **régression linéaire**
à des modèles plus complexes.

Et ça marche ? En général, **non.**

# Aujourd'hui

Réseaux de neurones ?

Une généralisation de la **régression linéaire**
à des modèles plus complexes.

Et ça marche ? En général, **non**.

Par contre, cette idée permet aujourd'hui de produire
d'excellents **détecteurs de motifs**.

# Aujourd'hui

Réseaux de neurones ?

Une généralisation de la **régression linéaire**
à des modèles plus complexes.

Et ça marche ? En général, **non**.

Par contre, cette idée permet aujourd'hui de produire
d'excellents **détecteurs de motifs**.

En tant que médecins, quel **regard critique**
pouvez-vous porter sur ces techniques ?

# Que lit-on sur une radio ?

# Une image : trois niveaux d'analyse [EPW11, Man11]

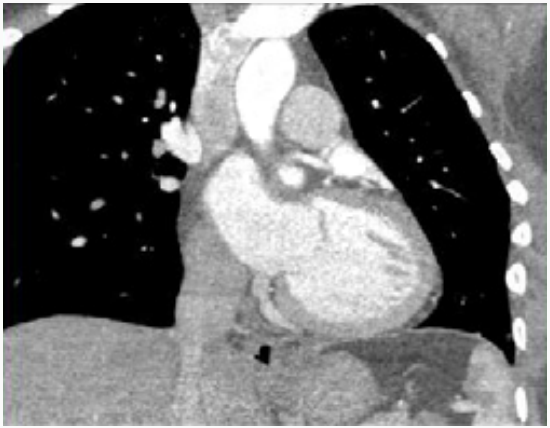

# Une image : trois niveaux d'analyse [EPW11, Man11]

1. Texture

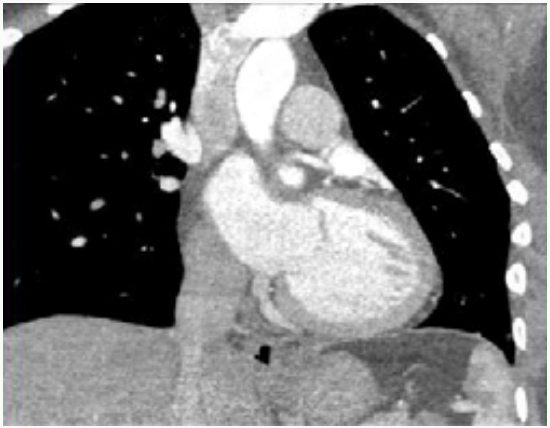

# Une image : trois niveaux d'analyse [EPW11, Man11]

1. Texture
2. Anatomie

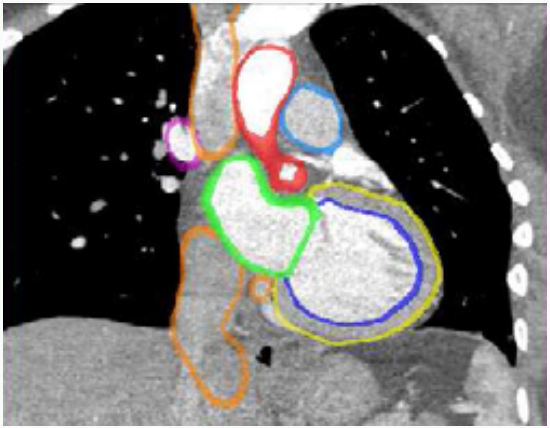

# Une image : trois niveaux d'analyse [EPW11, Man11]

1. Texture
2. Anatomie

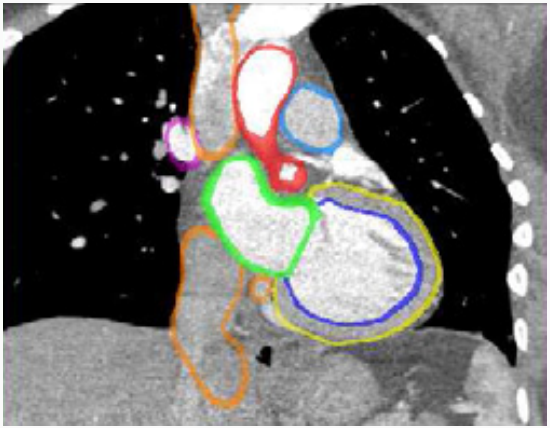

# Une image : trois niveaux d'analyse [EPW11, Man11]

1. Texture
2. Anatomie
3. Fonction

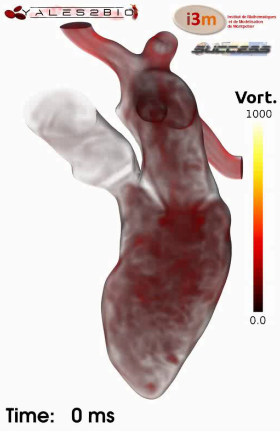

# Une image : trois niveaux d'analyse [EPW11, Man11]

1. Texture
2. Anatomie
3. Fonction

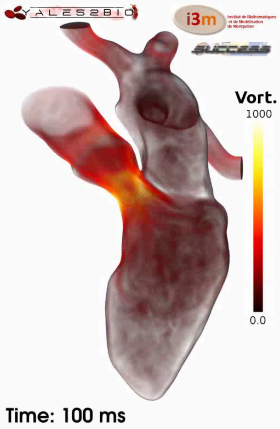

# Une image : trois niveaux d'analyse [EPW11, Man11]

1. Texture
2. Anatomie
3. Fonction

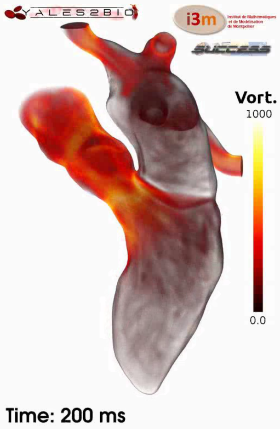

# Une image : trois niveaux d'analyse [EPW11, Man11]

1. Texture
2. Anatomie
3. Fonction

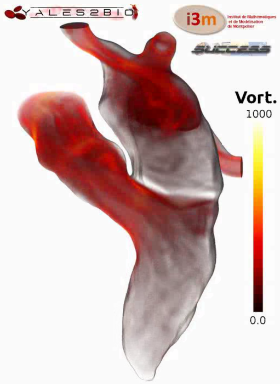

# Une image : trois niveaux d'analyse [EPW11, Man11]

1. Texture
2. Anatomie
3. Fonction

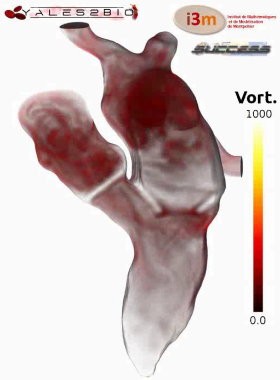

# Une image : trois niveaux d'analyse [EPW11, Man11]

1. Texture
2. Anatomie
3. Fonction

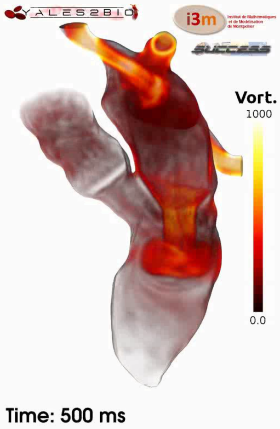

# Une image : trois niveaux d'analyse [EPW11, Man11]

1. Texture
2. Anatomie
3. Fonction

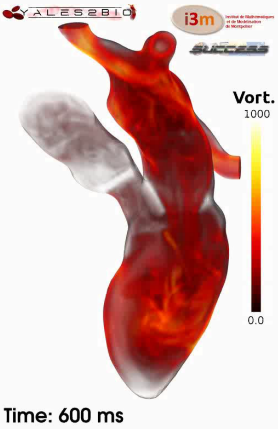

# Une image : trois niveaux d'analyse [EPW11, Man11]

1. Texture
2. Anatomie
3. Fonction

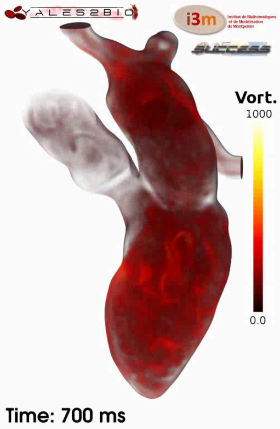

# Une image : trois niveaux d'analyse [EPW11, Man11]

1. Texture
2. Anatomie
3. Fonction

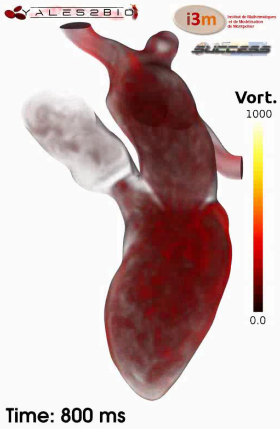

# Une image : trois niveaux d'analyse [EPW11, Man11]

1. Texture
2. Anatomie
3. Fonction

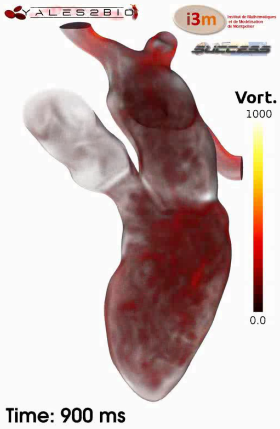

# Une image : trois niveaux d'analyse [EPW11, Man11]

1. Texture
2. Anatomie
3. Fonction

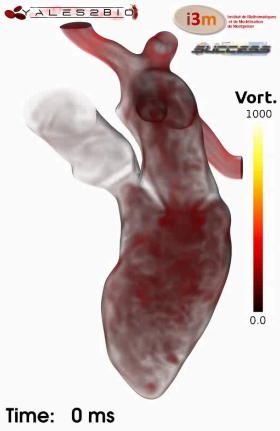

# Une image : trois niveaux d'analyse [EPW11, Man11]

1. Texture
2. Anatomie
3. Fonction

Chacun de ces niveaux d'abstraction peut être **modélisé** en se reposant sur le précédent.

# Une image : trois niveaux d'analyse [EPW11, Man11]

1. Texture
2. Anatomie
3. Fonction

Chacun de ces niveaux d'abstraction peut être **modélisé** en se reposant sur le précédent.

Découvrons la plus fondamentale de toutes ces théories : l'analyse par **filtrage multi-résolution**.

# Le filtrage, ou “produit de convolution”

**Convolution** (i.e. moyenne pondérée des pixels voisins) :

Généralisation peu coûteuse du **produit** “$a \cdot x$”,
paramétrée par les coefficients d’un petit filtre $\varphi$.

$\varphi$

$\star$

$x$

$=$

$\varphi \star x$

# Le filtrage, ou “produit de convolution”

**Convolution** (i.e. moyenne pondérée des pixels voisins) :

Généralisation peu coûteuse du **produit** “$a \cdot x$”,
paramétrée par les coefficients d’un petit filtre $\varphi$.

$\varphi$

$\star$

$x$

$=$

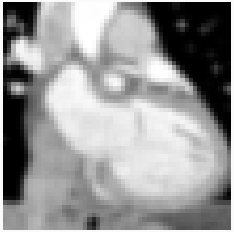

$\varphi \star x$

# Le filtrage, ou “produit de convolution”

**Convolution** (i.e. moyenne pondérée des pixels voisins) :

Généralisation peu coûteuse du **produit** “$a \cdot x$”,
paramétrée par les coefficients d’un petit filtre $\varphi$.


$\star$

$=$
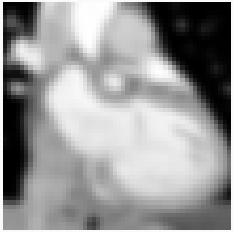

$\varphi$ $x$ $\varphi \star x$

# Le filtrage, ou “produit de convolution”

**Convolution** (i.e. moyenne pondérée des pixels voisins) :

Généralisation peu coûteuse du **produit** “$a \cdot x$”,
paramétrée par les coefficients d’un petit filtre $\varphi$.

$\star$

$=$

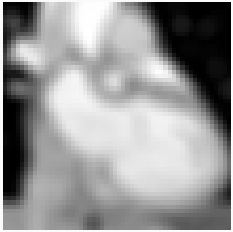

$\varphi$ $\quad$ $x$ $\quad$ $\varphi \star x$

# Le filtrage, ou “produit de convolution”

**Convolution** (i.e. moyenne pondérée des pixels voisins) :

Généralisation peu coûteuse du **produit** “$a \cdot x$”,
paramétrée par les coefficients d’un petit filtre $\varphi$.

$\varphi$

$\star$

$x$

$=$

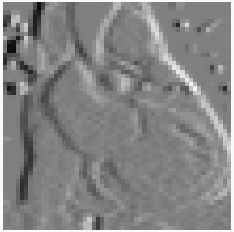

$\varphi \star x$

# Le filtrage, ou “produit de convolution”

**Convolution** (i.e. moyenne pondérée des pixels voisins) :

Généralisation peu coûteuse du **produit** “$a \cdot x$”,
paramétrée par les coefficients d’un petit filtre $\varphi$.


$\star$

$=$
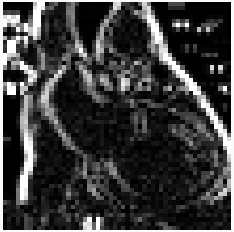

$\varphi$ $x$ $|\varphi \star x|$

# Le filtrage, ou “produit de convolution”

**Convolution** (i.e. moyenne pondérée des pixels voisins) :

Généralisation peu coûteuse du **produit** “$a \cdot x$”,
paramétrée par les coefficients d’un petit filtre $\varphi$.


$\star$

$=$
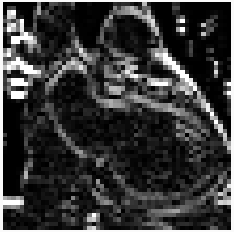

$\varphi$ $x$ $|\varphi \star x|$

# Le filtrage, ou “produit de convolution”

**Convolution** (i.e. moyenne pondérée des pixels voisins) :

Généralisation peu coûteuse du **produit** “$a \cdot x$”,
paramétrée par les coefficients d’un petit filtre $\varphi$.


