

Modèles Multiéchelles et Réseaux de Neurones Convolutifs



COLLÈGE
DE FRANCE
— 1530 —

Cours 1

▪ *Introduction aux réseaux
de Neurones Convolutifs*

Stéphane Mallat



Prediction: Supervised Learning

- High-dimensional $x = (x(1), \dots, x(d)) \in \mathbb{R}^d$:
- **Classification:** estimate a class label $f(x)$
given n sample values $\{x_i, y_i = f(x_i)\}_{i \leq n}$

Image Classification $d = 10^6$

Anchor



Joshua Tree



Beaver



Lotus



Water Lily



Huge variability
inside classes



Prediction: Supervised Learning

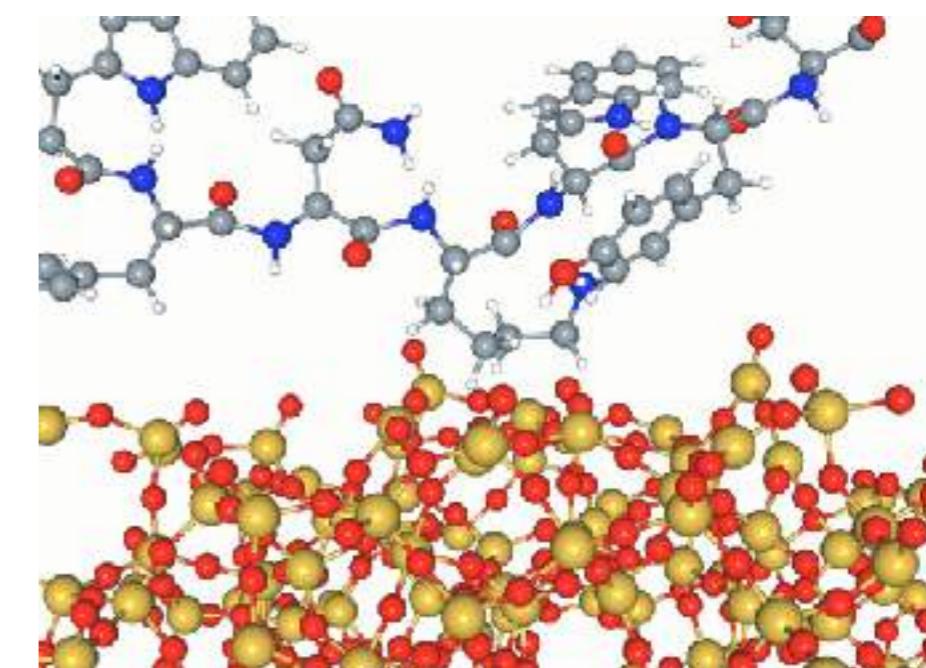
- High-dimensional $x = (x(1), \dots, x(d)) \in \mathbb{R}^d$:
- **Regression:** approximate a *functional* $f(x)$
given n sample values $\{x_i, y_i = f(x_i) \in \mathbb{R}\}_{i \leq n}$

Physics: energy $f(x)$ of a state vector x

Astronomy

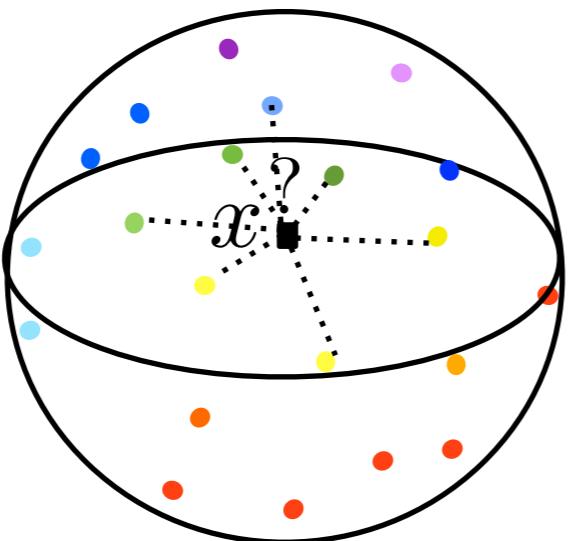


Quantum Chemistry



Curse of Dimensionality

- $f(x)$ can be approximated from examples $\{x_i, f(x_i)\}_i$ by local interpolation if f is regular and there are close examples:



- Need $n \geq \epsilon^{-d}$ points to cover $[0, 1]^d$ at a Euclidean distance ϵ
Problem: $\|x - x_i\|$ is always large
- To estimate $f(x)$ when x is in a high-dimensional Ω
requires *strong regularity* of f in Ω : what regularity ?

Linearize with a Representation

Change of variable $\Phi(x) = \{\phi_k(x)\}_{k \leq d'}$ to nearly linearize class boundaries, and approximate $f(x)$ by:

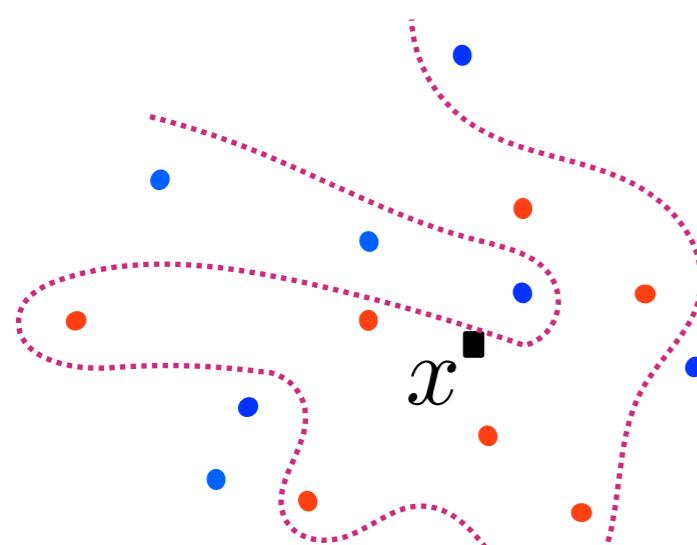
$$\tilde{f}(x) = \text{sign}(\langle w, \Phi(x) \rangle + b) = \text{sign}\left(\sum_k w_k v'_k + b\right)$$

$$x = (v_1, \dots, v_d)$$



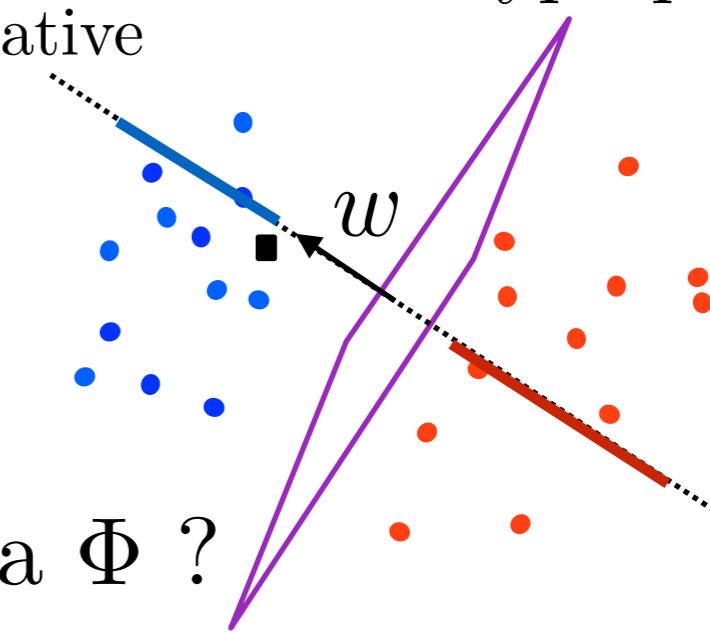
$$\Phi(x) = (v'_1, \dots, v'_d)$$

V : hyperplane



discriminative
direction

$$\Phi$$



- How and when is possible to find such a Φ ?
 - Only from a priori information on $f(x)$
 - Learned from data, with some a priori : neural networks



Challenges de Données

challengedata.ens.fr

- Données: images, séries temporelles, textes
- Calculer une prédiction \tilde{y} de y à partir de données x
- Exemples supervisés $\{x_i, y_i\}_{i \leq n}$
- Données de test $\{x_i^t\}_{i \leq n_t}$
- On doit calculer une prédiction \tilde{y}_i^t de chaque y_i^t inconnu
- Erreur évaluée par une fonction de risque $r(\tilde{y}, y)$

$$\text{Score} = n_t^{-1} \sum_{i=1}^{n_t} r(\tilde{y}_i^t, y_i^t)$$

- Maximum 2 soumissions par jour
- Résultat sur données cachées: intermédiaire 19/3/20, final 15/12/20.
- Oral entre le 23 et 27 Mars pour étudiants de M2 du MVA et PSL.



