

Sûreté de Fonctionnement

« Deep Learning : Forces, Faiblesses & Défis »

Master IRVEA

Année 2022/2023

Séance du 10 février 2023

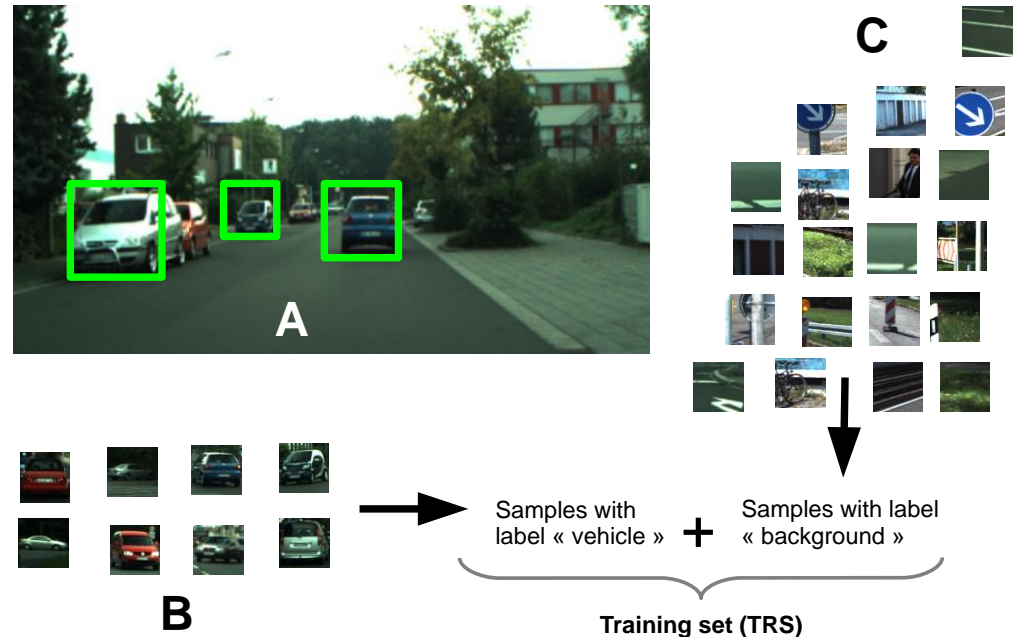
Présentation de l'Apprentissage & Du « Deep Learning »

A decorative graphic consisting of a solid teal horizontal bar, followed by a white horizontal bar, and then three thin, parallel white horizontal lines.

Apprentissage automatique

Apprentissage supervisé

- Construire une fonction $Y=f(X)$ à partir d'exemples
- Ex: Classification d'images




- En général pré-traitement des données -> caractéristiques

- Nombreux algorithmes : SVM, boosting, Réseaux de neurones ...

Apprentissage automatique

Autre types d'apprentissage

- Non supervisé :
recherche de structure
dans les données
- Par renforcement :
recherche de comportement
optimisant un cout par
essais/erreurs




Réseaux de neurones

Famille d'algorithmes (~1960)

- Neurones : unité de calcul élémentaire (somme + non linéarité)
- Réseau : neurones connectés par de
- Apprentissage : modification des po
- Méthode : descente de gradient

Différentes structures

- Perceptron multi-couches (Feed for
- Réseaux récurrents
- Extrême learning machines
-



Deep Learning

Retour des réseaux de neurones (~2006)


- Perceptron avec « beaucoup » de couches
- Ex: Resnet -> 152 couches
- Base théorique *très* similaire aux perceptrons

Avantages

- Permet des fonctions plus compl
- Etat de l'art sur de nombreux pb.

Problèmes pré 2006


- Puissance de calcul nécessaire
- Apprentissage (min. locaux)
- Données d'apprentissage



Deep Learning : Forces

Excellentes performances applicatives, beaucoup d'applications

- Nombreuses tâches de vision : record en détection, reconnaissance
- Algorithmes de jeux
- Contrôle de robots
- Reconnaissance de la parole
- Traduction automatique
- Description d'images
- ...



