

# L'intelligence artificielle

Les réseaux de neurones  
« deep learning »

# **Intelligence artificielle :**

Selon les fondateurs de la cybernétique, le terme « intelligence artificielle » désigne un comportement produit par une machine dont on peut raisonnablement estimer que, s'il avait été le fruit d'une action humaine, il aurait exigé de l'intelligence de la part de l'agent concerné.

Source : wikipedia

Remarque : une calculatrice est une IA

# **Yann Le Cun**

Titulaire pour l'année de la chaire « Informatique et sciences numériques » du Collège de France.  
Scientifique en chef de l'IA chez Facebook.

# **Stephane Mallat**

Professeur du Collège de France sur la Chaire de Sciences des Données.

**Hugo Larochelle** (video you tube)

Un peu d'histoire...

Alan Turing (1912-1954) : concevoir une machine comme un enfant (test de Turing)

1956 : machine neuronal, apprentissage rudimentaire

1980 : retropropagation du gradient (victoire aux échecs)

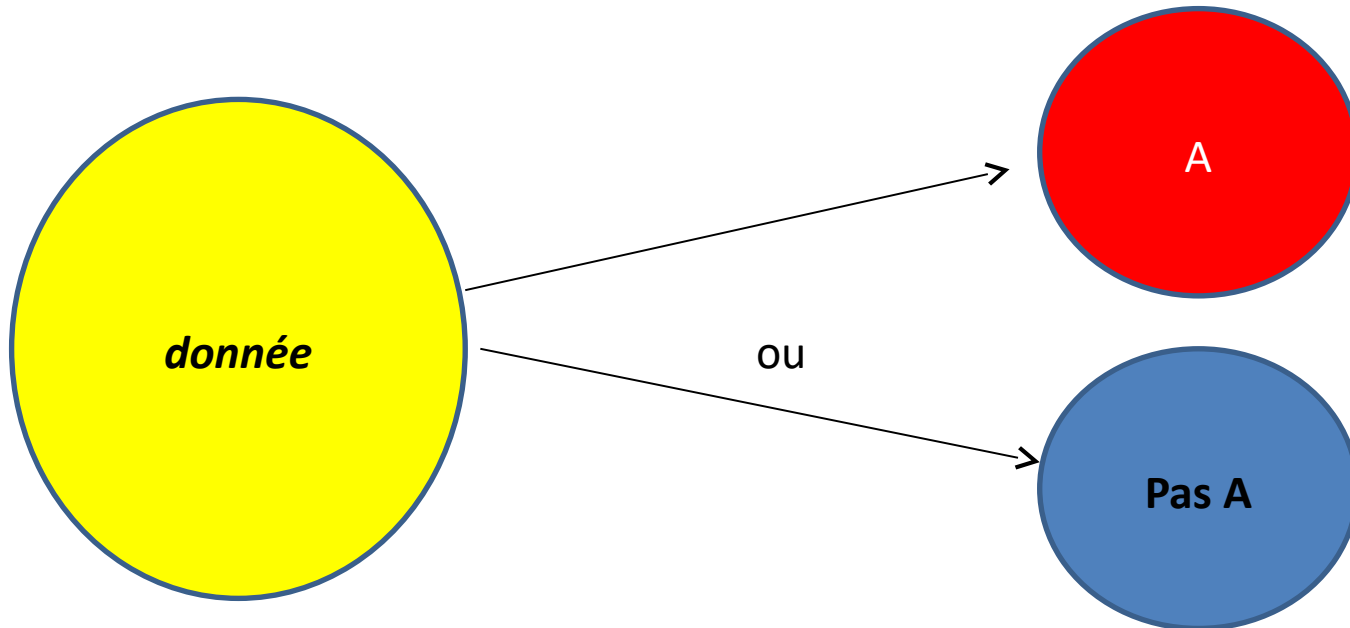
2012 : Avènement de l'IA : réseaux convolutifs, (bcp données, machine puissante)

# A quoi ça sert (actuellement et encore... )

- Vision par ordinateur (Imagerie médicale – reconnaissance faciale ou de caractère – détection de comportement -aide a la navigation)
- Traitement du langage et de la parole (Traduction- chatsbots – traitement de la voix, aide aux personnes mal entendante...)
- Robotiques <https://www.youtube.com/watch?v=sronAgjRHJw>
- Physique (calcul d'énergie, problème a N-corps, ...)
- Prédiction de comportement (élection, commerce, recrutement...)
- Jouer a des jeux (échec, go, ...)
- Militaires
- ...