$\star$

$=$


$\varphi$ $x$ $|\varphi \star x|$

# A priori multi-échelles sur les images

Théorie des **ondelettes** (Meyer, Mallat, Daubechies...) :

Petits filtres + dé-zooms en cascade [Mal16] :

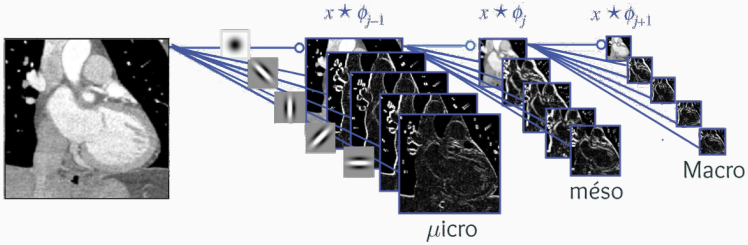

# A priori multi-échelles sur les images

Théorie des **ondelettes** (Meyer, Mallat, Daubechies...) :

Petits filtres + dé-zooms en cascade [Mal16] :

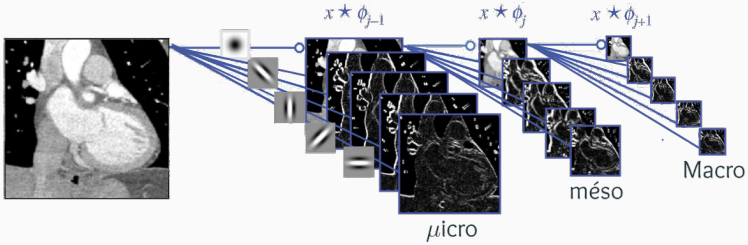


Image $\longrightarrow$ Coefficients pertinents

$\simeq$ Audio ".wav" $\longrightarrow$ Partition

# A priori multi-échelles sur les images

Théorie des **ondelettes** (Meyer, Mallat, Daubechies...) :

Petits filtres + dé-zooms en cascade [Mal16] :

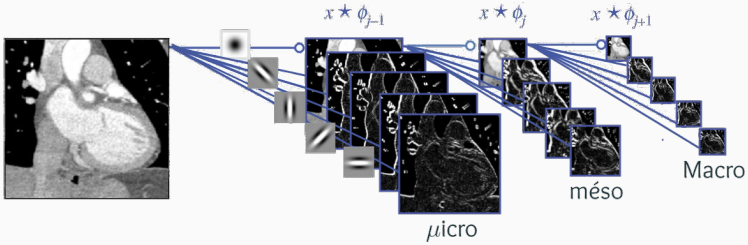


Image $\longrightarrow$ Coefficients pertinents

$\simeq$ Audio ".wav" $\longrightarrow$ Partition

$\Longrightarrow$ Format **JPEG 2000**, standard du cinéma numérique.

Voilà pour les modèles classiques.
Quid des réseaux de neurones ?

# “Apprentissage supervisé” = régression

On dispose :

- D’une base de données $\{(x_1 \to y_1), (x_2 \to y_2), \dots\}$.

# “Apprentissage supervisé” = régression

On dispose :

- D’une base de données $\{ (x_1 \to y_1), (x_2 \to y_2), \dots \}$.
- D’un modèle explicatif

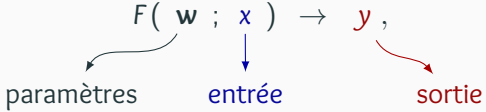

# “Apprentissage supervisé” = régression

On dispose :

- D’une base de données $\{ (x_1 \to y_1), (x_2 \to y_2), \dots \}$.
- D’un modèle explicatif

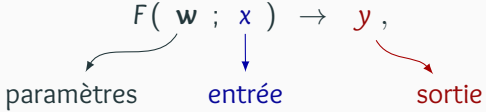

# “Apprentissage supervisé” = régression

On dispose :

- D’une base de données $\{ (x_1 \to y_1), (x_2 \to y_2), \dots \}$.
- D’un modèle explicatif

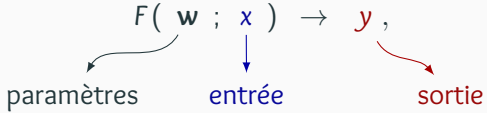


Trouvons, pas-à-pas, un choix $\mathbf{w}_{\text{optimal}}$ des paramètres qui minimise **l’erreur moyenne sur les prédictions**.

