

Quel avenir pour le big data?

IA et science des données

Bernadette Dorizzi

Un titre déjà démodé...

- Une panoplie de termes utilisés et pas toujours bien définis : Big Data, Intelligence Artificielle (IA), machine learning, robotique, sciences des données...
- Des réalités et des fantasmes, « les robots vont remplacer l'homme, la conscience des machines... »
- Que se passe t-il aujourd'hui?

- beaucoup de données

- de grandes capacités de calcul

- Des GAFA, c'est-à-dire une force de frappe

D'après McKinsey, en 2016 les BigTech (GAFA...) ont investi en IA plus de 30 milliards de dollars dont 90% en R&D et déploiement de solutions. En outre, 8 à 12 milliards d'investissement externes de capital risque (60% en machine learning, le reste en vision, robotique, langage naturel, voiture autonome...) sont venus soutenir des entreprises/startups tournées vers l'IA. Sans parler de l'annonce d'un investissement de 15 milliards de dollars par Alibaba. Toujours selon McKinsey, cité dans *Robotics and artificial intelligence*, l'impact potentiel de l'IA à l'horizon 2025 est estimé à plusieurs trillions de dollars par an.

- Des plateformes de développement faciles d'accès, gratuites, et des bases de données disponibles (quoi que?)

Ce qu'on en lit...

- Aube d'une **nouvelle révolution scientifique et industrielle**.
- bases d'un **nouveau paradigme de la démarche scientifique** et transforment en profondeur les notions et les méthodes mêmes de l'approche scientifique.
- **champs aussi divers que la biologie, les sciences cognitives, l'astrophysique, l'environnement ou la physique statistique.**
- Cette révolution a **de profondes implications micro-économiques, macro-économiques et sociétales.**
- La croissance exponentielle des données et l'IA soulèvent de **nombreuses questions éthiques**, sur des sujets tels que la valeur de la vie privée ou la prise de décisions dans des contextes mettant en péril des vies humaines.
- Cf. les rapports gouvernementaux de 2016 américain (*National artificial intelligence research and development strategic plan*), britannique (*Robotics and artificial intelligence*), français de 2017 (rapport France IA *Une stratégie pour la France en matière d'intelligence artificielle*), de 2018 (rapport Villani *Donner un sens à l'intelligence artificielle*).

Dans un souci de clarification

D'après <https://chaire-philo.fr/seance-introductive-du-seminaire-intelligence-artificielle-robotique-et-sante/>

- La caractéristique qu'apporte l'IA aux machines est celle d'apprendre des données que l'humain met à sa portée.
- Ce développement des capacités peut se faire par apprentissage statistique, par la création d'arbres de décision ou de réseaux de neurones (*deep learning*).
- De tels systèmes permettent de réaliser un nombre phénoménal de calculs en peu de temps et à partir de données échappant pour partie à l'humain, par exemple au-delà des spectres visible et audible.
- Pour autant, cela ne permet pas d'égaler « l'intelligence forte » des humains : avoir conscience de soi-même, éprouver de vrais sentiments et comprendre ce que l'on apprend.
- Ainsi, actuellement, l'IA a des capacités prodigieuses sur le plan quantitatif mais se montre faible par contraste sur le plan qualitatif.
- En effet, cette faculté au calcul reste partielle car elle mobilise des données passées et ne sait pas se projeter dans l'imaginaire d'où parfois se font les découvertes de phénomènes qui étaient jusqu'alors impensables, comme ce fut le cas pour Galilée.
- De plus, les machines font défaut de sérendipité, c'est-à-dire de la faculté de découvrir par hasard : elles peuvent produire de manière aléatoire mais parmi tous les produits ne sauront identifier celui d'une valeur singulière.

Et la recherche?