# Prise de décision et prévision

Catégoriser des données



# IMAGERIE MEDICALE

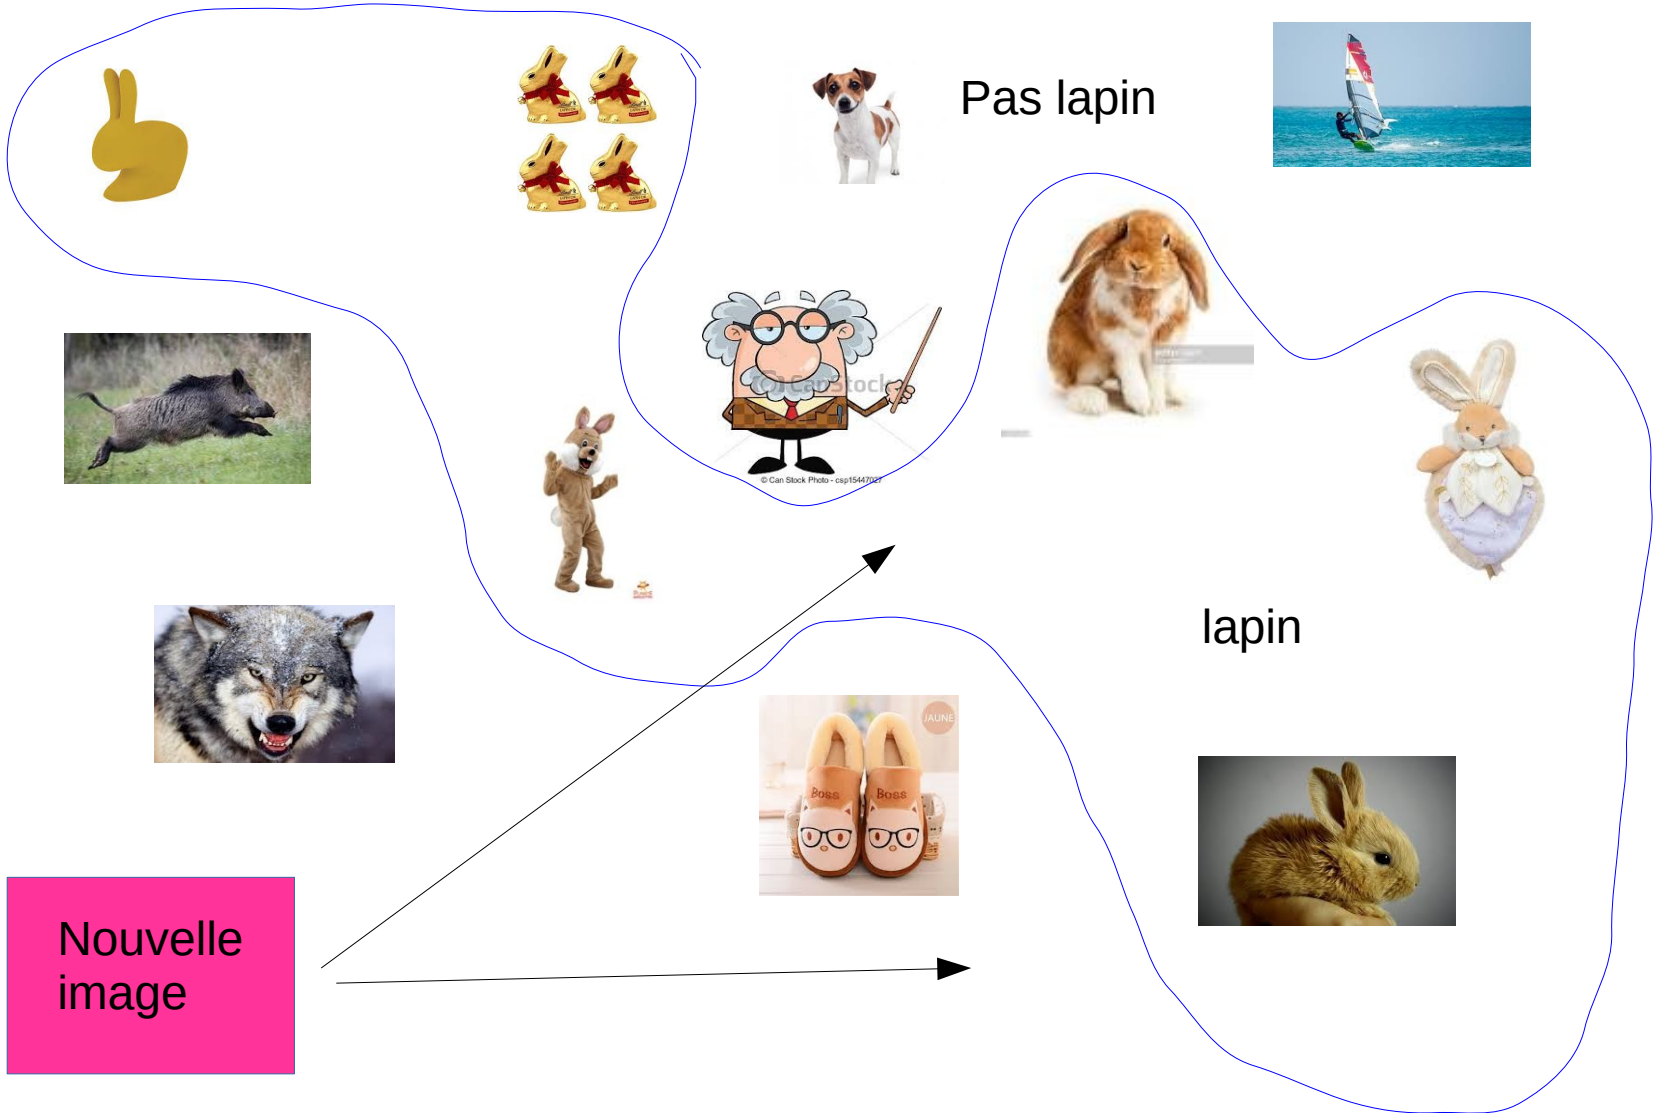


# Probleme : reconnaître les photos de lapins





# On a des données (par exemple fournie par internet)



# Comment entrer une photo dans un ordinateur ?

Une photo est un **VECTEUR** (une colonne de nombre) dans un Espace a n dimensions (n est la taille de la colonne)





48	49	46	42	44
110	79	54	47	48
190	192	190	153	99
150	166	189	203	183
131	140	145	161	165

48  
49  
46  
42  
44  
110  
79  
54

Photo de 30 sur 30 pixels  
N=900 !!