Deep Learning : Faiblesses


Questions théoriques

- Choix des modèles largement empiriques
- Hyper-paramètres long et complexes à régler

Questions pratiques

- Pas d'interprétation probabiliste (estimation de la confiance)
- Exemples inquiétants (problème de validation)

Bus




Autruche



Deep Learning : Faiblesses

Questions pratiques

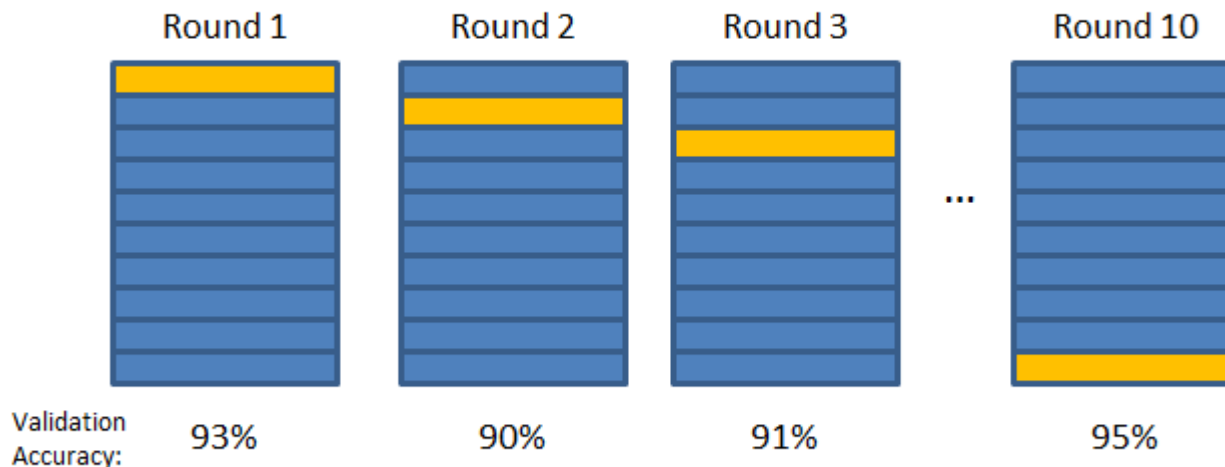

- Besoin de très grandes quantité de données
 - Réseaux entraînés sur ImageNet (14 million d'images)
 - Mobileye emploie 500 personnes pour annoter des données
- Puissance de calcul
 - Utilisation extensive de GPU
 - Couteux en embarqué
 - Circuits dédiés



Deep Learning : Applications

Validation des performances

- Pas de possibilité de valider dans l'absolu
- Validation possible sur un jeu de test
- Besoin de beaucoup de données ou cross-validation



Final Accuracy = Average(Round 1, Round 2, ...)

Quand ne pas utiliser le deep-learning ?

Problèmes sur des données en petites dimensions

- Une force du deep learning est d'intégrer la détection de caractéristiques pour des données complexes (images, flux audio), ce n'est pas forcément utile
- Exemples :
 - classifications de données statiques simples (télémétrie, gestion de stocks)
 - Problèmes pour lesquels les caractéristiques pertinentes sont connues/simples (détection d'objets connus dans un cadre contraint)
- Alternatives possibles:
 - Séparateurs à Vaste Marge (SVM)
 - Forêt d'arbre aléatoires (Random Forest)
 - Boosting

Quand ne pas utiliser le deep-learning ?

Problèmes pour lesquels l'analyse de la solution est intéressante

- Le deep learning fournit des réseaux de grande taille, souvent difficilement analysables
- La sortie du réseau n'est en général pas interprétable en terme de probabilité
- Pour des problèmes de petites tailles, il peut être utile de comprendre sur quoi se base le résultat et connaître son incertitude
- Alternatives
 - Processus Gaussiens: donnent une solution avec une variance associée
 - Réseaux Bayésien : fournissent un modèle explicite des dépendances entre variables et permettent d'expliquer sur quoi repose le résultat

Quand ne pas utiliser le deep-learning ?

Problème ou la performance n'est pas critique

- Sur certains problèmes, le gain du deep learning peut être réel mais faible au regard de son coût de calcul
- Exemple:
 - Classification de chiffres manuscrits sur la base de données MNIST
 - Meilleur modèle SVM : 0,56% d'erreur
 - Meilleur modèle Deep Learning : 0,23% d'erreur
 - Gain de 0,33% pour un coût computationnel > 10x
- Alternatives
 - Boosting/cascades
 - Forêt d'arbres aléatoires (Random Forest)

Problematiques d'Implantations et de Validations



Deep Learning : Implémentation

Principe de mise-en-œuvre

- **Entraînement du système :**
 - Détermination des coefficients par exposition à de très grands échantillons de données de plusieurs millions à plusieurs milliards de paramètres à ajuster.
- **Déploiement et calcul :**
 - Calcul en temps-réel
 - Nombre de calculs importants sur des réseaux profonds et des structures complexes.