Challenges de Données

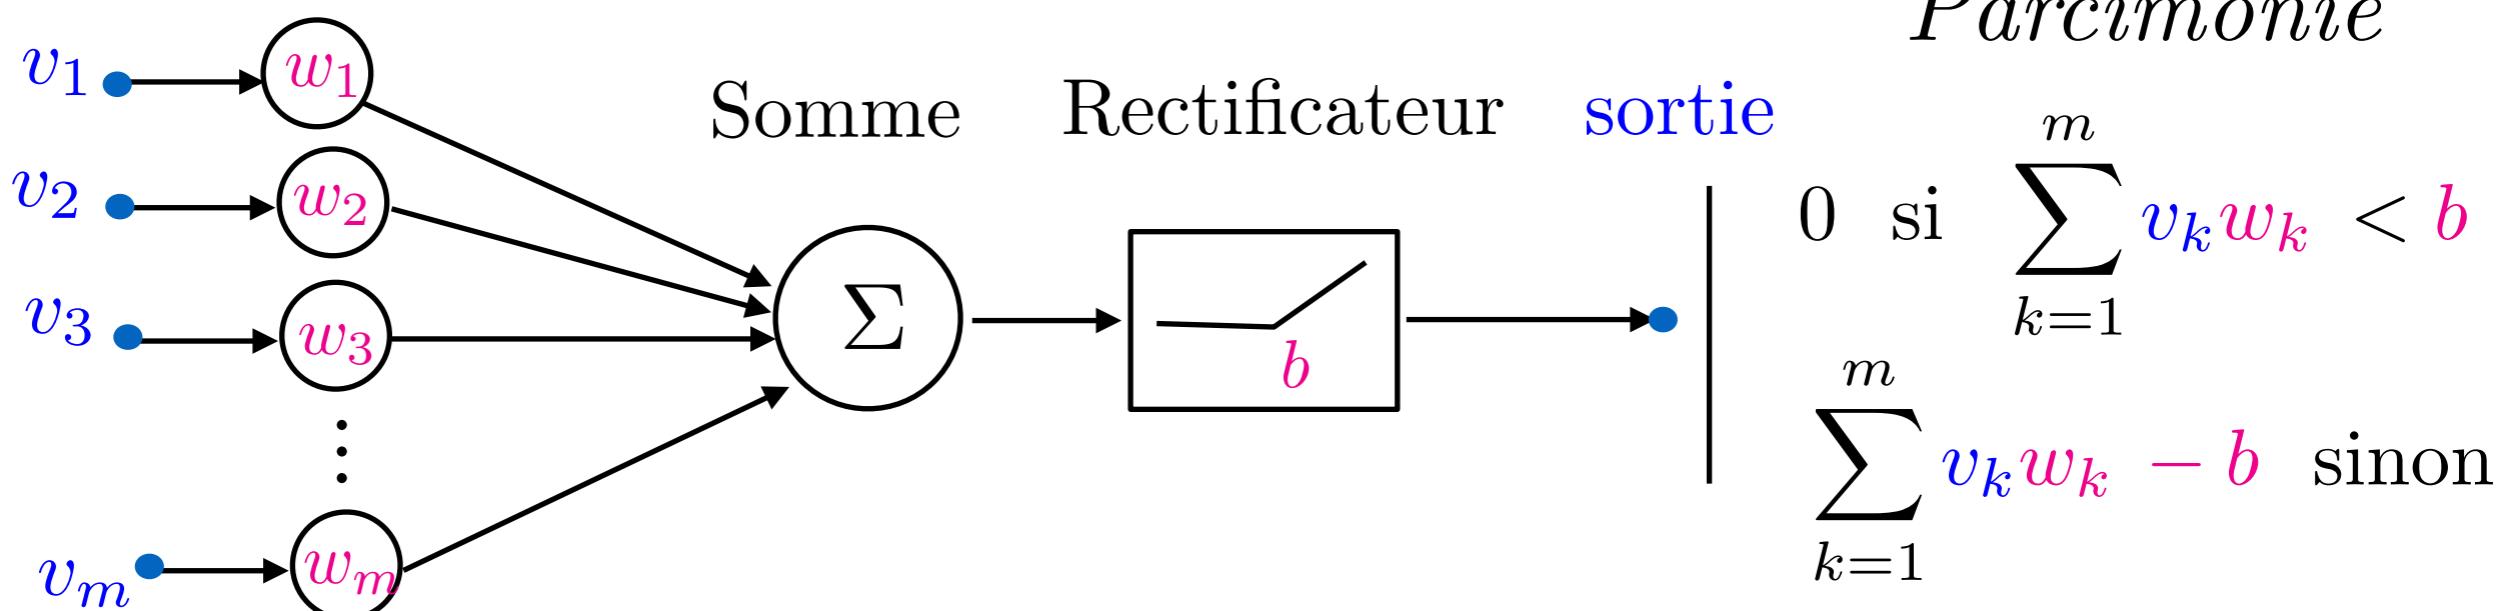
challengedata.ens.fr

- Confronter la « théorie » à l’algorithmique et aux résultats
- Le projet est l’occasion de se poser des questions
- Développer une représentation $\Phi(x)$ basée sur des a priori
- Eventuellement comparer avec des réseaux de neurones



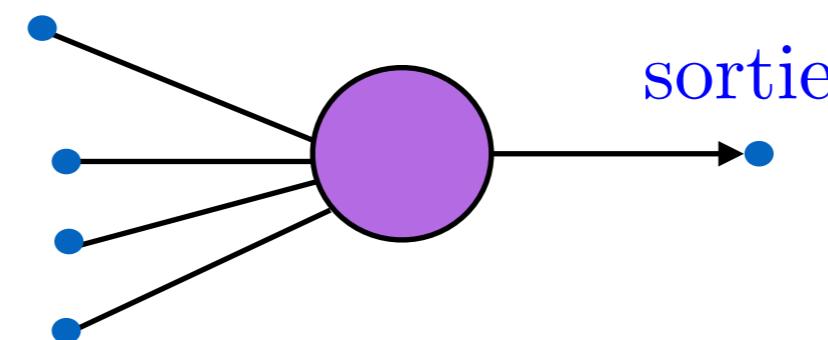
- Début dans les années 1950 : inspiration biologique
McCulloch & Pitts : modèle de neurone de grenouilles

entrées



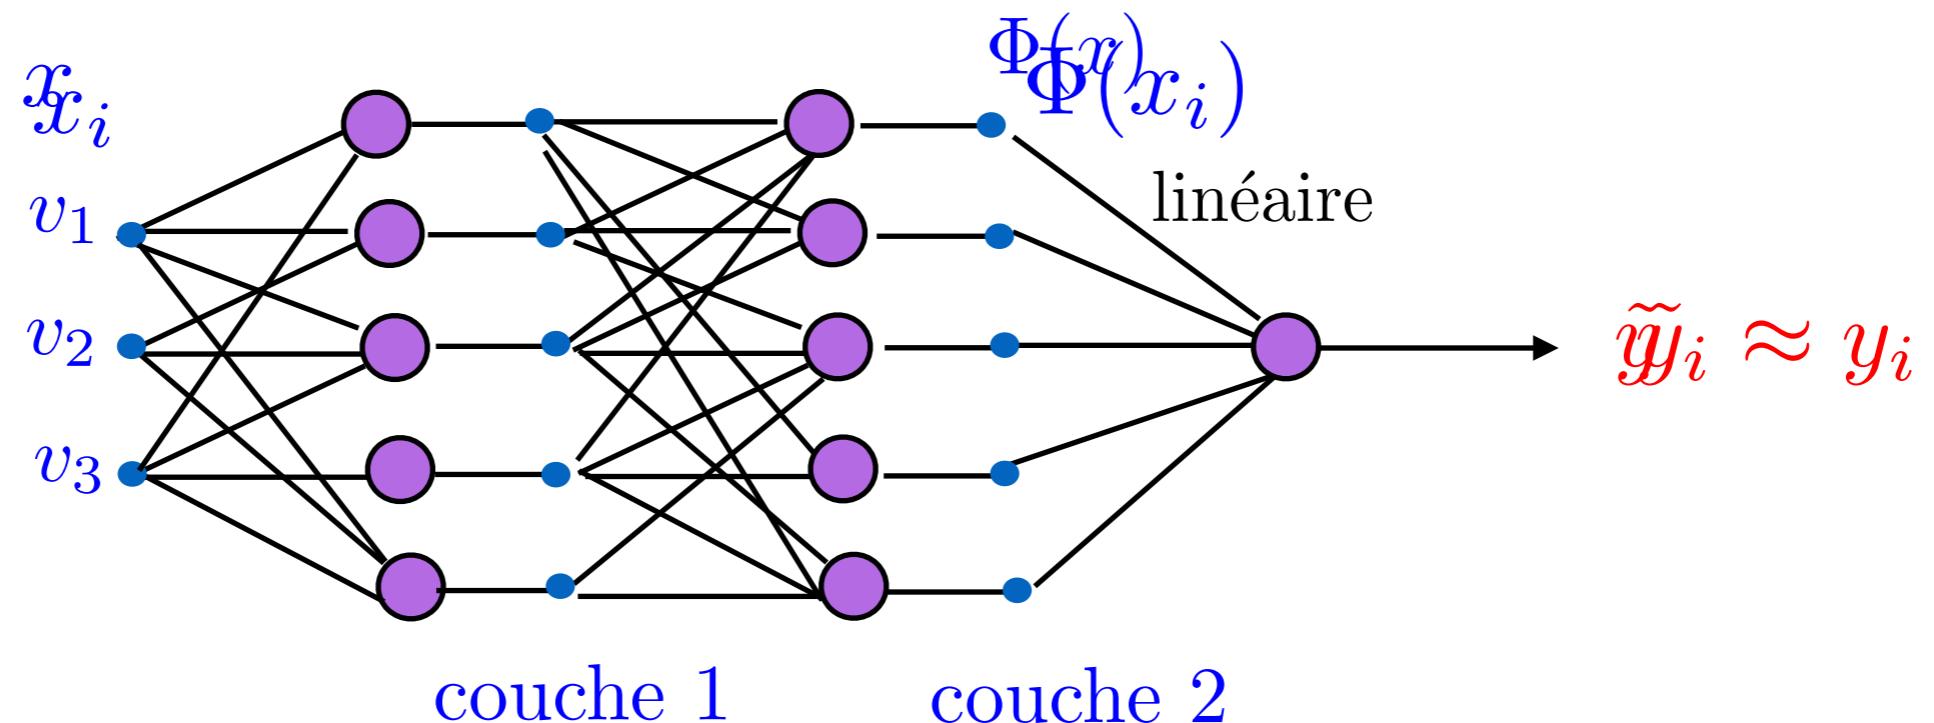
Un neurone est paramètré par les w_k et le seuil b

entrées





Réseaux de Neurones



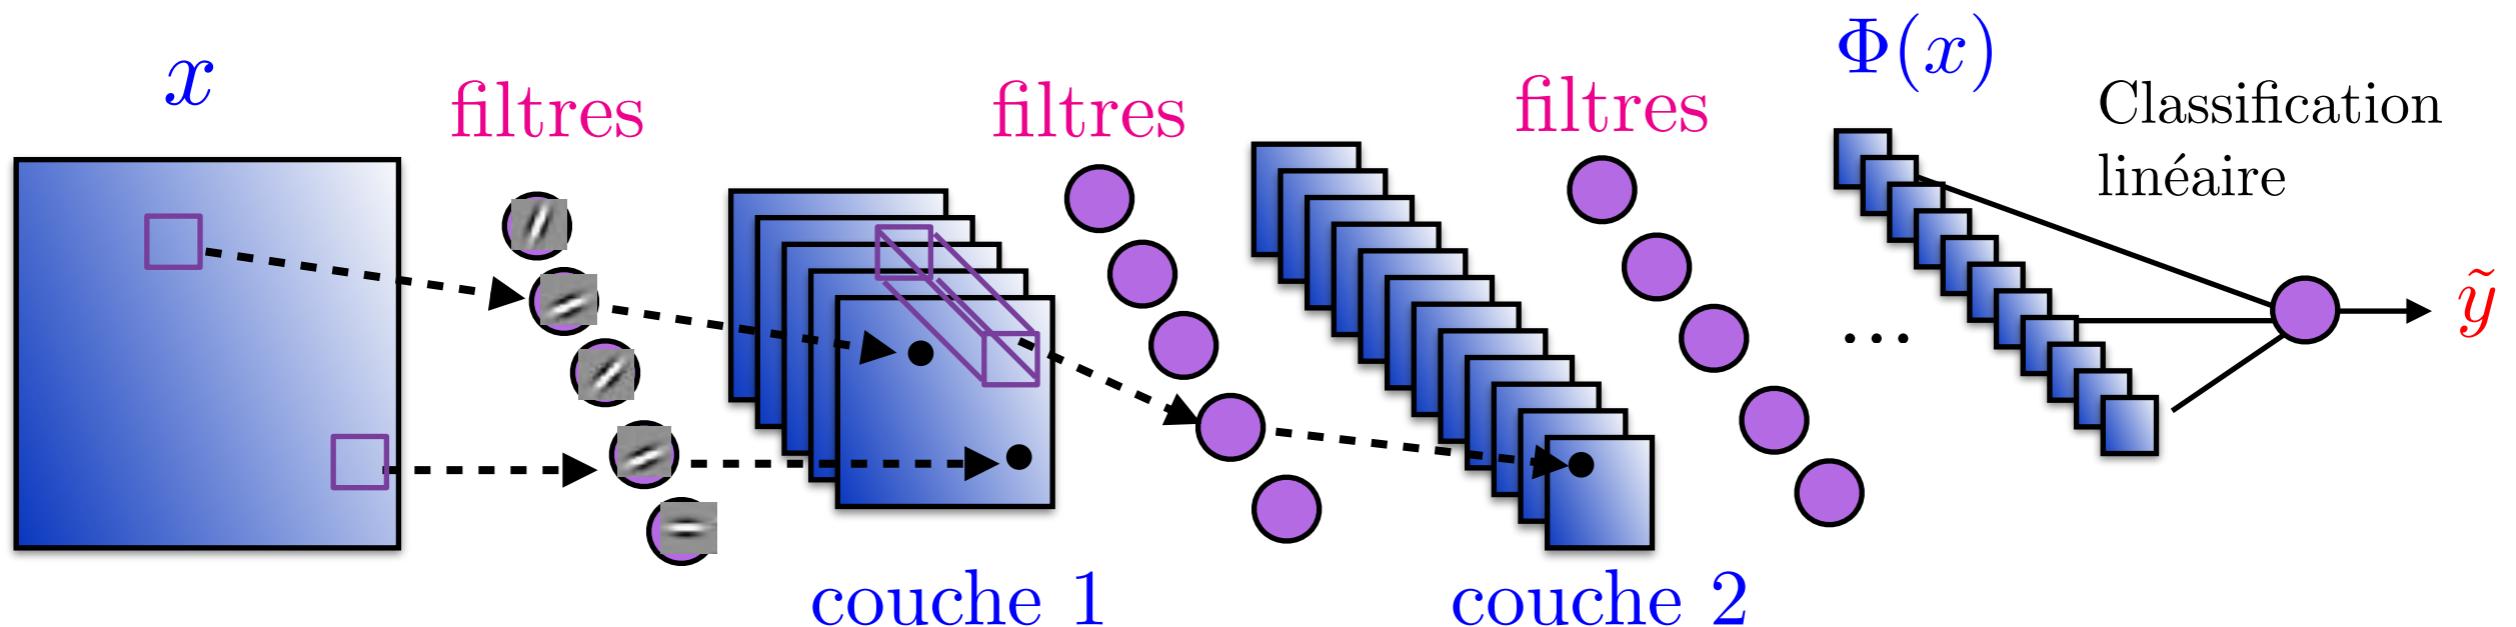
Apprentissage: optimise les **paramètres** pour minimiser les erreurs sur les exemples. Problèmes difficiles d'optimisation.