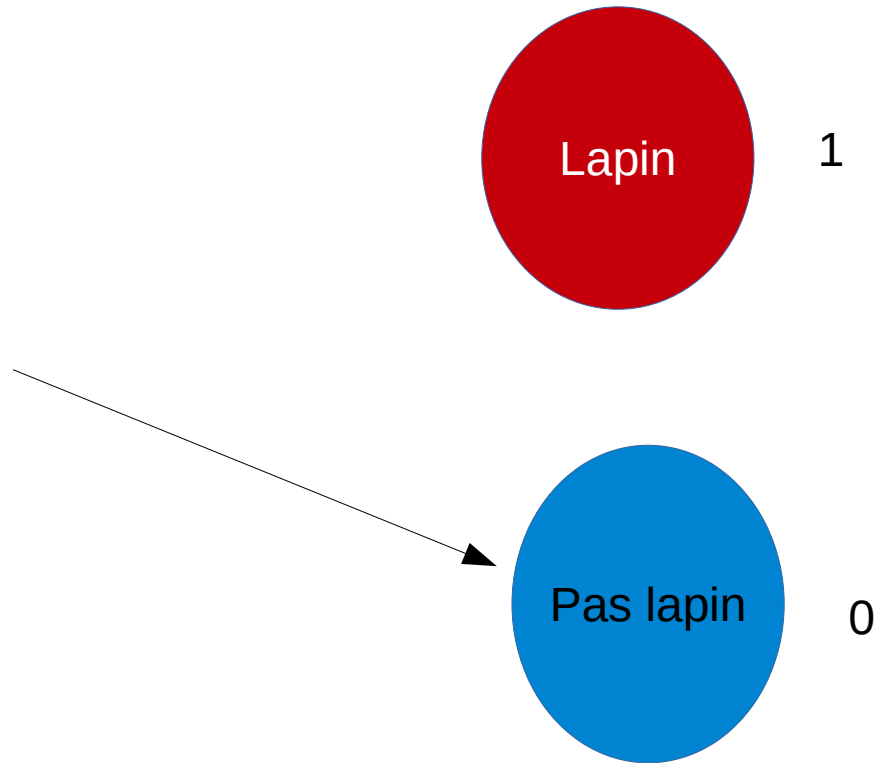
Une sortie est aussi un vecteur



1



0




Reconnaître des lapins c'est trouver une **fonction F** telle que :

$$F(v) = \begin{cases} 1 & \text{si } v = \text{photo de lapin} \\ 0 & \text{si } v = \text{photo de pas lapin} \end{cases}$$

**Problème** : Comment déterminer F  
(existe-t-elle, est-elle unique?)

# Comment déterminer la fonction $F$ ?


On a des données, c'est à dire des vecteurs  $v$  pour lesquels on connaît la sortie : **problème d'interpolation**




Et on **espère** que la fonction trouvée sera la **bonne** !