# Un jeu de donnée jouet, en dimension 1

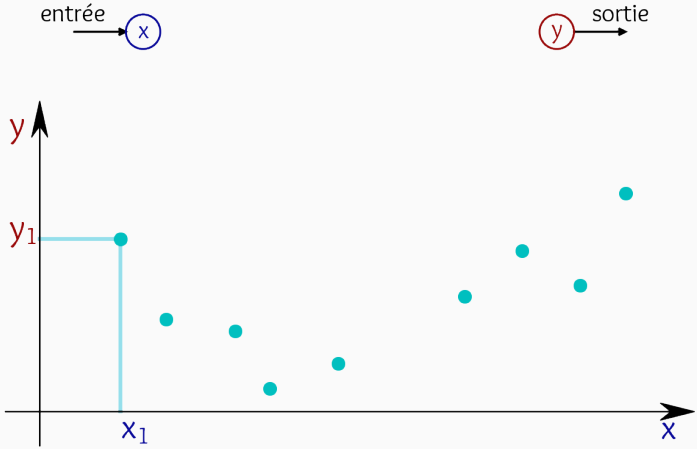

# Un jeu de donnée jouet, en dimension 1

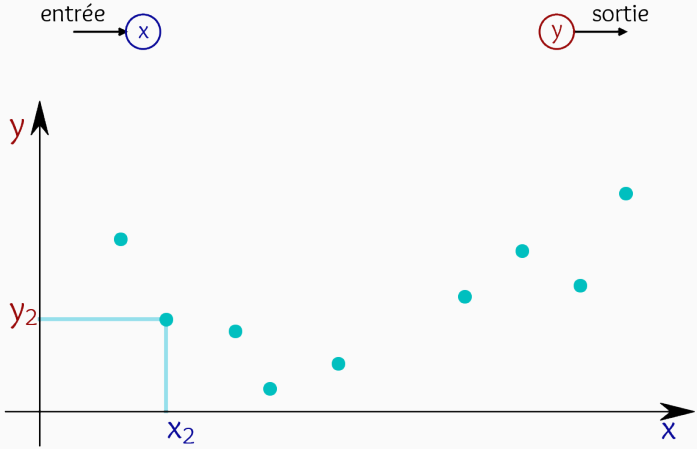

# Un jeu de donnée jouet, en dimension 1

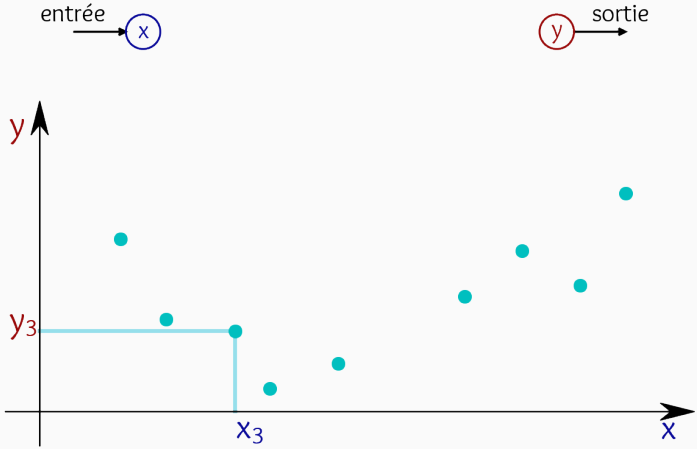

# Un jeu de donnée jouet, en dimension 1

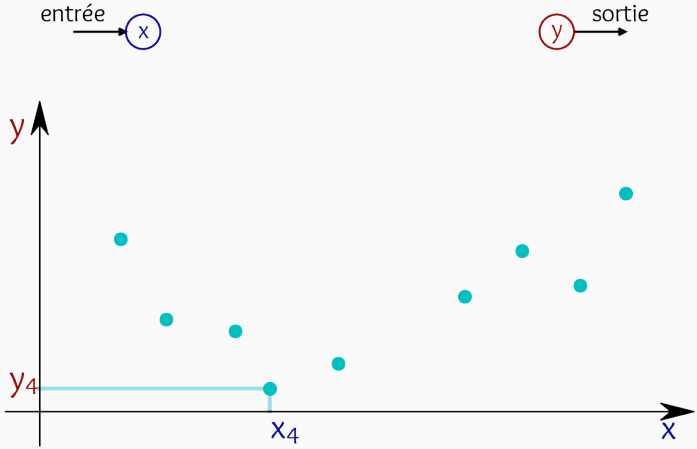

# Un jeu de donnée jouet, en dimension 1

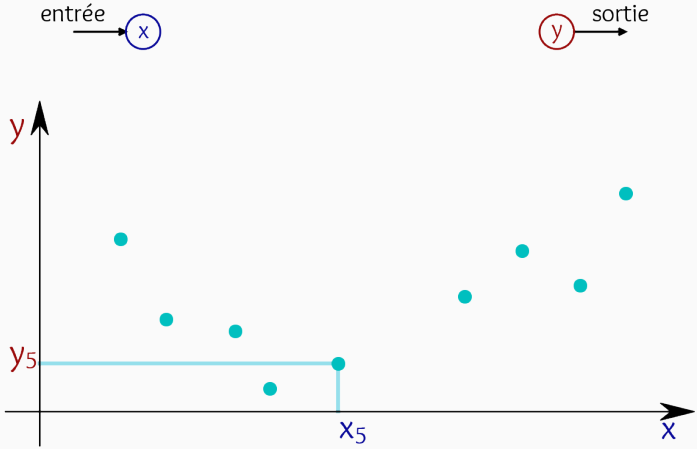

# Un jeu de donnée jouet, en dimension 1

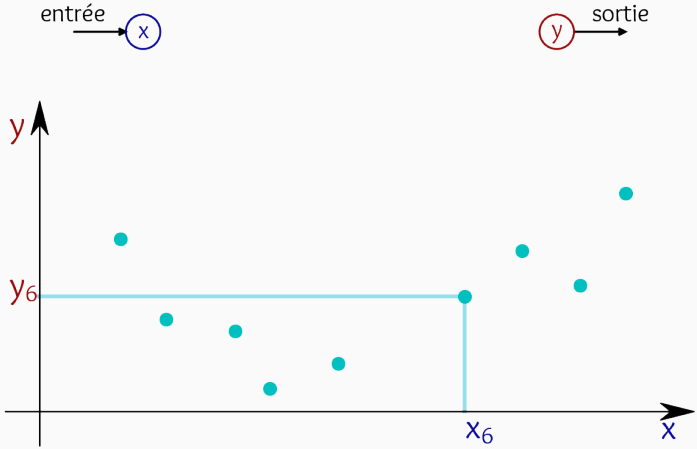

# Un jeu de donnée jouet, en dimension 1

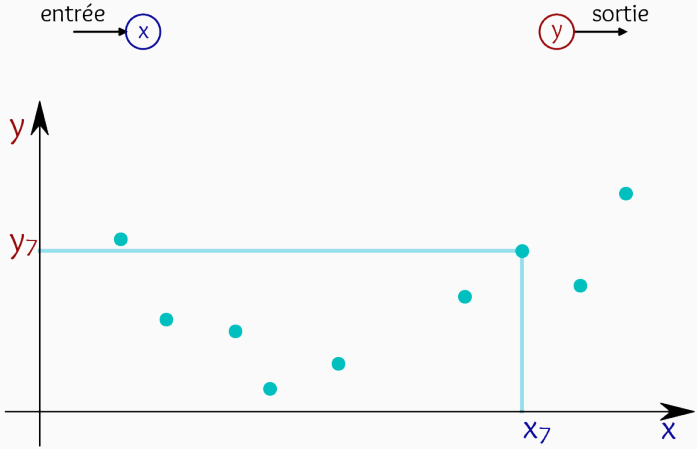

# Un jeu de donnée jouet, en dimension 1

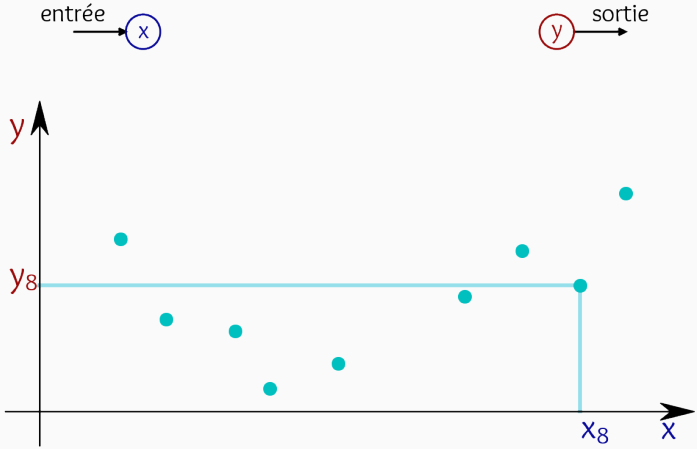

# Un jeu de donnée jouet, en dimension 1

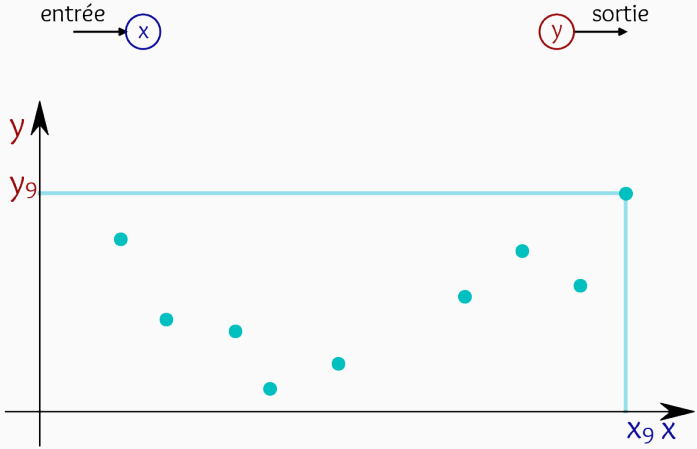

# Exemple fondamental : la régression linéaire

$$F(a, b; x) = a \cdot x + b$$
$$(a, b) = +0.00, +0.25$$

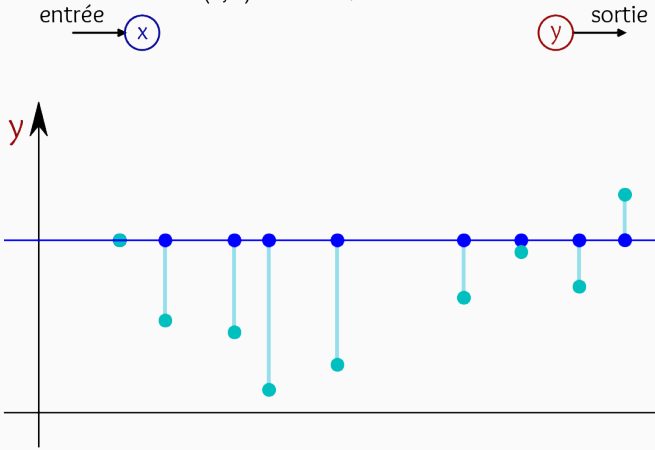

# Exemple fondamental : la régression linéaire

$$F(a, b; x) = a \cdot x + b$$
$$(a, b) = +0.01, +0.18$$


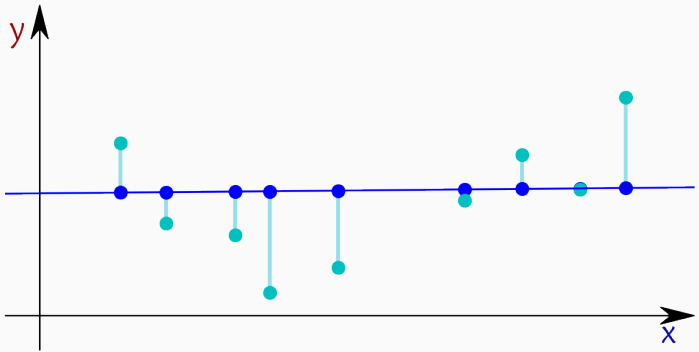

# Exemple fondamental : la régression linéaire

$$F(a, b; x) = a \cdot x + b$$
$$(a, b) = +0.02, +0.12$$

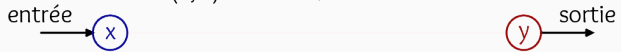


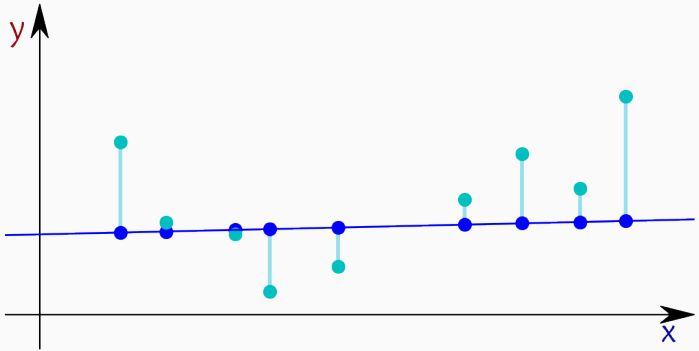

# Exemple fondamental : la régression linéaire

$$F(a, b; x) = a \cdot x + b$$
$$(a, b) = +0.04,\ +0.09$$


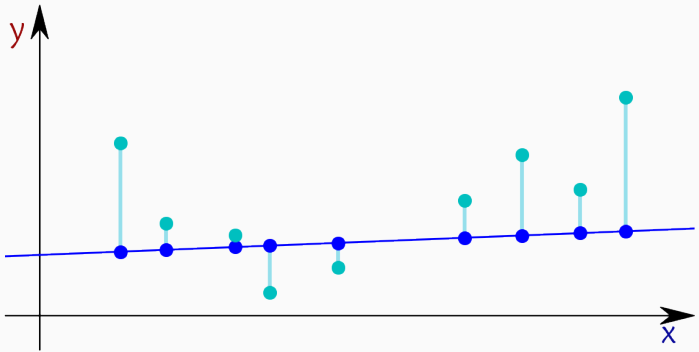

# Exemple fondamental : la régression linéaire

$$F(a, b; x) = a \cdot x + b$$
$$(a, b) = +0.08,\ +0.11$$


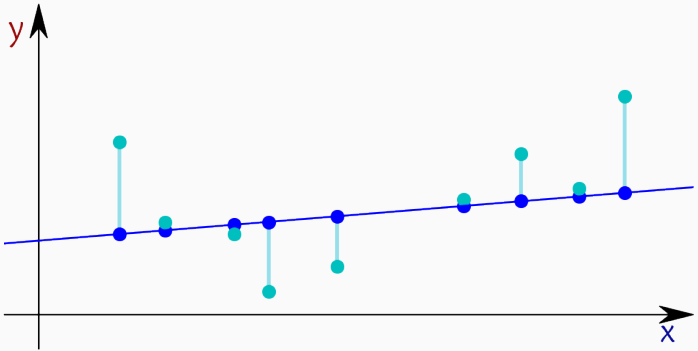

# Exemple fondamental : la régression linéaire

$$F(a, b; x) = a \cdot x + b$$

$$(a, b) = +0.17, +0.10$$


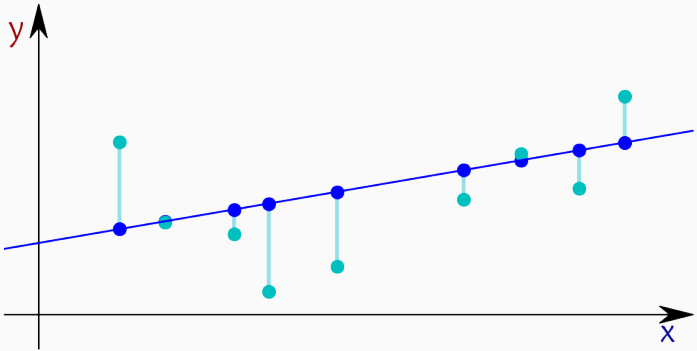

# Exemple fondamental : la régression linéaire

$$F(a, b; x) = a \cdot x + b$$
$$(a, b) = +0.20,\ +0.09$$


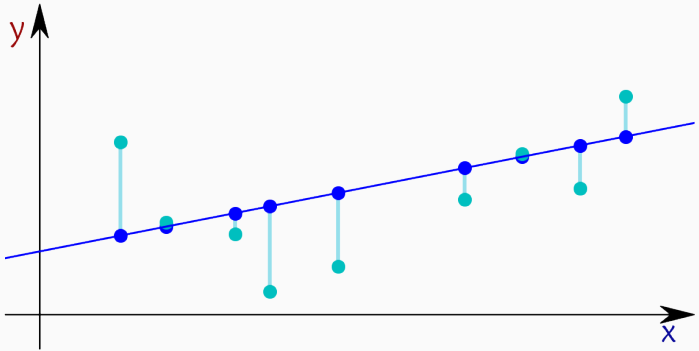

# Exemple fondamental : la régression linéaire

$$F(a, b; x) = a \cdot x + b$$
$$(a, b) = +0.16, +0.09$$


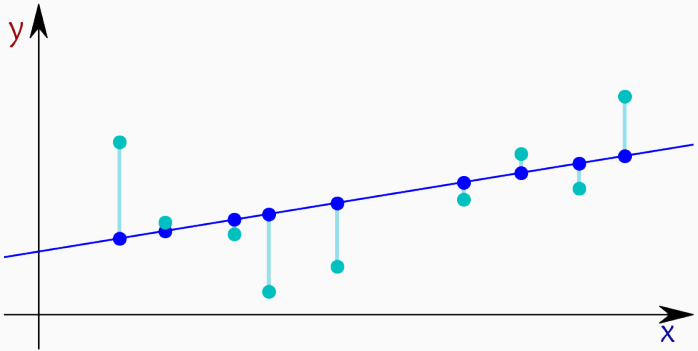

# Exemple fondamental : la régression linéaire

$$F(a, b; x) = a \cdot x + b$$
$$(a, b) = +0.15, +0.09$$


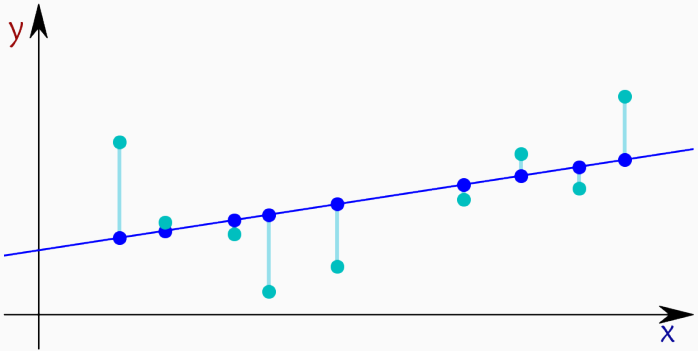

# Exemple fondamental : la régression linéaire

$$F(a, b; x) = a \cdot x + b$$
$$(a, b) = +0.15, +0.09$$


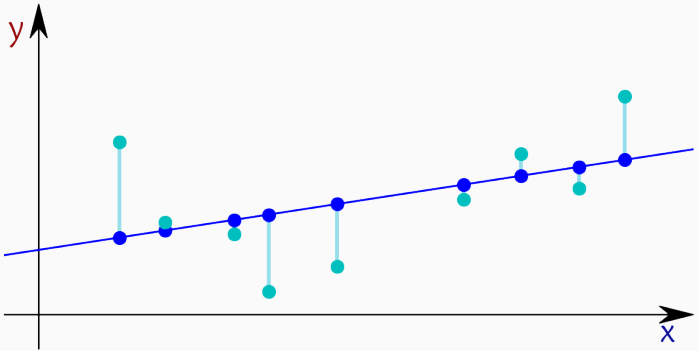

# Un modèle plus complexe : la régression quadratique

$$F(a, b, c; x) = a \cdot x^2 + b \cdot x + c$$

$$(a, b, c) = +0.00,\ +0.00,\ +0.25$$


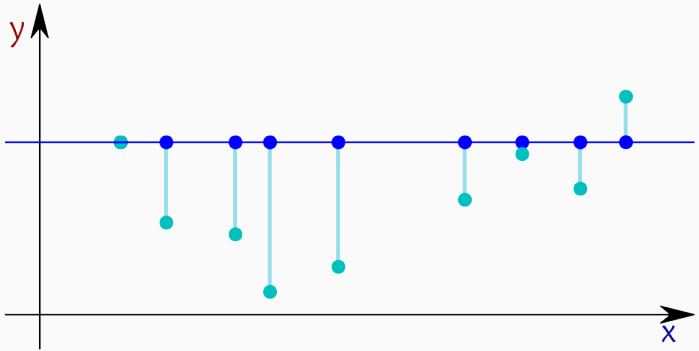

# Un modèle plus complexe : la régression quadratique

$$F(a, b, c; x) = a \cdot x^2 + b \cdot x + c$$

$$(a, b, c) = -0.00,\ +0.01,\ +0.18$$


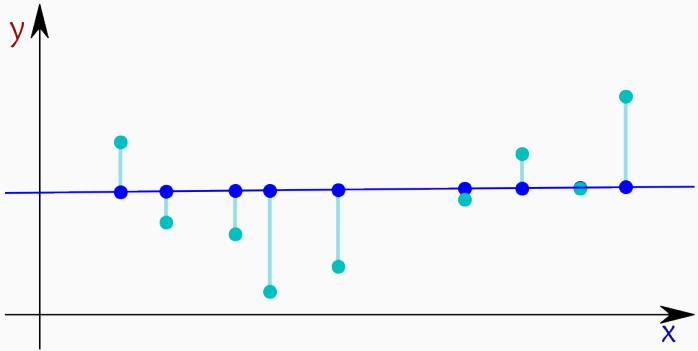

# Un modèle plus complexe : la régression quadratique

$$F(a, b, c; x) = a \cdot x^2 + b \cdot x + c$$

$$(a, b, c) = -0.00,\ +0.02,\ +0.12$$


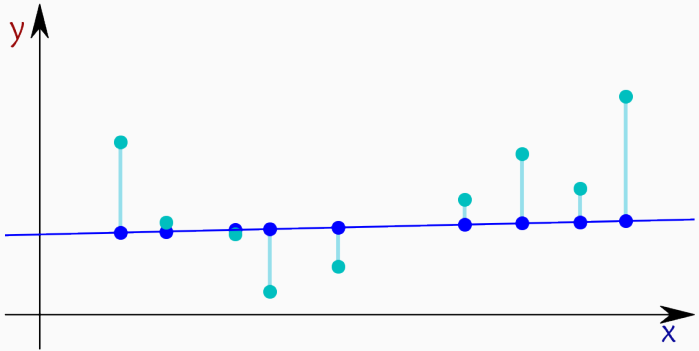

# Un modèle plus complexe : la régression quadratique

$$F(a, b, c; x) = a \cdot x^2 + b \cdot x + c$$

$$(a, b, c) = +0.00,\ +0.04,\ +0.09$$

entrée → x

y → sortie

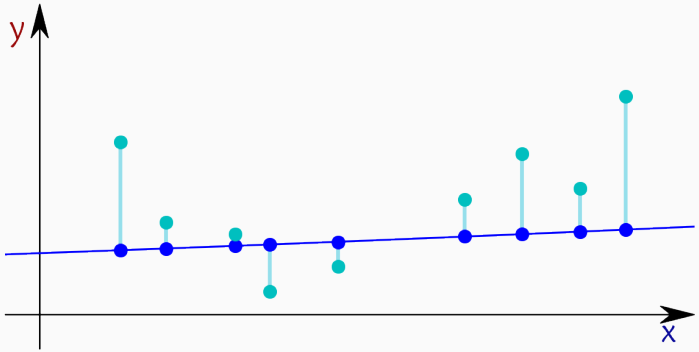

# Un modèle plus complexe : la régression quadratique

$$F(a, b, c; x) = a \cdot x^2 + b \cdot x + c$$
$$(a, b, c) = +0.03,\ +0.08,\ +0.11$$