- Des résultats applicatifs impressionnants mais des questions encore ouvertes
- Des thématiques multi-disciplinaires (Science, Business & Society) : Mathématique, (Statistique, Optimisation) , Informatique

05/12/2019 - Enjeux scientifiques et sociaux de l'intelligence artificielle



La Mission pour les initiatives transverses et interdisciplinaires du CNRS lance le défi Enjeux scientifiques et sociaux de l'intelligence artificielle. L'objectif est de soutenir des recherches interdisciplinaires visant à étudier les retombées et conséquences de l'usage d'outils de l'intelligence artificielle pour la recherche et à explorer les façons dont elle change la société. Date limite de candidature : **27 janvier 2020**.

- Des initiatives nationales : instituts 3IA, chaires en IA, institut de convergence Datala,
- Des initiatives européennes, canadiennes (Bengio), chinoises

Figure 3.1. AI patent families and scientific publications by earliest publication year

AI patent families grew by an average of 28 percent and scientific publications by 5.6 percent annually between 2012 and 2017





Figure 4.1. Top 30 patent applicants by number of patent families

Companies represent 26 of the top 30 AI patent applicants worldwide



Note: Fujitsu includes PFU; Panasonic includes Sanyo; Alphabet includes Google, Deepmind Technologies, Waymo and X Development; Toyota includes Denso; and Nokia includes Alcatel

Principes de l'apprentissage machine

- Réseaux de Neurones : ce n'est pas nouveau, les fondamentaux datent des années 1940, Mac Culloch and Pitts (biologistes) puis 1990
- Réseaux de neurones, inspirés du cerveau humain, apprentissage en modifiant le poids des connexions, dirigé par la minimisation des erreurs cf apprentissage humain lecture-écriture, correction entre un objectif et sa réalisation.
- Modèles statistiques, apprentissage à partir d'exemples, plus on a d'exemples mieux c'est mais les résultats seront dépendant des corpus choisis

History

2.2. NEURAL NETWORKS: KEY PERIODS, MODELS AND ALGORITHMS

15





Figure 2.2.1 – The key moments of the history of Artificial Neural Networks (ANNs) and deep learning. (a) Invention of the artificial neuron [MP43]. (b) Invention of Perceptron [Ros58]. (c) Invention of back-propagation [Wer74]. (d) Invention of Convolutional Neural Networks (CNNs) [LeC+89]. (e) Invention of Long Short-Term Memory networks (LSTMs) [HS97]. (f) Invention of Deep Belief Networks (DBNs) [HOT06]. (g) *AlexNet* CNN wins *ImageNet* [KSH12].





The Retina. Complex connections.

- Many different types of neurons – neurons have complex dendritic structure – and complex connections between neurons.



The Retina: Seung. Different types of neurons.

- Neurons: Dendrites, Axons, and Soma (cell body).




Réseaux de neurones biologiques


- Le cerveau humain compte environ 10^{11} neurones et 10^4 synapses.
- Une synapse relie un axone à un dendrite.
- Lorsqu'elle reçoit un signal, une synapse peut augmenter (exciter) ou diminuer (inhiber) le potentiel électrique. Un neurone réagit lorsque son potentiel électrique atteint un seuil.
- Il y a une sommation des signaux entrants puis un seuillage
- Un apprentissage peut se faire par des changements au niveau des synapses.

Réseaux de Neurones Artificiels

- Inspirés des neurones humains et de leur organisation




Modèle de neurone





Sommation pondérée des entrées et saturation

Automate neuronal



Fonction de transfert : saturation


Synapses et poids



Adaptation neuronale = modification des synapses
Apprentissage = modification des poids qui relient les
noeuds entre eux

Réseaux à couches : apprentissage


- L'apprentissage nécessite de grandes bases de données étiquetées
- On va minimiser une fonction de coût, (erreur en sortie) par rapport aux poids du réseau
- L'algorithme de rétropropagation du gradient permet de modifier les poids de manière à ce que le réseau réalise au mieux l'association souhaitée



→ Ceci est un 2


Tâche de classification

Réseaux à convolution (CNN)



Visual Object Recognition with Convolutional Nets (from Y. LeCun)

- In the mid 2000s, ConvNets were getting decent results on object classification
- Dataset: “Caltech101”:
 - ▶ 101 categories
 - ▶ 30 training samples per category
- But the results were slightly worse than more “traditional” computer vision methods, because:
 - ▶ 1. the datasets were too small
 - ▶ 2. the computers were too slow





cellphone



joshua



cougar body



Then., two things happened...