Information à priori: elle est dans l'architecture du réseau.



Réseaux Convolutionnels Profonds

- Les paramètres sont invariants par translations: **filtres**
Y. LeCun



Centaines de millions de paramètres

Prédictions exceptionnelles et *génériques*: pour l'image, parole, diagnostiques, traduction, en physique...

Le $\Phi(x)$ a aplati les frontières. Comment ?

Importance de l'architecture: symétrie, multiéchelle



ImageNet Data Basis

- Data basis with 1 million images and 2000 classes

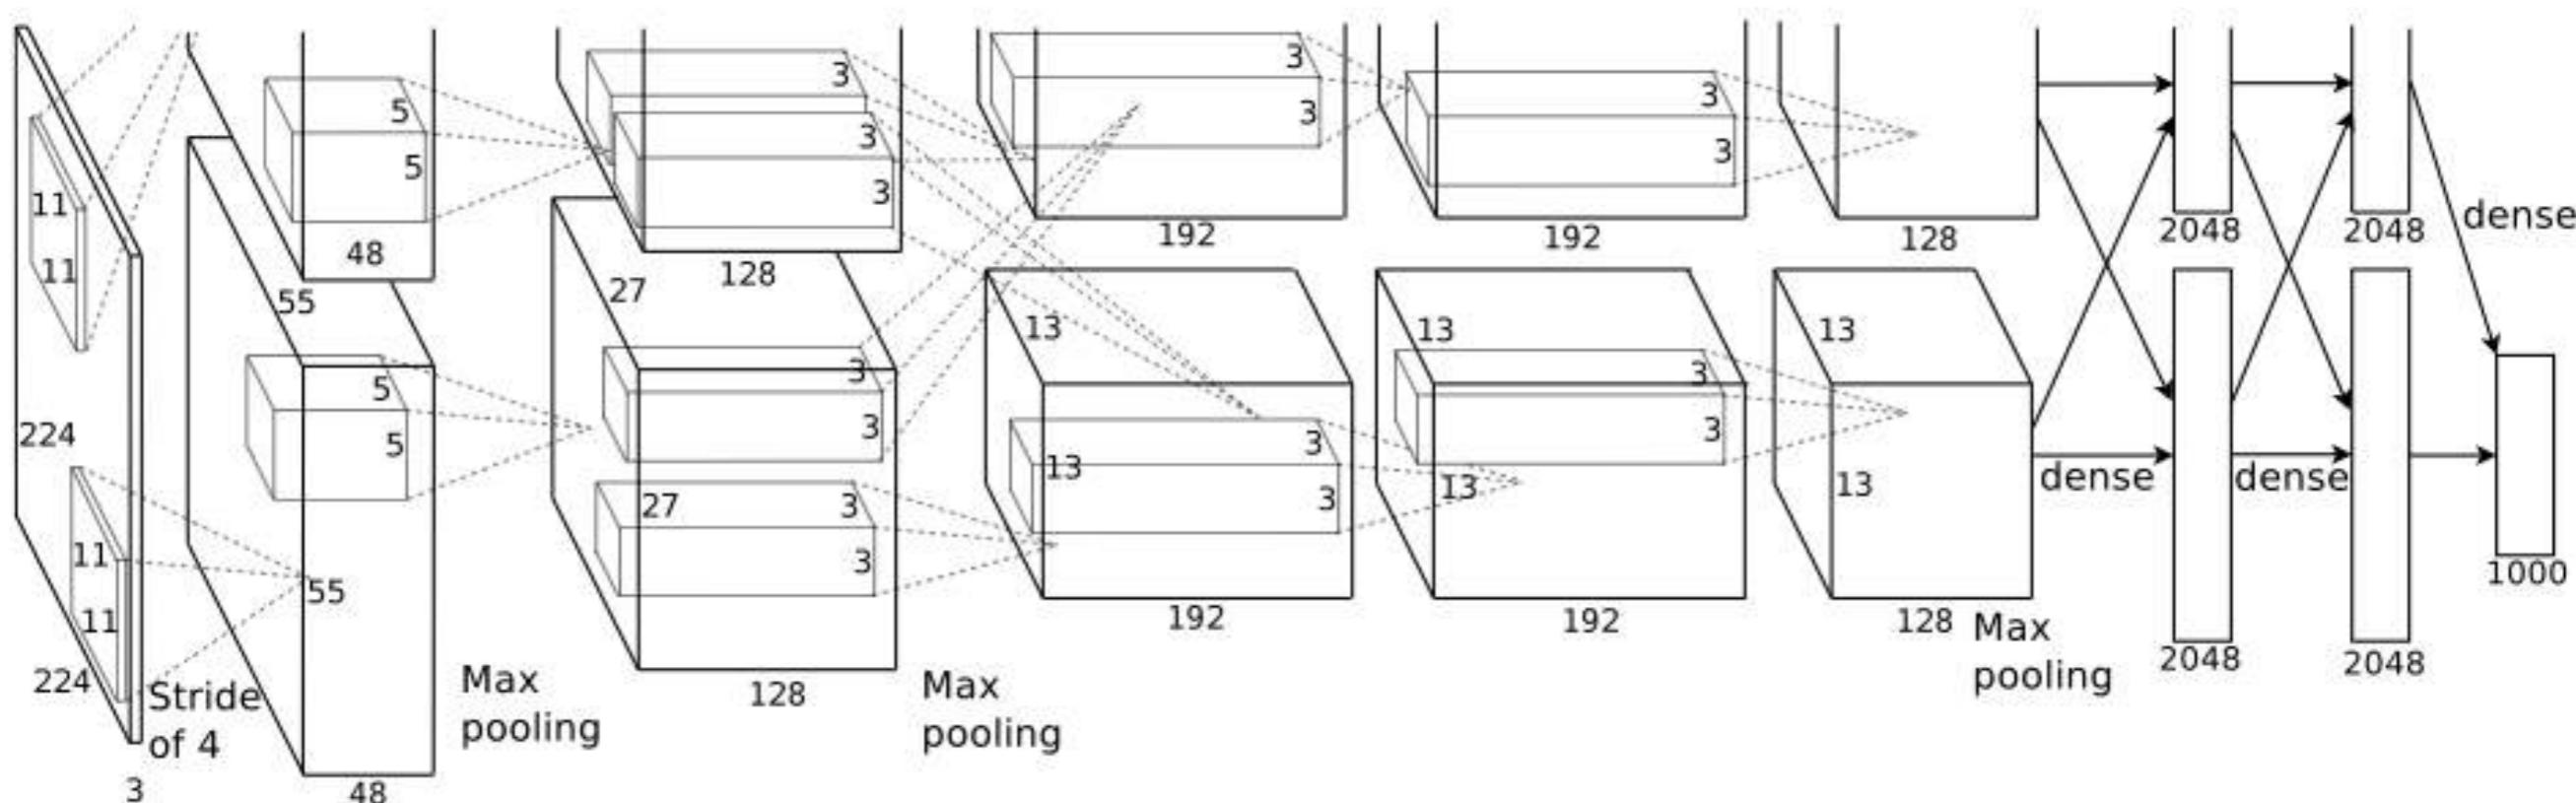




Alex Deep Convolution Network

A. Krizhevsky, Sutskever, Hinton

- Imagenet supervised training: $1.2 \cdot 10^6$ examples, 10^3 classes
15.3% testing error in 2012



New networks with 3% errors.
Up to 150 layers!

Pourquoi cela marche ?