Possibilité de scinder les plateformes :
Une plateforme d'apprentissage
Une plateforme de reconnaissance

Deep Learning : Implémentation

Spécificité du Deep Neural Network

- Recours à des modèles de réseaux de neurones impliquant une même opération sur un ensemble de neurones (ex: CNN)
- Possibilité de paralléliser par des GPU
- Repose sur des multiplications de matrices
- Ne requiert pas systématiquement une précision importante.

DNN et conception modulaire

- Principe de boîte à outils de différents modèles de réseaux de neurones adaptés à certaines classes de problèmes.
- Principe de modèle de composition entre les différentes couches et sous-réseaux.

Deep Learning : Implémentation

Utilisation de Hardware Spécifique

- GPU : accélération notable de l'ensemble des opérations matricielles, convolution...
- DSP : accélération des calculs, modèle VLIW.
- FPGA : synthèse de réseau au niveau du composant ou accélérateur de calcul lors de l'apprentissage.
- TPU (Tensor Processor Unit) : ASIC ad hoc pour augmenter le débit des opérations
 - Réduction de la précision de calcul
 - Optimisation du flot d'échange de données
 - Minimisation du contrôle
 - Hybride SIMD et VLIW

Deep Learning : Implémentation

Forces & Faiblesse des briques hardware

- CPU : Faible ratio Performance/Watt.
- GPU : Ratio Performance/Watt élevé.
Accélération des phases d'apprentissage et des phases de déploiement.
Adapté plus à certains types de réseau.
Speedup : x160 pour 130 W, Tesla K40, DnnWeaver
- FPGA : Ratio Performance/Watt élevé (voir très élevé)
Configuration différente entre apprentissage et déploiement.
Possibilité de « synthétise » le réseau sur le composant.
Plus flexible mais plus complexe à mettre en œuvre.
Speedup : x45 pour 25 W, Arria 10 DnnWeaver
- TPU : Usage pour l'instant uniquement dans la phase de déploiement. Technologie propriétaire adaptée à un Framework.

Deep Learning : Implémentation

Tendances actuelles (au niveau matériel)

- GPU : évolution des GPU pour prendre en compte les DNN et les DCN.

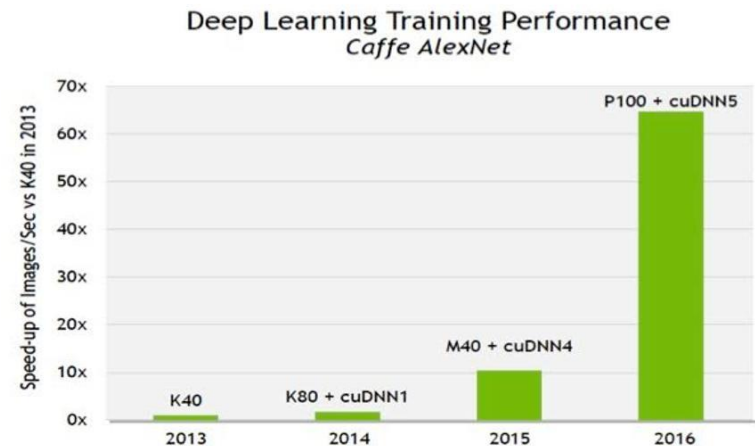
Augmentation des débits et du nombre de Teraflops

Accélération d'un facteur 50
dans les 3 dernières années !

Diminution des latences
et Augmentation du Débit

Enveloppe énergétique
reste élevée.