■ The ImageNet dataset [Fei-Fei et al. 2012]

- ▶ 1.2 million training samples
- ▶ 1000 categories

■ Fast & Programmable General-Purpose GPUs

- NVIDIA CUDA
- ▶ Capable of over 1 trillion operations/second



Matchstick



Sea lion



Flute



Strawberry



Bathing



Backpack




Racket



Very Deep ConvNet for Object Recognition

1 to 10 billion connections, 10 million to 1 billion parameters, 8 to 20 layers.

Samoyed (16); Papillon (5.7); Pomeranian (2.7); Arctic Fox (1.0); Eskimo Dog (0.6); White Wolf (0.4); Siberian Husky (0.4)




Very Deep ConvNet Architectures

■ Small kernels, not much subsampling (fractional subsampling).


VGG



GoogLeNet




ResNet



Kernels: Layer 1 (11x11)


Y LeCun

Layer 1: 3x96 kernels, RGB->96 feature maps, 11x11 Kernels, stride 4




Deep Learning = Learning Hierarchical Representations

■ It's deep if it has more than one stage of non-linear feature transformation



Feature visualization of convolutional net trained on ImageNet from [Zeiler & Fergus 2013]


Architecture of Alex Krizhevsky et al.



Des résultats impressionnants

- VISION (leçon inaugurale Yann Lecun, college de France, 2016) :
 - Scene parsing, reconnaissance d'objet, segmentation et reconnaissance, production d'images, de texte etc...
- Reconnaissance parole
- Médecine
- Traitement langage naturel, voiture autonome
- **Video, scene parsing,**





Des difficultés

- **Problèmes statistiques**

- Nécessité de grandes quantités de données pour apprendre beaucoup de paramètres
- Mais trop de paramètres libres peut nuire à la capacité de généralisation
- Données rares, outliers

- **Optimisation**

- **Problème d'explicabilité**

- On ne peut pas expliquer **pourquoi** un réseau a pris cette décision
- Analyse des couches cachées

- **Qualité des données**, données manquantes, bruitées, incertaines

- **Fiabilité, reproductibilité** des algorithmes d'apprentissage machine

Corrélation et causalité

- « Le tabagisme est corrélé à l'alcoolisme, mais ne cause pas l'alcoolisme. Alors que le tabagisme entraîne une augmentation du risque de développer un cancer du poumon »
- « The Deluge of Spurious Correlations in Big Data », S. Calude and G. Longo, CNRS, 2016
 - Les corrélations sont utiles à cause de leur pouvoir prédictif potentiel (on agit sur une variable pour prédire ou modifier la valeur d'une autre)
 - La corrélation n'explique pas "pourquoi" les choses évoluent ensemble.
 - Dans les grandes bases de données la corrélation dépasse la causalité.
 - Les corrélations falacieuses sont extrêmement présentes dans les grandes bases de données
 - Plus on a d'information, plus il est difficile d'en extraire du sens
 - Les données ne parlent pas pour elles-mêmes.
 - Danger de laisser la recherche de corrélation remplacer l'approche scientifique

4 éléments manquants en IA (au-delà du calcul)

Compréhension théorique de l'apprentissage profond

Quelle est la géométrie de la fonction objectif dans les réseaux profonds ?

Pourquoi l'architecture ConvNet fonctionne-t-elle si bien ?

[Mallat, Bruna, Tygert...]

Intégrer la représentation/apprentissage profond avec le raisonnement, l'attention, la planification et la mémoire

Beaucoup de travaux récents sur l'apprentissage des algorithmes » pour le raisonnement/la planification, l'attention, la mémoire

Intégrer l'apprentissage supervisé, non supervisé et de renforcement dans un seul "algorithme"

Trouver des moyens efficaces de faire de l'apprentissage non supervisé

Découvrir la structure et les régularités du monde en l'observant et en y vivant comme le font les animaux et les humains.