**Remarque** : un vecteur de taille  $n$  est un point dans un espace de dimension  $n$

Supposons  $n=2$  : une photo est alors un point dans le plan

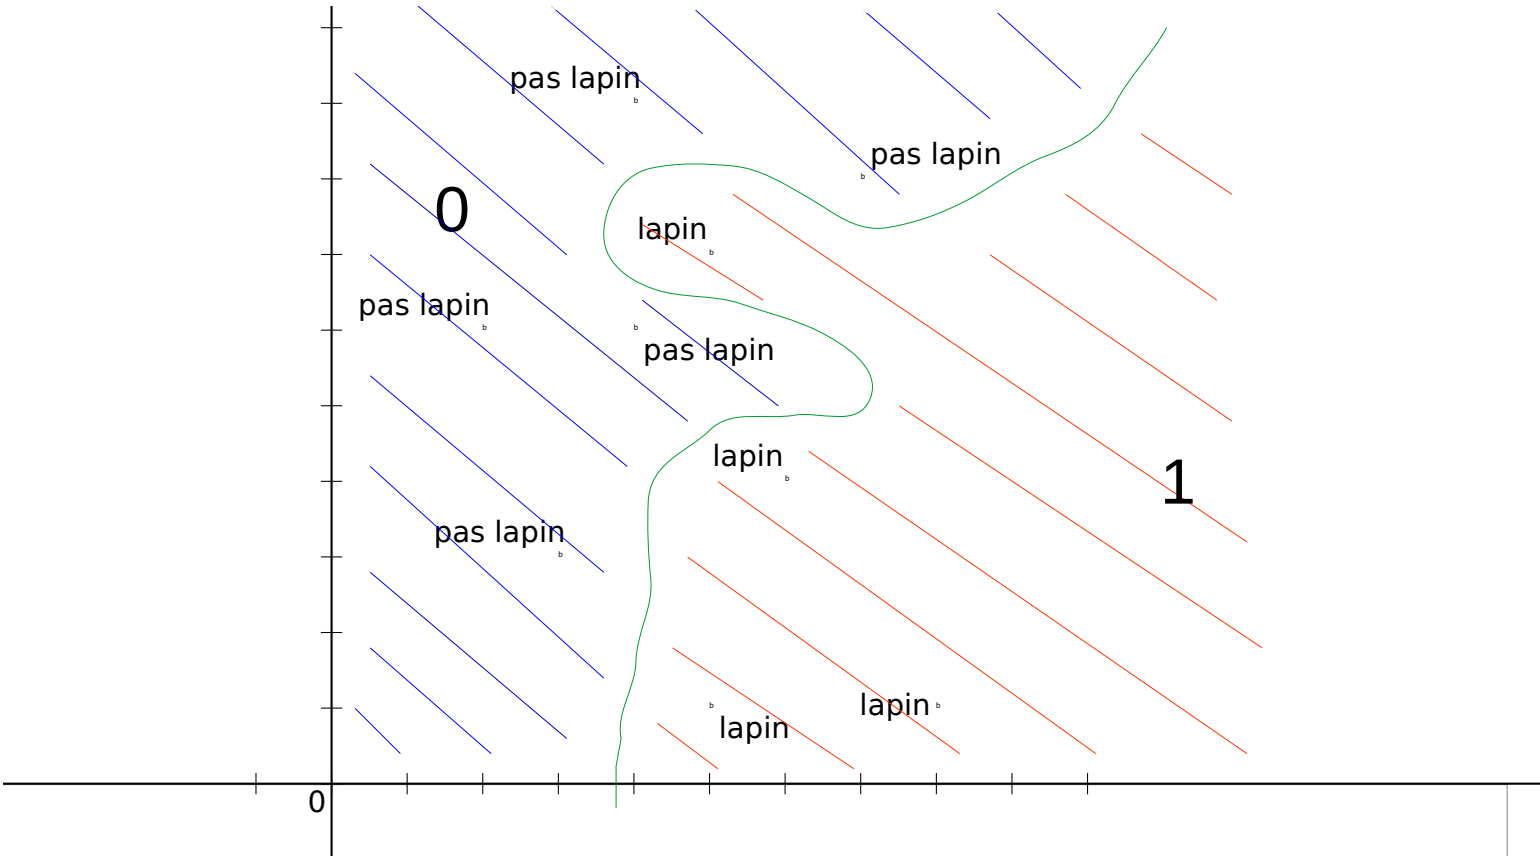







Les données sont des points dans un espace de dimension n

$$\varphi : (x; y) \mapsto \begin{cases} 1 & \text{si } (x; y) \text{ lapin} \\ 0 & \text{sinon} \end{cases}$$



Si on a beaucoup d'exemples, c'est un probleme assez simple...