- **Démonstrabilité du
comportement Complexe**



AlexNet training throughput based on 20 iterations,
CPU: 1x E5-2680v3 12 Core 2.5GHz, 128GB System Memory, Ubuntu 14.04
M40 bar: 8x M40 GPUs in a node
P100: 8x P100 NVLink-enabled

Deep Learning : Implémentation

- Tendances actuelles (au niveau matériel)
 - CPU : Architecture ManyCore.
Augmentation de l'efficacité énergétique
Amélioration des Interconnexions
Difficilement Qualifiable en termes de SdF
 - FPGA : intégration Processeur + FPGA pour SOC
DSP sur FPGA
Développement d'outils de synthèses adaptés au DNN et DCN.
Enveloppe énergétique modérée.
Problématique de qualification de l'implantation sur FPGA
Utilisation de Cœurs Démonstrables & Temps-réels



Deep Learning : Développement

Emergence de nombreuses solutions d'implantations
Attention 3 phases dans le développement :



Prototype



Apprentissage



Déploiement

Avec des contraintes, des acteurs et des normes différentes.

Deep Learning : Validation

Problèmes :

- Aucune garantie sur la qualité du résultat.
- Absence de « sûreté intrinsèque »

Problèmes complémentaires :

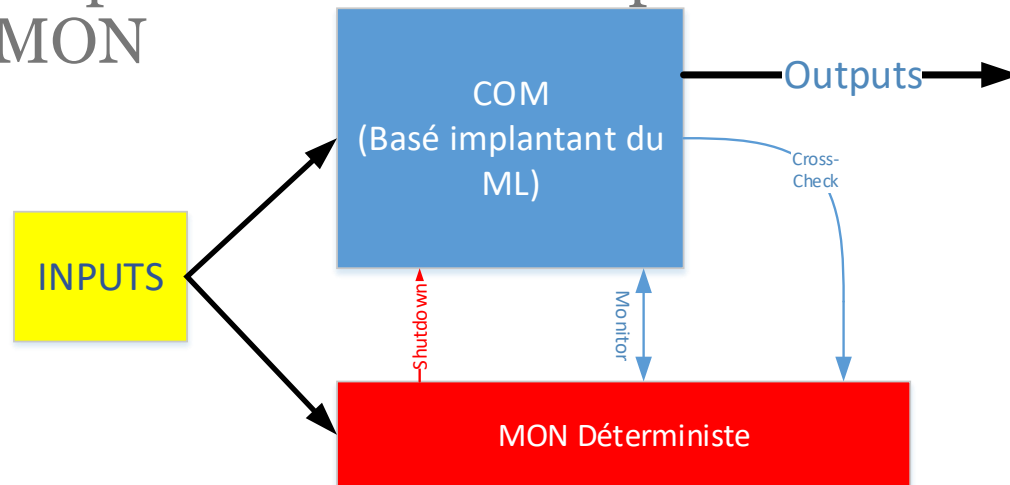
- Apprentissage en ligne : comportement se modifiant dans le temps ? Comment qualifier ?
- Rédaction du code, des bibliothèques (conformité avec Misra C/C++?)

La validation d'un tel algorithme est un problème ouvert à ce jour !

Deep Learning : Validation – Solutions explorées

Architecture de Systèmes basées sur l'autonomie décisionnelle

- Disposer pour chacune des opérations d'une approche COM-MON



Défis


- Disposer pour les opérations d'un algorithme de vérification de pertinence de la solution.

Deep Learning : Validation – Solutions explorées

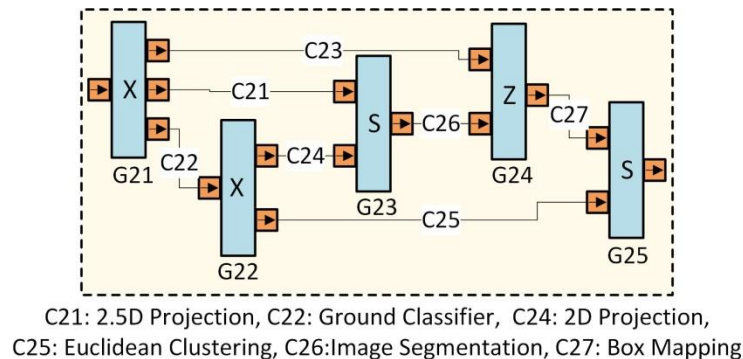

Nécessité d'une approche Model-Based compositionnelle combinant plusieurs flots de traitement