IA et Santé

- L'IA permet d'augmenter les capacités cognitives des médecins pour les aider à mieux prendre en charge leur patients
- Par exemple l'IA permet d'analyser des images médicales très complexes en prenant en compte des masses de données considérables qu'aucun cerveau humain ne peut appréhender en totalité.

Fév. 2017

Dermatologie



- **réseaux de neurones profonds**
- **Classification** de lésions bénignes vs. cancéreuses
- **performances** = dermatologues confirmés.
- **Pré-entraînement:**
1.3 Million d'images naturelles
- **Apprentissage final :**
 - ~130.000 lésions couvrant 2000 pathologies




<https://cs.stanford.edu/people/esteva/nature/>

N. Ayache
19 juin 2018

IA et patient numérique

Juin 2017

Radiologie



Courtesy of Therapixel



The Digital Mammography DREAM Challenge

Therapixel

Apprentissage : ~640.000 mammographies

1.200+ participants



Ophtalmologie

Fév. 2018

ARTICLES

<https://doi.org/10.1038/s41551-018-0195-0>

nature
biomedical engineering

Prediction of cardiovascular risk factors from retinal fundus photographs via deep learning

- Apprentissage : ~300 000 patients

Déc. 2016


JAMA | Original Investigation | INNOVATIONS IN HEALTH CARE DELIVERY

Development and Validation of a Deep Learning Algorithm for Detection of Diabetic Retinopathy in Retinal Fundus Photographs

- Apprentissage : ~130 000 patients

N. Ayache
19 juin 2018

IA et patient numérique



IDx-DR
FDA Approved
April 2018

informatiques mathématiques
Inria

Détection de rétinopathie diabétique

- Différents types de lésions.
- Objectif : détection précoce de rétinopathie, collaboration avec des médecins, génération d'alarmes
- Etat de l'art : réseau « global » , « boîte noire de prédiction »
- Notre approche : localisation et prédiction
- Besoin de données étiquetées, les médecins ne sont pas toujours d'accord

Automated detection of Diabetic Retinopathy

Gabriel Tozatto Zago

IFES, Vitoria, Brazil

Diabetic retinopathy detection using red lesion localization and
convolutional neural networks

Gabriel Tozatto Zago^{a*}, Rodrigo Varejão Andreão^b, Bernadette Dorizzi^c, Evandro Ottoni
Teatini Salles^d

^a*Department of Control and Automation Engineering, Instituto Federal do Espírito Santo, Brazil*


^b*Department of Electrical Engineering, Instituto Federal do Espírito Santo, Brazil*

^c*SAMOVAR, CNRS, Télécom SudParis, IP Paris, 9 rue Charles Fourier, 91011 EVRY, France*

^d*Department of Electrical Engineering, Universidade Federal do Espírito Santo, Brazil*

' Computers in Biology and Medicine

- Diabetic retinopathy (DR) is a consequence of diabetes mellitus which manifests itself in the retina.



Normal Vision





Vision with Diabetic Retinopathy



This disease is one of the most frequent causes of visual impairment in developed countries and is the leading cause of new cases of blindness in the working age population.

Diabetic Patients




Nearly 75 people go blind every day as a consequence of DR even though treatment is available

Automatic computer-aided screening of DR is a highly investigated field. The motivation for creating reliable automatic DR screening systems is to reduce the manual effort of mass screening, which also raises a financial issue.




DR detection state of the art


- Very difficult problem because different types of lesion
- Classic image processing : one algorithm for each type of lesion-
Preprocessing, features selection, simple classification methods
- Different databases of various quality
- Different stages in the processing




Normal




Non-proliferative




Moderate non-proliferative



Severe non-proliferative



Proliferative



Macular edema

DR and Convolutional Deep Network

- A unique global system for all types of lesion
- Need for huge database but transfer learning is efficient
- Need of expertise from expert for labeling
- No explanation is provided by the system
- Industrial systems in use for prevention

Our contribution

- Objective: early detection of retinopathy, collaboration with doctors, generation of alarms.
- State of the art: "global" network, "black box of prediction".
- Our approach: localisation and prediction
- Need labeled data, doctors don't always agree

Annotating the database





Figure 2 - DIARETDB1 (a) retinal image and ground truths. For each kind of evaluated lesion, the database provides a ground truth image composed by the superposition of each expert's annotation. Figure (b) shows hemorrhages ground truth, and (c) red small dots ground truth. The brighter the dots appear, the more the experts agree.