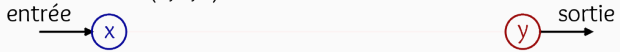


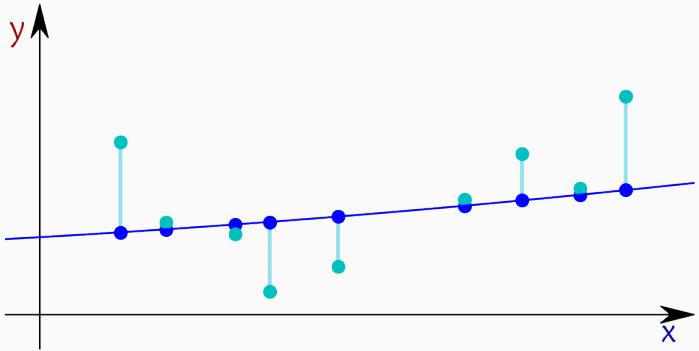

# Un modèle plus complexe : la régression quadratique

$$F(a, b, c; x) = a \cdot x^2 + b \cdot x + c$$

$$(a, b, c) = +0.08,\ +0.17,\ +0.12$$

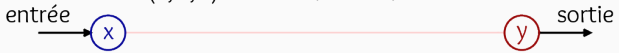


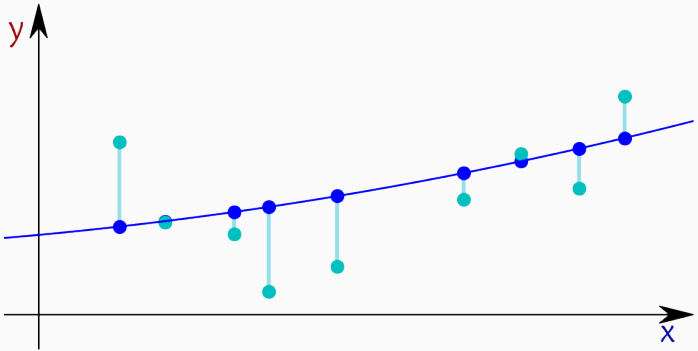

# Un modèle plus complexe : la régression quadratique

$$F(a, b, c; x) = a \cdot x^2 + b \cdot x + c$$

$$(a, b, c) = +0.21,\ +0.18,\ +0.13$$


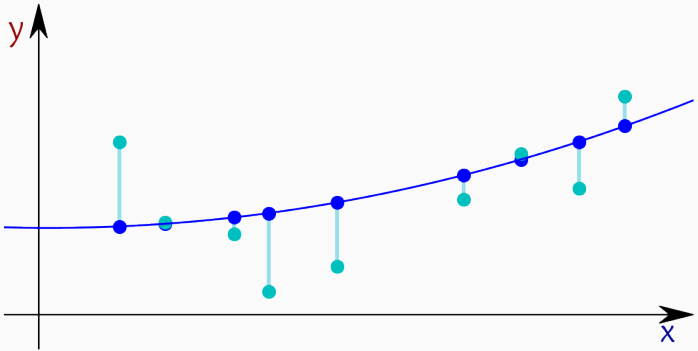

# Un modèle plus complexe : la régression quadratique

$$F(a, b, c; x) = a \cdot x^2 + b \cdot x + c$$

$$(a, b, c) = +0.66,\ +0.12,\ +0.20$$


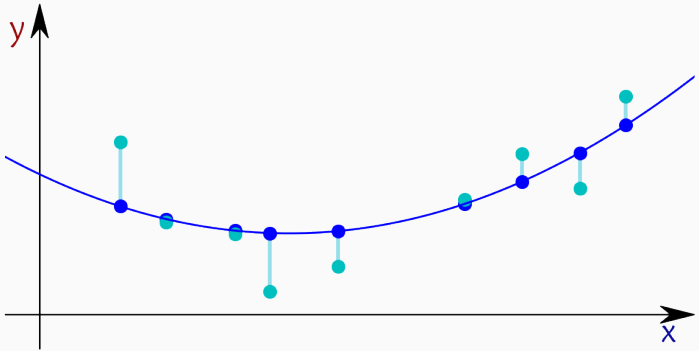

# Un modèle plus complexe : la régression quadratique

$$F(a, b, c; x) = a \cdot x^2 + b \cdot x + c$$

$$(a, b, c) = +1.18,\ +0.07,\ +0.30$$


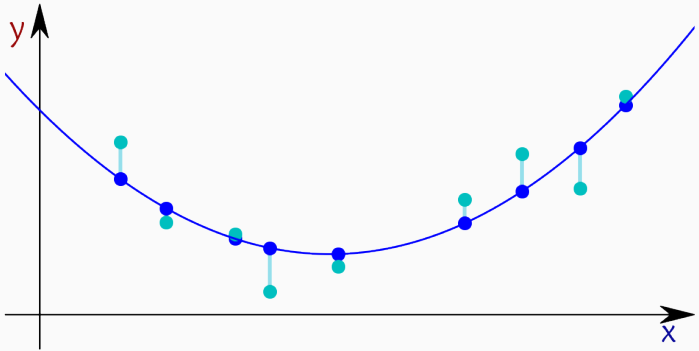

# Un modèle plus complexe : la régression quadratique

$$F(a, b, c; x) = a \cdot x^2 + b \cdot x + c$$
$$(a, b, c) = +1.36,\ +0.05,\ +0.33$$