$$F : v \mapsto \begin{cases} 1 & \text{si dans } B(v; \epsilon) \text{ } \#\text{lapin} \geq \#\text{paslapin} \\ 0 & \text{sinon} \end{cases}$$

Mais a-t-on vraiment beaucoup d'exemples ?

Image de 30 sur 30 pixels : le vecteur de l'image a 900 coordonnées

Si chaque coordonnées prend 10 valeurs alors on a :


**$10^{900}$  images possibles**

Si  $10^9$  exemples alors la proportion d'exemples est de :

**$1/10^{881}$**

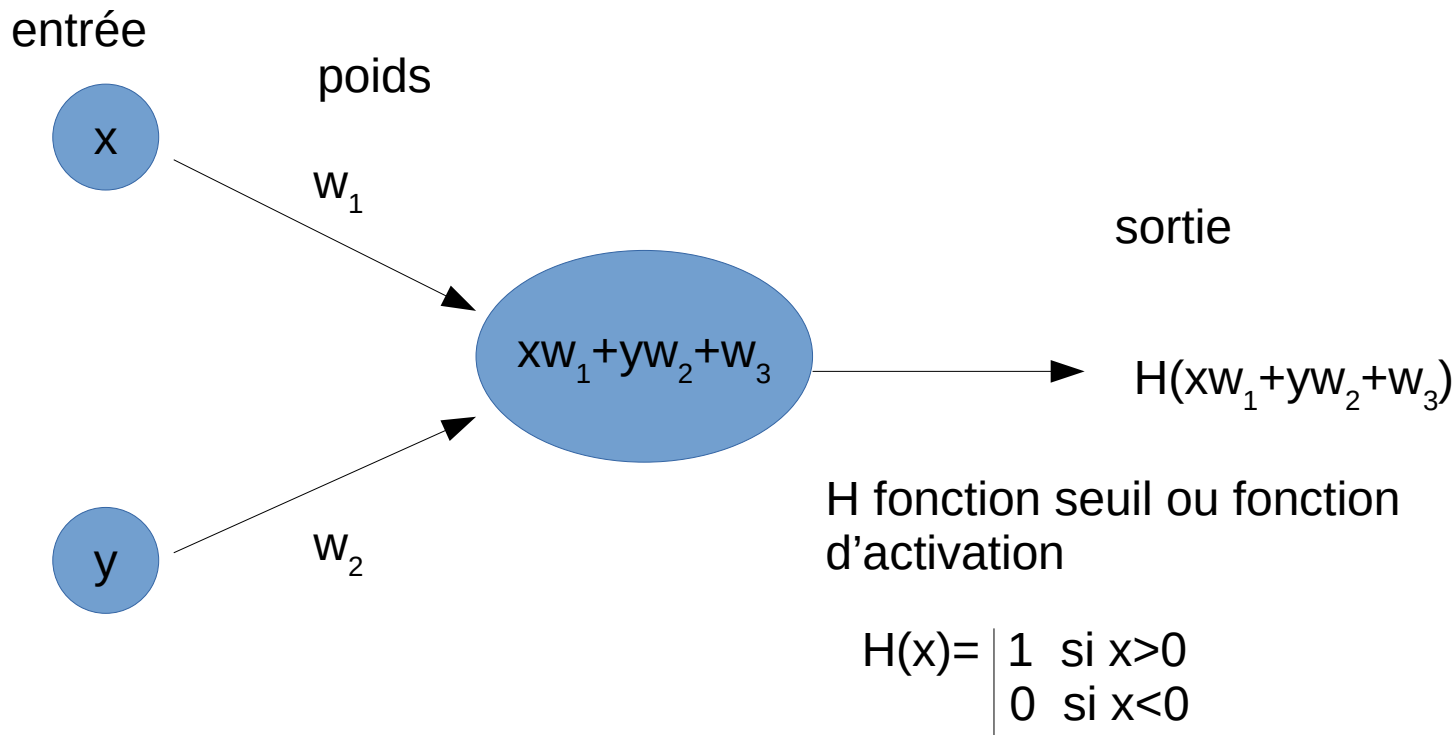
La distance moyenne entre deux images est d'environ de **12** unités