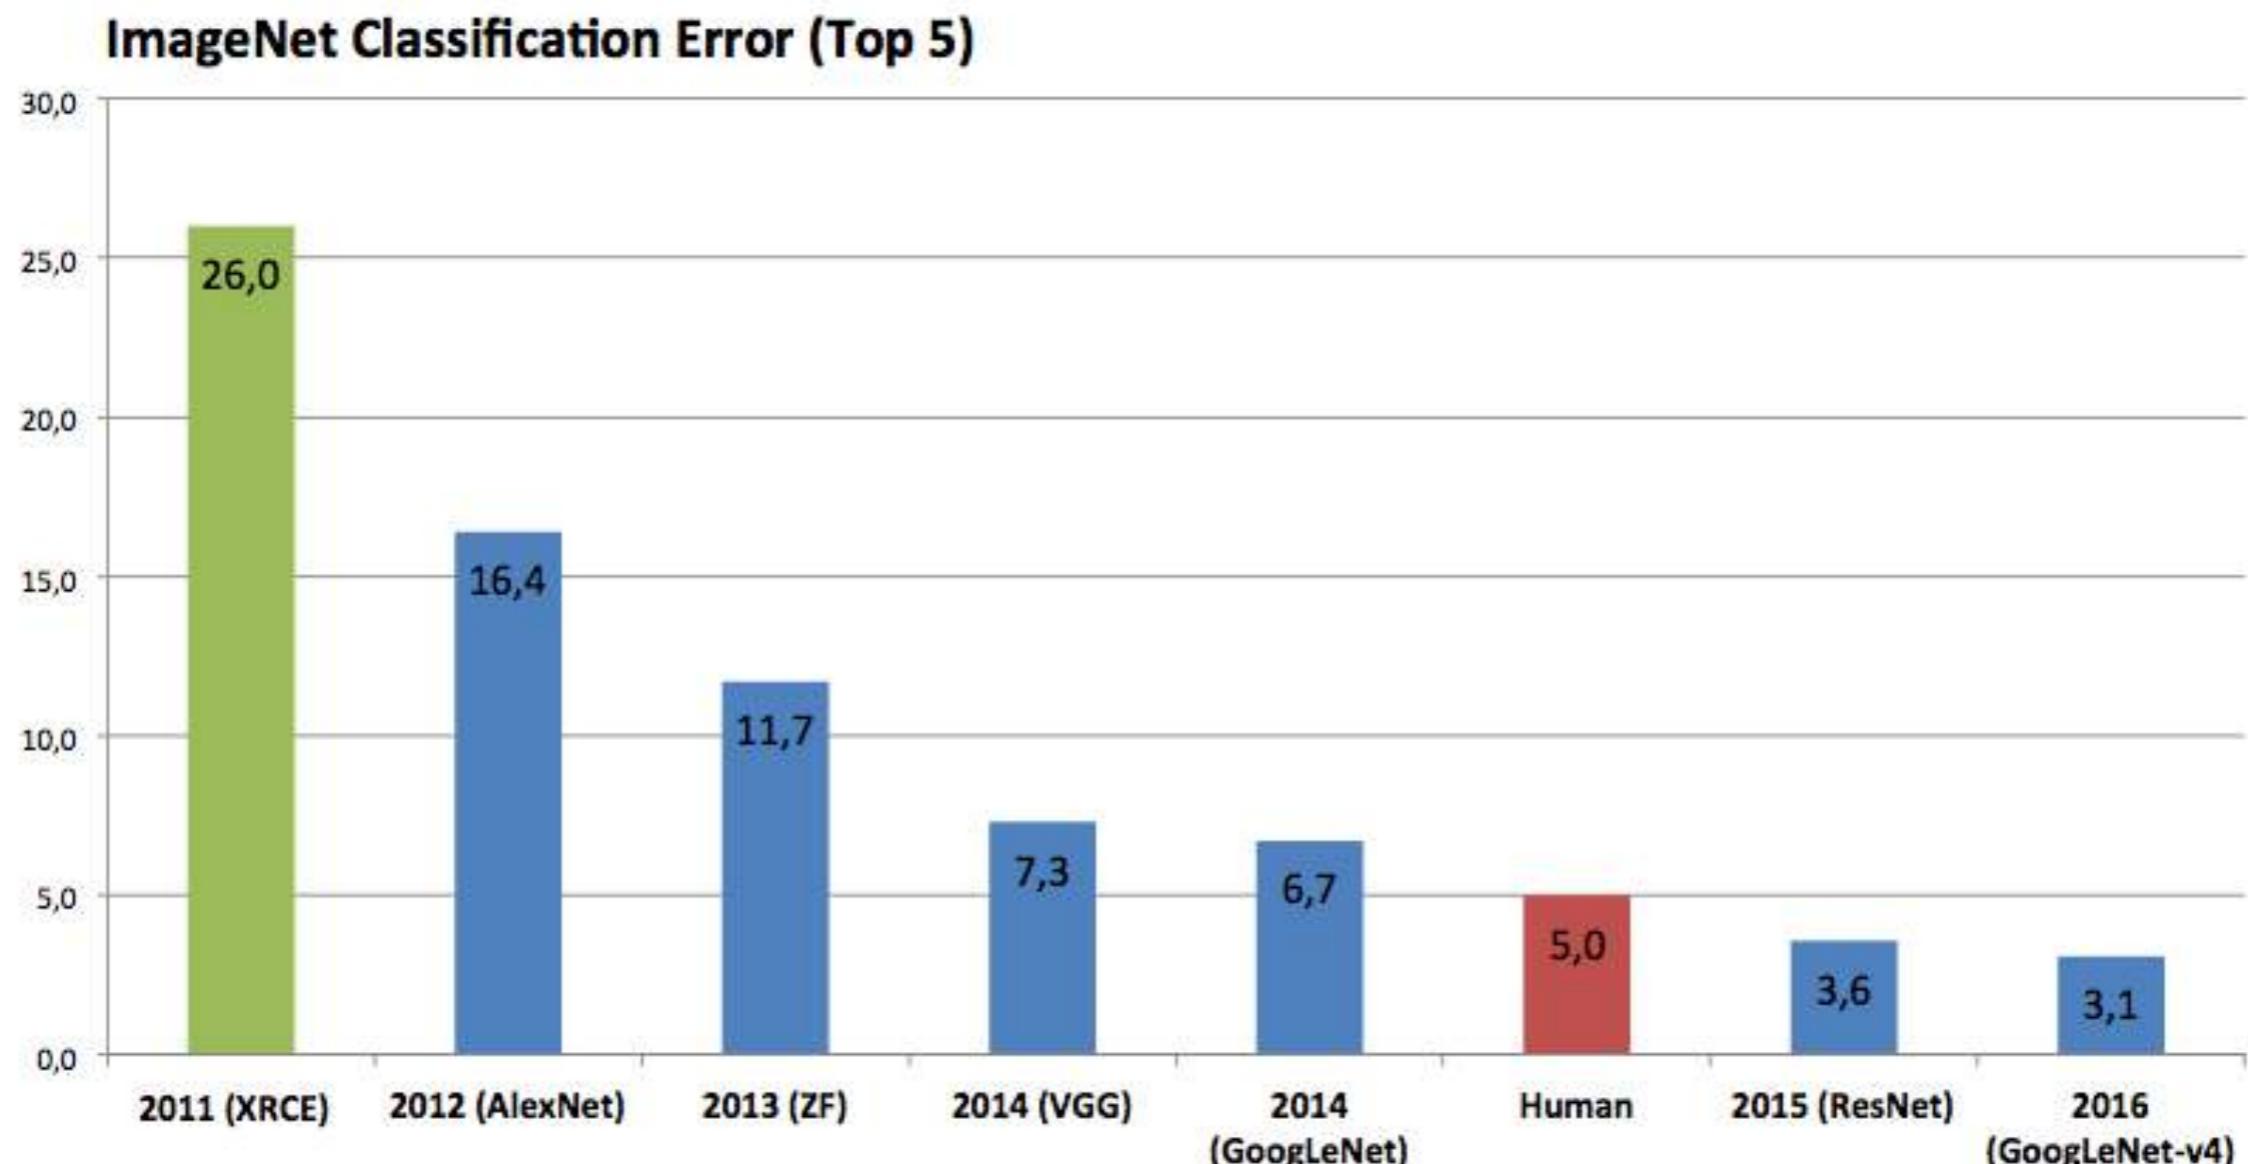
Image Classification

mite	container ship	motor scooter	leopard
mite	container ship	motor scooter	leopard
black widow	lifeboat	go-kart	jaguar
cockroach	amphibian	moped	cheetah
tick	fireboat	bumper car	snow leopard
starfish	drilling platform	golfcart	Egyptian cat
grille	mushroom	cherry	Madagascar cat
convertible	agaric	dalmatian	squirrel monkey
grille	mushroom	grape	spider monkey
pickup	jelly fungus	elderberry	titi
beach wagon	gill fungus	ffordshire bullterrier	indri
fire engine	dead-man's-fingers	currant	howler monkey

Quels types de "connaissance" ont été apprises ?



Erreurs sur ImageNet

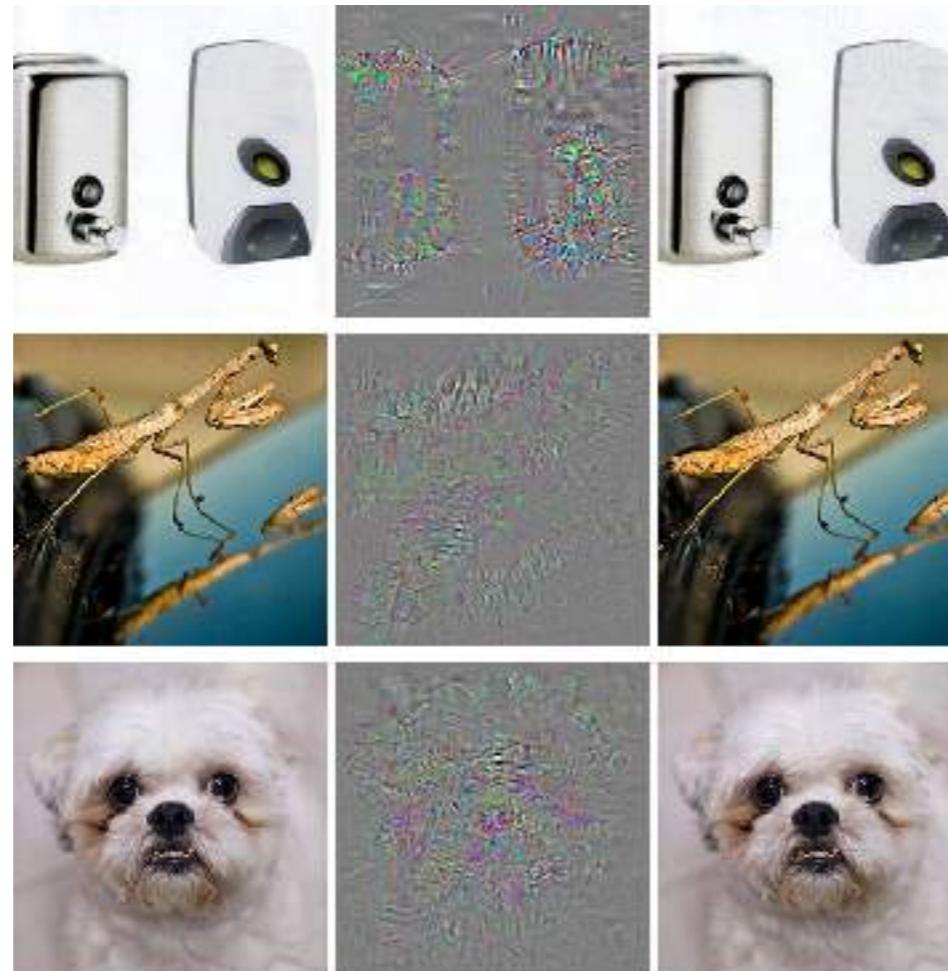




Why Understanding ?