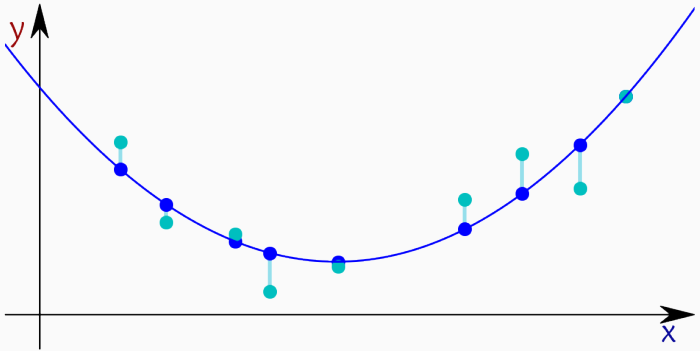

# Un modèle plus complexe : la régression quadratique

$$F(a, b, c; x) = a \cdot x^2 + b \cdot x + c$$

$$(a, b, c) = +1.36,\ +0.05,\ +0.33$$


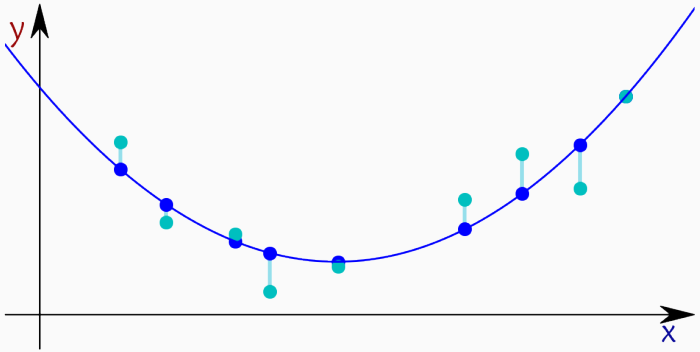

# Un modèle plus complexe : la régression quadratique

$$F(a, b, c; x) = a \cdot x^2 + b \cdot x + c$$

$$(a, b, c) = +1.36,\ +0.05,\ +0.33$$


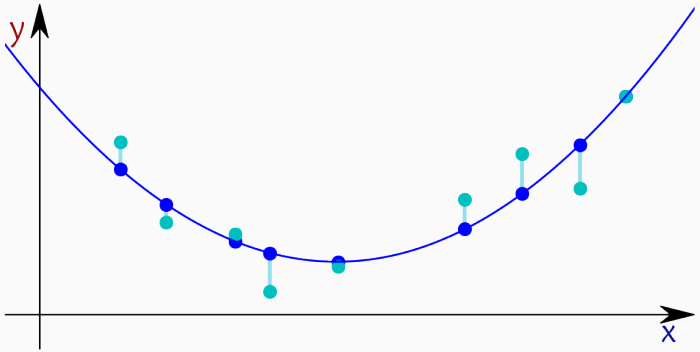

# Complexifions le modèle par l'ajout de variables intermédiaires...

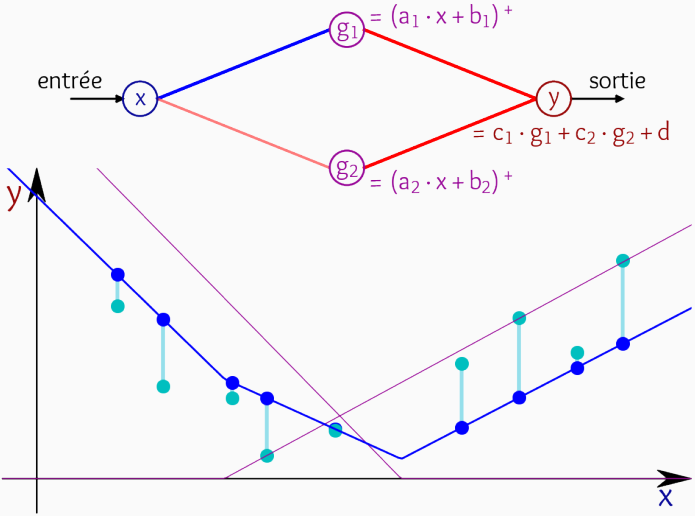

# Complexifions le modèle par l'ajout de variables intermédiaires...

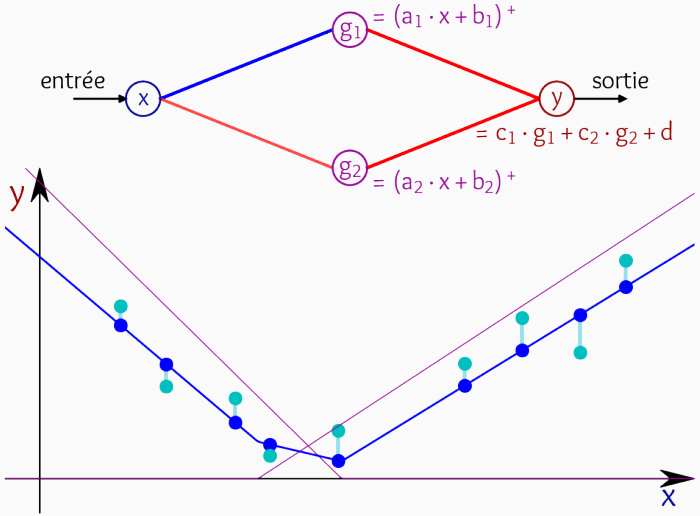

# Complexifions le modèle par l'ajout de variables intermédiaires...

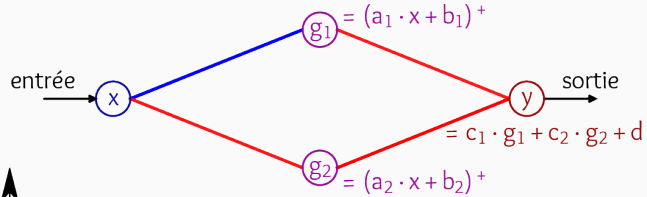


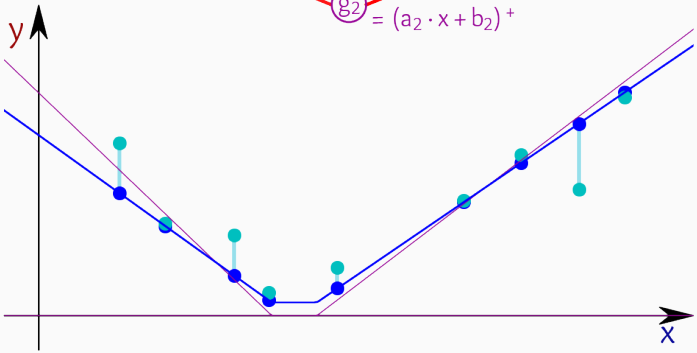

# Complexifions le modèle par l'ajout de variables intermédiaires...

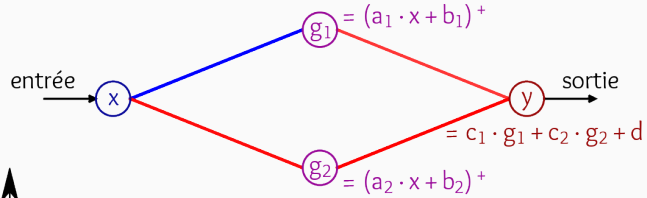


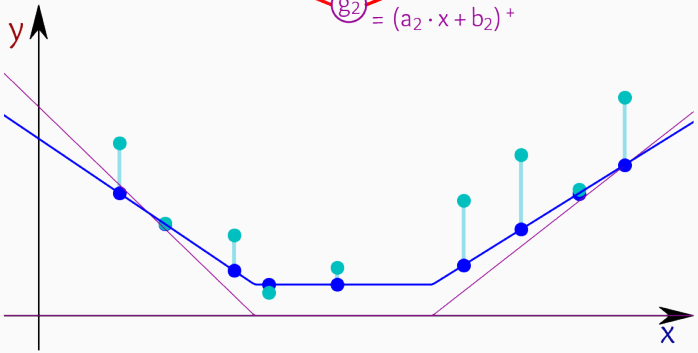

# Complexifions le modèle par l'ajout de variables intermédiaires...

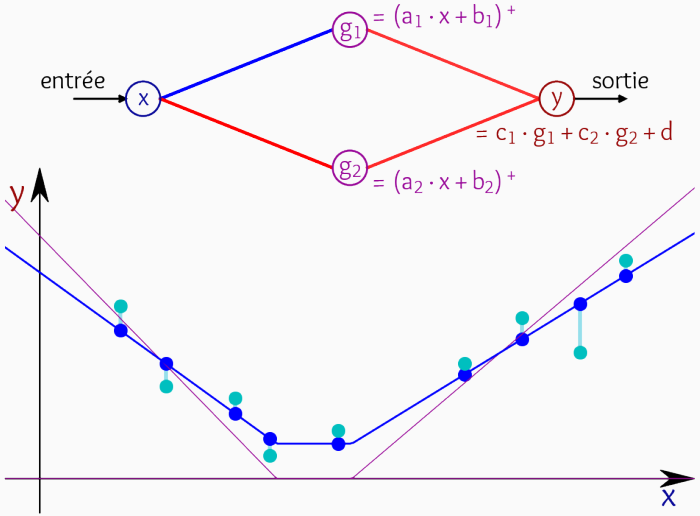

# Complexifions le modèle par l'ajout de variables intermédiaires...

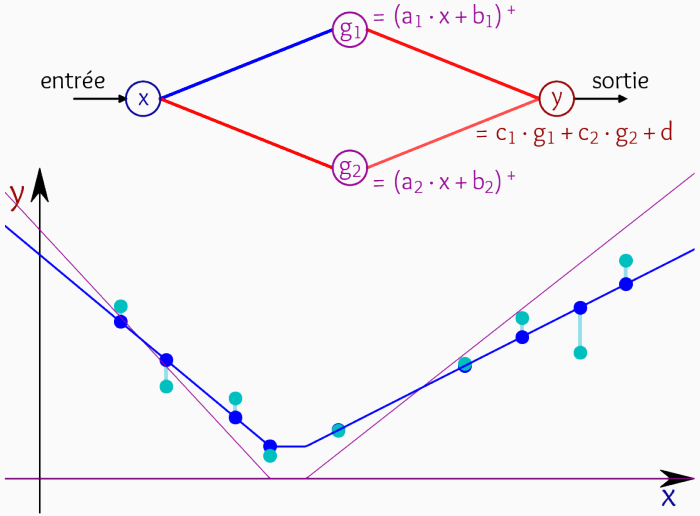

# Complexifions le modèle par l'ajout de variables intermédiaires...

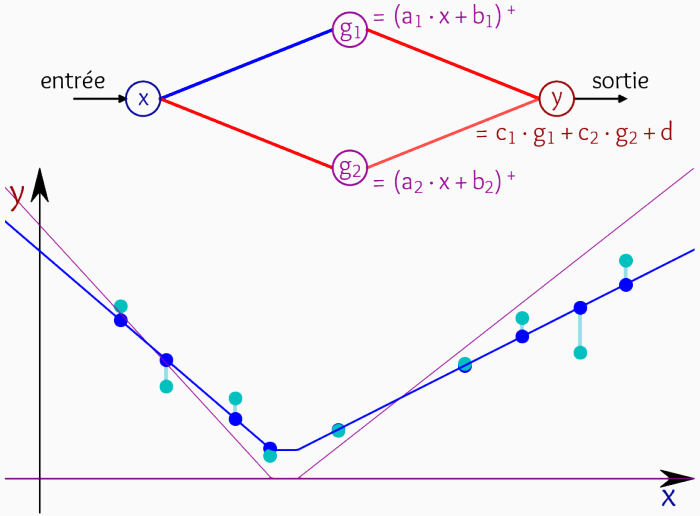

# Complexifions le modèle par l'ajout de variables intermédiaires...

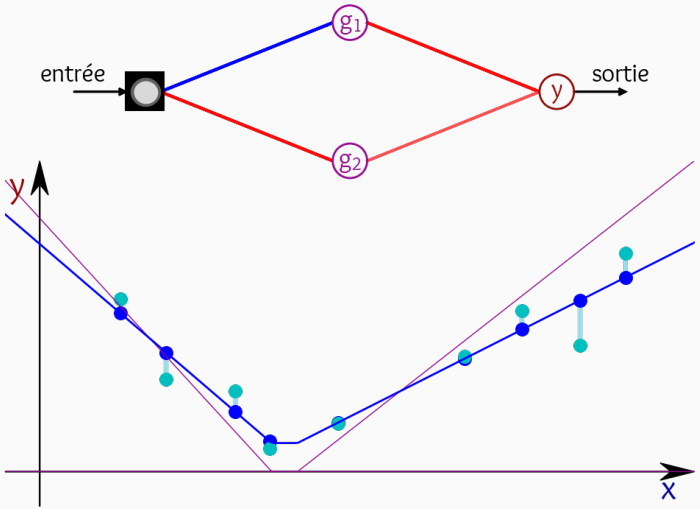

# Complexifions le modèle par l'ajout de variables intermédiaires...

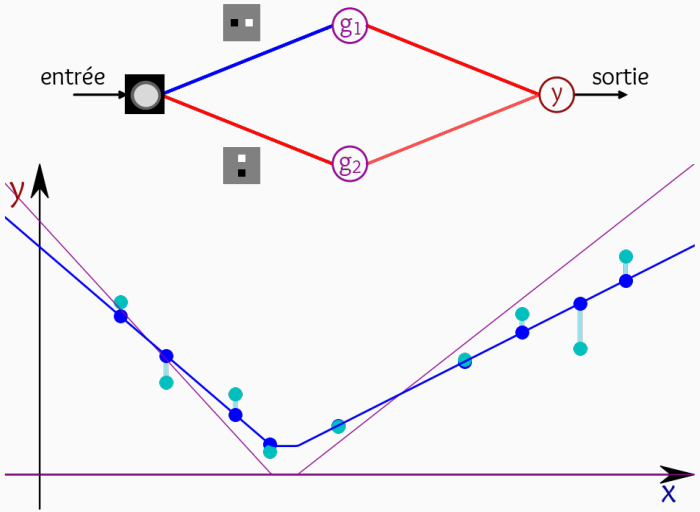

# Complexifions le modèle par l'ajout de variables intermédiaires...

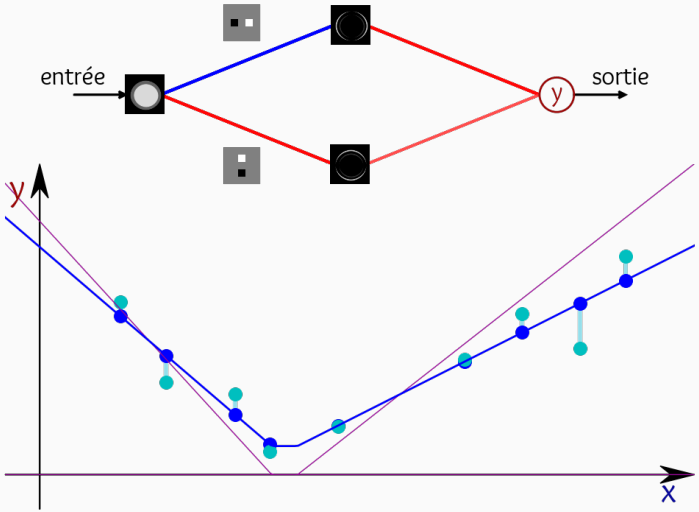

# Complexifions le modèle par l'ajout de variables intermédiaires...

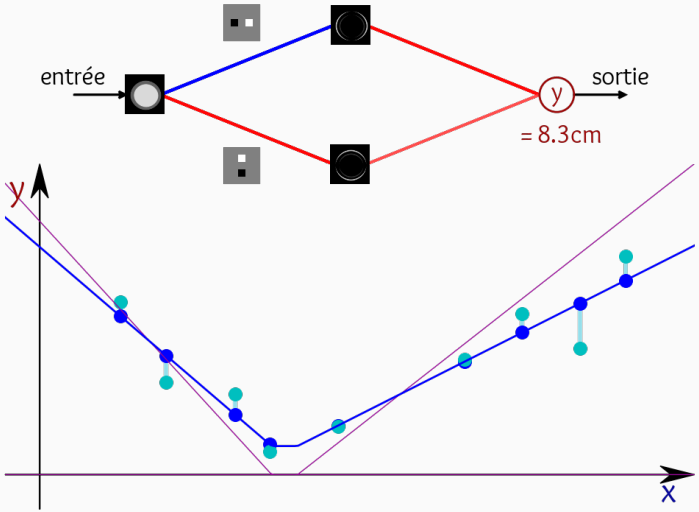

# On peut alors augmenter le nombre de “neurones” et de couches !

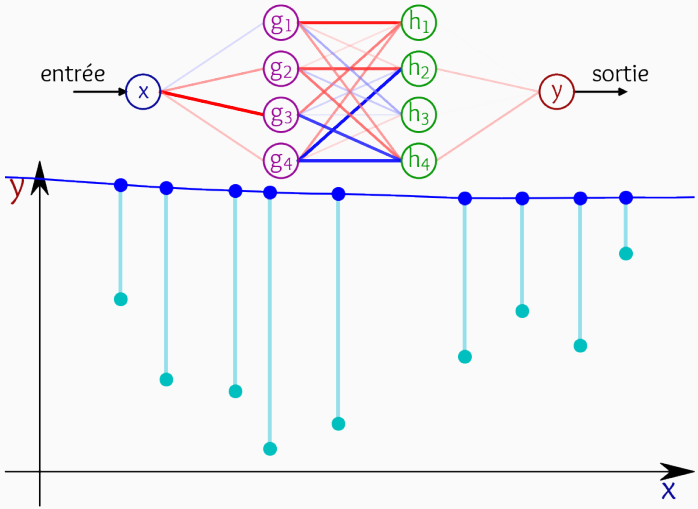

# On peut alors augmenter le nombre de “neurones” et de couches !

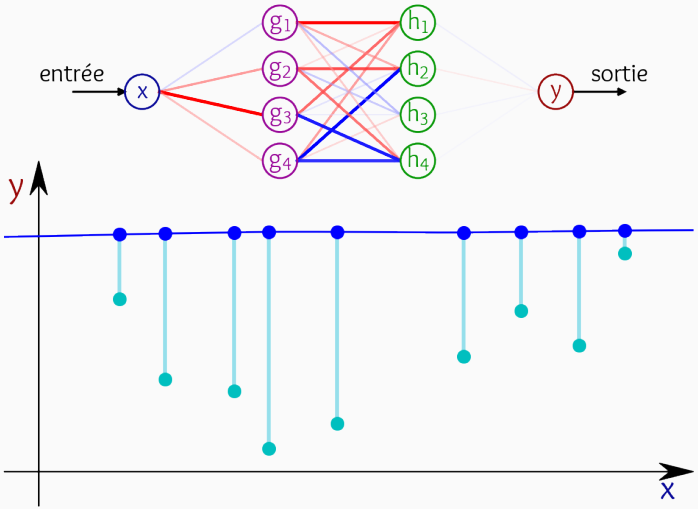

# On peut alors augmenter le nombre de “neurones” et de couches !

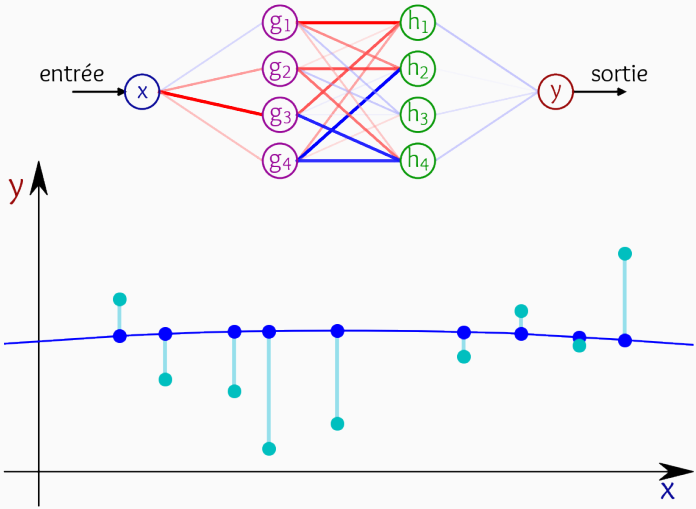

# On peut alors augmenter le nombre de “neurones” et de couches !

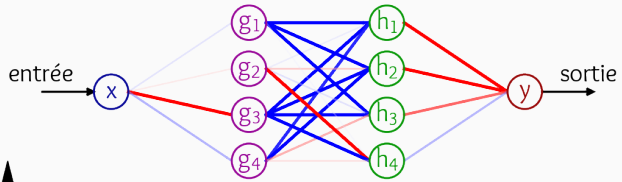


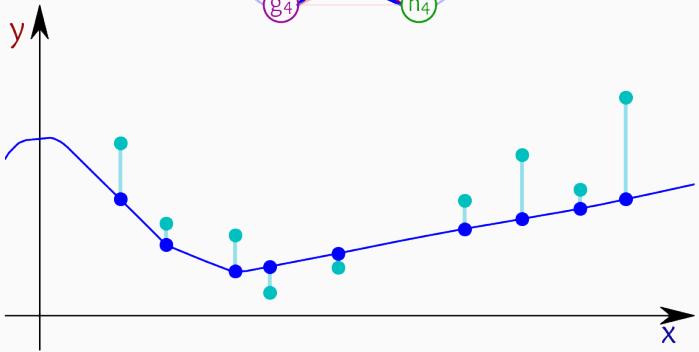

# On peut alors augmenter le nombre de “neurones” et de couches !

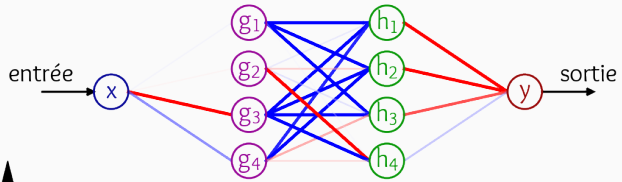


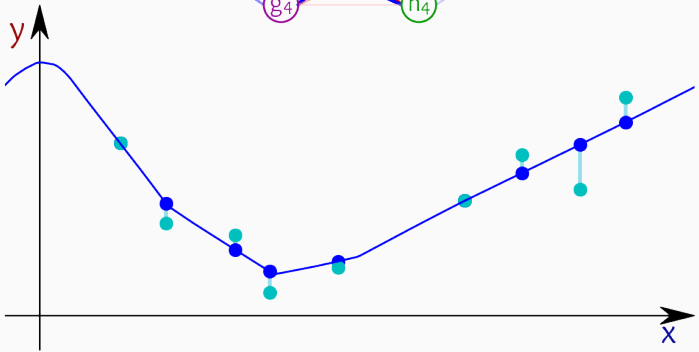

# On peut alors augmenter le nombre de “neurones” et de couches !

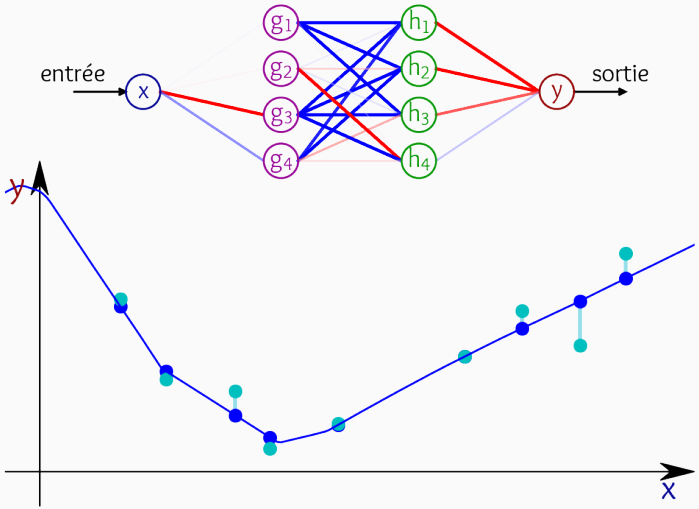

# On peut alors augmenter le nombre de “neurones” et de couches !

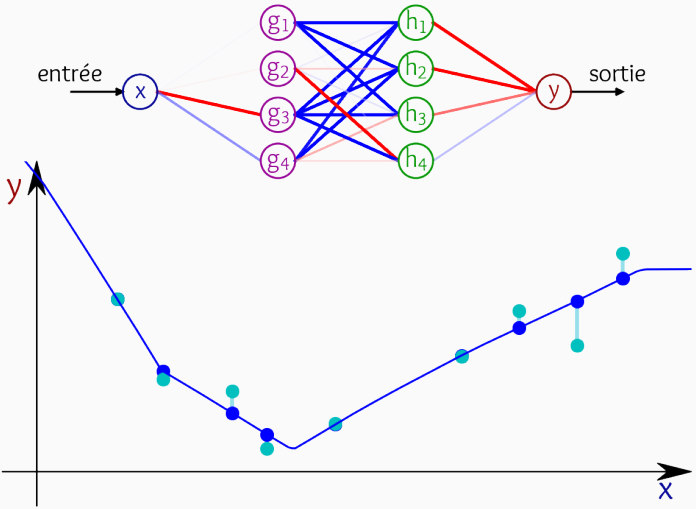

# On peut alors augmenter le nombre de “neurones” et de couches !

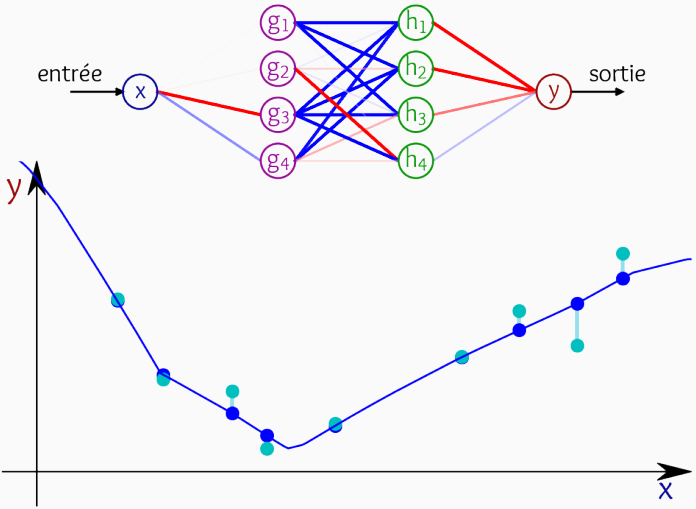

# On peut alors augmenter le nombre de “neurones” et de couches !

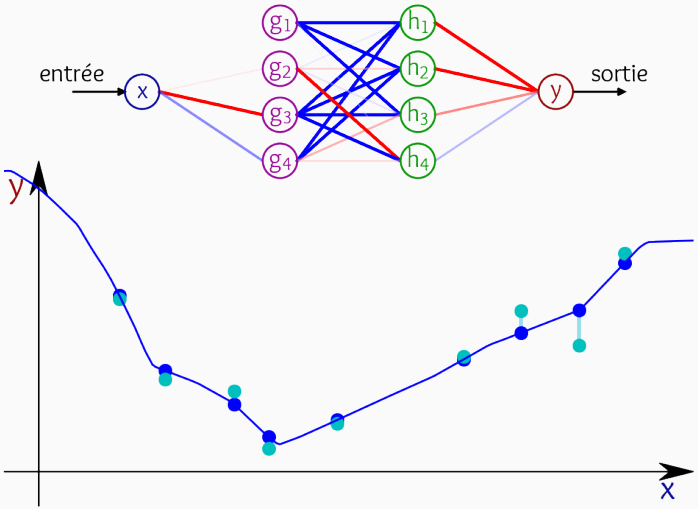

# On peut alors augmenter le nombre de “neurones” et de couches !

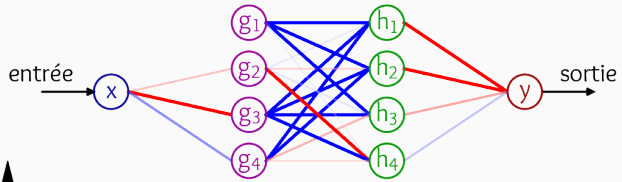


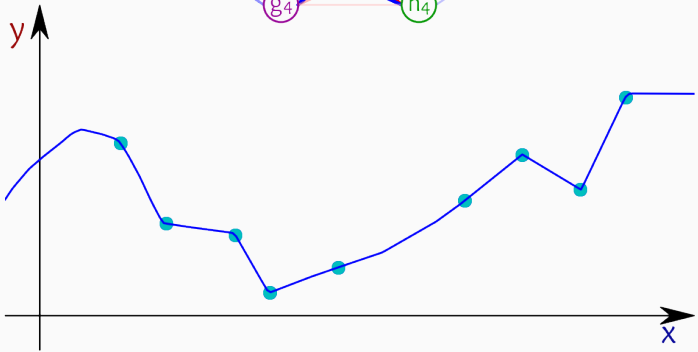

# On peut alors augmenter le nombre de “neurones” et de couches !

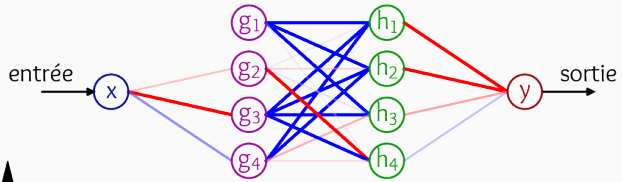


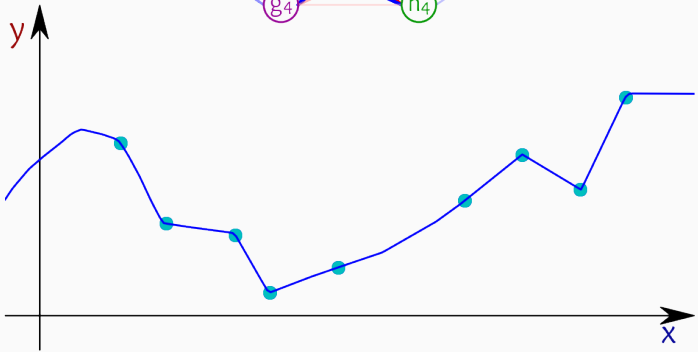

# Les réseaux de neurones, en bref

- Généralisation de la **régression linéaire** à des modèles arbitraires.

# Les réseaux de neurones, en bref

- Généralisation de la **régression linéaire** à des modèles arbitraires.