Test Vehicle



Tracking Results



Conclusions

- Le « Machine Learning » ouvre des opportunités nouvelles
 - Efficacité
 - Qualité des solutions
- Le « Machine Learning » pose des problèmes en termes de validation
 - Niveau Logiciel
 - Algorithmes non-déterministes
 - Aucune garantie sur la pertinence des solutions
 - Impossible de qualifier le code
 - Niveau matériel
 - Briques de calcul complexes fortement parallèles
- L'implantation du « Machine Learning » impose de repenser la validation
 - Au niveau Système
 - Au niveau « Exigences de Vérifications »

« SYSTEMES AUTONOMES, VALIDATION & QUALIFICATION »

Master IRVEA

Année 2021/2022

Séance du 7 avril 2022

Différences entre Systèmes Autonomes & Systèmes Automatisés (1)

- Un système automatisé
 - Connaissance a priori de son environnement
 - Connaissance des règles de prise de décision
 - Si vecteur X en entrée, vecteur Y pour action en sortie
 - Reproductibilité de la décision

Différences entre Systèmes Autonomes & Systèmes Automatisés (2)

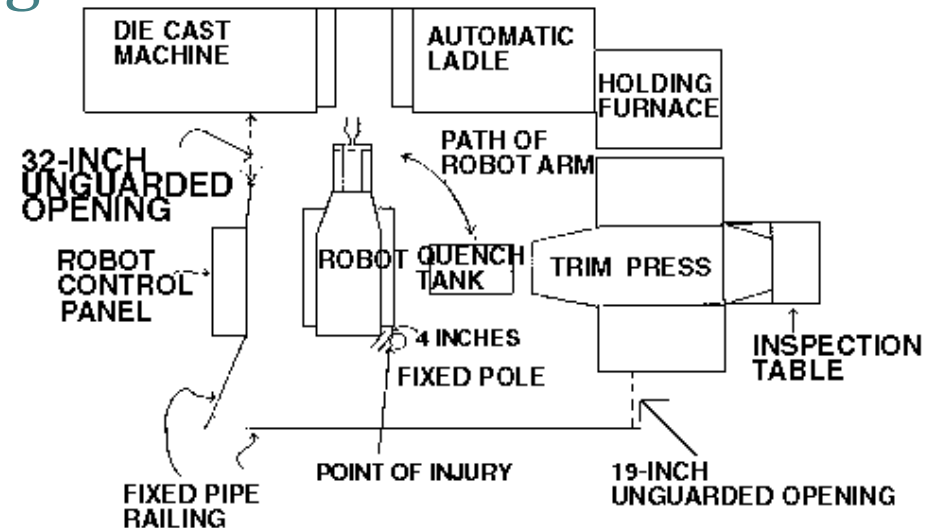

- Un Système Autonome
 - Absence de connaissance a priori de l'environnement
 - Règles de prise de décision
 - Soit déterministe, pour une situation donnée, génération de la même décision
 - Soit non-déterministe, pour une situation donnée, génération de plusieurs décisions possibles
 - Problème de l'explicabilité de la décision
 - Explicable : il est possible de comprendre le calcul ayant conduit à la décision
 - Non-Explicable : la n'est pas possible d'inférer le pourquoi de la décision a posteriori.

Limites des systèmes automatisés

- **Environnement prédéfini**
 - Ontologie permettant de caractériser les informations à posséder et à réaliser.
 - Ensemble de capteurs/estimateurs nécessaires à la détermination des informations pertinentes
 - Ensemble des actionneurs nécessaires à la réalisation des opérations nécessaires.
- **Décision**
 - Identification du domaine de validité du moteur de décision
 - Capacité de détecter les sorties de domaine => mise en sécurité du système.

Origine des fautes dans les Systèmes Automatisés (1)

- Violation d'une contrainte de fonctionnement
 - Ex: obstacle sur la voie quand la voie est supposée vide.
 - Ex: non-respect d'une règle d'exploitation.



Origine des fautes dans les Systèmes Automatisés (2)

- Flux d'informations erronées
 - Dysfonctionnement d'un capteur, d'un estimateur de mesure.
 - Corruption de données.
 - Injection de fausses données
- Erreur de prise de décision
 - Erreur d'implantation logicielle (Ariane 501)
 - Erreur de la logique de prise de décision



Origine des fautes dans les Systèmes Automatisés (2)

- Défaillance de l'interaction « Homme-Machine »
 - Confusion (Mauvaise Analyse ou mauvaise compréhension des informations)
 - Mauvaise interaction
 - Mauvaise décision



Validation & Vérification des Systèmes Automatisés (1)

- Validation & Vérification du bon fonctionnement
 - Tests sur un ensemble de scénarii représentatifs.
 - Preuves formelles si nécessaires.
- Règles d'exploitation
 - Garantir l'absence de violation du domaine d'exploitation
- Mise en place de systèmes de protections
 - Prévenir les violations des règles d'exploitation.
 - Identifier les violations et mettre en sécurité.
 - Monitorer les prises de décisions.