Proposed Model



Examples of model's lesion detection




Figure 9 - Qualitative results of the red lesion localization. Both images are composed of the original retinal image with the output of our approach superimposed and the localized lesions highlighted. The regions delimited by red squares are shown in detail at the right side of the retinal image. Figure (a) shows a false-positive example which is an intersection between blood vessels and (b) three true-positive examples.

Comparative results (messidor dataset)

Method	DR screening	
	AUC (95% CI)	Se (95% CI)
Experts		
Expert A [11]	.922 (.902-.936)	.945
Expert B [11]	.865 (.789-.925)	.912
Classical image processing		
Sánchez, et al. [11]	.876 (.856-.895)	.922
Rocha, et al. ^a [12]	-	-
Giancardo, et al. [37]	.854	-
Zhang, et al. [14]	-	-
Seoud, et al. [15]	.899	.939
Deep learning		
Orlando, et al. [21]	.893 (.875-.912)	.916 (.894-.943)
This work	.912 (.897-.928)	.940 (.921-.959)

Detection results (several database)

DR screening		
Dataset	AUC (95% CI)	Se (95% CI) ($Sp = 50\%$)
Messidor	.912 (.897-.928)	.940 (.921-.959)
Kaggle*	.764 (.756-.773)	.911 (.800-.823)
IDRiD	.818 (.742-.898)	.841 (.753-.948)
DDR	.848 (.836-.861)	.891 (.875-.908)
DIARETDB0	.786 (.713-.875)	.821 (.743-.969)

* Per subject evaluation

distributions can be seen in Figure 7. From Table 5, we observe that our model provides a Se superior to 80% in all the databases. Given that the international guidelines recommend a sensitivity ranging from 60% to 80% for DR screening [35], [36], our results suggest that our approach can be used in a real scenario for DR screening with the ability of greatly reducing the burden of experts in triage programs.

Comparative Results with other CNN approaches

Method	AUC (95% CI)	Se (95% CI)	Sp (95% CI)	Number of training images
Abràmoff, et al. [16]	.980 (.968-.992)	.968 (.933-.988)	.870 (.842-.894)	1,250,000
Gulshan, et al. [42]	.990 (.986-.995)	.961 (.924-.983)	.939 (.924-.953)	128,175
Gargeya, et al. [18]	.940	.930	.87	75,137
This work	.944 (.925-.966)	.900 (.860-.961)	.87 (.863-.871)	28

Conclusions

L'apprentissage profond permet une nouvelle vague d'applications

Aujourd'hui : Reconnaissance d'images, compréhension vidéo

Aujourd'hui : Meilleure reconnaissance de la parole :

Bientôt : Meilleure compréhension des langues, dialogue et traduction

Les réseaux d'apprentissage profond et les réseaux convolutifs sont aujourd'hui largement déployés :

compréhension de l'image sur Facebook, Google, Twitter, Microsoft....

Bientôt : de meilleurs pilotes automatiques pour les voitures, l'analyse d'images médicales, la perception des robots

Besoin de matériel (et de logiciels) pour les applications embarquées

Pour les caméras intelligentes, les appareils mobiles, les voitures, les robots, les jeux...

On est encore loin de construire des machines vraiment intelligentes

Nous devons intégrer le raisonnement à l'apprentissage profond

Nous avons besoin d'une bonne architecture pour la mémoire "épisodique" (à court terme).

Nous devons trouver de bons principes pour l'apprentissage non supervisé

L'analyse de données statistiques ne remplacera pas le besoin d'explication (approche scientifique)- corrélation versus causalité