- Introduction de **variables intermédiaires** et de **coudes**.

# Les réseaux de neurones, en bref

- Généralisation de la **régression linéaire** à des modèles arbitraires.
- Introduction de **variables intermédiaires** et de **coudes**.
- Entraînement **naïf** (barre souple + ressorts).

# Les réseaux de neurones, en bref

- Généralisation de la **régression linéaire** à des modèles arbitraires.
- Introduction de **variables intermédiaires** et de **coudes**.
- Entraînement **naïf** (barre souple + ressorts).

# Les réseaux de neurones, en bref

- Généralisation de la **régression linéaire** à des modèles arbitraires.
- Introduction de **variables intermédiaires** et de **coudes**.
- Entraînement **naïf** (barre souple + ressorts).

Réseau de neurones générique
$\simeq$ **Interpolation** entre les échantillons de la BDD.

# Les réseaux de neurones, en bref

- Généralisation de la **régression linéaire** à des modèles arbitraires.
- Introduction de **variables intermédiaires** et de **coudes**.
- Entraînement **naïf** (barre souple + ressorts).

Réseau de neurones générique
$\simeq$ **Interpolation** entre les échantillons de la BDD.

**Est-ce suffisant ?**

# Analyse d'images $\neq$ Big Data générique

# Analyse d'images $\neq$ Big Data générique

1 nombre

$\rightarrow$ 5 échantillons

# Analyse d'images $\neq$ Big Data générique

1 nombre

$\rightarrow$ 5 échantillons

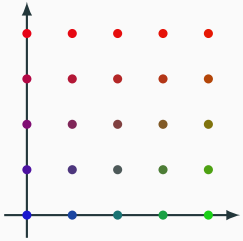

2 nombres

$\rightarrow 5^2$ échantillons

# Analyse d'images $\neq$ Big Data générique

1 nombre
$\rightarrow$ 5 échantillons

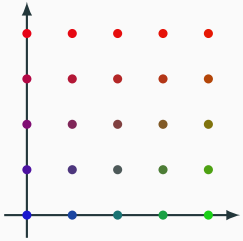

2 nombres
$\rightarrow 5^2$ échantillons

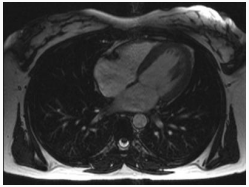

$128 \cdot 128$ nombres
$\rightarrow 5^{128 \cdot 128}$ échantillons

# Analyse d'images $\neq$ Big Data générique

1 nombre
$\rightarrow$ 5 échantillons

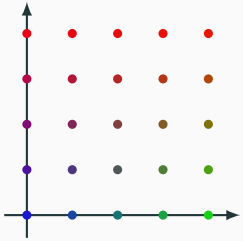

2 nombres
$\rightarrow 5^2$ échantillons

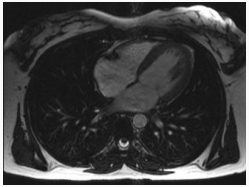

$128 \cdot 128$ nombres
$\rightarrow 5^{128 \cdot 128}$ échantillons

L'ensemble de toutes les images est **beaucoup trop vaste**
pour pouvoir être échantillonné avec la précision requise.

## En imagerie médicale, un bon modèle $F(\mathbf{w}; x) \simeq y$ doit donc :

Refléter un **a priori** raisonnable sur les données

Qu'est-ce qu'un scan IRM de cœur ? Un modèle déformé ?

## En imagerie médicale, un bon modèle $F(\mathbf{w}; x) \simeq y$ doit donc :

Refléter un **a priori** raisonnable sur les données

Qu'est-ce qu'un scan IRM de cœur ? Un modèle déformé ?

Être **contraignant**

Pour guider le modèle **en dehors** des cas couverts par la BDD.

## En imagerie médicale, un bon modèle $F(\mathbf{w}; x) \simeq y$ doit donc :

Refléter un **a priori** raisonnable sur les données

Qu'est-ce qu'un scan IRM de cœur ? Un modèle déformé ?

Être **contraignant**

Pour guider le modèle **en dehors** des cas couverts par la BDD.

Reposer sur des opérations **élémentaires**

Pour tourner sur des volumes 3D/4D.

## En imagerie médicale, un bon modèle $F(\mathbf{w}; x) \simeq y$ doit donc :

Refléter un **a priori** raisonnable sur les données

Qu'est-ce qu'un scan IRM de cœur ? Un modèle déformé ?

Être **contraignant**

Pour guider le modèle **en dehors** des cas couverts par la BDD.

Reposer sur des opérations **élémentaires**

Pour tourner sur des volumes 3D/4D.