Validation & Vérification des Systèmes Automatisés (2)

- Améliorer le design en fonction de l'incidentologie
 - Analyse des défaillances, natures
 - Prise en compte dans le système ou ses évolutions
- Bilan:
 - Concevoir un Système Automatisé est maîtrisé mais peut-être très coûteux.
 - La concurrence des fonctions automatisés peut conduire à l'émergence de comportements non-désirables qui doivent être identifiés lors de la conception.


Quand parlons nous de Systèmes Autonomes

- Augmentation de la capacité à prendre une décision
 - Dans un environnement « nouveau », des conditions « nouvelles ».
 - Dans un environnement complexe (nombres d'interactions importants, acteurs de nature différentes).
- La décision peut-être :
 - Prédéfinie (ie. l'algorithme n'évolue pas dans le temps).
 - Conditionnée (par un apprentissage par exemple).


Les Systèmes Autonomes & l'IA

- Systèmes Autonomes n'impliquent pas IA
 - Peut effectuer des traitements complexes sans IO
 - Traitement & analyse d'images
 - Traitement du signal
 - Peut prendre une décision sans IA
 - Système expert (Rule Based)
 - MDP
 - ...
 - Intérêt de l'IA pour les systèmes autonomes
 - Richesse et performance de l'analyse de la décision.
 - Simplification de l'implantation !
 - Apprentissage peut-être plus « simple » que développer un algorithme de contrôle-commande complexe de coordination par exemple.

Apprentissage par Renforcement & Génération de contrôleurs



Cependant l'erreur est aussi « Robotique »



Origine des Fautes dans les Systèmes Autonomes

**TOUTES LES FAUTES DES
SYSTEMES AUTOMATISES**

+

**TOUTES LES FAUTES LIEES A
LA PRISE DE DECISION EN
ENVIRONNEMENT INCERTAIN**

Problème de la décision dans les Systèmes Autonomes

- Comment caractérise-t-on une bonne décision ?
 - En terme de performances ?
 - En terme d'occurrence de risques ?
 - En terme d'éthique ?
- Comment mesure-t-on la performance d'une décision ?
 - Vitesse d'exécution ?
 - Perception par rapport à ce que ferait l'humain ?
 - Coût/Bénéfice ?

Problème : Optimisation multicritère

- Optimiser la performance
 - Possibilité de rouler sur une route de 2m de large à 200 km/h
 - Problème: Survenance d'une défaillance d'un pneumatique ?
- Optimiser la safety
 - Prendre en compte l'ensemble des événements quelqu'en soit l'occurrence
 - Problème: comportement « sous-efficace », éventuellement comportement aberrant.
- Optimiser la consommation
- Optimiser la perception sensorielle

Pistes pour définir la qualité d'une décision

- Prendre une « bonne décision humaine » comme référence :
 - Satisfaisante relativement au niveau de prise de risques.
 - Performantes par rapport au critère des « opérateurs qualifiés ».
 - Répondant aux attentes :
 - En terme de confiance,
 - En terme d'appréciation subjective.
 - S'appréciant dans un domaine normatif donné.

Piste pour définir la qualité d'une décision

- Mesurer la différence entre la décision proposée par le système et celle proposée par l'humain
 - Simple dans le cas de jeux
- Plus délicate dans les cas complexes comme :
 - Copilote virtuel
 - Véhicule Autonome



Problématique de la métrique de la performance

- Exemple : Véhicule Autonome
 - Métrique actuelle : nombres d'accidents par millions de km parcourus.
- Limite de la métrique
 - Ne prend pas en compte les défaillances systémiques (a priori sans objet pour l'humain).
 - Ne prend pas en compte la notion de performance de la conduite, son intégration.
 - Ne prend pas en compte la QoS de la conduite autonome.
 - Ne prend pas en compte les variétés de missions réalisées par le véhicule.