Szegedy, Zaremba, Sutskever, Bruna, Erhan, Goodfellow, Fergus

$$x + \epsilon = \tilde{x} \quad \text{with } \|\epsilon\| < 10^{-2} \|x\|$$



correctly
classified

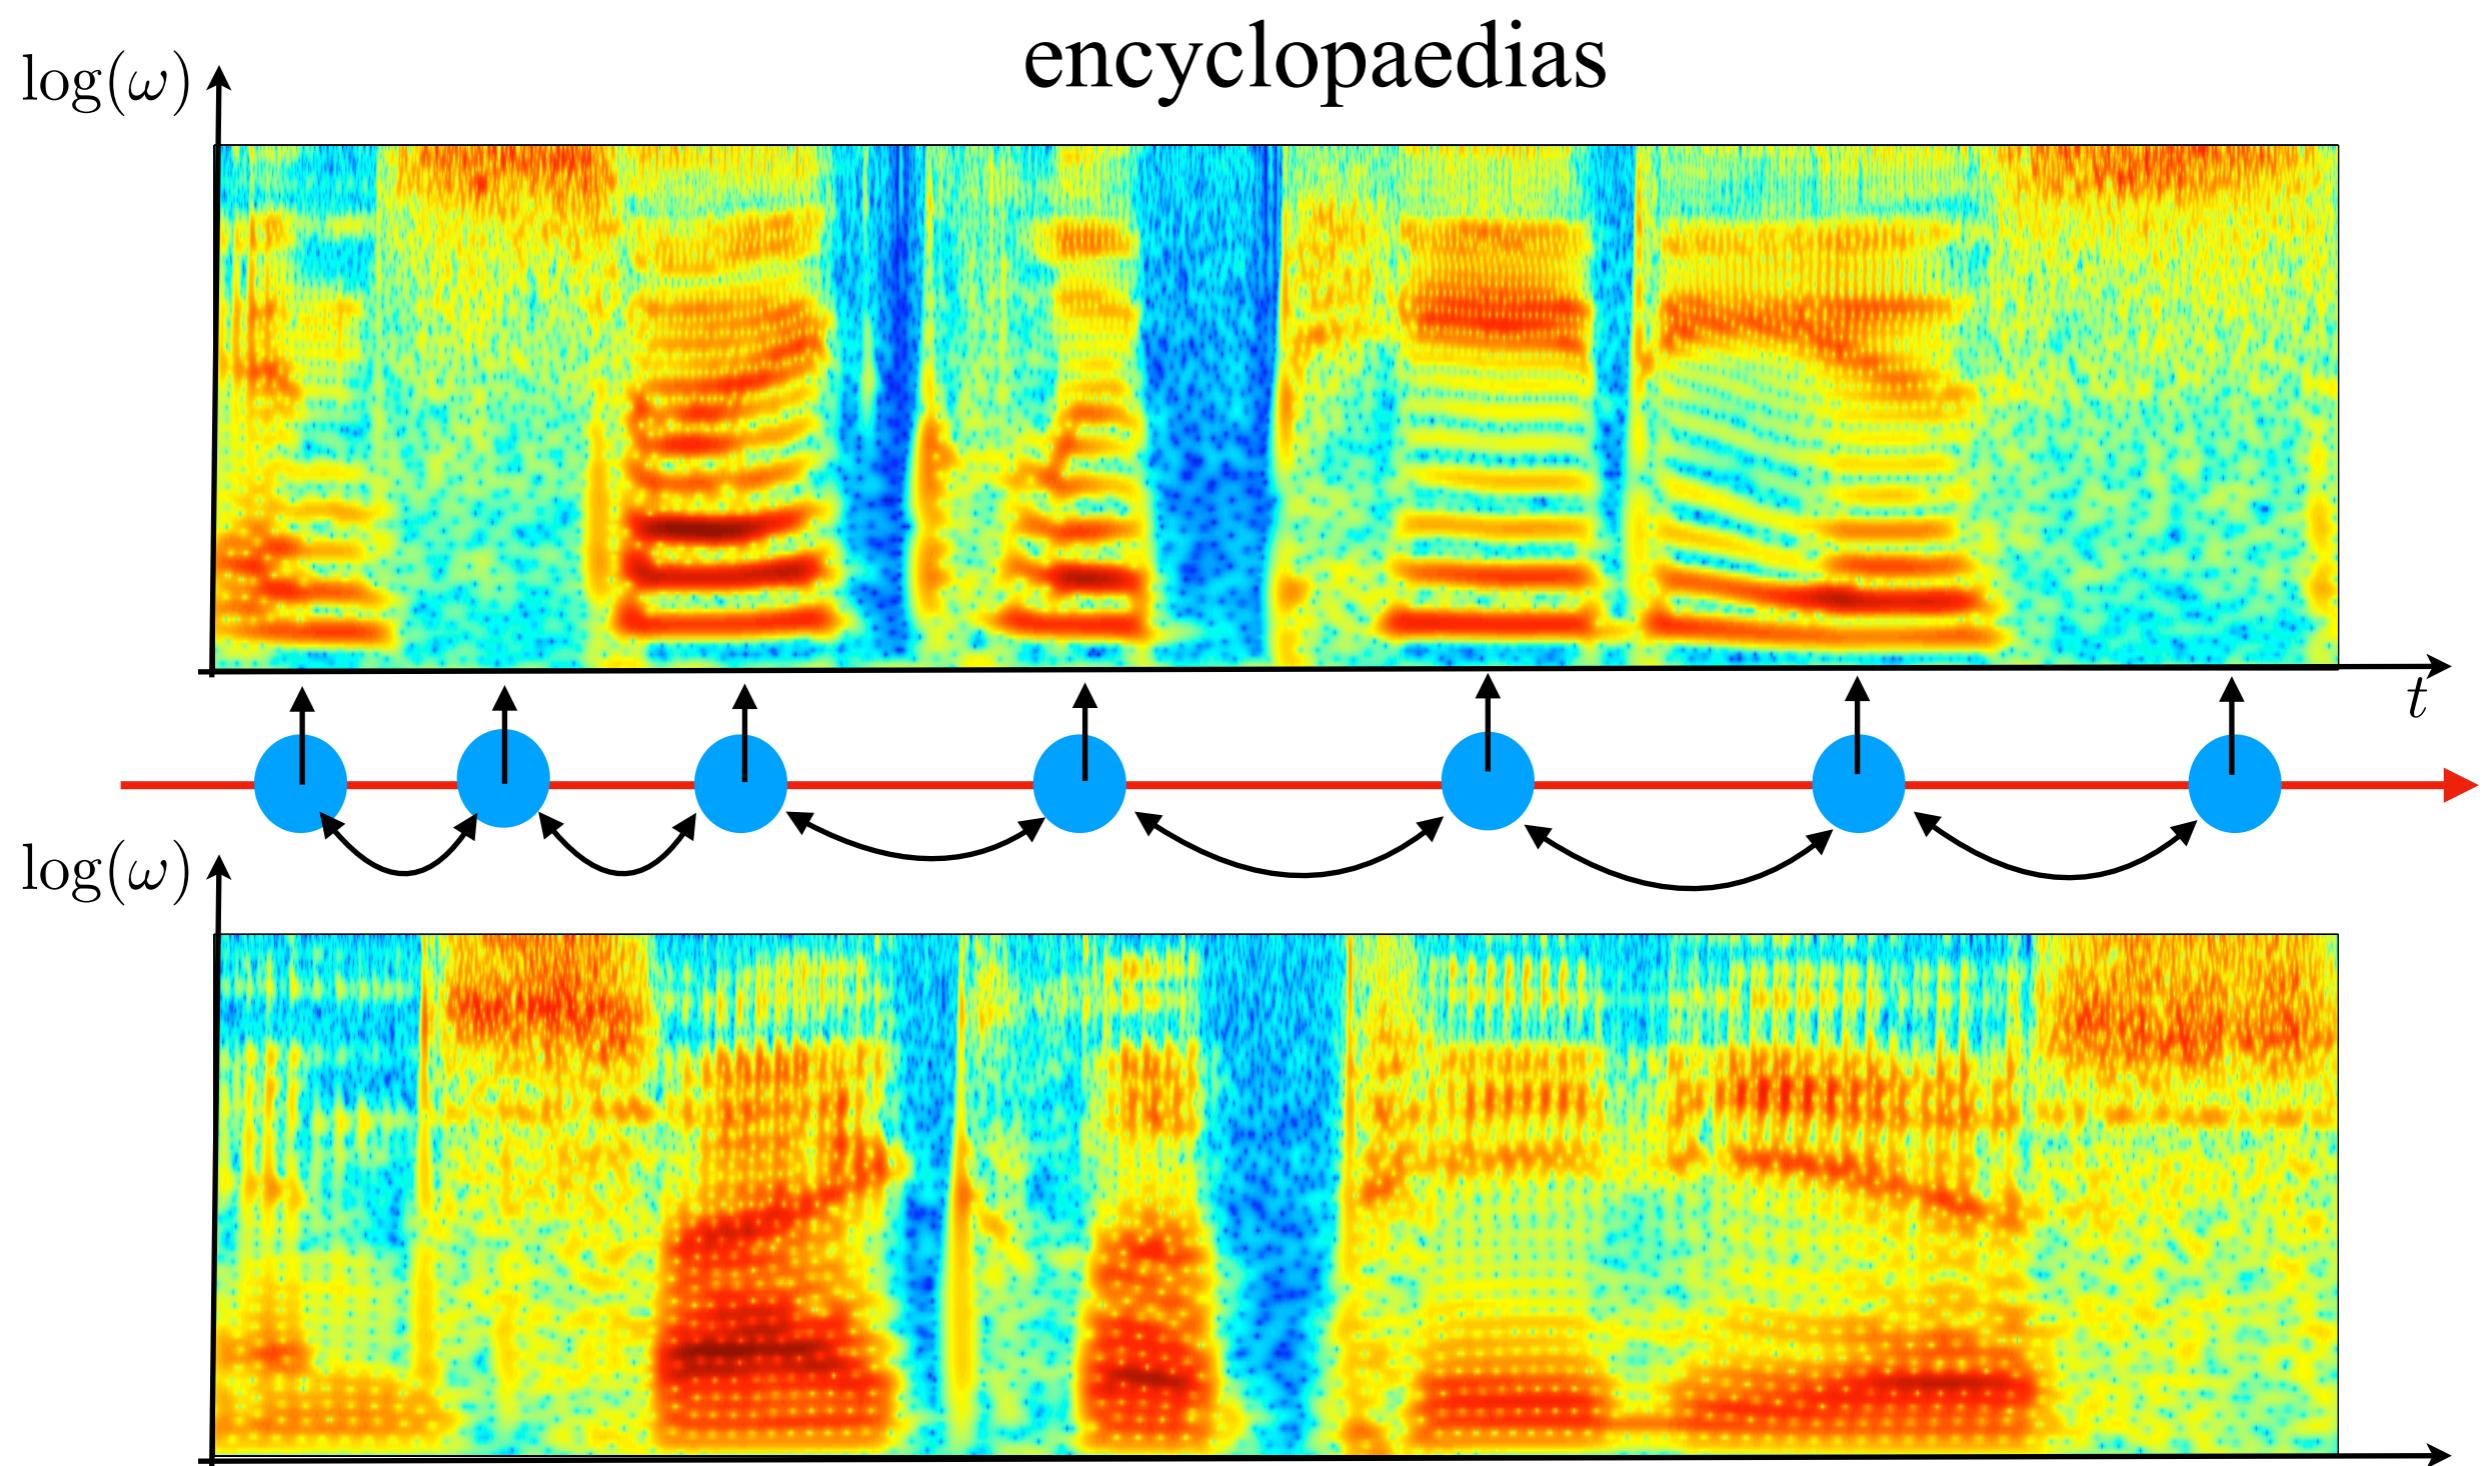
classified as
ostrich

- Trial and error testing can not guarantee reliability.