$\Longrightarrow$ **Combinons la régression avec JPEG2000 !**

Analyse par filtrage multi-résolution :

$\Longrightarrow$ Réseaux de neurones convolutifs

# Vers une optimisation des filtres de JPEG 2000

Traitement du signal classique [Dam] :

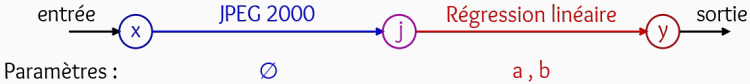


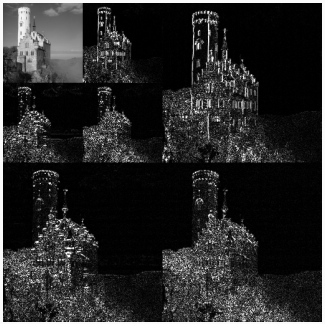

Traitement du signal moderne [PMC11] :

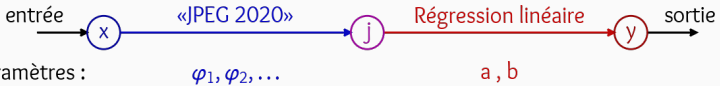


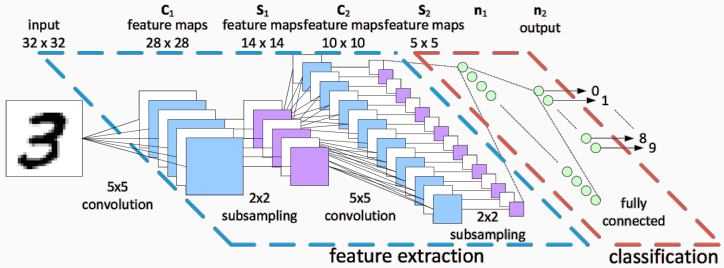

# Convolutional Neural Networks : un excellent compromis

JPEG2000, c'est un modèle $F(\mathbf{w}\,;x\,) \simeq y$ :

- Algorithmiquement simple.

# Convolutional Neural Networks : un excellent compromis

JPEG2000, c'est un modèle $F(\mathbf{w}\,;x\,) \simeq y$ :

- Algorithmiquement simple.
- Contraignant.

# Convolutional Neural Networks : un excellent compromis

JPEG2000, c'est un modèle $F(\mathbf{w}\,;x\,) \simeq y$ :

- Algorithmiquement simple.
- Contraignant.
- Encodant un a priori **multi-résolution** sur les images.

# Convolutional Neural Networks : un excellent compromis

JPEG2000, c'est un modèle $F(\mathbf{w}\,;x\,) \simeq y$ :

- Algorithmiquement simple.
- Contraignant.
- Encodant un a priori **multi-résolution** sur les images.

# Convolutional Neural Networks : un excellent compromis

JPEG2000, c'est un modèle $F(\mathbf{w}\,;x\,)\simeq y$ :

- Algorithmiquement simple.
- Contraignant.
- Encodant un a priori **multi-résolution** sur les images.

En **optimisant ses coefficients** sur une base d'images labellisées,
on obtient un **CNN** $\simeq$ "JPEG 2020" adapté au problème.