Problématique de la mesure de la métrique

- Qualification « a priori »
 - L'estimation de la mesure doit être réalisée a priori.
 - **Problème :**
 - Si la métrique consiste à un nombre de kms parcourus sans accident, comment effectuer ces tests ?
 - Si la métrique consiste en un certain nombre de situations à gérer, comment effectuer ces tests ?

Les problèmes de la décision

- Performances d'un système type reconnaissance de chiffres manuscrits (obtenu par mesure sur un dataset)
 - **Meilleur algorithme** : 0,23% (Deep Learning)
- Problème :
 - Comparaison avec l'humain (à peu près au même niveau de non reconnaissance)
 - L'humain peut prendre une décision supplémentaire
 - Je ne sais pas déchiffrer.
 - Prise en compte de l'évolution de l'écriture dans le temps.
- Performance bien plus mauvaise pour l'analyse de situation plus complexe
 - 80 à 90 % de reconnaissance des objets dans les meilleurs situations.

Les premières réponses (1)

- La validation par les tests réels
 - Mise en condition réelle.
 - Comparer le niveau de performance avec la performance humaine.
 - Estimer le delta objectif et subjectif.
- Limites
 - Uniquement quelques scénarii.
 - Uniquement quelques contextes.


Les premières réponses (2)

- **La validation par simulation**
 - Réaliser un ensemble de tests dans un simulateur.
 - Comparer le niveau de performance avec la performance humaine.
 - Estimer le delta objectif et subjectif.
- **Avantages**
 - Réalisation de nombreuses situations.
 - Coût d'évaluation plus modéré.
- **Limites**
 - Biais induit par l'environnement simulé.
 - Uniquement quelques contextes.

Le biais induit par la simulation

- Différence Environnement simulé/Environnement réel
 - Moins de variabilité.
 - Moins d'information.
 - Structure répétitive.
 - Biais induit sur les capteurs.
- Génération de situations pertinentes/représentatives
 - Simulation de situations dangereuses uniquement -> Difficilement comparable en terme d'accident par km parcourus.
 - Simulation aléatoire de parcours -> problème de représentativité du parcours.

Monde virtuel / Monde réel



Les approches formelles

- **Stabilité de de la réponse** : deux situations relativement proches doivent engendrer la même décision
- Comment garantir une telle stabilité de réponse ?
 - Deep Neural Network : a priori pas de solution lors de la conception.
- Proposition:
 - Introduire un modèle formel approché du modèle de réseaux de neurones employés vérifiant que toute propriété de stabilité dans le modèle formel est correct dans le modèle approché.
 - Démontrer la stabilité du modèle approché
 - En déduire la stabilité du modèle implanté.
- Limite / Défaut
 - Force de l'IA : tenir compte des signaux faibles.
Risque de masquer certains signaux faibles pour conserver la stabilité.

Les approches systèmes

- Panacher plusieurs systèmes de prise de décision [Diversité d'implantation]
- Adjoindre pour chacune des chaînes de prise de décision un estimateur de confiance [Moniteur de QoS]
- Effectuer un vote sur la solution en prenant les différences entre les solutions pondérées par l'estimateur de confiance dans la solution. [Générateur de décision/Détection d'une absence de capacité à répondre]

Les problèmes résiduels

Absence de solutions « satisfaisantes »

« La voiture autonome sera-t-elle programmée pour tuer son conducteur ? »

Pour éviter une collision imminente avec une foule de personnes, quelle décision ?

- **braquer brusquement** au risque de **tuer son conducteur ...**
- continuer et **percuter** la foule ?

Conclusions (1)

- Nécessité de développer une quantification de la performances de la décision
 - Définition de nouvelles métriques.
 - Définition de nouvelles méthodes de tests pour estimer cette performance.
 - Comparaison de la métrique humaine vs. la métrique système
- Séparer les deux problématiques de l'implantation et de la décision
 - L'implantation -> Problématique des Systèmes Automatisés
 - La qualification de la décision -> Problématique de la qualité de la décision, validation de celle-ci (à développer)

Conclusions (2)

- Définir la notion de GAME entre Décision d'un Système Autonome et Décision Humaine.
- Développer une nouvelle incidencetologie
 - Distinguer Erreur de Décision/Défaillance de l'implantation.