Reconnaissance de la parole

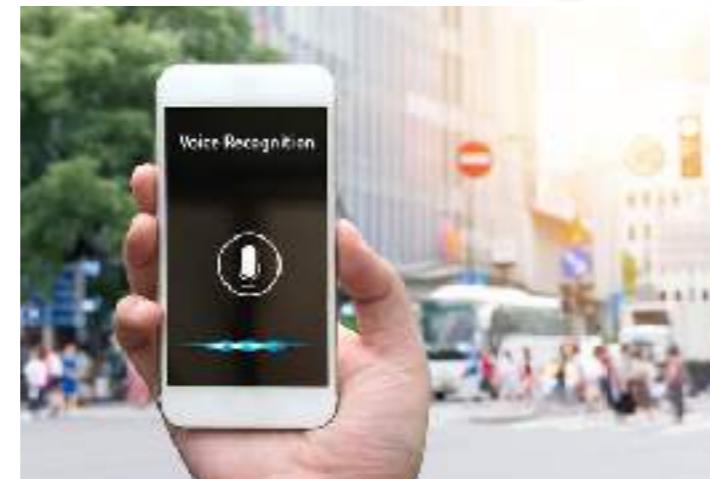
- Depuis les années 60.
- Jusqu'en 2010, basé sur le calcul de spectrogrammes et modèles de chaînes de Markov.



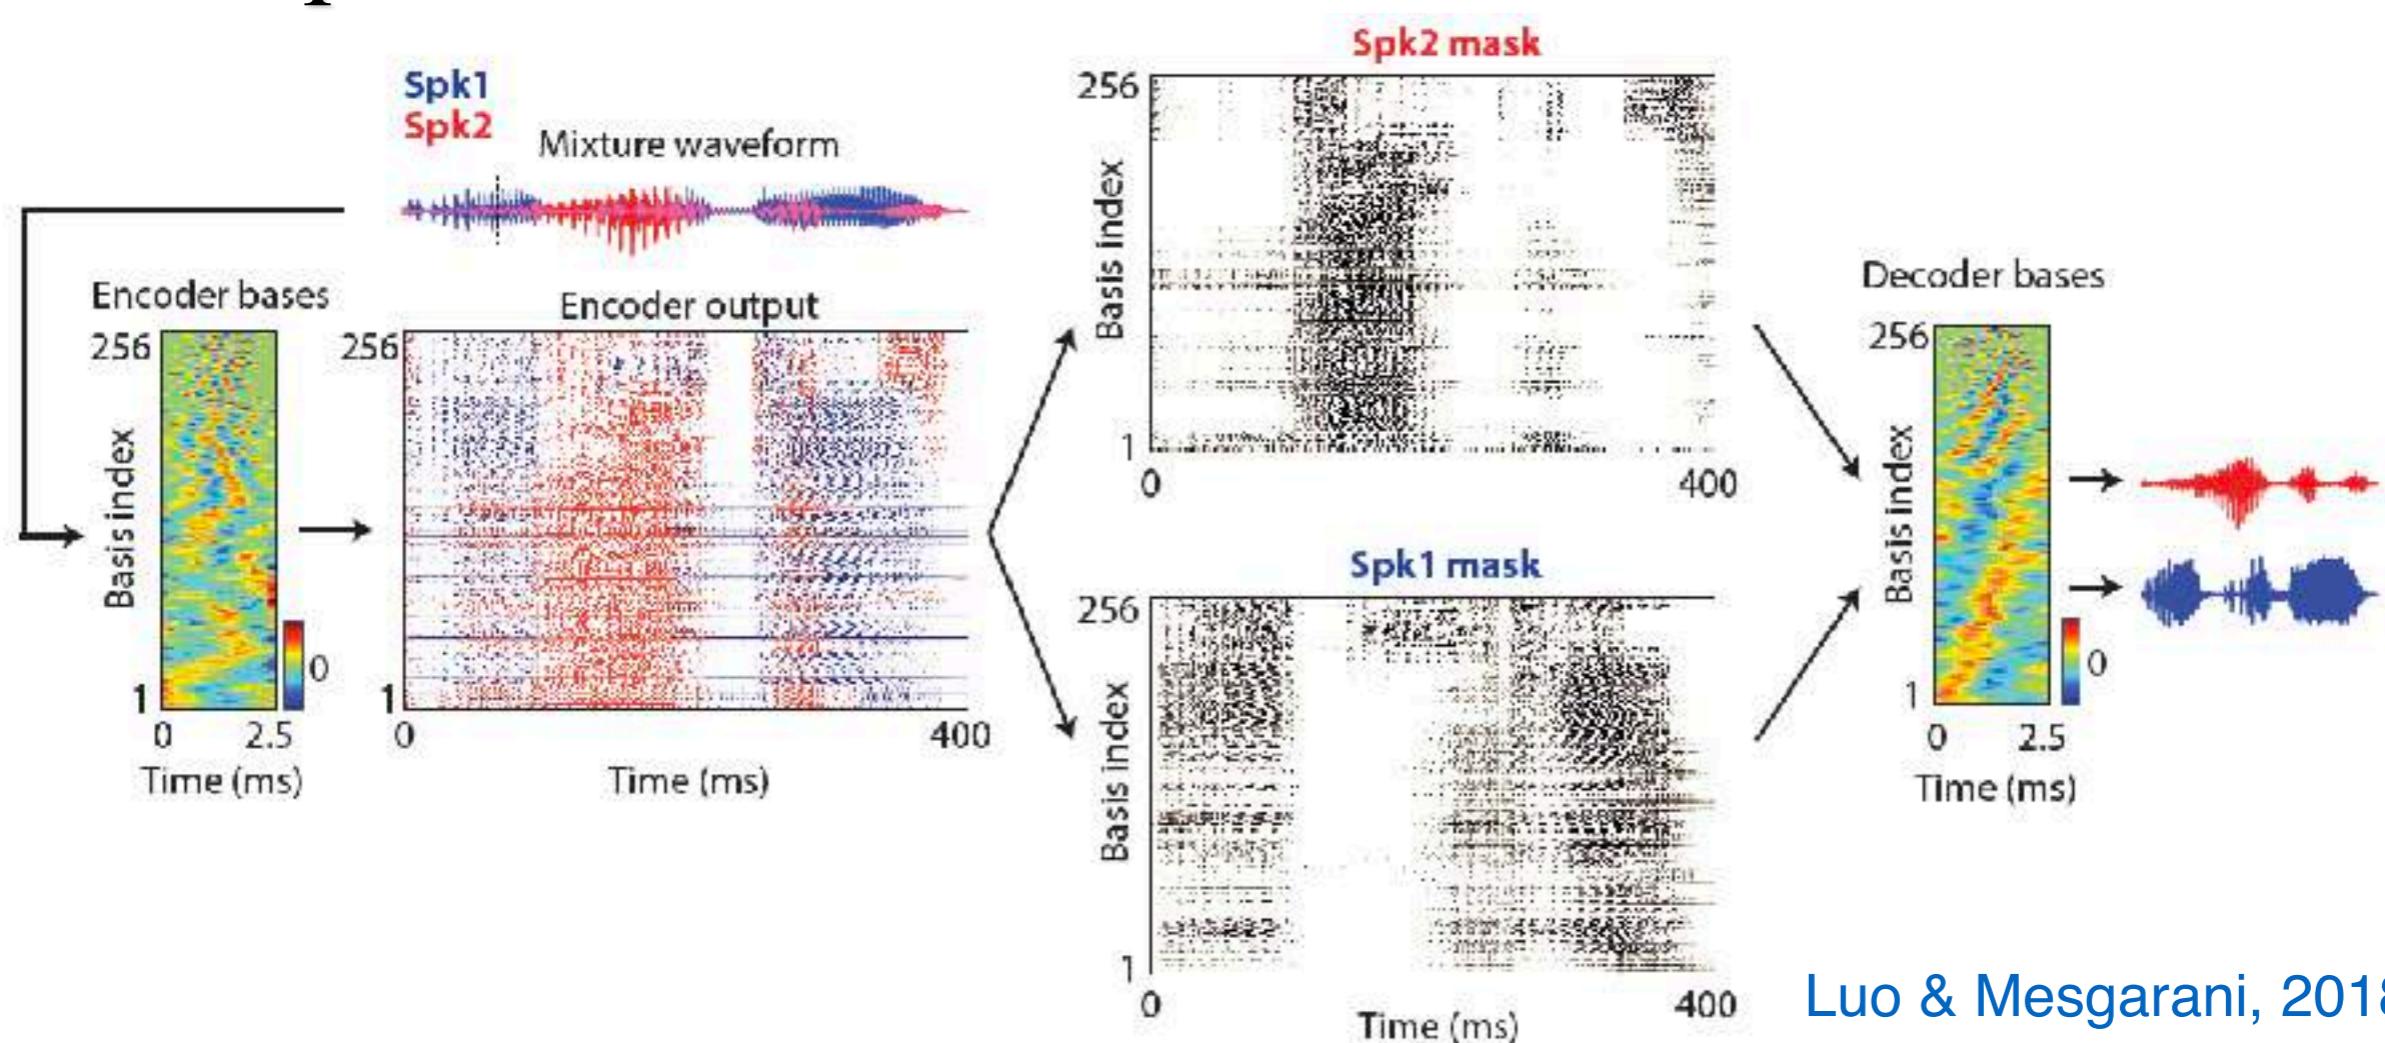


Reconnaissance Audio

- Reconnaissance de la parole, de la musique:



- Séparation de sources:





Physique: Interactions de n corps

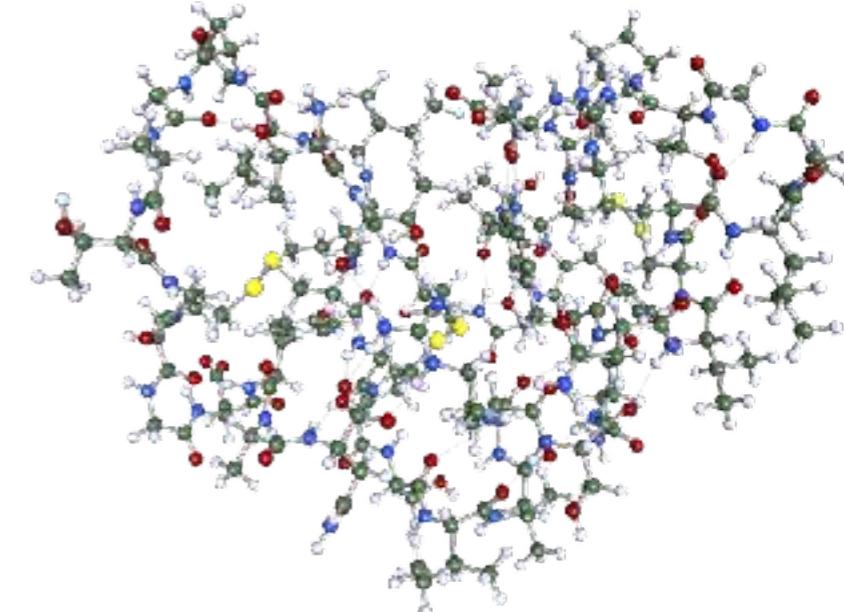
Astrophysique



Dynamique des fluides



Chimie Quantique



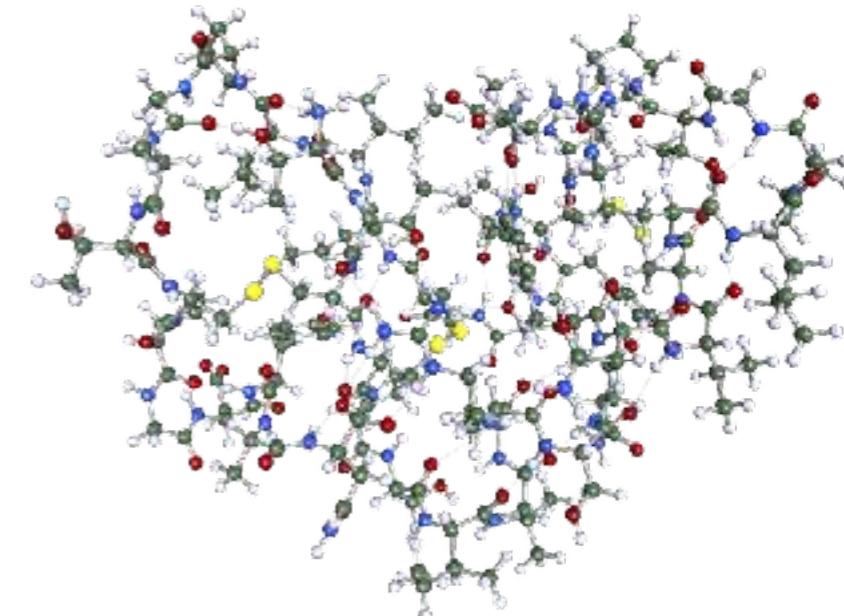
- Lois de la physique connues: équations de Newton, Boltzmann, Maxwell, Navier-Stokes, Schrodinger... mais calcul difficile des solutions résultant d'interactions d'un grand nombre de « corps élémentaires ».
- Simulations numériques: à partir des équations fondamentales.
- Peut-on prédire une solution par régression à partir d'une base de données de solutions et quelques informations à priori ?

De mieux en mieux avec des réseaux de neurones profonds...

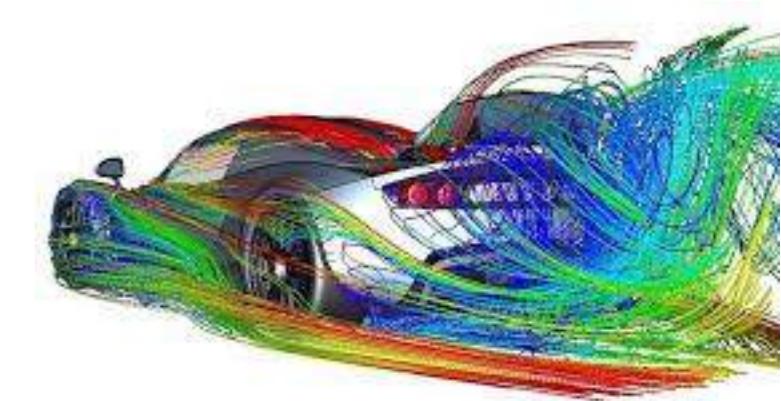
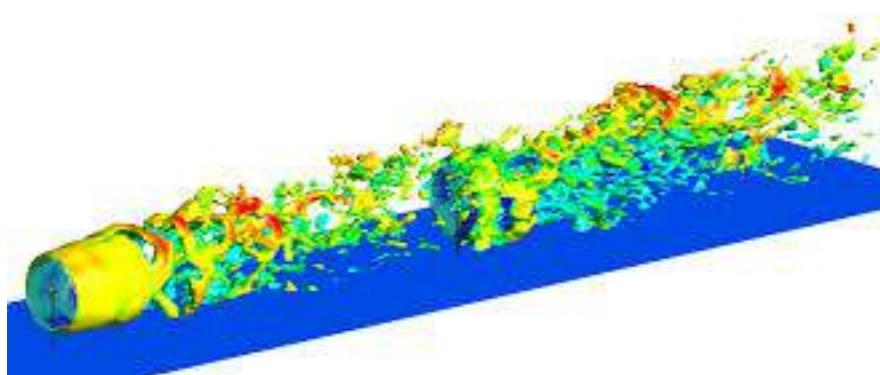


Applications Industrielles

Nouveaux matériaux, molécules pharmaceutiques:



Simulations numériques rapide ?