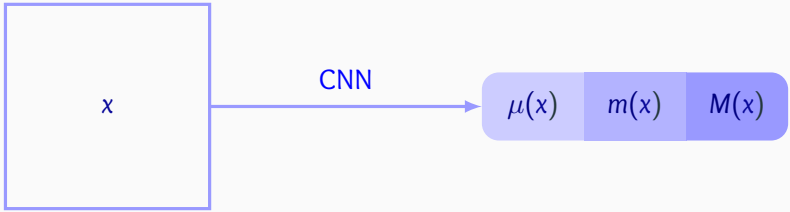

# Une application emblématique : le Deep Art [NN16]

# Une application emblématique : le Deep Art [NN16]

# Une application emblématique : le Deep Art [NN16]

# Une application emblématique : le Deep Art [NN16]

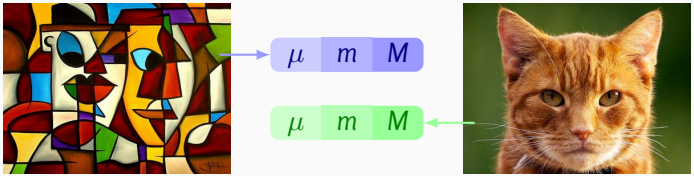

# Une application emblématique : le Deep Art [NN16]

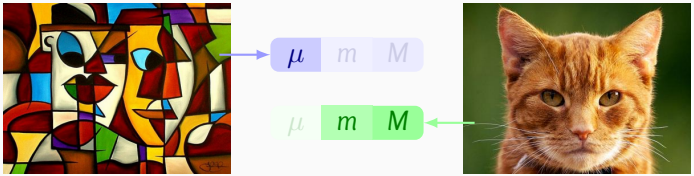

# Une application emblématique : le Deep Art [NN16]

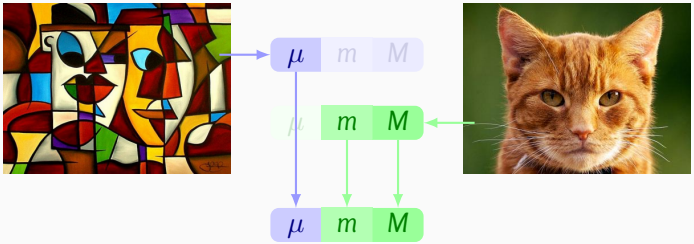

# Une application emblématique : le Deep Art [NN16]

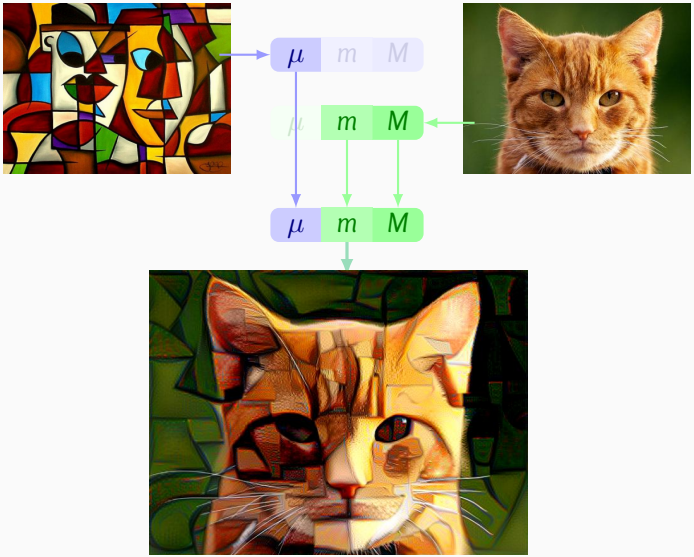

# Une application emblématique : le Deep Art [NN16]

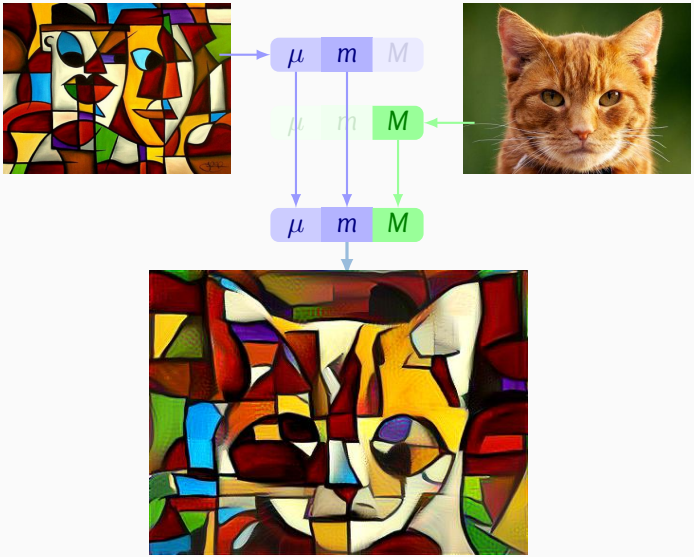

# Une application emblématique : le Deep Art [NN16]

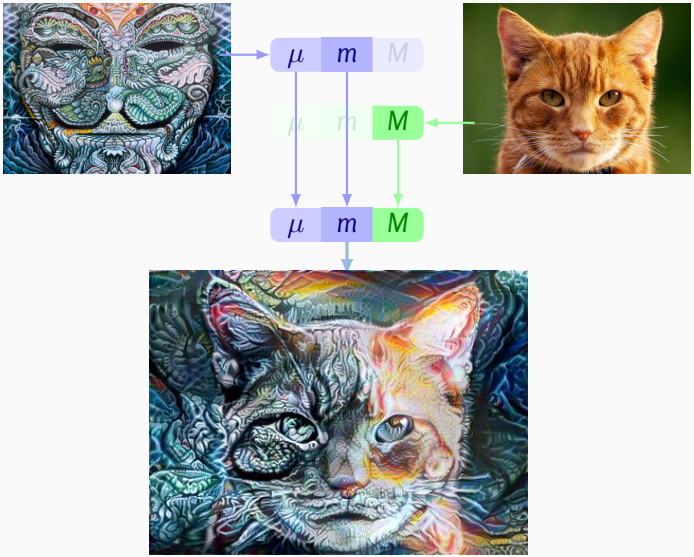

# Une application emblématique : le Deep Art [NN16]

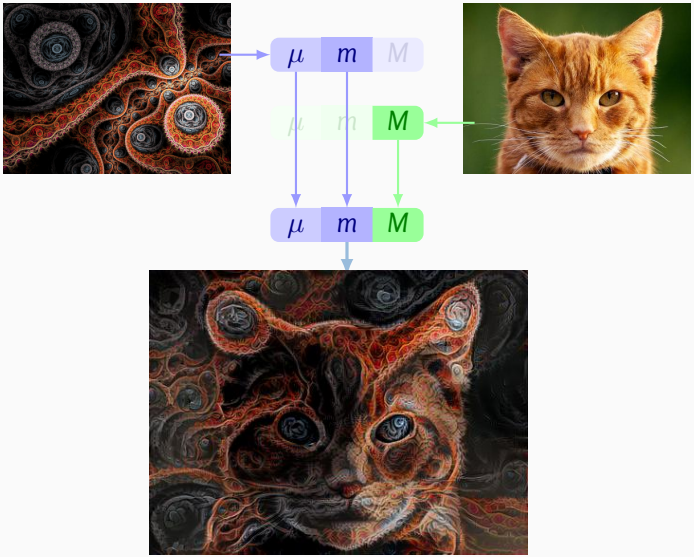

# Une application emblématique : le Deep Art [NN16]

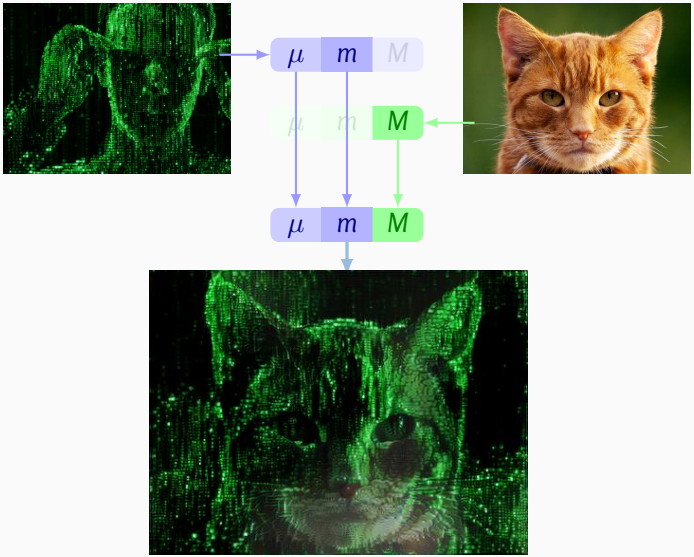

# Une application emblématique : le Deep Art [NN16]

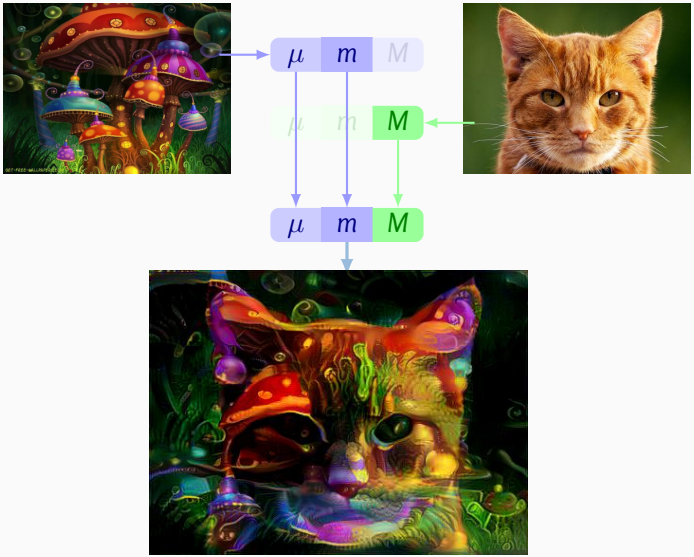

# Une application emblématique : le Deep Art [NN16]

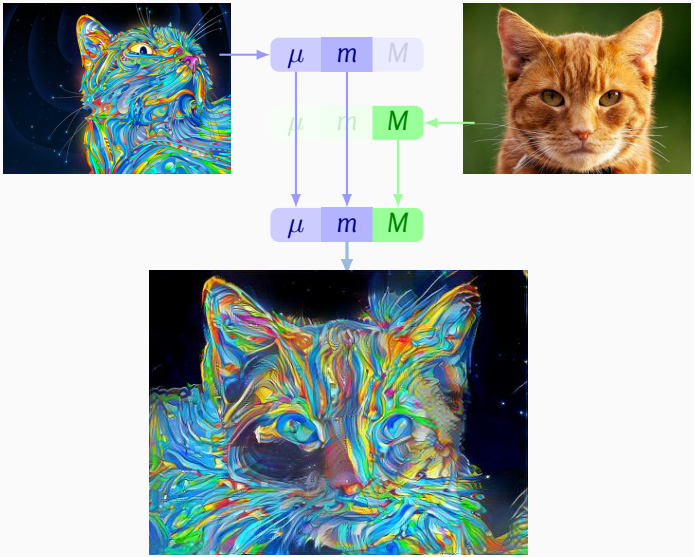

# Une application emblématique : le Deep Art [NN16]

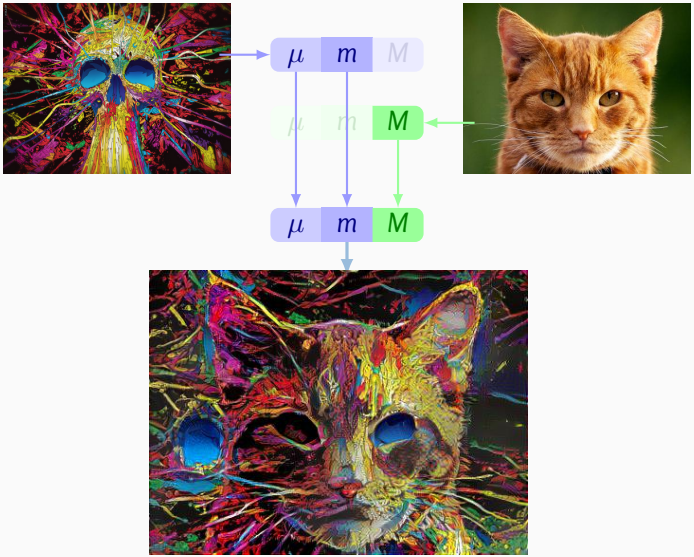

# Une application emblématique : le Deep Art [NN16]

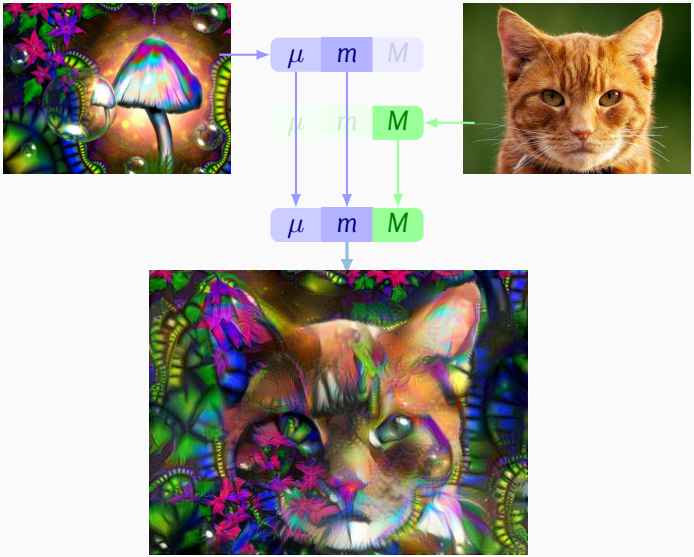

# Une application emblématique : le Deep Art [NN16]

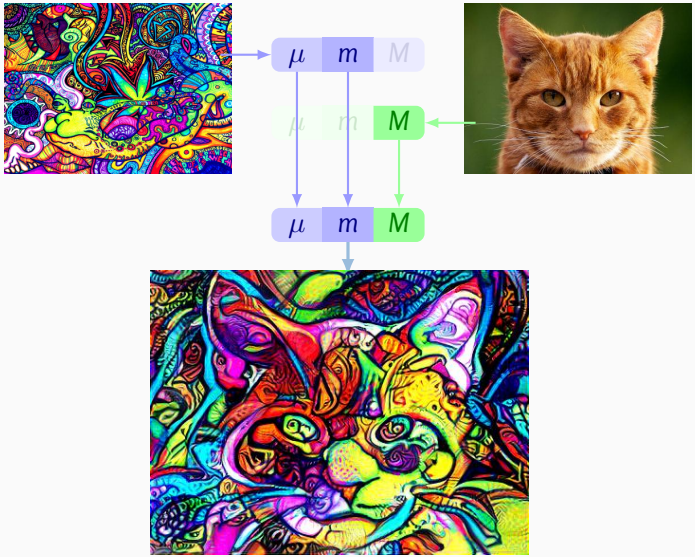

# Une application emblématique : le Deep Art [NN16]

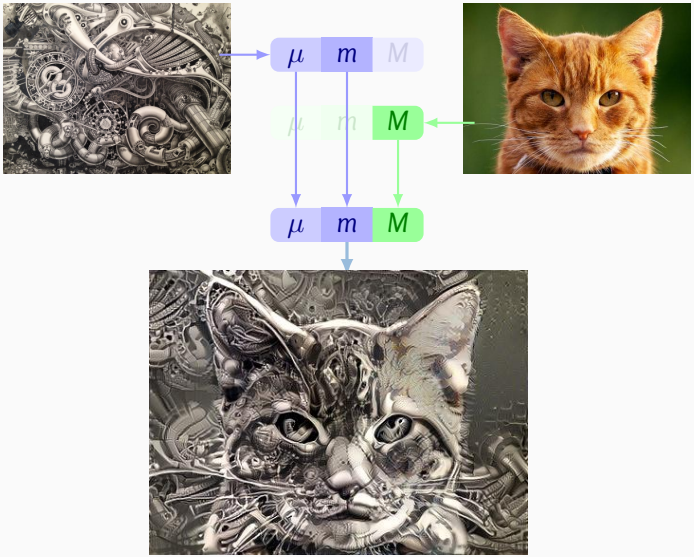

# Une application rêvée : la classification d'images

À partir de $\mathrm{CNN}(x) = [\,\mu(x)\,,\, m(x)\,,\, M(x)\,]$,
peut-on facilement **distinguer** une mouette d'un panda ?

# Une application rêvée : la classification d'images

À partir de CNN( x ) = [ $\mu(x)$ , $m(x)$ , $M(x)$ ],
peut-on facilement **distinguer** une mouette d'un panda ?

Ce que les chercheurs ont en tête [WZTF] :

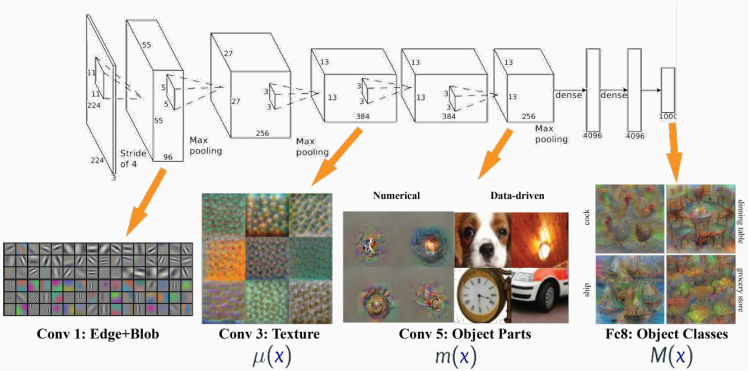

# Limites de l'analyse multi-résolution

Les CNNs font de la **détection de motif**, ni plus ni moins [NYC15] :

# Limites de l'analyse multi-résolution

Les CNNs font de la **détection de motif**, ni plus ni moins [NYC15] :

« $\mu(x)$ **est fiable ; $M(x)$ ne l'est pas.** »

# Limites de l'analyse multi-résolution

Les CNNs font de la **détection de motif**, ni plus ni moins [NYC15] :

« $\mu(x)$ **est fiable ;** $M(x)$ **ne l'est pas.** »

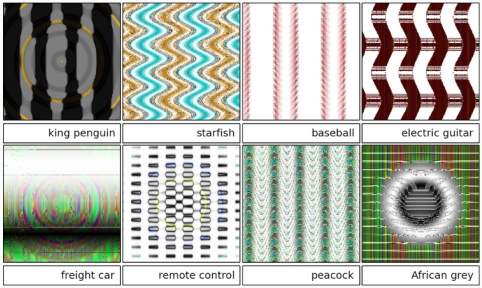

# Limites de l'analyse multi-résolution

Les CNNs font de la **détection de motif**, ni plus ni moins [NYC15] :

« $\mu(x)$ **est fiable ;** $M(x)$ **ne l'est pas.** »

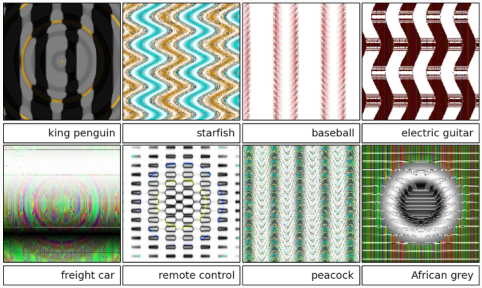

# Limites de l'analyse multi-résolution

Les CNNs font de la **détection de motif**, ni plus ni moins [NYC15] :

« $\mu(x)$ **est fiable ;** $M(x)$ **ne l'est pas.** »

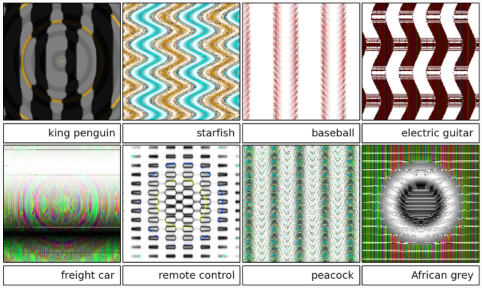


Problème : les modèles **structuraux** sont **beaucoup** plus coûteux.

(c'est mon métier… )

# Conclusion

# Un point sur le vocabulaire

On l'a vu :

Perceptron multicouche $\Longleftrightarrow$ Réseau de neurones

# Un point sur le vocabulaire

On l'a vu :

Perceptron multicouche $\Longleftrightarrow$ Réseau de neurones

Régression sur une banque de filtres multi-résolution $\Longleftrightarrow$ Apprentissage profond

# Un point sur le vocabulaire

On l'a vu :

Perceptron multicouche $\Longleftrightarrow$ Réseau de neurones

Régression sur une banque de filtres multi-résolution $\Longleftrightarrow$ Apprentissage profond

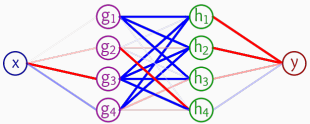


$\Longleftrightarrow^{?}$

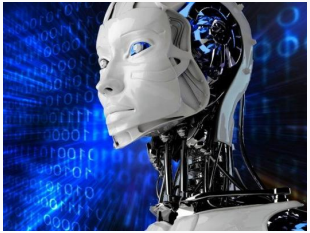

# Un point sur le vocabulaire

On l'a vu :

Perceptron multicouche $\Longleftrightarrow$ Réseau de neurones

Régression sur une banque de filtres multi-résolution $\Longleftrightarrow$ Apprentissage profond

$\overset{?}{\Longleftrightarrow}$

# Bilan

La révolution du Deep Learning, c'est :

- ~~L'intelligence artificielle.~~

# Bilan

La révolution du Deep Learning, c'est :

- ~~L'intelligence artificielle.~~
- Le premier modèle de **texture** vraiment convaincant.

# Bilan

La révolution du Deep Learning, c'est :

- ~~L'intelligence artificielle.~~
- Le premier modèle de **texture** vraiment convaincant.
- Le développement d'**outils logiciels** permettant de **tuner les paramètres** de nos modèles – TensorFlow, PyTorch...

# Bilan

La révolution du Deep Learning, c'est :

- ~~L'intelligence artificielle.~~
- Le premier modèle de **texture** vraiment convaincant.
- Le développement d'**outils logiciels** permettant de **tuner les paramètres** de nos modèles – TensorFlow, PyTorch...

# Bilan

La révolution du Deep Learning, c'est :

- ~~L'intelligence artificielle.~~
- Le premier modèle de **texture** vraiment convaincant.
- Le développement d'**outils logiciels** permettant de **tuner les paramètres** de nos modèles – TensorFlow, PyTorch...

Un logiciel d'analyse d'images repose **toujours** sur une **modélisation simpliste** des données.

Il n'y a pas de miracle.

# À retenir

Devant un produit “IA” :

- **« Montrez-moi ce qui ne marche pas. »**

# À retenir

Devant un produit “IA” :

- **« Montrez-moi ce qui ne marche pas. »**
- « **Expliquez-moi** cette erreur. »

# À retenir

Devant un produit “IA” :

- **« Montrez-moi ce qui ne marche pas. »**
- « **Expliquez-moi** cette erreur. »
- “Les données” **ne résoudront pas** automagiquement le problème.

# À retenir

Devant un produit “IA” :

- **« Montrez-moi ce qui ne marche pas. »**
- « **Expliquez-moi** cette erreur. »
- “Les données” **ne résoudront pas** automagiquement le problème.

# À retenir

Devant un produit “IA” :

- **« Montrez-moi ce qui ne marche pas. »**
- « **Expliquez-moi** cette erreur. »
- “Les données” **ne résoudront pas** automagiquement le problème.

Pour aller plus loin :

Cours de **Sciences des données** au Collège de France,

`www.college-de-france.fr/site/stephane-mallat/`

Jetez un œil à la leçon inaugurale, très accessible !

sites.google.com/view/masterclassiaimagerie/home


Mes TPs sont en ligne : www.math.ens.fr/~feydy/Teaching/

Merci pour votre attention.

Avez-vous des questions ?

# References i


Allessio Damato.
**Jpeg 2000 — wikipedia, the free encyclopedia.**
http://en.wikipedia.org/wiki/JPEG_2000.
Accessed : 2018-05-10.

Olivier Ecabert, Jochen Peters, and Matthew Walker.
**Segmentation of the heart and great vessels in ct images using a model-based adaptation framework.**
*Medical Image Analysis*, (15):863–876, 2011.

Stéphane Mallat.
**Understanding deep convolutional networks.**
*Phil. Trans. R. Soc. A*, 374(2065):20150203, 2016.

# References ii


Tomaso Mansi.
**A statistical model for quantification and prediction of cardiac remodelling : Application to tetralogy of fallot.**
*IEEE transactions on medical imaging*, 2011.

Yaroslav Nikulin and Roman Novak.
**Exploring the neural algorithm of artistic style.**
*arXiv preprint arXiv:1602.07188*, 2016.

# References iii


Anh Nguyen, Jason Yosinski, and Jeff Clune.
**Deep neural networks are easily fooled : High confidence predictions for unrecognizable images.**
In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pages 427–436, 2015.

Maurice Peemen, Bart Mesman, and Henk Corporaal.
**Speed sign detection and recognition by convolutional neural networks.**
In *Proceedings of the 8th International Automotive Congress*, pages 162–170, 2011.

# References iv


Donglai Wei, Bolei Zhou, Antonio Torralba, and William Freeman.
**mneuron : A matlab plugin to visualize neurons from deep models.**
http://vision03.csail.mit.edu/cnn_art/.
Accessed : 2018-05-10.