# Réseau de neurones



# LE PERCEPTRON (ou neurone)

ou comment trouver cette fonction



(Remarque : on veut une fonction H dérivable)

Chaque choix des poids donne une nouvelle fonction : **il faut donc choisir les poids**

## Comment déterminer les bons poids ?

On cherche les poids  $w_1, w_2, w_3$  tels que le coût :


$$C(w_1; w_2; w_3) = \sum_{\text{Exemples}} [H(w_1x + w_2y + w_3) - z]^2$$

soit **minimum**

Ou  $(x;y)$  est un exemple et  $z$  la sortie désirée pour cette exemple.

La fonction  $F:(x;y) \longrightarrow H(w_1x+w_2y+w_3)$

est une bonne fonction sur les exemples



On cherche à minimiser

$$\mathbf{C}(\mathbf{W}) = \sum_{\text{Exemples}} [\mathbf{H}(\mathbf{W} \cdot \mathbf{X}) - \mathbf{z}]^2$$

où  $W = (w_1; w_2; w_3)$ ,  $X = (x; y; 1)$  et  $z$  est la sortie attendu pour  $X$

### Principe de l'algorithme

1. On prend des poids  $W$  au hasard
2. Tant que le minimum de  $C(W)$  n'est pas atteint, faire :
  - (a) On prend un exemple  $X$  au hasard
  - (b) On modifie les poids (pour diminuer  $[H(W \cdot X) - z]^2$ )


$$W \leftarrow W - \eta \nabla [H(W \cdot X) - z]^2$$

Où  $\nabla f$  est le gradient de  $f(x_1; \dots; x_n)$

$$\nabla f = \left( \frac{\delta f}{\delta x_1}; \dots; \frac{\delta f}{\delta x_n} \right)$$



# Comment modifier les poids : la descente de gradient




$$f(x + h) \simeq f(x) + hf'(x)$$

Si  $h = -\eta f'(x)$ , pas  $\eta > 0$

alors  $f(x + h) \simeq f(x) - \eta[f'(x)]^2$

Si  $f'(x) \neq 0$ ,  $f(x + h) < f(x)$


# UN RESEAU DE NEURONE




$$z_i = H(w_{i,1}x + w_{i,2}y + w_{i,3})$$

Chaque choix des poids donne une nouvelle fonction : il faut donc choisir les poids


# UN RESEAU PLUS PROFOND



**ENCORE PLUS GROS**





# RESEAUX CONVOLUTIFS




# La convolution

$$(f * g)(x) = \int_{-\infty}^{+\infty} f(x - t)g(t) dt$$






Underfitting



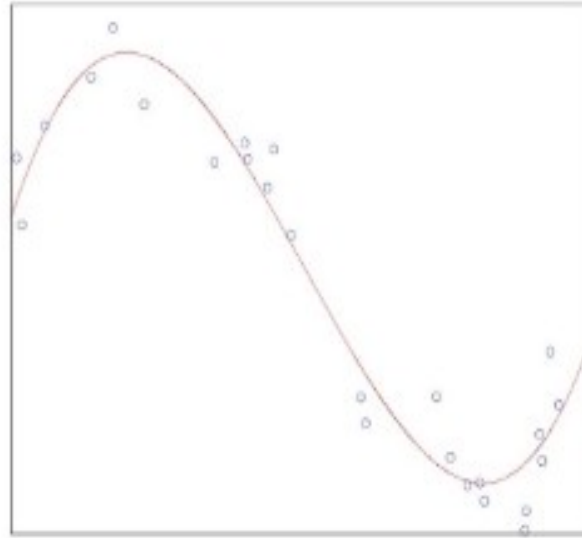
Desired




Overfitting



**underfit**  
(degree = 1)



**ideal fit**  
(degree = 3)



**overfit**  
(degree = 20)