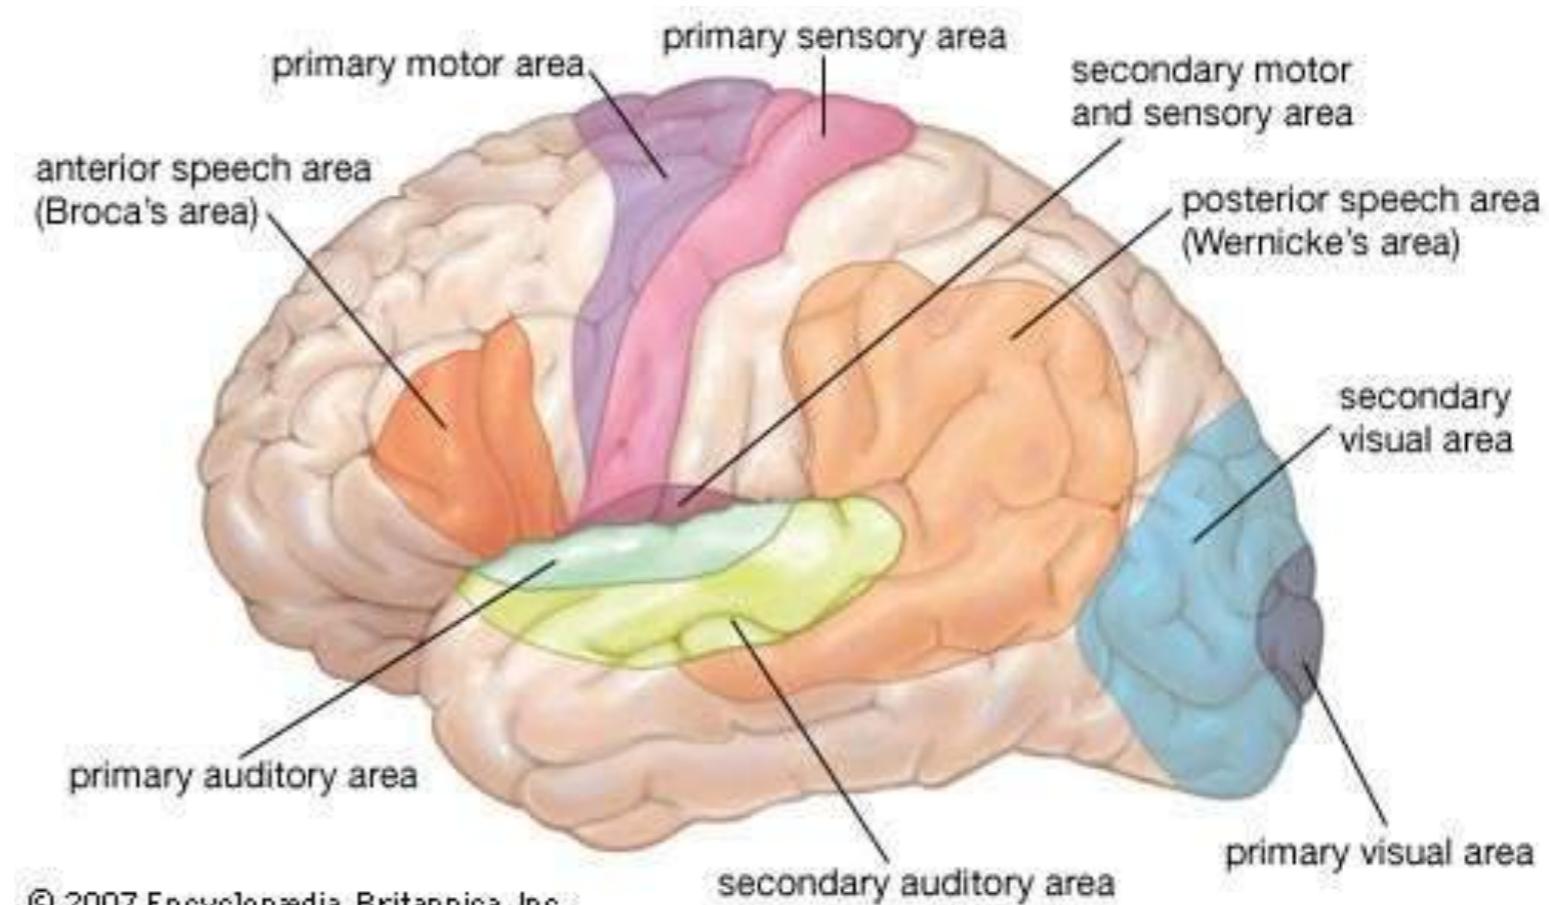


Liens avec la Neurophysiologie

Neurone



Cortex

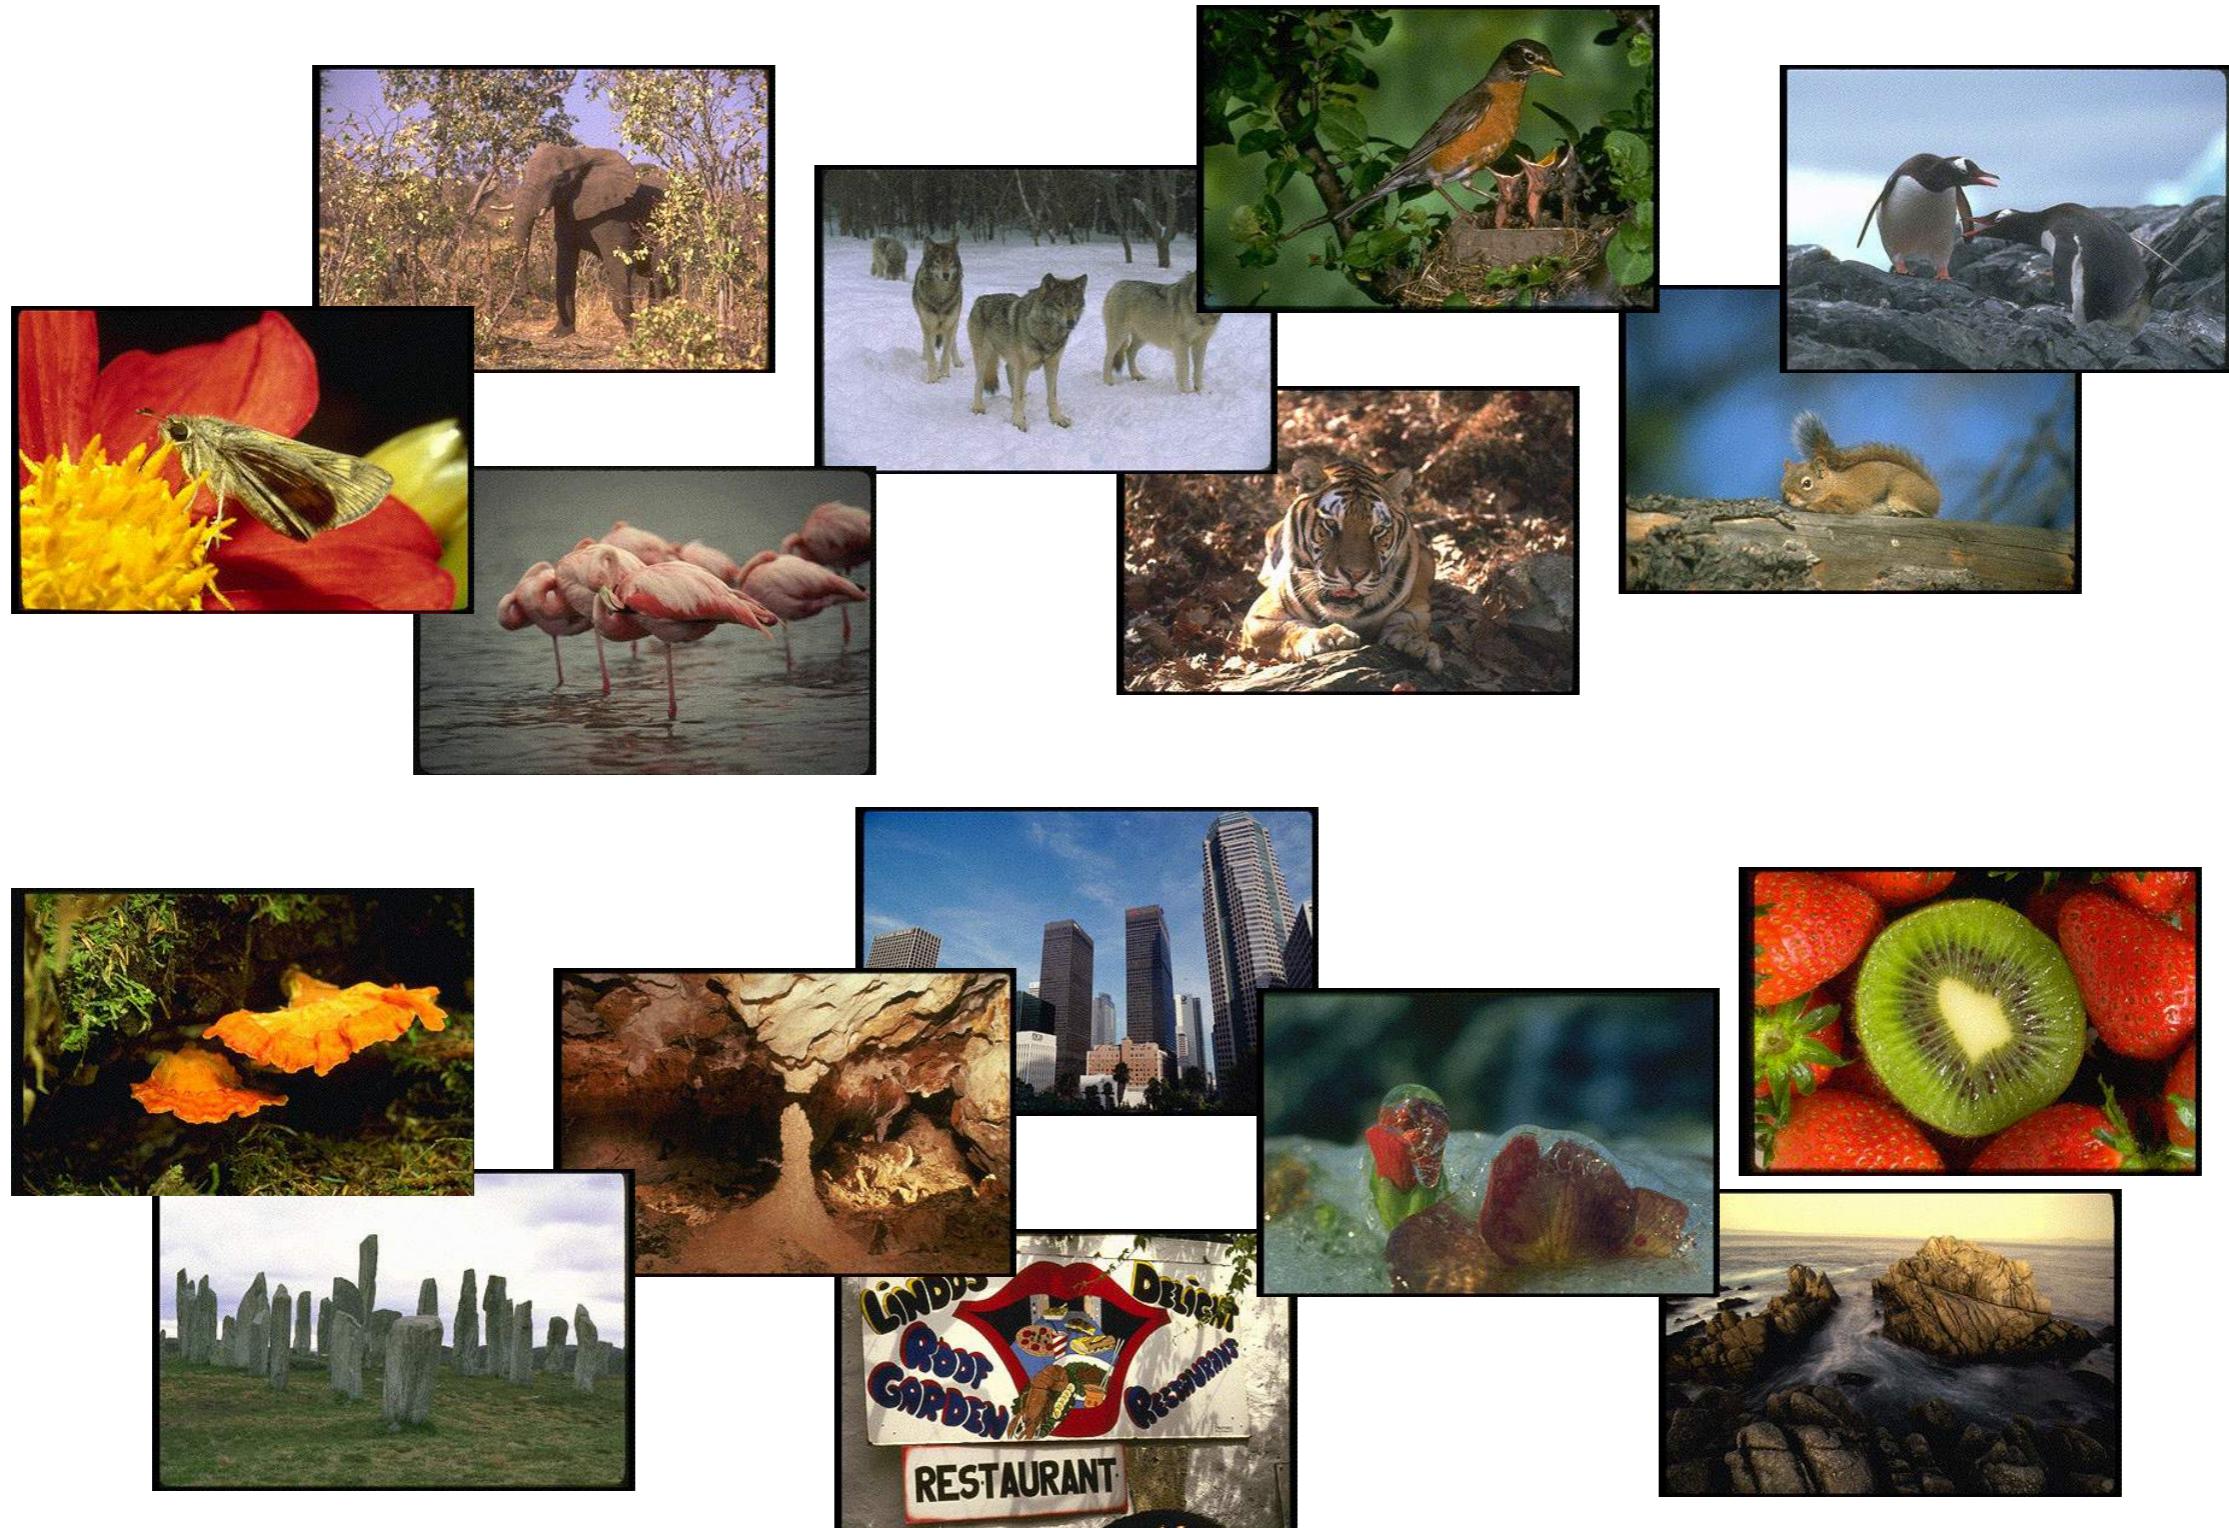


- Quelle similarité entre réseaux de neurones artificiels et biologie ? traitements, niveaux fonctionnels, modèles...



Perception Visuelle

- Reconnaissance d'animaux: 150ms



Questions

- Pourquoi ces architectures sont elles « génériques » ? Appliquées à des image, sons, physique, médecine, langage naturel...
- 3 types de problèmes:
 - Estimation: analyser l'erreur de généralisation
 - Optimisation: minimiser l'erreur empirique
 - Approximation: lien avec l'architecture
- Quelle est l'information a priori ?
- Pourquoi des convolutions ?
- Quels types de filtres ?
- Role des non-linéarités ?
- Liens avec la neurophysiologie de la perception: image et audio ?



Contenu du Cours

- Estimation, optimisation et **approximation** d'un réseau
- Régularité: séparation, symétries, parcimonie.
- Symétrie: convolution et analyse de Fourier
- Séparation et parcimonie: principe d'incertitude et représentations temps-fréquence
- Neurophysiologie de l'audition et de la vision
- Transformées multiéchelles et ondelettes
- Invariance par translations, rotations et déformations
- Classification d'images et de sons: SIFT et MFCC
- Invariants multiéchelles: réseaux d'ondelettes et scattering
- Régression en chimie quantique
- Ce qui manque: apprentissage de symétries ou de formes ?



Séminaires et Challenges

- 22 Janvier: Présentation de 8 challenges de données
- 29 Janvier: Présentation de 8 challenges de données
- 5 Février: Présentation des gagnants des challenges 2019
- 12 Février: *Geoffroy Peeters*, Applications à l'audio et musique
- 19 Février: Pas de cours et de séminaire.
- 26 Février : *Simon Thorpe*, Perception visuelle et CNN
- 4 Mars: *Gilles Wainrib*, Diagnostique médical interprétable
- 11 Mars : *Shihab Shamma*, Modèles physiologique de l'audition
- 18 Mars: *Edouard Oyallon*, Au-delà de l'information a priori